

Ferramenta para o Diagnóstico de Falhas em Transformadores de Potência utilizando DGA

O. M. Almeida, S. E. U. Lima, L. L. N. Reis, J. C. Oliveira, G. C. Leite.

Resumo - Falhas severas em transformadores de potência são sempre problemáticas. Assim, tem-se demonstrado um crescente interesse em manter estes equipamentos em boas condições operacionais. O diagnóstico de falhas incipientes está diretamente relacionado à avaliação das condições do sistema de isolamento. Existe um grande número de métodos disponíveis para o monitoramento e diagnóstico do sistema de isolamento de transformadores de potência. Entretanto, poucos consideram a questão das inconsistências normativas e os casos de resultados conflitantes. Neste artigo, métodos convencionais e sistemas inteligentes são aplicados ao diagnóstico de falhas incipientes em transformadores de potência a partir dos dados da análise cromatográfica dos gases dissolvidos no óleo.

Palavras-chave - Transformadores de Potência, Diagnóstico de Falhas, Análise de Gases Dissolvidos em Óleo, Sistemas Nebulosos, Redes Neurais Artificiais.

I. INTRODUÇÃO

Sistemas para diagnóstico e monitoramento de equipamentos do sistema elétrico de distribuição e transmissão sem a necessidade de desligamentos (*on-site*) têm sido propostos em níveis de pesquisas com implementações práticas finais por empresas do setor elétrico [1-3]. Neste contexto, as universidades têm desenvolvido um papel importante, principalmente em nível de pesquisa. Isto vem ocorrendo não somente no Brasil como também na maioria dos países desenvolvidos e em desenvolvimento. No Brasil, especificamente, o interesse por esta área foi acelerado nos últimos anos devido às mudanças estruturais no setor de energia elétrica que estabeleceram índices mais rigorosos de qualidade técnica e de serviço em um ambiente regulado [4-6].

Transformadores de potência de grande porte são um dos mais caros e críticos componentes de uma planta elétrica. Por isto, um grande esforço vem sendo empregado para garantir seu bom funcionamento no que concerne a evitar falhas que podem estar relacionadas ao ciclo natural de envelhecimento do sistema de isolamento e aquelas relacionadas aos regimes elétricos aos quais os transformadores estão submetidos. Atualmente, se encontra disponível um número considerável de ferramentas para diagnóstico das condições de transformadores de potência [3-9].

Este artigo apresenta uma ferramenta de diagnóstico de falhas incipientes em transformadores de potência através da análise dos gases dissolvidos em óleo, especial atenção é

dada aos casos de inconsistências normativas. A seção II trata da análise de gases dissolvidos em óleo, onde são descritos os principais gases associados às falhas em transformadores de potência imersos em óleo. Na seção III, apresenta-se o sistema de diagnóstico de falhas incipientes através de três metodologias: convencional baseado em normas, sistema nebuloso e rede neural artificial. Na seção IV, são analisados os resultados obtidos e na seção V são estabelecidas as conclusões e desenvolvimentos futuros.

II. ANÁLISE DE GASES DISSOLVIDOS NO ÓLEO (DGA)

Os métodos de diagnósticos com base em DGA são os mais estudados e os mais aplicados a transformadores de potência imerso em óleo. Estes métodos baseiam-se na análise de tipos de concentração e taxa de produção de gases gerados e dissolvidos no óleo do transformador e procuram associar o tipo de falha ao gás presente, por exemplo, descargas elétricas levam à geração de acetileno enquanto a presença de dióxido de carbono está associada ao sobreaquecimento da celulose [10-15].

Métodos convencionais de DGA têm sido empregados por mais de trinta anos e constitui uma técnica de sucesso que, aliada a novas tecnologias, ganha novo impulso a cada ano. A utilização destes métodos por décadas seguidas levou a uma base de conhecimento profunda na caracterização do equilíbrio dos gases no interior dos transformadores. Observa-se que o nível e período de formação dos gases dependem não somente da idade dos transformadores mais também da localização, natureza e severidade das falhas a que são submetidos.

Um programa de manutenção no qual o DGA é realizado em períodos anuais, dificilmente acompanha a curva de tendência da formação dos gases. É uma opinião geral de que em um programa de manutenção se o DGA for realizado em menores períodos de amostragem, grande parte das falhas catastróficas poderiam ser previstas. Estas opiniões têm levado a desenvolvimentos tecnológico no sentido de viabilizar o DGA em tempo real (*real-time DGA*) [2, 3] mesmo que simplificado, ou seja, com monitoramento da formação de alguns gases em particular, como por exemplo o gás carbônico, hidrogênio, furfuraldehide e umidade.

O mecanismo de formação de gases no interior de transformadores imersos em óleo mineral devido solicitações elétricas e térmicas é descrito através de um modelo termodinâmico que descreve o relacionamento entre a taxa de formação dos gases e a temperatura na vizinhança do ponto onde a falha ocorre [10-15].

Os principais gases formados a partir da decomposição do óleo mineral de transformadores submetidos à falhas incipientes são: hidrogênio (H_2), metano (CH_4), etano (C_2H_6),

Este trabalho foi apoiado integralmente pela Coelce.

O. M. Almeida, S. E. U. Lima, L. L. N. Reis, J. C. Oliveira trabalham no laboratório de Automação e Robótica da Universidade Federal do Ceará (e-mails: otacilio, sanderson, laurinda, juliana @dee.ufc.br).

G.C. Leite trabalha na Companhia Energética do Ceará - Coelce (e-mail: glete@coelce.com.br).

etileno (C_2H_4), acetileno (C_2H_2), monóxido (CO) e dióxido de carbono (CO_2). Na maioria dos métodos de interpretação dos dados são definidas razões entre esses gases de modo que seja possível a identificação de uma falha tomando por base a faixa em que se encontra cada razão. Historicamente, as mais utilizadas, são as razões apresentadas na tabela 1.

TABELA 1 – RAZÕES ENTRE AS CONCENTRAÇÕES DOS GASES.

Razão	$\frac{CH_4}{H_2}$	$\frac{C_2H_2}{C_2H_4}$	$\frac{C_2H_2}{CH_4}$	$\frac{C_2H_6}{C_2H_2}$	$\frac{C_2H_4}{C_2H_6}$
Notação	R1	R2	R3	R4	R5

III. DIAGNÓSTICO DE FALHAS BASEADO EM DGA

O diagnóstico de transformadores utilizando a tecnologia DGA é o resultado da interpretação do conjunto de dados obtido nas análises cromatográficas dos gases dissolvidos. O diagnóstico é utilizado para determinar a condição atual de funcionamento dos transformadores, auxiliar em previsões quanto ao seu uso futuro, bem como, para emitir sinais de alerta em advertência a condições críticas de funcionamento.

Os métodos de interpretação dos dados das análises cromatográficas do óleo possibilitam a identificação de falhas incipientes através do monitoramento das razões entre as concentrações dos gases dissolvidos ou da taxa de crescimento dos gases.

Desde que todos os fenômenos relacionados ao diagnóstico de falhas em transformadores são caracterizados por imprecisões, incertezas nas medidas e não-linearidades não modeladas, métodos convencionais, combinados com métodos baseados em inteligência computacional e em especial, os sistemas nebulosos e redes neurais podem ser empregados de forma eficiente para o diagnóstico automático de falhas incipientes [4-9].

A ferramenta desenvolvida apresenta um módulo de detecção de falhas e três módulos de identificação, utilizando métodos convencionais, sistemas nebulosos e redes neurais. As saídas desses módulos são combinadas através do módulo de decisão, conforme apresentado no fluxograma em 1.

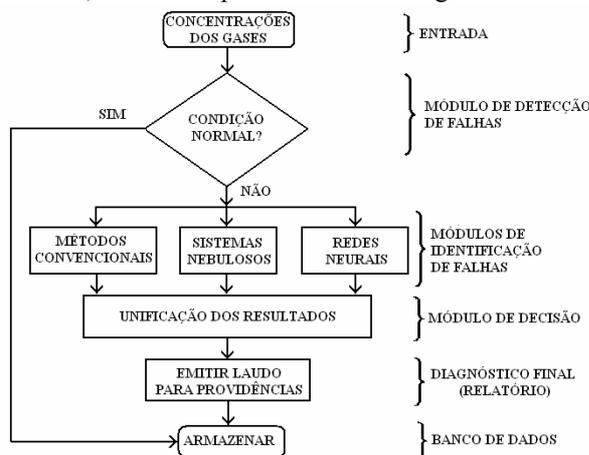


Figura 1 – Fluxograma da ferramenta proposta.

A. Diagnóstico de Falhas Incipientes Utilizando Métodos Convencionais

Neste módulo do sistema, chamado de Métodos Convencionais, foram implementados seis algoritmos de diagnóstico de falhas incipientes utilizando os critérios dos métodos: Dornenburg, Rogers, Duval, IEEE Std C57.104, IEC 599,

NBR 7274, Gás Chave e Tsuchie [10-15].

Neste artigo são considerados métodos convencionais de diagnóstico aqueles cujo diagnóstico é função das relações entre as concentrações dos gases e os intervalos de variação destas. IEEE, IEC e ABNT definem um método que é similar ao método de Rogers (Rogers modificado). A figura 2 apresenta graficamente este método de diagnóstico. As falhas são classificadas em função da faixa dos valores assumidos pelas razões R1, R2 e R5 descritas na tabela 1.

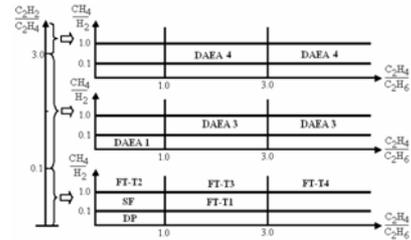


Figura 2 – Representação gráfica do método IEEE/IEC.

Os diagnósticos possíveis são: Sem Falha – SF (condição normal de envelhecimento), Descargas Parciais – DP, Falha Térmica – FT (quatro níveis de temperatura de sobreaquecimento) e Descargas de Alta de Energia ou Arco - DAEA (quatro níveis de densidade de energia). Assim, está associada uma variável de saída a cada diagnóstico possível. Em todos os métodos utilizados as entradas são os valores de concentração dos gases dissolvidos (H_2 , CH_4 , C_2H_2 , C_2H_4 , C_2H_6 , CO e CO_2) em partes por milhão (ppm).

O problema da “não-decisão”, característico dos métodos convencionais, pode ser observado na figura 2. Estas inconsistências se devem ao fato da norma apresentar regiões que não estão associadas a qualquer diagnóstico de falha. As normas apresentam apenas algumas combinações típicas das variáveis de entrada. Em geral, para correta utilização das normas é necessário, ainda, utilizar métodos de detecção de funcionamento anormal, para posteriormente realizar a identificação da falha.

B. Diagnóstico de Falhas Incipientes Utilizando Sistemas Nebulosos

Para desenvolver o módulo do sistema de diagnóstico baseado em lógica nebulosa foi definido inicialmente um conjunto de regras de decisão. Tomando-se como base a norma IEC 599 e adicionando-se regras empíricas de decisão, solucionado o problema da não-decisão, foram determinados os valores típicos das razões entre os gases (universo de discurso das variáveis de entrada) e a base de regras do sistema. Assim, o sistema é capaz de realizar um diagnóstico para todos os valores assumidos pelas variáveis de entrada, pois a base de regras é completa. Isso pode ser facilmente observado na figura 3, onde neste caso constata-se que todos os espaços estão preenchidos. A figura 3 apresenta de forma gráfica a base de regras do sistema nebuloso.

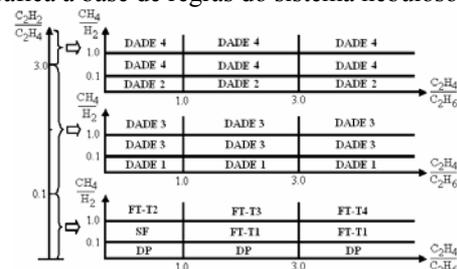


Figura 3 – Representação gráfica da base de regras do sistema nebuloso.

As variáveis de entrada são as razões de concentração dos gases (R1, R2 e R5), definidas na tabela 1, mais a relação CO/CO₂. A relação CO/CO₂ foi introduzida para possibilitar a identificação de falhas relacionadas à degradação da celulose. Para cada uma das entradas são definidas três faixas de valores, que em representação nebulosa constituem os conjuntos nebulosos: Pequeno (P), Médio (M) e Grande (G) com suas respectivas funções de pertinência.

As regras de decisão relativas à degradação da celulose foram estabelecidas utilizando-se as faixas de valores aceitáveis para a razão entre os gases monóxido de carbono (CO) e dióxido de carbono (CO₂). Para sobreaquecimento da celulose a temperaturas muito elevadas (sob condição de arco, por exemplo) a razão CO/CO₂ aproxima-se de 1:1, em consequência de uma geração muito rápida de CO. Para condições de leve sobreaquecimento (problemas de ventilação ou sobrecarga) o CO₂ cresce muito mais rapidamente que o CO, portanto a taxa de CO/CO₂ fica na faixa de 1:20 a 1:10. Uma razão CO₂/CO na faixa de 3.0 a 10.0 é considerada normal.

1) Funções de Pertinências

Utilizou-se funções de pertinência triangulares para os conjuntos nebulosos médios e trapezoidais para os pequenos e grandes, tanto para as variáveis de entrada quanto para a saída. Para o ajuste dos parâmetros das funções de pertinência utilizou-se o seguinte critério: os centros das funções triangulares são os valores médios dos intervalos definidos na IEC 599 e o grau de pertinência do limiar dos intervalos definidos na norma apresenta um grau de pertinência de 0.5. A figura 4 ilustra as funções de pertinência da variável R5. As funções de pertinência das demais variáveis de entrada são semelhantes.

Os diagnósticos estão agrupados em três grupos: falhas térmicas (sobreaquecimento), falhas elétricas (descargas e arco) e degradação da celulose. A não indicação de uma falha é interpretada como uma condição normal.

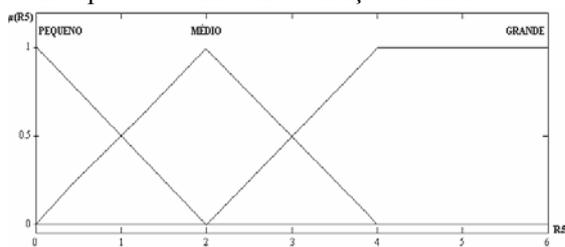


Figura 4 – Função de pertinência da variável R5.

2) Máquina de Inferência

Para implementar a máquina de inferência, a implicação de Mamdani é utilizada [16, 17]. Dado o conjunto nebuloso apresentado na saída do subsistema de inferência é realizada a “desnebulização”. Além de classificar a falha é calculada uma saída numérica que apresenta o valor aproximado da temperatura e o nível das descargas de energia. Finalmente, é avaliado se a falha envolve a degradação da celulose. A figura 5 apresenta o diagrama de blocos do sistema nebuloso implementado.

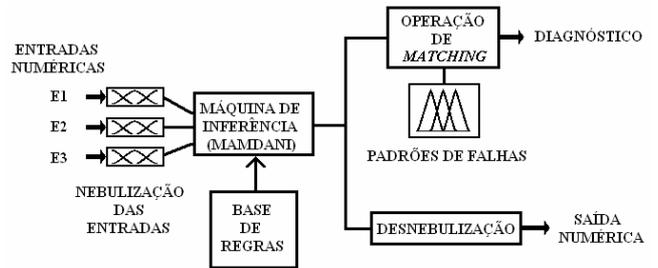


Figura 5 – Diagrama de blocos do sistema nebuloso.

C. Diagnóstico de Falhas Incipientes Utilizando Redes Neurais Artificiais (RNAs)

Para implementação deste módulo de diagnóstico foram testadas duas RNAs: Perceptrons de Multi-Camadas (MLP) e Funções de Base Radial (RBF). Tais redes realizam um mapeamento não-linear entre as entradas e saídas, são alimentadas adiante (*feedforward*) e totalmente conectadas.

1) A Rede Neural Perceptron Multi-Camadas - MLP

A MLP é talvez a rede neural mais popular em aplicações de reconhecimento padrão e aproximação de funções [18]. As memórias são os pesos (w_{ij} e w_{jk}) entre as camadas, ilustrados na figura 6,

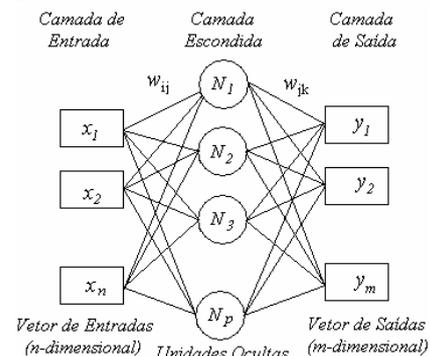


Figura 6 - RNA com propagação adiante (feedforward)

onde w_{ij} representa o peso que conecta o neurônio i ao j , a relação de entrada-saída do neurônio j está descrita em (1),

$$y_j^{(l)} = \Phi(v_j^{(l)}) = \Phi\left(\sum_{i=0}^p w_{ij}^{(l)} x_{ij}^{(l)}\right) \quad (1)$$

onde l indica a camada ($l > 0$, a camada de saída é a terceira camada), y_j é a saída do j -ésimo neurônio, v_j é a soma de pesos dos neurônios de entrada, x_{ij} é a i -ésima entrada do neurônio (p entradas da camada anterior e a polarização), w_{ij} é o peso da i -ésima entrada para o j -ésimo neurônio, e $\Phi(\cdot)$ denota a função de ativação do neurônio.

A função de ativação $\Phi(v)$ é uma função não-linear suave e pode ter várias formas, tais como a função logística e a função tangente hiperbólica.

O treinamento de uma MLP geralmente é realizado através do algoritmo “*Back-Propagation*”, que apresenta dois passos – o passo direto e o passo anterior (“*backward*”). No passo direto os pesos da rede são fixos e (18) é repetidamente utilizada para obter as saídas dos neurônios. Durante o passo anterior todos os pesos são ajustados de acordo com as equações de correção de erro colocadas a seguir:

$$e_j(n) = d_j(n) - y_j(n) \quad (2)$$

$$\delta_j^{(l)} = \begin{cases} e_j^{(l)} \Phi'(v_j^{(l)}(n)) \rightarrow \text{camada de saída} \\ \Phi' \left(v_j^{(l)}(n) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \right) \rightarrow \text{camada escondida} \end{cases} \quad (3)$$

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha w_{ji}^{(l)}(n-1) + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (4)$$

onde n é o número da iteração de treinamento, e representa o sinal de erro, d é a saída desejada, $\Phi'(\cdot)$ denota a derivada da função de ativação, η é o parâmetro da taxa de aprendizagem e α constante momento.

2) Redes de Função de Base Radial - RBF

Uma rede RBF consiste de um conjunto de unidades locais (são utilizadas funções Gaussianas) posicionadas no espaço vetorial de entrada. As unidades locais são completamente conectadas às unidades de saída através das conexões ponderadas. As unidades de saída utilizam o somatório ponderado de suas entradas para aplicar uma função de ativação e determinar a saída. Esta camada é em geral linear e fornece a resposta da rede ao padrão de entrada.

Desta forma uma rede RBF, em sua forma mais básica, envolve três camadas com papéis totalmente diferentes. A camada de entrada é constituída por nós de fonte (unidades sensoriais) que conectam a rede ao meio ambiente. A segunda camada, a única oculta da rede, aplica uma transformação não-linear do espaço de entrada para o espaço oculto, geralmente o espaço oculto é de alta dimensionalidade. No contexto de uma rede neural, as unidades ocultas fornecem um conjunto de “funções” que constituem uma “base” arbitrária para os padrões de entrada, quando eles são expandidos sobre o espaço oculto, por isso estas funções são chamadas de funções de base radial.

Os centros das funções de base radial são os pesos dos neurônios escondidos. O conjunto de funções de base $G(\cdot)$ são funções não-lineares aplicadas à distancia do padrão de entrada aos neurônios da camada escondida. A saída y é calculada através de (5) e (6).

$$G(x) = \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (5)$$

$$y_j = \sum_{i=1}^N [w_{ij} \cdot G(|X_i - X_{centro}|)] \quad (6)$$

3) Identificação da topologia MLP Ótima – Algoritmo Adaptive Back-Propagation

Neste estudo foram considerados alguns fatores para a seleção de uma MLP. Primeiro, o diagnóstico de falha é um problema de mapeamento não-linear complexo, devido ao fato das entradas e saídas serem ambas multivariáveis e não existe nenhuma relação linear obtida até o presente momento. Segundo, uma MLP de três camadas (com apenas uma camada escondida) tem a capacidade de aproximar qualquer função, independente de sua complexidade. Terceiro, o algoritmo de treinamento *Back-Propagation* tem sido aplicado a diversos problemas com sucesso. Portanto, espera-se que uma MLP seja capaz de modelar com suficiente precisão o sistema estudado.

Para determinação do vetor ótimo de entradas foram testadas várias combinações de entradas. O desempenho utili-

zando diretamente as concentrações dos gases foi inferior ao desempenho quando são utilizadas as razões entre as concentrações dos gases (R1, R2 e R5). Na saída temos um neurônio associado a cada padrão de falha (falha térmica de baixa temperatura, falha térmica de alta temperatura, descargas de baixa energia, descargas de alta energia e degradação da celulose).

O desempenho da rede MLP é influenciado pelo número de camadas escondidas e da quantidade de neurônios nestas camadas. Neste trabalho para determinar a topologia ótima realiza-se uma computação dos números de acertos de cada rede com um conjunto de dados de validação. Foram realizadas diversas simulações de modo a possibilitar a escolha do valor ótimo para o número de camadas escondidas e o número de neurônios destas camadas. Uma MLP com uma única camada escondida foi identificada como a melhor escolha para solução do problema. Portanto, o problema de otimização está parcialmente resolvido, sendo utilizadas MLPs de três entradas, cinco saídas e uma camada escondida.

A função de ativação tangente hiperbólica foi utilizada nos neurônios da camada escondida e a função logística nos neurônios de saída. O critério de parada do treinamento é realizado através do monitoramento do índice de acerto no conjunto de dados de validação para cada época de treinamento. O número máximo de épocas possíveis está limitado à 30000 épocas.

O algoritmo *Back-Propagation* convencional é susceptível aos problemas de velocidade de convergência e aprisionamento em mínimos locais. Para minimizar estes problemas foram utilizadas algumas modificações, tais como: utilização de constante de momento e adaptação da taxa de aprendizagem. Tal algoritmo é conhecido como *Adaptive Back-Propagation*.

A seleção da taxa de aprendizagem (η) é importante para determinar a velocidade de convergência do treinamento. Para acelerar o treinamento deve-se manter o passo de aprendizagem o maior valor possível sem comprometer a estabilidade do processo de aprendizagem.

Após a realização de vários testes foi adotada uma taxa de aprendizagem inicial de 0,08 e uma constante de momento de 0,1. A cada época de treinamento a taxa de aprendizagem é atualizada. Se o erro quadrático médio da época atual é superior a 105% do anterior então a taxa de aprendizagem é multiplicada por 0,8 e ainda descartamos os novos valores dos pesos. Se o erro quadrático médio da época atual é inferior ao da anterior então a taxa de aprendizagem é multiplicada por 1,1. A utilização deste método de treinamento proporcionou uma redução do tempo de treinamento, pois possibilita uma convergência mais rápida quando comparado ao *Back-Propagation* convencional [19].

4) Identificação da topologia RBF Ótima – Algoritmo Incremental RBF

O projeto de uma RBF constitui em última análise um problema de ajuste de curva em um espaço de alta dimensionalidade. As RBFs oferecem uma interessante alternativa ao uso de MLPs, tendo em vista que elas podem ser treinadas muito mais rapidamente.

O treinamento de uma rede RBF é dividido em duas etapas. Uma etapa não supervisionada para a camada escondida, onde é realizada a localização das unidades locais dentro do espaço vetorial de entrada (utilizando um método de agrupamento). E uma etapa supervisionada para as unidades de saída, para determinação dos pesos das unidades de saída (como uma RBF apresenta apenas uma camada ponderada a regra delta é suficiente). A parte crítica neste desenvolvimento envolve a determinação dos valores dos parâmetros e a quantidade de unidades locais necessária para otimizar uma determinada função de custo. Em busca da determinação automática destes valores foi utilizado o algoritmo *Incremental RBF*, que realiza, ao mesmo tempo, o projeto e treinamento da rede [20].

O algoritmo *Incremental RBF* inicia com uma rede que consiste de duas unidades locais posicionadas de forma aleatória dentro do espaço de entrada. Ambas unidades estão conectadas através de uma “conexão de vizinhança” (*edge*). Esta conexão revela simplesmente o fato de que estas unidades estão próximas uma da outra, portanto, não constitui de modo algum um peso. Cada unidade local está associada a uma função Gaussiana. O valor do desvio padrão da função Gaussiana é calculado através da média aritmética dos comprimentos das conexões de vizinhança de cada unidade. A idéia por trás disto é dar a cada unidade um “campo receptivo” dentro do espaço vetorial de entrada.

Os pesos dos neurônios da camada oculta (“centros” das funções Gaussianas) são atualizados de forma semelhante ao utilizado em uma rede auto-organizada de Kohonen [21]. De modo que deslocamos o vencedor e também os seus vizinhos em direção ao vetor de entrada. Logicamente, os vizinhos são deslocados em um passo muito menor que o vencedor. Os pesos dos neurônios de saída são atualizados através da regra delta.

O erro quadrático médio da saída em cada iteração é atribuído ao neurônio vencedor, a acumulação deste valor é realizada para que se tenha uma variável de atribuição de crédito para os neurônios ocultos. O erro acumulado de cada neurônio oculto é o parâmetro utilizado para decidir a localização de novas unidades dentro da camada oculta.

A inserção de novas unidades é realizada sempre que o erro de validação se estabiliza, mostrando que, para a atual configuração da rede, a regra delta e a adaptação dos centros não é capaz de melhorar o desempenho da rede. Assim, uma unidade oculta é inserida entre o neurônio que apresenta o maior erro acumulado e o vizinho deste mais distante. A localização da nova unidade dentro do espaço de entradas é tomada como a média dos pesos das unidades entre as quais ela é inserida. Para evitar inserções sucessivas na mesma região, após a inserção de um neurônio o erro acumulado dos vizinhos ao novo neurônio é reduzido em 50%. O erro acumulado atribuído ao novo neurônio é a média aritmética dos erros acumulados de seus dois vizinhos. Para enfatizar a importância dos erros mais recentes todos os erros acumulados são multiplicados por um fator τ ($0 < \tau < 1$) a cada iteração.

A formação da vizinhança é inspirada no método Hebbiano, desde que é realizada uma ligação de vizinhança (*edge*) entre neurônios que apresentam atividades correlatas (pro-

ximidade dentro do espaço vetorial de entrada) e são removidas ligações de vizinhança em caso contrário. A cada ligação de vizinhança é atribuída uma variável de idade que assume inicialmente o valor zero quando a ligação é criada e é incrementada sempre que esta ligação está conectada ao neurônio vencedor de uma dada iteração. A cada iteração os neurônios ocultos realizam pequenos movimentos dentro do espaço vetorial de entrada fazendo com que seja necessário atualizar a informação de proximidade e conseqüentemente a vizinhança. Em toda iteração são identificados os dois neurônios mais próximos (menor distância Euclidiana) do atual vetor de entrada e é formada uma ligação de vizinhança entre estes. Caso a ligação já exista sua variável de idade é colocada em zero. Uma ligação de vizinhança é removida sempre que a variável de idade associada a esta atinge uma idade limite.

D. O módulo de Decisão

O módulo de decisão combina as saídas dos três módulos de diagnóstico de modo a apresentar um diagnóstico unificado. A agregação do sistema de decisão é realizada através de uma operação nebulosa que utiliza o método do gás chave para determinar pesos para cada diagnóstico preliminar. A figura 7 ilustra o módulo de decisão.

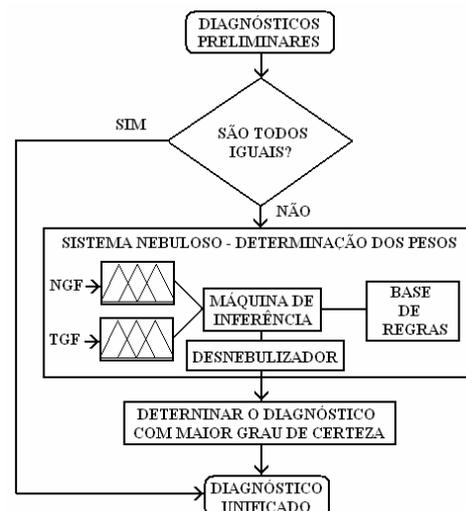


Figura 7 – Diagrama de blocos do módulo de decisão.

As variáveis de entrada do sistema nebuloso de decisão são as concentrações atuais e anteriores dos gases. Assim, inicialmente calcula-se o nível do gás gerado – NGF e a taxa de geração dos gases – TGF, com auxílio do método gás chave. O valor da desnebulização da variável de saída é o peso que será atribuído ao diagnóstico preliminar.

O grau de certeza dos diagnósticos preliminares, multiplicados pelo peso, indicam a possibilidade de ocorrência da falha, onde, o valor máximo é 1 (um), e indica plena certeza da ocorrência da falha, enquanto, o valor 0 (zero) significa que não há possibilidade da ocorrência de falha. O diagnóstico final é aquele que apresenta o maior grau de certeza dentre diagnósticos preliminares ponderados. Se mais de um diagnóstico preliminar apresentar grau de certeza igual a 1 (um) considera-se que tais falhas estão ocorrendo simultaneamente. Portanto a saída pode ser ambígua, ou seja, pode apresentar mais de um tipo de falha incipiente. Esta ambi-

guidade não constitui a princípio um problema, pois é perfeitamente possível que dois tipos de falhas estejam ocorrendo ao mesmo tempo no interior do transformador.

1) Nível de gás gerado (NGG)

Para calcular o NGG tomam-se os valores das concentrações dos gases combustíveis (H_2 , CH_4 , C_2H_6 , C_2H_4 , C_2H_2 e CO), comparados aos valores históricos obtidos para aquele equipamento que apresentam condição de normalidade [6]. Assim, o nível de gás gerado é calculado então, para cada um dos gases considerados, através de (7):

$$NGG_i = \frac{CA_{t_i}}{CL_i} \quad (7)$$

onde, CA_{t_i} representa a concentração atual (ppm) e CL_i o limite histórico máximo do gás para uma condição de normalidade.

A partir dos valores de NGG, e em função do diagnóstico preliminar de cada um dos módulos, realiza-se um somatório ponderado dos valores de NGG, para obter o nível de gás gerado final (NGF). Para ponderar os valores de NGG utilizam-se os percentuais dos gases quando da ocorrência da falha sob suspeita. Tais percentuais estão definidos no método do gás chave. A tabela 2 apresenta os percentuais de cada gás em função do tipo de falha.

TABELA 2 – PERCENTUAIS DOS GASES EM FUNÇÃO DA FALHAS

Tipo de Falha	Percentuais dos gases – P (%)					
	H_2	CH_4	C_2H_6	C_2H_4	C_2H_2	CO
Falha térmica	2	16	17	63	2	0
Celulose	6,7	1,3	0	0	0	92
Corona	86	13	0,5	0,2	0,1	0,2
Arco	60	5	1,6	3,4	30	0

Assim, o nível de gás gerado final (NGF) é dado por:

$$NGF = \sum_{i=1}^6 P_i NGG_i \quad (8)$$

onde NGG_i representa o nível de gás gerado para cada gás e P_i são os percentuais dos gases advindos do método do gás chave, em função do tipo da falha.

Uma vez obtido o nível de gás gerado final (NGF), realiza-se a nebulização da entrada e calcula-se sua pertinência aos conjuntos nebulosos arbitrados e apresentados na figura 8 (normal, alto e muito alto). Estes conjuntos foram determinados através da experiência de especialistas na área [6].

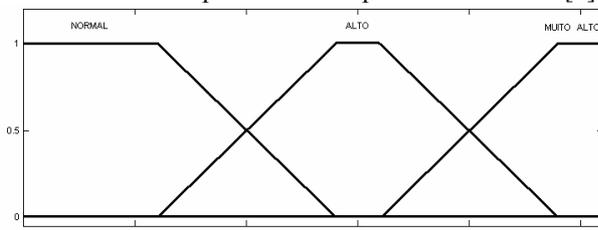


Figura 8 – Funções de pertinência dos conjuntos nebulosos para NGF.

2) Taxa de geração (TG)

A Taxa de Geração (TG), de cada um dos seis gases combustíveis, expressa a evolução deste no período de um mês. Esta taxa é igual ao crescimento percentual da concentração atual do gás em relação ao valor de uma amostra anterior. Esta taxa, similarmente a definição de Moraes [6], é dada pela seguinte equação:

$$TG_i(\%) = \frac{(CA_{t_i} - CA_{n_i}) \cdot 30}{I \cdot CA_{n_i}} \cdot 100 \quad (9)$$

onde CA_{t_i} representa a concentração atual em ppm, CA_{n_i} a concentração anterior em ppm e I o intervalo em dias entre as coletas.

A taxa de geração final (TGF) é calculada através de uma soma ponderada da taxa de formação de cada um dos gases combustíveis, de forma similar ao procedimento utilizado para o cálculo de NGF.

$$TGF = \sum_{i=1}^6 P_i TG_i \quad (10)$$

onde P_i representa os percentuais dos gases advindos do método do gás chave (função do diagnóstico preliminar) e TG_i a taxa de geração encontrada para cada um dos seis gases.

Depois de calculada a taxa de geração final, realiza-se a nebulização desta variável de entrada através de um *singleton* e então é calculada a sua pertinência dentro dos conjuntos nebulosos: aceitável, importante e perigoso. A figura 9 ilustra os conjuntos nebulosos definidos para TGF.

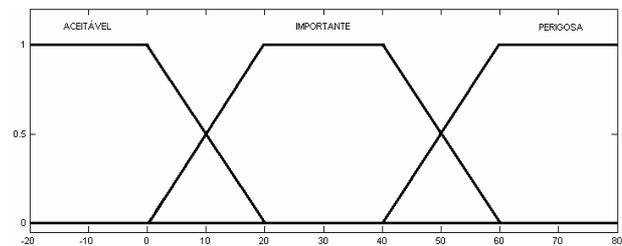


Figura 9 – Funções de pertinência dos conjuntos nebulosos para TGF

A variável de saída apresenta funções de pertinência para descrever as seguintes situações: sem falha, falha provável e falha certa. A figura 10 ilustra as funções de pertinência da variável de saída.

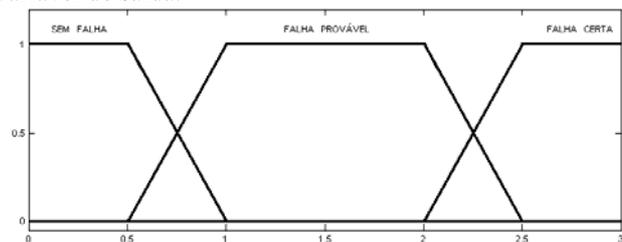


Figura 10 – Funções de pertinência dos conjuntos nebulosos para a saída.

3) Operação nebulosa de decisão

Uma vez obtidos os valores de pertinência das variáveis de entrada (NGF e TGF), determina-se a ativação das regras para obter o conjunto nebuloso de saída. A tabela 3 apresenta a base de regras do sistema de decisão.

TABELA 3 – BASE DE REGRAS DO SISTEMA DE DECISÃO.

TGF	Nível do gás gerado final (NGF)		
	Normal	Alto	Muito alto
Aceitável	Sem falha	Sem falha	Provável
Importante	Sem falha	Provável	Falha certa
Perigosa	Provável	Falha certa	Falha certa

A implicação de Mamdani, com os operadores mínimo e máximo, é utilizada na máquina de inferência para determinar os conseqüentes das regras nebulosas. O conjunto nebuloso de saída é desnebulizado através do centro de gravidade (centróide). A saída numérica é utilizada como peso do

diagnóstico preliminar. Portanto, o sistema de decisão utiliza a lógica nebulosa para integrar os diagnósticos preliminares e obter um diagnóstico final unificado.

IV. RESULTADOS

A. Interface Gráfica da Ferramenta Proposta

A ferramenta de diagnóstico de falhas incipientes foi desenvolvida em C++ *Builder* e está integrada ao banco de dados de análise cromatográfica de transformadores da COELCE, gerenciado através de implementações em linguagem SQL (*Structured Query Language* - Linguagem Estruturada para Pesquisas).

O sistema de diagnóstico apresenta também uma saída gráfica que permite a visualização da evolução das concentrações. A figura 12 utiliza os dados do transformador da figura 11 para ilustrar a evolução da concentração (em ppm) do gás hidrogênio (H_2). Este gráfico esclarece a condição de falha incipiente.

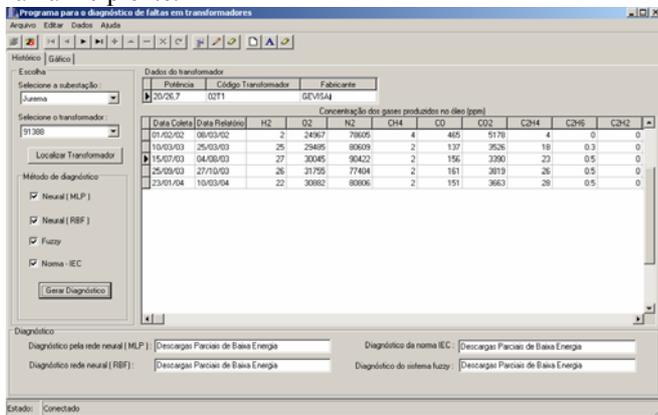


Figura 11 – Interface IHM do sistema de Diagnóstico de Falhas Incipientes.

Na primeira amostra (01/02/2002) a concentração de 2 ppm para o hidrogênio indica uma condição de normalidade. Nestas condições utiliza-se em geral um intervalo de coleta anual, portanto, a segunda coleta de óleo só foi realizada em 10/03/2003. Nesta segunda amostra fica caracterizada a condição de falha incipiente, pois a taxa de formação do hidrogênio foi elevada (maior que 10% ao mês). A falha foi identificada como sendo de descargas parciais no óleo. Para um melhor acompanhamento da condição de falha reduziu-se o intervalo entre as coletas, sendo que a terceira amostra data do dia 15/07/2003. Aqui já se observa uma grande redução da taxa de formação do gás, mas ainda assim realiza-se uma quarta coleta no dia 25/09/2003. Esta coleta indica a dissipação da falha, pois apresenta uma redução do valor da concentração do gás. Para confirmar a eliminação da falha foi realizada mais uma coleta no dia 23/01/2004. Uma vez que, esta amostra, confirma a eliminação da falha incipiente os intervalos de coletas podem ser novamente anuais.

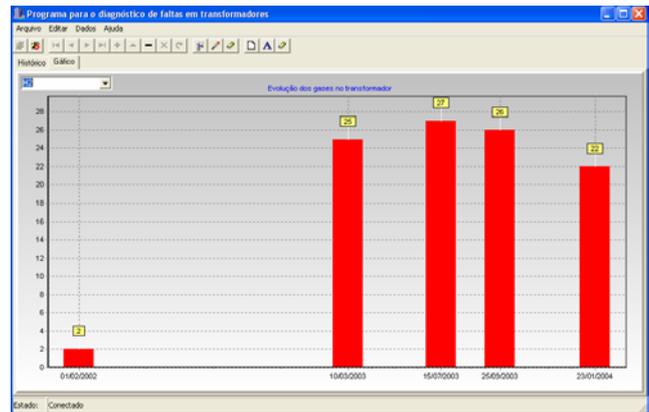


Figura 12 – Saída gráfica da Interface IHM do sistema de diagnóstico apresentado a evolução da concentração de H_2 .

A possibilidade de acompanhamento gráfico da evolução das concentrações dos gases é importante para esclarecer de forma definitiva a característica de uma falha ou a mitigação desta. A plataforma armazena e gerencia as informações e histórico dos transformadores utilizando o gerenciador/servidor de banco de dados *MySQL*. O banco de dados é atualizado automaticamente quando da utilização da ferramenta para realizar o diagnóstico de uma dada análise de gases dissolvidos.

B. Avaliação de Desempenho dos Métodos de Diagnósticos

Para realização da etapa de testes foram utilizadas 530 análises cromatográficas de transformadores da COELCE. A tabela 4 apresenta três amostras do conjunto de dados.

TABELA 4 – DADOS UTILIZADOS PARA TESTES.

Amostra	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2
1	2	28	63	0,2	0,1
2	21	5	13	2	0,2
3	58	2	0	0	0

Dentre as 530 amostras são encontradas situações de funcionamento normal e falhas incipientes (térmicas e elétricas), de modo que, submetendo-se os modelos à avaliação do “grau de certeza” apresentado no diagnóstico, pode-se avaliar a performance de cada módulo do sistema de diagnóstico proposto. Ou seja, é calculado o índice de acerto da ferramenta de diagnóstico, onde, a saída desejada é o resultado apresentado no laudo técnico do especialista.

O módulo de diagnóstico utilizando métodos convencionais apresentou o pior índice de acerto, por exemplo, utilizando-se apenas o método de Rogers o índice de acerto foi de 46%. E mesmo a combinação de vários métodos produziu resultados apenas ligeiramente melhores, da ordem de 58%, e ainda, com o problema de dúvidas associadas.

O sistema nebuloso apresentou o diagnóstico idêntico ao fornecido no laudo técnico em 79,7% das 530 amostras. O sistema é particularmente eficiente devido a solução do problema da não-decisão e a determinação da degradação da celulose através da adição de regras na base do sistema.

O módulo de diagnóstico que apresentou os melhores resultados foi o das RNAs conduzindo a níveis de 91,5% de acerto no diagnóstico. É importante ressaltar que é praticamente impossível atingir o percentual de 100% de acerto, tendo em vista que a seleção dos dados de entrada não ga-

rante que o conjunto de treinamento é realmente uma amostra representativa dos cinco padrões de falhas analisadas e ainda que o diagnóstico do especialista (baseado na IEC 599 e na ABNT NBR-7274) está correto para todos os casos.

A ferramenta completa apresentou um índice de acerto de 96,3%, entretanto a quantidade de diagnósticos com mais de uma falha provável foi elevado (cerca de 37%). Considerando que mais de uma falha pode ocorrer e que outros testes podem ser realizados para determinar a atual condição do sistema de isolamento de um transformador a ferramenta apresenta um desempenho satisfatório.

V. CONCLUSÃO

Métodos de monitoramento e diagnóstico de falhas incipientes em transformadores, baseados na análise de gases dissolvidos no óleo isolante, obtiveram indiscutível sucesso durante estes últimos 30 anos. Entretanto, este sucesso deve-se ao conhecimento e experiências de alguns especialistas. É de interesse geral dos engenheiros de manutenção que este conhecimento seja cientificamente organizado e representado em linguagem de máquina. Por isso, a aplicação de novas tecnologias de diagnósticos de falhas tornaram-se tema constante de pesquisa.

A utilização de um módulo de diagnóstico baseado em métodos convencionais é importante pois a grande maioria dos especialistas utilizam esses métodos para elaboração de laudos, entretanto, o diagnóstico realizado desta forma é resultado de uma análise que se apoia no conhecimento empírico do especialista, principalmente no que diz respeito a solucionar as inconsistências (problemas de não-decisão) e conflitos de diagnósticos. A lógica nebulosa possibilitou o desenvolvimento de um sistema particularmente eficaz na solução das inconsistências normativas. As redes neurais têm uma importância fundamental para resolver os problemas de conflitos entre os diferentes métodos, devido, principalmente, a sua capacidade de generalização.

A ferramenta de diagnóstico utilizou-se de dados obtidos de análise laboratoriais e têm como finalidade, além do diagnóstico do transformador propriamente dito, solucionar inconsistências normativas que rege esta área, sendo capaz de substituir o especialista na interpretação preliminar dos dados de análises dos gases dissolvidos no óleo.

A proposta reúne em um único sistema a possibilidade da realização do diagnóstico de falhas incipientes utilizando diversos métodos e o acompanhamento do histórico da análise cromatográfica dos gases. A ferramenta apresenta uma estrutura modular de fácil utilização e associa o desenvolvimento dos algoritmos inteligentes em C++ *Builder* com uma estrutura de gerenciamento de banco de dados desenvolvida em linguagem SQL. No banco de dados encontram-se as análises cromatográficas de 130 transformadores da COELCE. Por ser de natureza modular o sistema encontra-se preparado para a adição de novas estratégias de diagnóstico, possibilitando, inclusive o confronto entre estas.

VI. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] C. Bengtsson, "Status and Trends in Transformer Monitoring," *IEEE Transactions on Power Delivery*, vol. 11, no. 3, pp. 1379-1384, 1996.
- [2] S. Kovacevic and N. Dominelli, "Transformer Life Extension by Continuous On-Line Oil Conditioning," *Proceedings of Electrical Insulation Conference and Electrical Manufacturing & Coil Winding Technology Conference*, pp. 23-25, 2003.
- [3] S. Tenbohlen and F. Figel, "On-line condition monitoring of power transformers," *IEEE Power Engineering Society Winter Meeting*, vol.3, pp. 2211-2216, 2000.
- [4] S. E. U. Lima, "Diagnóstico Inteligente de Falhas Incipientes em Transformadores de Potência Utilizando a Análise dos Gases Dissolvidos em Óleo," Dissertação de Mestrado, Universidade Federal do Ceara, Depto. Engenharia Elétrica, 2005.
- [5] A. A. C. Freitas, "Redes Neurais Artificiais Aplicadas em Transformadores de Distribuição Imersos em Óleo," Dissertação de Mestrado, UNESP/FE/DEE, Bauru-SP, 2000.
- [6] D. R. Morais, "Ferramenta Inteligente para Detecção de Falhas Incipientes em Transformadores baseada na Análise de Gases Dissolvidos no Óleo Isolante," Dissertação de Mestrado, UFSC, Florianópolis-SC, 2004.
- [7] O. Roizman and V. Davydov, "Neuro-fuzzy Algorithms for power Transformer Diagnostics," *Application of Fuzzy Set Theory to Power System*, IEEE 2000, pp. 253-258, 2000.
- [8] Z. Wang, "Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults," Blacksburg, Virginia University, 2000.
- [9] Y. Zhang, X. Ding and Y. Liu, "An Artificial Neural Approach to Transformer Fault Diagnosis," *IEEE Transactions on Power Delivery*, no. 4, pp.1836-1841, October 1996.
- [10] *IEC 599 - Interpretation of the Analysis of Gases in Transformers and other Oil-filled Electrical Equipment in Service*, International Electrotechnical Commission, Geneva, Switzerland, 1978.
- [11] *ABNT - Diagnóstico de Falha Através das Análises de Gases Dissolvidos em Óleo Mineral*, ABNT NBR-7274/82, 1982.
- [12] *IEEE - Guide for the Interpretation of Gases Generated in Oil-immersed Transformers*, IEEE Std C57.104, New York, 1991.
- [13] M. Milasch, *Manutenção de Transformadores em Líquido Isolante*, São Paulo: Editora Edgard Blucher Ltda, 1984, p. 353.
- [14] M. Duval, "Dissolved Gas Analysis: It Can Save your Transformer.," *IEEE Electrical Insulation Magazine*, vol. 5, No. 6, pp. 22-27, 1989.
- [15] Tsuchie, M, "Recent Diagnostic Technology on Oil-immersed Power Transformer in Japan," *Mitsubishi Electric Corporation Meeting*, pp. 1496-1499, 2002.
- [16] C. H. Chen, *Fuzzy Logic and Neural Network Handbook*, New York: McGrawHill, 1996
- [17] T. Hesk and J. Neporent, *Fuzzy Logic for Real World Design*, San Diego: AnnaBooks, pp. 428, 1999.
- [18] S. Haykin, *Neural Networks - A Comprehensive Foundation*, New Jersey: Prentice Hall, 2nd ed., 1999.
- [19] N. K. Patel and R. K. Khubchandani, "ANN Based Power Transformer Fault Diagnosis," *IE Journal - EL*, vol. 85, pp. 60-63, 2004.
- [20] B. Fritzke, "Fast Learning with Incremental RBF Networks," *Neural Processing Letters*, vol. 1, no. 1, pp. 2-5, 1994.
- [21] T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biological Cybernetics*, vol. 43, pp. 59-69, 1982.