

PERAMALAN BEBAN JANGKA PENDEK DENGAN METODE BACKPROPAGATION NEURAL NETWORK PADA TRANSFORMATOR 150 kV GARDU INDUK WARU PT. PLN (Persero) BERDASARKAN FAKTOR BEBAN**Andika Pratama¹, Unit Three Kartini², Subuh Isnur Haryudo³, Tri Rijanto⁴**

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya

Email : andika.21024@mhs.unesa.ac.id, unitthree@unesa.ac.id, subuhisnur@unesa.ac.id, tririjanto@unesa.ac.id**Abstract (English)**

Short-term electricity load forecasting is a critical aspect of power system management to prevent overloading of transformers, which can lead to decreased efficiency and equipment damage. This study aims to develop a short-term load prediction model using the Backpropagation Neural Network (BPNN) method for a 150 kV transformer at the Waru Substation of PT PLN (Persero), taking into account the load factor. The data used includes active power, reactive power, current, and load factor, recorded every 30 minutes during the period of December 1–7, 2024. The modeling was conducted using a single hidden layer neural network architecture consisting of five neurons and trained using the Levenberg-Marquardt algorithm with 250 epochs. Simulation results show that the BPNN model is capable of delivering high prediction accuracy, with a Mean Absolute Percentage Error (MAPE) of 1.48% and a Mean Squared Error (MSE) of 0.0612. These findings indicate that BPNN is effective for short-term load forecasting and can be implemented as a decision-support tool in power system planning.

Article History

Submitted: 9 Juni 2025

Accepted: 12 Juni 2025

Published: 13 Juni 2025

Key Words

short term load forecasting, BPNN, artificial neural network, 150 kV transformer, load factor, PLN

Abstrak (Indonesia)

Peramalan beban listrik jangka pendek menjadi aspek penting dalam pengelolaan sistem tenaga listrik untuk menghindari beban lebih pada transformator yang dapat menyebabkan penurunan efisiensi hingga kerusakan peralatan. Penelitian ini bertujuan untuk mengembangkan model prediksi beban jangka pendek menggunakan metode *Backpropagation Neural Network* (BPNN) pada transformator 150 kV di Gardu Induk Waru, PT PLN (Persero), dengan mempertimbangkan faktor beban. Data yang digunakan mencakup daya aktif, daya reaktif, arus, dan faktor beban yang dicatat setiap 30 menit selama periode 1–7 Desember 2024. Pemodelan dilakukan dengan arsitektur jaringan saraf tiruan satu hidden layer yang terdiri dari lima neuron dan dilatih menggunakan algoritma *Levenberg-Marquardt* dengan 250 epoch. Hasil simulasi menunjukkan bahwa model BPNN mampu memberikan akurasi prediksi tinggi dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1,48% dan *Mean Squared Error* (MSE) sebesar 0,0612. Temuan ini menunjukkan bahwa BPNN efektif dalam melakukan peramalan beban jangka pendek dan dapat diimplementasikan sebagai alat bantu pengambilan keputusan dalam perencanaan sistem tenaga listrik.

Sejarah Artikel

Submitted: 9 Juni 2025

Accepted: 12 Juni 2025

Published: 13 Juni 2025

Kata Kunci

peramalan beban jangka pendek, BPNN, jaringan saraf tiruan, transformator 150 kV, faktor beban, PLN.

PENDAHULUAN

Energi listrik merupakan kebutuhan utama dalam kehidupan modern yang sangat berpengaruh terhadap pembangunan ekonomi dan peningkatan kualitas hidup masyarakat. PT PLN (Persero) sebagai penyedia tunggal listrik di Indonesia memiliki tanggung jawab untuk menjamin ketersediaan pasokan listrik yang andal. Permintaan beban listrik yang terus meningkat akibat pertumbuhan penduduk dan industrialisasi menuntut perencanaan dan pengelolaan sistem tenaga yang akurat, termasuk prediksi beban trafo di gardu induk [1], [2].

Peramalan beban listrik menjadi aspek penting dalam pengelolaan sistem kelistrikan karena dapat membantu PLN mempersiapkan kapasitas transformator yang sesuai untuk masa depan. Peramalan yang tidak akurat dapat menyebabkan kelebihan beban pada trafo, penurunan kualitas layanan, serta kerugian ekonomi akibat pemborosan daya atau gangguan pasokan [3-

5].

Peramalan beban listrik jangka pendek (*short-term load forecasting*) berfungsi untuk mengatur jadwal pembangkitan, memantau tegangan, serta merencanakan pengoperasian sistem distribusi secara efisien. STLF sangat sensitif terhadap faktor-faktor seperti cuaca, waktu, dan jenis konsumen sehingga dibutuhkan pendekatan yang mampu mengakomodasi kompleksitas ini [6-8].

Salah satu metode yang telah terbukti efektif untuk peramalan beban adalah Jaringan Saraf Tiruan (JST) dengan algoritma *Backpropagation*. Metode ini mampu melakukan pembelajaran terhadap pola historis beban dan memberikan hasil yang akurat bahkan dalam kondisi non-linear dan nonstasioner [9], [10].

Karakteristik data beban listrik yang cenderung non-linear dan memiliki komponen musiman serta noise, membuat metode tradisional seperti ARIMA kurang optimal. JST, khususnya *backpropagation*, menunjukkan performa lebih baik dalam menangkap pola kompleks melalui proses pelatihan berbasis bobot jaringan [8], [11], [12].

Dalam berbagai penelitian, JST *Backpropagation* telah diuji dengan berbagai arsitektur dan fungsi aktivasi. Pemilihan jumlah node dan *hidden layer* yang tepat dapat memberikan tingkat akurasi yang tinggi. Sebagai contoh, arsitektur 29-50-1 menunjukkan akurasi 87,50% dalam memprediksi beban transformator harian [1], [13], [14].

Akurasi model peramalan biasanya diukur menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Semakin kecil nilai MAPE, semakin baik model tersebut dalam memprediksi beban. Dalam banyak studi, JST menunjukkan nilai MAPE di bawah 5% untuk prediksi jangka pendek yang efektif [15], [16].


Penggunaan JST *Backpropagation* dalam sistem PLN telah diuji di beberapa unit pelaksana seperti di UP3 Pematang Siantar dan terbukti memberikan hasil prediksi yang mendekati nilai aktual. Hal ini menunjukkan potensi besar penerapan metode serupa pada Gardu Induk Waru, terutama dengan mempertimbangkan beban trafo 150 kV sebagai objek penelitian [1].

Penelitian ini akan berkontribusi dalam pengembangan metode peramalan beban jangka pendek di lingkungan PT PLN (Persero), khususnya pada Gardu Induk Waru. Dengan menggunakan metode JST *Backpropagation* yang berbasis data historis dan faktor beban, penelitian ini diharapkan dapat membantu pengambilan keputusan teknis yang lebih efisien dan terukur dalam perencanaan sistem distribusi listrik di masa mendatang.

METODE


Peramalan beban listrik dengan metode *Backpropagation* merupakan pendekatan berbasis kecerdasan buatan (*Artificial Intelligence*) yang digunakan untuk memprediksi kebutuhan daya listrik pada waktu tertentu di masa depan. Metode ini termasuk dalam jaringan saraf tiruan (*Neural Network*), tepatnya jenis *Multilayer Perceptron* (MLP), yang dilatih menggunakan algoritma *Backpropagation*.

Penelitian ini melibatkan beberapa tahapan, diantaranya adalah melakukan kajian literatur dari beberapa penelitian sebelumnya, pengumpulan data yang relevan untuk mendukung penelitian yang dilakukan, melakukan analisa data dan perhitungan menggunakan metode yang telah ditentukan, menganalisis hasil percobaan yang telah dilakukan, serta menyusun laporan akhir. Tahapan-tahapan tersebut diantaranya dapat dilihat pada gambar 1.



Gambar 1 Flowchart penelitian

BPNN akan digunakan untuk membaca dari data-data yang sudah dikumpulkan menjadi sebuah ramalan beban pada transformator dengan jangka periode waktu tertentu. Untuk pemrograman dalam permodelan BPNN ini dilaksanakan dengan menggunakan software Matlab, Skema pemodelan BPNN dapat dilihat di gambar 2.



Gambar 2 Flowchart metode BPNN

Proses peramalan beban listrik dengan metode *Backpropagation* diawali dengan memasukkan data historis beban listrik sebagai input (X. Data ini kemudian melalui tahap

praproses, yang meliputi normalisasi untuk menyesuaikan skala data (biasanya ke dalam rentang 0–1), pembagian data menjadi data latih dan data uji, serta penyusunan format input dan target agar sesuai dengan struktur jaringan saraf tiruan. Setelah itu, data yang telah diproses digunakan dalam tahap pelatihan (*training*) jaringan saraf tiruan menggunakan algoritma *backpropagation*. Pada tahap ini, bobot dan bias jaringan disesuaikan secara iteratif untuk meminimalkan *error* antara *output* prediksi dan target sebenarnya.

Perambatan maju dimulai dengan memberikan pola *input* ke *input layer*. Pola ini merupakan nilai aktivasi unit-unit input. Dengan melakukan perambatan maju dihitung nilai aktivasi pada unit-unit pada layer selanjutnya. Pada setiap layer, tiap unit pengolah melakukan penjumlahan berbobot dan menerapkan fungsi sigmoid untuk menghitung keluarannya.

Langkah-langkah algoritma Pelatihan Backpropagation adalah sebagai berikut:

Langkah 0: Inisialisasi bobot-bobot.

Langkah 1: Bila syarat berhenti adalah salah, kerjakan langkah 2 sampai 9.

Langkah 2: Untuk setiap data training, kerjakan langkah 3 sampai 8.

Feed Forward:

Langkah 3: Tiap unit input ($x_i, i=1, \dots, n$) menerima isyarat input x_i dan diteruskan ke unit-unit tersembunyi.

Langkah 4: Tiap unit tersembunyi ($z_j, j=1, \dots, p$) menjumlahkan isyarat masukan berbobot;

$$z_in_j = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

dengan menerapkan fungsi aktivasi hitung:

$$z_j = f(z_in_j) \quad (2)$$

dan mengirim sinyal ke unit output.

Langkah 5: Tiap unit output ($y_k, k=1, \dots, m$) menjumlahkan isyarat input berbobot,

$$y_in_k = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (3)$$

dengan menerapkan fungsi aktivasi hitung,

$$y_k = f(y_in_k) \quad (4)$$

Backpropagation Error:

Langkah 6: Tiap unit output ($y_k, k=1, \dots, m$) menerima pola sasaran berkaitan dengan pola pelatihan input.

Hitung error:

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad (5)$$

Faktor δ_k digunakan untuk menghitung koreksi error (Δw_{jk}) yang nantinya akan dipakai untuk memperbaiki w_{jk} . Selain itu juga dihitung koreksi bias (Δw_{ok}) yang nantinya akan dipakai untuk memperbaiki w_{ok} .

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (6)$$

$$\Delta w_{ok} = \alpha \delta_k \quad (7)$$

Langkah 7: Tiap unit tersembunyi ($z_j, j=1, \dots, p$) menjumlahkan input delta (dari langkah ke-6).

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (8)$$

Kemudian hasilnya dikalikan dengan turunan dari fungsi aktivasi yang digunakan untuk menghitung informasi kesalahan error δ_j dimana :

$$\delta_j = \delta_in_j f'(z_in_j) \quad (9)$$

Hitung koreksi bobot:

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (10)$$

Hitung koreksi bias:

$$\Delta v_{oj} = \alpha \delta_j \quad (11)$$

Langkah 8: Tiap unit output ($y_k, k=1, \dots, m$) memperbaiki bobot dan bias dari setiap unit tersembunyi ($j=0, \dots, p$)

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (12)$$

Tiap unit tersembunyi ($z_j, j=1, \dots, p$) memperbaharui bobot dan biasnya ($I=0, 1, \dots, n$)

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (13)$$

Langkah 9: Uji syarat berhenti.

Keterangan:

$x_1 \dots x_n$ = input

$y_1 \dots y_n$ = output

$z_1 \dots z_n$ = hidden layer

v_{ij} = bobot antara input layer dan hidden layer

w_{jk} = bobot antara hidden layer dan output layer

z_{in_j} = hasil pengolahan data di lapisan tersembunyi

z_j = sinyal luaran unit tersembunyi

f = fungsi aktivasi

y_{in_k} = hasil pengolahan data di lapisan output

y_k = sinyal output pembelajaran

t_k = sinyal referensi

δ = sinyal error


α = laju pembelajaran

Setelah pelatihan, dilakukan pengujian terhadap data untuk memeriksa apakah jumlah iterasi atau *epoch* yang ditentukan telah terpenuhi. Jika belum, proses pelatihan akan diulang. Jika *epoch* sudah terpenuhi, maka jaringan dievaluasi menggunakan nilai *Mean Squared Error* (MSE) untuk mengukur tingkat kesalahan prediksi. Apabila nilai MSE masih lebih besar dari batas yang ditetapkan (misalnya 0.05), maka proses pelatihan akan kembali dijalankan untuk meningkatkan akurasi model. Namun, jika nilai MSE sudah berada di bawah ambang batas, maka jaringan dianggap telah memiliki performa yang baik. Tahap berikutnya adalah menghasilkan hasil prediksi beban listrik berdasarkan jaringan yang telah dilatih. Setelah hasil prediksi diperoleh, proses peramalan dinyatakan selesai.

HASIL DAN PEMBAHASAN


Data Preparation

Penelitian ini menggunakan data total konsumsi beban listrik pada Transformator 6 Gardu Induk 150 kV Waru sebagai data inputan, yang kemudian juga digunakan sebagai variabel input untuk mendapat output hasil peramalan.




Gambar 3 Grafik data aktual daya aktif (MW)

Gambar 3 menunjukkan grafik data beban (MW) selama periode 1 hingga 7 Desember 2024 menunjukkan fluktuasi beban listrik setiap 30 menit dalam kurun waktu satu minggu. Dari data tersebut, terlihat pola harian yang konsisten di mana beban cenderung meningkat pada siang hingga malam hari dan menurun pada dini hari. Beban puncak tercatat sebesar 16,22 MW, menandakan titik konsumsi energi tertinggi selama periode tersebut. Sementara itu, beban minimum tercatat sebesar 8,99 MW, yang umumnya terjadi pada jam-jam dengan aktivitas rendah, seperti tengah malam hingga pagi hari. Pola ini menggambarkan karakteristik konsumsi listrik yang dinamis, dipengaruhi oleh kebutuhan operasional dan aktivitas pengguna selama satu minggu.



Gambar 4 Grafik data aktual daya reaktif (MVA)


Gambar 4 menunjukkan grafik data daya reaktif (MVA) selama periode 1 hingga 7 Desember 2024 menampilkan variasi nilai daya reaktif setiap 30 menit dalam rentang waktu satu minggu. Dari grafik tersebut, terlihat adanya fluktuasi yang cukup konsisten, mencerminkan perubahan beban induktif dan kapasitif yang terjadi seiring dengan aktivitas sistem tenaga listrik. Daya reaktif puncak tercatat sebesar 5,56 MVA, menunjukkan kondisi tertinggi di mana sistem memerlukan kompensasi daya reaktif terbesar untuk menjaga kestabilan tegangan. Sementara itu, nilai daya reaktif minimum berada pada angka 2,95 MVA, yang umumnya terjadi saat beban sistem sedang rendah. Pola ini menunjukkan pentingnya pengelolaan daya reaktif secara real-time untuk menjaga kualitas daya dan efisiensi sistem tenaga listrik selama periode operasional harian.



Gambar 5 Grafik data aktual arus (Ampere)

Gambar 5 menunjukkan grafik data arus (Ampere) selama periode 1 hingga 7 Desember 2024 menunjukkan pola fluktuasi arus listrik setiap 30 menit dalam rentang waktu satu minggu. Nilai arus tertinggi atau arus puncak tercatat sebesar 485,03 Ampere, yang mencerminkan saat-saat beban sistem berada pada titik tertingginya. Sebaliknya, arus minimum tercatat sebesar 269,27 Ampere, umumnya terjadi pada jam-jam dengan aktivitas beban rendah. Pola arus ini

sejalan dengan variasi beban listrik harian, di mana arus meningkat seiring dengan naiknya permintaan energi dan menurun saat konsumsi berkurang. Fluktuasi arus yang terlihat pada grafik menggambarkan respons sistem terhadap perubahan beban, serta pentingnya pemantauan arus secara berkala untuk menjaga keandalan dan keselamatan operasi sistem tenaga listrik.



Gambar 6 Grafik data aktual faktor beban (p.u)

Grafik faktor beban (per unit) yang ditampilkan merupakan data konstan yang dihitung berdasarkan data beban aktif (MW) selama periode 1 hingga 7 Desember 2024. Nilai faktor beban ini tidak menunjukkan pola fluktuasi, melainkan digunakan sebagai input tetap (konstan) dalam setiap sampel data beban (MW) yang diambil setiap 30 menit. Dengan memasukkan nilai faktor daya yang telah dihitung secara konsisten ke dalam model, proses peramalan beban dapat mempertimbangkan efisiensi penggunaan energi listrik dalam sistem. Meskipun faktor daya tidak berubah-ubah sepanjang periode tersebut, keberadaannya tetap penting untuk meningkatkan akurasi model prediksi beban dengan merepresentasikan hubungan antara daya aktif dan total daya dalam sistem.

Terdapat 4 variabel inputan diantaranya yaitu Daya Aktif (Gambar 3), Daya Reaktif (Gambar 4), Arus (Gambar 5), dan Load Factor dengan nilai 0,73 p.u (Gambar 6). Data inputan diambil selama 1 minggu yakni mulai tanggal 1 Desember 2024 hingga 7 Desember 2024 dengan interval waktu pencatatan per-30 menit dalam sehari. Data yang dikumpulkan terdiri dari 1152 data.

Data kemudian dikonversi menjadi format waktu (Time Series). Hal ini bertujuan agar memudahkan model dalam membaca dan mempelajari karakteristik atau pola pada data secara berurutan. Model akan mengenali hubungan antara periode waktu tertentu dengan fluktuasi jumlah konsumsi beban listrik. Data juga dikelola dan diurutkan sesuai dengan tanggal dan waktu yang sesungguhnya.

Selain itu dalam proses Preparation Data juga dilakukan normalisasi pada data. Normalisasi dilakukan untuk membantu model dalam mengatasi gradien terkait rentang skala pada data. Normalisasi dilakukan dengan teknik MinMax 0-1.

Langkah selanjutnya adalah membagi data menjadi data *training*, data *target*, dan data *testing*. Data *training* adalah sekumpulan data yang digunakan oleh model untuk mempelajari dan mengenal pola regresi pada data. Data target adalah nilai keluaran yang diharapkan untuk setiap *input* pada data *training*. Dalam proses *backpropagation*, *output* dari model akan dibandingkan dengan target, lalu dihitung *error*-nya. *Error* ini digunakan untuk memperbarui bobot jaringan melalui algoritma *backpropagation*. Sedangkan data testing adalah sekumpulan data hasil uji prediksi dari kemampuan model dalam mengenali pola. Hasil pembagian data yang akan digunakan dalam simulasi ini adalah 4.608 data *training*, 1152 data *target*, dan 1536 data *testing*.

Komponen Model

Setelah data preparation dilakukan, selanjutnya adalah menyusun komponen yang terdapat pada model, diantaranya tipe jaringan, input data, target data, training function, Adaption learning function, Performance function, jumlah layer, jumlah neuron per-layer, dan Transfer function. Susunan komponen untuk model jaringan dapat dilihat pada Tabel 1 dibawah ini.


Tabel 1 Komponen model

Nama jaringan	: Waru_6
Tipe jaringan	: Feed-forward backprop
Input data	: Training
Target data	: Target
Training function	: Trainlm
Adaption learning function	: LEARNGDM
Performance function	: MSE
Number of layers	: 1
Number of neurons	: 5
Transfer function	: LOGSIG

Hasil Simulasi


Berdasarkan hasil simulasi yang dilakukan menggunakan MATLAB, metode backpropagation pada jaringan saraf tiruan (JST) menunjukkan performa yang terbaik dalam meramalkan beban listrik pada transformator 6 Gardu Induk Waru adalah dengan menggunakan arsitektur jaringan yang terdiri dari 1 hidden layer dengan jumlah neuron sebanyak 5. Data yang diujikan merupakan data historis beban listrik dengan interval waktu setiap 30 menit, mulai dari tanggal 1 hingga 8 Desember 2024. Proses pelatihan jaringan dilakukan selama 250 epoch untuk memastikan model dapat mengenali pola beban secara optimal.

Hasil simulasi menunjukkan nilai *mean squared error* (MSE) yang rendah serta grafik perbandingan antara nilai aktual dan hasil peramalan memperlihatkan kemiripan pola yang signifikan. Dengan demikian, metode *backpropagation* terbukti cukup efektif dalam melakukan peramalan beban listrik, yang dapat dimanfaatkan untuk mendukung perencanaan dan pengelolaan sistem tenaga listrik. Grafik hasil peramalan bisa dilihat dalam Gambar 7 dan Gambar 8.




Gambar 7

Gambar 7 diatas adalah hasil peramalan untuk tanggal 1-7 Desember 2024. Hasil peramalan menunjukkan perbandingan pola grafik antara data aktual dan data hasil peramalan yang mengikuti atau hampir sama. Untuk mengetahui nilai perbandingan antara data aktual dan hasil peramalan dapat dilihat dengan melakukan perhitungan error seperti MSE dan MAPE pada Gambar 9 dan 10.




Gambar 8

Gambar 8 merupakan grafik perbandingan antara data aktual dengan data hasil peramalan untuk tanggal 8 Desember 2024. Hasil peramalan tidak menunjukkan fluktuasi karena input nilai yang dimasukkan untuk data tanggal 8 adalah 1. Nilai 1 merupakan nilai maksimum dari normalisasi data yang nantinya dari input tersebut menghasilkan prediksi dengan nilai di atas beban rata-rata dari data aktual sehingga transformator masih dapat memenuhi kebutuhan konsumen.



Gambar 9

Gambar 9 merupakan hasil *Mean Square Error* antara data aktual dan data hasil peramalan dengan rata-rata MSE adalah 0,0612. Dari hasil peramalan didapatkan nilai error terkecil sebesar 0,00 yang berarti sempurna atau sesuai dengan data aktual, nilai tersebut ditemukan pada beberapa periode diantaranya pada tanggal 2 pukul 11.30, tanggal 4 pukul 04.00, tanggal 5 pukul 21.00, tanggal 6 pukul 00.30, dan tanggal 6 pukul 19.00. Sedangkan nilai error terbesar didapatkan sebesar 6,39 ditemukan pada 1 periode yaitu pada tanggal 8 pukul 15.30.



Gambar 10

Gambar 10 merupakan grafik *Mean Average Percentage Error* dari hasil simulasi dengan rata-rata MAPE sebesar 1,48%. Nilai ini selaras dengan nilai MSE namun hanya berbeda pada cara penghitungan error dan satuan hasilnya. Letak nilai persentase terkecil dan terbesar yang ditemukan juga sama dengan nilai error terkecil dan terbesar pada nilai MSE.

PENUTUP

Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa peramalan beban jangka pendek menggunakan metode *Backpropagation Neural Network* (BPNN) pada transformator 150 kV di Gardu Induk Waru PT. PLN (Persero) menunjukkan kinerja yang baik dalam memprediksi nilai beban berdasarkan faktor beban sebagai variabel input. Arsitektur model terdiri dari 1 hidden layer. Parameter yang digunakan yakni *neuron*, *layer*, dan *epoch* sangat berpengaruh terhadap hasil prediksi. Kombinasi parameter terbaik pada penelitian ini

dengan karakteristik data inputan yang digunakan, dengan hasil nilai akurasi paling minim dan hasil grafik peramalan yang mengikuti pola atau tren dari data aktual adalah saat $neuron = 5$, $hidden\ layer = 1$, $epoch = 250$, dengan nilai akurasi $MAPE = 1,48\%$ dan $MSE = 0,0612$. Model menghasilkan prediksi yang baik saat menangkap pola interval yang lebih pendek.

Saran

Untuk mendapatkan hasil yang lebih baik dengan nilai error yang lebih kecil dari pemodelan Backpropagation untuk melakukan peramalan jangka pendek konsumsi beban listrik pada penelitian-penelitian selanjutnya, peneliti menyarankan untuk menambah dataset inputan yang digunakan. Semakin banyak data inputan maka membuat model akan lebih baik dalam melakukan pembelajaran. Sehingga akan menghasilkan prediksi yang lebih akurat baik pada nilai akurasi maupun pola grafik peramalan yang mengikuti data actual

DAFTAR PUSTAKA

- [1] R. Ramadana and D. Suhendro, "Peramalan Beban Trafo Daya Harian Gardu Induk Pada Ptpln (Persero) Up3 Pematang Siantar," J. intekna, vol. 23, no. 2, pp. 184–195, 2023.
- [2] C. I. Cahyadi, K. Atmia, and A. Fitriani, "Analisis Pengaruh Rugi-Rugi Daya Pada Jaringan Transmisi 150 kV Menggunakan Software Etap 12.6," Jambura J. Electr. Electron. Eng., vol. 4, no. 2, pp. 126–130, 2022, doi: 10.37905/jjee.v4i2.13306.
- [3] N. Ahmad, Y. Ghadi, M. Adnan, and M. Ali, "Load Forecasting Techniques for Power System: Research Challenges and Survey," IEEE Access, vol. 10, no. June, pp. 71054–71090, 2022, doi: 10.1109/ACCESS.2022.3187839.
- [4] F. V. Cerna, M. Pourakbari-kasmaei, L. S. S. Pinheiro, E. Naderi, M. Lehtonen, and J. Contreras, "Intelligent energy management in a prosumer community considering the load factor enhancement," Energies, vol. 14, no. 12, 2021, doi: 10.3390/en14123624.
- [5] I. K. Nti, M. Teimeh, O. Nyarko-Boateng, and A. F. Adekoya, "Electricity load forecasting: a systematic review," J. Electr. Syst. Inf. Technol., vol. 7, no. 1, 2020, doi: 10.1186/s43067-020-00021-8.
- [6] F. Alamsyah, B. Suprianto, W. Aribowo, and A. C. Hermawan, "PERAMALAN BEBAN LISTRIK HARIAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK," J. Tek. Elektro, ejournal.unesa.ac.id, vol. 10, pp. 203–209, 2021.
- [7] M. P. S. Gunawan and W. Aribowo, "Peramalan Beban Listrik Jangka Pendek Menggunakan Metode Feed Forward Backpropagation Neural Network," J. Tek. Elektro, vol. 09, pp. 561–568, 2020, [Online]. Available: <https://ejournal.unesa.ac.id/index.php/JTE/article/view/35265>
- [8] F. R. Rizqulloh, S. Prasetyono, and W. Cahyadi, "Analisa Perbandingan Peramalan Beban Listrik Jangka Pendek antara Metode Backpropagation Neural Network dengan Metode Regresi Linier," J. Arus Elektro Indones., vol. 6, pp. 69–77, 2020.
- [9] R. Dastres and M. Soori, "Artificial Neural Network Systems," Int. J. Imaging Robot., vol. 21, no. 2, pp. 13–25, 2021.
- [10] Hartono, M. Sadikin, D. M. Sari, N. Anzelina, S. Lestari, and W. Dari, "Implementation of Artifical Neural Networks with Multilayer Perceptron for Analysis of Acceptance of Permanent Lecturers," J. Mantik, vol. 4, no. 2, pp. 1389–1396, 2020, [Online]. Available: <https://iocscience.org/ejournal/index.php/mantik/article/view/954>
- [11] M. Yamasaki, R. Z. Freire, L. O. Seman, S. F. Stefenon, V. C. Mariani, and L. dos Santos Coelho, "Optimized hybrid ensemble learning approaches applied to very short-term load forecasting," Int. J. Electr. Power Energy Syst., vol. 155, no. PB, p. 109579, 2024, doi: 10.1016/j.ijepes.2023.109579.
- [12] C. Tarmanini, N. Sarma, C. Gezevin, and O. Ozgonenel, "Short term load forecasting based on ARIMA and ANN approaches," Energy Reports, vol. 9, pp. 550–557, 2023, doi: 10.1016/j.egy.2023.01.060.

- [13] A. Wanto et al., “Levenberg-Marquardt Algorithm Combined with Bipolar Sigmoid Function to Measure Open Unemployment Rate in Indonesia,” no. 1, pp. 22–28, 2021, doi: 10.5220/0010037200220028.
- [14] I. Pamungkas, STUDI KOMPARASI FUNGSI AKTIVASI SIGMOID BINER, SIGMOID BIPOLAR DAN LINEAR PADA JARINGAN SARAF TIRUAN DALAM MENENTUKAN WARNA RGB MENGGUNAKAN MATLAB. 2022. [Online]. Available: <http://digilib.unila.ac.id/id/eprint/65855>
- [15] I. Nabillah and I. Ranggadara, “Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut,” JOINS (Journal Inf. Syst., vol. 5, no. 2, pp. 250–255, 2020, doi: 10.33633/joins.v5i2.3900.
- [16] J. Ren, M. Zhang, C. Yu, and Z. Liu, “Balanced MSE for Imbalanced Visual Regression,” Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., vol. 2022-June, pp. 7916–7925, 2022, doi: 10.1109/CVPR52688.2022.00777.