

Analisis Arsitektur Jaringan Syaraf Tiruan- Multilayer Perceptron untuk Efektivitas Estimasi Beban Energi Listrik PT. PLN (Persero) UP3 Salatiga

RONI SAPUTRA, SAID SUNARDIYO, ANAN NUGROHO, SUBIYANTO

Teknik Elektro Universitas Negeri Semarang, Indonesia
Email: roni_saputra@students.unnes.ac.id

Received 11 Mei 2023 | *Revised* 12 Juni 2023 | *Accepted* 14 Juni 2023

ABSTRAK

PT PLN (Persero) UP3 Salatiga merupakan perusahaan penyedia energi listrik enam kabupaten di Jawa Tengah. Agar energi listrik yang mengalir ke pelanggan handal dan ekonomis, penyesuaian antara supply dan demand penting untuk dilakukan. Hal ini bisa dilakukan dengan perencanaan operasi sistem tenaga listrik dalam bentuk estimasi beban energi listrik. Pada penelitian ini, estimasi dilakukan dengan jaringan syaraf tiruan-multilayer perceptron. Sejumlah variasi jumlah layer dan node pada arsitektur perceptron diuji-cobakan untuk mendapatkan performa estimasi yang terbaik. Dari penelitian ini, diperoleh arsitektur terbaik yaitu TRAININGDA 4 hidden layer dengan 20 node hidden layer, dengan nilai MAPE sebesar 2.79% tahap training, serta nilai MAPE sebesar 3.24% tahap testing. Hasil ini mengindikasikan bahwa metode jaringan syaraf tiruan-multilayer perceptron lebih akurat sebagai estimator beban energi listrik PT PLN (Persero) UP3 Salatiga.

Kata kunci: *estimasi, estimasi beban, energi listrik, multilayer perceptron*

ABSTRACT

PT PLN (Persero) UP3 Salatiga is an electricity provider company for 6 districts in Central Java. To ensure reliable and economical electricity supply to customers, adjustment between supply and demand is important to be conducted. This can be achieved through planning of power system operation in the form of electricity load estimation. In this study, estimation was performed using artificial neural network-multilayer perceptron. Several variations of the number of layers and nodes in the perceptron architecture were tested to obtain the best estimation performance. From this study, the best architecture was obtained with TRAININGDA 4 hidden layers and 20 hidden layer nodes, resulting in MAPE value of 2.79% in the training phase and 3.24% in the testing phase. These results indicate that artificial neural network-multilayer perceptron method is more accurate as an estimator of electricity load for PT PLN (Persero) UP3 Salatiga.

Keywords: *estimation, load estimation, electrical energy, multilayer perceptron*

1. PENDAHULUAN

PT PLN (Persero) UP3 Salatiga merupakan perusahaan penyedia energi listrik yang memiliki cakupan wilayah kerja enam kabupaten atau kota di Provinsi Jawa Tengah meliputi Kabupaten Grobogan, Kabupaten Boyolali, Kabupaten Semarang, Kota Semarang, Kabupaten Temanggung, dan Kota Salatiga. Beban energi listrik pada wilayah tersebut cenderung terus meningkat setiap tahunnya. Pada tahun 2017 beban energi listrik sebesar 1,196,933,217 kWh, tahun 2018 sebesar 1,256,376,724 kWh, tahun 2019 sebesar 1,293,041,219 kWh, tahun 2020 sebesar 1,244,355,173 kWh, dan tahun 2021 sebesar 1,313,592,239 kWh. Sebagai energi yang memiliki peran vital untuk mencapai tujuan ekonomi, sosial, dan lingkungan dalam mewujudkan pembangunan berkelanjutan serta mendukung kegiatan ekonomi nasional maupun multinasional, tentunya berdampak pada meningkatnya kebutuhan energi yang sejalan dengan meningkatnya jumlah penduduk dan penggunaan peralatan yang menggunakan energi listrik (**Alkushima, dkk, 2016**). Besarnya beban energi listrik dari waktu ke waktu yang cenderung terus mengalami peningkatan, tidak bisa diketahui secara pasti. Ketidakpastian besarnya beban listrik dimasa depan serta tidak dilakukannya perencanaan terlebih dahulu akan menyebabkan masalah ketika penyediaan energi listrik tidak sebanding dengan permintaan energi listrik (**Rajagukguk, dkk, 2015**). Ketika *supply* energi listrik yang dihasilkan dari pembangkit terlalu besar dibanding dengan permintaan energi maka akan terjadi pemborosan energi yang akan mengakibatkan kerugian pihak penyedia energi listrik. Sedangkan ketika energi listrik yang dihasilkan pembangkit lebih kecil dibandingkan permintaan energi maka akan menimbulkan permasalahan antara lain pemadaman listrik secara bergilir yang mengakibatkan kerugian bagi pihak konsumen (**Triwulan, dkk, 2013**). Oleh sebab itu, perlu dilakukan estimasi untuk memperkirakan kebutuhan energi listrik sebagai upaya antisipasi hal yang tidak diinginkan dimasa depan (**Saragih, dkk, 2020**). Estimasi merupakan suatu teknik atau cara untuk memperkirakan secara sistematis mengenai segala kemungkinan yang akan terjadi pada masa yang akan datang berdasarkan data serta informasi pada masa lalu dan sekarang yang dimiliki, sehingga kesalahannya (selisih antara sesuatu yang terjadi dengan hasil estimasi) dapat diperkecil. Estimasi tidak harus memberikan jawaban secara pasti terkait kejadian yang akan terjadi, namun berusaha untuk memberi jawaban sedekat mungkin yang akan terjadi (**Syahrudiyanto, dkk, 2022**). PT PLN (Persero) UP3 Salatiga selama ini telah melakukan estimasi beban energi listrik pada wilayah kerjanya menggunakan metode regresi, berdasarkan pengkajian kecenderungan peningkatan beban listrik dari masa lalu ke masa yang akan datang dengan metode yang mereka lakukan tersebut memiliki nilai *error* yang cukup besar yaitu 5.57% atau akurasi estimasi sebesar 94.43%.

Penelitian terkait estimasi diperlukan metode yang sesuai dengan objek yang akan diteliti, sehingga dapat diperoleh hasil yang maksimal. Terdapat beberapa referensi metode estimasi yang dapat digunakan untuk memperkirakan beban energi listrik dimasa depan, baik metode estimasi dengan model statistik dan matematis maupun menggunakan alat bantu *software* (**Sharma & Nijhawan, 2015**). Beberapa penelitian estimasi beban energi listrik dilakukan oleh (**Hutabarat, dkk, 2022**) menggunakan metode regresi linear untuk memperkirakan kebutuhan energi listrik wilayah PLN Kota Parapat Simalungun tahun 2020-2024 dari pengaruh Produk Domestik Regional Bruto (PDRB), (**Nyoman, dkk, 2020**) menggunakan metode prediktor dengan *Long Short-Term Memory* (LSTM) hasil penelitian menunjukkan nilai *error output* terhadap data uji yaitu RMSE sebesar 60,992 dan MAE sebesar 28,278, (**Wijaya, 2019**) menggunakan *artificial neural network* dengan metode pembelajaran *backpropagation* sebagai prediktor, tingkat akurasi dari hasil prediksi dengan data real diperoleh tingkat akurasi sebesar 96,48%, (**Setyowati & Sunardiyo, 2020**) menggunakan *artificial neural network* dengan metode pembelajaran *backpropagation* sebagai prediktor, untuk arsitektur jaringan syaraf yang digunakan dalam penelitian ini yaitu jumlah *hidden layer* 1, *node hidden layer* 6,

12, 18, 24, dan 30, tingkat akurasi dari hasil prediksi dengan menggunakan enam variabel data *input* dan data target diperoleh tingkat akurasi sebesar 96,31%

Teknologi yang terus berkembang semakin canggih memberikan alternatif metode estimasi dengan memanfaatkan kecerdasan buatan (*artificial intelligence*). Salah satu kecerdasan buatan yang dapat diaplikasikan dalam proses estimasi adalah Jaringan Syaraf Tiruan (JST) **(Sakinah, dkk, 2018)**. JST merupakan suatu sistem cerdas yang dapat memproses data dan informasi yang diberikan dengan prinsip kerjanya menirukan jaringan syaraf manusia. JST mampu melakukan pengenalan dari pola yang diberikan berdasarkan variabel atau parameter yang digunakan, kemudian data tersebut akan diolah dan dipelajari oleh JST. JST dapat diaplikasikan dalam berbagai bidang yaitu dalam peramalan sosial, ekonomi, teknik, energi listrik, permasalahan saham, dan lainnya **(Simangunsong & Nasution, 2015)**. Salah satu tipe JST yaitu *multilayer perceptron*. *Multilayer perceptron* ini dapat digunakan secara efektif dalam melakukan prakiraan dan cocok untuk digunakan dalam mengolah data *time series* **(Hadimarta, dkk, 2020)**. Algoritma pembelajaran JST-*multilayer perceptron* yang akan digunakan yaitu algoritma *backpropagation*, algoritma pembelajaran ini digunakan karena dapat memperbarui bobot agar dapat meminimalisir *error* **(Saritas & Yasar, 2019)**. Ketika *output* yang dihasilkan tidak sama dengan target yang ditentukan maka *output* akan disebarkan mundur (*backward*) kembali pada *hidden layer* lalu diteruskan ke unit pada *input layer*, sehingga akan ada umpan balik untuk memvalidasi hasil *output* JST **(Syahputra, dkk, 2020)**.

Berdasarkan uraian permasalahan di atas, peneliti berupaya menyelesaikan permasalahan tersebut dengan melakukan penelitian "Analisis Arsitektur Jaringan Syaraf Tiruan-*Multilayer Perceptron* untuk Efektivitas Estimasi Beban Energi Listrik PT PLN (Persero) UP3 Salatiga". Penelitian ini akan menggabungkan arsitektur JST yaitu jumlah *hidden layer*, jumlah *node hidden layer*, dan fungsi pelatihan JST berdasarkan referensi dari penelitian terdahulu untuk mendapatkan arsitektur JST dengan nilai *error* terkecil untuk digunakan dalam estimasi beban energi listrik pada PT PLN (Persero) UP3 Salatiga. Arsitektur JST yang akan digunakan dalam penelitian ini yaitu jumlah *hidden layer* yang akan digunakan adalah 1, 2, 3, 4, dan 5, sedangkan berdasarkan literatur penelitian yang lain untuk *hidden layer* berjumlah hanya 1 saja, antara lain penelitian **(Khusniyah & Sutikno, 2016)**, **(Setyowati & Sunardiyo, 2020)** dan penelitian **(Fachri, dkk, 2019)**. Jumlah *node hidden layer* yang akan digunakan adalah 2, 3, 4, 5, 10, 15, 20, 25, jumlah *node hidden layer* ini berdasarkan beberapa referensi penelitian sebelumnya yaitu **(Maulidin & Assaffat, 2014)** yang menggunakan jumlah *node hidden layer* 2 dan penelitian **(Dudek, 2020)** yang menggunakan jumlah *node hidden layer* 2, 3, dan 4, selain itu peneliti juga akan menggunakan jumlah *node hidden layer* dengan kelipatan 5 sampai 25 *node hidden layer* untuk mendapatkan arsitektur dengan nilai *error* yang lebih kecil. Fungsi pelatihan yang akan digunakan adalah TRAINGD, TRAINGDM, TRAINGDA, dan TRAINGD_X. Serta jangka waktu estimasi lima tahun ke depan yang termasuk dalam kategori estimasi jangka panjang ini dipilih agar hasil penelitian dapat dijadikan salah satu acuan dalam menyusun perencanaan energi masa depan **(Aulia, 2018)**.

2. METODE

2.1 Alat dan Bahan

Peralatan yang digunakan untuk teknik estimasi dalam penelitian ini yaitu laptop dengan prosesor *intel core i5* generasi 10th dengan sistem operasi windows 10, 64 bits. Serta program pendukung lain yang dibutuhkan yaitu *toolbox neural network* yang diakses melalui *software Matlab 2021a* versi 9.10, *software microsoft office 365* Versi 16.0.15601.20088, serta *datasheet* beban energi listrik wilayah kerja PT PLN (Persero) UP3 Salatiga tahun 2017-2021,


untuk *datasheet* beban energi listrik sebelum dan setelah di normalisasi, pola data *training*, pola data *testing*, dan pola data estimasi dapat diakses pada bit.ly/dataestimasi.

2.2 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) atau *Artificial Neural Network* (ANN) merupakan model aritmatika yang meniru fitur fungsional jaringan syaraf biologis. Jaringan syaraf tiruan berisi neuron buatan yang saling terkait dan memproses. Sebagai aturan umum JST adalah sistem adaptif yang menyesuaikan strukturnya berdasarkan informasi eksternal atau internal yang berjalan melalui jaringan selama proses pembelajaran. JST dapat digunakan untuk memodelkan hubungan yang kompleks antara *input* dan *output* atau untuk mengungkap pola dalam data. JST dapat diterapkan secara efektif di bidang estimasi, pengenalan karakter tulisan tangan, evaluasi harga, dan lainnya (Naser, dkk, 2015). Suatu jaringan syaraf tiruan dapat dikatakan baik atau tidak, berdasarkan arsitektur jaringan atau hubungan antar neuron pada JST. Kumpulan neuron-neuron tersebut terletak pada lapisan-lapisan atau dikenal dengan *layer*. Lapisan JST terdiri dari tiga penyusun yaitu lapisan *input* (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan *output* (*output layer*) (Nurhayati, 2015).

2.3 Multilayer Perceptron

Multilayer Perceptron (MLP) merupakan model jaringan syaraf tiruan *feedforward* yang tersusun dari sejumlah neuron yang dihubungkan oleh bobot-bobot penghubung (Sinaga, 2020). Suatu JST-*multilayer perceptron* mempunyai sebuah *input layer*, satu atau lebih *hidden layer*, dan sebuah *output layer*. Setiap *layer* JST-*multilayer perceptron* tersebut masing-masing memiliki fungsi tersendiri (Fitri & Riana, 2022). *Input layer* berfungsi untuk menerima sinyal masukan dari luar lalu didistribusikan pada semua neuron di *hidden layer*. *Output layer* akan menerima sinyal keluaran dari *hidden layer* lalu menampilkan sinyal atau nilai *output* dari keseluruhan jaringan. Model *multilayer perceptron* yang merupakan salah satu jaringan saraf tiruan ini, cara kerjanya menirukan jaringan saraf pada makhluk hidup. JST-*multilayer perceptron* mampu mempelajari dan mengenali suatu pola berdasarkan pengetahuan yang didapatkan melalui proses *training* (Lingga, 2020). *Multilayer perceptron* dapat digunakan untuk mengolah data *time series* dan dapat digunakan untuk estimasi dengan akurasi yang sangat baik dengan nilai error <10% dari beberapa penelitian sebelumnya (Hadimarta, dkk, 2020). Arsitektur JST-*multilayer perceptron* ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur JST- *Multilayer Perceptron* dengan 2 *Hidden Layer*

2.4 Backpropagation

Terdapat beberapa algoritma pembelajaran JST antara lain *backpropagation*, *levenberg-marquardt*, *genetika*, *extreme learning machine* dan lainnya. Algoritma pembelajaran *backpropagation* dipilih dan digunakan dalam penelitian ini karena berdasarkan studi literatur

penelitian-penelitian sebelumnya tentang estimasi yang menggunakan algoritma pembelajaran *backpropagation* menunjukkan akurasi yang sangat baik dengan nilai *error* yang kecil <10%, antara lain penelitian **(Dudek, 2020)** nilai *error* 1,45 – 2,99%, **(Rodrigues, dkk, 2014)** nilai *error* 4,2%, **(Maulidin & Assaffat, 2014)** nilai *error* 7,233%, **(Aulia, 2018)** nilai *error* 0,48%, dan **(Simbolon, dkk, 2018)** nilai *error* 9%.

Proses pembelajaran *backpropagation* termasuk dalam jenis yang terawasi sehingga *backpropagation* sering digunakan oleh *perceptron* dengan banyak *layer* (*multilayer perceptron*) dalam mengubah bobot-bobot yang terdapat pada *hidden layer*. *Backpropagation* yang merupakan pelatihan jenis terawasi (*supervised*) menggunakan pola penyesuaian bobot dalam meminimalkan nilai kesalahan (*error*) antara *output* hasil estimasi dengan *output* acuan **(Andrijasa & Mistianingsih, 2010)**. *Backpropagation* merupakan salah satu metode dalam pembelajaran JST-*multilayer perceptron* dengan perhitungan serta propagasi balik dari *error* yang didapatkan sehingga akan diperoleh hasil bobot yang sesuai dengan pola data yang ada. Pada pelatihan estimasi algoritma *backpropagation* merupakan suatu cara yang mampu memberikan akurasi hasil yang baik dengan menganalisis data yang sudah ada pada masa lalu **(Simbolon, dkk, 2018)**.

2.5 Pengujian Kinerja Jaringan

Pengujian kinerja jaringan dengan evaluasi nilai *error* dari hasil *output* jaringan pada tahap *training* dan *testing*. Evaluasi *error* yang akan dilakukan dengan mengkalkulasikan MAD dan MAPE **(Astuti, dkk, 2019)**.

1) MAD

MAD (*Mean Absolute Deviation*) merupakan rata-rata kesalahan absolut (mutlak) hasil *output* jaringan tanpa memperhatikan lebih besar atau lebih kecil hasil *output* jaringan tersebut terhadap kenyataannya. Secara matematis MAD dirumuskan:

$$MAD = \frac{\sum_{t=1}^n |X_t - F_t|}{n} \quad (1)$$

Keterangan:

X_t = data aktual pada periode (t) tertentu

F_t = nilai peramalan pada periode (t) tertentu

n = jumlah data

2) MAPE

MAPE (*Mean Absolute Percentage Error*) merupakan ukuran kesalahan relatif yang menyatakan persentase kesalahan hasil *output* jaringan terhadap nilai aktual selama periode tertentu. Secara matematis MAPE dirumuskan:

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - F_t}{X_t} \right| \right) \times 100\% \quad (2)$$

Keterangan X_t , F_t , dan n sama dengan Persamaan (1)

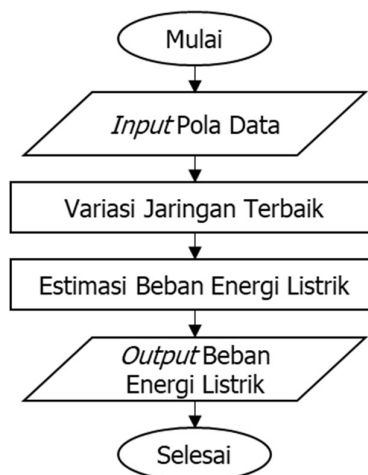
Persentase nilai MAPE menunjukkan kemampuan estimasi yang ditunjukkan pada Tabel 1.

Tabel 1. Kriteria Nilai MAPE pada Estimasi

No.	Nilai MAPE	Akurasi Estimasi
1.	<10%	Sangat Baik
2.	10-20%	Baik
3.	20-50%	Cukup
4.	>50%	Buruk

2.6 Diagram Alir Proses Estimasi

Tahap proses estimasi beban energi listrik disajikan pada Gambar 2 berikut.



Gambar 2. Flowchart Skema Estimasi Beban Energi Listrik

Meninjau *flowchart* program estimasi di atas pada Gambar 2. Proses estimasi menggunakan jaringan syaraf tiruan-*multilayer perceptron* yang diakses melalui *toolbox neural network* pada *software* Matlab. *Input* berisi data beban energi listrik yang disusun dalam bentuk siklus 12 bulan untuk estimasi satu bulan berikutnya. Variasi jaringan terbaik berdasarkan arsitektur *perceptron* yang diajukan maka akan ada sejumlah 160 variasi jaringan yang akan di *training*, lalu dipilih empat variasi jaringan terbaik dari setiap fungsi pelatihan yang dilanjutkan tahap *testing*, sehingga diperoleh satu variasi jaringan terbaik setelah dilakukan *testing*. Estimasi beban energi listrik dilakukan menggunakan variasi jaringan terbaik tersebut berdasarkan data hasil *training* dan *testing*. *Output* program diperoleh estimasi beban energi listrik satu bulan berikutnya, sehingga dilakukan *update* pola data untuk estimasi bulan selanjutnya hingga mencapai sejumlah bulan atau tahun yang diperlukan.

3. HASIL DAN PEMBAHASAN

Penelitian ini dilaksanakan di PT PLN (Persero) UP3 Salatiga dengan objek penelitian yaitu beban energi listrik wilayah kerja PLN tersebut. Penelitian dilakukan analisis arsitektur JST-*multilayer perceptron* untuk efektivitas estimasi beban energi listrik tahun 2022-2026. Analisis data menggunakan JST-*multilayer perceptron* yang diakses menggunakan *toolbox neural network* pada *software* matlab. Arsitektur jaringan yaitu *hidden layer*: 1, 2, 3, 4, 5, 10, 15, 20, dan 25, *node hidden layer*: 1, 2, 3, 4, dan 5, fungsi pelatihan: TRAINGD, TRAINGDM, TAINGDA, dan TRAINGDY. Berikut hasil dan pembahasan penelitian ini yang disajikan dalam tiga bagian yaitu *training*, *testing*, dan estimasi.

3.1 Training

Berdasarkan parameter yang ditentukan dalam penelitian ini yaitu empat fungsi pelatihan, lima jumlah *hidden layer* berbeda, delapan jumlah *node hidden layer* berbeda, maka keseluruhan ada 160 variasi model jaringan yang diteliti. Adapun hasil *training* semua variasi jaringan ditampilkan pada Tabel 2.

Tabel 2. Nilai dan Persentase Error Training Jaringan

Hidden Layer	Node Hidden Layer	Fungsi Pelatihan							
		TRAINGD		TRAINGDM		TRAINGDA		TRAINGDY	
		MAD	MAPE	MAD	MAPE	MAD	MAPE	MAD	MAPE
1	2	5,676,750	5.72%	6,160,970	6.09%	4,913,587	5.02%	3,590,847	3.64%
	3	5,977,723	5.97%	4,337,413	4.41%	3,970,603	4.07%	7,190,547	7.27%
	4	6,133,271	6.15%	4,952,544	4.80%	5,423,308	5.54%	3,273,883	3.38%
	5	5,774,354	5.84%	5,770,631	5.83%	3,752,844	3.94%	3,491,329	3.69%
	10	6,351,208	6.47%	5,045,716	5.03%	3,692,896	3.92%	3,375,192	3.64%
	15	5,234,550	5.10%	5,740,641	5.79%	6,530,237	6.68%	4,570,914	4.73%
	20	6,578,352	6.67%	5,084,633	5.08%	3,956,621	4.11%	3,260,362	3.40%
2	25	3,370,006	3.48%	5,994,336	5.93%	4,734,960	4.76%	6,635,634	6.55%
	2	5,612,567	5.69%	5,614,394	5.71%	3,589,555	3.84%	3,857,717	3.89%
	3	5,305,750	5.33%	6,637,803	6.57%	4,669,271	4.74%	5,105,362	5.23%
	4	3,973,415	3.99%	5,095,357	5.23%	4,491,052	4.57%	7,349,307	7.10%
	5	5,980,521	5.92%	5,417,404	5.53%	3,634,861	3.84%	4,113,490	4.08%
	10	4,462,562	4.37%	6,121,031	6.15%	3,901,639	4.16%	6,202,376	6.34%
	15	7,035,408	7.03%	6,023,160	6.00%	4,348,183	4.35%	2,898,065	3.01%
3	20	4,424,588	4.40%	6,329,151	6.27%	3,894,079	3.68%	5,324,850	5.00%
	25	3,723,027	3.79%	6,869,780	6.88%	3,631,746	3.89%	3,652,358	3.86%
	2	5,860,538	5.91%	4,690,551	4.79%	3,985,726	4.04%	3,516,390	3.61%
	3	5,724,198	5.89%	5,884,200	5.96%	3,903,346	4.05%	4,935,726	5.01%
	4	6,110,763	6.13%	6,513,301	6.36%	5,251,584	5.26%	3,307,406	3.39%
	5	5,678,591	5.69%	5,952,991	5.87%	6,889,736	6.72%	5,593,075	5.71%
	10	4,935,443	4.89%	5,942,521	5.96%	3,825,344	3.91%	3,289,791	3.58%
4	15	6,044,197	6.07%	6,576,302	6.57%	3,815,738	3.83%	5,466,403	5.37%
	20	5,813,651	5.75%	7,265,705	7.09%	7,088,838	7.03%	3,351,505	3.44%
	25	5,994,958	5.82%	4,646,102	4.73%	6,669,493	6.58%	2,943,664	3.26%
	2	6,995,158	6.86%	8,086,435	7.78%	3,535,291	3.71%	4,485,637	4.62%
	3	5,789,243	5.86%	5,771,625	5.86%	6,016,453	6.05%	2,829,054	2.93%
	4	6,119,542	6.15%	5,937,283	6.04%	4,541,624	4.72%	3,641,629	3.89%
	5	6,092,095	6.10%	8,084,920	7.74%	3,715,723	3.79%	3,434,020	3.48%
5	10	4,219,509	4.27%	6,279,837	6.31%	7,506,772	7.30%	3,954,396	4.18%
	15	7,490,362	7.44%	4,750,769	4.81%	3,988,740	4.05%	8,828,402	8.43%
	20	4,699,237	4.73%	5,372,173	5.45%	2,624,073	2.79%	6,605,051	6.61%
	25	2,717,430	2.59%	4,669,017	4.79%	3,671,080	3.91%	3,050,410	3.16%
	2	6,189,704	6.18%	5,858,754	6.04%	3,564,221	3.77%	5,868,477	5.93%
	3	6,150,731	6.14%	5,680,550	5.68%	4,919,490	5.00%	4,512,581	4.58%
	4	5,773,382	5.85%	5,996,336	6.06%	2,795,585	2.96%	3,320,544	3.41%
6	5	5,124,488	5.21%	8,534,939	8.16%	3,419,948	3.67%	4,508,901	4.54%
	10	5,567,851	5.56%	6,496,583	6.51%	3,188,287	3.27%	6,893,753	6.69%
	15	5,074,248	5.24%	6,255,626	6.21%	3,764,219	3.92%	3,710,728	3.81%
	20	5,421,342	5.34%	4,798,648	4.85%	5,630,429	5.75%	6,338,730	6.29%
	25	6,416,347	6.39%	6,039,861	6.02%	3,152,335	3.28%	4,703,281	4.74%

Berdasarkan Tabel 2 dapat diketahui untuk fungsi pelatihan TRAINGD, jaringan terbaik fungsi pelatihan ini didapat pada jaringan 4 *hidden layer* dengan 25 *node hidden layer*, yang memiliki nilai MAD sebesar 2,717,429 kWh dan MAPE sebesar 2.59%. Fungsi pelatihan TRAINGDM dapat diketahui bahwa jaringan terbaik fungsi pelatihan ini didapat pada jaringan 1 *hidden layer* dengan 3 *node hidden layer*, yang memiliki nilai MAD sebesar 4,337,413 kWh dan MAPE

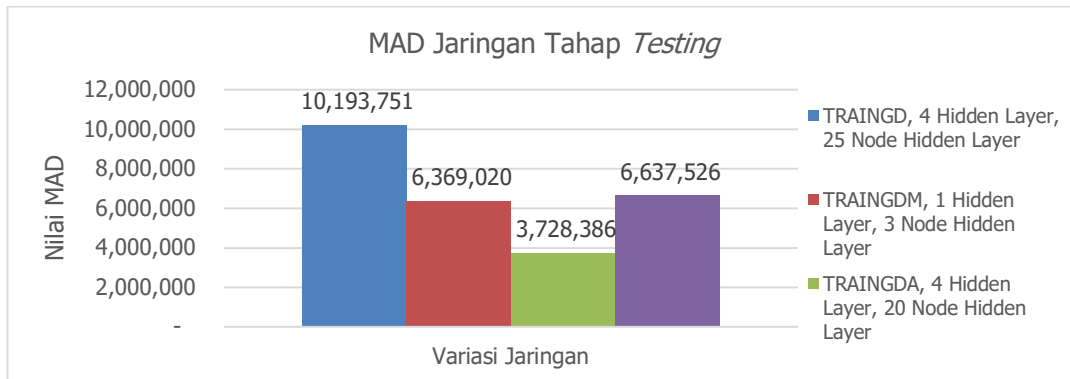
sebesar 4.41%. Fungsi pelatihan TRAINGDA dapat diketahui bahwa jaringan terbaik fungsi pelatihan ini didapat pada jaringan 4 *hidden layer* dengan 20 *node hidden layer*, yang memiliki nilai MAD sebesar 2,624,072 kWh dan MAPE sebesar 2.79%. Fungsi pelatihan TRAINGDX dapat diketahui bahwa jaringan terbaik fungsi pelatihan ini didapat pada jaringan 4 *hidden layer* dengan 3 *node hidden layer*, yang memiliki nilai MAD sebesar 2,829,054 kWh dan MAPE sebesar 2.93%. Empat variasi jaringan terbaik dengan nilai MAD dan MAPE paling kecil dari setiap fungsi pelatihan tersebut yang selanjutnya akan digunakan pada tahap *testing* jaringan.

3.2 Testing

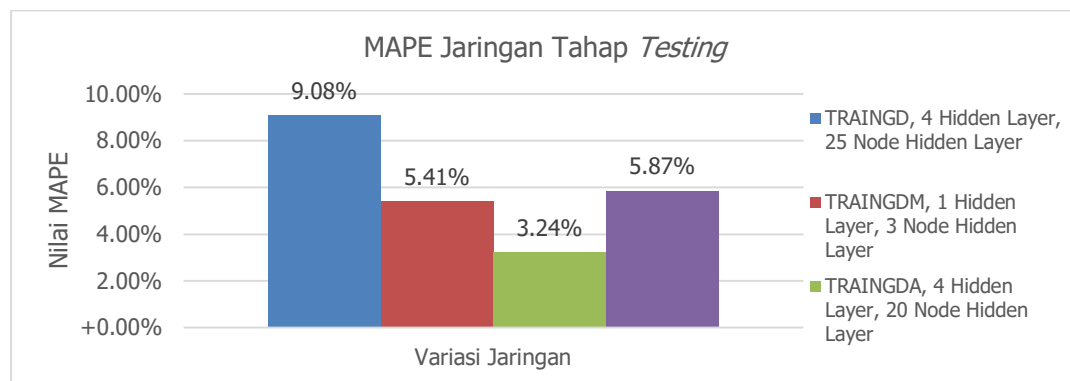
Tahap *testing* dilakukan untuk menguji keempat variasi jaringan terbaik dari tahap *training* untuk mendapatkan satu variasi jaringan terbaik yang akan digunakan untuk estimasi beban energi listrik. Adapun nilai MAD dan MAPE pada tahap *testing* ditampilkan pada Tabel 3, Gambar 3, dan Gambar 4.

Tabel 3. Nilai dan Persentase Error Hasil Testing

Fungsi Pelatihan	<i>Hidden Layer</i>	<i>Node</i>	MAD	MAPE
TRAINGD	4	25	2,717,429	2.59%
TRAINGDM	1	3	6,369,020	5.41%
TRAINGDA	4	20	3,728,386	3.24%
TRAINGDX	4	3	2,829,054	2.93%



Gambar 3. Grafik Nilai MAD Testing Jaringan




Gambar 4. Grafik Nilai MAPE Testing Jaringan

Berdasarkan hasil *testing* jaringan yang sudah dilakukan pada empat variasi jaringan berbeda yang merupakan variasi jaringan terbaik setiap fungsi pelatihan pada tahap *training*, menunjukkan bahwa hasil *testing* baik nilai MAD dan MAPE memiliki nilai yang beragam. Semua jaringan yang di-*testing* memiliki nilai MAPE yang termasuk kriteria akurasi estimasi yang sangat baik karena memiliki nilai MAPE <10%. Rata-rata nilai MAD dan MAPE keempat jaringan tersebut sebesar 6,732,171 kWh dan 5.9%. Variasi jaringan yang terbaik dengan memiliki nilai MAD dan MAPE paling kecil yang didapatkan pada tahap *testing* yaitu variasi jaringan TRAIINGDA 4 *hidden layer* dengan 20 *node hidden layer* yang memiliki nilai MAD sebesar 3,728,386 kWh dan MAPE sebesar 3.24%. Variasi jaringan terbaik tersebut yang akan digunakan untuk estimasi beban energi listrik.

3.3 Estimasi

Estimasi beban energi listrik dilakukan dengan memilih satu jaringan dari semua variasi jaringan yang sebelumnya sudah melewati tahap *training* dan *testing*. Jaringan yang dipilih dan digunakan dalam tahap estimasi yaitu TRAIINGDA 4 *hidden layer* dengan 20 *node hidden layer* yang merupakan jaringan terbaik dengan *error* terkecil pada tahap *testing*. Jaringan terbaik tahap *testing* dipilih untuk diimplementasikan pada tahap estimasi karena saat diujikan dapat menghasilkan *output* yang mendekati nilai real data sehingga ketika digunakan untuk estimasi juga akan menghasilkan *output* yang akan mendekati nilai realnya. Untuk hasil estimasi beban energi listrik pada PT PLN (Persero) UP3 Salatiga ditampilkan pada Gambar 5.



Gambar 5. Grafik Hasil Estimasi Beban Energi Listrik PT PLN (Persero) UP3 Salatiga Tahun 2022-2026

Hasil estimasi beban energi listrik PT PLN (Persero) UP3 Salatiga pada tahun 2022-2026 menunjukkan bahwa beban energi listrik memiliki nilai yang fluktuatif dalam rentang lima tahun kedepan. Rata-rata beban energi listrik lima tahun kedepan diperkirakan mencapai 1,274,104,970 kWh per tahun, atau total beban energi listrik lima tahun kedepan mencapai 6,370,524,854 kWh. Beban energi listrik tertinggi diperkirakan akan terjadi pada tahun 2022 dengan nilai 1,278,867,573 kWh, sedangkan beban energi listrik paling kecil diperkirakan terjadi pada tahun 2023 dengan nilai 1,272,107,991 kWh.

4. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan, pemodelan *JST-multilayer perceptron* terbaik untuk estimasi beban energi listrik PT PLN (Persero) UP3 Salatiga tahun 2022-2026 yaitu

TRAIINGDA 4 *hidden layer* dengan 20 *node hidden layer*, model jaringan ini pada tahap *training* menghasilkan *output* dengan nilai MAD sebesar 2,624,072 kWh dan MAPE sebesar 2.79%. serta pada tahap *testing* menghasilkan *output* dengan nilai MAD sebesar 3,728,386 kWh dan MAPE sebesar 3.24%. Variasi jaringan ini dapat menghasilkan *output* dengan MAD dan MAPE terkecil tahap *testing*, dengan nilai *error* tersebut menunjukkan bahwa model estimasi menggunakan JST-*multilayer perceptron* yang diusulkan memiliki akurasi estimasi yang lebih baik dibandingkan yang selama ini digunakan oleh PLN yang memiliki nilai *error* 5.56%. Hasil estimasi beban energi listrik di PT PLN (Persero) UP3 Salatiga menggunakan JST-*multilayer perceptron* dengan arsitektur jaringan tersebut: tahun 2022 sebesar 1,278,867,573 kWh, tahun 2023 sebesar 1,274,074,800 kWh, tahun 2024 sebesar 1,272,107,991 kWh, tahun 2025 sebesar 1,272,151,388 kWh, dan tahun 2026 sebesar 1,273,323,104 kWh.

DAFTAR RUJUKAN

- Alkusma, Y. M., Hermawan, H., & Hadiyanto, H. (2016). Pengembangan Potensi Energi Alternatif Dengan Pemanfaatan Limbah Cair Kelapa Sawit Sebagai Sumber Energi Baru Terbarukan Di Kabupaten Kotawaringin Timur. *Jurnal Ilmu Lingkungan*, 14(2), 96–102. <https://doi.org/10.14710/jil.14.2.96-102>
- Andrijasa, M. F., & Mistianingsih, D. (2010). Penerapan Jaringan Syaraf Tiruan Untuk Memprediksi Jumlah Pengangguran di Provinsi Kalimantan Timur Dengan Menggunakan Algoritma Pembelajaran Backpropagation. *Jurnal Informatika Mulawarman*, 5(1), 50–55.
- Astuti, Y., Novianti, B., Hidayat, T., Maulina, D., Universitas, M. I., & Yogyakarta, A. (2019). Penerapan Metode Single Moving Average Untuk Peramalan Penjualan Mainan Anak. *SENSITIF: Seminar Nasional Sistem Informasi Dan Teknologi Informasi*, (pp. 253–261).
- Aulia, R. (2018). Penerapan Metode Backpropagation Untuk Memprediksi Jumlah Kunjungan Wisatawan berdasarkan Tingkat Hunian Hotel. *JURTEKSI (Jurnal Teknologi Dan Sistem Informasi)*, IV(2), 115–122.
- Dudek, G. (2020). Multilayer perceptron for short-term load forecasting: from global to local approach. *Neural Computing and Applications*, 32(8), 3695–3707. <https://doi.org/10.1007/s00521-019-04130-y>
- Fachri, B., Perdana Windarto, A., & Parinduri, I. (2019). Penerapan Backpropagation dan Analisis Sensitivitas pada Prediksi Indikator Terpenting Perusahaan Listrik. *JEPIN (Jurnal Edukasi Dan Penelitian Informatika)*, 5(2), 202–208. <https://www.bps.go.id>
- Fitri, E., & Riana, D. (2022). Analisa Perbandingan Model Prediction Dalam Prediksi Harga Saham Menggunakan Metode Linear Regression, Random Forest Regression Dan Multilayer Perceptron. *METHOMIKA: Jurnal Manajemen Informatika Dan Komputerisasi Akuntansi*, 6(1), 69–78. <https://doi.org/10.46880/jmika.Vol6No1.pp69-78>

- Hadimarta, T. F., Rotul Muhima, R., Kurniawan, M., Informatika, J. T., Teknik, F., Dan, E., & Informasi, T. (2020). Implementasi Multilayer Perceptron Pada Jaringan Saraf Tiruan Untuk Memprediksi Nilai Valuta Asing. *INTEGER: Journal of Information Technology*, 5(1), 56–63.
- Hutabarat, P. H., Zambak, M. F., & Suwarno, S. (2022). Prediksi Kebutuhan Energi Listrik Wilayah PLN Kota Parapat Simalungun Sampai Tahun 2024. *JESCE (Journal of Electrical and System Control Engineering)*, 5(2), 52–58. <https://doi.org/10.31289/jesce.v5i2.5757>
- Khusniyah, T. W., & Sutikno. (2016). Prediksi Nilai Tukar Petani Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Scientific Journal of Informatics*, 3(1), 11–18. <http://journal.unnes.ac.id/nju/index.php/sji>
- Lingga, P. (2020). Implementasi Diagnosa Penyakit Panleukopenia Pada Kucing Dengan Menggunakan Jaringan Saraf Tiruan Multi Layer Perceptron (Studi Kasus: Clinic Sasmita Pet Shop). *Jurnal Informasi Dan Teknologi Ilmiah (INTI)*, 3(3), 275–278.
- Maulidin, M. S., & Assaffat, L. (2014). Jaringan Syaraf Tiruan Sebagai Metode Peramalan Beban Listrik Harian Di PT. Pismatex Pekalongan. *Media Elekrika*, 3(2), 36–44.
- Naser, S. A., Zaqout, I., Ghosh, M. A., Atallah, R., & Alajrami, E. (2015). Predicting Student Performance Using Artificial Neural Network: in the Faculty of Engineering and Information Technology. *International Journal of Hybrid Information Technology*, 8(2), 221–228. <https://doi.org/10.14257/ijhit.2015.8.2.20>
- Nurhayati. (2015). Jaringan Saraf Tiruan Backpropagation Untuk Menentukan Tingkat Pencemaran Air. *Jurnal Sistem Informasi Dan Teknologi Informasi*, 4(2), 124–131.
- Nyoman, I., Wardana, K., Jawas, N., Komang, I., & Aryanto, A. A. (2020). Prediksi Penggunaan Energi Listrik pada Rumah Hunian Menggunakan Long Short-Term Memory. *TIERS Information Technology Journal*, 1(1), 1–11. <http://journal.undiknas.ac.id/index.php/tiers>
- Rajagukguk, A. S. F., Marthinus P, & Meita R. (2015). Kajian Perencanaan Kebutuhan dan emenuhan Energi Listrik di Kota Manado. *Jurnal Teknik Elektro Dan Komputer*, 4(3), 1–12.
- Rodrigues, F., Cardeira, C., & Calado, J. M. F. (2014). The daily and hourly energy consumption and load forecasting using artificial neural network method: A case study using a set of 93 households in Portugal. *Energy Procedia*, 62, 220–229. <https://doi.org/10.1016/j.egypro.2014.12.383>

- Sakinah, N. P., Cholissodin, I., & Widodo, A. W. (2018). Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(7), 2612–2618. <http://j-ptiik.ub.ac.id>
- Saragih, I. C., Hartama, D., & Wanto, A. (2020). Prediksi Perkembangan Jumlah Pelanggan Listrik Menurut Pelanggan Area Menggunakan Algoritma Backpropagation. *Technology and Science (BITS)*, 2(1), 48–54.
- Saritas, M. M., & Yasar, A. (2019). Performance Analysis of ANN and Naive Bayes Classification Algorithm for Data Classification. *International Journal Of Intelligent Systems and Applications in Engineering*, 7(2), 88–91. <https://doi.org/10.1039/b000000x>
- Setyowati, D., & Sunardiyo, S. (2020). Prakiraan Kebutuhan Energi Listrik dengan Jaringan Saraf Tiruan (Artificial Neural Network) Metode Backpropagation Tahun 2020-2025. *Jurnal EECIS*, 14(1), 6–9. <https://jurnaleeccis.ub.ac.id/>
- Sharma, A., & Nijhawan, G. (2015). Rainfall Prediction Using Neural Network. *International Journal of Computer Science Trends and Technology*, 3(3), 65–69. www.ijcstjournal.org
- Simangunsong, F. R. D. B., & Nasution, S. D. (2015). Aplikasi Jaringan Saraf Tiruan Untuk Memprediksi Jumlah Pasien Rawat Inap Dengan Metode Back Propagation (Studi Kasus : RSUD. Tere Margareth). *Jurnal Riset Komputer (JURIKOM)*, 2(6), 43–47.
- Simbolon, I. A. R., Yatussa'ada, F., & Wanto, A. (2018). Penerapan Algoritma Backpropagation dalam Memprediksi Persentase Penduduk Buta Huruf di Indonesia. *Jurnal Informatika UPGRIS*, 4(2), 163–169.
- Sinaga, D. (2020). Jaringan Saraf Tiruan Infeksi Mata Dengan Menggunakan Metode Berarsitektur Multi Layer Perceptron. *Jurnal Majalah Ilmiah Informasi Dan Teknologi Ilmiah (INTI)*, 7(2), 189–192.
- Syahputra, R., Syahfitra, F. D., Putra, K. T., & Soesanti, I. (2020). Prediksi Beban Listrik Menggunakan Algoritma Jaringan Syaraf Tiruan Tipe Propagasi-Balik (Electricity Load Prediction Using Back-Propagation Neural Networks). *Semesta Teknika*, 23(2), 143–155. <https://doi.org/10.18196/st.232264>
- Syahrudy, Novriyenni, & Indah Ambarita. (2022). Estimasi Jumlah Perceraian Menggunakan Metode Regresi Linear Berganda Studi Kasus Pengadilan Agama Stabat. *Jurnal Informatika Kaputama (JIK)*, 6(3), 793–798.
- Triwulan, Y., Hariyanto, N., & Anwari, S. (2013). Peramalan Beban Puncak Listrik Jangka Pendek Menggunakan Metode Jaringan Syaraf Tiruan. *Jurnal Reka Elkomika*, 1(4), 339–439.

Wijaya, A. H. (2019). Artificial Neural Network Untuk Memprediksi Beban Listrik dengan Menggunakan metode Backpropagation (Studi Kasus PT. PLN Regional Sumatera Barat). *Jurnal CoreIT*, 5(2), 61–71.