

Klasifikasi Beban Listrik menggunakan *Feed – Forward Neural Network* pada Gedung Bertingkat**Ony Ramadhan Armanto¹, Masyitah Aulia², Moh. Yasya Bahrul Ulum³**ony.ramadhan@utssurabaya.ac.id¹, masyitah.aulia@utssurabaya.ac.id²,yasya.bahrul@utssurabaya.ac.id³^{1,2,3} Universitas Teknologi Surabaya**Informasi Artikel**

Diterima : 2 Jun 2025
Direvisi : 28 Jun 2025
Disetujui : 3 Agu 2025

Kata Kunci

Monitoring Energi,
Jaringan Syaraf Buatan,
Feed – Forward Neural
Network, Konsumsi
Energi, Klasifikasi Beban

Abstrak

Konsumsi energi listrik dari tahun ke tahun selalu meningkat sehingga kurang efisien dalam pengelolaannya. Hal ini cukup menjadi perhatian utama dalam sistem kelistrikan modern, terutama dalam sistem monitoring energi berbasis *Smart Grid*. Semakin mudah nya penggunaan teknologi semakin besar juga beban energi yang digunakan, Sehingga diperlukan adanya kemampuan untuk mengidentifikasi jenis beban listrik yang digunakan dalam suatu instalasi listrik maka diperlukan Klasifikasi Beban Listrik. Dan untuk menunjang kemampuan dari klasifikasi beban listrik maka dibantu dengan *Feed – Forward Neural Network*. Hasil dari penelitian ini menunjukkan akurasi sebesar 99.03% dengan nilai MAPE 6.43% serta RSPM 0.098 yang mengindikasikan performa klasifikasi yang sangat baik.

Keywords

Energy Monitoring, Artificial
Neural Network, Feed –
Forward Neural Network,
Energy Consumption, Load
Classification

Abstract

Electricity consumption continues to increase year by year, leading to inefficiencies in energy management. This issue has become a major concern in modern power systems, particularly in energy monitoring systems based on Smart Grid technology. As the use of technology becomes more accessible, energy loads also grow significantly. Therefore, the ability to identify the types of electrical loads used in an installation is crucial, necessitating the implementation of load classification systems. To support the performance of electrical load classification, a Feed-Forward Neural Network (FFNN) is utilized. The results of this study show that the classification model achieved an accuracy of 99.03% with an error rate of 6.43%, and the RSME 0.098, indicating excellent classification performance.

A. Pendahuluan


Daya yang digunakan untuk tenaga listrik pada dasarnya adalah energi yang difungsikan sebagai tenaga bantu untuk semua kegiatan manusia dari kegiatan rumah tangga (*Residential*), Komerisal (*Commercial*) hingga Industri (*Industrial*). Energi listrik dari sektor tersebut banyak digunakan secara tidak efektif, Hal ini disebabkan karena penggunaan energi listrik tidak merata dari beban terpasang[1]. Beban tidak merata tersebut menimbulkan suatu permasalahan dalam Kualitas Daya Listrik (*Power Quality*)[2]. Kualitas Daya Listrik merupakan ukuran dari daya listrik beban dan energi yang dilihat dari sisi tegangan (*Voltage*) dan arus (*Current*) sehingga jika terjadi gangguan maka akan menurunkan Kualitas Daya Listrik. Salah satu gangguan dari Kualitas Daya Listrik yaitu Ketidakseimbangan Beban (*Unbalanced Load*)[3].

Ketidakseimbangan beban adalah gangguan yang terjadi akibat pemerataan beban terletak dalam salah satu fasa. Hal ini dikarenakan pemasangan instalasi yang salah dan kurang baik[4]. Akibatnya energi yang tersalurkan tidak efisien, dan pembebanan kurang maksimal. Dalam sistem tiga fasa ketidakseimbangan beban dapat menyebabkan gangguan arus dan tegangan tidak merata dan mengakibatkan gangguan lanjutan akibat tidak meratanya arus dan tegangan[3], [5]. Untuk meminimalisir terjadinya gangguan maka digunakan jaringan syaraf buatan (*Artificial Neural Network*).

Jaringan Syaraf Buatan adalah salah satu bagian dari kecerdasan buatan yang sudah lama dibenamkan dalam teknologi untuk memudahkan pekerjaan manusia khususnya teknologi modern[6]. Salah satu metode dari Jaringan Syaraf Buatan yang sering digunakan adalah *Feed – Forward Neural Network* , Metode ini bekerja dengan menyusun lapisan – lapisan neuron secara berurutan, serta metode ini efektif jika data yang digunakan *non – liniear* sehingga dapat memodelkan hubungan kompleks tiap parameter[4], [7].

B. Metode Penelitian

Penelitian ini menggunakan salah satu metode dari *Artificial Neural Network* sebagai metode penelitian yaitu *Feed – Forward Neural Network* , kemudian untuk diagram penelitian sebagai berikut:



Gambar 1. Diagram Penelitian pada Gedung Bertingkat

Pada metode penelitian dimulai dari pengambilan data pada ruang kelistrikan menggunakan alat yaitu *Smart Meter Logger*, digunakan untuk menyimpan data hasil pembacaan dari panel kelistrikan atau panel pembebanan[8]. Kemudian beberapa data yang dikumpulkan diantaranya yaitu :

1. Data Jam , hari dan tanggal
2. Data Arus Tiap Fasa (A)
3. Data Tegangan tiap fasa (V)
4. Data Power Factor
5. Data Daya Nyata (Kw)
6. Data Daya Semu (VA)
7. Data Daya Reaktif (KVar)

Data yang dikumpulkan adalah data dengan rentang waktu 30 hari atau dalam 1 bulan. Pengambilan tersimpan kemudian dipindah untuk diolah dan dilakukan *Preprocessing Data*. Pada *Preprocessing Data* dilakukan pemilahan data yang terjadi diantaranya yaitu:

1. Data Hilang (*Missing Data*)
2. Data Berulang (*Repeated Data*)
3. Data Error (*Error Data*)


Jumlah data yang dari 1 bulan yaitu 8065 data lampau (*Historical*) yang dibagi menjadi 60% Training dan 40% Testing kemudian akan dilakukan training

menggunakan metode *Feed-Forward Neural Network*. Peralatan yang digunakan untuk training menggunakan aplikasi Matlab sebagai media bantu. Kemudian untuk training dilakukan jumlah hidden layer dan neuron dalam tabel berikut.

Tabel 1. Jumlah Hidden Layer dan Neuron

No	Hidden Layer	Neuron
1	3 Layer	10 Neuron
2	5 Layer	10 Neuron
3	10 Layer	10 Neuron
4	20 Layer	10 Neuron
5	50 Layer	10 Neuron
6	100 Layer	10 Neuron

Kemudian setelah menentukan jumlah hidden layer dan neuron ditentukan arsitektur jaringan dari *Feed – Forward Neural Network* , untuk penelitian ini menggunakan arsitektur jaringan 3 Hidden Layer dengan hidden layer 1 dan 2 kemudian hidden layer untuk output.



Gambar 2. Arsitektur Jaringan Feed - Forward Neural Network

Serta indikator penentuan bagus tidaknya suatu model dapat ditentukan dari error yang dapat dilihat dari nilai persentase rata – rata nilai eror (MAPE) dan Akar dari rata – rata kesalahan (RSME). Dapat dilihat dari tabel berikut.

Tabel 2. Indikator RMSE dan MAPE

No	RSMSE	MAPE	Hasil
1	0	<10%	Sangat Bagus
2	<0.2	10% - 20%	Bagus
3	0.2 - 0.3	20% - 30%	Cukup
4	> 0.3	>30%	Buruk

Kemudian setelah keluar hasil MAPE dan RMSE dapat memberikan nilai akurasi dari model dengan arsitektur jaringan syaraf buatan yang terbaik . Kemudian untuk Akurasi dari tiap hidden layer dapat dihitung dengan menggunakan rumus berikut:

$$\text{Akurasi} = (\text{Jumlah Prediksi} / \text{Total Jumlah Prediksi}) \times 100\% \quad (1)$$

C. Hasil dan Pembahasan

Setelah melakukan training dengan data selama 1 bulan dengan pembagian data berjumlah 60% , maka hasil nya sebagai berikut.

Tabel 3. Hasil RMSE dan MAPE

No	Hidden Layer	Neuron	RMSE (<i>Root Mean Square Error</i>)	MAPE (<i>Mean Absolite Percentage Error</i>)
1	3 Layer	10 Neuron	0.1538	18.00%
2	5 Layer	10 Neuron	0.1439	15.07%
3	10 Layer	10 Neuron	0.1406	15.18%
4	20 Layer	10 Neuron	0.2558	68.59%
5	50 Layer	10 Neuron	0.0984	6.43%
6	100 Layer	10 Neuron	0.1023	8.69%

Hasil dari training dan testing menunjukkan bahwa nilai RMSE dan MAPE terbaik ada pada 50 layer dengan 10 neuron. Hasil tersebut jika melihat tabel 2 dapat dikategorikan sebagai sangat bagus. Hal ini menunjukkan model data dan training berjalan dengan baik serta testing data dilakukan dengan sangat bagus. Berikut adalah akurasi dari tiap hidden layer dan neuron dari model data masing – masing.

Tabel 4. Akurasi Tiap Hidden Layer

No	Hidden Layer	Neuron	Akurasi
1	3 Hidden Layer	10 Neuron	97.64%
2	5 Hidden Layer	10 Neuron	98.04%
3	10 Hidden Layer	10 Neuron	98.02%
4	20 Hidden Layer	10 Neuron	93.46%
5	50 Hidden Layer	10 Neuron	99.03%
6	100 Hidden Layer	10 Neuron	98.95%

Hasil tabel 4 merupakan hasil akurasi dari tiap hidden layer dengan memperlihatkan pada 50 hidden layer menunjukkan akurasi sebesar 99.03% dan untuk akurasi kurang akurat terdapat pada 20 hidden layer . Sehingga *Confusion Matrix* dari model data 50 hidden layer yaitu :



Gambar 3. Confusion Matrix

Hasil dari *Confusion Matrix* menunjukkan pada tahap pelatihan (*Training Confusion Matrix*) menunjukkan performa sangat tinggi dengan hampir prediksi pada target hampir benar dengan tingkat kesalahan kecil yaitu 0.4% dan akurasi keseluruhan yaitu 99%. Kemudian untuk *Testing Confusion Matrix* menunjukkan model mampu mengenali dan mengetahui beban seimbang dan tidak seimbang dengan akurat, Ketidakakuratan dari model hampir kurang dari 1% hingga memiliki akurasi keseluruhan yaitu 98.6%.

Sehingga *All Confusion Matrix* yang merupakan hasil gabungan dari data training dengan data testing yaitu untuk memberikan hasil performa model secara menyeluruh dengan akurasi sebesar 98.6% serta menunjukkan konsistensi model kepada seluruh data training dan testing.

D. Simpulan

Dari hasil diatas penelitian ini dapat menggunakan model jaringan syaraf buatan dengan 50 Hidden Layer dengan 10 Neuron yang memiliki akurasi sebesar 98.6% dan juga hasil error yaitu MAPE sebesar 6.43% dan RMSE sebesar 0.0984. Maka model ini dapat direkomendasikan untuk mengetahui ketidakseimbangan beban pada suatu gedung bertingkat dengan akurasi akurat.

E. Ucapan Terima Kasih

Terima kasih peneliti ucapkan kepada dosen teknik elektro Universitas Teknologi Surabaya yang telah membantu saya dalam penelitian ini dan juga khususnya kepada Prof. Novie Ayub Windarko yang telah membagi ilmu kepada

dan juga saya ucapkan terima kasih kepada Universitas Teknologi Surabaya karena telah mewadahi penelitian saya.

F. Referensi

- [1] K. Zhou, S. Yang, and C. Shen, "A review of electric load classification in smart grid environment," *Renewable and Sustainable Energy Reviews*, vol. 24, pp. 103–110, Aug. 2013, doi: 10.1016/j.rser.2013.03.023.
- [2] A. Miron, A. C. Cziker, and H. G. Beleiu, "Fuzzy Control Systems for Power Quality Improvement—A Systematic Review Exploring Their Efficacy and Efficiency," *Applied Sciences*, vol. 14, no. 11, p. 4468, May 2024, doi: 10.3390/app14114468.
- [3] R. You and X. Lu, "Voltage Unbalance Compensation in Distribution Feeders Using Soft Open Points," *Journal of Modern Power Systems and Clean Energy*, vol. 10, no. 4, pp. 1000–1008, 2022, doi: 10.35833/MPCE.2021.000565.
- [4] L. Alhmoud, R. Abu Khurma, A. M. Al-Zoubi, and I. Aljarah, "A Real-Time Electrical Load Forecasting in Jordan Using an Enhanced Evolutionary Feedforward Neural Network," *Sensors*, vol. 21, no. 18, p. 6240, Sep. 2021, doi: 10.3390/s21186240.
- [5] N. Kongtrakul, W. Wangdee, and S. Chantaraskul, "Comprehensive review and a novel technique on voltage unbalance compensation," *IET Smart Grid*, vol. 6, no. 4, pp. 331–358, Aug. 2023, doi: 10.1049/stg2.12106.
- [6] M. Ghiassi, D. K. Zimbra, and H. Saidane, "Medium term system load forecasting with a dynamic artificial neural network model," *Electric Power Systems Research*, vol. 76, no. 5, pp. 302–316, Mar. 2006, doi: 10.1016/j.epsr.2005.06.010.
- [7] P. Bunnoon, K. Chalermyanont, and C. Limsakul, "Mid-Term Load Forecasting: Level Suitably of Wavelet and Neural Network based on Factor Selection," *Energy Procedia*, vol. 14, pp. 438–444, 2012, doi: 10.1016/j.egypro.2011.12.955.
- [8] Y.-C. Chen, S. S. Berutu, and Y.-H. Wang, "Smart Meter Development for Cloud-Based Home Electricity Monitor System," vol. 18, no. 4, 2020.