



Implementation of Hybrid Backpropagation Neural Network and Particle Swarm Optimization for Predicting Household Electricity Consumption Based On Tariff Categories

Implementasi Metode Hybrid Backpropagation Neural Network dan Particle Swarm Optimization untuk Prediksi Konsumsi Listrik Rumah Tangga Berdasarkan Golongan Tarif

Yuni Artha Chyntia Saragih^{1*}, Erma Suryani²

^{1,2}Sekolah Interdisiplin Manajemen dan Teknologi, Institut Teknologi Sepuluh Nopember, Indonesia

E-Mail: ¹yuniartha0@gmail.com, ²erma@its.ac.id

Received Jan 13th 2026; Revised Feb 23th 2026; Accepted Mar 27th 2026; Available Online Apr 23th 2026

Corresponding Author: Yuni Artha Chyntia Saragih

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Electricity consumption in the household sector continues to increase along with population growth and socio-economic development. This study proposes a hybrid forecasting model that integrates a Backpropagation Neural Network (BPNN) with Particle Swarm Optimization (PSO) to improve the accuracy of household electricity consumption prediction by tariff category. Historical monthly electricity sales data from 2020 to 2024 were used as the dataset, consisting of customer count, connected power, and energy consumption. The results show that the BPNN-PSO model outperforms the conventional BPNN model. The optimization process reduced the Mean Absolute Percentage Error (MAPE) from 57.97% to 46.38% and improved the coefficient of determination (R^2) from -0.2403 to 0.1831. Furthermore, the proposed model was used to forecast electricity demand for the 2025–2029 period, indicating consistent growth trends. The findings demonstrate that the hybrid BPNN-PSO approach provides a more reliable forecasting tool to support strategic planning and decision-making in the electricity sector.

Keywords: *Backpropagation, Electricity Consumption, Forecasting, Household Tariff, Particle Swarm Optimization*

Abstrak

Konsumsi listrik pada sektor rumah tangga terus meningkat seiring dengan pertumbuhan penduduk dan perkembangan sosial ekonomi. Penelitian ini mengusulkan model peramalan hybrid yang mengintegrasikan *Backpropagation Neural Network* (BPNN) dengan *Particle Swarm Optimization* (PSO) untuk meningkatkan akurasi prediksi konsumsi listrik rumah tangga berdasarkan golongan tarif. Data historis penjualan listrik bulanan periode 2020 sampai dengan 2024 digunakan sebagai dataset, yang mencakup jumlah pelanggan, daya tersambung, dan konsumsi energi. Hasil penelitian menunjukkan bahwa model BPNN-PSO memiliki kinerja yang lebih baik dibandingkan dengan BPNN murni. Proses optimasi berhasil menurunkan nilai *Mean Absolute Percentage Error* (MAPE) dari 57,97% menjadi 46,38% serta meningkatkan nilai koefisien determinasi (R^2) dari -0,2403 menjadi 0,1831. Model yang diusulkan kemudian digunakan untuk memproyeksikan kebutuhan listrik periode 2025–2029 dan menunjukkan adanya tren pertumbuhan yang konsisten. Temuan ini membuktikan bahwa pendekatan *hybrid* BPNN-PSO dapat menjadi alat peramalan yang lebih andal dalam mendukung perencanaan dan pengambilan keputusan di sektor ketenagalistrikan.

Kata Kunci: *Backpropagation, Konsumsi Listrik, Prediksi, Particle Swarm Optimization, Tarif Rumah Tangga*

1. PENDAHULUAN

Energi listrik merupakan salah satu kebutuhan utama yang menopang aktivitas sosial dan ekonomi masyarakat, khususnya pada sektor rumah tangga yang menjadi kontributor terbesar dalam konsumsi energi listrik. Seiring pertumbuhan penduduk dan peningkatan aktivitas ekonomi, permintaan listrik terus meningkat sehingga menuntut adanya perencanaan sistem ketenagalistrikan yang lebih akurat dan berkelanjutan [1]. Ketepatan dalam memprediksi konsumsi listrik menjadi faktor krusial karena berpengaruh langsung terhadap

perencanaan kapasitas pembangkit, pengelolaan jaringan distribusi, serta pengambilan keputusan strategis oleh penyedia tenaga listrik [1].

Prediksi konsumsi energi listrik telah menjadi topik penting dalam perencanaan sistem tenaga karena berdampak langsung pada keandalan dan efisiensi sistem ketenagalistrikan [8]. Berbagai studi menunjukkan bahwa metode berbasis machine learning memiliki performa yang lebih baik dibandingkan metode statistik konvensional dalam memodelkan pola data beban listrik yang bersifat non-linear [9], [21]. Salah satu metode yang banyak digunakan adalah *Artificial Neural Network* (ANN), khususnya *Backpropagation Neural Network* (BPNN), karena kemampuannya dalam menangkap pola kompleks pada data deret waktu [2], [10], [22]. Penelitian menunjukkan bahwa BPNN mampu memberikan hasil prediksi yang cukup akurat pada peramalan energi jangka menengah dan panjang [11], [23].

Namun demikian, performa BPNN sangat dipengaruhi oleh pemilihan parameter seperti learning rate, jumlah neuron, dan inisialisasi bobot awal [12]. Kelemahan utama BPNN adalah kecenderungan terjebak pada solusi lokal (*local optimum*) serta proses konvergensi yang relatif lambat, sehingga dapat menurunkan kualitas prediksi [4], [13]. Untuk mengatasi permasalahan tersebut, berbagai pendekatan optimasi telah dikembangkan, salah satunya melalui integrasi algoritma evolusioner seperti *Particle Swarm Optimization* (PSO) [14]. PSO dinilai lebih sederhana dan efisien dibandingkan algoritma optimasi lain karena memiliki mekanisme pencarian global yang efektif [15], [24].

Sejumlah penelitian menunjukkan bahwa integrasi PSO dalam pelatihan ANN mampu meningkatkan akurasi prediksi secara signifikan dibandingkan ANN murni [16]. Model *hybrid* BPNN–PSO telah diterapkan pada berbagai kasus peramalan dengan hasil performa yang lebih stabil dan error yang lebih rendah [17]. Studi lain juga melaporkan bahwa pendekatan *hybrid* mampu mengurangi nilai error seperti MAPE dan RMSE secara konsisten pada data deret waktu energi [18], serta lebih adaptif dalam menangani fluktuasi konsumsi energi yang dinamis [19], [25].

Secara khusus, beberapa penelitian terdahulu terkait BPNN–PSO menunjukkan hasil yang menjanjikan, namun masih memiliki keterbatasan. Penelitian pertama menunjukkan bahwa model BPNN–PSO mampu meningkatkan akurasi prediksi beban listrik, namun masih menggunakan data agregat sehingga tidak mampu merepresentasikan variasi konsumsi pada tingkat pelanggan [16]. Penelitian kedua mengembangkan model *hybrid* untuk prediksi energi, tetapi belum mempertimbangkan segmentasi pelanggan berdasarkan golongan tarif [17]. Penelitian ketiga menunjukkan bahwa metode BPNN–PSO dapat menurunkan error prediksi secara signifikan, namun belum menguji stabilitas model pada data dengan fluktuasi tinggi [18]. Sementara itu, penelitian keempat mengonfirmasi keunggulan metode *hybrid* dalam meningkatkan performa model, tetapi masih terbatas pada skala sistem makro dan belum diterapkan pada level unit layanan pelanggan [19].

Berdasarkan hasil analisis tersebut, dapat diidentifikasi beberapa gap penelitian, yaitu: (1) sebagian besar penelitian masih berfokus pada skala agregat atau makro, (2) belum mempertimbangkan karakteristik konsumsi listrik sektor rumah tangga berdasarkan golongan tarif, dan (3) belum banyak penelitian yang dilakukan pada level unit layanan pelanggan. Padahal, informasi prediksi yang lebih rinci sangat penting untuk mendukung perencanaan distribusi, evaluasi kebijakan tarif, serta peningkatan kualitas pelayanan pelanggan.

Oleh karena itu, penelitian ini memiliki urgensi untuk mengembangkan model prediksi yang lebih akurat dan spesifik pada sektor rumah tangga. Tujuan penelitian ini adalah: (1) mengembangkan model prediksi konsumsi listrik menggunakan *Backpropagation Neural Network* (BPNN), (2) mengoptimalkan model menggunakan *Particle Swarm Optimization* (PSO), dan (3) membandingkan kinerja model BPNN dengan model *hybrid* BPNN–PSO.

Kontribusi utama penelitian ini adalah penerapan metode *hybrid* BPNN–PSO untuk prediksi konsumsi listrik rumah tangga berbasis golongan tarif pada level unit layanan pelanggan, yang masih terbatas dalam penelitian sebelumnya. Selain itu, penelitian ini juga memberikan analisis komparatif antara model BPNN dan BPNN–PSO dalam meningkatkan akurasi prediksi, sehingga dapat menjadi referensi dalam pengembangan model prediksi konsumsi listrik di sektor ketenagalistrikan [20].


2. BAHAN DAN METODE

Penelitian ini bertujuan mengembangkan dan membandingkan model *Backpropagation Neural Network* (BPNN) dan *hybrid* BPNN–PSO dalam memprediksi konsumsi listrik rumah tangga. Tahapan penelitian meliputi pengumpulan data historis, pra-pemrosesan data, pembagian data latih dan validasi, pelatihan model, serta evaluasi kinerja menggunakan metrik MAPE dan R^2 . Alur metodologi penelitian secara keseluruhan ditunjukkan pada Gambar 1.

2.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen komparatif untuk membandingkan kinerja model BPNN dan *hybrid* BPNN–PSO dalam memprediksi konsumsi listrik rumah

tangga. Pendekatan eksperimen umum digunakan dalam studi prediksi beban listrik berbasis kecerdasan buatan karena memungkinkan evaluasi objektif terhadap performa model [3].



Gambar 1. Metodologi Penelitian

2.2. Dataset dan Pengumpulan Data

Data yang digunakan berupa data historis *time series* bulanan periode 2020–2024 yang mencakup jumlah pelanggan, daya tersambung, dan konsumsi energi listrik sektor rumah tangga. Penggunaan data historis sebagai dasar peramalan beban listrik merupakan praktik umum dalam penelitian prediksi permintaan energi [6].

2.3. Pra-Pemrosesan Data

Tahapan pra-pemrosesan meliputi pembersihan data, normalisasi, serta penyesuaian format data sebelum masuk ke proses pemodelan. Normalisasi dilakukan untuk menyetarakan skala antar variabel sehingga proses pembelajaran jaringan saraf menjadi lebih stabil dan efisien [2]. Tahap pra-pemrosesan merupakan langkah penting dalam pemodelan ANN karena sangat memengaruhi kualitas hasil prediksi [1].

2.4. Pemodelan *Backpropagation Neural Network* (BPNN)

Model BPNN dibangun menggunakan arsitektur *multilayer feedforward* yang terdiri dari lapisan input, *hidden layer*, dan *output layer*. Proses pelatihan dilakukan menggunakan algoritma *backpropagation* dengan mekanisme propagasi maju dan propagasi balik untuk meminimalkan error. Metode ini banyak digunakan dalam studi peramalan beban listrik karena kemampuannya dalam memodelkan hubungan *nonlinier* pada data *time series* [2], [4]. Tahap awal dilakukan dengan inisialisasi bobot dan bias secara acak. Pada proses *forward propagation*, sinyal dari lapisan input diteruskan ke lapisan tersembunyi dan selanjutnya ke lapisan *output*. Perhitungan nilai *neuron* pada lapisan tersembunyi dirumuskan pada persamaan 1 dan 2.

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

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

Selanjutnya, nilai *neuron* pada lapisan *output* dihitung dengan persamaan 3 dan 4.

$$y_in_k = w_{0k} + \sum_{i=1}^n z_i w_{ik} \quad (3)$$

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

Setelah diperoleh *output*, dilakukan proses *backward propagation* untuk memperbarui bobot dan bias berdasarkan error yang dihasilkan. Faktor koreksi pada lapisan *output* dihitung dengan persamaan 5.

$$\delta_k = (t_k - y_k)f'(y_{in_k}) \quad (5)$$

Pembaruan bobot pada lapisan *output* dilakukan dengan Persamaan 6.

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

Selanjutnya, error dipropagasikan ke lapisan tersembunyi dengan persamaan 7.

$$\delta_{in_j} = \sum_{k=1}^n \delta_k w_{jk} \quad (7)$$

dan pembaruan bobot dilakukan sebagai berikut (Persamaan 8):

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (8)$$

Proses ini dilakukan secara iteratif hingga nilai error minimum tercapai. Dalam proses pelatihan, forward propagation digunakan untuk menghitung *output*, sedangkan backward propagation digunakan untuk memperbaiki bobot dan bias menggunakan metode gradient descent. Kombinasi kedua proses ini memungkinkan jaringan saraf untuk belajar dari kesalahan sehingga menghasilkan prediksi yang lebih akurat.

2.5. Pemodelan Hybrid BPNN–PSO

Pada model *hybrid*, algoritma *Particle Swarm Optimization* (PSO) digunakan untuk mengoptimalkan bobot dan bias awal BPNN. PSO bekerja dengan memperbarui posisi partikel berdasarkan nilai *personal best* (pbest) dan *global best* (gbest) untuk memperoleh solusi optimal. Integrasi PSO dalam pelatihan ANN terbukti mampu meningkatkan akurasi prediksi dan mengurangi risiko terjebak pada solusi lokal [5], [6].

Dalam PSO, setiap partikel merepresentasikan solusi kandidat berupa bobot dan bias jaringan saraf. Proses optimasi dilakukan dengan memperbarui kecepatan dan posisi partikel berdasarkan pengalaman terbaik individu (*personal best/pbest*) dan terbaik global (*global best/gbest*). Persamaan pembaruan kecepatan partikel dirumuskan pada Persamaan 9.

$$V_i = V_i(t-1) + c_1 r_1 [X_{pbest_i} - X_i(t)] + c_2 r_2 [X_{gbest_i} - X_i(t)] - X_i(t) \quad (9)$$

Selanjutnya, posisi partikel diperbarui dengan Persamaan 10.

$$X_i(t) = X_i(t-1) + V_i(t) \quad (10)$$

Di mana v_i adalah kecepatan partikel, x_i adalah posisi partikel, w adalah *inertia weight*, c_1 dan c_2 adalah koefisien pembelajaran, serta r_1 dan r_2 adalah bilangan acak. Pada penelitian ini, PSO digunakan untuk mengoptimalkan bobot dan bias awal BPNN sebelum proses pelatihan dilakukan. Setiap partikel merepresentasikan kombinasi bobot dan bias, kemudian dievaluasi menggunakan fungsi error dari BPNN. Hasil optimasi berupa bobot terbaik (*gbest*) digunakan sebagai inisialisasi awal dalam proses pelatihan BPNN.

Dengan pendekatan ini, model BPNN memiliki titik awal yang lebih optimal sehingga dapat meningkatkan kecepatan konvergensi, mengurangi risiko terjebak pada *local minima*, serta meningkatkan akurasi prediksi konsumsi listrik. Diagram alir sistem dapat dilihat pada Gambar 2.

2.6. Evaluasi Kinerja Model

Kinerja kedua model dievaluasi menggunakan metrik *Mean Absolute Percentage Error* (MAPE) dan koefisien determinasi (R^2). MAPE digunakan untuk mengukur tingkat kesalahan prediksi secara persentase, sedangkan R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Kedua metrik tersebut umum digunakan dalam evaluasi model prediksi beban listrik berbasis kecerdasan buatan [1], [3].

2.7. Literature Review

Penelitian terkait prediksi konsumsi energi listrik telah berkembang pesat, khususnya dengan pemanfaatan metode berbasis kecerdasan buatan seperti *Artificial Neural Network* (ANN). ANN banyak digunakan karena kemampuannya dalam memodelkan hubungan nonlinier pada data deret waktu yang kompleks [9]. Salah satu algoritma yang umum digunakan adalah *Backpropagation Neural Network* (BPNN), yang terbukti mampu memberikan hasil prediksi yang cukup akurat dalam berbagai studi peramalan energi [10], [11].


Meskipun demikian, beberapa penelitian menunjukkan bahwa performa BPNN sangat bergantung pada parameter awal, seperti bobot dan bias, serta memiliki kelemahan dalam hal konvergensi yang lambat dan kecenderungan terjebak pada local optimum [12], [13]. Hal ini menyebabkan hasil prediksi yang dihasilkan belum optimal, terutama pada data dengan tingkat fluktuasi yang tinggi.

Untuk mengatasi keterbatasan tersebut, berbagai metode optimasi telah dikembangkan dan diintegrasikan dengan ANN, salah satunya adalah *Particle Swarm Optimization* (PSO). PSO merupakan algoritma optimasi berbasis populasi yang terinspirasi dari perilaku sosial kawanan, yang memiliki kemampuan dalam melakukan pencarian global secara efektif [14], [15]. Beberapa penelitian menunjukkan bahwa PSO mampu mengoptimalkan bobot dan bias pada jaringan saraf sehingga meningkatkan kecepatan konvergensi dan akurasi model [16].

Integrasi antara BPNN dan PSO menghasilkan model *hybrid* yang dikenal sebagai BPNN-PSO. Sejumlah penelitian menunjukkan bahwa model *hybrid* ini mampu meningkatkan performa prediksi dibandingkan dengan BPNN murni. Studi menunjukkan bahwa BPNN-PSO mampu menurunkan nilai error seperti *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE), serta meningkatkan nilai koefisien determinasi (R^2) [17], [18]. Selain itu, model *hybrid* juga lebih stabil dalam menangani data deret waktu yang bersifat dinamis dan *nonlinier* [19].

Namun demikian, sebagian besar penelitian terdahulu masih berfokus pada prediksi konsumsi listrik dalam skala agregat atau sistem makro, sehingga belum mampu menggambarkan variasi konsumsi pada tingkat pelanggan secara lebih rinci. Selain itu, penelitian yang secara khusus mengkaji konsumsi listrik sektor rumah tangga berdasarkan golongan tarif masih relatif terbatas [20].

Berdasarkan kajian literatur tersebut, dapat disimpulkan bahwa meskipun metode BPNN-PSO memiliki potensi yang besar dalam meningkatkan akurasi prediksi, masih terdapat peluang penelitian untuk mengembangkan model yang lebih spesifik pada sektor rumah tangga berbasis golongan tarif serta pada level unit layanan pelanggan. Oleh karena itu, penelitian ini mengusulkan penerapan model *hybrid* BPNN-PSO untuk mengisi celah tersebut dan menghasilkan prediksi konsumsi listrik yang lebih akurat dan aplikatif dalam mendukung perencanaan sistem ketenagalistrikan.



Gambar 2. Diagram Alir Sistem

3. HASIL DAN DISKUSI

Pengumpulan data diperoleh dari laporan penjualan tenaga listrik PT XYZ dari tahun 2015 hingga 2024. Tabel 1 merupakan data yang sudah di pilih.

Tabel 1. Data Jumlah Pelanggan

Data Jumlah Pelanggan										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jan	83.511	86.133	89.455	94.178	97.878	72.640	72.640	109.544.00	112.816	116.797
Feb	83.505	86.296	89.675	94.450	98.142	102.383	101.237	109.750.00	113.082	116.989
Mar	83.638	86.664	90.993	94.751	98.429	102.702	106.293	110.047.00	113.365	117.322
Apr	84.148	86.936	91.334	95.098	98.775	103.030	102.053	110.305.00	113.520	117.563
Mei	84.363	87.204	91.648	95.540	99.065	103.254	100.227	110.047.00	113.868	118.065

Data Jumlah Pelanggan										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jun	85.316	87.454	91.944	95.670	99.416	103.536	107.394	110.853.00	114.216	118.342
Jul	85.383	87.511	92.296	95.944	99.751	99.932	102.917	111.161.00	114.509	118.724
Agu	85.587	87.844	92.671	96.501	100.106	104.352	101.412	111.541.00	114.762	119.143
Sep	85.310	88.191	92.932	96.757	100.504	104.352	67.891	111.828.00	115.007	119.348
Okt	85.562	88.621	93.196	97.106	100.940	104.570	61.051	112.101.00	115377	119.803
Nov	85.744	88.972	93.612	97.401	101.270	76.483	109.111	112.374.00	115.600	120.064
Des	85.922	89.320	93.961	97.625	101.694	105.293	109.487	112.596.00	115.258	120.363

Tabel 1 menyajikan data historis jumlah pelanggan listrik sektor rumah tangga selama periode penelitian. Data ini digunakan untuk menggambarkan pertumbuhan jumlah pengguna listrik dari waktu ke waktu serta menjadi salah satu variabel input dalam model prediksi.

Tabel 2. Data Jumlah Energi (kWh)

Data Jumlah Energi (Kwh)										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jan	9.746.887	10.418.197	9.298.155	10.129.906	11.111.544	11.265.161	11.265.161	12.386.993.80	11.304.489.54	12.378.100.64
Feb	9.200.557	10.129.884	9.445.399	9.793.809	10.235.359	10.732.009	10.777.214	11.271.959.66	10.927.921.90	12.168.517.35
Maret	10.093.138	10.513.489	10.060.276	11.732.782	10.621.691	11.770.805	12.081.341	12.230.297.10	12.227.368.18	13.385.405.83
Apr	9.942.602	10.942.706	9.528.406	8.664.570	10.832.280	11.793.972	11.584.557	12.159.680.35	12.438.204	13.426.006.33
Mei	9.950.886	10.598.621	10.467.899	10.747.626	11.816.072	12.648.366	12.392.821	12.549.135.47	13.124.968.36	14.091.508.79
Jun	10.434.492	10.722.700	9.879.816	10.457.238	10.763.189	11.940.319	11.937.991	12.070.454.00	12.580.131.98	13.319.974.30
Jul	10.313.689	10.665.840	10.306.302	10.547.565	11.010.945	11.873.282	12.273.773	12.518.055.19	12.738.972.91	13.624.503.96
Agu	10.322.198	10.452.117	10.709.611	10.595.238	11.850.935	11.650.735	12.360.659	12.226.638.38	12.720.154.14	13.465.419.79
Sep	10.170.293	10.349.292	10.093.378	10.320.767	10.229.373	11.650.735	12.418.362	11.779.449.90	12.118.287.15	12.687.127.16
Okt	10.120.225	10.381.973	10.148.250	10.309.104	11.097.419	11.671.466	12.493.058	11.825.476.29	12.476.926.07	13.031.202.20
Nov	10.239.276	10.524.972	9.982.297	10.303.228	10.214.870	11.514.841	12.327.675	11.594.397.36	12.046.906.63	12.529.373.07
Des	9.979.705	9.943.320	9.425.893	9.970.860	11.366.183	11.574.779	12.047.278	12.554.550.32	12.583.585.59	12.804.651.33

Tabel 2 menunjukkan data konsumsi energi listrik dalam satuan *kilowatt-hour* (kWh) yang digunakan oleh pelanggan rumah tangga. Data ini merupakan variabel utama dalam penelitian karena digunakan sebagai dasar dalam proses pelatihan dan evaluasi model prediksi konsumsi listrik.

Tabel 3. Data Daya Tersambung (VA)

Data Daya Tersambung (VA)										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jan	68.715.700	73.111.800	78.127.150	83.195.200	88.791.200	94.680.300	94.680.300	107.883.200.00	113.051.150	119.576.050
Feb	68.730.950	73.352.400	78.455.050	83.613.800	89.154.700	95.096.200	101.749.650	108.170.650.00	113.403.650	119.852.450
Mar	68.869.050	73.892.150	78.878.100	84.095.500	89.546.600	95.593.650	102.405.250	108.613.900.00	113.867.650	120.408.950
Apr	69.403.250	74.304.150	79.300.500	84.544.900	90.112.200	96.054.600	103.068.700	109.005.000.00	114.210.400	120.822.900
Mei	69.616.850	74.743.300	79.682.100	85.212.900	90.592.050	96.331.750	103.503.400	109.543.150.00	114.801.300	121.525.100
Jun	70.631.100	75.109.950	80.110.750	85.484.150	91.072.450	96.693.000	104.025.350	109.942.950.00	115.387.750	121.944.400
Jul	70.696.750	75.240.700	80.665.100	85.929.300	91.499.300	97.297.150	104.474.300	110.377.750.00	115.737.650	122.486.200
Agu	70.967.500	75.771.800	81.247.450	86.649.000	92.047.550	99.653.250	104.909.100	111.004.350.00	116.316.000	123.187.800
Sep	71.766.350	76.326.150	81.575.250	87.061.650	92.577.650	99.653.250	105.502.600	111.622.900.00	116.813.500	123.509.750
Okt	72.096.350	76.917.950	81.952.800	87.667.600	93.293.300	100.120.500	106.152.850	111.972.450.00	117.388.600	124.169.600
Nov	72.418.300	77.431.900	82.454.750	88.168.950	93.808.150	100.685.100	106.819.350	112.392.400.00	117.733.300	124.579.150
Des	72.854.350	77.926.900	82.922.750	88.488.900	94.344.650	101.028.050	107.512.550	112.740.300.00	118.894.650	125.000.900

Tabel 3 berisi data daya tersambung pelanggan dalam satuan *Volt-Ampere* (VA). Variabel ini mencerminkan kapasitas daya listrik yang terpasang pada pelanggan dan digunakan sebagai indikator kemampuan konsumsi energi. Data ini menjadi salah satu variabel input yang berpengaruh dalam menentukan pola konsumsi listrik.

Selanjutnya, pada tahap *preprocessing* data yang terdiri dari cleaning, transformasi dan normalisasi data. Tabel 4 merupakan hasil normalisasi data.

Tabel 4. Normalisasi Data Jumlah Pelanggan

Normalisasi Data Jumlah Pelanggan										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jan	0,1019	0,1000	0,1000	0,1000	0,1000	0,1000	0,2914	0,1000	0,1000	0,1000

Normalisasi Data Jumlah Pelanggan										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Feb	0,1000	0,1409	0,1390	0,1631	0,1553	0,8287	0,7637	0,1539	0,1618	0,1430
Mar	0,1427	0,2332	0,3730	0,2329	0,2155	0,8365	0,8472	0,2318	0,2276	0,2177
Apr	0,3068	0,3015	0,4335	0,3135	0,2880	0,8445	0,7772	0,2994	0,2636	0,2718
Mei	0,3759	0,3688	0,4893	0,4161	0,3488	0,8500	0,7470	0,2318	0,3445	0,3844
Jun	0,6825	0,4315	0,5418	0,4462	0,4224	0,8569	0,8654	0,4431	0,4253	0,4466
Jul	0,7041	0,4459	0,6043	0,5098	0,4926	0,7686	0,7914	0,5238	0,4934	0,5323
Agu	0,7697	0,5294	0,6709	0,6391	0,5670	0,8769	0,7666	0,6234	0,5522	0,6263
Sep	0,6806	0,6165	0,7173	0,6985	0,6505	0,8769	0,2129	0,6986	0,6092	0,6722
Okt	0,7616	0,7245	0,7641	0,7795	0,7419	0,8822	0,9000	0,7702	0,6952	0,7743
Nov	0,8202	0,8126	0,8380	0,8480	0,8111	0,1941	0,8937	0,8418	0,7470	0,8329
Des	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000

Tabel 4 menampilkan hasil normalisasi data jumlah pelanggan yang telah ditransformasikan ke dalam skala tertentu, yaitu 0 sampai dengan 1. Tujuan normalisasi adalah untuk menyetarakan skala data sehingga tidak terjadi dominasi variabel tertentu dalam proses pelatihan model, serta meningkatkan stabilitas dan kecepatan konvergensi pada algoritma BPNN.

Tabel 5. Normalisasi Data Jumlah Energi

Normalisasi Data Jumlah Energi										
BULAN	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jan	0,4542	0,4801	0,1000	0,4820	0,5384	0,3225	0,3275	0,7954	0,2371	0,1871
Feb	0,1000	0,2493	0,1879	0,3944	0,1100	0,1000	0,1000	0,1000	0,1000	0,1000
Mar	0,6786	0,5564	0,5342	0,9000	0,2989	0,5336	0,7080	0,6975	0,5731	0,6062
Apr	0,5810	0,9000	0,2347	0,1000	0,4018	0,5433	0,4764	0,6537	0,6499	0,6231
Mei	0,5864	0,6245	0,7638	0,6431	0,8829	0,9000	0,8532	0,8966	0,9000	0,9000
Jun	0,9000	0,7238	0,4326	0,5674	0,3681	0,6044	0,6412	0,5980	0,7016	0,5790
Jul	0,8216	0,6783	0,6728	0,5909	0,4892	0,5764	0,7977	0,8772	0,7594	0,7057
Agu	0,8271	0,5072	0,9000	0,6033	0,9000	0,4835	0,8382	0,6954	0,7525	0,6395
Sep	0,7287	0,4249	0,5529	0,5318	0,1070	0,4835	0,8651	0,4165	0,5334	0,3157
Okt	0,6962	0,4511	0,5838	0,5287	0,5315	0,4921	0,9000	0,4452	0,6640	0,4588
Nov	0,7734	0,5656	0,4903	0,5276	0,1000	0,4268	0,8228	0,3011	0,5074	0,2501
Des	0,6051	0,1000	0,1770	0,4405	0,6629	0,4518	0,6921	0,9000	0,7028	0,3646

Tabel 5 menyajikan hasil normalisasi data konsumsi energi listrik. Proses ini dilakukan agar nilai variabel target berada dalam rentang yang sesuai dengan fungsi aktivasi jaringan saraf, sehingga dapat meningkatkan akurasi prediksi dan mengurangi risiko error selama proses pelatihan model.


Tabel 6. Normalisasi Data Daya Tersambung

Normalisasi Data Daya Tersambung										
Bulan	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
Jan	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000
Feb	0,1029	0,1399	0,1547	0,1632	0,1523	0,1524	0,5407	0,1473	0,1482	0,1407
Mar	0,1296	0,2296	0,2252	0,2360	0,2088	0,2151	0,5815	0,2203	0,2117	0,2228
Apr	0,2329	0,2981	0,2957	0,3039	0,2902	0,2732	0,6229	0,2847	0,2587	0,2838
Mei	0,2741	0,3710	0,3593	0,4049	0,3594	0,3081	0,6500	0,3734	0,3396	0,3874
Jun	0,4702	0,4319	0,4309	0,4459	0,4286	0,3536	0,6825	0,4392	0,4198	0,4492
Jul	0,4829	0,4537	0,5233	0,5131	0,4901	0,4297	0,7105	0,5108	0,4677	0,5291
Agu	0,5352	0,5419	0,6205	0,6219	0,5690	0,7267	0,7376	0,6140	0,5469	0,6326
Sep	0,6896	0,6340	0,6752	0,6843	0,6454	0,7267	0,7746	0,7159	0,6150	0,6801
Okt	0,7534	0,7323	0,7381	0,7758	0,7485	0,7856	0,8152	0,7735	0,6938	0,7740
Nov	0,8157	0,8177	0,8219	0,8516	0,8227	0,8567	0,8567	0,8426	0,7410	0,8378
Des	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000	0,9000

Tabel 6 menunjukkan hasil normalisasi data daya tersambung pelanggan. Normalisasi dilakukan untuk menjaga konsistensi skala antar variabel input sehingga proses pembelajaran jaringan saraf menjadi lebih optimal dan tidak bias terhadap variabel dengan nilai yang lebih besar.


Proses pelatihan BPNN dilakukan dengan parameter *learning rate* 0,1, *epoch* 1000, dan jumlah *neuron hidden layer* 20, menghasilkan nilai MAPE sebesar 57,97% dan R^2 sebesar -0,2403, yang mengindikasikan bahwa model BPNN murni belum mampu menangkap pola hubungan data secara optimal (*underfitting*). Selanjutnya, dilakukan optimasi menggunakan PSO dengan parameter inersia (w) = 0,7, koefisien kognitif (c_1) = 1,5, dan koefisien sosial (c_2) = 1,5, yang terbukti meningkatkan kinerja model dengan menurunkan nilai MAPE menjadi 46,38% serta meningkatkan nilai R^2 menjadi 0,1831. Secara visual,

pola hasil prediksi model *hybrid* BPNN–PSO lebih mendekati data aktual dibandingkan BPNN murni, meskipun masih terdapat penyimpangan pada beberapa titik ekstrem, yang menunjukkan bahwa model sudah mampu mengikuti pola umum data tetapi masih memiliki keterbatasan dalam menangkap perubahan yang sangat drastis.



Gambar 3. Perbandingan Nilai Aktual VS Hasil Latih Dengan BPNN Murni

Dari grafik pada Gambar 3 terlihat bahwa hasil prediksi model sudah mengikuti arah umum data aktual, terutama pada bagian tengah data. Namun, di beberapa bagian saat nilainya naik tinggi atau turun sangat rendah, hasil prediksi masih meleset cukup jauh. Model belum bisa menangkap perubahan yang drastis atau lonjakan yang tiba-tiba dengan baik. Hal ini menunjukkan bahwa model yang digunakan masih terlalu “sederhana” dan belum mampu memahami pola data yang rumit.



Gambar 4. Perbandingan Nilai Aktual VS Prediksi Dengan BPNN + PSO

Gambar 4 memperlihatkan bahwa pola hasil prediksi dengan BPNN–PSO (garis oranye) lebih mendekati nilai aktual (garis biru) dibandingkan model BPNN sebelumnya. Walaupun masih terdapat beberapa penyimpangan pada titik ekstrem, performa keseluruhan model menunjukkan peningkatan yang signifikan. Hal ini memperkuat temuan bahwa metode *hybrid* BPNN–PSO mampu memberikan hasil prediksi yang lebih akurat dan stabil dibandingkan BPNN murni. Selain itu, peningkatan kinerja model juga dapat diamati secara kuantitatif melalui perbandingan nilai metrik evaluasi yang dihasilkan oleh kedua metode. Evaluasi kuantitatif ini penting karena memberikan gambaran objektif mengenai seberapa besar perbaikan performa yang dicapai setelah dilakukan optimasi menggunakan PSO. Dengan demikian, nilai metrik evaluasi perbandingan antara metode BPNN murni dan BPNN–PSO dapat dilihat pada Tabel 7 dan 8 sebagai dasar dalam menentukan model terbaik yang digunakan pada tahap prediksi selanjutnya.

Tabel 7. Metrik Evaluasi BPNN

Metrik Evaluasi	Nilai
Mean Squared Error (MSE)	0,053066
Root Mean Squared Error (RMSE)	0,230362

Metrik Evaluasi	Nilai
<i>Mean Absolute Error</i> (MAE)	0,182614
<i>Mean Absolute Percentage Error</i> (MAPE)	57,97%
Koefisien Determinasi (R^2)	-0,2403

Tabel 8. Metrik Evaluasi BPNN + PSO

Metrik Evaluasi	Nilai
<i>Mean Squared Error</i> (MSE)	0,034950
<i>Root Mean Squared Error</i> (RMSE)	0,186949
<i>Mean Absolute Error</i> (MAE)	0,159604
<i>Mean Absolute Percentage Error</i> (MAPE)	46,38%
Koefisien Determinasi (R^2)	0,1831

Model terbaik dengan hasil menunjukkan pertumbuhan sebagai mana terlihat pada Tabel 9, yaitu BPNN–PSO, kemudian digunakan untuk memproyeksikan konsumsi listrik rumah tangga periode 2025–2029.

Tabel 9. Prediksi BPNN + PSO Periode 2025–2029

Faktor	Tahun Prediksi	% Laju Pertumbuhan
Jumlah Pelanggan	2025	5,97
	2026	6,88
	2027	7,88
	2028	8,34
	2029	8,82
Daya Tersambung	2025	4,11
	2026	4,20
	2027	4,33
	2028	4,43
	2029	4,49
Jumlah Energi (kWh)	2025	1,63
	2026	2,06
	2027	2,75
	2028	3,31
	2029	3,37

Tabel 9 menunjukkan bahwa jumlah pelanggan mengalami pertumbuhan sebesar 5,97%–8,82% per tahun, pertumbuhan daya tersambung sebesar 4,11%–4,49% per tahun, serta pertumbuhan konsumsi energi listrik sebesar 1,63%–3,37% per tahun. Temuan ini mengindikasikan adanya tren peningkatan kebutuhan listrik yang konsisten dan dapat dijadikan dasar pertimbangan dalam perencanaan kapasitas pembangkitan, penguatan jaringan distribusi, serta penyusunan kebijakan ketenagalistrikan yang lebih adaptif terhadap pertumbuhan permintaan.

Hasil penelitian menunjukkan bahwa model *hybrid* BPNN–PSO memiliki kinerja yang lebih baik dibandingkan dengan model BPNN murni, yang ditunjukkan oleh penurunan nilai error serta peningkatan nilai koefisien determinasi (R^2). Peningkatan performa ini terjadi karena algoritma *Particle Swarm Optimization* (PSO) mampu mengoptimalkan bobot dan bias awal pada jaringan saraf, sehingga proses pelatihan menjadi lebih efektif dan tidak terjebak pada solusi lokal. Hal ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa integrasi PSO dalam *Artificial Neural Network* (ANN) dapat meningkatkan kecepatan konvergensi dan akurasi prediksi [16], [17].

Selain itu, model BPNN–PSO menunjukkan kemampuan yang lebih baik dalam menangkap pola data konsumsi listrik yang bersifat nonlinier dan fluktuatif. Hal ini menunjukkan bahwa kombinasi metode pembelajaran (BPNN) dan optimasi global (PSO) mampu meningkatkan kemampuan generalisasi model. Temuan ini juga konsisten dengan studi sebelumnya yang melaporkan bahwa model *hybrid* mampu menurunkan nilai error seperti MAPE dan RMSE serta meningkatkan stabilitas model pada data deret waktu energi [18], [19].

Meskipun demikian, nilai error yang dihasilkan dalam penelitian ini masih relatif tinggi, yang mengindikasikan bahwa model belum sepenuhnya mampu menangkap seluruh variasi pola konsumsi listrik. Hal ini kemungkinan disebabkan oleh keterbatasan variabel input yang digunakan, di mana model hanya mempertimbangkan parameter internal tanpa memasukkan faktor eksternal seperti kondisi ekonomi, cuaca, maupun perilaku konsumsi pelanggan. Temuan ini sejalan dengan penelitian lain yang menyatakan bahwa akurasi model prediksi sangat dipengaruhi oleh kelengkapan variabel input yang digunakan [20].

Secara praktis, hasil penelitian ini menunjukkan bahwa model *hybrid* BPNN–PSO dapat digunakan sebagai alat bantu dalam perencanaan sistem ketenagalistrikan, khususnya dalam memprediksi konsumsi listrik sektor rumah tangga secara lebih akurat. Namun demikian, penelitian ini masih memiliki keterbatasan

pada jumlah variabel dan ruang lingkup data yang digunakan. Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan variabel eksternal serta mengembangkan metode *hybrid* lain guna meningkatkan performa model prediksi.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model *Backpropagation Neural Network* (BPNN) murni belum mampu memberikan performa prediksi yang optimal, yang ditunjukkan oleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 57,97% dan koefisien determinasi (R^2) sebesar -0,2403. Integrasi algoritma *Particle Swarm Optimization* (PSO) dalam pelatihan BPNN terbukti mampu meningkatkan kinerja model, dengan penurunan nilai MAPE menjadi 46,38% serta peningkatan nilai R^2 menjadi 0,1831. Hal ini menunjukkan bahwa optimasi bobot dan bias awal menggunakan PSO dapat memperbaiki proses pembelajaran jaringan saraf dan menghasilkan prediksi yang lebih akurat.

Selain itu, model *hybrid* BPNN-PSO mampu menghasilkan proyeksi konsumsi listrik rumah tangga periode 2025–2029 dengan tren peningkatan yang konsisten pada jumlah pelanggan, daya tersambung, dan konsumsi energi listrik. Hasil ini menunjukkan bahwa model yang diusulkan dapat digunakan sebagai alat bantu dalam mendukung perencanaan sistem ketenagalistrikan, khususnya pada sektor rumah tangga berbasis golongan tarif pada level unit layanan pelanggan. Dengan demikian, kontribusi utama penelitian ini adalah pengembangan model prediksi yang lebih spesifik dan aplikatif dibandingkan dengan penelitian sebelumnya yang umumnya masih berfokus pada skala agregat.

Namun demikian, penelitian ini masih memiliki beberapa keterbatasan, di antaranya keterbatasan variabel input yang digunakan serta belum mempertimbangkan faktor eksternal seperti kondisi ekonomi, cuaca, dan perilaku konsumsi pelanggan. Selain itu, nilai error yang masih relatif tinggi menunjukkan bahwa model belum sepenuhnya mampu menangkap pola data yang kompleks dan fluktuatif.

Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan variabel eksternal yang relevan, memperluas cakupan data, serta mengembangkan metode *hybrid* lain atau pendekatan machine learning yang lebih kompleks untuk meningkatkan akurasi dan stabilitas model prediksi konsumsi listrik.

REFERENSI

- [1] S. Salehimehr, B. Taheri, and M. Sedighzadeh, "Short-term load forecasting in smart grids using artificial intelligence methods: A survey," *The Journal of Engineering*, no. 12, pp. 1133–1142, 2022, doi: 10.1049/tje2.12183.
- [2] N. Mohammed and A. Al-Bazi, "An adaptive backpropagation algorithm for long-term electricity load forecasting," *Neural Computing & Applications*, vol. 34, pp. 477–491, 2021, doi: 10.1007/s00521-021-06384-x.
- [3] S. Mateo-Barcos, R. Giralt, A. Sumper, and E. Vinyals, "Forecasting electricity demand of municipalities through artificial neural networks and metered supply point classification," *Energy Reports*, vol. 11, pp. 3533–3549, 2024, doi: 10.1016/j.egyr.2024.03.023.
- [4] H. D. Purnomo, A. S. Nugroho, and R. M. Pratama, "Neuroevolution untuk optimalisasi parameter jaringan saraf tiruan," *Aiti: Jurnal Teknologi Informasi*, vol. 20, no. 2, pp. 125–134, 2023, doi: 10.24246/aiti.v20i2.125-134.
- [5] E. Y. Sari, Kusriani, and A. Sunyoto, "Optimization of weight backpropagation with *Particle Swarm Optimization* for student dropout prediction," in *Proc. 4th Int. Conf. Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, Yogyakarta, Indonesia, 2019, pp. 423–428, doi: 10.1109/ICITISEE48480.2019.9004032.
- [6] E. Ofori-Ntow Jnr and Y. Y. Ziggah, "Electricity demand forecasting based on feature extraction and optimized backpropagation neural network," *e-Prime – Advances in Electrical Engineering, Electronics and Energy*, vol. 6, p. 100293, 2023, doi: 10.1016/j.prime.2023.100293.
- [7] A. Agustyawan, T. G. Laksana, and U. Athiyah, "Combination of BPNN and PSO for water production prediction," *Scientific Journal of Informatics*, vol. 9, no. 1, pp. 84–94, 2022, doi: 10.15294/sji.v9i1.29849.
- [8] F. E. Bezerra et al., "Forecasting and minimizing electricity costs in Brazil," *Engineering Review*, vol. 41, no. 3, pp. 65–75, 2021, doi: 10.30765/ER.1529.
- [9] M. W. Hasan, "Energy consumption forecasting using LSTM," *Measurement: Energy*, vol. 5, p. 100033, 2025, doi: 10.1016/j.meae.2024.100033.
- [10] A. Hussein and M. Awad, "Hybrid RNN and GA for electricity forecasting," *Measurement: Energy*, vol. 2, p. 100004, 2024, doi: 10.1016/j.meae.2024.100004.
- [11] Y.-S. Kim et al., "Impact of normalization on electricity prediction," *Sustainable Cities and Society*, vol. 118, p. 105570, 2024, doi: 10.1016/j.scs.2024.105570.
- [12] M. Joshi and A. Arora, "BPNN-PSO for power quality improvement," in *Proc. INCET*, 2022, doi: 10.1109/INCET54531.2022.9824451.
- [13] S. Sena et al., "Determinants of electricity consumption for households," *Sustainability*, vol. 13, no. 2,

- p. 818, 2021, doi: 10.3390/su13020818.
- [14] J. P. Singh, O. Alam, and A. Yassine, "Geodemographic factors in electricity forecasting," *IEEE Access*, vol. 10, pp. 70456–70466, 2022, doi: 10.1109/ACCESS.2022.3188004.
 - [15] N. Selle, N. Yudistira, and C. Dewi, "Comparison of LSTM and RNN for electricity prediction," *Jurnal TI*, vol. 9, no. 1, pp. 155–162, 2022, doi: 10.25126/jtiik.2022915585.
 - [16] Widiartha et al., "Hybrid BPNN-PSO for accuracy improvement," *Current Journal of Applied Science and Technology*, vol. 42, no. 6, pp. 10–18, 2023, doi: 10.9734/cjast/2023/v42i64072.
 - [17] G. Quan et al., "PSO-BP integrated model for material behavior," *Materials*, vol. 16, no. 8, 2023, doi: 10.3390/ma16082982.
 - [18] Tyastama et al., "Hybrid BPNN-PSO for disease prediction," *JINITA*, vol. 3, no. 1, pp. 9–16, 2021, doi: 10.35970/jinita.v3i1.588.
 - [19] R. Dharmawan, A. Hasniaty, and Y. S. Akil, "Household electricity consumption analysis," *Jurnal Penelitian Enjiniring*, vol. 26, no. 1, pp. 34–40, 2023, doi: 10.25042/jpe.052022.05.
 - [20] D. H. Vo, "Socio-demographic determinants of electricity consumption," *PLOS ONE*, vol. 20, no. 4, 2025, doi: 10.1371/journal.pone.0320758.
 - [21] H. Wang, Z. Lei, X. Zhang, B. Zhou, and J. Peng, "A review of deep learning for renewable energy forecasting," *Energy Conversion and Management*, vol. 198, p. 111799, 2021. Available at: <https://doi.org/10.1016/j.enconman.2019.111799>.
 - [22] J. Kong, H. Dong, J. Jia, D. Hill, Y. Xu, and Y. Zhang, "Short-term residential load forecasting based on LSTM recurrent neural network," *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 841–851, 2020. Available at: <https://doi.org/10.1109/TSG.2017.2753802>.
 - [23] Y. Yu, Y. Chen, Y. Yong, and Y. Li, "A hybrid model for electricity consumption forecasting using deep learning and optimization algorithms," *Applied Energy*, vol. 285, p. 116405, 2021. Available at: <https://doi.org/10.1016/j.apenergy.2021.116405>.
 - [24] S. Mirjalili, "*Particle Swarm Optimization*: theory, literature review, and application in energy systems," *IEEE Access*, vol. 7, pp. 306–317, 2019. Available at: <https://doi.org/10.1109/ACCESS.2018.2880742>.
 - [25] X. Qiu, L. Zhang, Y. Ren, P. N. Suganthan, and G. Amaratunga, "Ensemble deep learning for electricity load forecasting," *Applied Soft Computing*, vol. 92, p. 106304, 2020. Available at: <https://doi.org/10.1016/j.asoc.2020.106304>.