

Prediksi Komsumsi Daya Listrik Pada Panel Listrik Menggunakan Metode *Neural Network*

Agus Khumaidi¹, Muhammad Khoirul Hasin², Anggarjuna Puncak Pujiputra³, Sholahuddin Muhammad Irsyad⁴, Noorman Rinanto⁵, Isa Rachman⁶, Perdinan Setia Budi⁷, Alfianto Taufiqul Malik⁸, Nurissabiqoh Binta Bayu⁹

e-mail: aguskhumaidi@ppns.ac.id¹, Khoirul.hasin@ppns.ac.id², anggarjunapuncak@ppns.ac.id³, muhhammad.irsyad@ppns.ac.id⁴, noorman.rinanto@ppns.ac.id⁵, isarachman@ppns.ac.id⁶, perdinansetia@student.ppns.ac.id⁷, alfianto.taufiqul@student.ppns.ac.id⁸, nbinta29@student.ppns.ac.id⁹

¹²³⁴⁵⁶⁷⁸⁹ Jurusan Teknik Otomasi, Politeknik Perkapalan Negeri Surabaya , Indonesia

Informasi Artikel

Riwayat Artikel

Diterima 5 Juni 2024
Direvisi 26 Juni 2024
Diterbitkan 31 Juli 2024

Kata kunci:

Efisiensi energi
Energi listrik
Neural Network

Keywords:

Energy efficiency
Electrical energy
Neural network

ABSTRAK

Penggunaan energi listrik yang meningkat menimbulkan tantangan terkait keterbatasan sumber daya alam dan dampak lingkungan, mendorong upaya global menuju efisiensi energi. Di gedung bertingkat, kurangnya sistem prediksi daya pada Sub Distribution Panel (SSDP) menghambat efisiensi dan keandalan distribusi energi listrik. Untuk mengatasi masalah ini, dikembangkan teknologi berbasis neural network yang memanfaatkan sensor PM2100 dan mikrokontroler ESP32 untuk memonitor dan memprediksi penggunaan daya listrik. Data ditampilkan dalam aplikasi Android, memungkinkan pemantauan real-time dan perencanaan yang lebih efisien. Hasil penelitian menunjukkan peningkatan pengelolaan daya, pencegahan kerusakan, dan optimasi penggunaan energi, menjadikan sistem ini model potensial bagi institusi lain dalam meningkatkan efisiensi dan keandalan distribusi energi listrik.

ABSTRACT

The increasing use of electrical energy presents challenges related to the limitation of natural resources and environmental impacts, prompting global efforts towards energy efficiency. In multi-story buildings, the lack of power prediction systems on Sub Distribution Panels (SSDP) hinders the efficiency and reliability of electrical energy distribution. To address this issue, a neural network-based technology was developed, utilizing PM2100 sensors and ESP32 microcontrollers to monitor and predict electrical power usage. Data is displayed in an Android application, enabling real-time monitoring and more efficient planning. The research results indicate improvements in power management, damage prevention, and energy usage optimization, positioning this system as a potential model for other institutions in enhancing the efficiency and reliability of electrical energy distribution.

Penulis Korespondensi:

Perdinan Setia Budi
Jurusan Teknik Otomasi
Politeknik Perkapalan Negeri Surabaya
Jl. Teknik Kimia, Keputih, Kec. Sukolilo, Surabaya, Jawa Timur 60111.



Email: perdinansetia@student.ppns.ac.id
Nomor HP/WA aktif: +62 8225 5639 2998

1. PENDAHULUAN

Penggunaan energi listrik telah menjadi pendorong utama perkembangan modernitas dalam berbagai sektor kehidupan manusia sejak abad ke-19, ketika listrik pertama kali ditemukan dan dimanfaatkan oleh para pionir seperti Thomas Edison dan Nikola Tesla. Sejak saat itu, energi listrik telah mengubah cara kita bekerja, berkomunikasi, dan menjalani kehidupan sehari-hari, memainkan peran krusial dalam memenuhi kebutuhan masyarakat modern. Namun, seiring dengan peningkatan penggunaan energi listrik, muncul pula tantangan terkait keterbatasan sumber daya alam dan dampak lingkungan [1]. Tantangan ini mendorong upaya global untuk beralih ke sumber energi terbarukan dan meningkatkan efisiensi penggunaan energi demi keberlanjutan planet ini.

Di berbagai gedung bertingkat, terutama pada Sub Distribution Panel (SSDP), sering kali diabaikan masalah sistem prediksi daya. Hal ini dapat menghambat efisiensi dan keandalan distribusi energi listrik. Kurangnya pemantauan dan pemeliharaan rutin meningkatkan risiko gangguan dan kerusakan peralatan, yang pada akhirnya dapat berdampak negatif pada operasional kampus. Sistem distribusi listrik yang tidak terawasi dengan baik dapat menyebabkan konsleting dan gangguan lainnya yang mengakibatkan pemadaman listrik, mengganggu kegiatan akademik dan administratif.

Untuk mengatasi masalah tersebut, penulis mengembangkan teknologi berbasis neural network untuk memonitor dan memprediksi penggunaan daya listrik pada SSDP di gedung bertingkat. Neural network dipilih karena kemampuannya dalam memproses data besar dan kompleks, serta memberikan prediksi yang lebih akurat dibandingkan metode konvensional. Teknologi ini diharapkan dapat memberikan gambaran akurat tentang kebutuhan energi, memungkinkan perencanaan yang lebih efisien, dan memberikan informasi yang diperlukan untuk pemeliharaan yang proaktif. Implementasi teknologi ini melibatkan penggunaan berbagai sensor untuk memastikan kondisi optimal pada SSDP. Sensor PM2100 digunakan untuk memonitor arus, tegangan, dan daya. Data yang dihasilkan PM2100 akan diolah menggunakan metode *neural network* yang bertujuan untuk memprediksi daya listrik pada panel gedung bertingkat.

Data yang dikumpulkan dari sensor-sensor tersebut diolah menggunakan mikrokontroler ESP32 dan ditampilkan dalam aplikasi Android untuk kemudahan akses dan monitoring. Integrasi ini memungkinkan pemantauan real-time dan prediksi penggunaan daya listrik, mendukung efisiensi energi dan keandalan sistem distribusi listrik di gedung bertingkat [2]. Dengan sistem ini, diharapkan terjadi peningkatan dalam pengelolaan daya, pencegahan kerusakan, dan optimasi penggunaan energi, yang semuanya berkontribusi positif terhadap keandalan dan efisiensi distribusi energi listrik di kampus. Implementasi ini juga diharapkan dapat menjadi model bagi institusi lain dalam upaya meningkatkan efisiensi dan keandalan distribusi energi listrik. Secara keseluruhan, pengembangan teknologi berbasis neural network ini diharapkan mampu memberikan solusi komprehensif dalam pemantauan dan prediksi penggunaan daya listrik, mendukung upaya global menuju efisiensi energi yang lebih tinggi, dan memberikan kontribusi signifikan terhadap keberlanjutan lingkungan hidup. Dengan mengintegrasikan sensor canggih, mikrokontroler modern, dan aplikasi mobile yang *user-friendly*, sistem ini menawarkan cara yang inovatif dan efektif [3] untuk mengelola penggunaan energi di gedung bertingkat, memastikan bahwa operasional kampus dapat berjalan dengan lancar dan tanpa gangguan.

2. METODE PENELITIAN

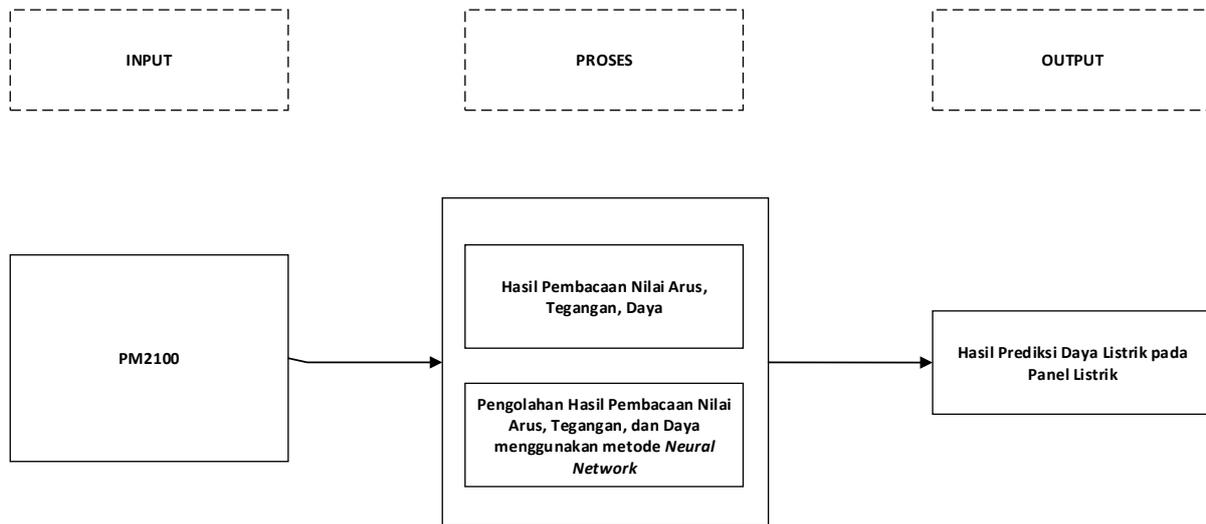
Penelitian ini berfokus pada perancangan sistem dengan menggunakan metode neural network untuk memonitor dan memprediksi penggunaan daya listrik. Tahapan yang dilakukan meliputi beberapa langkah penting. Pertama, penyusunan diagram blok untuk memberikan gambaran menyeluruh mengenai interaksi antara komponen-komponen dalam sistem, memastikan bahwa setiap bagian berfungsi secara sinergis. Kedua, pembuatan flowchart untuk menjelaskan alur kerja sistem secara berurutan, membantu dalam visualisasi proses dan identifikasi langkah-langkah kritis dalam operasional sistem. Selain itu, dibuat juga flowchart khusus untuk proses deteksi objek, yang



bertujuan untuk menguraikan secara rinci bagaimana sistem mendeteksi dan memproses data input dari sensor. Langkah terakhir adalah penerapan metode perancangan, yang bertujuan untuk memastikan bahwa desain yang dibuat sesuai dengan tujuan yang diinginkan, baik dari segi efisiensi, keandalan, maupun akurasi prediksi daya listrik. Dengan pendekatan ini, diharapkan sistem yang dirancang mampu memberikan solusi yang efektif dan inovatif dalam pengelolaan energi listrik di gedung bertingkat.

2.1 Blok Diagram

Gambar 1 menunjukkan bagaimana sistem penelitian bekerja. Ada bagian untuk masukan, bagian yang mengolahnya, dan bagian untuk keluaran. Ini membantu kita melihat cara kerja sistem dengan lebih mudah.



Gambar 1 Diagram Blok Sistem

Alat ini menggunakan sensor daya PM2100, untuk mengumpulkan informasi detail mengenai arus, tegangan, dan daya listrik di sekitar panel distribusi. Setelah informasi terkumpul, data tersebut melalui beberapa tahapan pengolahan dengan menggunakan metode Neural Network yang tertanam dalam sistem alat. Neural Network ini memungkinkan analisis mendalam dan pembuatan keputusan berdasarkan pola data yang telah dipelajari, sehingga prediksi penggunaan daya menjadi lebih akurat. Data yang telah diproses kemudian dikirimkan melalui mikrokontroler ESP32, yang berfungsi untuk memantau dan mengelola panel listrik secara real-time. Dengan pemantauan real-time ini, sistem dapat memberikan umpan balik yang cepat dan tepat, mendukung pengelolaan energi yang lebih efisien dan responsif terhadap perubahan kebutuhan listrik.

2.2 Pemilihan Metode *Neural Network*

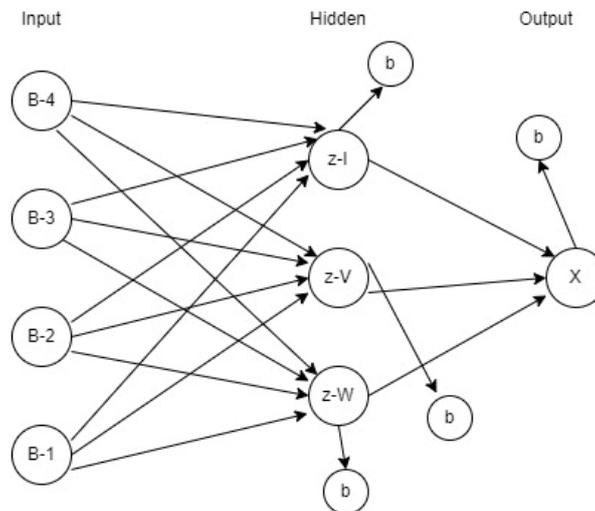
Data yang telah dikumpulkan dan dikelompokkan kemudian diolah melalui proses ekstraksi data. Keefektifan suatu model Jaringan Syaraf Tiruan (JST) salah satunya bergantung pada interkoneksi antar neuron atau yang dikenal sebagai arsitektur jaringan. Dalam membentuk struktur jaringan syaraf tiruan, pola-pola hubungan antar neuron dirancang [4]. Neuron-neuron ini berfungsi mengubah informasi yang diterima melalui sambungan keluarannya untuk diteruskan ke neuron lainnya. Dalam konteks jaringan syaraf, hubungan ini dikenal dengan istilah bobot dan bias. Arsitektur jaringan syaraf tiruan dalam konteks prediksi terdiri dari beberapa lapisan, termasuk lapisan input, lapisan tersembunyi, dan lapisan output, di mana pola hubungan antar neuron dan pengaturan bobot serta bias memainkan peran krusial dalam membentuk model yang efektif yaitu:

1. Lapisan Input (*Input Layer*) berfungsi sebagai unit penerima input eksternal yang menggambarkan suatu permasalahan dari luar.
2. Lapisan Tersembunyi (*Hidden Layer*) terdiri dari unit tersembunyi yang menghasilkan nilai output yang tidak dapat diamati secara langsung.



3. Lapisan Output (*Output Layer*) terdiri dari unit yang memberikan solusi dari Jaringan Syaraf Tiruan (JST) terhadap suatu permasalahan. Gambar arsitektur jaringan syaraf tiruan menjelaskan peran masing-masing lapisan dan elemen-elemen kunci.

Dalam keterangan gambar, B_i ($i \in \{1, 2, 3, 4\}$) berperan sebagai neuron pada lapisan input, mewakili Bulan ke-1, Bulan ke-2, Bulan ke-3, dan Bulan ke-4 percobaan.. Z_j ($j \in \{W, V, I\}$) berperan sebagai neuron pada lapisan tersembunyi. V_{ij} ($i \in \{1, 2, 3, 4\}$, $j \in \{W, V, I\}$) adalah bobot yang menghubungkan lapisan input dengan lapisan tersembunyi, sementara b adalah bias. W_{jk} ($j \in \{0\}$, $k \in \{W, V, I\}$) adalah bobot yang menghubungkan lapisan tersembunyi dengan lapisan output, dan $Y_k(x)$ berperan sebagai neuron pada lapisan output [5].



Gambar 2: *Backpropagation*

Pada Gambar 2, *Backpropagation* merupakan proses dimulai dengan menginisialisasi bobot secara acak, dan kemudian nilai bobot dan bias yang telah ditentukan dimasukkan. Dilakukan pengecekan terhadap kriteria yang sudah ditetapkan pada awalnya. Jika kriteria terpenuhi, hasil output berupa prediksi arus, tegangan, dan daya listrik akan dihasilkan, dan proses tersebut akan diakhiri. Kriteria yang dimaksud dalam hal ini adalah jumlah iterasi. Jika kriteria tersebut belum terpenuhi, proses akan tetap berlanjut.

2.3 Sistem Kerja *Neural Network* pada *Backpropagation*

1. Persiapan Data

Kumpulkan Data: Kumpulkan data historis yang akan digunakan untuk pelatihan dan pengujian jaringan saraf tiruan. Data ini biasanya mencakup fitur-fitur (misalnya, variabel input) dan target (misalnya, daya yang diinginkan).

Pisahkan Data: Pisahkan data menjadi dua set, yaitu data pelatihan (training set) dan data pengujian (testing set). Biasanya, 70-80% data digunakan untuk pelatihan dan sisanya untuk pengujian [6].

2. Menentukan Struktur Jaringan Saraf Tiruan

- Neuron: Unit dasar yang menerima input, memrosesnya, dan menghasilkan output.
- Lapisan (Layer): Jaringan saraf tiruan biasanya terdiri dari lapisan input, satu atau lebih lapisan tersembunyi (hidden layers), dan lapisan output.
- Bobot (Weights): Setiap koneksi antara neuron memiliki bobot yang akan diupdate selama pelatihan [7].

3. Langkah-langkah Algoritma *Backpropagation*

A. Inisialisasi Bobot

Semua bobot pada jaringan saraf tiruan diinisialisasi dengan nilai acak kecil.

B. Forward Propagation

Input: Data input diberikan ke neuron-neuron di lapisan input.



Perhitungan di Lapisan Tersembunyi:

Setiap neuron di lapisan tersembunyi menghitung nilai input totalnya sebagai kombinasi linear dari nilai input dan bobotnya.

Fungsi aktivasi (misalnya, sigmoid, ReLU) diterapkan pada nilai input total untuk menghasilkan output neuron.

Perhitungan di Lapisan Output:

Proses yang sama diterapkan di lapisan output untuk menghasilkan nilai prediksi jaringan [8].

C. Backward Propagation

Hitung Error di Lapisan Output:

Error dihitung sebagai selisih antara nilai prediksi dan nilai target sebenarnya.

Contoh fungsi error: Mean Squared Error (MSE).

Hitung Gradient Error:

Gradient dari error dihitung untuk setiap neuron di lapisan output.

Gradient ini menunjukkan seberapa besar perubahan error dengan perubahan kecil pada output neuron.

Backpropagate Error ke Lapisan Tersembunyi:

Error di lapisan output digunakan untuk menghitung error di lapisan tersembunyi sebelumnya.

Proses ini berlanjut kembali ke lapisan input.

Update Bobot:

Bobot diupdate menggunakan gradient descent atau metode optimasi lainnya.

Update dilakukan dengan mengurangi nilai gradient dikali dengan learning rate dari bobot yang ada.

D. Iterasi

Proses forward dan backward propagation diulang untuk sejumlah epoch tertentu atau sampai error mencapai nilai yang diinginkan [9].

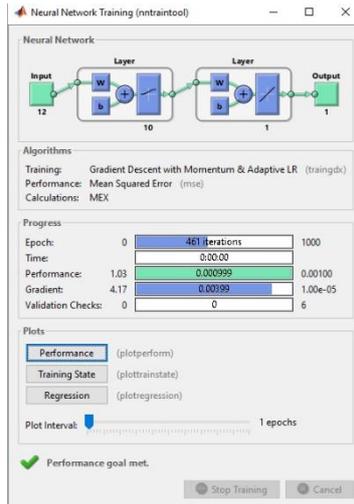
4. Setelah data latih dan data uji disiapkan dalam format xlsx (Excel), dilakukan pemrograman untuk melatih jaringan saraf tiruan. Arsitektur jaringan saraf tiruan yang digunakan dalam contoh ini adalah 12-10-1, yang berarti terdapat 12 nilai input (data selama 12 bulan), 10 neuron pada hidden layer, dan satu nilai output yaitu data pada bulan berikutnya [10]. Berikut adalah source code untuk pelatihan jaringan dalam prediksi ini:

```
1 clear;close all;clearing off;
2
3 % Proses membaca data latih dari excel
4 filename = 'Biodata.xlsx';
5 sheet = 1;
6 xrange = 'D6:F17';
7
8 Data = xlsread(filename, sheet, xrange);
9 data_latih = Data(:,1:12);
10 target_latih = Data(:,13);
11 [m,n] = size(data_latih);
12
13 % Pembuatan net
14 net = newff(data_latih,10,'logsig','purelin','trainlm');
15
16 % Memberikan nilai untuk mempengaruhi proses pelatihan
17 net.perfFcn = 'mse';
18 net.trainParam.goal = 0.001;
19 net.trainParam.show = 20;
20 net.trainParam.epoch = 1000;
21 net.trainParam.mc = 0.05;
22 net.trainParam.lr = 0.1;
23
24 % Proses training
25 [net_keluaran,D] = train(net,data_latih,target_latih);
26
27 % mail setelah pelatihan
28 bobot_hidden = net_keluaran.D(1,1);
29 bobot_keluaran = net_keluaran.D(2,1);
30 bias_hidden = net_keluaran.D(1,2);
31 bias_keluaran = net_keluaran.D(2,2);
32 jumlah_iterasi = tr_num_epochs;
33 nilai_keluaran = Y;
34 nilai_error = E;
35 error_net = (1/2)*sum(nilai_error.^2);
36
37 save net_net net_keluaran
```

Gambar 3: Program *Neural Network* pada *Matlab*
(Sumber: pemrogramanmatlab.com)

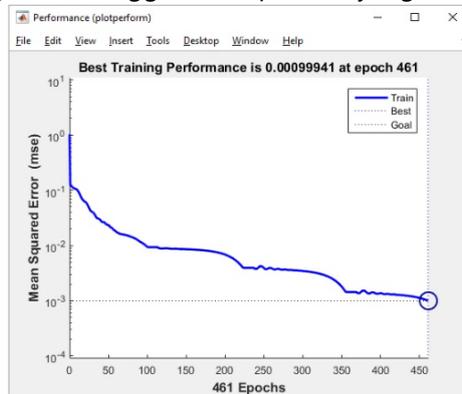
5. Sehingga menghasilkan tampilan proses pelatihan jaringan seperti yang ditunjukkan pada gambar berikut:





Gambar 4: Hasil *Training* pada *Matlab*
(Sumber: pemrogramanmatlab.com)

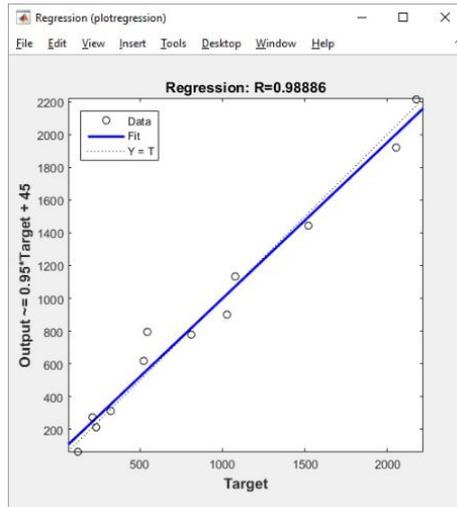
6. Dalam proses pelatihan ini, error goal (MSE) sebesar 0,00099941 berhasil dicapai pada epoch ke-461, seperti yang ditunjukkan pada gambar di bawah ini. Gambar tersebut memperlihatkan grafik penurunan error selama proses pelatihan, dengan penurunan yang signifikan hingga mencapai nilai yang ditargetkan pada epoch tersebut.



Gambar 5: Hasil *Error Goal* (MSE)
(Sumber: pemrogramanmatlab.com)

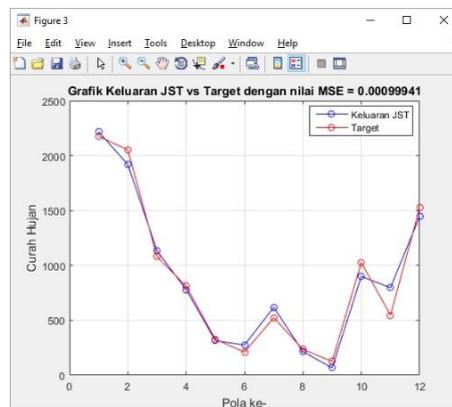
7. Selanjutnya melihat hasil koefisien korelasi RRR yang diperoleh adalah sebesar 0,98886, seperti yang ditampilkan pada gambar berikut:





Gambar 6: Koefisien Korelasi R
 (Sumber: pemrogramanmatlab.com)

8. Lalu melihat grafik perbandingan antara keluaran JST (prediksi curah hujan) dengan target (data curah hujan sebenarnya) adalah sebagai berikut:



Gambar 7: Grafik Keluaran JST vs Target nilai MSE
 (Sumber: pemrogramanmatlab.com)

3. HASIL DAN PEMBAHASAN

3.1 Data Penelitian

Pengambilan data sampel dilakukan dengan mengambil nilai data yang dihasilkan melalui PM2100 yang digunakan untuk memperoleh arus, tegangan, dan daya yang dihasilkan lalu diolah menggunakan metode Neural Network untuk menghasilkan nilai prediksi daya listrik pada panel. Berikut ini adalah tabel 1 hasil pengambilan dari data yang dihasilkan dari PM2100:

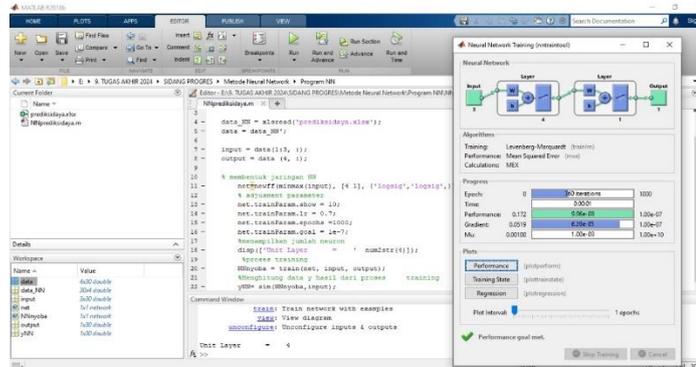
TABEL I : Hasil Pengambilan Data

No.	Tegangan	Arus	Daya
1.	230.5	0.052	0.29
2.	230.6	0.052	0.29
3.	230.7	0.052	0.29
4.	230.8	0.052	0.29
5.	230.8	0.052	0.29
6.	230.7	0.106	0.29



7.	230.7	0.106	0.29
8.	231.0	0.106	0.29
9.	230.7	0.106	0.29
10.	230.5	0.106	0.29
11.	230.6	0.052	0.29
12.	230.7	0.052	0.29
13.	230.8	0.052	0.29
14.	230.8	0.052	0.29
15.	230.7	0.052	0.29
16.	230.7	0.106	0.29
17.	231.0	0.106	0.29
18.	230.7	0.106	0.29
19.	230.5	0.106	0.29
20.	230.6	0.106	0.29
21.	230.7	0.052	0.29
22.	230.8	0.052	0.29
23.	230.8	0.052	0.29
24.	230.7	0.052	0.29
25.	230.7	0.052	0.29
26.	231.0	0.106	0.29
27.	230.7	0.106	0.29
28.	230.8	0.106	0.29
29.	231.0	0.106	0.29
30.	230.7	0.106	0.29

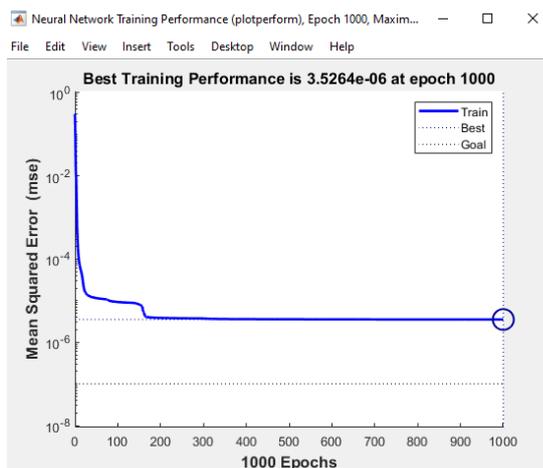
3.4 Pengujian Metode *Neural Network*



Gambar 8: *Training Neural Network*

Pada Gambar 8, ditunjukkan proses pelatihan data untuk jaringan saraf tiruan (Neural Network). Proses ini merupakan langkah penting dalam mengembangkan model yang akan digunakan untuk memprediksi daya listrik. Selama tahap pelatihan, data yang telah dikumpulkan dan dipersiapkan sebelumnya dimasukkan ke dalam model Neural Network, yang kemudian belajar mengenali pola dan hubungan dalam data tersebut. Proses pelatihan ini melibatkan iterasi berulang di mana model menyesuaikan bobot dan biasanya untuk meminimalkan kesalahan prediksi. Hasil dari proses ini adalah model yang terlatih dan diharapkan mampu membuat prediksi yang akurat mengenai daya listrik berdasarkan input yang diberikan. Proses pelatihan ini sangat penting karena menentukan seberapa baik model Neural Network dapat memprediksi daya listrik dalam situasi nyata, membantu dalam perencanaan dan pengelolaan penggunaan daya yang lebih efisien.

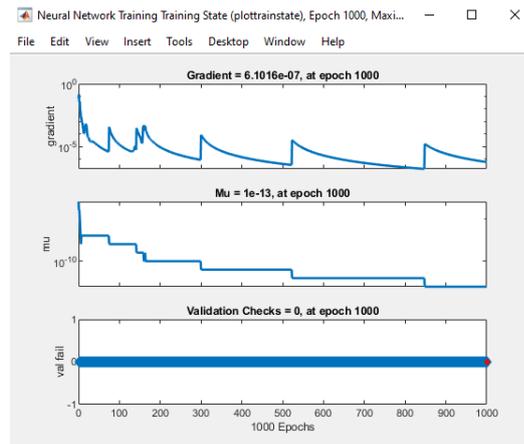




Gambar 9: Hasil *Best Training Performance*

Gambar 9 Hasil kinerja pelatihan terbaik (*Best Training Performance*) yang dicapai selama proses pelatihan jaringan saraf tiruan ditunjukkan dengan nilai Mean Squared Error (MSE) sebesar $3.5264e-06$ pada epoch ke-1000. Grafik yang dihasilkan menggambarkan penurunan nilai error secara bertahap selama iterasi pelatihan, hingga mencapai titik kinerja optimal pada epoch tersebut. Nilai MSE yang sangat kecil ini menunjukkan bahwa model jaringan saraf tiruan telah berhasil belajar dengan sangat baik dari data latih yang diberikan, sehingga menghasilkan prediksi yang akurat. Selain itu, grafik ini juga memberikan wawasan penting tentang stabilitas dan konvergensi jaringan selama pelatihan. Nilai MSE yang kecil pada epoch ke-1000 menunjukkan bahwa model telah mencapai tingkat kinerja optimal, di mana penyesuaian lebih lanjut pada bobot-bobot jaringan tidak menghasilkan peningkatan yang signifikan dalam kinerja prediksi. Dengan demikian, grafik hasil kinerja pelatihan ini merupakan bukti bahwa jaringan saraf tiruan telah mencapai tingkat keakuratan dan generalisasi yang tinggi terhadap data pelatihan yang digunakan, mencerminkan kemampuan model dalam memprediksi dengan presisi yang tinggi serta stabilitas yang baik sepanjang proses pelatihan. Dengan demikian, grafik hasil kinerja pelatihan ini tidak hanya menunjukkan bahwa jaringan saraf tiruan telah mencapai tingkat keakuratan yang sangat tinggi dalam memprediksi output dari data pelatihan, tetapi juga mencerminkan kemampuan model untuk melakukan generalisasi yang baik terhadap data yang belum pernah dilihat. Ini merupakan bukti bahwa model telah berhasil mengatasi tantangan-tantangan umum dalam pelatihan jaringan saraf tiruan, seperti overfitting dan underfitting, dan telah mencapai keseimbangan yang optimal antara kompleksitas model dan performa prediksi. Keberhasilan ini menandakan potensi yang besar dari model ini untuk diaplikasikan dalam berbagai tugas prediktif dan analitik di dunia nyata, di mana keakuratan dan kemampuan generalisasi adalah kunci utama untuk mendapatkan hasil yang dapat diandalkan dan bermakna.

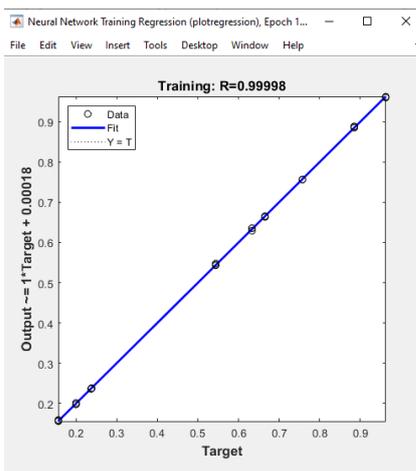




Gambar 9: Hasil *Training State*

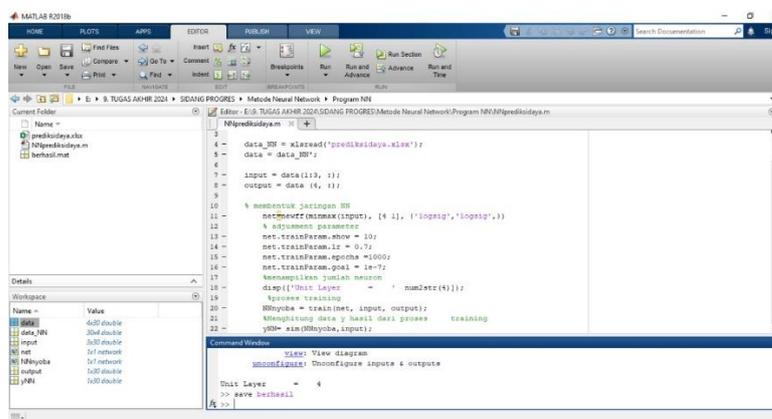
Gambar 9 menampilkan hasil training state yang dicapai pada proses pelatihan jaringan saraf tiruan, dengan nilai gradient sebesar $6.1016e-07$ pada epoch ke-1000. Grafik ini memberikan informasi penting mengenai kondisi jaringan selama pelatihan, khususnya mengenai laju perubahan (gradient) dari fungsi error seiring dengan pembaruan bobot. Pada awal pelatihan, gradient biasanya memiliki nilai yang lebih besar, mencerminkan perubahan yang signifikan pada bobot jaringan dalam upaya untuk mengurangi error. Namun, seiring berjalannya waktu dan bertambahnya jumlah epoch, nilai gradient cenderung menurun. Penurunan ini menunjukkan bahwa jaringan saraf tiruan semakin mendekati kondisi optimal, di mana bobot-bobot jaringan mencapai konfigurasi yang meminimalkan error secara efektif. Nilai gradient yang sangat kecil, yaitu $6.1016e-07$ pada epoch ke-1000, mengindikasikan bahwa perubahan pada bobot jaringan sudah sangat minimal. Hal ini menandakan bahwa jaringan telah mencapai titik stabil atau konvergensi, di mana penyesuaian lebih lanjut tidak lagi memberikan perbaikan yang signifikan terhadap kinerja jaringan. Dengan kata lain, jaringan telah belajar secara maksimal dari data pelatihan yang diberikan dan telah mencapai kemampuan prediksi yang optimal. Grafik training state ini juga berguna untuk memantau apakah jaringan saraf tiruan telah mengalami overfitting atau underfitting. Dalam kasus ini, nilai gradient yang kecil menunjukkan bahwa jaringan telah dilatih dengan baik tanpa overfitting, karena perubahan bobot yang stabil menunjukkan generalisasi yang baik terhadap data pelatihan. Oleh karena itu, gambar ini memberikan gambaran menyeluruh tentang efektivitas proses pelatihan dan stabilitas jaringan dalam meminimalkan error pada setiap iterasi.





Gambar 10: Hasil *Regression*

Gambar 10 menampilkan hasil regresi (Regression) dari proses pelatihan jaringan saraf tiruan, dengan nilai koefisien korelasi untuk data pelatihan (Training) sebesar $R=0.99998$. Koefisien korelasi R ini merupakan metrik statistik yang digunakan untuk mengukur kekuatan dan arah hubungan linear antara prediksi jaringan saraf tiruan dan nilai target sebenarnya. Nilai $R=0.99998$ yang mendekati 1, seperti yang diperoleh dalam hasil ini, menunjukkan bahwa prediksi model sangat akurat dan memiliki hubungan linear yang sangat kuat dengan nilai target. Secara praktis, nilai $R=0.99998$ menandakan bahwa hampir semua variasi dalam data target dapat dijelaskan oleh model prediktif yang telah dilatih. Grafik regresi ini biasanya menunjukkan garis regresi terbaik yang diapit oleh titik-titik data yang mewakili pasangan nilai prediksi dan nilai target. Ketika titik-titik data ini terletak sangat dekat dengan garis regresi, hal ini menunjukkan bahwa prediksi model sangat dekat dengan nilai target yang sebenarnya. Hasil ini menunjukkan bahwa jaringan saraf tiruan telah dilatih dengan sangat baik, mampu menangkap pola-pola dalam data pelatihan secara efektif dan memberikan prediksi yang sangat akurat. Nilai R yang sangat tinggi ini juga mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data pelatihan, yang merupakan indikasi positif bahwa model juga akan tampil baik pada data uji atau data baru yang belum pernah dilihat sebelumnya. Secara keseluruhan, gambar ini menggambarkan keberhasilan pelatihan model dalam menghasilkan prediksi yang akurat dan andal, yang merupakan tujuan utama dalam penggunaan jaringan saraf tiruan untuk analisis data dan prediksi.



Gambar 11: Uji Coba Hasil Prediksi pada *Neural Network*



Pada Gambar 11 ditampilkan uji coba hasil prediksi daya listrik menggunakan model yang telah dilatih sebelumnya. Hasil dari prediksi ini kemudian ditampilkan pada jendela perintah (command window) MATLAB. Proses uji coba ini melibatkan penerapan model Neural Network pada data uji yang belum pernah dilihat oleh model, untuk mengevaluasi akurasi dan performa prediksinya. Dengan menampilkan hasil prediksi di command window MATLAB, kita dapat dengan jelas melihat seberapa baik model tersebut memprediksi daya listrik dibandingkan dengan nilai sebenarnya. Uji coba ini sangat penting untuk memvalidasi efektivitas model dan memastikan bahwa prediksi yang dihasilkan dapat diandalkan dan berguna untuk aplikasi praktis, seperti dalam manajemen energi dan optimisasi penggunaan daya listrik. Secara keseluruhan, proses uji coba dan tampilan hasil prediksi ini merupakan langkah krusial dalam siklus pengembangan model, yang memastikan bahwa model Neural Network yang telah dilatih tidak hanya menunjukkan kinerja yang baik dalam lingkungan pelatihan tetapi juga dapat diandalkan dalam aplikasi nyata. Dengan validasi yang menyeluruh, kita dapat memastikan bahwa prediksi yang dihasilkan oleh model dapat digunakan untuk tujuan praktis dengan tingkat kepercayaan yang tinggi, memberikan manfaat nyata dalam konteks aplikasi seperti manajemen energi dan optimisasi penggunaan daya listrik.

4. KESIMPULAN

Kesimpulan dari pengembangan teknologi berbasis neural network untuk memonitor dan memprediksi penggunaan daya listrik pada Sub Distribution Panel (SSDP) di gedung bertingkat adalah bahwa teknologi ini dapat meningkatkan efisiensi dan keandalan distribusi energi listrik. Neural network dipilih karena kemampuannya dalam memproses data besar dan kompleks serta memberikan prediksi yang lebih akurat dibandingkan metode konvensional. Sistem ini menggunakan sensor PM2100 untuk memonitor arus, tegangan, dan daya, serta mikrokontroler ESP32 untuk mengolah data dan menampilkannya dalam aplikasi Android, memungkinkan pemantauan real-time dan prediksi penggunaan daya listrik. Dengan implementasi ini, diharapkan terjadi peningkatan dalam pengelolaan daya, pencegahan kerusakan, dan optimasi penggunaan energi, yang semuanya berkontribusi positif terhadap keandalan dan efisiensi distribusi energi listrik di kampus. Teknologi ini juga berpotensi menjadi model bagi institusi lain dalam meningkatkan efisiensi dan keandalan distribusi energi listrik, mendukung upaya global menuju efisiensi energi yang lebih tinggi, dan berkontribusi signifikan terhadap keberlanjutan lingkungan hidup. Integrasi sensor canggih, mikrokontroler modern, dan aplikasi mobile yang user-friendly menawarkan cara inovatif dan efektif untuk mengelola penggunaan energi di gedung bertingkat, memastikan operasional kampus berjalan dengan lancar dan tanpa gangguan.

DAFTAR PUSTAKA

- [1] F. A. Prastyo, M. Ahsan, D. A. Nugraha, P. S. Informatika, and K. Lumajang, "Autoregressive Integrated Moving Average Untuk Memprediksi Kebutuhan Daya Listrik Kabupaten Lumajang," vol. 6, no. 2, pp. 1–4, 2022.
- [2] D. A. Putra and R. Mukhaiyar, *Monitoring Daya Listrik Secara Real Time*. Jurnal Vocational Teknik Elektronika dan Informatika: Padang, 2020.
- [3] A. F. H. Sitanggang, *Perancangan Alat Monitoring Arus Bocor pada Kabel 20 kV Menggunakan Filter Kalman Berbasis Internet of Things*. Kampus: Jakarta, 2022.
- [4] R. Sistem and F. Bencana, *Algoritma Fungsi Pelatihan pada Machine Learning berbasis ANN*, vol. 1, no. 10. 2021.



- [5] B. Fachri, A. P. Windarto, and I. Parinduri, "Penerapan Backpropagation dan Analisis Sensitivitas pada Prediksi Indikator Terpenting Perusahaan Listrik," *J. Edukasi dan Penelit. Inform.*, vol. 5, no. 2, p. 202, 2019, doi: 10.26418/jp.v5i2.31650.
- [6] K. T. Brilliansyah and U. T. Kartini, "Peramalan Jangka Sangat Pendek Daya Listrik PLTS On Grid Rumah Tinggal Menggunakan Metode Recurrent Neural Network Long Short Term Memory (RNN-LSTM) Berdasarkan Data Meteorologi," *J. Tek. Elektro*, vol. 12, no. 1, pp. 60–66, 2023, doi: 10.26740/jte.v12n1.p60-66.
- [7] R. Dwisatya and M. R. Kirom, "Prediksi Beban Listrik Jangka Pendek Menggunakan Algoritma Feed Forward Back Propagation dengan Mempertimbangkan Variasi Tipe Hari," *Electrans*, vol. 14, no. 1, pp. 34–40, 2016.
- [8] A. H. Wijaya, "Artificial Neural Network Untuk Memprediksi Beban Listrik Dengan Menggunakan Metode Backpropagation," *J. CoreIT*, vol. 5, no. 2, pp. 61–70, 2019.
- [9] E. D. Aruna, B. Fatkhurrozi, and ..., "Peramalan Beban Listrik Kabupaten Cilacap," *ULIL ALBAB J. ...*, vol. 3, no. 2, pp. 385–396, 2024, [Online]. Available: <https://journal-nusantara.com/index.php/JIM/article/view/2813>
- [10] K. E. Purwantoro, U. T. Kartini, B. Suprianto, and A. I. Agung, "Prediksi Daya Listrik Jangka Sangat Pendek Pembangkit Photovoltaic Berbasis Internet of Things Menggunakan Feed Forward Neural Network," *J. Tek. ...*, 2022, [Online]. Available: <https://ejournal.unesa.ac.id/index.php/JTE/article/view/48876%0Ahttps://ejournal.unesa.ac.id/index.php/JTE/article/download/48876/40726>

