



XVIII Seminário Nacional de Distribuição de Energia Elétrica

SENDI 2008 - 06 a 10 de outubro

Olinda - Pernambuco - Brasil

Ferramenta Inteligente de Classificação do Diagnóstico de Falhas Incipientes em Transformadores de Potência Imersos em Óleo

Ronaldo Aquino	Milde Lira	Aida Ferreira	Heldemarcio Ferreira	Taciana Filgueiras
UFPE	UFPE	UFPE	CELPE	CELPE
rrba@ufpe.br	milde@ufpe.br	aidaaf@gmail.com	heldemarcio@celpe.com.br	taciana@celpe.com.br
José M. Bezerra	Zanoni Lins	Otoni Neto	Viviane Asfora	Agnaldo Magnum
UFPE	UFPE	UFPE	UFPE	UFPE
jmbb@ufpe.br	zdl@ufpe.br	otoninobrega@hotmail.com	vikhoury@gmail.com	agnaldomagnum@hotmail.com

RESUMO

Este trabalho faz parte de um P&D iniciado em novembro de 2007 entre a Universidade Federal de Pernambuco – UFPE e a Companhia de Eletricidade de Pernambuco – CELPE, cujo objetivo é desenvolver um sistema inteligente de manutenção preditiva para detectar automaticamente o tipo de falhas incipiente em transformadores de potência a partir da análise cromatográfica dos gases desenvolvido no óleo isolante destes equipamentos utilizando a norma IEC 599 (International Electrotechnical Commission). Este artigo apresenta a modelagem de um sistema protótipo desenvolvido com base nas redes neurais artificiais – RNAs tipo multilayer perceptron – MLP utilizando a razão dos gases dissolvidos em óleo conforme o critério da IEC. Os resultados obtidos mostraram-se bastantes promissores comparados com resultados de artigos que abordaram o mesmo tipo de problema.

PALAVRAS-CHAVE

Análise Cromatográfica, Transformador de potência, Redes Neurais, Sistema de Monitoramento.

1. INTRODUÇÃO

Em virtude do atual modelo do setor elétrico brasileiro onde as concessionárias de energia recebem mais de acordo com a sua maior disponibilidade operacional, tornou-se de maior importância a continuidade de operação ou a disponibilidade de operar a qualquer momento os diversos equipamentos. Além disto, é de grande importância também se antecipar a uma falha, pois afora os maiores prejuízos para a empresa em reparar o equipamento falhado, a ocorrência de falha do equipamento penaliza também a empresa através de multas elevadas aplicadas pela Agência Nacional de Energia Elétrica - ANEEL e denigre a própria imagem da empresa junto à sociedade. Sendo assim, verifica-se que a decisão do especialista da engenharia de manutenção em manter operando ou não um dado equipamento é de suma importância e deve assim ser bem balizada. Diante do exposto, verifica-se a grande importância da técnica de inteligência artificial a ser utilizada e desenvolvida

adequadamente para o sistema da CELPE que irá ajudar o Engenheiro de manutenção nesta tomada de decisão.

Transformadores de potencia é um dos equipamentos mais importante em um sistema elétrico. Uma falha incipiente em um transformador deveria ser detectada tão rápido quanto possível prevenindo o transformador de deteriorações futuras. Assim, um diagnóstico correto de suas falhas incipientes é vital para sua segurança e confiabilidade da rede elétrica.

Um transformador em operação está sujeito aos estresses térmicos e elétricos, os quais podem destruir o material isolante e liberar produtos gasosos. Os gases de acordo com a análise cromatográfica do óleo isolante contêm concentrações (ppm por volume) de hidrogênio, oxigênio, nitrogênio, metano, acetileno, etano, etileno, monóxido de carbono e dióxido de carbono. A análise dos gases dissolvidos em óleo - DGA pode determinar as condições dos transformadores a partir das concentrações destes gases dissolvidos no óleo isolante, taxa de geração dos gases, razão específica de gases e concentração total de gases combustíveis no óleo. Sobreaquecimento, descarga parcial e arcos são as três causas primárias associadas aos diversos tipos de falhas.

Embora a análise de gases dissolvidos no óleo isolante dos equipamentos seja utilizada mundialmente a mais de vinte anos, ainda hoje é considerada como a melhor técnica preditiva para diagnosticar problemas internos nos transformadores. Existem muitos métodos de interpretação destes gases baseado na técnica DGA para diagnosticar a natureza da deterioração do transformador, tais como, os critérios IEC (1), Rogers, Duval, Dornenburg, entre outros, que foram desenvolvidos através de extensas investigações das relações entre os gases gerados e as falhas incipientes resultantes. Desses métodos, apenas o da IEC / IEC revisada e o Rogers / Rogers modificado apresentam também diagnósticos de normalidade para os equipamentos, além dos diagnósticos de problemas já indicados em parte pelos outros métodos, sendo assim os mais usuais.

As redes neurais artificiais – RNAs foram designadas para diagnosticar falhas em transformadores por causa das suas excelentes habilidades de aprender classificações complexas (2, 3). Entre as características relevantes das redes neurais têm-se: processamento paralelo, aprendizado, memória associativa e distribuída. Para treinamento, validação e teste das redes desenvolvidas foram utilizados dados reais dos transformadores de 69kV da CELPE provenientes da análise cromatográfica dos gases dissolvidos em óleo isolante desde 1985, quando se intensificou a análise do óleo em uma quantidade maior de transformadores, até fevereiro de 2008. As redes a serem desenvolvidas podem adquirir experiência diretamente deste conjunto de dados e exibirem uma relação altamente não-linear entre entrada e saída.

2. ANÁLISE DO BANCO DE DADOS DA CELPE

A partir do banco de dados da CELPE, coletado com maior intensidade a partir de 1985 e composto por 4905 padrões de análises de gases dissolvidos no óleo isolante dos transformadores de 69KV, é possível obter informações valiosas quanto ao desempenho dos métodos ou critérios de diagnósticos de estados utilizados na cromatografia.

Embora tais diagnósticos não sejam conclusivos em termos de decisão da retirada ou não de operação de um determinado equipamento, pois outros parâmetros tais como taxa de evolução e quantidade de gases combustíveis gerados pelo defeito dentro de certo período de tempo, etc., eles são de extrema importância, visto que indicam a natureza ou tipo do problema, ou seja, se envolve ou não o papel (celulose) ou se está limitado ao próprio óleo isolante.

A tabela 1 mostra, de acordo com a norma IEC 599, o total absoluto e a porcentagem de dados por diagnósticos extraídos do banco de dados da CELPE (1985 até 2008), como também o total de padrões não tabelados.

Pelo método da IEC, os diagnósticos são obtidos das relações dos gases C₂H₂/C₂H₄, CH₄/H₂, e C₂H₄/C₂H₆, cujos valores são distribuídos por faixas, conforme mostra a Tabela 2, e geram para algumas dessas combinações, diagnósticos tabelados indicados na coluna 2 da Tabela 1.

Tabela 1 – Quantidade de amostras por classe de defeito de acordo com o código IEC

Códigos IEC	Diagnósticos Tabelados	Número de amostras	Porcentagem (%)
000	Deterioração normal do óleo isolante	571	11,64
001	Descarga parcial de baixa energia	436	8,88
010	Sobreaquecimento ou defeito térmico de baixa temperatura (de 150 a 300 graus C)	237	4,83
020	Sobreaquecimento ou defeito térmico de baixa temperatura (inferior a 150 graus C)	615	12,53
021	Descarga parcial de alta energia	208	4,24
022	Arco ou descarga de baixa energia	232	4,73
101	Arco ou descarga de alta energia	41	0,84
102	Arco ou descarga de baixa energia	143	2,92
110	Sobreaquecimento ou defeito térmico de média temperatura (de 300 a 700 graus C)	9	0,18
202	Sobreaquecimento ou defeito térmico de alta temperatura (superior a 700 graus C)	99	2,11
Tabelados	-	2590	52,80
Não tabelados	-	2315	47,19
Total	-	4905	-

Tabela 2 – Relação entre gases estabelecida pelo código IEC

Relação entre gases	Códigos IEC		
	C ₂ H ₂ /C ₂ H ₄	CH ₄ /H ₂	C ₂ H ₄ /C ₂ H ₆
0,1 > R	0	1	0
0,1 ≤ R < 1,0	1	0	0
1,0 ≤ R < 3,0	1	2	1
R ≥ 3,0	2	2	2

Analisando a Tabela 1, verifica-se que a quantidade de dados por diagnóstico não são iguais, visto que a maior parte do diagnóstico está relacionada à deterioração normal do óleo isolante e descarga da baixa energia, que são fenômenos associados, geralmente, ao envelhecimento normal do equipamento.

2.1. Pré-processamento dos Dados de Entrada da Rede Neural

A rede neural desenvolvida será alimentada com vetores de entrada correspondentes às três relações dos gases segundo a norma IEC. O pré-processamento dos dados de entrada proporciona a RNA um aprendizado rápido e mais eficiente. Assim as entradas: $X_1=C_2H_2/C_2H_4$; $X_2=CH_4/H_2$; e $X_3=C_2H_4/C_2H_6$ foram normalizadas conforme a Eq. (1)

$$X_i = \frac{|X_i - X_{\min}|}{|X_{\max} - X_{\min}|}, \quad (1)$$

onde : $X_i = X_1, X_2$ ou X_3 ; X_{min} é o menor valor encontrado no conjunto de X_i , dentro das 4905 amostras (tabeladas e não tabeladas). No banco de dados da CELPE, estes valores foram iguais a zero para X_{min1} , X_{min2} e X_{min3} ; X_{max} é o valor máximo encontrado no conjunto de X_i . No banco de dados, estes valores foram: $X_{max1} = 81,6$; $X_{max2} = 261,25$; $X_{max3} = 330,0$;

2.2. Elaboração do conjunto de Dados da Rede

As amostras não tabeladas, aproximadamente 47% do total, foram extraídas dos conjuntos de treinamento, validação e teste das redes. Estas amostras serão avaliadas posteriormente, durante o desenvolvimento do projeto.

O conjunto de dados para treinamento, validação e teste das RNAs será composto por 100 amostras de cada classe de diagnóstico. As classes com quantidades inferiores a estes valores serão replicadas e/ou complementada através da inclusão de dados criados pela inserção de ruídos aos dados existentes até que esta quantidade seja alcançada. Este procedimento faz-se necessário para evitar a tendência da rede em acertar as classes com maior número de padrões. Sendo assim, o conjunto de dados da rede será composto por 1000 amostras, onde 50% serão utilizados para treinamento, 25% para validação e o restante para teste. Este conjunto de 1000 amostras será selecionado de forma aleatória para compor os três conjuntos de treinamento, validação e teste, visando prevenir a tendência associada à ordem de apresentação dos dados. O conjunto de treinamento é utilizado para ensinar a rede por meio das alterações dos pesos das conexões das unidades de processamento; o conjunto de validação para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento, sendo utilizado geralmente como critério de parada do treinamento; e o de teste para verificar seu desempenho diante de dados reais nunca vistos anteriormente. Vale salientar que o conjunto de teste, apesar de não ser composto das mesmas amostras presentes no seu treinamento, ele deve possuir as mesmas características intrínsecas das amostras utilizadas no treinamento da rede.

3. ARQUITETURA DA REDE NEURAL

A referência (4) mostra o uso de RNA do tipo MLP para a solução de problemas desta natureza, sendo este tipo de rede o ponto de partida deste trabalho.

A rede MLP escolhida possui uma camada de entrada, uma camada intermediária (oculta) e uma camada de saída. Na primeira camada, a rede possui 3 nodos de entrada correspondendo às razões dos gases C₂H₂/C₂H₄, CH₄/H₂ e C₂H₄/C₂H₆; na camada de saída, possui 10 nodos que corresponde aos 10 diagnósticos apresentados da Tabela 1. Desta forma, o vetor de entrada da RNA é dado por Entrada= [C₂H₂/C₂H₄ CH₄/H₂ C₂H₄/C₂H₆]; e o de saída, é um vetor de tamanho 10 que possui apenas um elemento com valor 1 (um), e os demais com valor 0 (zero) como mostra a Tabela 3.

Tabela 3 – Código do vetor de saída da rede neural

CÓDIGO IEC	CÓDIGO SAÍDA RNA
000	1000000000
001	0100000000
010	0010000000
020	0001000000
021	0000100000
022	0000010000
101	0000001000
102	0000000100
110	0000000010
202	0000000001

Na determinação do número de nodos da camada intermediária, alguns autores propõem determinadas regras heurísticas para se definir um modelo inicial para a arquitetura da rede a ser adotada. Uma dessas regras estipula que a camada intermediária deve ter pelo menos uma quantidade de nodos igual à média dos nodos utilizados nas camadas de entrada e saída da rede. Foi analisado uma arquitetura com 8 nodos na camada intermediária, visto que a média dos números de nodos nestas camadas é 6,5; em seguida, analisou-se a rede com 9 e 10 nodos. A quantidade de 9 nodos na camada intermediária atingiu um valor satisfatório para o desempenho da rede, onde adotou-se como critério de escolha o erro médio quadrado - MSE no conjunto de validação da rede.

As redes foram treinadas com o algoritmo de treinamento Levenberg-Marquardt- LM (5). Este algoritmo é mais rápido que outros algoritmos de treinamento de um fator que varia de 10 a 100 vezes. A desvantagem do algoritmo LM, é que ele requer muita memória no seu processamento. Porém, na versão 3 do MATLAB[®], já houve uma redução de memória no algoritmo, permitindo que este seja usado em problemas de maior dimensão.

A Figura 1 ilustra a arquitetura final da rede escolhida com 3, 9 e 10 nodos na camada de entrada, intermediária e de saída, respectivamente.

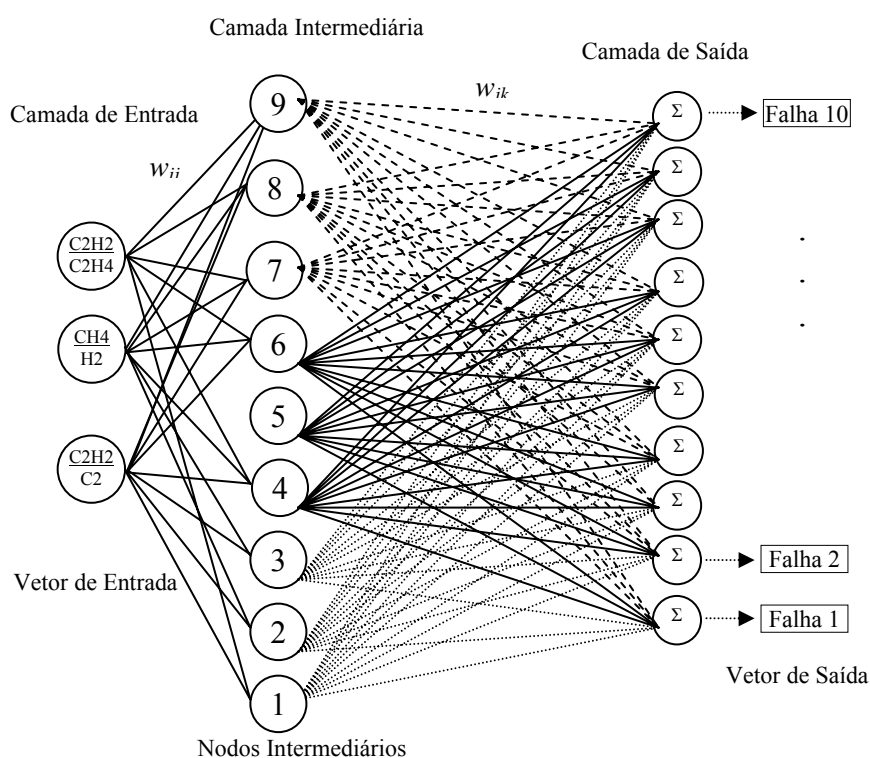


Figura 1 – Arquitetura da rede MLP selecionada

4. RESULTADOS DAS REDES NEURAIAS

A Tabela 4 mostra o erro percentual de classificação das redes no conjunto de teste como função do número de nodos na camada intermediária. Foram fornecidos 250 padrões (25 padrões por diagnóstico) para teste das redes. Como se pode observar, a Rede 1, selecionada por apresentar menor erro médio no conjunto de validação, também apresentou-se diante do conjunto de teste como a melhor.

Tabela 4 – Erro percentual de classificação no conjunto de teste

	8 Nodos	9 Nodos	10 Nodos
Rede 1	22,4	2,0	24,0
Rede 2	4,4	15,6	25,6
Rede 3	5,6	12,8	22,0
Rede 4	24,0	14,0	13,2
Rede 5	4,4	4,8	6,4
Rede 6	5,2	25,2	6,0
Rede 7	18,4	13,2	33,2
Rede 8	4,4	13,6	25,2
Rede 9	22,8	15,2	15,6
Rede 10	11,2	3,6	12,8
Média	12,28	12,0	18,4

A análise do total de acerto por diagnóstico da rede selecionada é apresentada na Tabela 5. Nela, pode-se observar que o erro máximo de classificação por diagnóstico ocorreu na classe correspondente ao código IEC 001, sendo de 8%. O percentual de acerto total foi de 98%, cujo valor encontra-se na faixa de artigos que abordaram o mesmo problema utilizando redes neurais (4), (5).

Tabela 5 – Percentual de acerto na classificação por diagnóstico

DIAGNÓSTICO	CÓDIGO IEC	Acerto	
		No. padrões	Percentual (%)
Sem Falha	000	25	100
Defeito térmico de baixa temperatura <150° C	001	23	92
Descargas Parciais de Pequena Densidade de Energia	010	24	96
Defeito térmico de baixa temperatura 150-300° C	020	25	100
Defeito térmico de média temperatura 300-700° C	021	25	100
Defeito térmico de alta temperatura >700° C	022	24	96
Descargas de energia reduzida	101	25	100
Descargas de alta energia	102	25	100
Descargas parciais de alta densidade de energia	110	25	100
Descargas de energia reduzida	202	24	96
Total	-	245	98

É importante observar que mesmo obtendo-se bons resultados, estes são preliminares e alguns aspectos serão buscados ao longo do projeto com objetivo de melhorar e dar mais consistência aos resultados obtidos pelas redes neurais artificiais, haja vista que os mesmos estão variando muito em função da iniciação dos pesos. Entre eles pode-se citar a busca por um número mais adequado de nodos na camada intermediária, definição da arquitetura em um intervalo maior. Bem como, será realizado para escolha da melhor rede um processo de validação cruzada através do método *k-fold*

podendo k ser igual a 10, como na Tabela 6, para se obter uma distribuição estatisticamente melhor dos dados entre os conjuntos de treinamento, validação e teste, conforme apresentado em (7), (8) e (9).

Tabela 6 – Experimentos criados a partir do método 10-fold

Exp.	Treinamento	Validação	Teste
1	5, 6, 7, 8, 9, 10	2, 3, 4	1
2	1, 6, 7, 8, 9, 10	3, 4, 5	2
3	1, 2, 7, 8, 9, 10	4, 5, 6,	3
4	1, 2, 3, 8, 9, 10	5, 6, 7	4
5	1, 2, 3, 4, 9, 10	6, 7, 8	5
6	1, 2, 3, 4, 5, 10	7, 8, 9	6
7	1, 2, 3, 4, 5, 6	8, 9, 10	7
8	2, 3, 4, 5, 6, 7	9, 10, 1	8
9	3, 4, 5, 6, 7, 8	1, 2, 10	9
10	4, 5, 6, 7, 8, 9	1, 2, 3	10

5. CONCLUSÕES

Um estudo sobre a eficiência da rede neural na detecção de falha incipiente em transformadores foi apresentado. Foi possível observar que a arquitetura da rede neural baseada em três camadas e poucos nodos na camada intermediária é suficiente para se detectar falhas incipientes em transformadores de potência. A fim de se alcançar uma taxa elevada de sucesso, informações confiáveis durante o treinamento e teste são necessárias.

Diante da vasta quantidade de dados extraídos do sistema de distribuição da CELPE, foi possível desenvolver um sistema de diagnóstico para transformadores baseado em redes neurais utilizando o critério IEC com 96% de acerto.

A rede neural poderá também ser usada como uma ferramenta para analisar amostras DGA usando outros critérios de diagnósticos em um curto período de tempo. Este esquema de diagnóstico em transformadores usando RNA e vários critérios DGA elevaria a confiabilidade do sistema.

O algoritmo utilizado no treinamento das redes, Levenberg-Marquardt, consegue reduzir significativamente o número de épocas necessárias para atingir o nível de acerto exigido comparado com outros algoritmos de aprendizagem supervisionado.

Os trabalhos futuros envolverão experimentos relacionados ao desenvolvimento do projeto, custo computacional e velocidade de convergência de diversas abordagens de redes neurais e sua combinação com regras heurísticas para diagnóstico de falhas em transformadores de potência.

No atual clima econômico, há uma demanda crescente em se estender o tempo de operação e reduzir os custos de manutenção dos transformadores. Com a ajuda de técnicas mais precisas de monitoramento da condição da isolação interna de um transformador, como o método baseado em RNA, a programação da manutenção pode ser otimizada, e uma vida mais longa em operação pode ser alcançada.

6. AGRADECIMENTOS

Os autores agradecem ao suporte financeiro da Companhia Energética de Pernambuco – CELPE, bem como, os dados para o desenvolvimento deste projeto.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- 1 IEC – International Electrotechnical Commission. Interpretation the analysis of gases in transformer and other Oil-filled impregnated Electrical Equipment in Service. CEI – IEC – 599, First Edition, 1978.
- 2 HAYKIN, Simon. Redes Neurais – Princípios e práticas. Bookman, Segunda Edição, Porto Alegre –RS- 2001.
- 3 LUDERMIR, Teresa B., BRAGA, Antônio P. & CARVALHO, André Carlos P.L.F. Redes Neurais Artificiais : Teoria e Aplicações. Editora LTC, Rio de Janeiro-RJ, Brasil, 2000.
- 4 GUARDADO, J.L., NAREDO, J.L., MORENO, P. & FUERTE, C.R. A Comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using Dissolved Gas Analysis. IEEE Transactions on Power delivery, October, 2001.
- 5 HAGAN, M.T. & MENHAJ, M. Training Feedforward Networks with the Marquardt Algorithm. IEEE Transactions on Neural Networks, vol. 5, no. 6, 1994.
- 6 BARROS FILHO, Vespúcio N. A., AQUINO, Ronaldo R. B., FERREIRA, Aida A. & SOUZA, Leonardo T. A.. Monitoramento e Diagnóstico de Estado de Grandes Transformadores, com Ênfase para o Diagnóstico pela Cromatografia com o Uso de Redes Neurais. IX Symposium of Specialists in Electric Operational and Expansion Planning, 2004, Rio de Janeiro. IX SEPOPE - SP-167, 2004.
- 7 LIRA, Milde M. S., AQUINO, Ronaldo. R. B., FERREIRA, Aida A., CARVALHO JR, Manoel Afonso & LIRA, Carlos A. B. O. Improving Disturbance Classification by Combining Multiple Artificial Neural Networks. In: IEEE World Congress on Computational Intelligent / IJCNN 2006, 2006, Vancouver, BC, Canada. IEEE Xplore, 2006. p. 3436-3442.
- 8 AQUINO, R. R. B., FERREIRA, Aida A., LIRA, Milde M. S., SILVA, Geane B., NÓBREGA NETO, Otoni., OLIVEIRA, Josinaldo B., DINIZ, Carlos F. D. & FIDELIS, Juclar. A Hybrid Intelligent System for Short and Mid-term Forecasting for the CELPE Distribution Utility. In: IEEE World Congress on Computational Intelligent / IJCNN 2006, 2006, Vancouver, BC, Canada. IEEE Xplore, 2006. p. 2556-2661.
- 9 AQUINO, Ronaldo R. B., OLIVEIRA, Josinaldo B., NÓBREGA NETO, Otoni., LIRA, Milde M. S., FERREIRA, Aida A., ROSAS, Pedro A. C. & SANTOS, Gabriela S. M. Avaliação de Métodos Convencionais e de Inteligência Artificial para Previsão de Ventos e Geração Eólica. SNPTEE, Rio de Janeiro, 2007.