

REGRAS EXTRAÍDAS DE UM ESPAÇO DE ENTRADA DE ALTA DIMENSÃO ATRAVÉS DA ADIÇÃO DE TRIBUTOS PARA A OBTENÇÃO DE UM NOVO MÉTODO DE ANÁLISE DE FALTAS INCIPIENTES EM TRANSFORMADORES

M. A. B. AMORA, A. P. S. BRAGA, O. M. ALMEIDA, F. R. BARBOSA, R. S. T. PONTES.

*Departamento de Engenharia Elétrica, Universidade Federal do Ceará
Caixa Postal 6001 - Campus do Pici - Bloco 705 - 60.455-760, Fortaleza – CE, Brasil.
E-mails: {marcio, arthurp, otacilio, fabio, ricthe}@dee.ufc.br
Laboratório, Departamento, Universidade*

Abstract— For diagnosis of incipient faults in power transformers and other power system elements are usually utilized the concentrations of dissolved gases present in the insulation oil, through DGA-based (Dissolved Gas Analysis) methods, like the Duval Triangle and others, which are described in IEEE C57.104 and in IEC 60599 standards. However, they present some limitations such as the existence of non-decision areas and erroneous results. In this paper, will be described a new methodology to improve the analysis of incipient faults based on rules extracted from a high-dimension space (21 attributes), formed by the gases concentrations and some of their interrelations. Utilizing a decision tree method (C4.5), a set of interpretable rules is extracted from high-dimension input space. Databases known in the DGA technical literature are adopted to analyze the proposed approach, with the new method being compared with standard methods. Considering data test folders in the performed 10-folder cross-validation statistical analysis, the extracted rules show greater accuracy with an error in the diagnosis of incipient faults of 6.25% against 18.75% from the Triangle method in the worst case. Were also performed reliability tests, comparing the new method with methods cited in the standards.

Keywords— Power Transformers, Oil Insulation, Fault Diagnosis, Decision Tree.

Resumo — Para o diagnóstico de falhas incipientes em transformadores e em outros equipamentos de um sistema elétrico de potência são normalmente utilizadas as concentrações de gases dissolvidos presentes no óleo isolante, por meio de métodos baseados em DGA (Dissolved Gas Analysis), como o Triângulo de Duval e outros, os quais são descritos nas normas IEEE C57.104 e IEC 60599. Entretanto, tais métodos apresentam várias limitações, como: a existência de possibilidade de diagnóstico sem decisão e de resultados errôneos. Neste trabalho, será descrita uma nova metodologia para melhorar a análise de falhas incipientes com base em regras extraídas de um espaço de alta dimensão (21 atributos), formado pelas concentrações de gases e algumas de suas inter-relações. Para a extração das regras interpretáveis foi utilizado um método de árvore de decisão (C4.5). Foram utilizados bases de dados conhecidas na literatura técnica para desenvolver e testar o método proposto. Considerando-se os dados de teste e uma análise estatística do tipo validação cruzada, as regras extraídas mostraram maior precisão com um erro no diagnóstico de falhas incipientes de 6,25% contra os 18,75% a partir do Método do Triângulo, no pior caso. Também foram realizados testes de confiabilidade em relação aos dados de entrada.

Palavras-chave — Transformadores de Potência, Isolamento a Óleo, Diagnóstico de Falhas, Árvore de Decisão.

1 Introdução

Os transformadores de potência são um dos equipamentos mais importantes e caros de um sistema de energia elétrica, trazendo sérias consequências para o sistema quando são retirados de operação devido à ocorrência de falhas graves.

Equipamentos de um sistema de potência que utilizam óleo isolante, como os transformadores de potência, podem ser diagnosticados quando da ocorrência de falhas internas incipientes através da análise periódica dos gases dissolvidos no óleo isolante [1, 2, 3, 4]. Para o diagnóstico, o especialista emprega geralmente um ou mais dos métodos padronizados, descritos nas normas IEEE C57.104 [3] e IEC 60599 [4]. No entanto, tais métodos apresentam sérias limitações: (i) existência de situações que não são abrangidas pelos critérios, (ii) a possibilidade da obtenção de mais de um diagnóstico possível, e (iii) a possibilidade da obtenção de resultados incorretos. Nestas situações, o conhecimento do especialista será inestimável na obtenção do diagnóstico.

Muitos estudos [1, 2, 5, 6, 7, 8] utilizam técnicas de Inteligência Artificial (AI), como Redes Neurais Artificiais (RNA) [1, 5, 6] e Sistemas de Inferência

de lógica Fuzzy (SIF) [7, 8] para superar as limitações mencionadas nos métodos convencionais para o diagnóstico de falhas incipientes. Estas abordagens permitem uma melhoria significativa na precisão, mas também apresentam suas próprias limitações: (i) soluções baseadas em RNA tem alta precisão, mas o raciocínio para justificar o diagnóstico não é interpretável, e (ii) soluções baseadas em SIF podem ser interpretadas, mas normalmente lidam com um grande número de regras e/ou operadores especiais, dificultando a facilidade de interpretação.

Este artigo descreve um método alternativo utilizando AI para o diagnóstico de falhas incipientes em transformadores e outros equipamentos do sistema de energia que utilizam óleo isolante, combinando um conjunto compacto de regras interpretáveis com uma alta precisão no diagnóstico. O método C4.5 [9] é utilizado para inferir uma árvore de decisão (*Decision Tree* - DT), que classifica os dados de um espaço de entrada de alta-dimensão, formado pelas concentrações de gases e algumas de suas inter-relações, conforme diagnósticos obtidos de especialistas.

O método C4.5 é uma extensão do algoritmo ID3 [10], sendo capaz de lidar com os atributos nu-

méricos. No entanto, o método C4.5 realiza partições no espaço de entrada utilizando hiperplanos que são ortogonais aos eixos de referência. Este método, então, pode gerar árvores de decisão extensas, com baixa capacidade de generalizar os dados que são não linearmente separáveis em relação aos eixos dos atributos [11]. Assim, de forma semelhante à representação do espaço criado por uma camada oculta em uma RNA [12], este trabalho cria um espaço de alto-dimensão com algumas relações significativas entre os gases, tornando assim a classificação das falhas incipientes mais fácil de ser tratada através de hiperplanos ortogonais aos eixos de atributos.

Este artigo está organizado da seguinte forma. Na Seção II é apresentada uma breve explicação sobre a ocorrência de falhas internas em transformadores de potência e dos métodos convencionais de diagnóstico de tais falhas através da análise dos gases dissolvidos presentes no óleo isolante. Questões sobre a confiabilidade no diagnóstico do transformador utilizando informações de medidas de gases dissolvidos no óleo isolante são apresentadas na Seção III. Na Seção IV são comentados os métodos de construção de uma DT, em particular o C4.5, utilizado neste trabalho para extrair regras que permitem o diagnóstico de equipamentos de potência que utilizam óleo isolante. Na Seção V, o problema de aumentar a dimensão de um problema através da adição de atributos nas variáveis de entrada de uma DT é discutido, mostrando o impacto na obtenção da solução desejada. O desenvolvimento do novo método proposto para o diagnóstico de falhas incipientes em transformadores de potência é apresentado na Seção VI e comparados com os resultados obtidos por métodos convencionais como o Triângulo de Duval [4]. Finalmente, as conclusões são apresentadas na Seção VII.

2 Diagnóstico de Falhas Incipiente em Transformadores de Potência

Halstead em [13] propõem um modelo termodinâmico que descreve a relação entre a temperatura de uma falha em um equipamento e as características de formação de gases, assumindo que todos os hidrocarbonetos do óleo são decompostos no mesmo gás para uma dada temperatura e que cada gás está em equilíbrio com os demais. De acordo com o modelo, a taxa de evolução de cada gás pode ser calculada em qualquer temperatura, de modo que uma relação entre a formação e a temperatura do gás pode ser obtida para cada gás. Estudos destas relações revelam que os gases são gerados com o aumento da temperatura na seguinte ordem [14]: $H_2 \rightarrow CH_4 \rightarrow C_2H_6 \rightarrow C_2H_4 \rightarrow C_2H_2$. O hidrogênio é obtido a baixas temperaturas e a sua quantidade aumenta progressivamente, enquanto que o acetileno é formado a uma temperatura muito elevada (cerca de 1000 ° C) e também aumenta progressivamente [14].

Esta é a idéia por trás dos métodos clássicos de diagnóstico de falhas incipientes em transformadores

de potência, onde são realizadas medições de gases dissolvidos no óleo isolante de transformadores e as razões para esses gases são analisadas, determinando o tipo de falha.

Os métodos convencionais (Gás Chave, Razões de Rogers, Razões de Dörnenburg e Triângulo de Duval) para o diagnóstico de falhas incipientes em transformadores são descritos em IEEE C57.104 [3] e na IEC 60599 [4].

A utilização das relações entre as concentrações de gás para indicar um tipo possível de falha é um processo empírico com base na experiência de especialistas, correlacionando-se análises das medidas de gases com o tipo de falha determinada como a causa de um problema em um transformador de potência quando este foi examinado [1].

Os métodos de diagnóstico com base nos princípios da degradação térmica empregam um conjunto de relações de certos gases combustíveis como indicadores chave do tipo de falha. As cinco relações estão apresentadas na Tabela 1 [3].

Tabela 2. Definições das razões [3].

Abbreviation	R1	R2	R3	R4	R5
Ratio	CH_4/H_2	C_2H_2/C_2H_4	C_2H_2/CH_4	C_2H_6/C_2H_2	C_2H_4/C_2H_6

Um dos métodos mais utilizado e preciso é o método do Triângulo de Duval. Este método foi desenvolvido por Michel Duval em 1974, e é descrita no Apêndice B da norma IEC 60599 [4]. Ele utiliza apenas três gases de hidrocarbonetos (CH_4 , C_2H_4 e C_2H_2). O procedimento para a aplicação deste método começa com o cálculo das percentagens de gases do metano (CH_4), etileno (C_2H_4) e o acetileno (C_2H_2), em relação à soma das concentrações dos gases gerados ($CH_4 + C_2H_4 + C_2H_2$) em p.p.m. (partes por milhão).

Uma vez obtida a percentagem ($\%CH_4$, $\%C_2H_4$, $\%C_2H_2$), estes servem para identificar um ponto num sistema de coordenadas triangulares. O Triângulo de Duval é geograficamente dividido em zonas que representam falhas. As coordenadas triangular correspondente ao resultado da análise de gases dissolvidos em ppm e podem ser calculados como se segue [15]: $\%C_2H_2 = 100x/(x+y+z)$; $\%C_2H_4 = 100y/(x+y+z)$; $\%CH_4 = 100z/(x+y+z)$; with $x = (C_2H_2)$, $y = (C_2H_4)$, and $z = (CH_4)$ in p.p.m..

A Figura 1 ilustra graficamente o método do Triângulo de Duval, e a composição das coordenadas e as áreas das respectivas falhas, cujos códigos: PD, D1, D2, T1, T2 e T3 são descritos na Tabela 2 [3], e uma zona intermédia DT que é atribuída a misturas de falhas elétricas e térmicas em transformadores com comutadores em carga (OLTC – *On Load Transformer Change*).

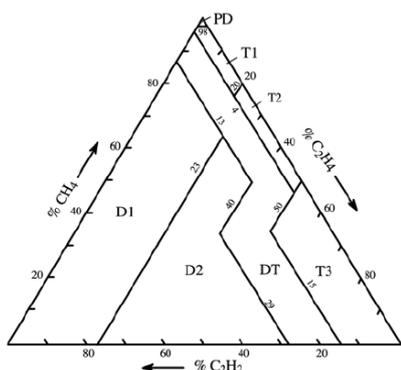


Figura 1. Método do Triângulo de Duval [15].

Tabela 2. Códigos do método do Triângulo de Duval [3].

Símbolo	Falha
PD	Descarga Parcial
D1	Descarga de baixa energia
D2	Descarga de alta energia
T1	Falha térmica com $T < 300$ °C
T2	Falha térmica com $300 < T < 700$ °C
T3	Falha térmica com $T > 700$ °C

Todos estes métodos descritos nas normas apresentam limitações importantes: (i) existência de situações que não são atendidas pelos critérios impostos pelas normas, (ii) a existência de mais de um diagnóstico possível, ou (iii) os resultados errados. Um dos métodos mais precisos é o método do Triângulo de Duval.

Além disso, podem existir imprecisões nas medições laboratoriais dos gases dissolvidos, especialmente para baixas concentrações de gás. Essas situações devem ser consideradas no processo de diagnóstico de um transformador. Na próxima seção serão discutidas questões sobre a confiabilidade do diagnóstico de transformadores com gases dissolvidos no óleo isolante.

3 Confiabilidade no Diagnóstico de Transformadores de Potência

Os parâmetros de qualidade: repetibilidade, reprodutibilidade e precisão, das medições laboratoriais de DGA são definidos na norma IEC 60567 [16]. A repetibilidade está relacionada com as diferenças que são observadas quando várias amostras do mesmo óleo são analisadas pelo mesmo laboratório durante um curto período de tempo [17]. A reprodutibilidade é definida como a diferença de observação quando amostras do mesmo óleo são analisadas por diversos laboratórios (reprodutibilidade interlaboratórios) ou são analisadas pelo mesmo laboratório (reprodutibilidade intra-laboratórios) durante longos períodos de tempo [17]. A precisão está relacionada com as diferenças que são observadas entre os valores medidos e os valores nominais contidos numa amostra de óleo padrão, preparados de acordo com a norma. [17]

Se a repetibilidade e a reprodutibilidade são pobres a realização da análise será mais difícil e pode afetar a detecção e diagnóstico das falhas. Resul-

tados de DGA imprecisos podem resultar na obtenção de resultados errados, o que pode ter consequências graves para os equipamentos em serviço [17].

Em [17] os autores indicam que é conhecido na indústria que muitos laboratórios oferecem resultados de DGA razoavelmente precisos, mas que muitos outros fornecem resultados bastante imprecisos. Pesquisas [21] foram realizadas pelo CIGRE Task Force TF 15-01-07 e IEC TC10 (MT25) sobre a repetibilidade, a reprodutibilidade intra-laboratório e a precisão de 25 laboratórios de 15 países diferentes, considerando-se os casos de concentrações médias (níveis entre 10 e 100 p.p.m.) e de baixas (entre 1 e 10 p.p.m.). Os resultados obtidos para a precisão média são indicados na Tabela 3.

Tabela 3. Precisão dos laboratórios avaliados pelo IEC / CIGRE [17].

Laboratório	Concentrações médias de gás	Concentrações baixas de gás
Melhor	± 3%	± 22%
Média	± 15%	± 30%
Pior	± 65%	± 64%

Este artigo apresenta uma alternativa para melhorar a precisão no diagnóstico de transformadores que utiliza regras de decisão extraídas através de uma DT. Na próxima seção, será discutida brevemente a construção de uma DT.

4 Árvores de Decisão e o Algoritmo C4.5

Em um processo de reconhecimento de padrões, o objetivo é aprender a classificar objetos, através da análise de casos de treino, cujos dados de entrada e os resultados (classes) são conhecidos [18], e a partir do aprendizado estimar as classes de novos casos. Uma maneira de fazer isso é através de uma DT.

A árvore vai conter nós folhas, rotulados com uma determinada classe, ou estruturas que contêm um ramo, ligando dois ou mais nós (ou subárvores) [18]. Assim, para realizar a classificação de um exemplo, primeiro aplicamos um vetor de atributos para a árvore. Os ramos são testados para estes atributos, seguindo o caminho para uma determinada folha, ou para outra, completando o processo de classificação. Como ilustrado na Figura 2.

Um dos algoritmos de construção de uma DT mais utilizado é o C4.5 [9]. O método C4.5 é uma extensão do algoritmo ID3 [10], com vantagens significativas: lida com os atributos categóricos (ordinais ou não) e com atributos contínuos, ele pode trabalhar com valores desconhecidos, utiliza a medição da proporção de ganho para selecionar o melhor atributo que divide os exemplos em um nó, pode lidar com os problemas em que os atributos têm custos diferentes, e apresenta um método de poda das árvores geradas.

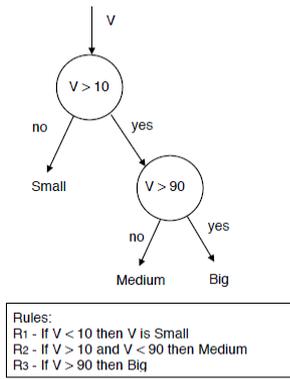


Figura 2. Exemplo simples de um processo de classificação utilizando DT.

As seguintes premissas guiam a utilização do algoritmo para a construção de uma DT [19]:

- Se todos os casos são de uma mesma classe, a árvore só terá uma folha, e para folha é associado o rótulo desta classe;
- Para cada atributo, calcular o potencial de informação fornecido pelo teste do atributo (baseado na probabilidade de cada caso ter um valor particular para o atributo). Além disso, também é calculado o ganho de informação da utilização do atributo;
- Dependendo do critério de seleção adotado, encontrar o melhor atributo para associar ao nó de ramificação.

O cálculo do ganho usa o conceito de "entropia", isto é, uma medida da desordem dos dados. A Entropia E é calculada por [19]:

$$E(\bar{y}) = -\sum_{j=1}^n \frac{|y_j|}{|\bar{y}|} \log \frac{|y_j|}{|\bar{y}|} \quad (1)$$

Realizando sobre todos os valores possíveis de \bar{y} . A entropia condicional será [23]:

$$E(j|\bar{y}) = \frac{|y_j|}{|\bar{y}|} \log \frac{|y_j|}{|\bar{y}|} \quad (2)$$

e, finalmente, ganho de informação é definido por [19]:

$$G(\bar{y}, j) = E(\bar{y}) - E(j|\bar{y}) \quad (3)$$

A entropia é utilizada para determinar qual o próximo nó a ser dividido no algoritmo. O objetivo é maximizar o ganho (G), dividindo pela entropia total calculada utilizando a divisão do argumento \bar{y} pelo valor j .

Após a criação completa da estrutura da DT, que deve classificar todas as instâncias do conjunto de treinamento, a mesma deve ser podada. Isso é necessário para reduzir os erros de classificação, causados pela especialização no conjunto de treinamento, o que é feito para tornar a árvore com uma maior capacidade de generalização. Na poda, o algoritmo C4.5 realiza uma pesquisa na árvore, de baixo para cima, e

transforma em folhas ramos que não mostram nenhum ganho significativo.

Na próxima seção será apresentada uma técnica de aumentar a dimensão do problema para permitir a obtenção de uma melhor solução através de uma DT.

5 Classificação em um Espaço de Entrada de Alta Dimensão

Nesta seção, propomos uma metodologia alternativa para a resolução de problemas de classificação, utilizando conceitos apresentados nos estudos do Teorema de Cover [20].

A nova metodologia propõe a solução de problemas de classificação inicialmente realizando um aumento das variáveis do problema, utilizando novos atributos originalmente não utilizados e relações entre os atributos do espaço de entrada original. Com isso, é obtida uma nova representação do problema em uma dimensão maior e, conforme o Teorema de Cover, com uma probabilidade maior de levar os padrões do novo espaço de atributos a serem linearmente separáveis, e a uma divisão mais favorável desse novo espaço de entrada por hiperplanos.

Os novos atributos propostos neste trabalho devem atender às exigências do Teorema de Cover e, portanto, devem ser linearmente independentes dos atributos originais. Neste artigo os atributos incorporados no modelo do problema, além de informações novas originalmente não utilizadas, são relações não lineares entre os atributos originais. Dessa forma, como exemplo, considerando como atributos originais x_1 e x_2 , os novos atributos propostos têm os formatos de x_3 , x_4 e x_5 apresentados em (4).

$$\left\{ \begin{array}{l} x_3 \rightarrow \text{Atributo físico ainda não utilizado} \\ x_4 = x_1 \cdot x_2 + b \\ x_5 = \frac{x_1}{x_2 + b} \end{array} \right. \quad (4)$$

onde b representa um valor constante ou uma soma de outros atributos.

Deve ser salientado que os novos atributos formados pelo produto ou pela razão de atributos originais devem ter significado físico no problema a ser tratado ou representarem uma relação adimensional (normalização), de forma a garantir um maior grau de significância para as regras obtidas da DT construída.

A obtenção de uma solução linear em uma dimensão maior permitirá a obtenção de uma solução de classificação por parte de uma DT com uma melhor construção das fronteiras de separação entre as classes. Na verdade, a utilização de atributos baseados em relações de outros atributos originais, representa uma abordagem semelhante à utilização de uma árvore oblíqua, entretanto não utilizando uma relação linear, mais sim agora uma razão ou produto entre atributos. Assim é obtido um hiperplano de separação linear numa dimensão maior, mas que numa projeção

numa dimensão menor, será uma reta não mais necessariamente paralela aos eixos.

6 Análise de Transformadores

Utilizando a ideia de aumentar o número de variáveis do problema original, comentada na Seção V. Foi construída uma DT para extrair regras que permitam um diagnóstico preciso de falhas incipientes em transformadores de potência. Os resultados deste desenvolvimento e uma comparação com os métodos indicados nas normas técnicas são apresentados nesta seção.

Uma DT foi treinada e testada utilizando um banco de dados de DGA com 162 casos, onde 117 casos foram obtidos da base de dados do IEC TC 10 [21], 39 casos das tabelas I a III em [22], e seis casos de transformadores de potência apresentados em [23]. Também, as seguintes hipóteses foram feitas na composição dos dados de entrada: (i) se a concentração de um determinado gás não estiver disponível então se considera o valor zero, (ii) uma razão de 0/0 é definida como de valor nulo (26), (iii) uma proporção dada do tipo $v/0$ é definida como sendo de valor 20 (26), considerando que v não é nulo, e (iv) concentrações indicadas como " <1 " nos conjuntos de dados são consideradas como de valor 0,5 (26).

O novo espaço de entrada, proposto e utilizado neste trabalho, considerou os seguintes atributos: a concentração de sete gases (H_2 , CH_4 , C_2H_2 , C_2H_4 , C_2H_6 , CO , e CO_2) normalmente utilizados nos métodos normatizados [3, 4] em partes por milhão (p.p.m.), as razões entre os gases (CH_4/H_2 , C_2H_2/C_2H_4 , C_2H_4/C_2H_6 , C_2H_4/CH_4 , C_2H_2/CH_4 , C_2H_2/H_2 , e CO/CO_2), e as porcentagens relativas ($CH_4\% = 100x / (x+y+z)$, $C_2H_2\% = 100.y / (x+y+z)$, $C_2H_4\% = 100.z / (x+y+z)$, $H_2\% = 100.H_2 / (H_2+C_2H_6+CO+CO_2)$, $C_2H_6\% = 100.C_2H_6 / (C_2H_6+x+y+z)$, $CO\% = 100.CO / (C_2H_6+x+y+z+CO+CO_2)$, e $CO_2\% = 100.CO_2 / (C_2H_6+x+y+z+CO+CO_2)$, onde $x=CH_4$, $y=C_2H_2$, e $z=C_2H_4$).

A maioria dessas relações de entrada adotadas já foram utilizadas nos métodos de diagnóstico indicados nas normas [3, 4] ou por outros métodos indicados na literatura [1, 14, 23, 24], embora não sejam utilizados em conjunto como neste trabalho.

Nas simulações realizadas para a construção de uma DT neste trabalho foi utilizado o software de uso livre SIPINA [25] que incorpora diversas técnicas de aprendizado, com destaque para o uso de árvores de decisão. Entre os diversos métodos de construção de uma DT, o software permite o uso do C4.5.

Em cada rodada de simulação utilizando validação cruzada [26], todas as pastas são subconjuntos formados por 10% do total de dados, onde os casos envolvendo os cinco rótulos considerados (PD, D1, D2, T1/T2 e T3) no problema são uniformemente distribuídos.

Na Tabela 4 são apresentados os erros relacionados aos conjuntos de treinamento e de testes para

cada pasta da validação cruzada, usando regras obtidas a partir de uma DT e o método do Triângulo de Duval. A porcentagem de erro de dados é calculada com base em 146 casos no conjunto de treino, e 16 casos no conjunto de validação. Analisando-se os resultados na Tabela 4, a DT associada com a pasta de número 2 demonstra o melhor desempenho em termos dos conjuntos de treino e de validação, inclusive também comparando com o método do Triângulo de Duval. Assim, o conjunto de regras obtido pela DT para o caso número 2 de validação cruzada é considerado como o conjunto de regras final que permite a análise dos transformadores. A Tabela 5 resume as 14 regras extraídas para esse melhor caso.

Tabela 4. Percentual de erro de classificação, considerando validação cruzada.

Pasta	1	2	3	4	5	6	7	8	9	10
Conjunto										
Treinamento (Regras extraídas AD)	2,7	1,4	4,1	3,4	1,4	2,7	2	2,7	4,1	2
Treinamento (Método do Triângulo)	13,7	13,7	13,7	13,7	13,7	13,7	13,7	13,7	13	13
Teste (Regras extraídas AD)	25	6,25	6,25	25	25	12,5	12,5	12,5	12,5	6,25
Teste (Método do Triângulo)	12,5	12,5	12,5	12,5	12,5	12,5	12,5	12,5	18,75	18,8

Tabela 5. Regras extraídas.

Diagnóstico	C2H2%	C2H4%	C2H4/CH4	CH4/H2	C2H2/H2	C2H2/C2H4	CH4	C2H6
PD	< 12,9		< 0,01					≥ 6,75
T1 ou T2	< 12,9	< 23,35	< 0,01					< 6,75
T1 ou T2	≥ 12,9	< 23,35						≥ 2345
T1 ou T2	< 12,9		> 1,25	< 0,08				
T1 ou T2	< 12,9		≥ 0,01 e < 1,25	< 135	< 0,02			
T1 ou T2	< 12,9		≥ 0,01 e < 1,25	< 135	≥ 0,02	≥ 0,03		
T3	< 12,9		> 0,01	> 135				
T3	< 12,9		> 1,25	≥ 0,08 e < 135				
T3	< 12,9		≥ 0,01 e < 1,25	< 135	≥ 0,02	< 0,03		
D1	≥ 12,9	< 23,35						< 2345
D1	≥ 12,9	≥ 23,35		< 0,05				
D1	≥ 12,9	≥ 23,35		≥ 0,36				< 3
D2	≥ 12,9	≥ 23,35		≥ 0,05				≥ 3
D2	≥ 12,9	≥ 23,35		> 0,05 e < 0,36				< 3

Observando a Tabela 5, pode-se verificar que apesar de 21 atributos terem sido inicialmente considerados na formação das árvores de decisão, apenas 8 deles permaneceram nas regras geradas. Isso ocorre porque o algoritmo C4.5 considera apenas os atributos que têm maior influência na saída desejada.

Na Tabela 6, são mostradas, a título de comparação, as porcentagens de sucesso no diagnóstico de falhas utilizando as regras extraídas e diversos métodos listados nas normas para a base de dados IET TC 10.

Tabela 6. Porcentagens de acerto, comparando diversos métodos e utilizando IET TC 10

Método	Acerto (%)
Método proposto (Regras DT)	99,15
Dörnenburg (ZIRBES, ROLIM e ZÜRN, 2005)	63,25
Dörnenburg IEEE C57.104 - 1991	62,39
Dörnenburg IEEE C57.104 - 2008	63,25
Rogers IEEE C57.104 - 2008	53,85
Triângulo de Durval (IEC 599 - 1999)	88,03

A Tabela 7 apresenta a porcentagem de sucesso no diagnóstico de falhas incipientes usando as regras obtidas da DT (Tabela 5), o método do Triângulo de Duval, o método de Dörnenburg e o método de Rogers, em situações de ocorrência de erros nas medi-

ções de gases obtidos a partir de laboratórios. O erro é modelado por uma Gaussiana, assumindo um desvio padrão de 15% e de 65%, respectivamente, para situações de variação média e máxima nos valores corretos dos dados de DGA.

Tabela 7. Taxa de acerto quando da possibilidade de erro nas medidas de gás (IEC TC 10)

Método	Sem erro	Erro com 15%	Erro com 65%
Rogers IEEE C57.104 - 2008	56,41	55,56	52,14
Dörnenburg IEEE C57.104 - 2008	67,52	67,52	64,96
Triângulo	88,03	85,47	77,78
Regras extraídas	99,15	95,73	82,91

7 Conclusão

Ao analisar os resultados da Tabela 6, pode-se concluir que as regras descritas na Tabela 5 apresenta uma taxa de acerto mais elevada do que a demonstrada por outros métodos, apesar do pequeno número de regras e atributos utilizados, com a taxa de sucesso atingindo 99,15% contra 88,03% para o método do Triângulo de Duval.

Outra vantagem importante das regras extraídas da DT é a de que não existem intervalos sem diagnóstico, como acontecem em versões dos métodos de Rogers e de Dörnenburg citados nas normas.

Analisando os resultados apresentados na Tabela 7, observa-se que o método apresentado neste artigo apresenta uma melhor robustez para uma distribuição de erros nos dados de entrada, com uma taxa de acerto de 82,91% no pior caso (erro com desvio padrão de 65 %). Entretanto, os métodos de Rogers e Dörnenburg apresentam uma menor variação percentual, comparando com o valor sem erro.

Referências Bibliográficas

[1] M. A. B. Amora, O. M. Almeida, A. P. S. Braga, F. R. Barbosa, S. S. Lima, L. A. C. Lisboa. Extraction of Knowledge from Artificial Neural Networks to Application in Analysis of Transformers. The 15th International Conference on Intelligent System Applications to Power Systems ISAP 2009, Curitiba, 2009.

[2] F. R. Barbosa, O. M. Almeida, A. P. S. Braga, M. A. B. Amora, S. J. M. Cartaxo. Application of an Artificial Neural Network in the Use of Physicochemical Properties as a Low Cost Proxy of Power Transformers DGA Data. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 19, no. 1, pp. 239 – 246, February 2012.

[3] IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers, IEEE Standard C57.104-2008, Sept. 2008.

[4] IEC Mineral Oil-Impregnated Electrical Equipment in Service – Guide to the Interpretation of Dissolved and Free Gases Analysis, IEC 60599 – 2008.

[5] M. H. Wang. Extension neural network for power transformer incipient fault diagnosis. IEE Proc., Gener. Transm. Distrib, Vol. 150, no. 6, pp. 679–685, Nov. 2003.

[6] D.G. Esp and A.J. McGrail. Data mining applied to transformer oil analysis data. IEE Digest, Vol. 1999 / no. 119, pp. 9/1–9/7.

[7] K. Spurgeon, W.H. Tang, Q.H. Wu, Z.J. Richardson, and G. Moss. Dissolved gas analysis using evidential reason-

ing. IEE Proc., Sci. Meas. Technol., Vol. 152, no. 3, pp.110–117, May 2005.

[8] V. Miranda, A. R. G. Castro. Improving the IEC Table for Transformer Failure Diagnosis with Knowledge Extraction from Neural Networks. IEEE Trans. Power Delivery, vol. 20, no. 4, pp. 2509–2516, Oct. 2005.

[9] Quinlan, J. R. C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, 1993.

[10] Quinlan, J. R. 1986. Induction of Decision Trees. Mach. Learn. 1, 1 (Mar. 1986), 81-106.

[11] L. Rokach and O. Maimon. Top-Down Induction of Decision Trees Classifiers - A Survey. IEEE Trans. on Systems, Man, and Cybernetics, Vol. 35, no 4, pp. 476 – 487, Nov. 2005.

[12] S. Haykin, Neural networks: a comprehensive foundation, 2 ed., Prentice Hall, 1999.

[13] W. D. Halstead. A thermodynamic assessment of the formation of gaseous hydrocarbons in faulty transformers. J. Inst. Petrol, Vol. 59, September 1959, PP. 239-241.

[14] Z. Wang. Artificial Intelligence Applications in the Diagnosis of Power Transformer. Incipient Faults. Thesis (PhD.), Virginia Polytechnic Institute and State University, Blacksburg, 2000.

[15] M. Duval M. Dissolved Gas Analysis and the Duval Triangle. Fifth AVO New Zealand International Technical Conference, 2006.

[16] Guide for the Sampling of Gases and of Oil from Oil-Filled Electrical Equipment and for the Analysis of Free and Dissolved Gases, IEC Publication 60567 (1992-07), 1992.

[17] M. Duval, J. Dukarm. Improving the Reliability of Transformer Gas-in-Oil Diagnosis. IEEE Elect. Insul. Mag., vol.21, no.4, pp. 21–27, 2005.

[18] J. Quinlan. Learning decision tree classifiers. ACM Computing Surveys (CSUR), 28(1):71–72, 1996.

[19] Korting, T. S. C4.5 algorithm and Multivariate Decision Trees. Image Processing Division, National Institute for Space Research – INPE. São José dos Campos – SP, Brazil.

[20] T. M. Cover. Geometrical and Statistical properties of systems of linear inequalities with applications in pattern recognition. IEEE Transactions on Electronic Computers EC-14: 326–334, 1965.

[21] M. Duval and A. de Pablo. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases. IEEE Elect. Insul. Mag., vol. 17, no. 2, pp. 31–41, Mar./Apr. 2001.

[22] M. Duval. A Review of Faults Detectable by Gas-in-Oil Analysis in Transformer. IEEE Electrical Insulation Magazine, Vol. 18, N° 3, pp. 8-17, May/June 2002.

[23] R. Naresh, V. Sharma, and M. Vashisth. An integrated neural fuzzy approach for fault diagnosis of transformers. IEEE Trans. Power Del., vol. 23, no. 4, pp. 2017–2024, Oct. 2008.

[24] Xiaochui Li, Huaren Wu. DGA Interpretation Scheme Derived From Case Study. IEEE Trans. Power Delivery, vol. 26, no. 2, pp. 1292 – 1293, April 2011.

[25] R. Rakotomalala. SIPINA. Programa computacional. Disponível em: <http://eric.univ-lyon2.fr/~ricco/sipina.html>. Acesso em: junho de 2012.

[26] T. Mitchell, Machine Learning, McGraw Hill, 1997.