



**SNPTEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

GSE - 12
16 a 21 Outubro de 2005
Curitiba - Paraná

**GRUPO VIII
GRUPO DE ESTUDO DE SUBESTAÇÕES E EQUIPAMENTOS ELÉTRICOS - GSE**

**DIAGNÓSTICO DE FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA – MELHORANDO A
NORMA IEC 60599 COM REGRAS DESCOBERTAS EM REDES NEURAIS**

Adriana Rosa Garcez Castro

NESC – UFPA

Vladimiro Miranda*

INESC Porto e FEUP, Portugal

RESUMO

O transformador é um dos equipamentos de maior importância dentro de um sistema de potência e a sua correta operação é decisiva para o funcionamento seguro do sistema. Atualmente, o diagnóstico dos transformadores é baseado fortemente nas técnicas de Análise dos Gases Dissolvidos no óleo. A tentativa de produção de um diagnóstico confiável têm conduzido a numerosos estudos, nos quais destacamos o que resultou no documento IEC 60599. Este artigo apresenta uma nova metodologia designada TFRENN que casa redes neurais com lógica difusa. Com esta metodologia, foi possível desenvolver um sistema inteligente e uma nova tabela de indicação de diagnóstico produzindo resultados com menos erros que o método preconizado na norma IEC.

PALAVRAS-CHAVE

Diagnóstico de transformadores, sistemas inteligentes, redes neurais, lógica difusa.

1.0 - INTRODUÇÃO

Já é bastante conhecido que as faltas no transformador, principalmente na forma de descargas parciais, arco elétrico ou sobreaquecimento, desenvolvem certos gases de hidrocarbono os quais são retidos no óleo isolante como gases dissolvidos. A concentração, proporção relativa e taxa de geração destes gases vêm sendo extensivamente utilizadas para a estimação da condição do transformador. Métodos tais como Dornenburg, Roger E IEC são comumente utilizados pelas empresas de energia. Contudo, a análise dos gases e interpretação de seus significados pode ser considerada, em certo grau, uma arte sujeita a variabilidade. Logo, a procura por métodos eficientes utilizando a informação da concentração dos gases dissolvidos em óleo é considerada ainda um tópico de grande interesse.

Alguns estudos têm mostrado a eficiência e dificuldades da utilização de redes neurais e lógica difusa [1-3] para o desenvolvimento de sistemas inteligentes de diagnóstico de transformadores. Nos sistemas desenvolvidos baseados em lógica difusa a proporção dos gases têm sido fuzziificada para representar a natureza vaga da análise baseada em gases dissolvidos em óleo (DGA). Os sistemas difusos são em geral construídos de acordo com os métodos baseados em DGA e a eficiência do sistema inteligente de diagnóstico depende muito do conhecimento complementar do especialista da área.

Para sobrepor as desvantagens dos sistemas difusos, alguns trabalhos utilizando redes neurais para o diagnóstico de transformadores vêm sendo desenvolvidos. Embora as redes neurais sejam reconhecidas por sua alta capacidade de expressar as relações entre as variáveis de um problema, por um número de razões, existe ainda uma certa desconfiança por parte das empresas na sua utilização. Um freqüente argumento é que as redes neurais não apresentam capacidade de explanação. De uma certa maneira, este argumento pode ser considerado válido. Em alguns casos, redes neurais são suficientes e não existe a necessidade de que o conhecimento

* INESC Porto, Campus da FEUP – R. Dr. Roberto Frias 378 – 4200-465 Porto - PORTUGAL
Tel: +351222094049 - Fax: +351222094005 - e-mail: vmiranda@inescporto.pt

aprendido durante o treinamento esteja explícito. Entretanto, existem casos em que isto se torna necessário. Um bom exemplo diz respeito exatamente aos sistemas de diagnóstico de transformadores. Se as relações entre as variáveis do sistema aprendidas durante o treinamento da rede forem totalmente explícitas, os engenheiros e técnicos do sistema poderão, além de compreender melhor o sistema, ganhar mais confiança no diagnóstico final produzido.

Visando então aliar as vantagens oferecidas por ambos os métodos, redes neurais e lógica difusa, e suprir as desvantagens dos mesmos, este artigo apresenta uma nova metodologia, chamada TFRENN (Extração de regras difusas transparentes de redes neurais), que será aplicada para o desenvolvimento do sistema de diagnóstico de faltas incipientes em transformadores.

A metodologia TFRENN foi desenvolvida com o principal objetivo de extrair regras difusas transparentes de redes neurais. A importância de se obter regras transparentes deve ser ressaltada devido ao fato de que estas permitem uma completa compreensão, por parte dos seres humanos, do conhecimento capturado pela rede neural treinada para um determinado problema.

A aplicação da metodologia permitiu o desenvolvimento de uma mais eficiente ferramenta para o diagnóstico de faltas, com resultados superiores aos já publicados usando técnicas semelhantes. Adicionalmente, esta técnica permitiu ainda a descoberta de novas regras para classificação de faltas, as quais proporcionaram a construção de uma nova tabela para diagnóstico de faltas, útil em aplicações práticas. Os resultados para esta nova tabela, assim como os resultados do sistema de diagnóstico inteligente, mostraram-se superiores aos apresentados pela tabela publicada pelo IEC, que é atualmente uma das mais utilizadas para diagnóstico de faltas incipientes em transformadores.

Uma breve introdução da metodologia TFRENN, o sistema inteligente de diagnóstico desenvolvido e alguns resultados comparativos são apresentados nas próximas seções.

2.0 - METODOLOGIA TFRENN

A Figura 1 apresenta a topologia da rede neural na qual a metodologia TFRENN para extração de regras difusas pode ser aplicada.




FIGURA 1 – Topologia da Rede Neural Artificial

Basicamente, a metodologia TFRENN permite que todo conhecimento aprendido por uma rede neural do tipo da Figura 1, treinada com determinadas restrições e considerando apenas uma saída, seja extraído em formas de regras difusas transparentes do tipo:

- R_1 : Se x_1 é pequeno E x_2 é grande E x_3 é médio ENTÃO $y_1 = a_1$
 R_2 : Se x_1 é médio E x_2 é grande E x_3 é pequeno ENTÃO $y_2 = a_2$
 \vdots
 R_n : Se x_1 é pequeno E x_2 é muito pequeno E x_3 é médio ENTÃO $y_n = a_n$

Sendo a saída do sistema dada por:

$$y = b - \sum_{j=1}^n y_j v_j \quad (1)$$

onde b é definido como o valor *default* do sistema difuso e v_j o valor de ativação da j -ésima regra.

As funções de pertinência do sistema difuso extraído da rede neural podem ser vistas na Figura 2.

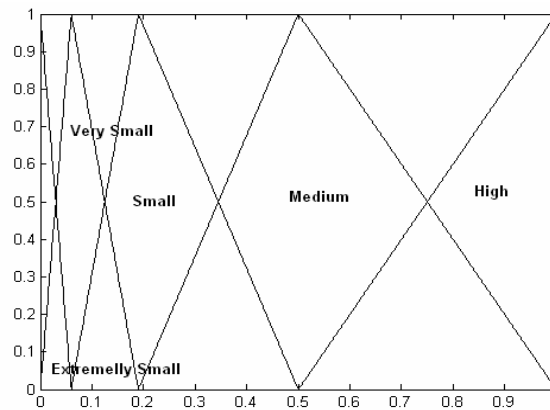


FIGURA 2 – Funções de pertinência do sistema difuso transparente

Todos os detalhes da metodologia TFRENN estão descritos em [4] a [7].

3.0 - DIAGNÓSTICO DE FALTAS EM TRANSFORMADORES

3.1 Sistema de Diagnóstico proposto

Muitos métodos para a detecção da possível falta em um transformador usando as medidas dos gases dissolvidos em óleo, já estão bem estabelecidos. A Tabela 1 apresenta o critério IEC 60599 largamente usado para diagnóstico de faltas [8].

TABELA 1 – critério IEC 60599

Caso	Falta	$\frac{C_2H_2}{C_2H_4}$	$\frac{CH_4}{H_2}$	$\frac{C_2H_4}{C_2H_6}$
PD	Descarga Parcial	NS	<0.1	<0.2
D1	Descarga de baixa energia	>1	0.1-0.5	>1
D2	Descarga de alta energia	0.6-2.5	0.1-1	>2
T1	Falta térmica $T < 300\text{ }^\circ\text{C}$	NS	>1 mas NS	<1
T2	Falta térmica $300\text{ }^\circ\text{C} < T < 700\text{ }^\circ\text{C}$	<0.1	>1	1-4
T3	Falta térmica $T > 700\text{ }^\circ\text{C}$	<0.2	>1	>4

Nota - NS = valor não-significativo

Em nosso trabalho, assim como na tabela IEC, escolhemos como entradas para nosso sistema as razões:

$$\frac{C_2H_2}{C_2H_4}, \frac{CH_4}{H_2} \text{ e } \frac{C_2H_4}{C_2H_6}.$$

Uma rede neural do tipo da Figura 1 foi treinada então com 3 entradas e 1 saída. A rede foi treinada para classificar a falta no transformador em 5 tipos de acordo com nosso banco de dados (Tabela 2). O banco de dados é composto por dados de faltas de equipamentos inspecionados em serviço usados na publicação IEC 60599 [8]-[9]. Adicionalmente, dados fornecidos pela CELPA (Centrais Elétricas do Pará) e dados coletados da literatura também foram utilizados no banco de dados. Os dados foram divididos de tal forma que foram utilizados para treinamento e validação da rede neural.

Para classificação de faltas, a rede neural trabalha como uma função discriminante. Considerando que 5 tipos de faltas são utilizadas para o treinamento da rede neural, então 6 linhas discriminatórias são criadas em -0.5, 0.5, 1.5, 2.5, 3.5 e 4.5, e então a classificação das faltas é realizada de acordo com:

- Se a saída da RNA está entre $[-0.5 \ 0.5]$ então T1
- Se a saída da RNA está entre $[0.5 \ 1.5]$ então T2
- Se a saída da RNA está entre $[1.5 \ 2.5]$ então PD
- Se a saída da RNA está entre $[2.5 \ 3.5]$ então DL
- Se a saída da RNA está entre $[3.5 \ 4.5]$ então DH

TABELA 2 – Tipos de Falhas do Banco de dados

	Tipo de falta	Número de amostras
T1	Falta térmica - $T < 300^{\circ}\text{C}$	77
T2	Falta térmica - $T > 300^{\circ}\text{C}$	71
PD	Descarga Parcial (corona)	30
DL	Descarga de baixa energia	37
DH	Descarga de Alta Energia	103

Considerando que existem casos no banco de dados com características não bem definidas, após o treinamento da rede neural nós decidimos então *fuzzificar* a saída da mesma usando as funções de pertinência da Figura 3.




FIGURA 3 – Fuzzificação da saída da RNA (NI – não identificada)

Analisando a Figura 3, a *fuzzificação* da saída nos permite classificar o tipo de falta incipiente, por exemplo, como:

Diagnóstico:

Descarga de Alta Energia (DH) com possibilidade=0.65 ou Descarga de baixa energia (DL) com possibilidade = 0.35

Ou, por exemplo:

Diagnóstico:

Falta térmica (T1) $T < 300^{\circ}\text{C}$ com possibilidade=1

A *fuzzificação* da saída da RNA utilizando funções de pertinência trapezoidal nos permite formular casos com uma hipótese e casos de indecisão onde teremos duas hipóteses, sendo que a hipótese com menor valor de possibilidade não será descartada.

Após o treinamento da rede neural, a metodologia TFRENN pôde ser aplicada, de onde então 125 regras transparentes foram extraídas. Os tipos de regras extraídas podem ser vistas na Tabela 3.

TABELA 3 – Tipo de Regras Transparentes Extraídas da RNA

Regra 1	: SE (x1 is Extremamente Pequeno) E (x2 is Extremamente Pequeno) E (x3 is Extremamente Pequeno)	ENTÃO y1 = 2.0691
Regra 2	: SE (x1 is Extremamente Pequeno) E (x2 is Extremamente Pequeno) E (x3 is Muito Pequeno)	ENTÃO y2 = 1.9076
Regra 3	: SE (x1 is Extremamente Pequeno) E (x2 is Extremamente Pequeno) E (x3 is Pequeno)	ENTÃO y3 = 2.1377
Regra 4	: SE (x1 is Extremamente Pequeno) E (x2 is Extremamente Pequeno) E (x3 is Medium)	ENTÃO y4 = 2.6410
Regra 5	: SE (x1 is Extremamente Pequeno) E (x2 is Extremamente Pequeno) E (x3 is High)	ENTÃO y5 = 2.0093
Regra 6	: SE (x1 is Extremamente Pequeno) E (x2 is Muito Pequeno) E (x3 is Extremamente Pequeno)	ENTÃO y6 = 1.7228
Regra 7	: SE (x1 is Extremamente Pequeno) E (x2 is Muito Pequeno) E (x3 is Muito Pequeno)	ENTÃO y7 = 1.3173
Regra 8	: SE (x1 is Extremamente Pequeno) E (x2 is Muito Pequeno) E (x3 is Pequeno)	ENTÃO y8 = 1.3820
.		
.		
Rule 124	: SE (x1 is Alto) AND (x2 is Alto) AND (x3 is Médio)	ENTÃO y124 = 3.8561
Rule 125	: SE (x1 is Alto) AND (x2 is Alto) AND (x3 is Alto)	ENTÃO y125 = 4.2259

com $x_1 = \frac{C_2H_2}{C_2H_4}$, $x_2 = \frac{CH_4}{H_2}$ e $x_3 = \frac{C_2H_4}{C_2H_6}$ e lembrando que as funções de pertinência do sistema são as funções da Figura 2.

3.2 Nova Tabela para Diagnóstico de Transformadores

A partir das 125 regras difusas extraídas da rede neural utilizando a metodologia TFRENN, e considerando que estas regras são transparentes, nós pudemos então transformá-las para regras *crisp* considerando o valor máximo de saída da regra para cada caso. Após análise das regras *crisp* extraídas, uma tabela para diagnóstico dos transformadores pôde então ser criada. A nova tabela criada a partir do conhecimento aprendido pela rede neural é mostrada na Tabela 4.

TABELA 4 – Nova Tabela para Diagnóstico de Transformadores

Caso	C ₂ H ₂ /C ₂ H ₄	CH ₄ /H ₂	C ₂ H ₄ /C ₂ H ₆
PD Descarga parcial			
	<0.1	<0.1	>2.6 or <0.36
	<0.1	0.1-0.36	<0.1 or >1.06
	0.1-0.36	<0.1	<0.1
	0.1-0.36	0.36-2.6	>2.6
	0.36-1.06	<0.36	<0.36
	0.36-1.06	1.06-2.6	1.06-2.6
	1.06-2.6	<0.36	<0.36
	1.06-2.6	0.36-1.06	0.36-1.06
	>2.6	<0.1	<0.1
	>2.6	0.1-0.36	<0.36
	>2.6	0.36-1.06	0.36-1.06
D1 Descarga de Baixa Energia			
	<0.1	<0.1	1.06-2.6
	0.1-0.36	<0.36	>1.06
	0.1-0.36	<0.1	0.36-1.06
	0.36-1.06	0.36-1.06	1.06-2.6
	0.36-1.06	1.06-2.6	>2.6
	1.06-2.6	<0.1	>0.36
	1.06-2.6	0.1-0.36	0.36-2.6
	1.06-2.6	0.36-2.6	1.06-2.6
	>2.6	<0.1	>0.1
	>2.6	0.1-0.36	>0.36
	>2.6	0.36-1.06	>1.06
	>2.6	1.06-2.6	<0.1 ou 1.06-2.06
D2 Descarga de Alta Energia			
	0.36-1.06	<0.36	>1.06
	1.06-2.6	0.36-1.06 ou 1.06-2.6	>2.6
	0.36-1.06	0.36-1.06	>2.6
	>2.6	1.06-2.6	>2.6
T1 Falta Térmica T < 300 °C			
	<0.1	0.36-1.06	0.1-1.06
	<0.1	>1.06	<1.06
	0.1-0.36	0.36-1.06	0.1-1.06
	<0.36	>1.06	<1.06
	0.36-1.06	1.06-2.6	0.1-0.36
T2 Falta Térmica T > 300 °C			
	<0.1	0.1-0.36	0.1-0.36
	<0.1	0.36-1.06	<0.1 ou >1.06
	<0.1	>1.06	>1.06
	0.1-0.36	0.36-1.06	<0.1 ou 0.36-1.06
	0.1-0.36	>2.6	>1.06
	0.36-1.06	>2.6	<1.06

3.3 Resultados Comparativos

Como resultado do nosso trabalho nós temos então 6 sistemas de diagnóstico a serem comparados:

RNA – rede neural

RNA/D – rede neural com saída fuzzificada

TFRENN – sistema difuso extraído

TFRENN/D – sistema difuso extraído com a saída fuzzificada

NT - Nova tabela extraída do conhecimento aprendido pela rede IEC 60599

A Tabela 5 apresenta os resultados comparativos para 318 casos de diagnóstico de transformadores.

	% de diagnóstico correto	Und	NI	Erros
RNA/D	100	5	0	0
RNA	99.05	0	0	3
TFRENN/D	100	7	0	0
TFRENN	99.37	0	0	2
NT	95.91	0	8	5
IEC 60599	94.02	0	14	5

onde Und corresponde ao número de casos quando a saída difusa indicou 2 possibilidades, mas uma destas possibilidades sendo a correta. E NI indica o número de casos não identificados.

Através dos resultados apresentados podemos verificar que o resultado apresentado pela Tabela IEC pode ser considerado o pior caso. Podemos também concluir que os resultados tanto para a rede neural quanto para o sistema difuso extraído desta apresentam um melhor resultado quando a saída das mesmas é fuzzificada.

Com a saída fuzzificada podemos observar que de fato, para todos os casos onde a saída cai na zona de indecisão, onde duas hipóteses são produzidas, o diagnóstico correto foi considerado como uma possibilidade. Contudo, caso considerássemos apenas a maior possibilidade levaria a erros de diagnóstico, como no caso dos sistemas sem a saída fuzzificada.

Considerando a Tabela NT extraída do conhecimento aprendido pela rede, podemos verificar que ela apresenta resultados um pouco melhores do que a tabela IEC. Enquanto a Tabela IEC não identifica 14 casos, a nossa tabela não identifica apenas 8.

4.0 - CONCLUSÃO

Dos resultados obtidos com a aplicação da metodologia TFRENN pode-se observar que a percentagem de diagnóstico correto foi maior que a percentagem de diagnóstico correto obtido com o IEC 60599.

Outro importante ponto que podemos destacar diz respeito ao problema de não-decisão, característico do método IEC e outros métodos baseados na razão das concentrações de gases. Através da Tabela 4 pode-se verificar que para os sistemas inteligentes desenvolvidos não houve nenhum caso de falta não identificada, enquanto que para a Tabela IEC tivemos 14 casos de falta não identificada. A tabela NT também apresenta resultado superior desde que apresenta um número menor de casos não identificados.

Através da metodologia TFRENN nós pudemos não só desenvolver um sistema inteligente de diagnóstico, mas também a partir das regras difusas transparentes extraídas, criar uma nova tabela útil para aplicações práticas que apresenta, considerando os 318 casos empregados para o desenvolvimento dos sistemas, resultado superior ao da tabela IEC.

5.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Yann-Chang Huang. Evolving Neural Nets for fault Diagnosis of Power Transformer, IEEE Transactions on Power Delivery, Vol 18, Nº 3, pp 843-848, July, 2003.
- (2) Y. Zhang, X. Ding, Y. Liu E P. J. Grefin. An Artificial Neural Approach to Transformer Fault Diagnosis, IEEE Transactions on Power Delivery, Vol 11, Nº 4, pp 1836-1841, October, 1996.
- (3) K. Tomsovic, M. Tapper E T. Ingvarsson. A Fuzzy Information Approach to Integrating different Transformer Diagnostic Methods, IEEE Transactions on Power Delivery, Vol. 8, Nº 3, pp 1638-1644, July, 1993.
- (4) Adriana R.G. Castro, Vladimiro Miranda. Mapping Neural Networks Into Rule Sets E Making Their Hidden Knowledge Explicit – Application to Spatial Load Forecasting, *Proceedings of PSCC02 - 14th Power Systems Computation Conference*, Sevilla, Spain, June 2002
- (5) Adriana R.G. Castro. Knowledge Extraction from Artificial Neural Networks - an Application to Transformer Fault Diagnosis, Ph.D. Thesis, Ed. FEUP - Faculty of Engineering, University of Porto, Portugal, July 2004.
- (6) Adriana Castro, Vladimiro Miranda, "Knowledge Discovery in Neural Networks with Application to Transformer Failure Diagnosis", *IEEE Transactions on Power Systems*. (aceite para publicação)
- (7) Vladimiro Miranda, Adriana Castro, "Improving the IEC Table for Transformer Failure Diagnosis with Knowledge Extraction from Neural Networks", *IEEE Transactions on Power Delivery* (aceite para publicação)
- (8) IEC Publication 60599. Interpretation of the analysis of gases in transformers E other oil-filled electrical equipment in service, March 1999.
- (9) M. Duval E A. Pablo. Interpretation of Gas-in-oil Analysis using new IEC Publication 60599 E IEC TC10 Databases, IEEE Electrical Insulation Magazine, March/April, Vol17, Nº2, pp 31-41.