

COMPARATIVE ANALYSIS OF MOTHER WAVELET FOR VOLTAGE SAG AND SWELL CLASSIFICATION USING DISCRETE WAVELET TRANSFORM (DWT) AND RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

ANALISIS KOMPARATIF *MOTHER WAVELET* UNTUK KLASIFIKASI GANGGUAN *VOLTAGE SAG* DAN *SWELL* MENGUNAKAN *DISCRETE WAVELET TRANSFORM (DWT)* DAN *RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)*

Nurhalim¹, Fera Gustia Handayani^{2*}, Antonius Rajagukguk³, Iswadi Hasyim Rosma⁴, Edy Ervianto⁵

¹Program Studi Teknik Elektro, Fakultas Teknik, Universitas Riau, Indonesia
Email: nurhalimunri@gmail.com

²Program Studi Teknik Elektro, Fakultas Teknik, Universitas Riau, Indonesia
Email: feragustiahandayani07@gmail.com

³Program Studi Teknik Elektro, Fakultas Teknik, Universitas Riau, Indonesia
Email: antonius.rajagukguko@lecturer.unri.ac.id

⁴Program Studi Teknik Elektro, Fakultas Teknik, Universitas Riau, Indonesia
Email: iswadi.hr@lecturer.unri.ac.id

⁵Program Studi Teknik Elektro, Fakultas Teknik, Universitas Riau, Indonesia
Email: edy.ervianto@eng.unri.ac.id

Received: September 25, 2025 Revised: October 24, 2025 Published: October 31, 2025
DOI: <https://doi.org/10.24912/tesla.v27i2.35672>

Abstract

Power quality disturbances, such as voltage sag and swell, can lead to system instability and equipment damage. In this study, identification is defined as the process of detecting the presence and characteristics of these disturbances through time-frequency feature extraction using the Discrete Wavelet Transform (DWT). A Radial Basis Function Neural Network (RBFNN) is then employed as the classification method to determine the specific type of disturbance (sag or swell). The need for an automated identification and classification system arises because manual monitoring is slow and subjective, whereas industrial applications require rapid decisions based on measurable metrics. The disturbance dataset, specifically comprising voltage sag and voltage swell, was generated through modeling and simulation using MATLAB/Simulink. Features were extracted from the disturbance signals by decomposing them up to 7 levels with the DWT, using four different Mother Wavelets: Daubechies-4 (db4), Haar, Symlet-4 (sym4), and Coiflet-4 (coif4). These feature datasets were then normalized and divided into training, validation, and testing sets to train and evaluate the RBFNN model. Performance was assessed based on Mean Squared Error (MSE), classification accuracy, and the confusion matrix as objective success criteria. The results indicate that all models successfully achieved an MSE below 10^{-5} and 100% accuracy on the test data, signifying a very low error rate. The model utilizing the Haar wavelet demonstrated the best training efficiency, requiring the fewest epochs. Therefore, this combination is highly recommended for practical power quality monitoring applications.

Keywords: Discrete Wavelet Transform, Power Quality Disturbances, Radial Basis Function Neural Network, Voltage Sag, Voltage Swell

Abstrak

Gangguan kualitas daya, seperti *Voltage Sag*, dan *Swell*, dapat menyebabkan ketidakstabilan sistem dan kerusakan pada peralatan. Identifikasi pada penelitian ini didefinisikan sebagai proses mendeteksi

ANALISIS KOMPARATIF *MOTHER WAVELET* UNTUK KLASIFIKASI GANGGUAN *VOLTAGE SAG* DAN *SWELL* MENGGUNAKAN *DISCRETE WAVELET TRANSFORM* (DWT) DAN *RADIAL BASIS FUNCTION NEURAL NETWORK* (RBFNN)

keberadaan dan karakteristik gangguan melalui ekstraksi fitur waktu- frekuensi menggunakan *Discrete Wavelet Transform* (DWT) dan *Radial Basis Function Neural Network* (RBFNN) sebagai metode klasifikasi untuk proses menentukan jenis gangguan (*sag* dan *swell*). Kebutuhan akan sistem identifikasi dan klasifikasi otomatis diperlukan karena pemantauan manual bersifat lambat dan subjektif, sementara industri memerlukan keputusan cepat berbasis metrik yang terukur. Dataset gangguan, yang secara spesifik mencakup *Voltage Sag* dan *Voltage Swell*, dihasilkan melalui pemodelan dan simulasi dengan perangkat lunak MATLAB/Simulink. Fitur dari sinyal gangguan ini diekstraksi dari dekomposisi *Discrete Wavelet Transform* (DWT) hingga 7 level, dengan empat variasi *Mother Wavelet* (*Daubechies-4*, Haar, *Symlet-4*, dan *Coiflet-4*). Data fitur tersebut kemudian dinormalisasi dan dibagi menjadi data *training*, *validation* dan *testing*, untuk melatih dan menguji model RBFNN, yang kinerjanya dievaluasi berdasarkan *Mean Squared Error* (MSE), akurasi klasifikasi dan *confusion matrix* sebagai kriteria objektif keberhasilan. Hasil penelitian menunjukkan bahwa semua model berhasil mencapai MSE di bawah 10^{-5} dan akurasi 100% pada data uji, yang mengindikasikan tingkat kesalahan sangat rendah. Model berbasis *wavelet* Haar menunjukkan efisiensi pelatihan terbaik dengan jumlah *epoch* paling sedikit. Oleh karena itu, kombinasi ini sangat direkomendasikan untuk aplikasi pemantauan kualitas daya.

Kata Kunci: Gangguan Kualitas Daya, *Discrete Wavelet Transform*, *Radial Basis Function Neural Network*, *Voltage Sag*, *Voltage Swell*

PENDAHULUAN

Kualitas daya telah menjadi isu krusial dalam sistem tenaga listrik modern, baik dari perspektif industri maupun konsumen. Masalah kualitas daya didefinisikan sebagai setiap deviasi pada tegangan, arus, atau frekuensi yang dapat berdampak negatif pada peralatan pelanggan. *Voltage sag* dan *voltage swell* adalah dua gangguan yang sering ditemukan pada sistem distribusi yang mana dapat menyebabkan operasi peralatan yang tidak efisien dan memperpendek masa pakainya [1]. Oleh karena itu, identifikasi dan klasifikasi gangguan yang akurat menjadi langkah fundamental sebelum mitigasi yang tepat dapat dilakukan.

Teknik pemrosesan sinyal tradisional seperti *Fourier Transform* (FT) sangat efektif untuk menganalisis sinyal stasioner, namun memiliki keterbatasan saat menghadapi gangguan non-stasioner seperti transien [2]. Sebagai alternatif, *Discrete Wavelet Transform* (DWT) menawarkan keunggulan signifikan karena kemampuannya dalam analisis multi-resolusi, yang menyediakan resolusi waktu dan frekuensi yang baik secara bersamaan [3]. Kemampuan DWT untuk mengekstraksi informasi penting dari sinyal gangguan menjadikannya alat yang ampuh untuk identifikasi kualitas daya.

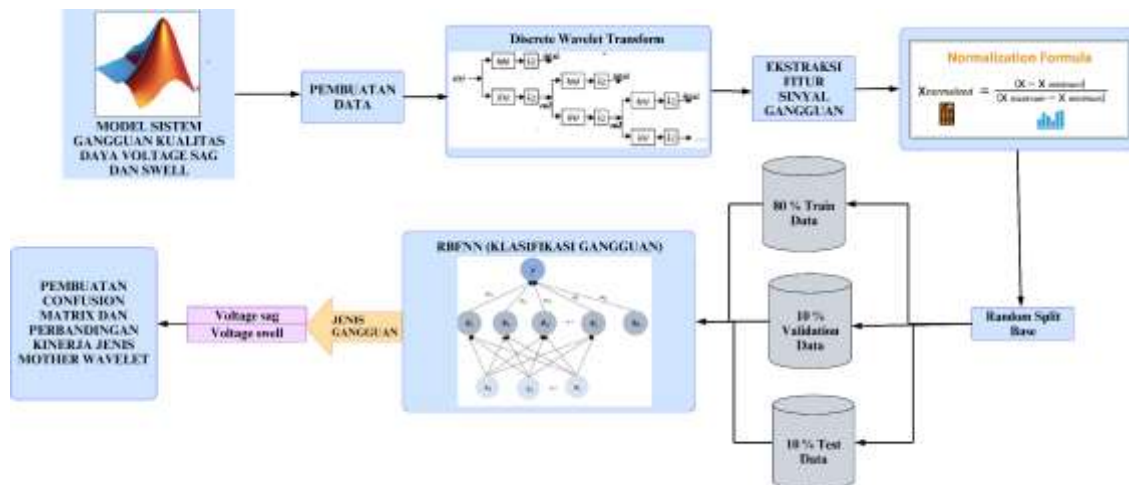
Setelah fitur-fitur sinyal diekstraksi, diperlukan metode klasifikasi yang cerdas untuk mengidentifikasi jenis gangguan secara otomatis. *Artificial Neural Network* (ANN) telah banyak digunakan untuk tugas ini. Salah satu pengembangan ANN yang efisien adalah *Radial Basis Function Neural Network* (RBFNN), yang dikenal memiliki kemampuan adaptasi, pengenalan pola, dan kecepatan komputasi yang lebih baik [4]. Kombinasi DWT untuk ekstraksi fitur dan RBFNN untuk klasifikasi telah menunjukkan potensi besar dalam meningkatkan akurasi dan efisiensi pemantauan kualitas daya [5]. Meskipun beberapa penelitian sebelumnya menunjukkan keberhasilan metode DWT dan ANN dengan akurasi di atas 90% [2, 6-8]. Analisis mendalam mengenai dampak pemilihan jenis *mother wavelet* terhadap kinerja klasifikasi masih jarang dibahas secara komprehensif. Pemilihan *mother wavelet* yang optimal dapat meningkatkan efisiensi dan

akurasi ekstraksi fitur.

Oleh karena itu, penelitian ini berfokus pada perbandingan kinerja empat jenis *mother wavelet* yang berbeda (Haar, *Coiflet-4*, *Symlet-4*, dan *Daubechies-4*) untuk sistem klasifikasi yang mengintegrasikan DWT dan RBFNN, serta evaluasi. Evaluasi ini bertujuan untuk menentukan konfigurasi optimal yang tidak hanya memberikan akurasi klasifikasi tertinggi tetapi juga efisiensi komputasi terbaik untuk gangguan *Voltage Sag* dan *Swell*.

METODOLOGI PENELITIAN

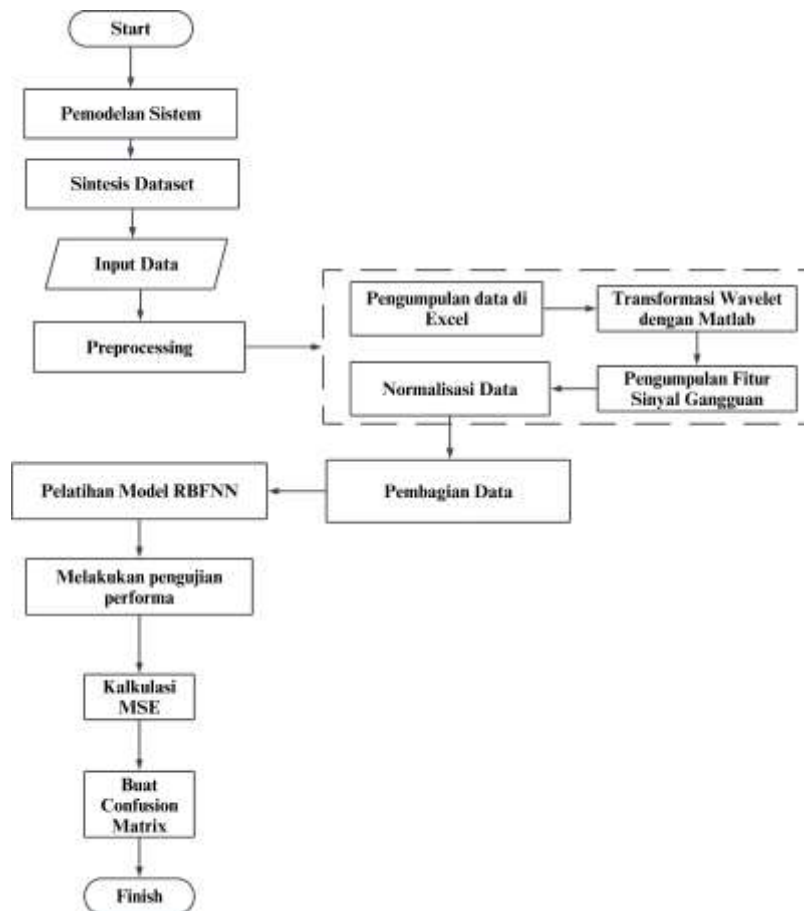
Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis yang digambarkan dalam Gambar 1. Proses dimulai dari pemodelan sinyal gangguan, ekstraksi fitur, hingga pelatihan dan evaluasi model RBFNN.



Gambar 1. Blok Diagram Alur Sistem Klasifikasi Gangguan

Diagram tersebut menunjukkan alur metodologi penelitian untuk klasifikasi gangguan kualitas daya berupa *voltage sag* dan *voltage swell* menggunakan *Radial Basis Function Neural Network* (RBFNN) berbasis transformasi *wavelet* diskrit (DWT). Proses dimulai dengan pembuatan model sistem gangguan guna menghasilkan data sinyal, yang kemudian dianalisis menggunakan transformasi *wavelet* untuk memperoleh representasi waktu dan frekuensi. Hasil transformasi digunakan dalam ekstraksi fitur sinyal gangguan, diikuti dengan normalisasi min-max agar fitur memiliki skala yang seragam. Data yang telah dinormalisasi dibagi menjadi 80% data pelatihan, 10% validasi, dan 10% pengujian. Selanjutnya, RBFNN digunakan untuk mengklasifikasikan jenis gangguan, sedangkan *confusion matrix* dan perbandingan jenis *mother wavelet* digunakan untuk mengevaluasi kinerja sistem klasifikasi.

ANALISIS KOMPARATIF *MOTHER WAVELET* UNTUK KLASIFIKASI GANGGUAN *VOLTAGE SAG* DAN *SWELL* MENGGUNAKAN *DISCRETE WAVELET TRANSFORM* (DWT) DAN *RADIAL BASIS FUNCTION NEURAL NETWORK* (RBFNN)



Gambar 2. Flowchart Penelitian

Alur kerja dimulai dari pemodelan sistem untuk menyintesis dataset sinyal gangguan *voltage sag* atau *voltage swell*, dilanjutkan input dan *preprocessing*, kemudian sinyal didekomposisikan dengan DWT hingga level-7 di MATLAB, diambil fitur statistik yaitu energi, RMS, *mean*, standar deviasi, *skewness*, kurtosis, entropi, yang bisa direkap ke Excel atau CSV, setelah itu fitur dinormalisasi (0–1) dan data dibagi menjadi data *training*, *validation*, dan *testing* (80%,10% dan 10%), model RBFNN lalu dilatih (penyetelan *center* atau *Spread*, dan target MSE) untuk mengklasifikasikan jenis gangguan, dan kinerjanya dievaluasi pada data uji memakai akurasi serta *confusion matrix*, sebelum akhirnya hasil antar *mother wavelet* dibandingkan untuk menarik kesimpulan.

A. Pemodelan Sinyal Gangguan Kualitas Daya

Dua jenis gangguan kualitas daya utama dimodelkan dan disimulasikan menggunakan MATLAB/Simulink untuk menghasilkan dataset sintesis dengan tegangan 20 kV dan frekuensi 50 Hz. Jenis gangguan yang dimodelkan adalah:

1. **Voltage Sag:** Dihasilkan dengan menyimulasikan gangguan hubung singkat tiga fasa pada sistem distribusi.
2. **Voltage Swell:** Dihasilkan melalui simulasi pelepasan beban besar secara tiba-tiba.

Seluruh sinyal gangguan dihasilkan tanpa adanya derau (*noise*). Total sampel data yang dihasilkan yaitu 600 sampel, yang terdiri dari 300 sampel untuk masing-masing jenis gangguan kualitas daya. Data sinyal dari hasil simulasi ini kemudian disimpan untuk diproses lebih lanjut.

B. Ekstraksi Fitur Menggunakan *Discrete Wavelet Transform* (DWT)

Sinyal gangguan yang telah dihasilkan kemudian diproses untuk mengekstraksi fitur-fitur penting yang membedakan setiap jenis gangguan. Setiap sinyal gangguan didekomposisi menggunakan DWT hingga 7 level untuk memastikan fitur pada frekuensi rendah yang menjadi ciri khas *sag* dan *swell* dapat ditangkap dengan baik, sesuai dengan praktik umum dalam analisis kualitas daya. Empat jenis *mother wavelet* yang berbeda digunakan untuk analisis komparatif, yaitu *Daubechies-4* (dB4), Haar, *Coiflet-4* (Coif4), dan *Symlet-4* (Sym4). Proses ini, yang didasarkan pada dekomposisi multi-resolusi [9], menghasilkan koefisien detail (cD) untuk setiap level dan koefisien aproksimasi (cA) pada level terakhir.

Dari koefisien *wavelet* yang diperoleh, serangkaian fitur statistik dihitung untuk merepresentasikan karakteristik sinyal secara kuantitatif. Fitur-fitur ini meliputi Energi, Standar Deviasi, Nilai Minimum, Nilai Maksimum, Rata-rata (*Mean*), *Root Mean Square* (RMS), *Skewness*, Kurtosis, dan Entropi Shannon [10].

C. Normalisasi Data

Seluruh fitur dinormalisasi Min–Max ke [0,1] menggunakan statistik yang dihitung hanya dari data latih guna mencegah data *leakage*. *Min–Max* dipilih karena menjaga skala seragam.

D. Pembagian Data

Setelah dilakukan normalisasi fitur, dataset fitur dibagi menjadi tiga bagian menggunakan metode *random split based on ratio* dimana 80% untuk data latih (*training*), 10% untuk data validasi, dan 10% untuk data uji (*testing*). Pengacakan memakai *seed* tetap untuk replikasi. Data uji ditahan ketat dan hanya dipakai sekali di akhir, sedangkan data validasi digunakan untuk pemilihan hiperparameter (penyetelan *center* atau *spread* RBF, dan target MSE) dan *early stopping*. Dengan *database* sebagai berikut :

Tabel 1. Pembagian Data untuk RBFNN

Bagian	Jumlah
<i>Training</i>	480
<i>Validation</i>	60
<i>Testing</i>	60

E. Klasifikasi Menggunakan RBFNN

Vektor fitur yang telah diekstraksi dan dinormalisasi digunakan untuk melatih dan menguji model RBFNN. [11]. Model RBFNN dilatih menggunakan data latih dengan target *Mean Squared Error* (MSE) $\leq 10^{-5}$. RBFNN dipilih karena komputasinya yang lebih cepat dan arsitekturnya yang efektif [13, 14]. Kinerja model dievaluasi berdasarkan akurasi klasifikasi pada data uji dan dianalisis menggunakan *confusion matrix*.

ANALISIS KOMPARATIF *MOTHER WAVELET* UNTUK KLASIFIKASI GANGGUAN *VOLTAGE SAG* DAN *SWELL* MENGGUNAKAN *DISCRETE WAVELET TRANSFORM* (DWT) DAN *RADIAL BASIS FUNCTION NEURAL NETWORK* (RBFNN)

HASIL DAN DISKUSI

A. Kinerja Pelatihan RBFNN

Proses pelatihan dilakukan untuk setiap model RBFNN yang menggunakan fitur dari empat *mother wavelet* berbeda. Semua model berhasil mencapai target konvergensi dengan nilai MSE di bawah 10^{-5} , yang mengindikasikan bahwa fitur yang diekstraksi mampu dipelajari dengan baik oleh jaringan. Tabel 2 merangkum kinerja pelatihan dari setiap model.

Tabel 2. Ringkasan Kinerja Pelatihan Model RBFNN

Jenis <i>Mother Wavelet</i>	MSE	Jumlah <i>Epoch</i>
Haar	1,59332e-06	253
Coif4	1,05594e-06	305
Sym4	3,15445e-06	328
dB4	3,99394e-06	332

Pelatihan bertujuan untuk meminimalkan *mean squared error* (MSE) hingga di bawah ambang 10^{-5} . Keempat model masing-masing memanfaatkan fitur DWT dari *mother wavelet* Haar, Coif4, Sym4, dan dB4 seluruhnya memenuhi kriteria tersebut, menandakan bahwa representasi fitur yang dipelajari sudah memadai. Ringkasnya, Haar mencapai MSE 1,59332e-06 dalam 253 *epoch*, Coif4 mencapai MSE terendah 1,05594e-06 dalam 305 *epoch*, Sym4 mencapai 3,15445e-06 dalam 328 *epoch*, dan dB4 mencapai 3,99394e-06 dalam 332 *epoch*. Meskipun MSE akhir berbeda secara numerik, seluruhnya berada jauh di bawah 10^{-5} , yang secara praktis menunjukkan bahwa kapasitas representasi jaringan terhadap fitur DWT telah cukup untuk klasifikasi.

B. Analisis Kinerja Generalisasi dan Klasifikasi

Karena seluruh model pada pelatihan telah menuntaskan pelatihan hingga galat yang sangat rendah, evaluasi selanjutnya menilai apakah variasi dinamika pelatihan tersebut berimbas pada performa di data baru. Kemampuan generalisasi model, yaitu performanya pada data yang belum pernah dilihat, merupakan tolak ukur utama keberhasilan. Tabel 3 menyajikan rekapitulasi akurasi klasifikasi pada data validasi dan data uji untuk setiap *mother wavelet*.

Tabel 3. Rekapitulasi Akurasi Generalisasi Model RBFNN

Jenis <i>Mother Wavelet</i>	Akurasi Validasi	Akurasi Pengujian
Haar	100%	100%
Coif4	100%	100%
Sym4	100%	100%
dB4	100%	100%

Berdasarkan hasil pada data uji, keempat jenis *mother wavelet* menunjukkan kinerja generalisasi yang sempurna dengan mencapai akurasi sempurna 100%, menandakan tidak ada satupun kesalahan klasifikasi.



Gambar 3. *Confusion Matrix* Data Uji *Mother Wavelet* (Haar kiri atas, Coif4 kanan atas, Sym4 kiri bawah, dan dB4 kanan bawah)

Gambar 3 menampilkan empat *confusion matrix* yang merupakan hasil pengujian sebuah model klasifikasi untuk gangguan kualitas daya, yaitu *Sag* (penurunan tegangan) dan *Swell* (kenaikan tegangan). Setiap matriks merepresentasikan pengujian yang menggunakan *mother wavelet* yang berbeda untuk ekstraksi fitur, yaitu Haar (kiri atas), Coif4 (kanan atas), Sym4 (kiri bawah), dan dB4 (kanan bawah). Hal yang paling menonjol dari keempatnya adalah semua menunjukkan akurasi sempurna 100%. Ini berarti model berhasil menebak dengan benar setiap data uji tanpa ada satu pun kesalahan. Pada setiap matriks, semua sampel data berada pada kotak diagonal (kiri atas ke kanan bawah), yang menandakan bahwa kelas prediksi sepenuhnya sesuai dengan kelas sebenarnya. Sebagai contoh, pada pengujian menggunakan wavelet Haar, 29 data *Sag* berhasil diprediksi sebagai *Sag* dan 31 data *Swell* berhasil diprediksi sebagai *Swell*. Hasil yang konsisten ini menunjukkan bahwa keempat jenis *mother wavelet* tersebut sama-sama efektif dalam mengekstrak fitur pembeda antara gangguan *Sag* dan *Swell* untuk dataset yang diuji.

Konsistensi ini menunjukkan bahwa separabilitas fitur hasil DWT untuk membedakan *Sag* dan *Swell* sangat tinggi; begitu jaringan mencapai tingkat pembelajaran yang memadai (pelatihan), kemampuan generalisasi menjadi jenuh (saturated) sehingga perbedaan kecil pada MSE akhir atau jumlah epoch tidak lagi diterjemahkan menjadi perbedaan akurasi. Implikasinya, pemilihan *mother wavelet* dapat disesuaikan dengan tujuan praktis: Haar diprioritaskan bila efisiensi pelatihan penting, sedangkan Coif4 dipilih bila menginginkan fit pelatihan paling rapat keduanya, sebagaimana Sym4 dan dB4 setara dalam generalisasi pada dataset ini.

Analisis komparatif menunjukkan bahwa keempat jenis *mother wavelet* (Haar, Coif4, Sym4, dan dB4) memiliki kemampuan generalisasi yang sempurna pada data uji, di mana semuanya berhasil mencapai akurasi klasifikasi 100%. Ini menandakan bahwa tidak ada satupun kesalahan klasifikasi yang terjadi pada data yang belum pernah dilihat sebelumnya oleh model, sehingga membuktikan keandalan pendekatan yang digunakan.

Meskipun hasil akurasi akhirnya identik, terdapat perbedaan minor dalam kinerja pelatihan:

- Efisiensi Pelatihan: Model yang menggunakan fitur dari *wavelet* Haar menunjukkan efisiensi konvergensi terbaik, karena hanya memerlukan 253 *epoch* untuk mencapai target MSE, jumlah iterasi paling sedikit di antara keempat model.

ANALISIS KOMPARATIF *MOTHER WAVELET* UNTUK KLASIFIKASI GANGGUAN *VOLTAGE SAG* DAN *SWELL* MENGGUNAKAN *DISCRETE WAVELET TRANSFORM* (DWT) DAN *RADIAL BASIS FUNCTION NEURAL NETWORK* (RBFNN)

- Tingkat Kesalahan Pelatihan: Model berbasis Coif4 berhasil mencapai nilai MSE pelatihan terendah ($1,05594e-06$), yang mengindikasikan model ini paling sesuai dengan data latih.

Meskipun ada perbedaan dalam efisiensi komputasi dan tingkat error pelatihan, hasil akhir pada data uji yang seragam menunjukkan bahwa metode ekstraksi fitur DWT secara umum sangat kuat dan mampu menghasilkan fitur-fitur yang representatif untuk diklasifikasikan oleh RBFNN, terlepas dari jenis *mother wavelet* yang digunakan dalam penelitian ini.

KESIMPULAN

Penelitian ini berhasil mengevaluasi sistem klasifikasi gangguan kualitas daya (*Voltage Sag* dan *Swell*) menggunakan kombinasi DWT dan RBFNN. Berdasarkan analisis komparatif, disimpulkan bahwa keempat *mother wavelet* yang diuji (Haar, Coif4, Sym4, dan dB4) mampu menghasilkan fitur yang sangat representatif, yang terbukti dengan pencapaian akurasi klasifikasi 100% pada data uji oleh semua model. Meskipun semua model memiliki akurasi yang sempurna, model yang menggunakan fitur dari *wavelet* Haar menunjukkan efisiensi pelatihan terbaik, karena mencapai target konvergensi dengan jumlah *epoch* paling sedikit (253). Oleh karena itu, untuk aplikasi yang mempertimbangkan kecepatan komputasi, konfigurasi DWT-Haar dan RBFNN direkomendasikan.

DAFTAR PUSTAKA

- [1] F. Z. Dekhandji, Detection of power quality disturbances using discrete wavelet transform, 2017 6th International Conference on Systems and Control (ICSC) (2017).
- [2] H. Jain and S. K. Gawre, Detection and classification of current interruptions and transients by using wavelet transform and neural network, 2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT) (2016).
- [3] S. Alshahrani, M. Abbod, B. Alamri, and G. Taylor, Evaluation and classification of power quality disturbances based on discrete wavelet transform and artificial neural networks, 2015 International Conference on Smart Grid and Clean Energy Technologies (ICSGCE) (2015).
- [4] V. Wahyuningrum, Penerapan radial basis function neural network dalam pengklasifikasian daerah tertinggal di Indonesia, Jurnal Aplikasi Statistika & Komputasi Statistik, 12 (1) (2020), 37.
- [5] I. G. D. Arjana, Identifikasi penurunan kualitas daya pada penyulang menggunakan kombinasi transformasi wavelet dan neural network, Majalah Ilmiah Teknologi Elektro, 9 (1) (2010).
- [6] A. K. Sharma, O. P. Mahela, and S. R. Ola, Detection of power quality disturbances using discrete wavelet transform, 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES) (2016).

- [7] P. Patil, K. Muley, and R. Agrawal, Identification of power quality disturbance using neural network, 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI) (2019).
- [8] A. A. Aryaguna, D. O. Anggriawan, and T. Elektro Industri, Identifikasi jenis gangguan pada jaringan distribusi menggunakan metode artificial neural network, Jurnal Inovtek Seri Elektro, 3 (1) (2021).
- [9] S. G. Mallat, A theory for multiresolution signal decomposition: The wavelet representation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 11 (7) (1989).
- [10] J. Mathew, N. Sivakumaran, and P. A. Karthick, Automated detection of seizure types from the higher-order moments of maximal overlap wavelet distribution, Diagnostics, 13 (4) (2023).
- [11] A. Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, O'Reilly Media, Inc. (2019).
- [12] X. Liu, N. Li, S. Liu, J. Wang, N. Zhang, X. Zheng, K.-S. Leung, and L. Cheng, Normalization methods for the analysis of unbalanced transcriptome data: A review, Frontiers in Bioengineering and Biotechnology, 7 (2019).
- [13] M. Madhiarasan, Accurate prediction of different forecast horizons wind speed using a recursive radial basis function neural network, Protection and Control of Modern Power Systems, 5 (1) (2020), 22.
- [14] I. Kopal, M. Harničárová, J. Valíček, J. Krmela, and O. Lukáč, Radial basis function neural network-based modeling of the dynamic thermo-mechanical response and damping behavior of thermoplastic elastomer systems, Polymers, 11 (6) (2019), 1074.