



GRUPO DE ESTUDO DE TRANSFORMADORES, REATORES, MATERIAIS E TECNOLOGIAS EMERGENTES - GTM

DIAGNÓSTICO EM TRANSFORMADORES DE POTÊNCIA E REATORES DA ARGO COM O USO DE REDES NEURAIS ARTIFICIAIS

**RAFAEL DE OLIVEIRA FERNANDES*(1); BEATRIZ DE LIMA TAVARES(1); VICTOR HUGO PARREIRA
ROSA(1); ERIOSVALDO ALMEIDA DE SANTANA(1)
ARGO ENERGIA (1)**

RESUMO

O foco principal deste trabalho é o uso de RNA (Redes Neurais Artificiais) para a análise de causa-raiz de Emissão de Gases Dissolvidos (EGD) em óleo isolante de um Transformador de Potência (TR) e de um Reator, ambos de Alta Tensão, da Argo Energia. Para a etapa de treinamento, utilizou-se dados simulados das relações de gases dissolvidos, e para a etapa de operação utilizou-se dados reais obtidos através da análise cromatológica de EGD do óleo isolante do TR e do Reator. Com os resultados obtidos, demonstrou-se a possibilidade do uso de RNA para a análise de gases dissolvidos nos equipamentos.

PALAVRAS-CHAVE

Redes Neurais Artificiais, Gases Dissolvidos, Transformador de Potência, Reator, Análise Preditiva.

1.0 INTRODUÇÃO

Um TR é um ativo muito importante e valioso em uma instalação de um sistema elétrico de potência. Uma avaria em um transformador, por exemplo, causa a interrupção de energia elétrica de serviços, e consequentemente penalidades junto aos órgãos de regulação e custos adicionais de reparo para as transmissoras de energia, antes do seu retorno em operação. Já um Reator *Shunt* (RS), durante a operação normal de um sistema de energia elétrica, tem a função, por exemplo, de manter as tensões de transmissão e de distribuição dentro de uma pequena faixa operativa, tipicamente entre 0,95 a 1,05 pu do valor nominal, diante do balanço de potência reativa. Uma outra aplicação importante de um RS é a sua utilização para evitar-se o efeito *Ferranti* - que consiste no aumento da tensão sustentada, em regime permanente, na extremidade aberta de uma linha de transmissão, sendo que os tipos mais comuns em sistemas de transmissão de alta e extra-alta tensão são os imersos em óleo.

A confiabilidade e a disponibilidade de um TR e RS estão relacionadas com o seu ciclo de vida, projetado pelo fabricante, contudo, ao considerar-se os equipamentos na ótica da operação elétrica, tais condições de operação, por exemplo, como operar fora da sua faixa limite de tensão, de fluxo de potência, podem trazer condições adversas ao equipamento, as quais tenderão a reduzir o seu ciclo de vida. Desta forma, a detecção prévia de EGD tem um papel preventivo muito importante em relação às condições operativas adversas do equipamento. Neste trabalho, serão apresentados os resultados somente de EGD de um TR da Argo, dado que as análises cromatológicas de EGD dos Reatores da Argo não indicaram EGD suficientes para pudessem ser aplicadas nas análises.

A análise de EGD é uma metodologia usada como uma ferramenta para diagnósticos de falha e de manutenção de equipamentos imersos em óleo. Desta forma, a análise de gases dissolvidos é considerada como sendo uma das melhores técnicas para o diagnóstico de falhas iminentes em tais equipamentos. A metodologia mais aceita na análise de processos de emissão de gases nestes equipamentos é a análise cromatológica do óleo isolante, que permite obter o conteúdo de gases de hidrogênio (acetileno - C₂H₂, etileno - C₂H₄, etano - C₂H₆ e metano - CH₄), assim como obter o conteúdo de óxidos (monóxido de carbono - CO e dióxido de carbono - CO₂), gerados pela reação química, condições de operação elétrica e estresse mecânico e térmico dos equipamentos [1], [2]. A relação de causa e efeito entre o tipo de gás formado e o tipo de falha estão diretamente ligadas com a quantidade de gases emitidos. Dependendo das relações obtidas, tem-se a classificação da causa-raiz da falha, podendo ser, por exemplo: Falha Térmica (FT), Descarga Parcial (DP), Descarga Parcial de Baixa Densidade de Energia (DPBDE), Descarga Parcial de Alta Densidade de Energia (DPADE), Envelhecimento Normal (ENN), Descarga de Alta Energia com Centelhamento Contínuo (DAECC) e Descarga de Alta Energia de Arco com Fluxo de Potência (DAEAFP).

2.0 ANÁLISE DE GASES DISSOLVIDOS

O procedimento de EGD em equipamentos é realizado em três etapas: amostragem, extração e análise, sendo que a metodologia mais aceita é o processo de análise de cromatografia, que permite obter os conteúdos dos gases de hidrogênio, assim como os derivados dos óxidos. A relação de causa e efeito entre o tipo de gás formado e o tipo de falha observada, pode ser verificada conforme a Figura 1. Observa-se a associação entre a EGD e as falhas incipientes nos equipamentos, contudo, a interpretação para essas associações ainda é um ponto de discussão em aberto e que vem sendo aprimorado ao longo do tempo [3], [4].




Figura 1 – Geração de Gases Combustíveis e Temperatura. Fonte [4]

2.1 Métodos de Interpretação da EGD

O método utilizado neste trabalho para a EGD no óleo isolante dos equipamentos foi realizado de acordo com [1] e [2], onde consideram-se como parâmetros de entrada os conteúdos de gases: H₂, CH₄, C₂H₂, C₂H₄, C₂H₆ e CO, assim como as relações de gases: R₁ = C₂H₂/C₂H₄, R₂ = CH₄/H₂, R₃ = C₂H₂/CH₄, R₄ = C₂H₆/C₂H₂, R₅ = C₂H₄/C₂H₆ e R₆ = C₂H₆/CH₄, enquanto que as saídas são as condições de diagnóstico do TR.

De acordo com a metodologia adotada, as condições de diagnóstico são classificadas em térmicas, falhas elétricas, condição normal e casos sem identificação [3] e [4]. Para o diagnóstico de EGD adotou-se as seguintes condições de relação de gases para os tipos de falha, conforme a Tabela 1, onde é possível verificar a classificação de diagnóstico de falha de acordo com o apresentado em [1].

Tabela 1 – Diagnóstico de Falha - IEC 60599 [1]

Tipo de Falha	R1	R2	R5
DP	Não aplicável (NA)	<0,1	<0,2
DPBDE	>1	0,1 – 0,5	>1
DPADE	0,6 – 2,5	0,1 - 1	>2
FT (T<300°C)	NA	>1	1 - 4
FT (300°C<T<700°C)	<0,1	>1	1 - 4
FT (T>700°C)	<0,2	>1	>4

Para a aplicação prática com os dados simulados e dados reais, considerou-se as seguintes condições e inequações:

R1: SE(R1<>" ", SE(R1<=0,1, "0", SE(E(R1>0,1, R1<= 3), "1", "2"))),""

R2: SE(R2<>" ", SE(R2<=0,1, "1", SE(E(R2>0,1, R2<= 1), "0", "2"))),""

R5: SE(R3<>" ", SE(R3<=1, "0", SE(E(R3>1, R3<= 3), "1", "2"))),""

Diante das três condições e inequações apresentadas, classificou-se as causas de acordo com a Tabela 2.

Tabela 2 – Classificação da Causa-Raiz

R1	R2	R5	Causa
0	0	0	ENN
0	1	0	DPBDE
1	1	0	DPADE
1	0	1	DAECC
2	0	2	DAECC
1	0	2	DAEAFP
0	0	1	FT < 150°C
0	2	0	FT 150 - 300°C
0	2	1	FT 300 - 700°C
0	2	2	FT > 700°C
Outra combinação			Não se aplica

2.2 Redes Neurais Artificiais

Após a adoção do critério de classificação da causa-raiz, baseando-se nas relações de gases dissolvidos no óleo isolante, implementou-se uma RNA MLP (*Multi-Layer Perceptron*), inserção de momento e taxa de aprendizado [4-6]. Este tipo de rede pertence à arquitetura *feedforward* de camadas múltiplas, cujo treinamento é efetivado de forma supervisionado [6]. Na etapa de treinamento da RNA, com o intuito de se obter a matriz de pesos sinápticos, utilizou-se dados simulados baseados nas três condições e inequações apresentadas no item 2.1 deste trabalho, bem como no critério de classificação apresentado na Tabela 2. Os dados simulados foram obtidos através de simulação aleatória das amostras de entrada, mantendo-se os valores mínimos e máximos de acordo com as três condições e inequações apresentadas, sendo que os dados utilizados foram normalizados.

Para a etapa de treinamento, considerou-se 6 saídas, sendo elas: **FT** (150 - 300°C), **DPBDE**, **DPBAE**, **ENN**, **DAECC** e **DAEAFP**, num total de 68 amostras. A fim de validar a rede treinada, obteve-se mais um conjunto de dados simulados para a etapa de operação, num total de 32 amostras. Já na etapa de operação, como entrada de parâmetros para a RNA considerou-se a relação dos gases emitidos de acordo com a norma IEC 60599 [1], com as seguintes relações de gases: C₂H₂/C₂H₄, CH₄/H₂, C₂H₄/C₂H₆ e C₂H₂/C₂H₆. Vale destacar que no novo valor da relação de gases, relação C₂H₂/C₂H₆, foi obtido de acordo com o exposto em [4].

Nesta etapa de operação, as relações foram obtidas através de leituras reais das análises laboratoriais, considerando-se um transformador de potência de 100 MVA, 550/20 kV, fabricado no ano de 2018, de concessão da Argo Energia. Nesta etapa de operação, obteve-se 37 medições em campo, intercaladas semanalmente, com dados obtidos através do processo normal de manutenção preventiva da empresa.

Na Figura 2, é possível verificar-se a arquitetura RNA MLP adotada neste trabalho durante a etapa de treinamento, considerando-se quatro amostras de dados de entrada, uma camada de neurônio escondida, e uma camada de neurônio de saída, com 6 saídas.




Figura 2 – Arquitetura MLP – Etapa de Treinamento/Operação – Dados Simulados

Já na Tabela 3, tem-se a classificação da causa-raiz, de acordo com a combinação das saídas, via a entrada de dados.

Tabela 3 – Entradas / Saídas MLP

Saída Binária	Classificação
1 0 0 0 0 0	FT (150 – 300 °C)
0 1 0 0 0 0	DPBDE
0 0 1 0 0 0	DPADE
0 0 0 1 0 0	ENN
0 0 0 0 1 0	DAECC
0 0 0 0 0 1	DAEAFP

3.0 IMPLEMENTAÇÃO RNA MLP

Utilizando-se a plataforma computacional de programação *Matlab*, foi desenvolvido e implementado uma RNA MLP, sem o uso de *toolbox*, com 4 amostras de entrada, 1 camada intermediária (escondida) com 15 neurônios e uma camada de neurônio de saída. A taxa de aprendizado utilizada foi: $\eta=0,022$ e a taxa de momento foi: $\alpha = 0,9$. A função de ativação foi a degrau unitária, e as saídas foram processadas de modo a ter-se os valores binários de acordo com o apresentado na Tabela 3. Os pesos sinápticos foram ajustados durante a etapa de treinamento (aprendizagem) da RNA, cuja arquitetura, de modo resumido, pode ser verificada na Figura 2.

3.1 Etapa de Treinamento e Operação – Dados Simulados

De acordo com [4], o uso da relação Rnovo = C2H2/C2H6, como sendo a quarta amostra de entrada da RNA MLP, apresentou resultados mais consistentes do que apenas considerar-se as relações R1, R2 e R5 e, por este motivo, esta quarta relação foi utilizada neste trabalho. Desta forma, este trabalho utilizou 4 amostras de entrada, conforme pode ser observado na Figura 2. O número total de amostras da etapa de treinamento foi de 68 amostras para cada relação de gases. A fim de obter-se o desempenho da rede implementada, simulou-se um novo conjunto de dados, tendo-se agora um conjunto de dados de operação, com 29 amostras para cada relação de gases. Na Figura 3-a), tem-se a distribuição das amostras de treinamento dos dados simulados e, na Figura 3-b), tem-se as amostras de operação dos dados simulados.

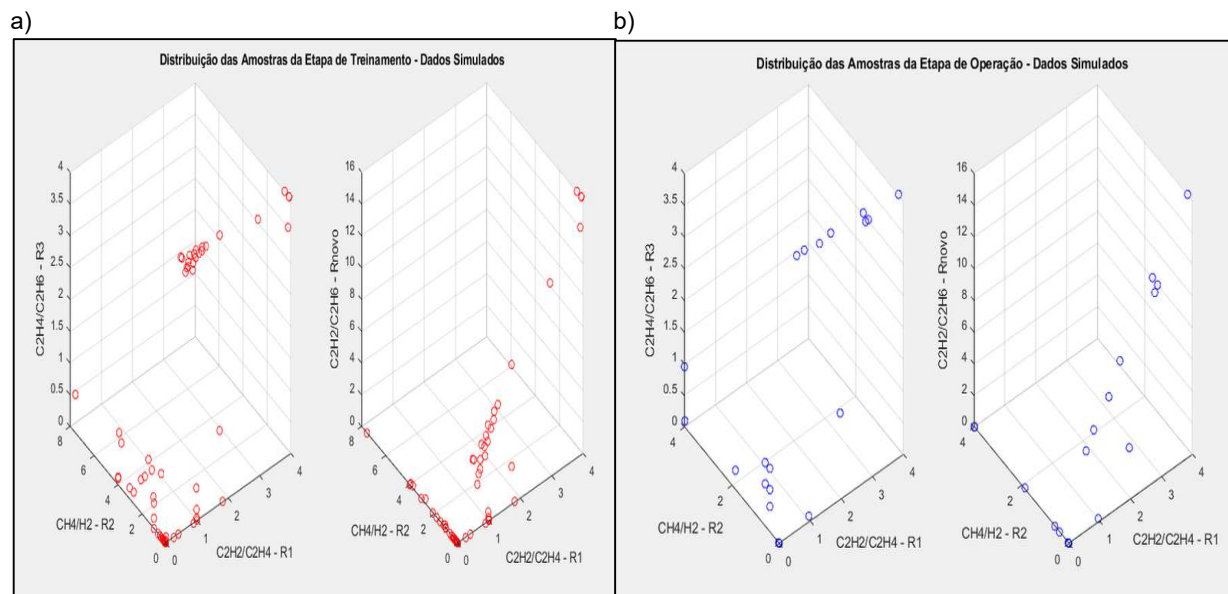


Figura 3 - Distribuição das Amostras dos Dados Simulados a) Treinamento, b) Operação

3.1.1 Resultados Obtidos

Após a leitura dos dados no algoritmo desenvolvido, obteve-se os resultados apresentados na Tabela 4. Na Figura 4, apresenta-se o Erro Quadrático Médio (EQM), sendo que houve uma convergência muito rápida do algoritmo. O número total de épocas pode ser alterado devido aos valores de pesos sinápticos obtidos na etapa de treinamento.

Tabela 4 – Resumo Resultados Obtidos

A	B	C	D	E	F
68	29	2559	0,0308	21,23	100

Onde:

A = Número de amostras da etapa de treinamento;

B = Número de amostras da etapa de operação;

C = Número de épocas;

D = Erro quadrático médio;

E = Tempo de processamento, em segundos;

F = Taxa de acerto, em porcentagem.




Figura 4 – Erro Quadrático Médio - Etapa de Operação (Dados Simulados)

3.2 Etapa de Treinamento e Operação – Dados Reais

Após a análise qualitativa e quantitativa dos dados reais obtidos através dos resultados de análise laboratorial (cromatológica) da EGD e, pelo fato do TR ainda ser considerado um equipamento novo e em operação comercial

desde o ano de 2019, observou-se que os resultados indicaram apenas 4 possíveis causa-raiz, sendo elas: FT (150 - 300°C), DPBDE, ENN e DAECC.

Assim, utilizou-se os dados da Fase A do TR (37 amostras para a etapa de treinamento), e das Fases B (50 amostras) e C (36 amostras), para a etapa de operação, respectivamente. Portanto, nas Figuras 5-a, 5-b e 6, respectivamente, tem-se a distribuição das amostras de relação de EGD dos dados reais obtidos através das análises de cromatografia do TR, tanto da etapa de treinamento, como da etapa de operação.

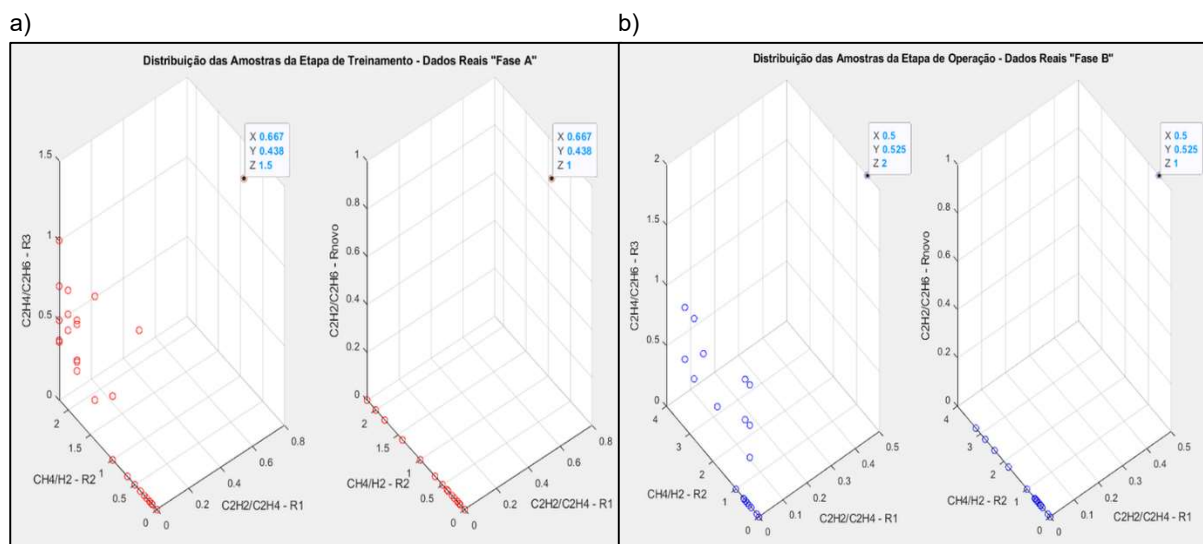


Figura 5 – a) Distribuição das Amostras de Dados Reais de Treinamento – Fase A, b) Distribuição das Amostras de Dados Reais de Operação – Fase B




Figura 6 – Distribuição das Amostras de Dados Reais de Operação – Fase C

Considerando-se agora somente 4 saídas da MLP, a nova arquitetura obtida está de acordo com o apresentado na Figura 7. Já na Tabela 5, apresenta-se a nova classificação, agora considerando-se apenas 4 saídas.

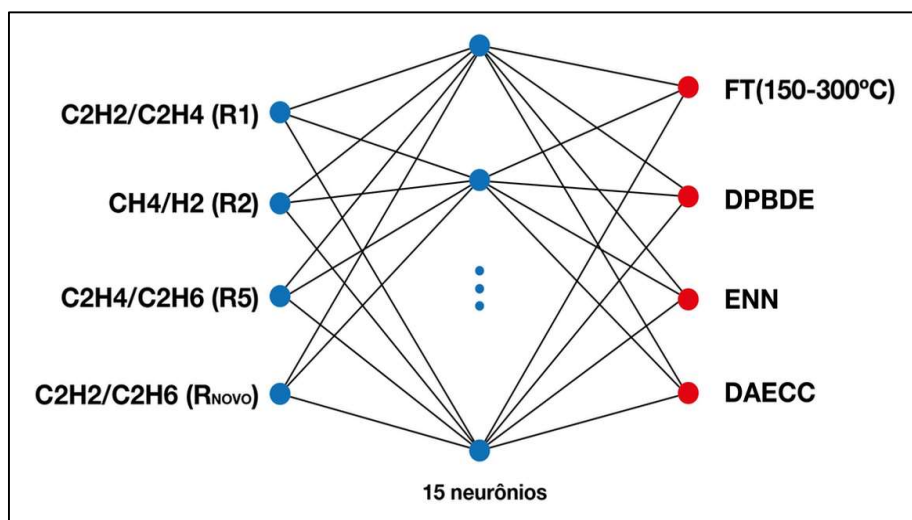


Figura 7 – Arquitetura MLP – Etapa de Treinamento/Operação - Dados Reais

Tabela 5 – Entradas / Saídas MLP

Saída Binária	Classificação
1 0 0 0 0 0	FT (150 – 300 °C)
0 1 0 0 0 0	DPBDE
0 0 1 0 0 0	ENN
0 0 0 1 0 0	DAECC

3.2.1 Resultados Obtidos

Após a leitura dos dados no algoritmo implementado, obteve-se os resultados de acordo com as Tabelas 6 e 7, assim como o EQM, de acordo com as Figuras 8 e 9, respectivamente. As letras de A à F possuem o mesmo significado, conforme já descritas na Tabela 4.

Tabela 6 – Resultados Obtidos – Fase **A** Treinamento

Fase **B** Operação

A	B	C	D	E	F
37	50	3066	0,0254	14,35	100

Tabela 7 – Resultados Obtidos – Fase **A** Treinamento

Fase **C** Operação

A	B	C	D	E	F
37	36	3070	0,0253	15,36	100




Figura 8 – EQM – Fase A Treinamento, Fase B Operação




Figura 9 – EQM – Fase A Treinamento, Fase C Operação

3.3 Matrizes de Pesos Sinápticos

Considerando-se os dados simulados, com a arquitetura da rede tendo-se 6 saídas, na Tabela 8, tem-se a matriz de pesos sinápticos entre a camada intermediária e a camada de neurônios de saída. Já na Tabela 9, tem-se a matriz de pesos sinápticos entre a primeira camada de neurônios (amostras de entrada) e a camada intermediária, obtidas após a etapa de treinamento.

Tabela 8 – Matriz de Pesos Sinápticos Camada Intermediária ↔ Camada de Saída

w_{ji}	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	3,152	0,408	0,791	-2,034	-1,582	1,357	1,247	-3,086	-1,590	-0,818	2,521	-0,351	1,298	0,486	-0,374	-1,898
2	-3,121	-4,355	-3,214	-1,607	-1,592	-0,755	-1,201	4,009	1,535	-0,909	-1,861	0,076	-3,077	-0,519	-0,418	0,643
3	2,791	-1,709	1,885	3,946	3,435	-2,330	0,205	0,054	-1,465	0,101	-2,562	-1,078	1,285	-1,696	-1,211	-1,121
4	1,051	5,628	-2,030	-2,828	-0,279	-1,627	-3,031	-1,784	-0,206	-1,179	-3,111	0,123	-0,190	-1,399	2,538	-0,576
5	4,553	-0,248	-1,409	-0,225	5,107	-0,523	0,573	-0,743	0,221	0,648	1,215	1,437	-1,516	1,812	-2,019	1,615
6	3,540	-0,998	-0,764	1,297	-6,298	0,029	0,292	0,537	1,012	0,639	0,733	1,616	-0,597	1,150	0,177	1,788

Tabela 9 – Matriz de Pesos Sinápticos
Primeira Camada de Neurônios ↔ Camada Intermediária

w_{ji}	1	2	3	4	5
1	0,951	0,961	7,927	1,043	0,514
2	1,128	4,365	1,596	0,390	0,252
3	0,659	4,992	-2,482	-0,467	1,258
4	0,750	4,596	0,177	-3,794	0,019
5	1,888	-0,601	1,795	0,757	0,585
6	2,597	1,843	2,421	0,677	0,630
7	-0,735	-0,480	-3,975	0,047	0,961
8	0,063	-0,866	-1,100	0,637	1,107
9	1,419	1,327	0,404	0,083	1,015
10	3,577	0,408	3,342	0,869	1,650
11	2,044	0,115	-0,349	1,029	1,480
12	0,888	3,564	2,279	0,388	0,511

13	2,322	0,036	1,583	0,959	1,740
14	-0,042	-0,105	3,542	1,267	-0,458
15	1,296	-0,256	-1,027	0,411	1,973

Considerando-se agora os dados reais, com a arquitetura da rede tendo-se 4 saídas, na Tabela 10, tem-se a matriz de pesos sinápticos entre a camada intermediária e a camada de neurônios de saída. Já na Tabela 11, tem-se a matriz de pesos sinápticos entre a primeira camada de neurônios (amostras de entrada) e a camada intermediária, obtidas após a etapa de treinamento.

Tabela 10 – Matriz de Pesos Sinápticos Camada Intermediária ↔ Camada de Saída

w_{ji}	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	4,374	1,252	1,678	-1,357	1,680	1,348	1,135	-0,284	3,250	-0,137	-1,705	-2,641	-1,041	-0,565	1,051	-1,508
2	0,653	-2,989	-1,625	2,415	-1,302	-1,552	-1,474	0,779	-1,648	-2,592	2,235	1,170	0,294	-0,257	-2,550	1,761
3	-0,001	3,415	-0,761	-3,763	-1,101	-2,025	-1,866	0,472	-4,504	3,035	-0,490	0,129	0,459	-0,494	-1,309	-0,947
4	2,895	-1,388	-0,933	1,497	-1,465	0,462	1,505	-0,722	0,267	0,484	0,999	-1,261	0,682	0,970	0,109	0,241

Tabela 11 – Matriz de Pesos Sinápticos
Primeira Camada de Neurônios ↔ Camada Intermediária

w_{ji}	1	2	3	4	5
1	0,543	-0,529	5,021	-0,236	-1,083
2	2,065	0,219	2,112	-0,416	-0,006
3	-0,391	1,471	-4,360	0,040	1,747
4	2,135	-0,342	2,068	-0,202	-0,413
5	2,666	1,209	2,151	0,606	0,536
6	2,673	1,229	1,828	1,274	0,976
7	0,865	0,040	-0,144	-0,394	-0,351
8	4,877	0,762	3,895	0,996	0,913
9	0,543	0,369	4,329	1,471	0,392
10	-0,273	0,427	-1,974	0,980	0,266
11	-1,361	-0,040	-1,141	-0,786	-0,560
12	0,714	0,543	-0,249	0,157	0,849
13	0,626	1,134	-0,046	0,590	0,504
14	2,118	0,772	2,041	0,172	0,895
15	-0,294	0,542	-1,896	-0,042	0,577

4.0 ANÁLISE DOS RESULTADOS

Em relação à etapa de treinamento e de operação, considerando-se somente os dados simulados e obtidos de acordo com os critérios apresentados na Tabela 1, houve uma taxa de acerto de 100% para as 6 classificações.

Já em relação à etapa de treinamento e operação, com somente a utilização de dados reais, obtidos via a análise cromatológica do óleo isolante do TR, agora considerando-se 4 classificações (4 saídas), houve, também, uma taxa de acerto de 100%, demonstrando-se que a rede foi treinada de modo adequado e, neste caso, confirmando-se que a arquitetura da rede MLP utilizada se mostrou adequada para este tipo de aplicação.

Apesar do número de épocas ter apresentado um número elevado, o tempo de processamento foi relativamente baixo, com o maior tempo registrado de apenas 21,23 s. Não houve a necessidade de ter-se mais de uma camada neural intermediária (escondida), dado que as amostras apresentaram um padrão de comportamento linearmente separáveis e em uma região bem compacta [6].

A taxa de aprendizado $\eta=0,022$ foi obtida após algumas iterações e observações de resultados durante a etapa de treinamento, com os dados simulados. Já a taxa de momento $\alpha = 0,9$ demonstrou-se adequada à arquitetura adotada, com o algoritmo apresentando um tempo de convergência relativamente baixo, com um EQM também baixo.

5.0 CONCLUSÃO

A partir das amostras de entrada, obtidas após as análises laboratoriais do óleo isolante (cromatografia), e com o padrão de treinamento obtido para a rede neural MLP, foi possível obter-se a causa-raiz das falhas do TR. Desta forma, ações preditivas podem ser tomadas ao longo do tempo de operação do equipamento.

A utilização do parâmetro “Rnovo = C2H2/C2H6” em conjunto com os outros parâmetros definidos por R1, R2 e R5, respectivamente, trouxe um desempenho satisfatório para este tipo de aplicação, com uma taxa de acerto, durante a etapa de operação, de 100%.

Verifica-se, portanto, um ganho significativo para as equipes de manutenção da empresa, assim como uma possível redução de impacto financeiro, permitindo, por exemplo, a realização de intervenções programadas em detrimento aos desligamentos automáticos para investigação de causa e efeito – quando aplicável, podendo-se ter, por exemplo, uma minimização do valor da Parcela Variável por Indisponibilidade (PVI) quando de uma possível avaria do equipamento sem a análise preditiva.

Por fim, com os resultados obtidos, a RNA MLP mostrou-se adequada, sendo possível, então, de ser utilizada na rotina de trabalho das equipes de manutenção e operação das empresas, com o intuito de se avaliar a emissão de gases dissolvidos e as possíveis falhas nos equipamentos ao longo do tempo de operação.

6.0 REFERÊNCIAS BIBLIOGRÁFICAS

- [1] IEC Publication 599, "Interpretation of the Analysis of Gases in Transformers, and other Oil-Filled Electrical Equipment in Service" First Edition 1978.
- [2] IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers, IEEE Standard C57.104-2008, Feb. 2009.
- [3] H. Ding, R. Heywood, J. Lapworth, R. Josebury, A. Roxborough and E. McCulloch, "Practical experience of dissolved gas in transformer oil for the detection of incipient faults," 2017 IEEE 19th International Conference on Dielectric Liquids (ICDL), Manchester, 2017, pp. 1-5.
- [4] A.R.Soto, S.L.Lima, O.R.Saavedra, "Incipient Fault Diagnosis in Power Transformer by DGA using a Machine Learnin ANN – Mean Shift Approach.
- [5] S. S. M. Ghoneim, I. B. M. Taha and N. I. Elkalashy, "Integrated ANNbased proactive fault diagnostic scheme for power transformers using dissolved gas analysis," in IEEE Transactions on Dielectrics and Electrical Insulation, vol. 23, no. 3, pp. 1838-1845, June 2016.
- [6] I.N.da Silva, D.H. Spatti, R.A. Flauzino, "Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas", Fundamentos Teóricos e Práticos, 2 Edição.

DADOS BIOGRÁFICOS



Rafael de Oliveira Fernandes, graduado em Engenharia Elétrica pela Universidade Federal de Itajubá (UNIFEI) no ano de 2001, com mestrado na área de Estabilidade Transitória com PMU pela Unicamp no ano de 2019. Atualmente é doutorando na Unicamp na área de Transitórios Eletromagnéticos. É Engenheiro de Proteção e Controle na Argo Energia. Membro Individual do Cigré-B5 e Membro Correspondente do WGB5.62, WGC2.18 e WGC4.62 do Cigré. É Coordenador no Brasil do Cobei junto à IEC – CE03.TC95-MT04 (Funções de Proteção e Guias de Aplicação).

(2) Beatriz de Lima Tavares, graduada em Engenharia Elétrica pela PUC Minas, possui Especialização em Engenharia de Segurança do Trabalho pela PUC Minas, Mestre em Sistemas de Potência pela UNICAMP e Doutoranda na mesma área pela USP São Carlos. Atua há 13 anos no setor de energia, com experiência em planejamento da expansão, regulação, operação e manutenção. Ocupa atualmente o cargo de Gerente de Expansão na Argo Energia.

(3) Victor Hugo Parreira Rosa, graduado em Engenharia Elétrica – ênfase em Eletrotécnica, pela Universidade de Uberaba. Atualmente é Coordenador de O&M na Argo Energia.

(4) Eriosvaldo Almeida de Santana, graduado em Engenharia Elétrica pela Universidade de Mogi das Cruzes - UMC, com ênfase em Eletrotécnica. Possui Pós-graduação em Engenharia de Produção pela Universidade Federal do Paraná - UFPR. Possui experiência nas áreas de alta e extra alta tensão de subestações de energia elétrica. Atualmente é gerente de O&M na empresa Argo Energia.