

Forecasting Electricity Sales Using the Artificial Neural Network Backpropagation Method

Yosi Febria Utami^{1*}, Gumgum Darmawan², Resa Septiani Pontoh³

Program Studi Statistika, Universitas Padjadjaran

Corresponding Author: Yosi Febria Utami yosi19002@mail.unpad.ac.id

ARTICLE INFO

Keywords: Forecasting,
Electricity Sales, Artificial
Neural Network
Backpropagation

Received : 21 August

Revised : 25 September

Accepted: 27 October

©2023 Utami, Darmawan, Pontoh:
This is an open-access article
distributed under the terms of the
[Creative Commons Atribusi 4.0
Internasional](https://creativecommons.org/licenses/by/4.0/).



ABSTRACT

PT PLN operates in the field of providing electrical energy and one of its goals is to meet consumer needs for electrical energy now and in the future, as well as PLN UID West Java. The initial step is to estimate how much electricity will be sold in the future. For this reason, electricity sales forecasting is carried out which can be taken into consideration by PLN UID West Java in making decisions. This research uses monthly electricity sales data in West Java for the last ten years. This data is not linear and not stationary, so an alternative method is used, namely Artificial Neural Network Backpropagation. Forecasting produces the best network architecture 12-7-1 with a MAPE of 2.965%. This architectural model is used to forecast electricity sales in West Java until August 2024.

Peramalan Penjualan Tenaga Listrik dengan Menggunakan Metode Artificial Neural Network Backpropagation

Yosi Febria Utami^{1*}, Gumgum Darmawan², Resa Septiani Pontoh³
Program Studi Statistika, Universitas Padjadjaran

Corresponding Author: Yosi Febria Utami yosi19002@mail.unpad.ac.id

ARTICLE INFO

Kata Kunci: Peramalan,
Penjualan Tenaga Listrik,
*Artificial Neural Network
Backpropagation*

Received : 21 Agustus

Revised : 25 September

Accepted: 27 Oktober

©2023 Utami, Darmawan, Pontoh:

This is an open-access article
distributed under the terms of the

[Creative Commons Atribusi 4.0
Internasional](https://creativecommons.org/licenses/by/4.0/).



ABSTRAK

PT PLN bergerak di bidang penyediaan energi listrik dan salah satu tujuannya adalah untuk memenuhi kebutuhan konsumen akan energi listrik saat ini maupun di masa depan, begitu juga PLN UID Jawa Barat. Langkah awalnya adalah memperkirakan berapa banyak tenaga listrik yang terjual di masa depan. Untuk itu dilakukan peramalan penjualan tenaga listrik yang dapat menjadi bahan pertimbangan PLN UID Jawa Barat dalam pengambilan keputusan. Penelitian ini menggunakan data penjualan tenaga listrik bulanan di Jawa Barat sepuluh tahun terakhir. Data tersebut bersifat tidak linear dan tidak stasioner, sehingga digunakan metode alternatif yaitu Artificial Neural Network Backpropagation. Peramalan menghasilkan arsitektur jaringan terbaik 12-7-1 dengan MAPE sebesar 2,965%. Model arsitektur ini digunakan untuk meramalkan penjualan tenaga listrik di Jawa Barat hingga Agustus 2024.

PENDAHULUAN

PT PLN merupakan perusahaan yang bergerak di bidang penyediaan energi listrik dan salah satu tujuannya adalah untuk memenuhi kebutuhan konsumen akan energi listrik. Berdasarkan Pasal 28 dan Pasal 29 Undang-Undang Nomor 30 tahun 2009 tentang ketenagalistrikan, dijelaskan bahwa PLN selaku Pemegang Izin Usaha Penyediaan Tenaga Listrik untuk kepentingan umum wajib menyediakan tenaga listrik secara terus-menerus, dalam jumlah yang cukup dengan mutu dan keandalan yang baik. Untuk memenuhi kewajiban yang diminta oleh Undang-Undang tersebut, PLN harus mampu untuk melayani kebutuhan tenaga listrik saat ini maupun di masa yang akan datang, begitu juga dengan PLN UID Jawa Barat. Langkah awalnya adalah dengan memperkirakan berapa banyak tenaga listrik yang terjual di masa yang akan datang. Oleh karena itu, diperlukan suatu metode yang dapat digunakan dalam mengestimasi penjualan tenaga listrik bulanan di Jawa barat untuk waktu yang akan datang. Metode yang digunakan dalam penelitian ini yaitu *Artificial Neural Network Backpropagation*. Penelitian ini diharapkan dapat memberikan manfaat bagi PLN UID Jawa Barat dalam mendapatkan metode peramalan alternatif untuk memperkirakan penjualan tenaga listrik di masa depan. Selain itu, dapat berguna sebagai bahan evaluasi dan menjadi pertimbangan PLN UID Jawa Barat dalam pengambilan keputusan.

TINJAUAN PUSTAKA

Deret waktu dapat diklasifikasikan menjadi model linear dan nonlinear (Kitagawa, 2010). Deret waktu linear merupakan deret waktu yang setiap titiknya dapat dilihat sebagai kombinasi linear dari nilai atau perbedaan masa lalu atau masa depan. Sebaliknya, setiap penyimpangan yang terjadi dalam proses linear disebut deret waktu nonlinear (Tsay & Chen, 2019). Metode-metode linear seringkali tidak dapat mengakomodasi data yang fluktuatif sehingga sulit untuk menganalisis dan memprediksi secara akurat proses nyata yang diwakili oleh deret waktu ini (Lachtermacher, 1994). Dalam prakteknya, data deret waktu umumnya bersifat tidak stasioner yang artinya nilai deret waktu tersebut tidak berfluktuasi di sekitar rata-rata yang konstan atau dengan varian yang konstan (Hyndman & Athanasopoulos, 2018). Untuk mengatasi permasalahan tersebut diperkenalkan metode alternatif lain seperti metode *Artificial Neural Network Backpropagation*.

Artificial Neural Network (ANN) atau Jaringan Saraf Tiruan adalah suatu sistem yang memproses informasi tertentu dengan kinerja yang memiliki karakteristik seperti jaringan saraf biologi (Fausett, 1994). Berdasarkan penelitian yang telah dilakukan oleh Arungpadang dkk (2018) dapat diketahui bahwa estimasi pemakaian listrik menggunakan ANN memiliki hasil yang dapat mengikuti kecenderungan data historis dibandingkan estimasi metode peramalan tradisional yang memiliki hasil cenderung linear. *Backpropagation* melakukan pelatihan terhadap jaringan untuk menghasilkan keseimbangan antara kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa namun tidak sama dengan pola yang digunakan selama pelatihan (Jumarwanto dkk, 2009).

METODOLOGI

Data yang digunakan dalam penelitian ini adalah data historis penjualan tenaga listrik (dalam satuan kWh) yang diambil mulai dari Bulan Mei 2012 sampai dengan Bulan Agustus 2022. Total pengamatan dalam penelitian ini adalah sebanyak 124 data. Peramalan pada penelitian ini akan menggunakan *Artificial Neural Network* (ANN) dengan algoritma *Backpropagation* sebagai metode pelatihan jaringan yang akan dibentuk. ANN sendiri memiliki beberapa lapisan, secara umum terdapat tiga lapis yang membentuk *neural network*, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output* (Sudarsono, 2016). Lapisan *input* berfungsi sebagai penghubung jaringan ke sumber data. Lapisan *input* berisi unit-unit *input* yang menerima pola masukan dari luar untuk menggambarkan suatu permasalahan. Lapisan kedua disebut lapisan tersembunyi yang terletak di antara lapisan *input* dan lapisan *output*. Lapisan *output* merupakan solusi *neural network* terhadap suatu permasalahan, dimana pada penelitian ini solusinya adalah hasil peramalan.

Pembentukan Arsitektur Jaringan


Pola hubungan di antara neuron-neuron disebut dengan arsitektur jaringan (Fausett, 1994). Algoritma *backpropagation* biasanya digunakan pada jaringan *multilayer* dengan tujuan meminimalkan *error* pada keluaran yang dihasilkan oleh jaringan (Anike dkk, 2012). Oleh karena itu, penelitian ini menggunakan arsitektur *multilayer perceptron*. Terdapat tiga hal yang harus ditentukan dalam pembentukan arsitektur jaringan, yaitu banyak unit *input*, unit tersembunyi, dan unit *output*. Banyak unit pada lapisan *input* dapat ditentukan berdasarkan banyaknya variabel independen yang digunakan (Kaastra & Boyd, 1996). Banyak unit tersembunyi dalam prakteknya sering dipilih melalui eksperimen atau *trial and error*. Pada masalah peramalan, banyak unit *output* yang digunakan adalah satu neuron *output* untuk peramalan satu langkah ke depan (Zhang et al., 1998).

Pemilihan Fungsi Aktivasi

Fungsi aktivasi merupakan sebuah operasi dasar yang digunakan dalam sebuah jaringan. Fungsi aktivasi berguna membawa informasi *input* ke *output*. Pemilihan fungsi aktivasi akan didasarkan pada permasalahan yang dihadapi serta metode atau algoritma pelatihan yang digunakan dalam melatih sebuah jaringan. Fungsi aktivasi yang digunakan untuk algoritma *backpropagation* harus memiliki beberapa syarat, yaitu bersifat kontinu, terdiferensial dengan mudah, dan merupakan fungsi yang tidak menurun secara monoton (Fausett, 1994). Fungsi aktivasi yang memenuhi syarat tersebut adalah fungsi aktivasi *sigmoid biner* yang mempunyai nilai 0 sampai 1. Fungsi aktivasi *sigmoid biner* dirumuskan sebagai berikut:

$$y = f(x) = \frac{1}{1 + e^{-x}} \dots\dots\dots (1)$$

Fungsi aktivasi sigmoid biner dapat dilihat pada gambar berikut:



(Sumber: Fausett, 1994)

Gambar 1. Fungsi Aktivasi Sigmoid Biner

Normalisasi Data

Normalisasi adalah proses penskalaan nilai sehingga nilai bisa terletak pada rentang tertentu (Nasution, 2019). Normalisasi data dilakukan agar keluaran jaringan sesuai dengan fungsi aktivasi yang digunakan. Dalam penelitian ini normalisasi data akan menggunakan teknik *min-max normalization* terhadap data aktual agar menghasilkan nilai sesuai dengan rentang fungsi aktivasi yang digunakan, yaitu fungsi aktivasi *sigmoid biner* yang berada antara 0 hingga 1. Rumus normalisasi data yang digunakan dalam penelitian ini adalah sebagai berikut:

$$Y'_t = \left[\frac{(Y_t - Y_{min})}{Y_{max} - Y_{min}} \right] (b - a) + a \quad \dots \dots \dots (2)$$

Dengan,

- Y'_t : data pengamatan pada waktu ke- t setelah dinormalisasi
- Y_t : data pengamatan pada waktu ke- t
- Y_{min} : data pengamatan minimum
- Y_{max} : data pengamatan maksimum
- a : nilai interval tertinggi dari normalisasi yang dilakukan
- b : nilai interval terendah dari normalisasi yang dilakukan

Pembagian Data

Sebelum dilakukan berbagai prosedur dalam membentuk sebuah jaringan, perlu dilakukan pembagian data menjadi data latih dan data uji. Data latih adalah data yang digunakan ketika proses pelatihan untuk melakukan proses mengenali pola data dan pembelajaran data (pembentukan model). Sedangkan, data uji adalah data yang digunakan ketika proses pengujian untuk melakukan proses pengujian dari hasil pengenalan dan pembelajaran data pada proses pelatihan (pemilihan ramalan terbaik). Hal ini bertujuan untuk mendapatkan data yang cukup untuk proses pelatihan dan pengujian sehingga didapatkan hasil yang optimal. Proporsi pembagian data latih dan data uji tidak tergantung pada suatu aturan khusus. Namun pada umumnya 80% untuk data latih dan 20% untuk data uji (Hyndman & Anthanasopoulos, 2018).

Tahap Pelatihan dan Pengujian

Terdapat tiga tahapan utama dari pelatihan jaringan dengan backpropagation yaitu tahap *feedforward* dari pola pelatihan *input*, tahap perhitungan dan *backpropagation* dari nilai *error*, dan yang terakhir adalah tahap

penyesuaian bobot (Fausett, 1994). Proses pelatihan jaringan dilakukan dengan menggunakan algoritma *backpropagation* dengan tahapan sebagai berikut:

1. Inisialisasi bobot dengan nilai random sekecil mungkin.
2. Selama iterasi belum terpenuhi, maka lakukan langkah 3-10.
3. Untuk setiap pasangan data uji, lakukan langkah 4-9.
4. Langkah 4 hingga 6 merupakan tahap *feedforward*. Setiap unit *input* ($X_i, i = 1, \dots, n$) menerima sinyal *input* x_i dan meneruskan ke semua unit pada lapisan tersembunyi.
5. Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) menjumlahkan sinyal *input* terbobot dengan perhitungan sebagai berikut:

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad \dots \dots \dots (3)$$

dimana, x_i merupakan nilai sinyal *input*, v_{ij} adalah bobot vektor dari lapisan *input* ke lapisan tersembunyi, dan v_{0j} adalah nilai bias pada lapisan *input* ke lapisan tersembunyi. Nilai z_in_j tersebut kemudian diaktivasi menggunakan fungsi aktivasi yang telah ditetapkan pada lapisan tersembunyi untuk menghasilkan sinyal *output* menggunakan rumus sebagai berikut:

$$z_j = f(z_in_j) \quad \dots \dots \dots (4)$$

Selanjutnya sinyal akan dikirimkan ke semua unit pada lapisan *output*, langkah ini dilakukan sebanyak lapisan tersembunyi.

6. Setiap unit *output* ($Y_k, k = 1, \dots, m$) menjumlahkan sinyal *input* terbobot dengan perhitungan sebagai berikut:

$$y_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad \dots \dots \dots (5)$$

Gunakan fungsi aktivasi berikut untuk menghitung sinyal *output*:

$$y_k = f(y_in_k) \quad \dots \dots \dots (6)$$

Sehingga diperoleh nilai *output* y_k yang dihasilkan oleh jaringan.

7. Langkah 7 dan 8 merupakan tahap *error backpropagation*. Setiap unit *output* ($Y_k, k = 1, \dots, m$) menerima pola target sesuai dengan pola pelatihan *input*. Untuk unit k dalam lapisan *output*, dapat dihitung informasi *error* dengan rumus sebagai berikut:

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad \dots \dots \dots (7)$$

dimana t_k adalah nilai *output* yang diinginkan atau target untuk unit k , dan y_k adalah *output* nyata yang didapatkan oleh unit k di lapisan *output*, y_in_k adalah akumulasi sinyal *input* terbobot yang masuk ke unit k pada lapisan *output*, dan $f'(y_in_k)$ adalah turunan fungsi aktivasi yang digunakan pada lapisan *output*.

Selanjutnya hitung koreksi bobot (selanjutnya akan digunakan untuk memperbaiki w_{0k}) dengan laju percepatan a menggunakan rumus sebagai berikut:

$$\Delta w_{jk} = a \delta_k z_j \quad \dots \dots \dots$$

(8)

dimana, a adalah laju pembelajaran (*learning rate*), δ_k adalah informasi *error* pada unit k dalam lapisan *output*.

Kemudian hitung koreksi bias (selanjutnya akan digunakan untuk memperbarui w_{0k}) menggunakan rumus sebagai berikut:

$$\Delta w_{0k} = \alpha \delta_k \quad \dots \dots \dots (9)$$

Kirim δ_k ke unit-unit pada lapisan sebelumnya (lapisan tersembunyi).

8. Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) jumlahkan delta *input* (dari unit pada lapisan yang berada setelahnya),

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad \dots \dots \dots (10)$$

Kalikan nilai ini dengan turunan fungsi aktivasi untuk menghitung informasi *error*,

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad \dots \dots \dots (11)$$

Hitung koreksi bobot (selanjutnya akan digunakan untuk memperbarui v_{0j}),

$$\Delta v_{0j} = \alpha \delta_j \quad \dots \dots \dots (12)$$

9. Langkah 9 dan 10 merupakan tahap perubahan bobot dan bias. Setiap unit *output* ($Y_k, k = 1, \dots, m$) pada setiap lapisan *output* memperbarui nilai bias dan bobot ($j = 0, \dots, p$) dengan perhitungan sebagai berikut:

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad \dots \dots \dots (13)$$

10. Serta masing-masing unit tersembunyi ($Z_j, j = 1, \dots, p$) memperbarui nilai bias dan bobot ($i = 0, \dots, n$) dengan rumus sebagai berikut:

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad \dots \dots \dots (14)$$

11. Kondisi stop. Proses pelatihan akan terus berlanjut selama nilai *error* yang dihasilkan masih terus berkurang. Ketika nilai *error* mulai meningkat, maka jaringan sudah mengingat pola data latih dengan terlalu baik dan akan berkurang kemampuannya dalam menggeneralisasi, sehingga pelatihan perlu dihentikan dan memasuki langkah 9 yaitu kondisi stop. Selanjutnya dilakukan proses pengujian terhadap data uji yang bertujuan untuk membuktikan bahwa proses pelatihan telah menghasilkan suatu model yang terbaik dengan nilai *error* yang minimum. Model yang terbaik adalah model dengan nilai ukuran kesalahan yang terkecil baik untuk data latih maupun data uji. Proses pengujian menggunakan algoritma yang sama dengan proses pelatihan, namun hanya melalui tahapan *feedforward* saja dan tidak perlu melakukan inisialisasi bobot kembali karena nilai bobot yang digunakan adalah hasil dari proses pelatihan.

Evaluasi Model

Evaluasi model adalah sebuah proses untuk mengukur performa model yang telah dihasilkan pada proses pelatihan dan pengujian (Id, 2021). Peramalan akan dilakukan dengan model terpilih yaitu model yang memiliki nilai ukuran kesalahan terkecil pada tahap pelatihan dan pengujian. Nilai hasil

peramalan dikembalikan ke nilai aslinya untuk mendapatkan nilai output pada *range* yang sebenarnya dengan rumus:

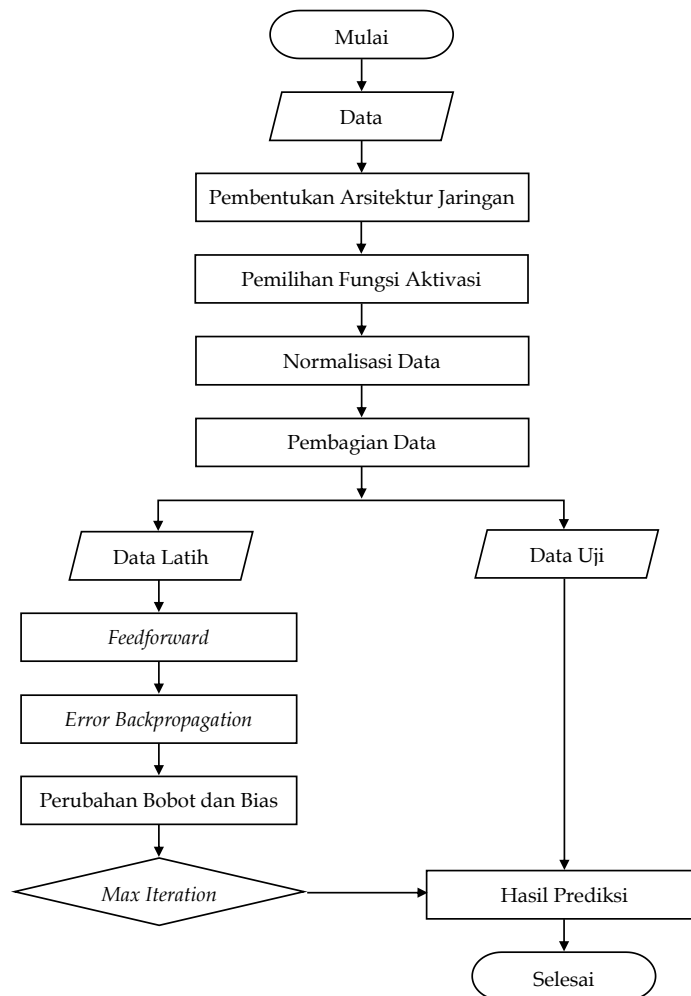
$$X_i = [X'_i \times (X_{max} - X_{min})] + X_{min} \quad \dots \dots \dots (15)$$

Ukuran performa pembelajaran algoritma backpropagation dapat menggunakan nilai *mean absolute percentage error* (MAPE) yang didefinisikan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad \dots \dots \dots (16)$$

Dengan,

- Y_t : nilai aktual pada periode ke- t
- \hat{Y}_t : nilai prediksi pada periode ke- t
- n : banyaknya pengamatan



Gambar 2. Diagram Alur Penelitian

HASIL PENELITIAN

Pembentukan Arsitektur Jaringan

Langkah pertama yang dilakukan dalam peramalan ANN adalah membentuk arsitektur pada lapisan *input*, *tersembunyi*, dan *output*. Pada data bulanan dengan periode satu tahun, *input* peramalan yang digunakan terdiri

dari 12 *input* sesuai dengan banyaknya bulan dalam satu periode (tahun). *Input* tersebut berupa data periode 12 bulan sebelumnya. Penentuan banyaknya unit tersembunyi dilakukan secara *trial and error* berdasarkan nilai MAPE terkecil yang diperoleh dari proses pengujian nanti. Adapun *output* yang digunakan dalam peramalan ini adalah sebanyak satu *output*, yaitu berupa perkiraan besarnya penjualan tenaga listrik (kWh) untuk dua tahun yang akan datang.

Normalisasi dan Pembagian Data

Normalisasi dilakukan menggunakan teknik *min-max normalization* yang kemudian menghasilkan skala nilai pada data peramalan yang berada diantara rentang 0 hingga 1. Perhitungan normalisasi dilakukan menggunakan rumus (2) yang terdapat pada bab sebelumnya. Data yang telah dinormalisasi selanjutnya dibagi menjadi data latih dengan proporsi 80% dan data uji 20%.

Tahap Pelatihan dan Pengujian


Proses pelatihan dan pengujian dilakukan dengan menggunakan *package neuralnet* pada *software R*. Saat menggunakan *package* tersebut perlu untuk mengatur terlebih dahulu besar parameter *learning rate*, banyak iterasi maksimum, fungsi aktivasi, dan pengaturan inisialisasi bobot. Dimana *learning rate* yang digunakan sebesar 0,01 dengan iterasi maksimum sebesar 100000. Fungsi aktivasi menggunakan fungsi *sigmoid biner* atau pada *software R* disebut *logistic*. Inisialisasi bobot diatur ke nilai random sesuai dengan tahapan *backpropagation*. Proses pelatihan dan pengujian dilakukan satu persatu berdasarkan banyak unit tersembunyi yang akan dicoba secara *trial and error*. Proses pelatihan dan pengujian akan berhenti setelah menghasilkan nilai kesalahan yang kecil. Ukuran evaluasi yang digunakan dalam penelitian ini adalah *mean absolute percentage error* (MAPE). Model arsitektur *backpropagation* terbaik ditentukan berdasarkan banyak unit tersembunyi yang memiliki ukuran MAPE terkecil. Berikut adalah hasil pelatihan dan pengujian beberapa model arsitektur *backpropagation* dengan jumlah unit tersembunyi yang berbeda-beda:

Tabel 1. Hasil MAPE dengan Berbagai Model Arsitektur


Model Arsitektur	MAPE Pelatihan (%)	MAPE Pengujian (%)
12-1-1	4,029	4,371
12-2-1	3,274	3,390
12-3-1	4,037	4,378
12-4-1	3,994	3,018
12-5-1	3,369	3,046
12-6-1	3,129	3,096
12-7-1	3,179	2,965
12-8-1	3,231	3,312

12-9-1	3,007	3,123
12-10-1	3,942	3,192

Berdasarkan hasil pada tabel di atas, dapat diketahui bahwa banyak unit tersembunyi yang dapat digunakan dalam peramalan ini adalah sebanyak 7 unit. Karena dengan 7 unit tersembunyi tersebut dapat menghasilkan nilai MAPE pengujian terkecil dibandingkan dengan yang lainnya. Dengan demikian, dapat diperoleh model arsitektur backpropagation terbaik dalam peramalan ini yaitu model 12-7-1. Hasil pelatihan dan pengujian ANN Backpropagation dengan model arsitektur 12-7-1 dapat dilihat pada Gambar 2 dan Gambar 3 berikut:



Gambar 3. Plot Hasil Ramalan Data Latih Model Arsitektur 12-7-1



Gambar 4. Plot Hasil Peramalan Data Uji Model Arsitektur 12-7-1

Pada gambar di atas terdapat garis putus-putus berwarna merah yang menunjukkan menunjukkan hasil ramalan menggunakan model arsitektur 12-7-1 terhadap data aktual. Berdasarkan kedua gambar di atas terlihat bahwa secara garis besar hasil peramalan pada data latih dan data uji telah mengikuti pola data aktual. Hal ini terbukti dengan nilai MAPE yang diperoleh yaitu 3,179% pada tahap pelatihan dan 2,965% pada tahap pengujian.

Hasil Peramalan

Setelah mendapatkan model arsitektur terbaik dari proses pelatihan dan pengujian, maka selanjutnya dilakukan peramalan penjualan tenaga listrik untuk 2 tahun yang akan datang. Hasil peramalan yang diperoleh dari model ANN Backpropagation masih berada dalam rentang 0 hingga 1. Oleh karena itu, hasil peramalan tersebut perlu dikembalikan ke bentuk semula dengan cara melakukan denormalisasi menggunakan rumus (15) yang telah dijelaskan sebelumnya. Hasil peramalan penjualan tenaga listrik Jawa Barat yang telah didenormalisasi dapat dilihat pada tabel berikut:

Tabel 2. Hasil Peramalan Penjualan Tenaga Listrik Jawa Barat

Tahun	Bulan	Penjualan Tenaga Listrik (kWh)
2022	September	4.526.183.009
	Oktober	4.657.802.235
	November	4.620.828.340
	Desember	4.626.195.382
2023	Januari	4.663.291.550
	Februari	4.658.689.403
	Maret	4.561.894.050
	April	4.211.599.201
	Mei	4.153.269.389
	Juni	4.336.509.075
	Juli	4.478.025.241
	Agustus	4.469.698.387
	September	4.551.810.752
	Oktober	4.608.444.690
	November	4.693.436.129
	Desember	4.666.344.479
2024	Januari	4.635.686.354
	Februari	4.296.033.061
	Maret	4.322.193.540
	April	4.518.979.569
	Mei	4.548.594.667
	Juni	4.493.096.284
	Juli	4.340.378.501
	Agustus	4.553.112.344

Dari tabel di atas dapat diketahui bahwa secara umum hasil peramalan penjualan tenaga listrik di Jawa Barat berfluktuatif sesuai dengan data historis penjualan tenaga listrik pada periode sebelumnya. Nilai peramalan penjualan tertinggi terjadi pada bulan November 2023 yaitu sebesar 4.693.436.129 kWh. Sedangkan nilai peramalan terendah terjadi pada bulan Mei 2023 yaitu sebesar 4.153.269.389 kWh.

PEMBAHASAN

Dari hasil yang telah disajikan pada bagian sebelumnya, dapat diketahui bahwa secara umum hasil peramalan penjualan tenaga listrik di Jawa Barat berfluktuatif sesuai dengan data historis penjualan tenaga listrik pada periode sebelumnya. Hasil ini dapat membantu PLN UID Jabar sebagai pertimbangan dalam menghadapi ketidakpastian naik turunnya penjualan tenaga listrik di Jawa Barat. Nilai peramalan penjualan tertinggi terjadi pada bulan November 2023 yaitu sebesar 4.693.436.129 kWh. Sedangkan nilai peramalan terendah terjadi pada bulan Mei 2023 yaitu sebesar 4.153.269.389 kWh. Metode ANN Backpropagation 12-7-1 menghasilkan nilai MAPE yang sangat kecil yaitu 2,965%. Dengan demikian, diharapkan metode ini dapat digunakan sebagai metode alternatif PLN UID Jawa Barat dalam memperkirakan penjualan tenaga listrik di masa depan. Selain itu, diharapkan penelitian ini dapat berguna sebagai bahan evaluasi dan sebagai bahan pertimbangan PLN UID Jawa Barat dalam pengambilan keputusan seperti keputusan terkait investasi, perencanaan kapasitas, penetapan harga, dan lainnya.

KESIMPULAN DAN REKOMENDASI

Berdasarkan analisis yang telah dilakukan dalam penelitian ini dapat diperoleh kesimpulan bahwa metode Artificial Neural Network Backpropagation dapat digunakan sebagai metode alternatif untuk meramalkan data penjualan tenaga listrik di Jawa Barat. Model arsitektur terbaik diperoleh setelah melakukan trial and error dalam penentuan banyak unit tersembunyi. Diperoleh arsitektur jaringan ANN Backpropagation terbaik yaitu 12-7-1 dengan 12 unit pada lapisan input, 7 unit pada lapisan tersembunyi, dan 1 unit pada lapisan output dengan nilai MAPE sebesar 2,96%. Metode Artificial Neural Network Backpropagation telah menghasilkan nilai ramalan untuk data penjualan listrik di Jawa Barat hingga Agustus 2024 yang dapat dijadikan PT PLN (Persero) UID Jawa Barat sebagai bahan evaluasi dan pertimbangan dalam pengambilan keputusan di masa yang akan datang.

PENELITIAN LANJUTAN

Setiap penelitian memiliki keterbatasan. Dengan demikian, penelitian selanjutnya diharapkan dapat menemukan faktor-faktor yang mempengaruhi penjualan tenaga listrik agar mendapatkan hasil peramalan yang lebih sesuai dengan keadaan sebenarnya.

UCAPAN TERIMA KASIH

Pada penyusunan artikel ini, Kami mendapatkan banyak bantuan dari berbagai pihak sehingga dapat memperlancar penyusunan artikel ini. Oleh

karena itu, Kami mengucapkan terimakasih kepada PLN UID Jawa Barat yang telah memberikan izin dalam melakukan penelitian ini. Selanjutnya terimakasih kepada Dosen-Dosen Program Studi Statistika yang telah memberikan banyak ilmu yang bermanfaat dan membimbing penulis selama penelitian ini. Dan terimakasih kepada seluruh pihak yang tidak dapat disebutkan satu persatu.

DAFTAR PUSTAKA

- Anike, Marleni. (2012). Pengembangan Sistem Jaringan Syaraf Tiruan dalam Memprediksi Jumlah Dokter Keluarga Menggunakan Backpropagation (Studi Kasus: Regional X cabang Palu). Doctoral dissertation, Universitas Atma Jaya Yogyakarta.
- Arungpadang, T. A., Hontong, F. A., & Tarigan, L. (2018). Analisis Kebutuhan Energi Listrik dengan Jaringan Syaraf Tiruan. *Jurnal Tekno Mesin*, 4(2).
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice Hall, Inc.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- Id, Ibnu Daqiqil. (2021). *Machine Learning: Teori, Studi Kasus dan Implementasi Menggunakan Python (Vol. 1)*. Pekanbaru: Unri Press.
- Jumarwanto, A., Hartanto, R., & Prastiyanto, D. (2009). Aplikasi Jaringan Syaraf Tiruan Backpropagation untuk Memprediksi Penyakit THT di Rumah Sakit Mardi Rahayu Kudus. *Jurnal Teknik Elektro*, 1(1).
- Kitagawa, Genshiro. (2010). *Introduction to Time Series Modeling*. Boca Raton: Chapman & Hall/CRC.
- Kaastra, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215-236.
- Lachtermacher, G., & Fuller, J. D. (1994). Backpropagation in hydrological time series forecasting. *Stochastic and Statistical Methods in Hydrology and Environmental Engineering: Time Series Analysis in Hydrology and Environmental Engineering*, 229-242.
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan normalisasi data untuk klasifikasi wine menggunakan algoritma K-NN. *CESS (Journal of Computer Engineering, System and Science)*, 4(1), 78-82.
- Sudarsono, A. (2016). Jaringan Syaraf Tiruan Untuk Memprediksi Laju Pertumbuhan Penduduk Menggunakan Metode Bacpropagation (Studi Kasus Di Kota Bengkulu). *Jurnal Media Infotama*, 12(1).

Tsay, R. S. & Chen, R. (2019). *Nonlinear Time Series Analysis*. New York: John Wiley and Sons.

Undang-Undang Republik Indonesia Nomor 30 Tahun 2009.

Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*, 14 (1), 35-62.