Análise Comparativa de Técnicas de Inteligência Artificial no Diagnóstico de Falhas em Transformadores de Potência

Alex R. Soto* Shigeaki L. Lima**
Osvaldo R. Saavedra***

*Universidade Federal do Maranhão, São Luís/MA, 65075-380
Brasil (Tel: 98-3272-9202; e-mail: arsotoe@hotmail.com).

**Instituto de Energia Elétrica, Universidade Federal do Maranhão, São Luís/MA, CEP 65075-380,
Brasil (Tel: 98-3272-9202; shigeaki.lima@ufma.br)

*** Instituto de Energia Elétrica, Universidade Federal do Maranhão, São Luís/MA, CEP 65075-380,
Brasil (Tel: 98-3272-8295; o.saavedra@ieee.org)

Abstract: Fault diagnosis in power transformers (TP) is still an open area for the development of maintenance and operation tools for electric power systems. In recent research (2010 to 2018), Dissolved Gas Analysis (DGA) is still the most commonly approach to address the problem of fault diagnosis. Traditional techniques have a low hit rate and power transformers are a valuable asset for power systems. Thus, new methods involving mathematical and computational techniques of Artificial Intelligence (AI) have been developed to aid in the diagnosis with a higher hit rate. Nevertheless, the availability of data has been a limitation, not allowing to generalize the good performance of the algorithms. In this work an evaluation of seven classification algorithms using AGD in power transformers is carried out. From the tests performed, satisfactory results were obtained for two classification algorithms with a performance of approximately 95% using a database of 352 cases.

Resumo: O diagnóstico de falhas em transformadores de potência (TP) ainda é uma área aberta para os pesquisadores no desenvolvimento de ferramentas para operação e manutenção de sistemas de energia elétrica. Nas pesquisas recentes (2010 a 2018), a Análise de Gases Dissolvidos (AGD) segue como a abordagem mais utilizada para tratar o problema de diagnóstico de falhas, considerando que as técnicas tradicionais apresentam uma baixa taxa de acerto e as unidades transformadoras constituem um ativo valioso para os sistemas de energia elétrica. Dessa forma, novos métodos envolvendo técnicas matemáticas e computacionais de Inteligência Artificial (IA) foram desenvolvidos com o objetivo de auxiliar no diagnóstico, possibilitando uma maior taxa de acerto. Não obstante, a disponibilidade de dados de falhas têm sido uma limitante, não permitindo generalizar o bom desempenho dos algoritmos. Neste trabalho é realizada uma avaliação de sete algoritmos de classificação de dados para análise AGD em transformadores de potência. Dos testes realizados, foram observados resultados satisfatórios para dois algoritmos de classificação com um desempenho de aproximadamente 95 % utilizando uma base de dados de 352 casos.

Keywords: Dissolved gas analyses; power transformers; artificial intelligence techniques; conventional techniques; gas failure.

Palavras-chaves: Análise de gases dissolvidos; transformadores de potência; técnicas de inteligência artificial; técnicas convencionais; gases falha.

1. INTRODUÇÃO

Os transformadores de potência são equipamentos importantes e ativos valiosos em sistemas de energia elétrica, sendo fundamentais no provimento de um serviço de energia estável e confiável ao usuário final (SUNG-WOOK KIM et al., 2013). A confiabilidade deste equipamento é altamente dependente do sistema de isolamento (papel-óleo). Quando submetido a um longo período de operação e sobrecargas, podem ocorrer falhas que produzem uma variedade de gases (gases de falha), que podem expor o equipamento a riscos (V. MIRANDA et al., 2012).

A análise de gases dissolvidos (AGD) é um método clássico entre uma variedade de métodos existentes para o diagnóstico de falhas em transformadores de potência (JINGMIN FAN et al., 2017). O AGD utiliza métodos de interpretação da cromatografia dos gases, formalizado nas relações da *International Electrochemical Commission* (IEC), e representado pelo método de Dornenburg, método de Rogers e o triângulo de Duval (JAE-YOON LIM et al., 2017).

Com a inserção de ferramentas matemáticas e de Inteligência Artificial (IA), vários algoritmos foram desenvolvidos para o diagnóstico de falhas em transformadores de potência,

alguns utilizando Lógica Fuzzy (A. ABUSIADA et al., 2013), Máquina Suporte Vetorial (Y. BENMAHAMED et al., 2017), Redes Neurais Artificiais (HUAREN WU et al., 2011) entre outros. Entretanto ainda não há consenso quanto a uma metodologia que resolva satisfatoriamente o problema, pois tanto os métodos convencionais quanto os baseados em IA trabalham com dados pontuais que não permitem generalizar os desempenhos alcançados nas metodologias propostas na literatura atual (S. L. LIMA et al., 2015).

Na universidade de Waikato (Nova Zelândia) foi desenvolvido um pacote de algoritmos classificadores, agrupados e associados em um software computacional denominado WEKA 3.8 (REMCO R. BOUCKAERT et al., 2016). Neste trabalho são avaliados os algoritmos de classificação de dados (baseados em redes neurais, redes Bayesianas e árvore de decisão) por meio do software computacional WEKA, como uma aplicação que permita realizar o diagnóstico de falhas em transformadores de potência baseado em AGD. Considerando que há uma variedade de algoritmos classificadores na plataforma WEKA, foram escolhidos os que apresentam melhor desempenho de cada subgrupo (*bayes, functions, lazy, meta, misc, rules e trees*).

O artigo está organizado como segue: na seção 2, a formulação do problema é apresentada; na seção 3, se apresenta descrição breve dos classificadores pré-selecionados; em seção 4, são desenvolvidas as simulações e análise dos classificadores; finalmente na seção 5 são apresentadas as conclusões do trabalho.

2. ANÁLISE DE GASES DISSOLVIDOS

A identificação de falhas em transformadores de potência a partir da interpretação do AGD implica em associar um conjunto de gases quentes que são formados no interior do transformador, devido a solicitação que tenha sido submetido, por exemplo sobrecargas e a presença de umidade e outros elementos que provoquem a deterioração do óleo isolante.

O que se estabeleceu para o AGD e está contido nas normas (IEC, IEEE, ABNT) é uma relação causa-efeito entre o tipo do gás formado e o tipo da falha observada (Fig.1). De forma geral, os gases imersos no óleo são gerados pela quebra de ligações de hidrocarbonetos, devido a energia térmica e/ou elétrica fornecido durante a operação ou durante falhas elétricas que ocorreram no equipamento.

3. DESCRIÇÃO DE CLASSIFICADORES PRÉ-SELECIONADOS

3.1 Classificador Bayes.BayesNet

É um algoritmo de aprendizagem baseado nas redes bayesianas, para estimar as tabelas de probabilidade condicional da rede é utilizado o algoritmo de aprendizado denominado de árvore *Naïve Bayes* aumentada (TAN) (IAN H. WITTEN et al., 2011), sendo este aprendizado considerado como o mais sofisticado baseado no escalonamento, *simulated annealing* e *algoritmos genéticos*.

Opcionalmente a velocidade de busca pode ser melhorada usando árvores de decisão adicionais.

3.4 Classificador Meta.AttributeSelectedClassifier

Este algoritmo classificador possui um processo de pré-seleção da base de dados considerando os atributos das condições de classificação (tipos de falhas). Esta característica torna esse classificador mais eficiente, pois a seleção de atributos permite obter informação conjunta dos dados que serão processados no treinamento IAN H. WITTEN et al., 2011).

3.5 Classificador Misc.InputMappedClassifier

Este algoritmo tem como processo de mapeamento os dados de treinamento e teste. Os atributos do modelo que não foram encontrados nos dados de entrada são gerados pelo algoritmo, enquanto o atributo não visto pelo algoritmo pode ser treinado em um novo classificador.

3.6 Classificador Rules.PART

É um algoritmo classificador que tem a particularidade de obter as regras de classificação a partir de árvores de decisão, este processo é obtido sob a heurística do algoritmo c4.5, usado na geração de árvores de decisão sob o conceito de entropia da informação em cada nó de decisão (QUINLAN, J.R, 193).

3.7 Classificador Trees.J48

É um algoritmo classificador de árvore de decisão, sendo o classificador Tree J48 a última versão de acesso público em JAVA c4.5 (QUINLAN, J.R, 193). Na implementação é considerado o enxerto de ramificações adicionais no processo de pós-processamento, alcançando vantagem superiores a árvores de estrutura única, interpretável e incluindo árvores convencionais e reforçados.

4. ANÁLISE E TESTE DE ALGORITMOS CLASSIFICADORES

4.1 Dados utilizados

Neste artigo foi utilizada uma base de dados com 352 amostras de gases/falhas, sendo que 246 foram utilizados para o treinamento e 106 para validação de todos os classificadores. As relações de gases utilizadas como dados de entrada são as estabelecidas na norma IEC 60599 (C2H2/C2H4, CH4/H2, C2H4/C2H6) (JAE-YOON LIM et al., 2017), e as saídas classificadas estarão armazenadas no vetor TIP de condições de classificação (tipos de falha), com os códigos tipificados (PD, DL, DH, T1, T2, T3 e NOR) de condição de falha, sendo:

PD: Descarga parcial

DL: Descarga de baixa energia

DH: Descarga de alta energia

T1: Falha térmica $T < 300^{\circ}\text{C}$

T2: Falha térmica $300^{\circ}\text{C} < T < 700^{\circ}\text{C}$

T3: Falha térmica $T > 700^{\circ}\text{C}$

NOR: Condição normal

Na tabela 1 é apresentada uma distribuição de condições de classificação por tipo de algoritmo classificador. Por cada quadro de classificação, a diagonal indica às condições de classificação correta, enquanto os dados fora de diagonal as condições de classificação incorretas.

Considerando como referência o classificador Trees.J48, as falhas de alta energia (DH) tem um acerto total (25 falhas), enquanto as falhas de baixa energia (DL) foram classificadas 14 corretamente, 1 foi classificada como descarga de alta energia (DH), 1 foi classificada como falha térmica $T < 300^{\circ}\text{C}$ (T1) e 1 como falha de descarga parcial (PD).

Tabela 1. Algoritmos avaliados

		DH	T1	NOR	T2	DL	PD
bayes.BayesNet	DH	23	0	0	0	2	0
	T1	0	23	0	0	0	0
	NOR	1	0	6	0	1	2
	T2	0	0	0	23	0	0
	DL	1	0	1	0	13	2
	PD	0	0	0	0	1	7
lazy.IBk	DH	23	0	1	0	1	0
	T1	0	21	2	0	0	0
	NOR	0	0	9	0	0	1
	T2	0	0	3	20	0	0
	DL	2	0	0	0	15	0
	PD	0	0	0	0	1	7
functions.Mul tilayerPercept ron	DH	25	0	0	0	0	0
	T1	0	23	0	0	0	0
	NOR	4	1	4	0	0	1
	T2	0	0	0	23	0	0
	DL	1	1	0	0	15	0
	PD	0	0	0	0	1	7
rules.PART	DH	24	0	1	0	0	0
	T1	0	23	0	0	0	0
	NOR	2	0	6	0	0	2
	T2	0	0	0	23	0	0
	DL	1	1	1	0	13	1
	PD	0	0	0	0		8
trees.J48	DH	25	0	0	0	0	0
	T1	0	23	0	0	0	0
	NOR	0	0	8	0	0	2
	T2	0	0	0	23	0	0
	DL	1	1	0	0	14	1
	PD	0	0	0	0	0	8
meta.AttributeS electClassi	DH	25	0	0	0	0	0
	T1	0	23	0	0	0	0
	NOR	0	0	8	0	0	2
	T2	0	0	0	23	0	0
	DL	1	1	0	0	14	1
	PD	0	0	0	0	0	8
misc.InputMa ppedClassifier	DH	25	0	0	0	0	0
	T1	23	0	0	0	0	0
	NOR	10	0	0	0	0	0
	T2	23	0	0	0	0	0
	DL	17	0	0	0	0	0
	PD	8	0	0	0	0	0

Da tabela 1 são determinadas as taxas de acerto e erro para os algoritmos avaliados, considerando as seguintes definições:

$$\begin{aligned} Taxa_acerto &= \frac{NA}{NM} \\ Taxa_erro &= \frac{NE}{NM} \end{aligned} \quad (1)$$

Em que:

NA: Número de amostras classificadas corretamente

NE: Número de amostras classificadas incorretamente

NM: Número de amostras.

Na figura 2 é apresentado um histograma com a avaliação dos algoritmos, considerando taxa de acerto e erro.

Fig. 2 Histograma de avaliação de desempenho dos classificadores no DGA

Em tabela 1 e Fig. 2, é apresentado o desempenho (taxa de acerto) do classificador Misc.InputMappedClassifier com um valor de 23,58 %. Este nível de acerto é muito baixo, se comparado com as técnicas de AGD convencional (Rogers, IEC60599 e Doremberg) encontradas na literatura especializada. Portanto, este método não será avaliado neste trabalho. Os demais foram agrupados em três grupos, segundo o desempenho e serão analisados a seguir.

4.2 Grupo 1: Bayes.BayesNet e lazy.IBk

Estes classificadores têm uma taxa de acerto similar, da ordem de 0,896. Todavia, de acordo com os dados expostos na tabela 1, é observado que o processo de classificação por estado de falha durante a validação dos algoritmos é diferente um do outro.

O classificador Bayes.BayesNet após treino e teste, obteve uma boa taxa de acerto para os tipos de falhas térmicas (T1 e T2). Entretanto, para os tipos de falhas (DH, DL, PD, NOR) apresentou um pequeno número casos classificados incorretamente. Já o classificador Lazy.IBk tem uma taxa de acerto igual ao Bayes.BayesNet. Entretanto, a classificação por tipo de falha apresentou classificações incorretas em todos os tipos de falhas.

A partir dos dois algoritmos analisados é possível afirmar que o algoritmo Bayes.BayesNet tem melhor desempenho, sendo que as condições de fronteira para os dois tipos de falhas (T1 e T2) obtidos no processo de validação é classificada corretamente. Entretanto, no segundo algoritmo, para todas as condições de classificação, ocorre algum erro de classificação, como mostrado na tabela 1.

4.3 Grupo 2: Functions.MultilayerPerceptron e rules.PART

O algoritmo baseado em Redes Neurais Artificiais e Árvores de Decisão obteve uma taxa de acerto 0,915. O classificador Functions.MultilayerPerceptron, conseguiu classificar corretamente três (03) tipos de falhas (T1, T2, DH). Nos demais casos apenas 26 foram classificados corretamente e 9 dados classificados incorretamente (tabela 1). Já o classificador Rules.PART classificou corretamente três (03) tipos de falhas (T1, T2, PD), 43 foram classificados corretamente e 9 dados classificados incorretamente (tabela 1).

Dos algoritmos classificadores supracitados é possível constatar que as falhas térmicas têm uma condição de fronteira bem estabelecida, o qual facilitou a classificação enquanto para outros tipos de falhas esse processo é mais complexo, havendo interseção entre as fronteiras dos gases, o qual dificulta a classificação correta.

4.4 Grupo 3: Trees.J48 e Meta.AttributeSelectedClassifier

Estes classificadores utilizam árvore de decisão, e ambos obtiveram uma taxa de acerto 0,9528. Por meio da figura 2 e figura 3 é possível afirmar que os algoritmos tem a mesma taxa de classificação por falha, sendo um comportamento de fronteira bem estabelecido para os quatro (04) tipos de falhas (DH, T1,T2, PD), e apenas para os tipos de classificação (NOR, DL) se apresenta instabilidade nas condições de fronteira de classificação.

Fig. 3 Histogramas de erro médio absoluto por algoritmo de classificação.

Uma vez que os classificadores foram agrupados por taxa de acerto, foi observado que nos itens 4.2 e 4.3 houve diferença na classificação das condições de falha. Estas diferenças

podem ser observadas no histograma de erro médio absoluto da figura 3.

Assim mesmo na figura 3 é observado que o algoritmo Misc.InputMappedClassifier tem o erro médio absoluto mais alto (0,269), enquanto os algoritmos de melhor adequação no AGD são Trees.J48 e Meta.AttributeSelectedClassifier com um erro de apenas 0,033.

5. CONCLUSÕES

Os métodos convencionais de diagnóstico de falhas em transformadores de potência podem proporcionar uma informação importante enquanto a classificação de falhas. Entretanto, os métodos mais populares (IEC 50699, Rogers, Doremberg e Triângulo de Duval) nem sempre podem classificar todas as condições de falha como indicado na literatura especializada. Por outro lado, existem técnicas computacionais e matemáticas baseadas em inteligência artificial (redes Bayesianas, redes neurais artificiais, lógica fuzzy, árvores de decisão e outros) que podem ser utilizadas com objetivo de alcançar uma melhora no desempenho e robustez do classificador.

Seguindo esse entendimento, neste artigo foi reportada a avaliação de um conjunto de algoritmos de classificação baseado em IA, que se encontram inseridos e disponíveis na plataforma WEKA, e comparando o desempenho quando aplicado ao problema do diagnóstico de falhas em transformadores de potência através de análises de gases dissolvidos.

Dentre os algoritmos avaliados, o classificador Misc.InputMappedClassifier teve uma taxa de desempenho mais baixa de todos os algoritmos, alcançando apenas uma classificação de 23,58 % dos dados no processo de validação.

Dos algoritmos agrupados com desempenho de 89,62 % (grupo 1), foi verificada superioridade do classificador com técnicas de redes bayesianas (bayes.BayesNet), que classificou as falhas térmicas corretamente. Já no grupo de algoritmos com desempenho de 91,51 % (grupo 2) foi verificado um bom desempenho, também sobre as falhas térmicas em relação as demais falhas, e no último grupo foi verificado que os algoritmos alcançaram uma taxa de acerto de até 95,28 % (grupo 3), com distribuição de taxa de acerto e erro médio absoluto por condição de falha com indicadores iguais.

Após a análise de todos os grupos de algoritmos classificadores, foi concluído que as falhas térmicas tanto T1 e T2 tem as condições de fronteira bem estabelecidas, em quanto que se verifica que os algoritmos trees.J48 e meta.AttributeSelectedClassifier, tem um desempenho superior em relação aos restantes, dentro do universo disponível na versão WEKA 3.8.

AGRADECIMENTOS

Ao Grupo Equatorial Energia, representado pela empresa de distribuição de energia do Maranhão e Pará (CEMAR/CELPA) pelo apoio no projeto de pesquisa e

desenvolvimento denominado “Diagnóstico de falhas on-line em transformadores de potência”, no qual é baseado esse trabalho. Ao CNPq pelo apoio a um dos coautores.

REFERÊNCIAS

- A. Abu-Siada, S. Hmood and S. Islam (2013). A New Fuzzy Logic Approach for Consistent Interpretation of Dissolved Gas-in-Oil Analysis. *IEEE Transactions on Dielectrics and Electrical Insulation*, volume (20), 1-7.
- Huaren Wu, Xiaohui Li and Danning Wu (2011). RMP Neural Network Based Dissolved Gas Analyzer for Fault Diagnostic of Oil-filled Electrical Equipment. *IEEE Transactions on Dielectrics and Electrical Insulation*, volume (18), 1-4.
- Ian H. Witten, Eibe Frank and Mark A. Hall (2011). *Data Mining: practical machine learning tools and techniques*, page 269. Morgan Kaufmann Publishers, Burlington, MA 01803, USA
- Jingmin Fan1, Feng Wang, Qiuqin Sun, Feng Bin, Fangwei Liang, Xuanyi Xiao (2017). Hybrid RVM–ANFIS algorithm for transformer fault diagnosis. *IET Generation, Transmission & Distribution*, volume (11), 1.
- Jae-Yoon Lim, Dae-Jong Lee, and, Pyeong-Shik Ji (2017). Fault Diagnosis of Power Transformer Using Confidence Weight based Fusion Method. *IEEE Transactions on Dielectrics and Electrical Insulation*, volume (1), 1-4.
- Quinlan, J.R (1993). ‘C4.5: programs for machine learning’, page 13. Morgan Kaufmann Publishers, San Mate
- Remco R. Bouckaert, Eibe Frank, Mark Hall, Richard Kirkby, Peter Reutemann, Alex Seewald and David Scuse (2016). ‘WEKA Manual for Version 3-8-1’, page 13. University of Waikato, Hamilton, New Zealand.
- S. L. Lima, O. R. Saavedra and V. Miranda, A Two-Level (2015). Framework to Fault Diagnosis and Decision Making for Power Transformers, *IEEE Transactions on Power Delivery*, vol. 30, no. 1
- Sung-wook Kim, Sung-jik Kim, Hwang-dong Seo, Jae-ryong Jung, Hang-jun Yang (2013). New Methods of DGA Diagnosis using IEC TC 10 and Related Databases Part 1: Application of Gas-ratio Combinations. *IEEE Transactions on Dielectrics and Electrical Insulation*, volume (20), 1.
- V. Miranda, A. R. G. Castro and S. Lima (2012). Diagnosing Faults in Power Transformers With Autoassociative Neural Networks and Mean Shift, *IEEE Transactions on Power Delivery*, vol. 27, no. 3
- Y. Benmahamed, M. Tegar and A. Boubakeur (2017). Application of SVM and KNN to Duval Pentagon 1 for Transformer Oil Diagnosis. *IEEE Transactions on Dielectrics and Electrical Insulation*, volume (24), 1-9.
- GLOBECORE COMPANY: TRANSFORMADOR OIL, disponível em <https://globecore.com/6-transformer-oils.html>. Acesso em 05/05/2019