

Perbandingan Konvergensi dan Stabilitas DFNN Murni dan ANN BackPropagation untuk Klasifikasi Tingkat Keparahan Kerusakan Kumparan Stator

Giovanni Dimas Prenata*, Ahmad Ridho'i

Program Studi Teknik Elektro, Fakultas Teknologi Elektro dan Informatika Cerdas, Universitas 17 Agustus 1945
Surabaya

Jalan Semolowaru Nomor 45, Menur Pumpungan, Kecamatan Sukolilo, Kota Surabaya, Jawa Timur 60118

E-mail: gprenata@untagp-sby.ac.id

Naskah Masuk: 13 Juli 2026; Diterima: 15 September 2026; Terbit: 30 September 2026

ABSTRAK

Abstrak - Penelitian ini membandingkan konvergensi dan kestabilan dua metode pelatihan jaringan saraf tiruan (ANN), yaitu Pure DFNN dan BackPropagation, dalam klasifikasi tingkat keparahan kerusakan belitan stator motor induksi. Evaluasi dilakukan melalui 10 kali percobaan untuk masing-masing model, dengan parameter keberhasilan berdasarkan pencapaian nilai Mean Squared Error (MSE) mendekati ambang batas 0.0001. Hasil menunjukkan bahwa Pure DFNN mampu mencapai konvergensi tercepat dengan 294 iterasi dan MSE 0.000101230, namun variasi iterasinya sangat fluktuatif hingga mencapai 3514 iterasi, mencerminkan sensitivitas terhadap inisialisasi bobot. Di sisi lain, ANN BackPropagation menunjukkan konsistensi konvergensi yang lebih stabil, dengan seluruh percobaan berada pada rentang 226 hingga 449 iterasi, serta pencapaian MSE terbaik sebesar 0.000100122. Kedua metode sama-sama berhasil mencapai nilai error akhir yang sangat kecil. Namun demikian, hasil ini mengindikasikan bahwa ANN BackPropagation lebih unggul dalam hal stabilitas dan robustness, sementara Pure DFNN lebih cepat dalam beberapa kasus namun kurang konsisten. Temuan ini penting dalam pemilihan algoritma pelatihan ANN untuk sistem diagnosis kerusakan motor induksi yang memerlukan keandalan jangka panjang.

Kata kunci: Artificial Neural Network, DFNN, BackPropagation, Kegagalan Stator, Konvergensi.

ABSTRACT

Abstract - This study compares the convergence and stability of two artificial neural network (ANN) training methods Pure DFNN and BackPropagation for classifying the severity of stator winding faults in induction motors. The evaluation was conducted through 10 trials for each model, with success criteria defined by achieving a Mean Squared Error (MSE) close to the threshold of 0.0001. The results indicate that Pure DFNN achieved the fastest convergence with 294 iterations and an MSE of 0.000101230. However, its iteration range was highly fluctuating, reaching up to 3514 iterations, indicating sensitivity to weight initialization. In contrast, the ANN BackPropagation method demonstrated more stable convergence, with all trials falling within a narrow range of 226 to 449 iterations and achieving the best MSE of 0.000100122. Both methods succeeded in producing minimal final error values. Nevertheless, the findings suggest that ANN BackPropagation is superior in terms of stability and robustness, while Pure DFNN may offer faster convergence in certain cases but lacks consistency. These results are significant for selecting appropriate ANN training algorithms in induction motor fault diagnosis systems that require long-term reliability.

Keywords: Artificial Neural Network, DFNN, BackPropagation, Stator Fault, Convergence.

Copyright © 2026 Jurnal Teknik Elektro dan Komputasi (ELKOM)

1. PENDAHULUAN

Motor induksi tiga fasa merupakan salah satu mesin listrik yang paling luas digunakan pada sektor industri karena memiliki konstruksi sederhana, kokoh, biaya perawatan relatif rendah, serta mampu beroperasi pada berbagai kondisi pembebanan. Keandalan motor menjadi faktor penting karena gangguan yang tidak terdeteksi dapat menyebabkan penurunan kinerja, penghentian proses produksi, dan peningkatan biaya pemeliharaan. Oleh karena itu, condition monitoring dan diagnosis dini pada motor induksi terus

dikembangkan untuk mengidentifikasi perubahan kondisi sebelum berkembang menjadi kerusakan yang lebih berat [1] [2].

Salah satu bagian yang kritis pada motor induksi adalah belitan stator. Degradasi isolasi, tekanan termal, penuaan, ketidakseimbangan operasi, dan gangguan turn-to-turn dapat mengubah karakteristik listrik serta termal motor dan selanjutnya memengaruhi arus, faktor daya, kecepatan, torsi, daya, dan temperatur. Diagnosis gangguan stator sejak tahap awal penting karena kerusakan yang berkembang dapat menurunkan efisiensi dan meningkatkan risiko kegagalan operasi [1] [3] [4]. Berbagai pendekatan berbasis arus stator, transformasi wavelet, dan parameter operasi telah digunakan untuk mendeteksi serta membedakan kondisi sehat dan kondisi gangguan pada motor induksi [4] [5] [6] [7] [8].

Perkembangan machine learning dan artificial intelligence memperluas metode diagnosis motor dari pendekatan berbasis ambang menuju pembelajaran pola multivariat. Jaringan saraf telah digunakan untuk mendeteksi gangguan belitan stator, rotor, dan bearing melalui data arus maupun parameter operasi. Pendekatan convolutional neural network mampu mendeteksi gangguan awal belitan stator [3], sedangkan ANN berbasis seleksi fitur menunjukkan kemampuan diagnosis pada berbagai jenis gangguan [9] [10]. Feed-forward neural network juga telah digunakan untuk mendeteksi dan mengklasifikasikan 12 tipe gangguan kehilangan fasa motor induksi [11], sementara metode shallow dan deep learning lainnya mendukung pemantauan kondisi pada berbagai skenario operasi [12] [13] [14] [15].

Pada konteks penelitian di Indonesia, diagnosis gangguan belitan stator telah dikembangkan menggunakan arus starting berbasis MATLAB/Simulink [5], transformasi wavelet [6], Neural Network untuk klasifikasi hubung singkat turn-to-turn [7], serta kombinasi transformasi wavelet dan K-Nearest Neighbor untuk klasifikasi kerusakan motor [8]. Hasil-hasil tersebut menegaskan bahwa parameter listrik dan pola sinyal motor memiliki informasi diagnostik yang kuat. Namun, sebagian besar penelitian menitikberatkan pada keberhasilan deteksi atau akurasi klasifikasi, sedangkan konsistensi proses pelatihan jaringan saraf pada beberapa inisialisasi bobot masih relatif jarang dibahas secara eksplisit.

Dasar eksperimental pemilihan fitur pada penelitian ini diperkuat oleh pengujian penurunan resistansi belitan stator pada empat kondisi, yaitu 6,8 Ω , 5,7 Ω , 3,9 Ω , dan 3,5 Ω , dengan lima kondisi pembebanan: tanpa beban, beban generator, serta generator dengan satu hingga tiga lampu. Pada beban generator, penurunan resistansi dari 6,8 Ω menjadi 3,5 Ω menurunkan kecepatan dari 1447,6 rpm menjadi 1364,6 rpm, meningkatkan arus dari 2,31 A menjadi 3,40 A, menurunkan efisiensi dari 89,68% menjadi 75,16%, dan meningkatkan temperatur belitan hingga mendekati 50 $^{\circ}\text{C}$ [16]. Pola tersebut menunjukkan bahwa parameter tegangan, arus, faktor daya, kecepatan, torsi, daya, dan temperatur secara fisik berkaitan dengan tingkat degradasi belitan stator.

Artificial Neural Network (ANN) memiliki kemampuan untuk memodelkan hubungan nonlinier antarfitur, tetapi performanya dipengaruhi oleh arsitektur, learning rate, jumlah lapisan, dan inisialisasi bobot. ANN Backpropagation memperbarui bobot berdasarkan gradien error, sedangkan Deep Feedforward Neural Network (DFNN) menggunakan struktur feedforward yang lebih dalam untuk membentuk representasi bertingkat. Pada dataset eksperimental yang relatif terbatas, variasi bobot awal dapat menyebabkan perbedaan jumlah iterasi yang dibutuhkan untuk mencapai target error. Oleh karena itu, evaluasi satu kali pengujian saja belum cukup untuk menilai keterulangan dan kestabilan proses pelatihan [9] [10] [12] [13] [14].

Penelitian penulis sebelumnya yang masih berada pada domain diagnosis dan pemantauan kondisi motor listrik menunjukkan bahwa perubahan kondisi mekanis maupun elektris dapat tercermin secara jelas pada parameter terukur. Pada pengujian degradasi resistansi belitan stator, perubahan resistansi dari 6,8 Ω hingga 3,5 Ω terbukti diikuti oleh perubahan arus, kecepatan, efisiensi, dan temperatur motor [16]. Pada penelitian lain mengenai kerusakan bearing motor, analisis arus stator dalam domain frekuensi menggunakan Discrete Fourier Transform (DFT) mampu membedakan pola bearing normal dan rusak pada beberapa kondisi pembebanan [17]. Lebih dekat dengan fokus penelitian ini, evaluasi klasifikasi gangguan stator motor induksi menggunakan Support Vector Machine (SVM), Gaussian Naive Bayes (GNB), dan K-Nearest Neighbor (KNN) dengan masukan tegangan fasa, arus fasa, faktor daya, kecepatan, torsi, daya, dan temperatur menghasilkan akurasi 100% pada seluruh data uji. Konsistensi hasil dari tiga metode dengan prinsip yang berbeda juga menunjukkan bahwa kualitas dan relevansi fitur memiliki peran penting dalam diagnosis gangguan stator [18]. Ketiga studi tersebut memperkuat bahwa parameter listrik, mekanis, dan termal memiliki informasi diagnostik yang kuat untuk merepresentasikan kondisi motor. Namun, penelitian-penelitian tersebut lebih menitikberatkan pada perubahan karakteristik fisik atau kinerja diagnosis, sedangkan kestabilan konvergensi dan repeatability proses pelatihan jaringan saraf pada beberapa inisialisasi bobot masih perlu dievaluasi secara khusus.


Berdasarkan permasalahan tersebut, penelitian ini berfokus secara khusus pada klasifikasi tingkat keparahan kerusakan belitan stator motor induksi dengan membandingkan Pure DFNN dan ANN Backpropagation. Kedua model diuji sebanyak sepuluh kali menggunakan inisialisasi bobot acak pada

dataset dan kriteria penghentian yang sama. Evaluasi diarahkan pada dua aspek utama, yaitu jumlah iterasi yang diperlukan untuk mencapai konvergensi dan konsistensi nilai Mean Squared Error (MSE) akhir terhadap ambang sekitar 0,0001. Dengan pendekatan ini, kontribusi penelitian tidak hanya terletak pada kemampuan model mencapai error rendah, tetapi juga pada analisis stabilitas dan repeatability pelatihan sebagai pertimbangan untuk sistem diagnosis gangguan stator yang andal.

2. METODE PENELITIAN


2.1. Algoritma Artificial Neural Network (ANN) Backpropagation

Artificial Neural Network (ANN) atau jaringan saraf tiruan merupakan model komputasi yang tersusun atas neuron-neuron buatan dan hubungan berbobot untuk memetakan pola masukan menjadi keluaran. Pada aplikasi diagnosis motor induksi, ANN dapat mempelajari hubungan nonlinier antara parameter listrik, mekanis, dan termal dengan kondisi kerusakan [7] [10] [11] [12]. Secara umum, jaringan terdiri atas input layer, satu atau lebih hidden layer, dan output layer. Pada model ANN Backpropagation yang digunakan dalam penelitian ini, 11 parameter pengukuran menjadi masukan jaringan, satu hidden layer terdiri atas 2 neuron, dan satu neuron keluaran digunakan untuk merepresentasikan tingkat keparahan kerusakan stator.



Gambar 1. Arsitektur Backpropagation

Backpropagation merupakan algoritma pembelajaran terawasi yang memperbarui bobot jaringan secara iteratif berdasarkan gradien error. Prosesnya terdiri atas forward pass untuk menghasilkan keluaran jaringan dan backward pass untuk menghitung kontribusi error terhadap bobot pada setiap lapisan. Error dihitung menggunakan Mean Squared Error (MSE), kemudian bobot diperbarui menggunakan learning rate hingga nilai error mendekati kriteria penghentian. Mekanisme ini banyak digunakan pada feedforward neural network dan telah diterapkan pada diagnosis gangguan motor induksi [7] [10] [11].



Gambar 2. Diagram Alir Algoritma ANN Backpropagation

Secara konseptual, ANN dapat dipandang sebagai sistem pemrosesan informasi yang terdiri atas lapisan masukan, satu atau lebih lapisan tersembunyi, dan lapisan keluaran. Dua proses komputasi utama dalam ANN adalah propagasi maju (forward propagation) dan Backpropagation. Pada proses propagasi maju, sinyal masukan diproses dengan menghitung jumlah berbobot dari setiap masukan, menambahkan bias

sebagai faktor penggeser, kemudian melewati hasilnya melalui fungsi aktivasi untuk menghasilkan keluaran.

$$Z_j = \sum_{i=1}^n W_{ij}X_i + b_j \quad (1)$$

Nilai yang telah dihitung tersebut kemudian dilewatkan melalui fungsi aktivasi, misalnya fungsi sigmoid, untuk menghasilkan keluaran neuron.

$$f(Z_j) = \frac{1}{1 + e^{-Z_j}} \quad (2)$$

Selanjutnya, keluaran jaringan dibandingkan dengan nilai target menggunakan metrik Mean Squared Error (MSE), yang berfungsi untuk mengukur selisih antara data hasil prediksi dan data aktual.

$$E = \frac{1}{N} \sum_{k=1}^N (t_k - y_k)^2 \quad (3)$$

Pada metode Backpropagation, pembaruan bobot dilakukan dengan mengurangi nilai bobot searah dengan gradien kesalahan, yaitu ke arah penurunan nilai kesalahan. Dengan demikian, kesalahan jaringan dapat diminimalkan secara bertahap pada setiap iterasi pelatihan.

$$W_{ij}(t+1) = W_{ij}(t) - \eta \frac{\partial E}{\partial W_{ij}} \quad (4)$$

Keterangan:

w_{ij} = bobot antarneuron


η = learning rate

E = fungsi kesalahan

$\partial E / \partial W_{ij}$ = turunan fungsi kesalahan terhadap bobot

2.2. Deep Feedforward Neural Network (DFNN)

Pada penelitian ini digunakan Pure Deep Feedforward Neural Network (DFNN) dengan pendekatan Multi-Layer Perceptron. Arsitektur jaringan terdiri atas lima lapisan. Lapisan pertama adalah input layer dengan 11 masukan dan unit bias. Lapisan kedua, ketiga, dan keempat masing-masing berfungsi sebagai hidden layer dengan 2 neuron. Lapisan kelima merupakan output layer dengan satu neuron keluaran. Struktur feedforward bertingkat dipilih untuk membandingkan karakteristik konvergensi dengan ANN Backpropagation yang lebih dangkal pada dataset stator yang sama [9] [10] [14].



Gambar 3. Arsitektur DFNN

Perhitungan nilai keluaran pada neuron-neuron seperti O10, O11, O20, O21, O30, O31, hingga keluaran akhir Y dilakukan menggunakan Persamaan (1) dengan fungsi aktivasi sigmoid.

$$output = activation\ function\ (\sum_{i=1}^n a_i w_i + b) \quad (1)$$


Proses pembaruan bobot pada jaringan dilakukan secara bertahap melalui mekanisme Backpropagation. Bobot antara lapisan keempat dan lapisan kelima diperbarui menggunakan Persamaan (7), setelah nilai error dihitung menggunakan Persamaan (5) dan delta output diperoleh melalui Persamaan (6).

$$error = output - target \quad (5)$$

$$delta\ output = error * output \quad (6)$$

$$w_i = w_{i-1} + LR * x_i * delta\ output \quad (7)$$

Sementara itu, pembaruan bobot dari lapisan ketiga ke lapisan kedua, serta dari lapisan kedua ke lapisan pertama, dilakukan menggunakan prinsip yang sama. Proses tersebut diawali dengan menghitung nilai delta pada lapisan tersembunyi, kemudian nilai delta tersebut digunakan dalam Persamaan (7) untuk memperbarui bobot jaringan.



Gambar 4. Arsitektur DFNN

2.3. Akuisisi Data Eksperimental dan Konfigurasi Dataset

Data penelitian diperoleh dari pengujian eksperimental laboratorium pada motor induksi tiga fasa, bukan dari simulasi MATLAB/Simulink. Eksperimen dasar dilakukan pada empat tingkat resistansi belitan stator, yaitu 6,8 Ω sebagai kondisi normal, 5,7 Ω sebagai kerusakan ringan, 3,9 Ω sebagai kerusakan sedang, dan 3,5 Ω sebagai kerusakan berat. Setiap kondisi resistansi diuji pada lima skenario pembebanan, yaitu tanpa beban, beban generator, generator dengan satu lampu, dua lampu, dan tiga lampu. Konfigurasi eksperimen tersebut merupakan basis pengukuran kondisi stator yang telah dilaporkan pada penelitian eksperimental sebelumnya [16].

Pada setiap pengujian dicatat parameter kelistrikan, mekanis, dan termal. Sebelas parameter yang digunakan sebagai masukan model adalah tegangan antarfasa V_{rs} , V_{st} , dan V_{rt} ; arus fasa I_r , I_s , dan I_t ; faktor daya ($\cos\phi$); kecepatan putar (rpm); torsi (Nm); daya (W); dan temperatur belitan ($^{\circ}\text{C}$). Efisiensi juga dihitung pada eksperimen dasar untuk mengevaluasi kinerja motor, tetapi tidak digunakan sebagai fitur masukan jaringan pada penelitian klasifikasi ini. Sebelum proses pelatihan dan pengujian, setiap fitur dinormalisasi dengan metode Min-Max agar perbedaan skala antarfitur tidak mendominasi proses pembelajaran.

Dataset pemodelan terdiri atas 40 sampel pengukuran yang dibagi menjadi 24 data latih dan 16 data uji. Komposisi dibuat seimbang untuk empat tingkat keparahan, yaitu enam sampel latih dan empat sampel uji pada setiap kelas. Target numerik jaringan ditetapkan sebesar 0,10 untuk kondisi normal 6,8 Ω , 0,40 untuk kerusakan 5,7 Ω , 0,70 untuk kerusakan 3,9 Ω , dan 0,95 untuk kerusakan 3,5 Ω . Pada tahap interpretasi keluaran, nilai di bawah 0,25 dikategorikan normal; 0,25 sampai kurang dari 0,55 sebagai kerusakan ringan; 0,55 sampai kurang dari 0,825 sebagai kerusakan sedang; dan nilai 0,825 atau lebih sebagai kerusakan berat. Kedua model menggunakan dataset, target, dan kriteria MSE yang sama sehingga perbandingan konvergensi dilakukan pada kondisi eksperimen yang setara.

Untuk menilai kestabilan pelatihan, Pure DFNN dan ANN Backpropagation masing-masing dijalankan sebanyak sepuluh kali dengan inisialisasi bobot awal secara acak. Kriteria konvergensi ditentukan berdasarkan nilai MSE yang mendekati ambang 0,0001. Pada setiap run dicatat jumlah iterasi saat model mencapai kondisi konvergen dan nilai MSE akhir. Dengan demikian, validasi yang dianalisis dalam penelitian ini bukan hanya kemampuan mencapai error rendah, tetapi juga repeatability proses pelatihan terhadap perubahan bobot awal.

3. HASIL DAN PEMBAHASAN

Penelitian ini melakukan serangkaian eksperimen untuk membandingkan kinerja konvergensi dan stabilitas dua model dalam mengklasifikasikan tingkat keparahan gangguan belitan stator, yaitu Pure Deep Feedforward Neural Network (DFNN) dan Artificial Neural Network (ANN) berbasis Backpropagation. Setiap model diuji sebanyak sepuluh kali dengan inisialisasi bobot secara acak. Kriteria keberhasilan pelatihan ditetapkan berdasarkan kemampuan model dalam mencapai nilai Mean Squared Error (MSE)

yang mendekati ambang batas 0,0001. Oleh karena itu, analisis difokuskan pada jumlah iterasi maksimum yang diperlukan untuk mencapai konvergensi serta konsistensi nilai MSE pada beberapa kali pengujian.

Tabel 1. Hasil Pengujian Model Pure DFNN


Model Name	Max Iteration	MSE
NewCode_Stator_1	573	0.000100347
NewCode_Stator_2	442	0.000100393
NewCode_Stator_3	495	0.000100674
NewCode_Stator_4	3514	0.000101302
NewCode_Stator_5	395	0.000100162
NewCode_Stator_6	294	0.00010123
NewCode_Stator_7	377	0.000100181
NewCode_Stator_8	449	0.000100709
NewCode_Stator_9	322	0.000101342
NewCode_Stator_10	413	0.000100444

Evaluasi terhadap model Pure DFNN menunjukkan bahwa jumlah iterasi maksimum yang diperlukan untuk mencapai konvergensi berada pada rentang 294 hingga 3514 iterasi. Sebagian besar pengujian menunjukkan konvergensi yang cepat, seperti pada NewCode_Stator_6 yang mencapai MSE sebesar 0,00010123 hanya dalam 294 iterasi, serta NewCode_Stator_9 yang mencapai MSE sebesar 0,000101342 dalam 322 iterasi. Namun demikian, terdapat satu pencilan ekstrem pada NewCode_Stator_4 yang memerlukan 3514 iterasi untuk mencapai MSE sebesar 0,000101302. Fenomena ini menunjukkan bahwa meskipun Pure DFNN cenderung mampu mencapai konvergensi dengan cepat pada sebagian besar pengujian, model ini masih sensitif terhadap variasi inisialisasi bobot awal, sehingga dalam kondisi tertentu dapat mengalami keterlambatan konvergensi yang signifikan.

Tabel 2. Hasil Pengujian Model ANN Backpropagation

Model Name	Max Iteration	MSE
NewCode_Stator-4_1	287	0.000100581
NewCode_Stator-4_2	449	0.000100133
NewCode_Stator-4_3	332	0.000100122
NewCode_Stator-4_4	328	0.000100743
NewCode_Stator-4_5	295	0.000100479
NewCode_Stator-4_6	226	0.000100885
NewCode_Stator-4_7	226	0.000100182
NewCode_Stator-4_8	321	0.000100167
NewCode_Stator-4_9	348	0.00010063
NewCode_Stator-4_10	363	0.000100201

Ditinjau dari stabilitas nilai MSE, Pure DFNN menghasilkan nilai kesalahan akhir dalam rentang yang sangat sempit, yaitu antara 0,000100162 hingga 0,000101342. Kinerja terbaik dicapai oleh NewCode_Stator_5 dengan MSE sebesar 0,000100162, sedangkan nilai MSE tertinggi diperoleh pada NewCode_Stator_9 sebesar 0,000101342. Perbedaan nilai MSE yang relatif kecil antarpercobaan menunjukkan bahwa variasi kinerja pada Pure DFNN terutama dipengaruhi oleh kecepatan konvergensi, yaitu jumlah iterasi yang dibutuhkan, bukan oleh kualitas nilai kesalahan akhir yang dihasilkan.




Gambar 5. Hubungan Iterasi terhadap MSE pada model NewCode_Stator_5 (model Pure DFNN)

Sebaliknya, ANN Backpropagation menunjukkan rentang iterasi yang lebih terkonsentrasi, yaitu antara 226 hingga 449 iterasi. Konvergensi tercepat diperoleh pada NewCode_Stator-4_6 dan NewCode_Stator-4_7, yang masing-masing mencapai konvergensi dalam 226 iterasi dengan nilai MSE sebesar 0,000100885

dan 0,000100182. Pengujian dengan iterasi terlama terdapat pada NewCode_Stator-4_2, yang memerlukan 449 iterasi untuk mencapai MSE sebesar 0,000100133. Berbeda dengan Pure DFNN, tidak ditemukan pencilaan dengan jumlah iterasi yang berlebihan pada model ANN Backpropagation. Hal ini menunjukkan bahwa ANN Backpropagation memiliki kinerja konvergensi yang lebih stabil dan konsisten terhadap dataset yang digunakan.

Berdasarkan nilai MSE akhir, ANN Backpropagation juga menunjukkan rentang hasil yang sempit, yaitu dari 0,000100122 hingga 0,000100885. Kinerja terbaik dicapai oleh NewCode_Stator-4_3 dengan MSE sebesar 0,000100122, sedangkan kesalahan tertinggi diperoleh pada NewCode_Stator-4_6 dengan MSE sebesar 0,000100885. Sama seperti pada Pure DFNN, seluruh nilai MSE akhir tetap berada sangat dekat dengan ambang batas yang ditetapkan. Hal ini menunjukkan bahwa kedua model mampu menghasilkan tingkat kesalahan yang rendah. Dengan demikian, perbedaan utama antara kedua model tidak terletak pada kinerja kesalahan akhir, melainkan pada konsistensi konvergensi dan sensitivitas terhadap kondisi inisialisasi bobot awal.



Gambar 6. Hubungan Iterasi terhadap MSE pada model NewCode_Stator-4_7 (model ANN Backpropagation).

Dalam perbandingan secara langsung, Pure DFNN menunjukkan potensi untuk mencapai konvergensi lebih cepat pada sebagian besar pengujian, tetapi memiliki konsistensi yang lebih rendah. Hal ini ditunjukkan oleh adanya satu percobaan yang membutuhkan jumlah iterasi jauh lebih besar, yaitu 3514 iterasi. Sebaliknya, ANN Backpropagation menunjukkan pola konvergensi yang lebih stabil, dengan seluruh pengujian berada dalam rentang iterasi yang relatif sempit, yaitu 226 hingga 449 iterasi. Temuan ini mengindikasikan bahwa ANN Backpropagation lebih robust terhadap variasi inisialisasi bobot awal dalam konteks klasifikasi tingkat keparahan gangguan stator. Sementara itu, Pure DFNN dapat memberikan keunggulan pada kasus tertentu yang membutuhkan konvergensi cepat, tetapi berpotensi kurang andal dari aspek keterulangan hasil. Temuan ini memiliki relevansi penting dalam implementasi praktis diagnostik motor induksi, karena konsistensi dan keandalan pada berbagai pengujian menjadi faktor krusial untuk menjamin kinerja klasifikasi yang dapat diandalkan, khususnya pada kondisi pengukuran yang bervariasi.

4. KESIMPULAN

Berdasarkan hasil sepuluh kali percobaan yang membandingkan model Pure Deep Feedforward Neural Network (DFNN) dan Artificial Neural Network (ANN) berbasis Backpropagation dalam mengklasifikasikan tingkat keparahan gangguan belitan stator pada motor induksi, dapat disimpulkan bahwa kedua metode mampu mencapai nilai akhir Mean Squared Error (MSE) yang sangat rendah dan mendekati ambang batas 0,0001. Model Pure DFNN menunjukkan potensi konvergensi yang cepat, dengan jumlah iterasi minimum sebesar 294. Namun demikian, model ini juga menunjukkan fluktuasi yang signifikan, dengan jumlah iterasi mencapai 3514 pada salah satu pengujian, sehingga mengindikasikan adanya keterbatasan dalam aspek konsistensi.

Sebaliknya, ANN berbasis Backpropagation menunjukkan stabilitas konvergensi yang lebih baik, dengan seluruh jumlah iterasi berada dalam rentang yang relatif sempit, yaitu antara 226 hingga 449 iterasi. Nilai MSE terbaik yang dicapai oleh ANN Backpropagation adalah 0,000100122, sedangkan Pure DFNN memperoleh nilai yang sedikit lebih tinggi, yaitu 0,000100162. Dengan demikian, ANN berbasis Backpropagation dapat dinyatakan lebih unggul dari aspek stabilitas dan konsistensi konvergensi. Sementara itu, Pure DFNN tetap dapat menjadi pilihan pada skenario tertentu yang membutuhkan

konvergensi lebih cepat, dengan catatan bahwa sensitivitas terhadap kondisi inisialisasi bobot awal perlu dikelola secara memadai.

REFERENSI

- [1] T. Garcia-Calva, D. Morinigo-Sotelo, V. Fernandez-Cavero, and R. Romero-Troncoso, "Early detection of faults in induction motors—A review," *Energies*, vol. 15, no. 21, art. 7855, 2022, doi: 10.3390/en15217855.
- [2] R. R. Kumar, M. Andriollo, G. Cirrincione, M. Cirrincione, and A. Tortella, "A comprehensive review of conventional and intelligence-based approaches for the fault diagnosis and condition monitoring of induction motors," *Energies*, vol. 15, no. 23, art. 8938, 2022, doi: 10.3390/en15238938.
- [3] M. Skowron, T. Orlowska-Kowalska, M. Wolkiewicz, and C. T. Kowalski, "Convolutional neural network-based stator current data-driven incipient stator fault diagnosis of inverter-fed induction motor," *Energies*, vol. 13, no. 6, art. 1475, 2020, doi: 10.3390/en13061475.
- [4] A. M. Hussein, A. A. Obed, R. H. A. Zubo, Y. I. A. Al-Yasir, A. L. Saleh, H. Fadhel, A. Sheikh-Akbari, G. Mokryani, and R. A. Abd-Alhameed, "Detection and diagnosis of stator and rotor electrical faults for three-phase induction motor via wavelet energy approach," *Electronics*, vol. 11, no. 8, art. 1253, 2022, doi: 10.3390/electronics11081253.
- [5] J. Sufrianti and A. Hamzah, "Simulasi dan deteksi gangguan belitan stator motor induksi tiga fasa menggunakan arus starting dengan MATLAB/Simulink," *JOM FTEKNIK*, vol. 4, no. 1, pp. 1–11, Feb. 2017.
- [6] F. I. Huda, I. D. P. K., and B. Y. Dewantara, "Identifikasi gangguan belitan stator motor induksi metode wavelet," in *Prosiding Seminar Nasional Sains dan Teknologi (SNST) ke-10*, Semarang, Indonesia, 2019, pp. 42–47, doi: 10.36499/psnst.v1i1.2901.
- [7] B. J. Irawan, I. D. P. K., B. Y. Dewantara, and D. Rahmatullah, "Klasifikasi hubung singkat turn to turn pada belitan stator motor induksi yang disebabkan kegagalan isolasi menggunakan metode Neural Network (NN)," *Media Elekrika*, vol. 13, no. 1, pp. 1–11, Jun. 2020, doi: 10.26714/me.13.1.2020.1-11.
- [8] G. Priyandoko, "Klasifikasi kerusakan motor induksi menggunakan metode transformasi wavelet diskrit dan K-Nearest Neighbor," *JOINTECS (Journal of Information Technology and Computer Science)*, vol. 6, no. 2, pp. 109–116, May 2021, doi: 10.31328/jointecs.v6i2.2390.
- [9] M. Skowron and T. Orlowska-Kowalska, "Efficiency of cascaded neural networks in detecting initial damage to induction motor electric windings," *Electronics*, vol. 9, no. 8, art. 1314, 2020, doi: 10.3390/electronics9081314.
- [10] C.-Y. Lee, M.-S. Wen, G.-L. Zhuo, and T.-A. Le, "Application of ANN in induction-motor fault-detection system established with MRA and CFFS," *Mathematics*, vol. 10, no. 13, art. 2250, 2022, doi: 10.3390/math10132250.
- [11] A. Dawood, B. M. Hasaneen, and A. M. Abdel-Aziz, "Design of an efficient neural network model for detection and classification of phase loss faults for three-phase induction motor," *Neural Computing and Applications*, vol. 36, pp. 5827–5845, 2024, doi: 10.1007/s00521-023-09387-y.
- [12] M.-C. Kim, J.-H. Lee, D.-H. Wang, and I.-S. Lee, "Induction motor fault diagnosis using support vector machine, neural networks, and boosting methods," *Sensors*, vol. 23, no. 5, art. 2585, 2023, doi: 10.3390/s23052585.
- [13] S. Sobhi, M. Reshadi, N. Zarft, A. Terheide, and S. Dick, "Condition monitoring and fault detection in small induction motors using machine learning algorithms," *Information*, vol. 14, no. 6, art. 329, 2023, doi: 10.3390/info14060329.
- [14] M. Benninger and M. Liebschner, "Optimization of practicality for modeling- and machine learning-based framework for early fault detection of induction motors," *Energies*, vol. 17, no. 15, art. 3723, 2024, doi: 10.3390/en17153723.
- [15] A. O. Louzada, W. A. Souza, A. L. O. Vitor, M. F. Castoldi, and A. Goedtel, "Detection of stator faults in three-phase induction motors using stray flux and machine learning," *Energies*, vol. 18, no. 6, art. 1516, 2025, doi: 10.3390/en18061516.
- [16] G. D. Prenata, L. U. Iskhan, and R. S. Widagdo, "The effect of stator winding resistance reduction on the performance of a three-phase induction motor," *TESLA: Jurnal Teknik Elektro*, vol. 28, no. 1, pp. 40–49, 2026, doi: 10.24912/tesla.v28i1.37752.
- [17] G. D. Prenata, M. A. S. Syariffudin, and R. S. Widagdo, "Application of Fourier transform for early detection of bearing failures in electric motors," *Journal Geuthee of Engineering and Energy*, vol. 5, no. 1, pp. 24–32, May 2026, doi: 10.52626/joge.v5i1.69.
- [18] G. D. Prenata, "Evaluasi metode klasifikasi berbasis jarak dan probabilitas untuk deteksi gangguan stator motor induksi," *Jurnal Elektro Kontrol (ELKON)*, vol. 6, no. 1, 2026, doi: 10.24176/elkon.v6i1.17376.