

PREDIKSI BEBAN LISTRIK HARIAN MENGUNAKAN METODE MULTILAYER PERCEPTRON (MLP)

Hidayah Dwi Putra Baraka^{1*}, Anggraeny Sekar Kinasih², Syafiq Varel Maulana³

¹²³Program Studi Teknik Elektro Fakultas Teknik dan Informatika Universitas PGRI Semarang

*Email : Hidayahdwiputrabaraka10@gmail.com

Abstrak— Prediksi beban listrik merupakan salah satu langkah penting dalam mendukung pengelolaan sistem tenaga listrik yang andal dan efisien. Informasi mengenai kondisi prediksi listrik pada periode berikutnya dapat digunakan untuk membantu proses pemantauan, evaluasi kinerja sistem, serta pengambilan putusan dalam pengoprasian peralatan listrik. Penelitian ini bertujuan untuk memprediksi kelistrikan menggunakan metode Multi Layer Perceptron (MLP), berdasarkan data pengukuran kelistrikan Tingkat tinggi dari sebuah rumah indekos yang terdiri atas Real Power (Daya aktif), Apparent Power (Daya semu), dan Power Factor (Faktor daya). Model MLP kemudian dilatih menggunakan Algoritma Backpropagation agar mampu mempelajari hubungan nonlinear antarparameter kelistrikan. Selanjutnya performa model dievaluasi menggunakan Mean Absolute Percentage Error (MAPE) untuk mengukur Tingkat akurasi hasil prediksi. Hasil penelitian diharapkan menunjukkan bahwa metode MLP mampu menghasilkan prediksi parameter kelistrikan dengan Tingkat kesalahan rendah sehingga digunakan sebagai salah satu alternatif dalam mendukung proses pemantauan dan pengelolaan sistem tenaga listrik secara lebih efektif.

Kata kunci: Prediksi Beban Listrik; Multi Layer Perceptron; Artificial Neural Network; Peramalan Beban; Sistem Tenaga Listrik

I. PENDAHULUAN

Perkembangan sistem tenaga Listrik menuntut pengelolaan energi yang lebih efisien dan andal. Salah satunya Upaya yang dapat dilakukan Adalah memprediksi parameter kelistrikan untuk membantu proses pemantauan, pengendali beban dan pengambilan Keputusan operasional. Prediksi akurat dapat meningkatkan efisiensi penggunaan energi serta menjaga kestabilan sistem tenaga listrik [2].

Parameter yang umum digunakan dalam analisis sistem tenaga meliputi preal *Real Power*, *Apparent Power*, dan *Power Factor*. Ketiga parameter tersebut sa;ing berhubungan memlalui persamaan $PF = P/S$, sehingga perubahan daya aktif dan daya semu akan memengaruhi nilai factor daya. Dalam penelitian ini, *Power Factor* dihitung berdasarkan data aktual *Real Power* dan *Apparen Power*.

Metode Multi Layer Perceptron (MLP) dipilih karena mampu memodelkan hubungan nonlinear antarparameter dan menghasilkan prediksi yang baik pada berbagai penelitian beban listrik [2], [3]. Oleh karena itu, penelitian ini menerapkan MLP untuk memprediksi *Real Power* menggunakan data aktual yang diproses. Akurasi model evaluasi menggunakan *Mean Absolute Percentage Error* (MAPE).

II. STUDI PUSTAKA

A. Real Power, Apparent Power, dan Power Factor

Pada sistem tenaga listrik AC, *Real Power* (P) merupakan daya yang digunakan untuk melakukan kerja, sedangkan *Apparent Power* (S) adalah total daya yang disalurkan ke beban. Hubungan keduanya menghasilkan *Power Factor* (PF) yang menunjukkan efisiensi

penggunaan daya listrik dan dihitung menggunakan persamaan:

$$PS = \frac{F}{S}$$

Semakin tinggi nilai *Power Factor*, semakin efisien pemanfaatan energi listrik.

B. Multi Layer Perceptron (MLP)

Multi Layer Perceptron (MLP) adalah salah satu metode *Artificial Neural Network* yang terdiri atas lapisan input, hidden layer, dan output layer. MLP mampu mempelajari hubungan nonlinier antarvariabel melalui proses pelatihan menggunakan *algoritma Backpropagation*, sehingga banyak digunakan pada penelitian prediksi beban Listrik [2], [3], [6].

C. Normalisasi Data

Normalisasi dilakukan untuk menyamakan rentang nilai setiap parameter agar proses pelatihan jaringan lebih stabil. Penelitian ini menggunakan metode *Min-Max Normalization* dengan persamaan:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

D. Evaluasi Model

Kinerja model dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE) karena mampu menunjukkan tingkat kesalahan prediksi dalam bentuk persentase. Semakin kecil nilai MAPE, semakin baik performa model dalam memprediksi data aktual [4], [5].

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right|$$

III. METODE/DESAIN

Penelitian ini menggunakan pendekatan kuantitatif untuk mengembangkan model prediksi *Real Power* dengan metode *Multi Layer Perceptron* (MLP). Data yang digunakan merupakan rekaman data kelistrikan Tingkat tinggi dari sebuah rumah indekos yang dihuni oleh 7 orang selama 7 hari [1]. Pengukuran aktual berupa *Real Power* (kW) dan *Apparent Power* (kVA). Nilai *Power Factor* (PF) diperoleh melalui perhitungan menggunakan persamaan $PF=P/S$. seluruh tahapan pengolahan data, pelatihan model, dan proses prediksi dilakukan menggunakan *MATLAB R2018a*.

A. Data Penelitian

Data penelitian diperoleh dari hasil pengukuran parameter kelistrikan yang terdiri atas *Real Power* dan *Apparent Power* selama tujuh hari pengamatan. Selanjutnya, nilai *Power Factor* dihitung berdasarkan perbandingan antara *Real Power* dan *Apparent Power* sehingga diperoleh tiga parameter yang digunakan sebagai masukan model MLP.

Tabel 1. Data rekaman harian

Hari	Real Power (kW)	Apparent Power (kVA)
1	162,2554	180,7906
2	155,0452	173,4676
3	155,7388	174,2482
4	152,4227	170,7976
5	165,3632	184,1306
6	154,8861	173,4588
7	157,7194	176,5723

B. Perhitungan Power Factor

Nilai *Power Factor* dihitung berdasarkan perbandingan antara *Real Power* dan *Apparent Power* dengan persamaan berikut.

$$PF = \frac{P}{S}$$

Sebagai contoh pada data hari pertama diperoleh:

$$PF = \frac{162.2554}{180.7906} = 0.8975$$

Perhitungan tersebut dilakukan pada keseluruhan data sehingga diperoleh nilai *Power Factor* yang selanjutnya digunakan sebagai salah satu variabel masukan.

C. Normalisasi Data

Sebelum proses pelatihan, seluruh data dinormalisasikan menggunakan metode *Min-Max* agar berada pada rentang 0-1. Sebagai contoh normalisasi *Real Power* hari pertama:

$$\begin{aligned} x &= 162.2554 \\ x_{\min} &= 152.4227 \\ x_{\max} &= 165.3632 \end{aligned}$$

$$x_{\text{norm}} = \frac{162.2554 - 152.4227}{165.3632 - 152.4227}$$

$$x_{\text{norm}} = 0,7599$$

D. Pembentukan Data Input dan Target

Model MLP menggunakan tiga variable masukan, yaitu: *Real Power*, *Apparent Power*, dan *Power Factor*. Dengan skema tersebut diperoleh enam pasang data yang digunakan dalam proses pelatihan jaringan.


E. Arsitektur Jaringan MLP

Jaringan MLP yang digunakan terdiri atas tiga lapisan yaitu *input layer*, *hidden layer* dan *output layer*. *Input layer* memiliki tiga neuron yang mewakili variable *Real Power*, *Apparent Power*, dan *Power Factor*, sedangkan *hidden layer* terdiri atas lima neuron dengan fungsi aktivasi *tansig*. *Output layer* memiliki satu neuron dengan fungsi aktivasi *purelin* yang menghasilkan prediksi *Real Power*.

F. Proses Pelatihan dan Prediksi

Tahapan penelitian diawali dengan pembacaan data dari *Microsoft Excel*, kemudian dilakukan perhitungan *Power Factor*, normalisasi data menggunakan metode *Min-Max*, serta pembentukan pasangan input dan target. Selanjutnya dibangun model MLP untuk proses pelatihan menggunakan *algoritma trainlm*. Setelah model selesai dilatih, jaringan digunakan untuk memprediksi nilai *Real Power* pada hari berikutnya. Hasil prediksi kemudian dikembalikan ke skala asli melalui proses denormalisasi dan evaluasi menggunakan nilai *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

G. Flowchart



Gambar 1. Flowchart metode penelitian MLP.

Tahapan penelitian secara keseluruhan seperti Gambar 1. Flowchart menunjukkan urutan proses mulai dari pengambilan data, perhitungan *Power Factor*, normalisasi, pembentukan data masukan dan target, pelatihan jaringan MLP, proses prediksi, hingga evaluasi kinerja model menggunakan parameter MSE, RMSE, dan MAPE.

IV. HASIL DAN PEMBAHASAN

A. Hasil Pengolahan Data

Tahapan awal penelitian dilakukan dengan mengolah data hasil pengukuran yang terdiri atas *Real Power* dan

Apparent Power selama tujuh hari. Selanjutnya nilai *Power Factor* dihitung menggunakan persamaan $PF=P/S$. Ketiga variabel tersebut digunakan sebagai data masukan pada proses pelatihan jaringan saraf tiruan.

Sebelum proses pelatihan dilakukan, seluruh data dinormalisasi menggunakan metode *Min-Max* agar berada pada rentang 0–1. Normalisasi bertujuan mengurangi perbedaan skala antarvariabel sehingga proses pembelajaran jaringan menjadi lebih stabil dan konvergen.

Tabel 2. Tabel *Real Power*, *Apparent Power*, dan *Power Factor*

Hari	Real Power (kW)	Apparent Power (kVA)	Power Factor
1	162,2554	180,7906	0,897476971
2	155,0452	173,4676	0,893799188
3	155,7388	174,2482	0,89377566
4	152,4227	170,7976	0,892417107
5	165,3632	184,1306	0,898075605
6	154,8861	173,4588	0,892927312
7	157,7194	176,5723	0,89322844


B. Hasil Pelatihan Jaringan Multi Layer Perceptron

Model prediksi dibangun menggunakan arsitektur 3-5-1, yang terdiri atas tiga neuron pada lapisan input, lima neuron pada *hidden layer*, dan satu neuron pada lapisan *output*. Fungsi aktivasi yang digunakan Adalah tansig pada *hidden layer* dan *purelin* pada *output layer*, sedangkan proses pelatihan menggunakan *algoritma Levenberg*-

C. Hasil Training Jaringan


Selama proses pengujian, MATLAB menghasilkan beberapa grafik yang digunakan untuk mengevaluasi proses pembelajaran jaringan.

Performance plot menunjukkan perubahan nilai *Mean Square Error* (MSE) terhadap jumlah epoch selama proses pelatihan. Grafik ini digunakan untuk mengetahui apakah jaringan telah menjapai kondisi konvergen.




Gambar 2. *Performance plot*.

Setelah pengujian pada Gambar 2, nilai MSE mengalami penurunan seiring bertambahnya jumlah epoch hingga mencapai kondisi terbaik (*best performance*). Hal tersebut menunjukkan bahwa proses pelatihan berhasil meminimalisir kesalahan prediksi dan jaringan mampu mempelajari hubungan antara variabel masukan.



Gambar 3. *Training state*.


Berdasarkan Gambar 3, menunjukkan kondisi pelatihan jaringan selama proses optimasi. Penurunan nilai gradien mengindikasikan bahwa bobot jaringan semakin mendekati kondisi optimum sehingga proses pelatihan dapat dihentikan sesuai kriteria yang telah ditentukan.



Gambar 4. *Regresi plot*


Nilai koefisien regresi (R) yang mendekati 1 menunjukkan bahwa hasil prediksi memiliki tingkat kesesuaian yang baik terhadap data aktual. Semakin tinggi nilai R, semakin baik kemampuan jaringan dalam memodelkan pola data.

D. Hasil Prediksi Beban Listrik



Gambar 5. Perbandingan data aktual dan prediksi.

Memperlihatkan bahwa pola hasil prediksi mengikuti kecenderungan perubahan data aktual. Meskipun terdapat selisih pada beberapa titik pengamatan, secara umum model mengikuti perubahan beban Listrik harian sehingga dapat digunakan sebagai model prediksi jangka pendek.



Gambar 6. Error histogram.

Berdasarkan Gambar 6, Sebagian besar nilai error berada di sekitar nol. Hal tersebut menunjukkan bahwa model memiliki Tingkat kesalahan yang relative kecil dan hasil prediksi masih berapa dalam batas yang dapat diterima.

E. Evaluasi Model

Parameter	Nilai
MSE	0.223119
RME	0.472355
MAPE	0.2226 %


Tabel 3. Hasil evaluasi model.

Nilai MSE menunjukkan rata-rata kuadrat kesalahan antara hasil prediksi dan data aktual. Nilai RMSE menggambarkan besar penyimpangan prediksi terhadap data sebenarnya dalam satuan yang sama dengan variabel target, sedangkan MAPE menunjukkan persenatse kesalahan rata-rata model. Semakin kecil nilai ketiga parameter tersebut, semakin baik kemampuan model dalam melakukan prediksi.

F. Prediksi Real Power Hari ke-8 hingga ke-10

Tabel 4. Hasil prediksi hari ke-8 hingga ke-10

Hari	Real Power (kW)	Apparent Power (kVA)	Power Factor
8	142.71	159.54	0.89453
9	149.21	166.8	0.89453
10	152.8	170.81	0.89453



Gambar 7. Grafik prediksi hari ke-8 hingga hari ke-10

Dari Tabel 4, dan Gambar 7 menunjukkan hasil prediksi beban listrik setelah periode pengamatan berakhir. Nilai prediksi diperoleh dari model MLP yang telah dilatih menggunakan data histori. Hasil tersebut memberikan Gambaran mengenai kecenderungan perubahan beban listrik pada periode berikutnya dan dapat dimanfaatkan sebagai informasi pendukung dalam perencanaan operasi sistem tenaga listrik.

V. KESIMPULAN

Penelitian ini berhasil menerapkan metode *Multi Layer Perceptron* (MLP) untuk memprediksi beban listrik menggunakan rekaman data kelistrikan dari sebuah rumah indekos dengan variabel *Real Power*, *Apparent Power*, dan *Power Factor* sebagai data masukan. Tahapan penelitian meliputi perhitungan *Power Factor*, normalisasi data menggunakan metode *Min-Max*, pembentukan data input dan target, pelatihan jaringan MLP, serta evaluasi menggunakan MSE, RMSE, dan MAPE.

Berdasarkan hasil simulasi MATLAB, model MLP mampu mengikuti pola perubahan data historis dan menghasilkan prediksi *Real Power* pada periode berikutnya. Meskipun demikian, jumlah data yang terbatas menyebabkan kemampuan generalisasi model masih belum optimal. Oleh karena itu penelitian selanjutnya disarankan menggunakan data historis lebih banyak serta melakukan optimasi parameter jaringan agar akurasi prediksi dapat ditingkatkan.

REFERENSI

- [1] N. D. Sidiq, "Analisa Listrik Kos," Kaggle, 2026. [Online]. Available: <https://www.kaggle.com/datasets/nauvaldhonandsidiq/analisa-listrik-kos>
- [2] G. Dudek, "Multilayer Perceptron for Short-Term Load Forecasting: From Global to Local Approach," *Neural Computing and Applications*, vol. 32, no. 10, pp. 3695–3707, 2020, doi: 10.1007/s00521-019-04130-y.
- [3] F. Baskoro, F. Alamsyah, B. Suprianto, and W. Ariwibowo, "Peramalan Beban Listrik Harian Menggunakan Artificial Neural Network," *Jurnal Teknik Elektro*, vol. 10, no. 1, pp. 203–209, 2021, doi: 10.26740/jte.v10n1.p203-209.
- [4] P. V. Matrenin, V. Z. Manusov, A. I. Khalyasmaa, D. V. Antonenkov, S. A. Eroshenko, and D. N. Butusov, "Improving Accuracy and Generalization Performance of Small-Size Recurrent Neural Networks Applied to Short-Term Load Forecasting," *Mathematics*, vol. 8, no. 12, p. 2169, 2020, doi: 10.3390/math8122169.
- [5] Z. Hamad and I. Abdulrahman, "Deep Learning-Based Load Forecasting Considering Data Reshaping Using MATLAB/Simulink," *International Journal of Energy and Environmental Engineering*, vol. 13, no. 2, pp. 853–869, 2022, doi: 10.1007/s40095-022-00480-x.
- [6] Y. Chen and D. Zhang, "Theory-Guided Deep Learning for Electrical Load Forecasting (TgDLF) via Ensemble Long Short-Term Memory," *Advances in Applied Energy*, vol. 1, p. 100004, 2021, doi: 10.1016/j.adapen.2020.100004.