

DETECTAREA DEFECTELOR TRANSFORMATOARELOR DE PUTERE FOLOSIND DGA BAZATĂ PE PENTAGONUL DUVAL COMBINAT ȘI CLASIFICATORI ANN

Ancuța-Mihaela ACIU¹, Maria-Cristina NIȚU¹, Marcel NICOLA^{1,2}
Claudiu-Ionel NICOLA^{1,2}

¹ Divizia cercetare-dezvoltare echipamente electrotehnice și eficiență energetică, Institutul Național de Cercetare-Dezvoltare și Încercări pentru Electrotehnică – ICMET Craiova, Craiova, România

² Departamentul de Automatică și Electronică, Universitatea din Craiova, Craiova, România
ancutu13@yahoo.com¹, cristinamarianitu@yahoo.com¹, marcel_nicola@icmet.ro¹,
marcel.nicola@edu.ucv.ro², nicolaclaudiu@icmet.ro¹, claudiu.nicola@edu.ucv.ro²

Rezumat. Pornind de la necesitatea reducerii timpului de analiză și detectare a stărilor de defect a transformatoarelor de putere, în acest articol se prezintă realizarea unei aplicații software caracteristică acestui subiect, bazată pe clasificatori de tip Artificial Neural Networks (ANN), în care metoda teoretică de analiză este de tip Duval Combined Pentagons (DCP). Aplicația software se bazează pe algoritmi implementați în Classification Learner from the Matlab Statistics și Machine Learning toolbox. Optimizarea acurateții clasificatorilor este realizată cu ajutorul Bayesian search, Grid search, and Random search. Validarea aplicației software dezvoltată a fost realizată prin mai multe studii de caz, dintre care s-au prezentat două cazuri comparativ cu lucrările de mentenanță realizate.

1. INTRODUCERE

Procesul de mentenanță pentru transformatoarele de mare putere implică utilizarea de instrumente precise pentru detectarea posibilelor defecțiuni. Analiza gazelor dizolvate (DGA) este utilizată pe scară largă pentru evaluarea stării de sănătate a transformatoarelor de putere imersate în ulei. DGA permite identificarea stărilor de defect încă din stare incipientă, intervenirea la momentul oportun pentru îndepărtarea cauzelor ce le generează, prelungește durata de viață a transformatoarelor și menținerea acestora în condiții optime de funcționare [1-3].

DGA are la bază gaze precum: hidrogenul (H_2), metanul (CH_4), etanul (C_2H_6), etilena (C_2H_4), acetilena (C_2H_2), monoxidul de carbon (CO) și dioxidul de carbon (CO_2). Aceste gaze cheie pot indica descărcări parțiale de energie redusă, defecțiuni termice, descompunerii termice la temperatură joasă spre medie a uleiului, descompunerea izolației solide, îmbătrânirea normală a hârtiei sau arcuri electrice de mare energie [4, 5].

Metode bazate pe DGA au fost dezvoltate de-a lungul anilor, printre acestea amintim: metoda gazelor cheie, metode bazate pe rapoarte (Doernenburg, Roger și IEC), triunghiurile Duval și pentagoanele Duval [6-9]. În cazul suprapunerii de defecte, altfel spus valorile gazelor analizate indică defecte la limitele delimitate de metodele de analiza, rezultatul diagnozei poate fi eronat. Pentru a se evita o diagnosticare eronată, Duval împreună cu alți doi cercetători au dezvoltat pentagonul Duval Combinat, care permire o analiză amplă în cazul unor defecte incerte simplificând procesul de diagnoză [10]. Metodele clasice utilizate în diagnosticarea stărilor de defect ale transformatoarelor au fost îmbunătățite utilizând o serie

de algoritmi dintre care se pot aminti: fuzzy logic [11], neuro-fuzzy [12], and neural networks [13].

În literatura de specialitate sunt prezentate o gamă largă de lucrări în care sunt dezvoltate aplicații de clasificare a defectelor ce apar în funcționarea transformatoarelor de mare putere bazate pe algoritmi de tip Machine Learning (ML) [14-16]. În această lucrare se prezintă implementarea unor algoritmi de clasificare de tipul ML, și anume ANN. Acești algoritmi sunt implementați, antrenați și testați, pe baza metodei DCP, iar rezultatele obținute au o acuratețe de peste 94%. Performanțele clasificării sunt îmbunătățite prin optimizarea corespunzătoare în ceea ce privește acuratețea.

Restul lucrării este organizat după cum urmează: Secțiunea 2 prezintă materialele și metodele utilizate pentru identificarea defectelor transformatoarelor pe baza DGA prin metoda DCP, iar descrierea implementării MatLab pentru algoritmi de clasificare ANN este prezentată în Secțiunea 3. Testarea aplicației software cu algoritmi de clasificare ANN este prezentată în Secțiunea 4, iar secțiunea finală a lucrării prezintă câteva concluzii și orientări pentru lucrările viitoare.

2. MATERIALE ȘI METODE

Aplicația software dezvoltată în cadrul acestei lucrări pentru diagnosticarea stării de defect a transformatoarelor de mare putere are structura prezentată în Fig. 1. Metoda utilizată este DCP, iar pentru clasificarea/identificarea defectelor s-au implementat o serie de algoritmi de clasificare de tip ANN împreună cu optimizarea celui mai performant algoritm (ANN mediu).




Fig. 1 – Arhitectura aplicației software bazată pe clasificatori de tip ANN utilizând metoda DCP.

Pentagonul Duval Combinat (DCP) este un instrument puternic utilizat în DGA pentru diagnosticarea defecțiunilor transformatoarelor imersate în ulei, în cazuri în care există o suprapunere de defecte. Acesta are la bază suprapunerea pentagoanelor Duval 1 și 2, utilizează procente relative a celor cinci gaze combustibile cheie, gaze ce sunt dizolvate în uleiul de transformator (H_2 , CH_4 , C_2H_4 , C_2H_6 și C_2H_2).

Cele cinci gaze se reprezintă grafic sub forma unui pentagon regulat, fiecare gaz corespunzând unui vârf. Procentul relativ al fiecărui gaz (concentrația sa împărțită la totalul celor cinci gaze) este marcat de-a lungul axei sale respective, de la centru (0%) la vârf.

Cele 10 zone de defect (Fig. 2) pe care DCP-ul le identifică sunt:

- PD - descărcări parțiale de tip corona,
- D1 - descărcări electrice cu energie redusă,
- D2 - descărcări electrice de mare energie,
- S - gazarea rădăcină a uleiului mineral,
- T1-O - defecte termice cu temperatura $<300^{\circ}\text{C}$, dar fără carbonizarea izolației solide,
- T1-C - defecte termice cu temperatura $<300^{\circ}\text{C}$, cu implicarea probabilă a izolației solide, posibilă carbonizare,
- T2-O - defecte termice cu temperatura cuprinsă între 300°C și 700°C , dar cu șanse puține de implicare a izolației solide sau de carbonizare a hârtiei,
- T2-C - defecte termice cu temperatura cuprinsă între 300°C și 700°C , cu probabilitate ridicată de implicare a izolației solide (aproximativ 80%),
- T3-H - defecte termice numai în ulei, interval de temperatură $>700^{\circ}\text{C}$,
- T3-C - defecte termice la temperaturi ridicate (peste 700°C) cu implicarea în defect a izolației solide (carbonizarea hârtiei).




Fig. 2 – Reprezentarea grafică a DCP.

Prin utilizarea DCP-ul se simplifică procesul de diagnosticare permițând o amplă analiză, identificând condiții de defecțiune nuanțate (suprapunere de defecte), cum ar fi carbonizarea izolației și supraîncălzirea, în aceste condiții realizând evaluarea severității problemelor termice.

3. ALGORITMI DE CLASIFICARE ANN - IMPLEMENTARE MATLAB

Pentru această aplicație, se utilizează clasificatori de tip ANN, care se bazează pe ANN de tip feed-forward, prin intermediul aplicației Classification Learner din toolboxul Statistics și Machine Learning al MatLab. O ANN de tip feed-forward se caracterizează prin faptul că are arhitectura bazată pe un strat de intrare, straturi intermediare complet conectate și un strat de ieșire. Pentru fiecare strat intermediar, se înmulțește mărimea de intrare cu o matrice de ponderi, la care se adaugă un vector bias. Funcția de activare furnizează mărimea de ieșire a rețelei numite scoruri de clasificare. Ecuațiile de caracterizare a funcționării unei astfel de ANN sunt date în ecuațiile următoare:

$$y = f\left(\sum_{i=1}^m w_i x_i + b\right) \quad (1)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

În ecuațiile (1) și (2) prin: x_i se notează cele m intrări ale ANN, ponderile sunt notate cu w , iar mărimea de ieșire cu y . Funcția de activare σ este uzual o funcție de tip sigmoid, dar se pot utiliza și funcții al cărui grafic are aliura funcției $\tanh$. Intrarea și ieșirea acestui tip de ANN nu sunt interconectate, iar ponderile sunt ajustate în mod corespunzător dând caracterul de feed-forward, deosebindu-se astfel de ANN cu back-propagation. Prin optimizarea modelului în funcție de datele de intrare se obțin valorile nodurilor din straturile de ieșire ale ANN.

În faza de antrenament, valorile (intrările) și defectele (ieșirile) corespunzătoare gazului sunt selectate pe baza intervalului de valori prezentat în Tabelul 3 conform DCP. Astfel, performanțele de antrenament pentru următorii algoritmi bazați pe clasificatori ANN (Medium, Wide, Trilayered, Narrow, Bilayered) sunt prezentate în Tabelul 1.

Se observă că cele mai bune performanțe dintre clasificatori prezentați se obțin utilizând algoritmul clasificatorului ANN mediu.

Tabelul 1.

Performanța algoritmului clasificatorilor ANN			
Tipul clasificatorului ANN	Precizie [%]	Viteză de predicție [obs/sec]	Timp de antrenament [sec]
Medium ANN	94.8	~17000	7.83
Wide ANN	94.5	~20000	8.94
Trilayered ANN	94.0	~18000	9.84
Narrow ANN	93.9	~16000	7.97
Bilayered ANN	93.8	~17000	8.85

În continuare se prezintă doi dintre indicatorii care oferă informații despre performanțele de antrenare ale unui algoritm de clasificare. Astfel, pentru fiecare dintre algoritmi de clasificare bazați pe ANN antrenați se prezintă matricea de confuzie și curbele Receiver Operating Characteristic (ROC) corespunzătoare.

Figurile 3 și 4 prezintă matricea de confuzie și respectiv curba ROC pentru algoritmul de clasificare ANN mediu bazat pe detectarea defectelor transformatorului utilizând DCP. Acest algoritm are o acuratețe de 94.8% (a se vedea Tabelul 1), iar din Fig. 3 se poate observa că pentru clasele de defecte adevărate și cele prezise în cazul defectului de tip T1-O avem un procent de predicție de 100% și din Fig. 4 aria sub curbă pentru același tip de defect este 1 ceea ce reprezintă o performanță foarte bună de clasificare.

D1	148	5	3	8						
D2	4	152		6						2
PD	2		162							
S	6	7		148					1	2
T1_C					161		1	1	1	
T1_O						164				
T2_C					1		160	3		
T2_O					1		2	159	2	
T3_C	1				1		2	1	152	7
T3_H		6		1					9	148
	D1	D2	PD	S	T1_C	T1_O	T2_C	T2_O	T3_C	T3_H

Predicted Class

Fig. 3 – Matricea de confuzie din etapa de antrenament a algoritmului de clasificare ANN mediu bazat pe detectarea defectelor transformatorului folosind DCP.




Fig. 4 – Curba ROC din etapa de antrenament a clasificatorului ANN mediu bazată pe detectarea defectelor transformatorului folosind DCP.

Aplicația Classification Learner din Matlab are opțiunea de a optimiza algoritmi de clasificare, iar cele trei tipuri de optimizare utilizate sunt: căutare Bayesiană, căutare în Grilă și căutare Aleatorie. Astfel, în continuare se prezintă performanțele stagiului de antrenament în ceea ce privește optimizarea clasificatorului ANN mediu care a oferit cele mai bune rezultate din punct de vedere al acurateții.

Tabelul 2 prezintă aceste performanțe pentru cele trei tipuri de optimizare, iar din punct de vedere al acurateții cea mai bună acuratețe este obținută utilizând optimizarea de tip Bayesian search (căutare Bayesiană).

Tabelul 2.

Performanța algoritmului de clasificare ANN optimizabil			
Optimizarea clasificatorului ANN mediu	Precizie [%]	Viteză de predicție [obs/sec]	Timp de antrenament [sec]
căutare Bayesiană	95.9	~150000	177.66
căutare în Grilă	95.7	~200000	451.23
căutare Aleatorie	94.9	~210000	81.79

Etapă de antrenament a performanței folosind optimizarea de căutare Bayesiană pentru algoritmul clasificatorului ANN mediu este prezentată în Figura 5.

Hiperparametrii obținuți în etapa de antrenament pentru această optimizare sunt următorii:

- numărul de straturi complet conectate (două straturi unde dimensiunea primului strat este 299, iar dimensiunea celui de-al doilea strat este 61);
- funcția de activare (Tanh)
- puterea de regularizare ($\lambda = 1.265 \cdot 10^{-5}$).

Figurile 6 și 7 prezintă matricea de confuzie și curba ROC pentru algoritmul clasificatorului ANN mediu cu optimizare de căutare Bayesiană.




Fig. 5 – Etapa de antrenament al performanței folosind optimizarea căutării Bayesiene pentru algoritmul de clasificare ANN mediu.

D1	148	6	3	6					1	
D2	3	154		4						3
PD	2		162							
S	6			156						2
T1_C					163		1			
T1_O		1				163				
T2_C					1		156	3	4	
T2_O							1	162	1	
T3_C				1	1		1	1	154	6
T3_H		1		1					8	154
	D1	D2	PD	S	T1_C	T1_O	T2_C	T2_O	T3_C	T3_H

Fig. 6 – Matricea de confuzie din etapa de antrenament a algoritmului de clasificare ANN mediu cu optimizare de căutare Bayesiană bazată pe detectarea defectelor transformatorului folosind DCP.




Fig. 7 – Curba ROC din etapa de antrenament a algoritmului de clasificare ANN mediu cu optimizare de căutare Bayesiană bazată pe detectarea defectelor transformatorului folosind DCP.

4. REZULTATE ȘI DISCUȚII

Validarea aplicației software a fost realizată compararea rezultatelor obținute cu situații reale identificate în cazul reabilitării sau reparării transformatoarelor de putere. În această lucrare vom prezenta două studii de caz realizate pe transformatoare de 25 MVA, 35/6.3 kV, imersate în ulei mineral.

În Tabelul 3 este prezentat conținutul de gaze dizolvate identificat pentru cele două studii de caz, precum și valorile acceptate conform standardelor în vigoare.

Tabelul 3
Concentrația de gaze dizolvate

Gaze cheie [ppm]	Limite conform standardelor [ppm]	Cazul 1 (T1)	Cazul 2 (T2)
H ₂	50-150	21	47
CH ₄	30-130	323	179
C ₂ H ₂	2-20	53	0
C ₂ H ₄	60-280	593	20
C ₂ H ₆	20-90	28	157

Secvența din Matlab:

`“result_MANNOB=trainedMediumANNClassifierBayesianDCP.predictFcn(Test)”`

se utilizează în algoritmul bazat pe clasificator de tip ANN mediu cu optimizare bayesiană pentru faza de testare.

Figurile 8 și 9 prezintă rezultatele celor două studii de caz utilizate pentru testarea algoritmului propus.




Fig. 8 – Rezultat test 1 pentru algoritmul de clasificare ANN mediu cu optimizare bayesiană bazată pe detectarea defectelor transformatorului folosind DCP.

Pe baza datelor prezentate în Tabelul 3 pentru transformatorul T1, aplicând DCP și algoritmi de clasificare ANN a fost identificat un defect termic (T3-H), cu temperatura $>700^{\circ}\text{C}$, care afectează doar izolației lichida (uleiul).

S-a constatat că starea de funcționare a transformatorului este una acceptabilă, deși concentrația de acetilenă este ridicată, depășind valorile prevăzute de standard. Acest lucru datorându-se contaminării uleiului din cuva principală a transformatorului cu ulei ce provine din comutatorul de reglaj și o degradare moderată a izolației datorită șocurilor termice (supraîncălzirii) înregistrate. Capacitatea de răcire a uleiului a fost compromisă fapt ce a dus la formarea de nămol.

Au fost realizate lucrări de mentenanță, care au implicat deconectarea și decuvarea transformatorului. Cuvă comutatorului prezenta neetanșeități, uleiul necesită tratamente de revitalizare, izolația solidă prezenta urme de îmbătrânire. Problemele identificate au fost remediate, implicând și o verificare a conexiunilor pe ploturile selectorului.




Fig. 9 – Rezultat test 2 pentru algoritmul de clasificare ANN mediu cu optimizare bayesiană bazată pe detectarea defectelor transformatorului folosind DCP.

În urma folosirii aplicației prezentate, în cazul studiului al doilea a fost identificat un defect termic (T1-O), cu temperatura $<300^{\circ}\text{C}$, care nu implică carbonizarea izolației solide.

Starea de funcționare a transformatorului este una acceptabilă, deși starea de degradare a izolației solide este avansată. Degradarea izolației solide poate fi generată de un defect la

nivelul înfășurărilor sau de funcționarea necorespunzătoare a sistemului de răcire. Capacitatea de răcire a uleiului este scăzută, generând formarea de nămol. Conținutul de CO₂, susține starea de defect identificată.

S-au realizat lucrări de reparație la nivelul sistemului de răcire, care era defect, iar pentru monitorizarea temperaturii, la intrarea și ieșirea sistemului de răcire au fost introduși senzori de măsurare a umidității și temperaturii.

5. CONCLUZII

În această lucrare este prezentată o metodă de diagnosticare a stării de sănătate a transformatoarelor de putere ce are la bază analiza DGA cu ajutorul DCP-ului, acesta fiind un instrument valoros utilizat în diagnosticarea stărilor incerte de defect. Folosirea algoritmilor de clasificare facilitează scurtarea timpilor de analiză a stărilor de defect, cu o acuratețe ridicată.

Clasificarea stărilor de defect a transformatoarelor realizată cu ajutorul clasificatorilor ANN, furnizează o acuratețe foarte bună care poate fi îmbunătățită prin algoritmi de optimizarea de tip căutare Bayesiană.

Validarea aplicației software dezvoltată a fost realizată prin mai multe studii de caz, dintre care s-au prezentat două cazuri împreună cu lucrările de mentenanță realizate.

În lucrările viitoare se propune utilizarea combinată a mai multor metode de analiză a stărilor de defect a transformatoarelor în vederea obținerii unor rezultate de clasificare cu ajutorul altor tipuri de algoritmi de clasificare.

CONFIRMARE

Această lucrare a fost realizată prin intermediul Programului NUCLEU din cadrul Planului Național de Cercetare Dezvoltare și Inovare 2022-2027, realizat cu sprijinul MCID, proiect nr. PN 23 33 02 03.

Lucrarea a fost prezentată la Simpozionul de Mașini Electrice SME'XXI, ediția 2025.

BIBLIOGRAFIE

1. H.M. Avis, A.E. Lombard, V. Sibeko, *Predictive modelling based on transformer oil data for power system planning and operation*, 33rd Southern African Universities Power Engineering Conference (SAUPEC), Pretoria, South Africa, pp. 1-6, 2025.
2. S. Nxumalo, L. Maluleka, S. Minhas, *The Effect of Dissolved Gases on the Breakdown Strength of Ester Transformer Oil*, 33rd Southern African Universities Power Engineering Conference (SAUPEC), Pretoria, South Africa, pp. 1-6, 2025.
3. CIGRÉ Brochure 771 - *Advances in DGA Interpretation*, JWG D1/A2.47, CIGRE: Paris, France, July 2019.
4. A. Nanfak, E. Samuel, I. Fofana, F. Meghnefi, M.G. Ngaleu, C.H. Kom, *Traditional fault diagnosis methods for mineral oil-immersed power transformer based on dissolved gas analysis: Past, present and future*, IET Nanodielectr., pp.1-34, 2024.
5. H. Kalathiripi, V. Undety, P.S. Puan, *Transformer Oil Analysis using DGA and UV-Visible Spectroscopy for Condition Monitoring*, International Conference on Sustainable Energy Technologies and Computational Intelligence (SETCOM), PP. 1 - 5, Gandhinagar, India, 2025.
6. IEEE Std C57.104™-2019 - *Guide for the Interpretation of Gases Generated in Mineral Oil-Immersed Transformers*, 2019.
7. CEI/IEC 60599:2022 - *Mineral oil-impregnated electrical equipment in service – Guide to the interpretation of dissolved and free gas analysis*, Edition .4, pages 80, 2022.
8. K. Helal, A. Maher, D. -E. A. Mansour, R.A. Abd El-aal, *Adaptation of the Duval Triangle for Enhanced Dissolved Gas Analysis and Diagnosis of Dielectric Nanofluids*, 25th International Middle East Power System Conference (MEPCON), pp. 1 – 5, Cairo, Egypt, 2024.
9. N. Hirkaney, S. Lall, *Comparison of fault identification methods for analyzing transformer dissolved gas*, 3rd International Conference on Energy, Power and Electrical Engineering (EPEE), pp.902-907, Wuhan, China, 2023.
10. L. Cheim, M. Duval, S. Haider, *Combined Duval Pentagons: A Simplified Approach*, Energies, **13**, 11, pp. 1-12, June 2020.

11. F.F. Selim, A.M. Azmy, M.A. Hassan, E.G. Atiya, *A Fuzzy logic-based methodology for dissolved gas analysis to enhance the accuracy of power transformer incipient faults detection*, 25th International Middle East Power System Conference (MEPCON), pp. 1 – 7, Cairo, Egypt, 2024.
12. R.A. Prasajo, K. Diwyacitta, Suwarno, H. Gumilang, *Transformer paper condition assessment using Adaptive Neuro-Fuzzy Inference System model*, International Conference on Electrical Engineering and Computer Science (ICECOS), pp. 237 - 242, Palembang, Indonesia, 2017.
13. F. Guerbas *et al.*, *Neural networks and particle swarm for transformer oil diagnosis by dissolved gas analysis*, Scientific Reports, **14**, pp. 1-14, April 2024.
14. M.A. Aljanobi, H.F. AlBinali, *State of The Art Machine Learning based DGA Analytical Solution*, IEEE PES 14th Asia-Pacific Power and Energy Engineering Conference (APPEEC), pp.1-4,Melbourne, Australia, 2022.
15. D. Saravanan, A. Hasan, A. Singh, H. Mansoor, R.N. Shaw, *Fault prediction of transformer using machine learning and DGA*, IEEE International Conference on Computing, Power and Communication Technologies (GUCON), pp. 1-5, Greater Noida, India, 2020.
16. A.-M. Aciu, M.-C. Nițu, C.-I. Nicola, M. Nicola, *Determining the remaining functional life of power transformers using multiple methods of diagnosing the operating condition based on SVM classification algorithms*, Machines, **12**, 1, pp. 1-34, January 2024.