

Perancangan Algoritma ANN untuk Sistem Diagnosis Motor Induksi Tiga Fasa

Suparman Uden¹, Sofian Yahya², Adnan Rafi Al Tahtawi³

^{1,2,3}Jurusan Teknik Elektro, Politeknik Negeri Bandung, Bandung 40559

E-mail : ¹suparman.uden.toi20@polban.ac.id

E-mail : ²sofianyahya@polban.ac.id

E-mail : ³adnan.rafi@polban.ac.id

ABSTRAK

Motor induksi tiga fasa merupakan salah satu jenis motor listrik yang banyak digunakan di industri. Pada praktiknya, motor induksi tiga fasa seringkali dihadapkan pada berbagai kondisi, salah satunya adalah adanya ketidakseimbangan tegangan dan arus yang dapat menurunkan efisiensi. Dengan demikian diperlukan sebuah sistem diagnosis untuk dapat mendeteksi kondisi tersebut. Penelitian ini bertujuan merancang algoritma *Artificial Neural Network* (ANN) untuk mengidentifikasi ketidakseimbangan tegangan dan arus pada motor induksi tiga fasa. ANN bekerja dengan cara mempelajari dan mengklasifikasikan data yang terkumpul. Alur pengujian menggunakan 30% data, sedangkan alur pelatihan menggunakan 70% sisanya. Hasil klasifikasi menunjukkan bahwa 19,50% tegangan seimbang, dan 80,50% tidak seimbang. Kami mencapai persentase akurasi 100,00% untuk tegangan seimbang dan tidak seimbang, disertai dengan *Mean Squared Error* (MSE) sebesar 0,0077 dan *Root Mean Squared Error* (RMSE) sebesar 0,0876.

Kata Kunci

Diagnosa Ketidakseimbangan, Motor Induksi Tiga Fasa, Artificial Neural Network

Three-phase induction motors are a type of electric motor that is widely used in industry. In practice, three-phase induction motors are often faced with various conditions, one of which is an imbalance in voltage and current which can reduce efficiency. Thus, a diagnostic system is needed to be able to detect this condition. This research aims to design an artificial neural network (ANN) algorithm to identify voltage and current imbalances in three-phase induction motors. ANN works by learning and classifying collected data. The testing pipeline uses 30% of the data, while the training pipeline uses the remaining 70%. The classification results show that 19.50% of the voltage is balanced, and 80.50% is unbalanced. We achieved an accuracy percentage of 100.00% for both balanced and unbalanced voltages, accompanied by a Mean Squared Error (MSE) of 0.0077 and a Root Mean Squared Error (RMSE) of 0.0876.

Keywords

Diagnosis of Imbalance, Three Phase Induction Motor, Artificial Neural Network

1. PENDAHULUAN

Motor induksi tiga fase adalah peralatan listrik yang banyak digunakan dalam industri kontemporer. Keseimbangan tegangan dan arus di setiap fase secara signifikan mempengaruhi keandalan dan efektivitas motor ini. Ketidakseimbangan dapat muncul sebagai akibat dari peristiwa seperti gangguan pada sistem distribusi daya atau kerusakan pada komponen internal motor, yang dapat menyebabkan ketidakseimbangan. Identifikasi ketidakseimbangan ini secara tepat waktu sangat penting untuk mencegah kerusakan yang lebih parah dan menjamin fungsi motor yang optimal dalam jangka panjang. V. G. De

Araújo et al. menyatakan bahwa mengidentifikasi ketidakseimbangan ini dapat menurunkan biaya yang terkait dengan pemeliharaan motor dan meningkatkan efisiensi pengoperasian sistem secara keseluruhan. Penelitian mereka menunjukkan bahwa menggunakan metode jaringan syaraf tiruan (JST) untuk menemukan ketidakseimbangan pada motor induksi tiga fase dengan benar (1).

Tujuan utama dari penelitian ini adalah untuk membuat model jaringan syaraf tiruan (JST) yang dapat secara akurat mendeteksi dan mendiagnosis ketidakseimbangan tegangan dan

arus pada motor induksi tiga fase. Kami mengantisipasi model ini akan beradaptasi dengan berbagai keadaan operasional dan menghasilkan prakiraan waktu nyata yang tepat, sehingga memungkinkan tindakan perbaikan yang tepat waktu dan efisien. J. M. Fordal et al. menyatakan bahwa memanfaatkan teknologi JST untuk membuat model prediktif dapat meningkatkan keandalan sistem dengan meminimalkan waktu henti yang tidak terduga dan biaya perbaikan (2).

Penelitian ini menggunakan metodologi simulasi berbasis komputer untuk membangun dan mengevaluasi model jaringan syaraf tiruan (JST). Kami melatih dan menguji model menggunakan data dari pengukuran motor langsung dan simulasi berbagai kondisi operasional. Variabel input penting, seperti tegangan dan arus pada setiap fase motor, melatih model ANN untuk secara akurat mengidentifikasi tren ketidakseimbangan yang muncul. Teknologi ANN dan data operasional waktu nyata digunakan dalam penelitian terbaru oleh O. D. Sanchez et al. untuk menunjukkan cara membuat sistem pemantauan yang lebih baik dan lebih andal untuk deteksi anomali dini pada motor induksi tiga fasa (3).

Kami mengantisipasi bahwa penerapan model Jaringan Syaraf Tiruan (JST) akan menghasilkan keuntungan yang signifikan dalam domain pemeliharaan prediktif dan pengoperasian motor industri. Melalui identifikasi perbedaan tegangan dan arus yang tepat, perusahaan dapat segera mengurangi kemungkinan periode tidak aktif yang tidak terduga, meningkatkan efektivitas energi, dan memperpanjang masa operasional motor. Hal ini sejalan dengan upaya untuk mencapai produktivitas yang optimal dan efisiensi operasional yang tahan lama. Penggunaan sistem pemantauan berbasis jaringan syaraf tiruan (JST) di sektor industri telah menghasilkan peningkatan produktivitas yang besar dan penurunan lebih dari 20% dalam biaya pemeliharaan, menurut penelitian J. Lee et al. (4).

Penelitian ini sangat relevan dalam konteks Industri 4.0, di mana penggunaan teknologi digital dan pemantauan berbasis data memainkan peran penting dalam meningkatkan efektivitas dan ketergantungan sistem produksi. Dengan memanfaatkan teknologi jaringan syaraf tiruan (JST) untuk mengidentifikasi ketidakseimbangan pada motor induksi tiga fasa, kami dapat menggabungkan sistem ini dengan platform Internet of Things (IoT) untuk menciptakan pengaturan produksi yang lebih cerdas dan fleksibel. S. Ayvaz dan K. Alpay

melakukan penelitian baru-baru ini yang menunjukkan bagaimana mengintegrasikan teknologi jaringan syaraf tiruan (JST) ke dalam sistem Internet of Things (IoT) dapat meningkatkan operasi industri dengan mengurangi waktu henti peralatan dan meningkatkan ketersediaan produksi secara keseluruhan (5).

Jaringan syaraf tiruan (JST) telah membuat kemajuan yang signifikan dalam mendiagnosis ketidakseimbangan tegangan dan arus pada motor induksi tiga fase dalam beberapa tahun terakhir. Sebuah studi oleh M. A. Sheikh et al. (6) menunjukkan bahwa jaringan syaraf tiruan (JST) bagus dalam menemukan ketidakseimbangan tegangan dengan melihat bentuk gelombang arus stator. NA Mohar et al. (7) melakukan investigasi terpisah dan merancang model jaringan syaraf tiruan (JST) untuk mengidentifikasi gangguan satu fasa pada motor induksi. Studi ini menunjukkan kemampuan yang lebih unggul jika dibandingkan dengan pendekatan tradisional.

K. Tarek et al. (8) melakukan penelitian yang mendemonstrasikan desain jaringan syaraf tiruan (JST) yang disetel menggunakan algoritme genetika untuk mengidentifikasi ketidakseimbangan arus. Hasilnya menunjukkan peningkatan akurasi dan kecepatan deteksi. Demikian pula, Y. Li (9) memperkenalkan pendekatan jaringan syaraf tiruan (JST) berbasis wavelet untuk mendeteksi ketidakseimbangan tegangan. Metode ini dapat secara akurat mengidentifikasi ketidakseimbangan secara real-time dengan tingkat presisi yang tinggi. Lebih lanjut, K. A. Al Sumarmad et al. (10) mengusulkan metodologi hibrida yang mengintegrasikan jaringan syaraf tiruan (JST) dan logika fuzzy untuk mendiagnosis ketidakseimbangan. Strategi ini menawarkan keuntungan dalam hal fleksibilitas dan kemampuannya untuk menangani noise. Karya X. Zeng et al. (11) menambahkan temuan ini dengan menunjukkan bahwa menggabungkan jaringan syaraf tiruan (JST) dengan metode pemrosesan sinyal dapat meningkatkan akurasi deteksi secara signifikan.

M. Skowron et al. (12) mengembangkan struktur jaringan syaraf tiruan (JST) baru khusus untuk aplikasi industri dalam sebuah penelitian baru-baru ini. Studi ini menunjukkan bahwa arsitektur ini sangat efektif dalam mendeteksi ketidakseimbangan dalam kondisi operasional yang berbeda, menyoroti efisiensinya. Selain itu, H. Liu et al. (13) menekankan betapa pentingnya memilih fitur yang tepat saat membuat jaringan syaraf tiruan (JST) untuk mendeteksi ketidakseimbangan.

Temuan penelitian tersebut mengungkapkan bahwa pemilihan fitur yang tepat dapat meningkatkan akurasi deteksi sebanyak 15%. Selain itu, M. Hussain et al. (14) menggunakan metode deep learning untuk membuat model jaringan saraf tiruan (JST) yang dapat mengidentifikasi ketidakseimbangan dengan lebih akurat daripada model konvensional. A. Mariyaraj dan S. P. Thankappan (15) melakukan penelitian yang menggarisbawahi keuntungan potensial dari penggabungan jaringan saraf tiruan (JST) dengan sistem kontrol berbasis Internet of Things (IoT). Integrasi ini dapat menghasilkan solusi yang lebih efektif dan komprehensif untuk mendeteksi dan memantau ketidakseimbangan pada motor induksi tiga fase.

Secara kolektif, berbagai penelitian ini menunjukkan bahwa jaringan saraf tiruan (JST) merupakan alat yang sangat baik dan dapat diandalkan untuk menemukan ketidakseimbangan tegangan dan arus pada motor induksi tiga fase. Akurasi yang unggul, kecepatan deteksi yang cepat, dan fleksibilitas yang luar biasa menunjukkan potensi yang sangat besar untuk penggunaan yang lebih luas di berbagai sektor industri di masa depan.

2. METODE

2.1 Perancangan Sistem ANN

Untuk menentukan parameter ketidakseimbangan tegangan dan arus, penting untuk mengetahui standar yang digunakan sebagai acuan. Standar untuk ketidakseimbangan tegangan mengacu pada IEEE Std 112-2004 (16), yang menyatakan bahwa nilai maksimum untuk ketidakseimbangan tegangan adalah 3%. Standar untuk ketidakseimbangan arus mengacu pada The American National Standards Institute (ANSI) C84.1-1995 (17), yang menyatakan bahwa nilai maksimum untuk ketidakseimbangan arus adalah 5%.

Mengacu pada IEEE Std 112-2004 (16), persentase ketidakseimbangan tegangan dapat ditentukan dengan menggunakan rumus berikut.

$$VU = \frac{\max\left[\left|V_a - \frac{V_a+V_b+V_c}{3}\right|, \left|V_b - \frac{V_a+V_b+V_c}{3}\right|, \left|V_c - \frac{V_a+V_b+V_c}{3}\right|\right]}{\frac{V_a+V_b+V_c}{3}} \quad (1)$$

Dimana, V_a , V_b , V_c adalah tegangan fasa.

Tabel 1. Contoh perhitungan ketidakseimbangan

No	Input			Persen <i>Unbalance</i>	Keterangan
	VR	VS	VT		

1	220,80	220,90	220,50	0%	<i>Balance</i>
2	220,80	220,90	225,50	1%	<i>Balance</i>
3	220,80	219,90	225,50	2%	<i>Balance</i>
4	220,80	217,90	228,50	3%	<i>Balance</i>
5	220,80	215,90	231,50	4%	<i>Unbalance</i>

Demikian pula, persentase ketidakseimbangan arus, seperti yang dirujuk dalam IEEE Std 112-2004 (16), dapat ditentukan dengan menggunakan rumus berikut.

$$IU = \frac{\max\left[\left|I_a - \frac{I_a+I_b+I_c}{3}\right|, \left|I_b - \frac{I_a+I_b+I_c}{3}\right|, \left|I_c - \frac{I_a+I_b+I_c}{3}\right|\right]}{\frac{I_a+I_b+I_c}{3}} \quad (2)$$

Dimana, I_a , I_b , I_c adalah arus fasa.

Tabel 2. Contoh perhitungan ketidakseimbangan arus

No	Input			Persen <i>Unbalance</i>	Keterangan
	IR	IS	IT		
1	2,92	2,90	2,94	1%	<i>Balance</i>
2	2,92	2,97	2,88	2%	<i>Balance</i>
3	2,94	2,82	2,77	3%	<i>Balance</i>
4	2,92	2,95	2,75	4%	<i>Balance</i>
5	2,90	2,75	2,62	5%	<i>Balance</i>
6	2,92	2,76	2,62	6%	<i>Unbalance</i>

Setelah menghitung ketidakseimbangan, langkah selanjutnya adalah memberi label 1 dan -1. Tujuannya adalah agar JST dapat memahami tujuan yang diinginkan dengan lebih baik ketika diberikan input yang beragam.

Untuk memberi label tegangan, ada ketentuan yang harus diikuti sebagai berikut:

1. Nilai dengan keterangan *Balance* diberi label -1.
2. Nilai dengan keterangan *Unbalance* diberi label 1.

Tabel 3. Contoh target capaian ANN tegangan

No	Input			Keterangan	Target
	VR	VS	VT		
1	220,80	220,90	220,50	<i>Balance</i>	-1
2	220,80	220,90	225,50	<i>Balance</i>	-1
3	220,80	219,90	225,50	<i>Balance</i>	-1
4	220,80	217,90	228,50	<i>Balance</i>	-1
5	220,80	215,90	231,50	<i>Unbalance</i>	1

Untuk memberikan label pada arus, ada ketentuan yang harus diikuti sebagai berikut:

1. Nilai dengan keterangan *Balance* diberi label -1.
2. Nilai dengan keterangan *Unbalance* diberi label 1.

Tabel 4. Contoh target capaian ANN arus

No	Input			Keterangan	Target
	IR	IS	IT		
1	2,92	2,90	2,94	Balance	-1
2	2,92	2,97	2,88	Balance	-1
3	2,94	2,82	2,77	Balance	-1
4	2,92	2,95	2,75	Balance	-1
5	2,90	2,75	2,62	Balance	-1
6	2,92	2,76	2,62	Unbalance	1

Selanjutnya, perlu dilakukan perhitungan *Error* dan Akurasi yang digunakan untuk mendukung proses analisis data. Untuk menentukan kelayakan penelitian ini, nilai *error* dan akurasi dari perbandingan antara klasifikasi aktual (manual) dengan klasifikasi JST diperiksa.

Mean Squared Error (MSE), memberikan perbandingan antara klasifikasi aktual dengan klasifikasi yang dibuat oleh Jaringan Syaraf Tiruan (JST). Nilai MSE yang sangat rendah menunjukkan bahwa JST telah terlatih dengan baik, dan sebaliknya.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

dimana,

y_i = klasifikasi aktual

\hat{y}_i = klasifikasi prediksi

Root Mean Squared Error (RMSE), adalah akar kuadrat dari Mean Squared Error (MSE). Semakin kecil nilai RMSE, maka dapat dikatakan bahwa model tersebut semakin akurat dalam prediksinya.

$$RMSE = \sqrt{MSE} \quad (4)$$

Akurasi Klasifikasi, diukur dalam persentase. Semakin tinggi nilai persentase akurasi, maka hal ini mengindikasikan bahwa hasil prediksi semakin baik.

$$Akurasi = \frac{K-IC}{K} \times 100 \quad (5)$$

dimana,

K = Jumlah sampel yang diuji

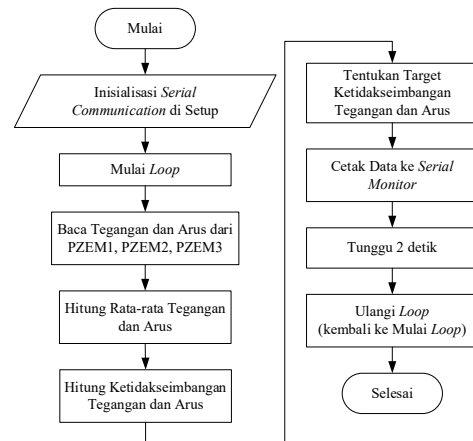
IC = Jumlah klafikasi yang salah

2.2 Simulasi Sistem Artificial Neural Network

Untuk membuat sistem klasifikasi ANN, diperlukan pengambilan dataset tegangan dan arus pada motor induksi tiga fasa yang sudah memiliki target -1 atau 1. Program akuisisi data dikembangkan untuk mengumpulkan dataset tegangan dan arus dari motor induksi tiga fasa

dengan menggunakan bahasa C/C++ pada perangkat lunak Arduino IDE. Program ini menggunakan library PZEM-004t yang sudah tersedia di Arduino, sehingga hanya membutuhkan pemanggilan library untuk sintaks yang digunakan. Hasil dari akuisisi data ini akan dikumpulkan sebagai dataset di PLX-DAQ.

Gambar 3 berikut ini menunjukkan diagram alir program akuisisi data.



Gambar 1. Diagram alir program akuisisi data

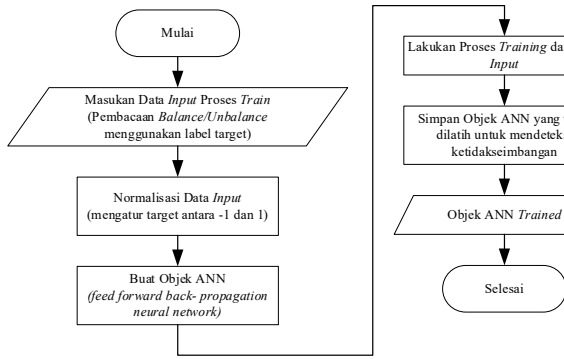
Untuk mencapai hasil yang optimal dalam melatih Jaringan Syaraf Tiruan (JST), diperlukan beberapa parameter ini.

Tabel 5. Parameter training ANN

Architecture	1 input, 1 hidden layer, 1 output
Training Algorithm	Feed Forward Backpropagation
Transfer Function	Tansig
Maximum Training Epoch	1000
Performance Function	Mean Square Error (MSE)
Hidden Neurons	15

Desain arsitektur ANN yang dirancang terdiri dari 6unit input, 15 neuron tersembunyi, dan 2unit output.

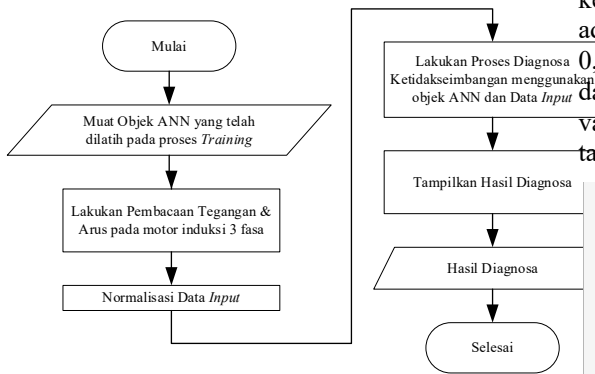
Selanjutnya adalah *training* JST yang hasilnya akan dimanfaatkan dengan cara dipanggil pada saat proses *testing*. Berikut ini diagram alir proses *training* ANN seperti pada Gambar 5.




Gambar 2. Diagram alir proses *training* ANN

Pada proses *training* ini, dimulai dengan memanggil file dataset input dari ANN, yang terdiri dari 9 kolom, termasuk 1 kolom untuk waktu, 6 kolom untuk input, dan 2 kolom untuk target. Selanjutnya, dilakukan pemisahan data sebanyak 70% untuk keperluan pelatihan, sedangkan 30% sisanya dialokasikan untuk pengujian. Parameter untuk pemodelan JST dapat dilihat pada Tabel 5. Selanjutnya, hasil akan ditampilkan dalam bentuk data yang informatif untuk menilai kesesuaian pemodelan ANN.

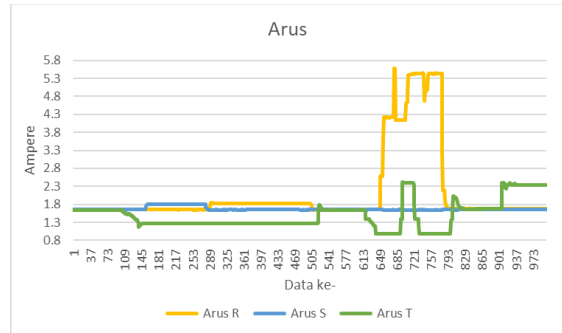
Setelah *training ANN*, selanjutnya proses *testing ANN* menggunakan input data baru. Hasil Diagnosa tersebut akan ditampilkan dalam *histogram*. Diagram alir ditunjukkan pada Gambar 6.



Gambar 3. Diagram alir proses *testing* ANN



Gambar 4. Grafik dataset tegangan



Gambar 5. Grafik dataset arus

Berdasarkan Gambar 7 dan Gambar 8 diatas, terlihat jelas bahwa 1000 titik data yang dihasilkan menunjukkan variasi dan fluktuasi pada seluruh fase yang berbeda. Hal ini memungkinkan visualisasi kemampuan JST untuk membedakan tegangan dan arus yang seimbang atau tidak seimbang.

Proses *training ANN* dibuat hanya dengan waktu 02 detik dalam 60 putaran *training* dari keseluruhan 1000 data input. Nilai kinerja awal adalah 12,4 dan nilai saat dihentikan adalah 0,00604. Gradien dihentikan pada nilai 0,00439 dan nilai μ dihentikan pada 0,0001. Lalu, 6 validasi cek dilakukan, yang sama dengan nilai target.


Training Progress			
Unit	Initial Value	Stopped Value	Target Value
Epoch	0	60	1000
Elapsed Time	-	00:00:02	-
Performance	12.4	0.00604	0
Gradient	14.1	0.00439	1e-07
μ	0.001	0.0001	1e+10
Validation Checks	0	6	6

Gambar 6. *Training progress*

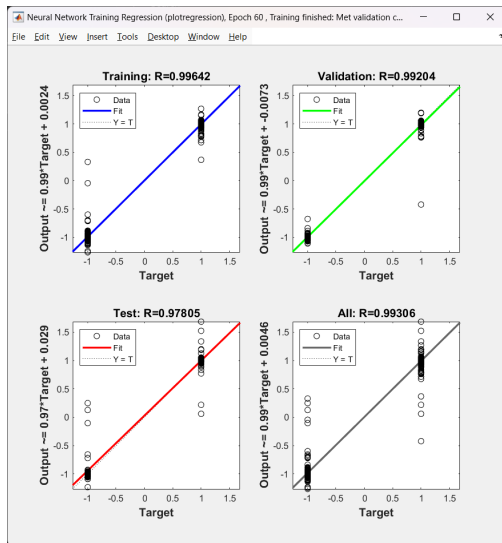
3. HASIL DAN PEMBAHASAN

3.1 Pengujian *Training ANN*

Berikut ini menyajikan hasil pengumpulan data, yang akan berfungsi sebagai data masukan untuk prosedur simulasi.



Gambar 7. Regression pemodelan ANN



Gambar 8. Performance pemodelan ANN

Dari Gambar 10 dan Gambar 11 yang menunjukkan bahwa *training* ANN sudah bagus dan layak untuk digunakan dengan dibuktikan pada hasil *performance* dengan *Best Validation Performance* adalah 0,014896 pada *epoch* 54 dan target dari keseluruhan *Regression* sudah diatas 0,95.

Berdasarkan hasil diatas, dapat dikatakan bahwa pemodelan yang ini layak untuk digunakan, dengan kesimpulan sebagai berikut pada Tabel 6.

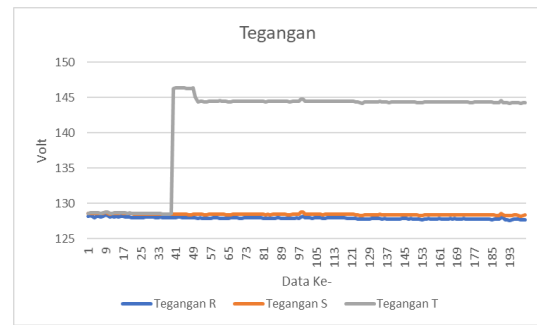
Tabel 6. Hasil Kesimpulan Pemodelan ANN

Pemodelan ANN	
Total Data	1000
Accuracy Model	99.20%
Mean Squared Error (MSE)	0.0183
Root Mean-Squared Error (RMSE)	0.1353


3.2 Pengujian Testing ANN

Proses *testing ANN* dilakukan dengan data input yang berbeda dari Gambar 7 dan Gambar 8. Berikut ini data input *testing* yang akan

dicoba pada simulasi, seperti Gambar 12 dan Gambar 13.




Gambar 9. Grafik input tegangan proses testing



Gambar 10. Grafik input arus proses testing

Gambar 14 menampilkan hasil dari proses klasifikasi *testing*.



Gambar 11. Hasil klasifikasi testing ANN

Proses pengujian menghasilkan, 39 data termasuk *balance*, dan 161 data termasuk *unbalance*, dari total 200 data yang diproses. Akurasi klasifikasi adalah 100,00%, dan kesalahan adalah 0,00%. Nilai MSE adalah 0.0077 dan RMSE adalah 0.0876, yang menunjukkan kesalahan yang minimal.

Tabel 7. Hasil kesimpulan pengujian keseluruhan sistem

Pengujian Sistem	
Number of test voltage samples	200
Percentage Correct classification	100,00%
Percentage Incorrect classification	0,00%

<i>Mean Squared Error (MSE)</i>	0,0077
<i>Root Mean-Squared Error (RMSE)</i>	0,0876

4. KESIMPULAN

Perancangan algoritma ANN untuk sistem diagnosis motor induksi tiga fasa telah berhasil dirancang dan disimulasikan. Hasil pengujian sistem menunjukkan bahwa simulasi metode ANN 100% akurat, menemukan keseimbangan pada 19,50% data dan ketidakseimbangan pada 80,50% data, dengan nilai MSE 0,0077 dan nilai RMSE 0,0876. Mendiagnosis ketidakseimbangan tegangan dan arus pada motor induksi tiga fasa dapat membantu memberikan proteksi sederhana untuk mengetahui kondisi motor sebelum terjadi kerusakan yang parah.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Politeknik Negeri Bandung melalui Wakil Direktur bidang akademik yang telah memberikan bantuan pembiayaan Tugas Akhir mahasiswa program sarjana terapan dan diploma III tahun akademik 2023/2024 sesuai SK Direktur Nomor B/295/PL1/HK.02.00/2024.

DAFTAR PUSTAKA

- V. G. De Araújo, R. De Andrade Teixeira, T. F. Do Nascimento, A. O. Salazar, and D. A. De Moura Fonseca, "Application of Artificial Intelligence Techniques for Monitoring and Fault Diagnosis in Three-Phase Induction Motors," in 2023 IEEE 8th Southern Power Electronics Conference and 17th Brazilian Power Electronics Conference (SPEC/COBEP), Florianopolis, Brazil: IEEE, Nov. 2023, pp. 1–8. doi: 10.1109/SPEC56436.2023.10407229.
- J. M. Fordal, P. Schjøberg, H. Helgetun, T. Ø. Skjermo, Y. Wang, and C. Wang, "Application of sensor data based predictive maintenance and artificial neural networks to enable Industry 4.0," *Adv. Manuf.*, vol. 11, no. 2, pp. 248–263, Jun. 2023, doi: 10.1007/s40436-022-00433-x.
- O. D. Sanchez, G. Martinez-Soltero, J. G. Alvarez, and A. Y. Alanis, "Real-Time Neural Classifiers for Sensor Faults in Three Phase Induction Motors," *IEEE Access*, vol. 11, pp. 19657–19668, 2023, doi: 10.1109/ACCESS.2023.3246379.
- J. Lee, J. Ni, J. Singh, B. Jiang, M. Azamfar, and J. Feng, "Intelligent Maintenance Systems and Predictive Manufacturing," *Journal of Manufacturing Science and Engineering*, vol. 142, no. 11, p. 110805, Nov. 2020, doi: 10.1115/1.4047856.
- S. Ayvaz and K. Alpay, "Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time," *Expert Systems with Applications*, vol. 173, p. 114598, Jul. 2021, doi: 10.1016/j.eswa.2021.114598.
- M. A. Sheikh, N. M. Nor, T. Ibrahim, and M. Irfan, "Unsupervised on-line method to diagnose unbalanced voltage in three-phase induction motor," *Neural Comput & Applic*, vol. 30, no. 12, pp. 3877–3892, Dec. 2018, doi: 10.1007/s00521-017-2973-0.
- N. A. Mohar et al., "Fault Detection Analysis for Three Phase Induction Motor Drive System using Neural Network," *J. Phys.: Conf. Ser.*, vol. 1878, no. 1, p. 012039, May 2021, doi: 10.1088/1742-6596/1878/1/012039.
- K. Tarek, L. Abdelaziz, C. Zoubir, K. Kais, and N. Karim, "Optimized multi layer perceptron artificial neural network based fault diagnosis of induction motor using vibration signals," *Diagnostyka*, vol. 22, no. 1, pp. 65–74, Mar. 2021, doi: 10.29354/diag/133091.
- Y. Li, "Exploring real-time fault detection of high-speed train traction motor based on machine learning and wavelet analysis," *Neural Comput & Applic*, vol. 34, no. 12, pp. 9301–9314, Jun. 2022, doi: 10.1007/s00521-021-06284-0.
- K. A. Al Sumarmad, N. Sulaiman, N. I. A. Wahab, and H. Hizam, "Energy Management and Voltage Control in Microgrids Using Artificial Neural Networks, PID, and Fuzzy Logic Controllers," *Energies*, vol. 15, no. 1, p. 303, Jan. 2022, doi: 10.3390/en15010303.
- X. Zeng et al., "Embedded Hardware Artificial Neural Network Control for Global and Real-Time Imbalance Current Suppression of Parallel Connected IGBTs," *IEEE Trans. Ind. Electron.*, vol. 67, no. 3, pp. 2186–2196, Mar. 2020, doi: 10.1109/TIE.2019.2905825.
- M. Skowron, M. Wolkiewicz, T. Orłowska-Kowalska, and C. Kowalski, "Application of Self-Organizing Neural Networks to Electrical Fault Classification in Induction Motors," *Applied Sciences*, vol. 9, no. 4, p. 616, Feb. 2019, doi: 10.3390/app9040616.
- H. Liu, M. Zhou, and Q. Liu, "An embedded feature selection method for imbalanced data classification," *IEEE/CAA J. Autom. Sinica*, vol. 6, no. 3, pp. 703–715, May 2019, doi: 10.1109/JAS.2019.1911447.
- M. Hussain, T. Din Memon, I. Hussain, Z. Ahmed Memon, and D. Kumar, "Fault Detection and Identification Using Deep Learning Algorithms in Induction Motors," *Computer Modeling in Engineering & Sciences*, vol. 133, no. 2, pp. 435–470, 2022, doi: 10.32604/cmcs.2022.020583.
- A. Mariyaraj and S. P. Thankappan, "IoT-integrated smart energy management system with enhanced ANN controller for small-scale microgrid," *Electr Eng*, May 2024, doi: 10.1007/s00202-024-02448-y.
- IEEE Std 112-2004, "IEEE Standard Test Procedure for Polyphase Induction Motors and Generators".

17. ANSI Standard C84.1-1995, "Electric Power Systems and Equipment-Voltage Ratings," 2005.