

DIAGNOSIS GANGGUAN PERMULAAN TRANSFORMATOR DAYA DENGAN JARINGAN SYARAF TIRUAN

Noor Akhmad Setiawan
Program Diploma Teknik Elektro
Fakultas Teknik Universitas Gadjah Mada
Email: noorwewe@ugm.ac.id

Abstrak

Penelitian ini adalah studi tentang aplikasi jaringan syaraf tiruan untuk diagnosis gangguan permulaan pada transformator daya. Jaringan syaraf yang digunakan adalah jaringan syaraf multi-layer perceptron melalui variasi metode pembelajaran resilient backpropagation, scaled conjugate gradient, dan Levenberg-Marquardt serta pengolah awal data masukan penskalaan, pembagian dengan rerata, normalisasi rerata dan deviasi standard. Diagnosis gangguan permulaan berbasis dissolved gas in oil analysis.

Jaringan syaraf tiruan yang digunakan mempunyai enam masukan dengan tiga keluaran. Pembelajaran dilakukan dengan data gangguan permulaan transformator dari suatu penelitian. Penelitian dilakukan dengan membandingkan jaringan syaraf tiruan dalam topologi, metode pembelajaran, pengolah awal data masukan divariasasi untuk mendapat yang terbaik dari sisi kebenaran diagnosis, rerata kebenaran, waktu yang dibutuhkan, kemampuan mencapai target untuk beberapa pembelajaran dengan inisialisasi Nguyen-Widrow yang bersifat acak.

Hasil penelitian menunjukkan bahwa jaringan syaraf tiruan topologi gabungan multi layer perceptron dengan pengolah awal data masukan dibagi rerata serta metode pembelajaran resilient backpropagation adalah pilihan terbaik. Hasil penelitian didapatkan dengan membandingkan dengan topologi lain yang diteliti dalam penelitian ini. Jaringan syaraf tiruan juga lebih baik dari metode konvensional gas kunci dan perbandingan gas untuk kasus transformator yang diteliti dalam penelitian ini sehingga metode jaringan syaraf tiruan ini diharapkan dapat menggantikan pakar diagnosis gangguan mula transformator.

Kata kunci : jaringan syaraf, diagnosis, transformator, gangguan

1. PENDAHULUAN

Transformator daya adalah peralatan pokok pada sistem tenaga listrik. Realibilitasnya tidak hanya mempengaruhi kelangsungan suplai energi listrik, akan tetapi juga mempengaruhi operasi ekonomis sistem tenaga listrik. Jumlah transformator yang banyak dengan perbedaan jenis dan kapasitas mempersulit perawatan dan pemeriksaan rutin karena perbedaan transformator berakibat perbedaan karakteristik dan masalah yang timbul [1]. Sedangkan untuk mendatangkan seorang ahli dalam perawatan dan pemeriksaan transformator secara rutin diperlukan biaya yang cukup besar, di samping kerusakan transformator yang juga akan mengakibatkan kerugian yang besar, di mana pada saat ini masalah penghematan energi di antaranya dengan penghematan biaya operasi dan perawatan sedang menjadi perhatian para peneliti. Apabila dapat dibuat perangkat lunak dengan kemampuan sama atau mendekati dengan seorang pakar diagnosis transformator khususnya gangguan permulaan sebagai anstisipasi gangguan selanjutnya maka penghematan biaya dapat dilakukan.

Beberapa penelitian sebelumnya yang membahas tentang diagnosis gangguan permulaan transformator menggunakan kecerdasan buatan di antaranya Wang [2] mengumpulkan keahlian pakar dan merepresentasikannya dalam bahasa mesin kemudian menggunakan kecerdasan buatan untuk mengekstraksi keahlian tersebut langsung dari data kasar. Penelitian ini menyatakan bahwa jaringan syaraf tiruan (JST) *multi layer perceptron modular* adalah pilihan terbaik untuk diagnosis gangguan permulaan transformator daya berbasis JST. Tomsovic dan Amar [3] menawarkan beberapa metode dalam ekstraksi dari data tes yaitu menggunakan pendekatan himpunan *fuzzy* dan JST serta hibridisasi logika *fuzzy* dan

JST. Penelitian ini belum mendapatkan hasil maksimal untuk sistem berbasis JST karena data yang kurang memadai. How dkk [1] membuat perangkat lunak ADAPT untuk interpretasi DGA dari transformator daya dengan logika *fuzzy*. Tomsovic dan Baer [3] menekankan pada aplikasi logika *fuzzy* untuk diagnosis dan monitoring peralatan listrik di antaranya transformator berbasis DGA. Dalam penelitian ini juga ditawarkan metode lain seperti JST. Zhou dkk [4] membangun perangkat lunak NEUCOMS untuk monitoring kondisi transformator daya berbasis DGA menggunakan JST dikombinasi dengan logika *fuzzy* untuk proses awal masukan. Lai [5] menggunakan JST *backpropagation* murni untuk diagnosis gangguan permulaan transformator. Lai juga mengajukan logika *fuzzy* berbasis DGA dengan metode *key gases* dan metode perbandingan gas. Metode JST mempunyai banyak variasi topologi, metode pembelajaran dan pemroses awal data masukan. Penelitian ini akan membandingkan beberapa model JST *multilayer perceptron* (MLP) untuk mendapatkan hasil optimum.

2. LANDASAN TEORI

Dissolved Gas in Oil Analysis

Tekanan elektrik dan panas pada bahan insulasi dalam transformator akan membebaskan gas-gas di dalamnya. Distribusi dari gas-gas ini berhubungan dengan gangguan elektrik, sedangkan laju pembentukan gas berhubungan dengan tingkat bahaya dari gangguan tersebut. Jenis gas-gas yang dihasilkan dapat memberikan informasi untuk program perawatan preventif. Pada umumnya gas yang terbentuk adalah hidrogen (H_2), karbon monoksida (CO), karbon dioksida (CO_2), metana (CH_4), asetilen (C_2H_2), etana (C_2H_6) dan etilen (C_2H_4) (Lai, 1998), sedangkan gas yang timbul tetapi tidak menunjukkan gangguan adalah oksigen (O_2) dan nitrogen (N_2) [6].

Intensitas energi yang didisipasikan akibat gangguan yang bervariasi akan menghasilkan pola-pola yang berbeda dari gas-gas yang dihasilkan. Keseluruhan atau sebagian gas-gas tersebut terlarut dalam minyak. Sifat gangguan dapat diketahui dari tipe gas dan jumlahnya dari gas-gas yang ada dalam contoh minyak *Dissolved gas analysis* (DGA) atau analisis gas terlarut merupakan metode yang paling banyak digunakan dalam diagnosis gangguan transformator. Metode DGA dibuat berdasar penemuan Halstead tentang termodinamika [5].

Ada dua macam metode DGA konvensional yaitu metode gas kunci (*key gas method*) dan metode perbandingan gas (*gas ratio method*), sedangkan metode yang terbaru adalah metode kecerdasan buatan.

Multi layer perceptron neural network (MLP)

MLP mungkin adalah JST yang paling populer dalam aplikasi pengenalan pola [7]. Memori adalah bobot antara lapisan-lapisan direpresentasikan dengan w_{ij} sehingga hubungan masukan-keluaran adalah :

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

di mana l adalah nomor lapisan ($l > 0$, lapisan masukan adalah lapisan ketiga), $y_j^{(l)}$ menunjukkan keluaran dari neuron ke- j pada lapisan ke- l , $v_j^{(l)}$ menunjukkan jumlah neuron-neuron masukan yang telah dikalikan bobotnya, $x_{ij}^{(l)}$ menunjukkan masukan ke- i dari neuron (p masukan dari lapisan sebelumnya dan satu masukan bias tetap), $w_{ij}^{(l)}$ menunjukkan kontribusi bobot dari input ke- i ke neuron, dan $\Phi(\cdot)$ adalah fungsi aktivasi neuron.

Fungsi aktivasi $\Phi(\cdot)$ adalah fungsi tak linier *smooth* (dapat dideferensialkan di manapun) dan dapat mempunyai berbagai bentuk, seperti fungsi logistik, tangen hiperbola :

$$\Phi(v) = \frac{1}{1 + \exp(-av)} \quad a > 0 \text{ dan } -\infty < v < \infty \quad \dots\dots\dots(2)$$

$$\Phi(v) = a \tanh(bv) \quad (a, b) > 0 \quad \dots\dots\dots(3)$$

Pembelajaran MLP biasanya menggunakan algoritma *back-propagation*, terdiri dua jalan, jalan maju (*forward*) dan balik (*backward*). Pada berjalan maju bobot dari jaringan tetap dan persamaan (1) digunakan untuk mendapatkan keluaran dari masukan melalui seluruh lapisan. Selama berjalan balik, semua bobot disesuaikan dengan persamaan koreksi error :

$$e_j(n) = d_j(n) - y_j(n) \quad \dots\dots\dots(4)$$

$$\delta_j^{(l)} = \begin{cases} e_j^{(L)} \Phi'(v_j^{(L)}(n)) & \text{untuk neuron } j \text{ dalam lapisan keluaran } L \\ \Phi'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) & \text{untuk neuron } j \text{ dalam lapisan hidden } l \end{cases} \quad \dots\dots(5)$$

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha w_{ji}^{(l)}(n-1) + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad \dots\dots\dots(6)$$

di mana n adalah nomor iterasi, e adalah isyarat error, d adalah isyarat target, $\Phi'(\cdot)$ adalah diferensial dari fungsi aktivasi, η adalah laju pembelajaran dan α adalah konstanta momentum.

Selama proses pembelajaran, sampel data diberikan pada jaringan secara acak. Sekali pemberian semua sampel data pada jaringan dinamakan satu *epoch*. Dalam pembelajaran biasanya dilakukan banyak *epoch*. Pembelajaran akan berakhir ketika error individu kuadrat dan/atau error sistem rerata lebih kecil dari nilai yang diberikan. Error didefinisikan :

$$e_{kuadrat} = \frac{1}{2} [e_j(n)]^2 \quad \dots\dots\dots(7)$$

$$e_{rerata} = \frac{1}{2N} \sum_{j=1}^N [e_j(n)]^2 \quad \dots\dots\dots(8)$$

Algoritma pembelajaran propagasi balik biasanya menggunakan metode *gradient descent* untuk meminimumkan fungsi errornya. Metode ini biasanya terlalu lambat dalam menangani masalah-masalah di lapangan [8]. Modifikasi dilakukan untuk mempercepat proses pembelajaran. Ada banyak metode pembelajaran yang digunakan dalam jaringan syaraf tiruan MLP, di antaranya adalah *resilient backpropagation* yang dikembangkan oleh Riedmiller [9] selanjutnya disebut RP. Metode lain yaitu *Scaled conjugate gradient* selanjutnya disebut SCG adalah variasi dari metode optimasi yang banyak dipakai untuk mengatasi optimasi skala besar secara efektif yaitu metode *conjugate gradient*. Martin F. Moller menemukan suatu algoritma yang merupakan modifikasi dari metode *conjugate gradient* [10]. Algoritma Levenberg-Marquardt selanjutnya disebut LM adalah algoritma yang berbasis matriks Hessian. Metode ini tidak menghitung matriks Hessian tetapi memperkirakannya dengan perkalian transpos matriks Jacobian dengan matriks Jacobian [11].

3. CARA PENELITIAN

Cara penelitian sesuai tahapan berikut :

1. Perancangan model JST untuk diagnosis gangguan transformator berbasis DGA
Perancangan ini menggunakan topologi MLP murni. Topologi MLP murni dirancang dengan memperhatikan optimasi JST. Percobaan yang dilakukan dalam penelitian ini memberikan topologi 1 lapisan tersembunyi dengan jumlah neuron 6 adalah topologi yang terbaik dari sisi validasi dibanding topologi lain yang dicoba dalam penelitian ini. Keluaran menggunakan bipolar (-1 dan 1). Fungsi aktivasi menggunakan fungsi asimetris yaitu tangen hiperbolik (Haykin, 1994). JST akan mengindikasikan normal apabila neuron yang menunjukkan normal bernilai 1 atau nilai positif mendekati 1, demikian pula untuk *discharges* dan *thermal*. Sebaliknya jika neuron yang bersesuaian, misalnya neuron normal, memberikan nilai -1 atau negatif mendekati -1, berarti mengindikasikan tidak normal, demikian pula untuk *discharges* dan *thermal*.
2. Representasi data pada model untuk pembelajaran
Representasi data masukan pada topologi untuk pembelajaran dilakukan dengan lima cara yaitu representasi data kasar, representasi data terproses dengan dibagi rata-ratanya, representasi data dengan penskalaan rentang -1 sampai 1, representasi data dengan normalisasi rerata dan standar deviasi. Data pembelajaran dan pengujian diambil dari publikasi Tomsovic dan Amar (1997).
3. Pembelajaran JST
Pembelajaran JST menggunakan algoritma pembelajaran cepat dengan kemampuan lebih baik dibanding yang lain yaitu *resilient backpropagation*(RP), *scaled conjugate gradient*(SCG), *levenberg-marquardt*(LM)(Demuth dan Beale, 2000). Metode pembelajaran tersebut diterapkan pada masing-masing topologi.

4. Pengujian hasil pembelajaran JST
Hasil pembelajaran diuji dengan sepuluh kali pembelajaran, dengan epoch maksimum 4000, kemudian dihitung tingkat kebenaran maksimum, rata-rata kebenaran dari sepuluh proses pembelajaran, rerata waktu yang dibutuhkan selama proses pembelajaran, dan persentase target MSE tercapai dari sepuluh kali pembelajaran.
5. Analisis hasil pembelajaran dan pengujian
Berdasarkan hasil pembelajaran dan pengujian pada langkah 4, maka tahap selanjutnya adalah tahap analisis dan pembahasan. Variabel yang diamati adalah tingkat kebenaran sistem JST MLP dengan masing-masing metode pembelajaran dan pengolahan awal data masukan, serta waktu yang dibutuhkan untuk pembelajaran, dan dibandingkan dengan metode konvensional gas kunci, perbandingan gas IEC dan Roger, flag point.

4. HASIL DAN PEMBAHASAN

Hasil penelitian untuk topologi MLP murni dapat dilihat pada Tabel 1. Dari hasil pengujian yang didapatkan, dengan memperhatikan variabel yang diujikan, kombinasi pengolah awal dibagi rerata menunjukkan performa terbaik secara umum, terutama dari sisi kebenaran dan rerata kebenaran dengan inisialisasi bobot acak (metode Nguyen-Widrow). Hasil penelitian Demuth dan Beale (2000) menyatakan metode LM cepat untuk sistem JST MLP dengan jumlah bobot yang relatif sedikit, tetapi lambat untuk jumlah bobot banyak karena kebutuhan memori yang besar, sebaliknya dengan metode RP.

Tabel 1. Kemampuan JST MLP dengan variasi metode pembelajaran dan pengolah awal

Pengo-lah data awal	Metode pembelajaran	Kebenaran maksimum (%)	Rerata kebenaran (%)	Rerata waktu (detik)	Persentase target tercapai (%)
Tanpa pengolah (kasar)	RP	80	56,5	26,19	20
	SCG	80	56	57,22	0
	LM	70	50,5	51,83	20
Dibagi rerata	RP	85	76	10,41	70
	SCG	80	75	5,15	90
	LM	85	75	1,59	70
Penskala-an	RP	75	70	21,86	50
	SCG	85	74,5	11,33	80
	LM	80	69	1,53	50
Normalisasi rerata dan sd	RP	75	71,5	10,78	70
	SCG	80	74,5	5,26	90
	LM	80	65	1,16	50

Perbandingan hasil pengujian menunjukkan bahwa topologi MLP dengan proses awal dibagi rerata memberikan hasil yang relatif lebih baik dibandingkan dengan topologi MLP murni terutama dari rata-rata kebenaran yang memberikan keuntungan pada saat pembelajaran.. Dalam penelitian ini diputuskan untuk menggunakan metode RP dengan topologi MLP dan pemroses awal dibagi rerata dibandingkan dengan metode lain yang pernah dipakai dan diteliti. Metode pembelajaran RP dipilih walaupun metode LM memberikan kecepatan yang terbaik saat pembelajaran, karena pada saat penggunaan tidak lagi melakukan pembelajaran sehingga kecepatan pembelajaran tidak begitu penting sedangkan metode LM mempunyai beban komputasi yang lebih besar dibanding RP. Metode LM lebih tepat untuk aplikasi on-line dengan bobot yang adaptif. Apabila dibandingkan dengan metode konvensional seperti *flag point*, gas kunci, IEC, dan metode Roger, metode MLP menunjukkan tingkat kebenaran yang jauh lebih baik untuk data yang dipakai dalam penelitian ini, hal ini karena metode konvensional tidak mempunyai kemampuan belajar dari data transformator yang terkena gangguan permulaan, sehingga tidak mampu mendeteksi gangguan permulaan pada transformator yang berbeda-beda karakteristiknya. Keunggulan metode JST ini sangat menonjol pada kemampuan belajarnya sehingga karakteristik yang berbeda dari transformator mampu ditangani dengan metode JST ini. Hasil diagnosis dengan metode konvensional dapat dilihat pada Tabel 2.

Tabel 2. Persentase kebenaran hasil diagnosis gangguan permulaan trafo dengan berbagai metode DGA konvensional

Metode	Flagpoint	Keygas	Roger's	IEC
Kebenaran (%)	25	45	35	50

5. KESIMPULAN

Jaringan syaraf tiruan dengan topologi MLP dikombinasi dengan pengolah awal data masukan dibagi merata dapat digunakan sebagai alternatif diagnosis gangguan permulaan transformator sebagai pengganti pakar diagnosis dengan tingkat kebenaran dan kemampuan pembelajaran yang cukup baik (85%) apabila dibandingkan metode konvensional.

DAFTAR PUSTAKA

- [1] How, W.Y., Khalid M., Zain, S.A.F.S, 1999, "**Transformer Fault Diagnosis Using Fuzzy Logic Interpretations**" CAIRO Universiti Teknologi Malaysia, Kuala Lumpur.
- [2] Wang, K.O., 2000, "**Expert System for Transformer Fault Diagnosis**" Bachelor of Engineering Honours Thesis, University of Queensland.
- [3] Tomsovic, K., Amar, A., 1997, "**On Refining Equipment Condition Monitoring using Fuzzy Sets and Artificial Neural Nets**" School of Electrical Engineering and Computer Science Washington State University, Pullman, WA.
- [4] Zhou, Z.H., Chen, Z.Q., Chen, S.F., 2001, "**Condition Monitoring of Power Transformer with Neural Networks**" Proceedings of International Conference on Info-tech & Info-net, Beijing, vol 3, pp. 468-472.
- [5] Lai, L.L., 1998, "**Intelligent System Applications in Power Engineering**" John Wiley & Sons Ltd., West Sussex, pp. 195-205.
- [6] DiGiorgio, J.B., 2000-2001, "**Dissolved Gas Analysis of Mineral Oil Insulating Fluids**" NTT-Technical Bulletin
- [7] Haykin, S., 1994, "**Neural Network A Comprehensive Foundation**" MacMillan College Publishing Company Inc., New York.
- [8] Demuth, Howard, Beale, Mark, 2000, "**Neural Network Toolbox for Use With Matlab User's Guide**" The MathWorks, Inc.
- [9] Micusik, D., Stopjakova, V., Benuskova, L., 2002, "**Application of Feed-Forward Artificial Neural Networks to the Identification of Defective Analog Integrated Circuits**" Neural Computing & Applications, Springer-Verlag London Limited, vol. 1 No.1, pp. 71-79.
- [10] Moller, Martin F., 1990, "**A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning**", Computer Science Department University of Aarhus, Denmark.