

PRAKIRAAN KEBUTUHAN ENERGI LISTRIK WILAYAH PROVINSI JAWA TENGAH MENGGUNAKAN METODE *BACKPROPAGATION* *NEURAL NETWORK* DAN METODE EKSTRAPOLASI LINIER

Deva Okky Deltania

Fakultas Teknik, Program Studi Teknik Elektro

Universitas Negeri Semarang

Email: devaokkydeltania18@students.unnes.ac.id

Yohanes Primadiyono

Fakultas Teknik, Program Studi Teknik Elektro

Universitas Negeri Semarang

Email: primasigma@mail.unnes.ac.id

ABSTRAK

Kebutuhan energi listrik mengalami peningkatan seiring dengan berjalannya waktu. Faktor-faktor yang mempengaruhi peningkatan tersebut, diantaranya yaitu laju pertumbuhan penduduk, permintaan kebutuhan listrik dalam berbagai sektor seperti rumah tangga, industri, bisnis, social atau public dan juga kenaikan PDRB suatu wilayah. PLN sebagai perusahaan penyedia listrik harus memikirkan hal tersebut agar terjadi keseimbangan supply dan demand. Salah satu cara yang dapat dilakukan oleh PLN yaitu memprakirakan kebutuhan energi listrik di masa yang akan datang. Metode Backpropagation Neural Network (Jaringan Syaraf Tiruan) dan metode Ekstrapolasi Linier digunakan untuk memprakirakan kebutuhan listrik di wilayah Provinsi Jawa Tengah dari tahun 2022-2027. Hasil dari penelitian ini menunjukkan pada metode Backpropagation Neural Network arsitektur jaringan terbaik menggunakan model fungsi pembelajaran LEARNGDM, fungsi pelatihan TRAINGDX dengan 30 neuron yang menghasilkan nilai MAPE atau nilai rata-rata error dengan data aktual PLN terkecil yaitu 5.4%. Sedangkan pada metode Ekstrapolasi Linier prakiraan yang dihasilkan menunjukkan nilai MAPE atau nilai rata-rata error dengan data aktual PLN sebesar 10.7%.

Kata kunci: Prakiraan kebutuhan energi listrik, Backpropagation Neural Network, Matlab, Ekstrapolasi Linier

ABSTRACT

The need for electrical energy has increased over time. Factors influencing this increase include the rate of population growth, the demand for electricity in various sectors such as household, industrial, business, social or public as well as an increase in the PDRB of a region. PLN as an electricity supply company must think about this so that there is a balance of supply and demand. One way that can be done by PLN is to predict the need for electrical energy in the future. The Backpropagation Neural Network method and the Linear Extrapolation method are used to predict electricity demand in the Central Java Province region from 2022-2027. The results of this study show that the Backpropagation Neural Network method has the best network architecture using the LEARNGDM learning function model, the TRAINGDX training function with 30 neurons which produces the MAPE value or the average error value with the smallest PLN actual data, namely 5.4%. Whereas in the Linear Extrapolation method the resulting forecast shows the MAPE value or the average error value with the actual PLN data of 10.7%.

Keywords: Forecast of electricity demand, Backpropagation Neural Network, Matlab, Linear Extrapolation

1. PENDAHULUAN

Kebutuhan energi listrik akan terus mengalami peningkatan seiring dengan berjalannya waktu, laju pertumbuhan penduduk, dan keragaman aktivitas manusia di dunia. Diantara beberapa faktor tersebut, laju pertumbuhan penduduk menjadi faktor yang utama. Berdasarkan data yang diperoleh dari Badan Pusat Statistik Jawa Tengah (BPS) Jateng, laju pertumbuhan penduduk di Provinsi Jawa Tengah dari tahun ke tahun terus mengalami perubahan. Sedangkan jumlah pengguna kebutuhan energi listrik di Wilayah Provinsi Jawa Tengah pada tahun 2016-2021 pada tiap tahunnya terus mengalami peningkatan. Konsumsi energi listrik selama tahun 2016-2021 disajikan dalam Tabel 1 berikut ini:

Tabel 1. Kebutuhan Energi Listrik Wilayah Provinsi Jawa Tengah tahun 2016-2021

<i>Tahun</i>	<i>Kebutuhan Energi Listrik Wilayah Provinsi Jawa Tengah tahun 2016-2021</i>
2016	9.191.764
2017	9.603.887
2018	10.011.388
2019	10.393.738
2020	10.727.635
2021	11.100.297

Ketersediaan akan energi listrik tersebut merupakan masalah kompleks, karena akan timbul masalah jika penyediaan energi listrik kurang tetapi permintaan energi listrik bertambah. Oleh karena itu perlu adanya perencanaan atau prakiraan agar kebutuhan konsumen terhadap energi listrik dapat terpenuhi. Peramalan atau prakiraan beban daya yang akurat adalah alat yang efektif untuk perusahaan penyedia listrik seperti PLN dalam mengoptimalkan keputusan penjadwalan keseimbangan beban, memaksimalkan keuntungan mereka dan meminimalkan kemungkinan kecelakaan seperti gangguan, kelebihan beban, dll [1].

Ada beberapa metode yang dilakukan untuk memprakirakan kebutuhan energi listrik, diantaranya yaitu metode *Backpropagation Neural Network* (Jaringan Syaraf Tiruan) dan metode Ekstrapolasi Linier. Salah satu jenis dari algoritma JST adalah *Backpropagation*. Jaringan syaraf tiruan *Backpropagation* merupakan salah satu metode yang dapat memproyeksikan besarnya konsumsi energi listrik di masa yang akan datang dengan pola konsumsi energi listrik pada masa lampau [2]. Algoritma *backpropagation* menggunakan pembelajaran yang diawasi, yang berarti bahwa disediakan algoritma dengan contoh input dan output jaringan yang akan dihitung, dan kemudian kesalahan (selisih antara hasil aktual dan yang diharapkan) juga dapat dihitung. Fungsi dari algoritma *backpropagation* adalah untuk mengurangi kesalahan daripada metode ANN [3]. Prediksi prakiraan kebutuhan energi listrik dilakukan di wilayah provinsi Jawa Tengah dengan kepadatan penduduk yang relatif banyak. Dengan begitu kebutuhan akan energi listrik di wilayah tersebut juga banyak. Konsumsi energi listrik di wilayah Jawa Tengah cukup fluktuatif, dimana mengalami peningkatan ketika bulan Mei dan Oktober dan mengalami penurunan pada bulan Februari dan Agustus. Adanya peningkatan konsumsi energi listrik seiring dengan pertumbuhan penduduk memiliki pola yang relatif sama dari tahun ke tahun. Pola inilah yang digunakan dalam proses pembelajaran metode jaringan syaraf tiruan yaitu *Backpropagation Neural Network*.

Penelitian dari (Ujianto & Winardi, 2014) [11] yang berjudul *Proyeksi Kebutuhan Energi Listrik Apj Pekalongan Tahun 2014-2018 Menggunakan Jaringan Saraf Tiruan Metode Backpropagation Dengan Software Matlab R2014a*. Penelitian itu membuat sebuah peramalan konsumsi energi listrik untuk mengoptimalkan penyediaan energi listrik. Metode yang digunakan adalah jaringan saraf tiruan *Backpropagation* dengan menggunakan software Matlab R2014a. Peramalan dilakukan di APJ Pekalongan untuk masa peramalan tahun 2014 hingga 2018. Konsumsi energi pada suatu daerah pada umumnya memiliki karakter tersendiri. Karakter tersebut dapat dipengaruhi beberapa faktor seperti PDRB (Product Domestic Regional Bruto) dan jumlah pelanggan baik itu Rumah Tangga, Industri, Komersial, dan Umum. Hasil peramalan jaringan saraf


tiruan Backpropagation menunjukkan kenaikan dari 878.863 KWH pada tahun 2013 menjadi sebesar 1.235.000 MWH pada tahun 2018. Konsumsi energi listrik mengalami kenaikan sebesar 358.137 MWH dengan kenaikan rata-rata tiap tahunnya sebesar 7.08%.

Pada penelitian sebelumnya hanya menggunakan metode Backpropagation sedangkan pada penelitian ini juga menggunakan peramalan secara numerik. Salah satunya adalah teknik ekstrapolasi yang merupakan metode untuk menaksir suatu fungsi. Solusi ini adalah cara untuk mencari fungsi dengan mencocokkan titik-titik data di dalam tabel-tabel [4]. Pendekatan seperti ini di dalam metode numerik disebut pencocokan kurva (*curve fitting*). Fungsi yang diperoleh dengan pendekatan ini merupakan fungsi hampiran, karena itu nilai fungsinya tidak setepat nilai sejatinya. Pada penelitian ini akan dilakukan percobaan prediksi energi listrik dengan memperhatikan akurasi dan tingkat kesalahan sebagai evaluasi hasil prakiraan MAPE Mean Absolute Percentage menggunakan teknologi sistem cerdas yaitu Backpropagation Neural Network dan menggunakan metode ekstrapolasi linier yang akan dibandingkan hasil dari keduanya dengan data aktual dari PT. PLN (Persero) Distribusi Jateng & DIY-Semarang Jawa Tengah.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode penelitian kuantitatif. Penelitian ini bertujuan melakukan prakiraan atau peramalan kebutuhan energi listrik di wilayah Provinsi Jawa Tengah dan menentukan nilai Mean Absolute Percent Error MAPE dengan menggunakan data-data yang diperoleh dari PT. PLN (Persero) Distribusi Jateng & DIY-Semarang, Jawa Tengah. Data yang diperoleh akan diolah dengan metode perhitungan matematis yang disajikan dalam bentuk diagram maupun grafik untuk memperoleh model arsitektur prakiraan kebutuhan energi listrik di wilayah Provinsi Jawa Tengah. Kemudian hasil yang didapatkan akan dihitung nilai *Mean Absolute Percent Error* MAPE untuk melihat tingkat akurasi terhadap angka prakiraan dan angka realisasi [5].

2.1. Metode Backpropagation Neural Network



Gambar 1. Diagram Alur Penelitian Metode *Backpropagation*

Berdasarkan Gambar 1 diagram alur di atas pada gambar 1 adalah alur dari sistem yang akan digunakan, dimulai dari pengumpulan data hingga nantinya didapatkan hasil prakiraan yang akan dibandingkan dengan nilai data aktual dari PLN. Langkah-langkah dalam penelitian ini adalah sebagai berikut:

1. Pengumpulan Data
Data yang dibutuhkan diambil dari data PT. PLN (Persero) Distribusi Jateng & DIY Semarang dan laporan statistik pln.go.id untuk wilayah Provinsi Jawa Tengah meliputi:
 - a. Pelanggan PLN jenis rumah tangga
 - b. Pelanggan PLN jenis bisnis
 - c. Pelanggan PLN jenis industry
 - d. Pelanggan PLN jenis sosial
 - e. Jumlah penduduk atau populasi
 - f. PDRB
 - g. Jumlah energi yang terjual
2. Normalisasi Data
Normalisasi data merupakan kegiatan yang mengubah skala nilai data dengan satuan GWh yang akan di inputkan menjadi nilai yang lebih kecil tanpa mengubah kandungan makna pada data tersebut.
3. Pengaturan Parameter Jaringan
Pengaturan parameter jaringan dilakukan setelah menentukan data. Kegiatan ini dilakukan untuk mendapatkan arsitektur pemodelan terbaik dalam analisa pengujian prakiraan kebutuhan energi listrik untuk wilayah Provinsi Jawa Tengah.
4. Pelatihan Model Jaringan

Kegiatan pelatihan model dilakukan untuk meminimalisir adanya nilai error, sehingga model jaringan dapat sesuai dan dapat dipakai untuk proses prediksi. Data tahun 2016-2021 digunakan sebagai data pelatihan model.

5. Pengujian Model

Pengujian model berfungsi untuk mengetahui ketepatan atau akurasi hasil pada model arsitektur yang dibangun, dengan membandingkan data yang sebenarnya. Data tahun 2022-2027 digunakan sebagai data pengujian model.

6. Denormalisasi Data

Denormalisasi data dilakukan untuk mengembalikan data yang masih ter-normalisasi dalam bentuk skala (0.1) ke dalam bentuk angka desimal dengan satuan GWh.

7. Pengujian dengan Data Aktual

Langkah selanjutnya dilakukan pengujian terhadap data actual untuk mengetahui akurasi prakiraan dengan mendapatkan nilai MAPE.

8. Kesimpulan dan Saran

Dalam penelitian ini penulis ingin melihat kinerja dari backpropagation neural network dalam memprakirakan kebutuhan energy listrik. Penelitian ini diharapkan dapat memperoleh hasil dengan model yang dikembangkan mendapatkan nilai MSE (Mean Square Error) yang kecil. MSE (Mean Square Error) adalah ukuran ketepatan atau kemampuan model dalam mencapai target atau nilai sesuai dengan yang diinginkan. Parameter penelitian dapat dilihat pada Tabel 2.

2.1.1. *Parameter Metode Backpropagation Neural Network*

Tabel 2. Parameter Arsitektur Backpropagation

<i>Parameter</i>	<i>Spesifikasi</i>
<i>Jumlah Neuron Lapisan Input</i>	6
<i>Neuron Pada Hidden Layer</i>	6,10,12,18,24,30
<i>Jumlah Neuron Lapisan Output</i>	1
<i>Fungsi Aktivasi Hidden Layer</i>	Pureline
<i>Fungsi Aktivasi Output Layer</i>	Pureline
<i>Jumlah Iterasi</i>	10000
<i>Max Fail</i>	16000

Input data penelitian dapat dilihat pada Tabel 3.

2.1.2. *Variabel-variabel Metode Backpropagation Neural Network*

Tabel 3. Input Model Jaringan

<i>Input</i>	<i>Keterangan</i>
<i>X1</i>	<i>Data Pelanggan Jenis Rumah Tangga</i>
<i>X2</i>	<i>Data Pelanggan Jenis Bisnis</i>
<i>X3</i>	<i>Data Pelanggan Jenis Sosial</i>
<i>X4</i>	<i>Data Pelanggan Jenis Industri</i>
<i>X5</i>	<i>PDRB</i>
<i>X6</i>	<i>Jumlah Penduduk</i>

Output data peneliian ditunjukkan pada Tabel 4.

Tabel 4. Output Model Jaringan

<i>Output</i>	<i>Keterangan</i>
---------------	-------------------

2.2. Metode Ekstrapolasi Linier

Setelah dilakukan peramalan dengan metode *Backpropagation*, langkah selanjutnya adalah melakukan peramalan dengan metode ekstrapolasi atau *time series method*.



Gambar 2. Alur Desain Penelitian Metode Ekstrapolasi Linier

Dari Gambar 2 di atas langkah atau proses yang akan dilakukan adalah sebagai berikut:

1. Pengumpulan data historis untuk peramalan dari tahun 2016-2021.
2. Identifikasi pola data yang ditunjukkan oleh data historis yang digunakan.
3. Peramalan prakiraan kebutuhan energi listrik Wilayah Provinsi Jawa Tengah menggunakan metode ekstrapolasi.
4. Menghitung hasil peramalan dengan data actual tahun 2021 untuk mengetahui keakuratan apakah mendekati nilai data actual atau sebaliknya.
5. Evaluasi hasil prakiraan dengan MSE dan MAPE.

2.3. Evaluasi Hasil Prakiraan

Setelah semua tahap dilakukan, langkah selanjutnya adalah melakukan evaluasi terhadap hasil data yang diperoleh dari kedua metode prakiraan yang digunakan. Evaluasi prakiraan menggunakan persamaan matematis MSE dan MAPE.

2.3.1. Mean Square Error (MSE)

Mean Square Error (MSE) dilatih dengan metode belajar terbimbing. Metode ini pada jaringan terdiri dari pola input dan pola target. Pelatihan dilakukan berulang-ulang sehingga dihasilkan

jaringan yang memberi tanggapan yang benar ke seluruh input. Menghitung MSE yaitu dengan cara membandingkan nilai output ($y_i(x)$) dan nilai target ($T_i(x)$). Hasilnya adalah perbedaan antara hasil dibagi dengan jumlah variabel (n). Ini akan memberikan hasil error peramalan. Selisih yang dihasilkan antara keduanya dapat ditentukan dengan cara menggunakan persamaan berikut [6].

$$MSE = \frac{1}{n} \sum_{i=1}^n (T_i(x) - y_i(x))^2 \quad (1)$$

Keterangan:

T_i = nilai output yang diinginkan atau target

Y_i = nilai output jaringan syaraf

n = jumlah observasi.

2.3.2. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan nilai rata – rata perbedaan absolut yang ada diantara nilai dari prediksi dan nilai realisasi yang disebutkan sebagai hasil persenan dari nilai realisasi. Penggunaan *Mean Absolute Percentage Error* (MAPE) pada evaluasi dari hasil prakiraan dapat melihat tingkat akurasi terhadap angka peramalan dan angka realisasi [5]. Nilai dari *Mean Absolute Percentage Error* (MAPE) dapat dihitung menggunakan persamaan sebagai berikut [7].

$$MAPE = \frac{\sum |x_t - y_t|}{x_t} \times 100\% \quad (2)$$

Dimana:

x_t = nilai actual

y_t = nilai prediksi

n = jumlah data

3. HASIL DAN PEMBAHASAN

3.1. Pengolahan Data Backpropagation Neural Network

Dalam penelitian ini, data yang digunakan merupakan data 10 tahun yang lalu atau data historis selama 10 tahun. Data tersebut meliputi data dari Badan Pusat Statistik (BPS) dan PT. PLN Unit Induk Distribusi (UID) Jateng dan DIY. Data yang digunakan meliputi data jumlah penduduk, PDRB, data jumlah pelanggan pada sektor (rumah tangga, industri, bisnis, dan social/publik), data jumlah energy tarjual pada sektor (rumah tangga, industri, bisnis, dan social/publik), tahun 2012-2021 menurut unit PLN di Provinsi Jawa Tengah. Kemudian data tersebut dibagi menjadi 2 yaitu data untuk pelatihan dan data untuk pengujian yang sebelumnya dilakukan proses transformasi menggunakan min-max normalization. Setelah semua data ditransformasi, maka data tersebut akan dilatih dan diujikan dengan arsitektur jaringan yang dibuat. Data hasil pengujian kemudian dianalisa untuk menentukan nilai kesalahan dan akurasi kesalahan terkecil dengan menggunakan MSE agar dapat menentukan arsitektur jaringan terbaik yang akan digunakan untuk proses prediksi sehingga dapat menghasilkan prediksi terakurat pada penelitian.

Tabel 5. Data Input Penelitian

Tahun	Pelanggan Rumah Tangga	Pelanggan Bisnis	Pelanggan Sosial	Pelanggan Industri	PDRB	Jumlah Penduduk	Konsumsi Energi listrik
2012	7153353	235399	188016	5429	691343115.96	32998692	16600.42
2013	7591588	253985	203449	5992	726655118.06	33264339	18205.08
2014	7922096	273999	216443	6494	764959150.95	33522663	19631.46
2015	8283579	306735	231665	7096	806775362.18	33774141	20408.19
2016	9540163	405789	261667	8375	849383564.59	34019095	21674.84
2017	9948614	443183	274955	9923	893750333	34257865	21057.04
2018	10373031	468043	285023	10492	941091144	34490835	23558.01
2019	10768909	493405	296551	12748	991516549	34718204	24750.62
2020	11107710	525183	307059	12716	965225710	36516035	25090.74
2021	11474394	565621	320923	14270	997.317.100	36742501	26661.16

3.1.1. Normalisasi Data

Setelah dilakukan pengumpulan data, data-data tersebut akan dibagi menjadi data pelatihan dan data pengujian dengan sebelumnya dilakukan proses transformasi data min-max normalization untuk memperkecil nilai data tanpa mengubah karakteristik data tersebut [8]. Dibawah ini adalah tabel data yang telah ditransformasi

Tabel 6. Transformasi Data Keseluruhan

Tahun	X1	X2	X3	X4	X5	X6	Y
2012	0.1	0.1	0.1	0.1	0.1	0.1	0.1
2013	0.181135	0.145027	0.192895	0.150944	0.192327	0.156765	0.227598
2014	0.242326	0.193513	0.271109	0.196369	0.292477	0.211965	0.341019
2015	0.309251	0.272819	0.362734	0.250843	0.401809	0.265703	0.402782
2016	0.541895	0.512789	0.543324	0.366576	0.51247	0.318046	0.503503
2017	0.617516	0.60338	0.623307	0.506651	0.629214	0.369068	0.454377
2018	0.696093	0.663606	0.683909	0.558138	0.752992	0.41885	0.653247
2019	0.769386	0.725049	0.753299	0.762278	0.884834	0.467436	0.74808
2020	0.832112	0.802034	0.816549	0.759382	0.816094	0.851607	0.775125
2021	0.9	0.9	0.9	0.9	0.9	0.9	0.9

3.1.2. Menentukan Pola Data

Dalam masa peramalan atau prakiraan, Jaringan Saraf Tiruan memerlukan data input. Data tersebut akan dimasukan ke jaringan yang sudah dilakukan pelatihan dan pengujian untuk mendapatkan hasil prakiraan. Untuk itu dilakukan proyeksi data input yang berupa jumlah penduduk, pelanggan PLN semua sektor, dan PDRB [5]. Proyeksi tersebut menggunakan bantuan *software* Ms. Excel dengan fungsi *trendline* metode linier. Data tahun 2012-2021 yang sudah didapat digunakan sebagai *source* agar diperoleh grafik persamaan yang selanjutnya digunakan untuk mendapatkan data input pada tahun 2022-2027.

3.1.3. Permodelan

Pembuatan model diperlukan untuk menentukan beberap parameter yang akan diimplementasikan ke dalam *software* Matlab. Langkah pertama dalam permodelan ini yaitu klik *new* kemudian membuat jaringan baru atau *create network or data*. Pada tampilan *create network or data* berisikan tipe jaringan, data input dan target, fungsi pelatihan, fungsi pembelajaran adaptasi, fungsi performa, jumlah layer, neuron, dan fungsi transfer.

1. Arsitektur Jaringan

Arsitektur jaringan yang digunakan pada penelitian ini menggunakan *feed-forward backprop* dalam algoritma *backpropagation*. *Backpropagation Neural Network* atau Propagasi Kembali adalah proses memperbarui dan menemukan nilai bobot atau koefisien optimal yang membantu model meminimalkan kesalahan yaitu perbedaan antara nilai aktual dan prediksi.

2. Data Input dan Data Target

Setelah data tersebut di import, data tersebut nantinya akan dipakai pada proses pelatihan *JST Backpropagation*. Kedua data tersebut digunakan untuk menentukan bobot awal dalam permodelan ini.

3. Fungsi Pelatihan

Dalam *Backpropagation* ada 14 opsi fungsi pelatihan. Pada penelitian ini fungsi pelatihan yang digunakan yaitu, TRAINGDA, TRAINGD, dan TRAINGD_X. Sedangkan pada *adaption learning function* ada 2 opsi pilihan yaitu LEARNGD, dan LEARNGDM. Pada penelitian ini digunakan kedua opsi tersebut dalam melakukan pelatihan jaringan.

4. Jumlah Layer dan Fungsi Aktivasi

Pada penelitian ini digunakan 2 lapisan layer, yaitu 1 lapisan layer tersembunyi dan 1 lapisan *output* dengan 6 variabel input 1 variabel output. Sedangkan diantara lapisan input dan output terdapat lapisan tersembunyi yang berjumlah 1-5 buah. Lapisan tersembunyi akan berfungsi menentukan jumlah neuron. Lapisan tersembunyi yang digunakan berbeda-beda yaitu 6, 12, 18, 24 dan 30.

Fungsi aktivasi yang digunakan pada pelatihan ini yaitu LOGSIG, sedangkan pada proses pengujian dan prediksi, fungsi aktivasi yang digunakan adalah PURELINE. Setelah semua parameter diisi sesuai dengan yang diinginkan, langkah selanjutnya mengklik *Create* untuk membuat permodelan pada pelatihan jaringan ini.

3.1.4. Parameter Jaringan

Dalam pelatihan ini digunakan parameter sebagai berikut, terdiri dari 6 neuron yang berbeda yaitu 6 neuron, 10 neuron, 12 neuron, 18 neuron, 24 neuron, dan 30 neuron. Epoch atau iterasi yang digunakan 10000, fungsi yang digunakan ada 3 yaitu TRAINGD, TRAINGDA, dan TRAINGD_X. Sedangkan *adaption learning function* yang digunakan yaitu LEARNGD, dan LEARNGDM.

1. TRAINGD

Bobot-bobot jaringan akan diperabiki sesuai dengan perubahan yang terjadi [8].

2. TRAINGDA

Laju pembelajaran merupakan suatu konstanta yang nilainya tidak berubah-ubah selama proses iterasi terjadi. Perubahan bobot dipengaruhi oleh besarnya laju pembelajaran [9].

3. TRAINGD_X

Mengkombinasikan pembelajaran adaptif learning rate dengan penambahan momentum [9].

Fungsi pembelajaran LEARNGD dapat dilihat pada Tabel 7 di bawah ini:

Tabel 7. MSE Fungsi Pembelajaran LEARNGD

No.	Jumlah Neuron	Fungsi Pembelajaran LEARNGD		
		TRAINGD	TRAINGDA	TRAINGD _X
1.	6	0,00039008	0,00033798	0,000647484
2.	10	0,00173768	0,00130196	0,000899508
3.	12	0,00028573	0,00007836	0,000284245
4.	18	0,00005484	0,00009450	0,000042019
5.	24	0,00670002	0,00170814	0,000128945
6.	30	0,00002215	0,00055494	0,000560964

Fungsi pembelajaran LEARNGDM dapat dilihat pada Tabel 8 di bawah ini:

Tabel 8. MSE Fungsi Pembelajaran LEARNGDM

No.	Jumlah Neuron	Fungsi Pembelajaran LEARNGDM		
		TRAINGD	TRAINGDA	TRAINGD _X
1.	6	0,00129011	0,00008765	0,000093271
2.	10	0,00308932	0,00233113	0,000053089
3.	12	0,00049207	0,00001559	0,001035568

4.	18	0,00001031	0,00043553	0,000027753
5.	24	0,00894017	0,00082981	0,000020081
6.	30	0,00053395	0,00014807	0,000008251

Pada Tabel 8 di atas, fungsi pembelajaran LEARNGD memiliki nilai MSE terkecil pada fungsi pelatihan TRAINGD dengan 30 neuron yaitu sebesar 0.00002215. Sedangkan pada fungsi pembelajaran LEARNGDM, MSE terkecil ditunjukkan pada fungsi pelatihan TRAINGDX dengan neuron 30 yaitu sebesar 0.000008251. Untuk itu prediksi kebutuhan listrik akan menggunakan arsitektur fungsi pembelajaran LEARNGDM, fungsi pelatihan TRAINGDX 3 neuron.

3.1.5. Tahap Prediksi

Prediksi atau prakiraan yang akan dilakukan yaitu untuk jangka 5 tahun kedepan, mulai dari tahun 2022-2027. Pada tahap ini, menggunakan menu *Simulate* pada Matlab seperti pada tahap pengujian. Dengan membuat arsitektur jaringan dan melakukan import data ke Matlab. Pada proses prediksi atau prakiraan, dibutuhkan data input. Data input tersebut akan dimasukkan ke dalam arsitektur jaringan yang telah dipilih untuk mendapatkan hasil prediksi konsumsi energi listrik. Sehingga dilakukan proyeksi data input yang sama dengan data pelatihan dan pengujian berupa jumlah penduduk, PDRB, data jumlah pelanggan pada sektor (rumah tangga, industri, bisnis, dan social/publik) menggunakan bantuan software MS.Excel dengan fungsi trendline metode linier. Data input tahun 2012-2021 digunakan sebagai sumber data proyeksi agar mendapatkan persamaan grafik untuk memproyeksi data tahun 2022-2027. Selain mengetahui grafik persamaan, fungsi trendline ini juga akan menampilkan nilai R^2 , atau tingkat keakurasian data sumber dengan data hasil proyeksi. Hasil proyeksi *trendline* dapat dilihat pada Tabel 9 di bawah ini:

Tabel 9. Data Input Hasil Trendline

Tahun	Pelanggan Rumah Tangga	Pelanggan Bisnis	Pelanggan Sosial	Pelanggan Industri	PDRB	Jumlah Penduduk
2022	12115950	613429	341751	15007.9	1100000000	33928650
2023	12627545	652755	356874	16036	1140000000	34321515
2024	13139140	692081	371997	17064.1	1180000000	34714380
2025	13650735	731407	387120	18092.2	1220000000	35107245
2026	14162330	770733	402243	19120.,3	1260000000	35500110
2027	14673925	810059	417366	20148.4	1300000000	35892975

Prediksi juga bisa dilakukan dengan mengetikkan perintah *sim* pada *command window* Matlab dengan format “prediksi = *sim*(arsitektur jaringan yang dipilih, data input yang akan dipakai dalam peramalan);”[8]. Setelah didapatkan hasil prediksi, hasil tersebut masih berupa data yang ternormalisasi untuk itu perlu dilakukan proses denormalisasi dengan persamaan di bawah ini:

$$x = \frac{(x')^{a+b}-0.1}{0.8+b} \quad (8)$$

Dimana:

X = data awal

X' = data yang telah dinormalisasi

a = nilai maksimal

b = nilai minimal

Data hasil perbandingan antara prediksi MATLAB dengan data aktual PLN dapat dilihat pada Tabel 10.

Tabel 10. Tabel Perbandingan Hasil Prediksi MATLAB dengan Data Aktual PLN

No.	Tahun	Data Aktual PLN	Fungsi Pembelajaran LEARNGDM, TRAINGDX, 30
1.	2022	29496	28339.14897
2.	2023	31474	30551.40957
3.	2024	33125	30838.67107

4.	2025	34690	33210.45956
5.	2026	36342	34227.46217
6.	2027	38069	34594.51004

Sedangkan nilai MAPE perbandingan antara Hasil prediksi MATLAB dengan data aktual PLN dapat dilihat pada Tabel 11.

Tabel 11. Nilai MAPE perbandingan antara Hasil Prediksi MATLAB dengan Data Aktual PLN

No.	Tahun	Fungsi Pembelajaran LEARNGDM, TRAINGDX, 30
1.	2022	3.9%
2.	2023	2.9%
3.	2024	6.9%
4.	2025	4.2%
5.	2026	5.8%
6.	2027	9.1%
Rata-rata error		5.4%

Berdasarkan tabel di atas, diketahui bahwa nilai rata-rata *error* antara data Aktual PLN dengan hasil prediksi menggunakan Matlab yaitu sebesar 5,4%. Dengan begitu arsitektur jaringan untuk prediksi berjalan dengan sangat baik, karena nilai MAPE kurang dari 10%.

3.2. Pengolahan Data Metode Ekstrapolasi Linier

Dalam metode ini, yang pertama dilakukan adalah mencari nilai Regresi (r) dengan menggunakan persamaan sebagai berikut:

$$r = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2} \sqrt{\sum(y-\bar{y})^2}} \quad (4)$$

Data konsumsi energi listrik dari tahun 2012-2021 yang digunakan sebagai data dalam ekstrapolasi linier dapat dilihat pada Tabel 12 di bawah ini:

Tabel 12. Konsumsi Energi Tahun 2012-2021

Tahun	Code (x)	Konsumsi Energi Listrik (y)
2012	0	16600.42
2013	1	18205.08
2014	2	19631.46
2015	3	20408.19
2016	4	21674.84
2017	5	21057.04
2018	6	23558.01
2019	7	24750.62
2020	8	25090.74
2021	9	26661.16

Nilai X dan Y yang digunakan dalam prediksi dengan metode ekstrapolasi linier dapat dilihat pada Tabel 13.

Tabel 13. Nilai X dan Y untuk Regresi

Code (x)	Konsumsi Energi Listrik (y)	$x - \bar{x}$	$x - \bar{x}^2$	$y - \bar{y}$	$y - \bar{y}^2$	$(x - \bar{x})(y - \bar{y})$
0	16600,42	-4,5	20,25	-5163,336	26660038,65	23235,012
1	18205,08	-3,5	12,25	-3558,676	12664174,87	12455,366
2	19631,46	-2,5	6,25	-2132,296	4546686,232	5330,74

3	20408,19	-1,5	2,25	-1355,566	1837559,18	2033,349
4	21674,84	-0,5	0,25	-88,916	7906,055056	44,458
5	21057,04	0,5	0,25	-706,716	499447,5047	-353,358
6	23558,01	1,5	2,25	1794,254	3219347,417	2691,381
7	24750,62	2,5	6,25	2986,864	8921356,554	7467,16
8	25090,74	3,5	12,25	3326,984	11068822,54	11644,444
9	26661,16	4,5	20,25	4897,404	23984565,94	22038,318
$\bar{x} = 4,5$	$\bar{y} = 21763,756$		8,25		9340990,494	8658,687

Setelah didapatkan nilai r , langkah selanjutnya mencari nilai a dan b , kemudian dimasukkan dalam persamaan dibawah ini:

$$y = a + bx \quad (5)$$

Hasil peramalan dengan metode ekstrapolasi linier ditunjukkan pada Tabel 14.

Tabel 14. Hasil Peramalan dengan Ekstrapolasi Linier

No.	Tahun	Code	Hasil Prakiraan
1.	2022	10	27536.21338
2.	2023	11	28585.7512
3.	2024	12	29635.28902
4.	2025	13	30684.82683
5.	2026	14	31734.36465
6.	2027	15	32783.90247

Perbandingan hasil prediksi ekstrapolasi linier dengan data aktual PLN dapat dilihat pada Tabel 15.

Tabel 15. Perbandingan Hasil Peramalan Ekstrapolasi Linier dengan Data Aktual PLN

No.	Tahun	Code	Data PLN	Aktual	Hasil Peramalan	Selisih dengan data Aktual	%MAPE
1.	2022	10	29496		27536.21338	1959.78662	6.6%
2.	2023	11	31474		28585.7512	2888.2488	9.2%
3.	2024	12	33125		29635.28902	3489.71098	10.5%
4.	2025	13	34690		30684.82683	4005.17317	11.5%
5.	2026	14	36342		31734.36465	4607.63535	12.6%
6.	2027	15	38069		32783.90247	5285.09753	13.8%
Rata-rata error							10.7%

Berdasarkan hasil prakiraan dengan metode ekstrapolasi linier didapatkan nilai rata-rata *error*nya sebesar 10.7%. Dengan begitu dapat dikatakan bahwa prakiraan dengan metode ekstrapolasi linier ini baik karena nilai *error* yang diperoleh antara rentang 10-20%.

3.3. Pembahasan

Hasil prediksi terbaik menggunakan *software* Matlab ditunjukkan pada fungsi pembelajaran LEARNGDM dengan model TRAINGDX 30 neuron. Hasil prediksi tersebut dapat dilihat pada tabel 4.20 yang menunjukkan perbandingan nilai *error* antara hasil prediksi dengan data aktual PT. PLN (Persero) Distribusi Jateng & DIY-Semarang, Jawa Tengah dengan persentase *error* sebesar 5.4%. Pada model TRAINGDX 30 ini mempunyai korelasi mendekati 1, yaitu sebesar 0.99386, sedangkan waktu yang dibutuhkan dalam pelatihan hanya 8 detik, dengan *epoch* yang dicapai 7.614 iterasi.

Sedangkan prakiraan dengan metode ekstrapolasi linier menunjukkan nilai rata-rata *error* sebesar 10.7% antara hasil prakiraan dengan data aktual PLN yang dapat dilihat pada tabel 4.24.

Nilai R dari metode ekstrapolasi yaitu 0.986344441, nilai tersebut menunjukkan hubungan yang kuat dan searah antara variabel x dan y karena mendekati dengan 1[9].

Berdasarkan kedua metode yang dipakai, prakiraan menggunakan software Matlab lebih baik dibandingkan dengan metode ekstrapolasi karena nilai rata-rata *error* yang dihasilkan lebih sedikit dan kurang dari 10%, yang berarti prakiraan tersebut dapat dikatakan sangat baik berdasarkan kriteria nilai MAPE oleh [10]. Sedangkan pada metode ekstrapolasi nilai rata-rata *error* yang didapatkan lebih dari 10% yaitu sebesar 10,7% yang berarti prakiraan dikatakan baik atas dasar kriteria persentase MAPE [10].

Neural networks (jaringan syaraf tiruan) melibatkan pengembangan struktur matematika (mirip dengan jaringan syaraf dalam otak manusia) yang memiliki kemampuan belajar dari data masa lalu yang disajikan dalam bentuk dataset yang terstruktur dengan baik. *Neural networks* akan lebih efektif apabila jumlah variabel yang terlibat banyak dan berhubungan dengan kompleks. *Neural networks* memiliki keunggulan dan kelemahan. Sedangkan metode ekstrapolasi linier menggunakan persamaan estimasi atau estimating equation dengan penggunaan rumus matematika antara variabel yang diketahui dengan variabel yang tidak diketahui. Analisis korelasi mengungkapkan seberapa benar persamaan estimasi sebenarnya antara variabel x dan y. Dengan begitu prakiraan menggunakan metode *Backpropagation Neural Network* lebih baik dibandingkan metode ekstrapolasi asalkan menggunakan parameter yang tepat.

Menurut PLN UID Jateng ada beberapa faktor yang mempengaruhi peningkatan kebutuhan energi listrik diantaranya yaitu:


1. Adanya peningkatan jumlah penduduk di Jawa Tengah
2. Adanya peningkatan pelanggan PLN, pada semua sektor
3. Adanya peningkatan PDRB (Produk Domestik Regional Bruto di Jawa Tengah, dll.

Di bawah ini adalah tabel perbandingan antara data aktual PLN, Prakiraan dengan MATLAB, dan Ekstrapolasi Linier

Hasil perbandingan ketiga prediksi dari data aktual PLN, prediksi MATLAB, dan prediksi ekstrapolasi linier ditunjukkan pada Tabel 16.

Tabel 16. Perbandingan Data Aktual PLN, Prediksi Matlab, dan Prediksi Ekstrapolasi Linier

No.	Tahun	Data Prediksi PLN	Prediksi Matlab	Prediksi Ekstrapolasi Linier
1.	2022	29496	28339.14897	27536.21338
2.	2023	31474	30551.40957	28585.7512
3.	2024	33125	30838.67107	29635.28902
4.	2025	34690	33210.45956	30684.82683
5.	2026	36342	34227.46217	31734.36465
6.	2027	38069	34594.51004	32783.90247
Rata-rata error			5.4%	10.7%



Gambar 3. Grafik Perbandingan Data Aktual PLN, Prediksi Matlab, Prediksi Ekstrapolasi Linier

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, ada beberapa hal yang dapat disimpulkan yaitu: Prakiraan kebutuhan energi listrik di wilayah Provinsi Jawa Tengah untuk tahun 2022-2027 menggunakan metode Backpropagation Neural Network mendapatkan hasil terbaik dengan arsitektur jaringan fungsi pembelajaran LEARNGDM, dengan model TRAINGDX 30 neuron. Nilai MAPE yang dihasilkan berdasarkan arsitektur jaringan tersebut sebesar 5.4%. Pada metode ekstrapolasi linier diperoleh nilai rata-rata error atau MAPE sebesar 10.7%. Berdasarkan kedua metode yang dipakai, metode Backpropagation Neural Network dapat menghasilkan prediksi yang lebih akurat dibandingkan prediksi menggunakan metode ekstrapolasi linier. Besarnya nilai kebutuhan energi listrik di PT. PLN (Persero) Distribusi Jateng & DIY-Semarang, Jawa setiap tahunnya mengalami peningkatan yang dipengaruhi oleh beberapa faktor diantaranya yaitu, kenaikan jumlah penduduk, PDRB, dan jumlah pelanggan PT. PLN (Persero) Distribusi Jateng & DIY-Semarang pada semua sektor.

DAFTAR PUSTAKA

- [1] P. Budrugaec, "Jurnal 2.Pdf," *Journal of thermal analysis*.
- [2] I. Nabillah and I. Ranggadara, "Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut," *JOINS (Journal Inf. Syst.*, vol. 5, no. 2, pp. 250–255, 2020, doi: 10.33633/joins.v5i2.3900.
- [3] R. Hedayani, R. S. Saputra, F. I. Permana, and G. N. Mahardhika, "Analisis Peramalan Kebutuhan Persediaan Untuk Keunggulan Bersaing Pada Perusahaan Orca," *J. Manaj.*, vol. 5, no. 2, pp. 93–104, 2016, doi: 10.26460/jm.v5i2.195.
- [4] T. T. Hanifa, S. Al-faraby, F. Informatika, and U. Telkom, "Analisis Churn Prediction pada Data Pelanggan PT. Telekomunikasi dengan Logistic Regression dan Underbagging," vol. 4, no. 2, pp. 3210–3225, 2017.
- [5] Siana Halim and Adrian Michael Wibisono, "Penerapan Jaringan Saraf Tiruan Untuk Peramalan," *J. Tek. Ind.*, vol. 2, no. 2, pp. 106–114, 2000, [Online]. Available: <http://puslit2.petra.ac.id/ejournal/index.php/ind/article/view/15993>
- [6] H. Mustafidah, D. K. Hakim, and S. Sugiyanto, "Tingkat Keoptimalan Algoritma Pelatihan Pada Jaringan Syaraf Tiruan (Studi Kasus Prediksi Prestasi Belajar Mahasiswa)," *Juita*, vol. II, no. 3, pp. 159–166, 2013.
- [7] G. T. P. Yoga, G. D. Arjana, and I. M. Mataram, "Perbandingan Kombinasi Fungsi Pelatihan Jaringan Saraf Tiruan Backpropagation Pada Peramalan Beban," *J. Spektrum*, vol. 7, no. 1, pp. 41–47, 2020.
- [8] D. H. Tanjung, "Jaringan Saraf Tiruan dengan Backpropagation untuk Memprediksi Penyakit Asma," *Creat. Inf. Technol. J.*, vol. 2, no. 1, p. 28, 2015, doi: 10.24076/citec.2014v2i1.35.
- [9] M. Yanto, E. P. W. Mandala, D. E. Putri, and Y. Yuhandri, "Peramalan Penjualan Pada Toko Retail Menggunakan Algoritma Backpropagation Neural Network," *J. Media Inform. Budidarma*, vol. 2, no. 3, pp. 110–117, 2018, doi: 10.30865/mib.v2i3.811.
- [10] P. Chang, Y. Wang, and C. Liu, "The development of a weighted evolving fuzzy neural network for PCB sales forecasting," vol. 32, pp. 86–96, 2007, doi:

10.1016/j.eswa.2005.11.021.

- [11] Ujianto, T., & Winardi, B. (2014). *2014-2018 Menggunakan Jaringan Saraf Tiruan Metode Backpropagation Dengan Software Matlab R2014a.*