

**PRAKIRAAN KEBUTUHAN ENERGI LISTRIK WILAYAH  
PROVINSI BANTEN TAHUN 2021-2030 MENGGUNAKAN  
METODE *BACKPROPAGATION NEURAL NETWORK***

**SKRIPSI**

Disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik (S.T)



**Disusun Oleh:  
Irvan Setiawan  
NPM.3332160057**

**JURUSAN TEKNIK ELEKTRO  
FAKULTAS TEKNIK  
UNIVERSITAS SULTAN AGENG TIRTAYASA  
2023**

## HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Dengan ini saya sebagai penulis skripsi berikut:

Judul : Prakiraan Kebutuhan Energi Listrik Wilayah Provinsi  
Banten Tahun 2021-2030 Menggunakan Metode  
*Backpropagation Neural Network*  
Nama Mahasiswa : Irvan Setiawan  
NPM : 3332160057  
Fakultas/Jurusan : Teknik/Teknik Elektro

Menyatakan dengan sesungguhnya bahwa Skripsi tersebut diatas adalah benar-benar hasil karya asli saya dan tidak memuat hasil karya orang lain, kecuali dinyatakan melalui rujukan yang benar dan dapat dipertanggungjawabkan. Apabila dikemudian hari ditemukan hal-hal yang menunjukkan bahwa sebagian atau seluruh karya ini bukan karya saya, maka saya bersedia dituntut melalui hukum yang berlaku. Saya juga bersedia menanggung segala akibat hukum yang timbul dari pernyataan yang secara sadar dan sengaja saya nyatakan melalui lembar ini.

Cilegon, 28 Maret 2022

  
NISTRAI  
WYV  
MARET 2022  
Irvan Setiawan  
NPM. 3332160057

## HALAMAN PENGESAHAN

Dengan ini ditetapkan bahwa skripsi berikut:

Judul : Prakiraan Kebutuhan Energi Listrik Wilayah Provinsi  
Banten Tahun 2021-2030 Menggunakan Metode  
*Backpropagation Neural Network*

Nama Mahasiswa : Irvan Setiawan

NPM : 3332160057

Fakultas/Jurusan : Teknik/Teknik Elektro

Telah diuji dan dipertahankan pada tanggal 9 Januari 2023 melalui Sidang Skripsi  
di Fakultas Teknik Universitas Sultan Ageng Tirtayasa Cilegon dan dinyatakan  
LULUS.

### Dewan Penguji

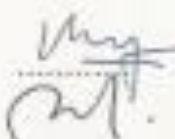
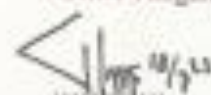
Pembimbing I : H.M. Hartono, S.T., M.T.

Pembimbing II : Ir. Lantip Pramono, M.Eng.

Penguji I : Dr. Romi Wiryadinata, ST., M.Eng.

Penguji II : Cakra Adipura W, S.T., M.T.

Tanda Tangan



Mengetahui,  
Kepala Jurusan



Dr. Romi Wiryadinata, S.T., M.Eng  
NIP.198307032009121006

## **PRAKATA**

Saya bersyukur kepada Tuhan Yang Maha Esa atas berkat dan rahmat-Nya, yang telah memungkinkan saya menyelesaikan skripsi ini. Penulisan skripsi ini merupakan salah satu persyaratan untuk mendapatkan gelar Sarjana Teknik dari Jurusan Teknik Elektro di Fakultas Teknik Universitas Sultan Ageng Tirtayasa. Saya menyadari bahwa tanpa bantuan dan bimbingan dari berbagai pihak selama masa perkuliahan hingga penyusunan skripsi ini, saya akan menghadapi banyak kesulitan. Oleh karena itu, saya ingin mengucapkan terima kasih kepada:

1. Kedua orang tua tercinta dan semua keluarga yang sudah memberikan nasehat, semangat, doa serta materi yg tidak terhingga nilainya.
2. Bapak Dr. Romi Wiryadinata, S.T., M.Eng selaku Ketua Jurusan Teknik Elektro dan dosen pembimbing akademik yang telah memberikan bimbingan kepada saya selama masa perkuliahan ini,
3. Bapak H.M Hartono, S.T., M.T. dan Bapak Ir. Lantip Pramono, M.Eng selaku dosen pembimbing skripsi yang telah menyediakan waktu, tenaga, dan pikiran untuk mengarahkan saya dalam penyusunan skripsi ini,
4. Ibu Ceri Ahendyarti, S.T., M.Eng. selaku koordinator skripsi yang telah membantu memberikan arahan untuk menyelesaikan tugas akhir ini.
5. Seluruh teman-teman jurusan teknik elektro 2016 dan seluruh teman-teman Bidikmisi untirta yang selalu ada untuk membantu saya dalam suka dan duka selama menjalani masa perkuliahan.

Terima kasih kepada semua pihak yang telah membantu. Semoga Tuhan Yang Maha Esa membalas segala kebaikan yang telah diberikan. Semoga skripsi ini dapat bermanfaat bagi pengembangan ilmu..

Cilegon, 28 Maret 2022

Penulis

## **ABSTRAK**

**Irvan Setiawan**

**Teknik Elektro**

Prakiraan Kebutuhan Energi Listrik Wilayah Provinsi Banten Tahun 2021-2030

Menggunakan Metode *Backpropagation Neural Network*

Permintaan kebutuhan energi listrik di masa depan memerlukan perencanaan dan peramalan yang baik. Oleh karena itu, diperlukan perencanaan yang sistematis berdasarkan data historis masa lalu. Penelitian ini menggunakan metode jaringan syaraf tiruan dengan algoritma propagasi balik untuk meramalkan kebutuhan energi listrik Provinsi Banten dimasa depan. Hasil pelatihan terbaik pada arsitektur jaringan menggunakan model pelatihan ke-3 dengan rata-rata tingkat kesalahan terkecil yaitu dengan 6 neuron pada lapisan masukan, 18 neuron pada lapisan tersembunyi dan 4 neuron pada lapisan keluaran. Hasil peramalan dengan metode JST *backpropagation* menunjukkan bahwa kebutuhan listrik Provinsi Banten akan meningkat sebesar 23.981,67 GWh pada tahun 2021 hingga mencapai 29.732,27 GWh pada tahun 2030. Ramalan JST *backpropagation* memiliki error sebesar 0,64% lebih rendah dibandingkan RUPTL PT PLN sebesar 3,72%.

Kata kunci: Prakiraan, JST *backpropagation*, RUPTL PT PLN

## ***ABSTRACT***

**Irvan Setiawan**

**Electrical Engineering**

Forecast of Electrical Energy Demand Province Banten Area in the Year 2021-  
2030 Using the Backpropagation Neural Network Method

The need for electrical energy in the future requires good planning and prediction, Therefore it is necessary to plan systematically based on past historical data. This research uses Artificial Neural Network with an algorithm backpropagation to predict the electricity demand of Banten Province in the future. From the results of the best network architecture training is to use the third training model which has an average percentage fault smallest is 6 neuron on input layer, 18 neuron on hidden layer and 4 neuron on output layer. Forecast results with the ANN method backpropagation the demand for electrical energy in Banten Province increases by 23,981.67 GWh in 2021 to 29,732.27 GWh in 2030. JST forecast backpropagation has a lower error value of 0,64% compared to PT PLN RUPTL of 3,72%.

Keywords: Forecast, ANN backpropagation, RUPTL PT PLN

## DAFTAR ISI

<b>HALAMAN PERNYATAAN KEASLIAN SKRIPSI.....</b>	<b>II</b>
<b>HALAMAN PENGESAHAN.....</b>	<b>III</b>
<b>PRAKATA .....</b>	<b>iv</b>
<b>ABSTRAK .....</b>	<b>v</b>
<b>ABSTRACT .....</b>	<b>vi</b>
<b>DAFTAR ISI.....</b>	<b>vii</b>
<b>DAFTAR GAMBAR.....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>x</b>
<b>BAB I.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	4
1.3 Tujuan Penelitian .....	4
1.4 Manfaat Penelitian .....	4
1.5 Batasan Masalah.....	5
1.6 Sistematika Penulisan .....	5
<b>BAB II .....</b>	<b>7</b>
2.1 Peramalan Beban Listrik .....	7
2.2 Jenis Beban Listrik.....	8
2.3 Metode Prakiraan Kebutuhan Energi Listrik .....	9
2.4 <i>Backpropagation Neural Network</i> .....	13
2.5 RUPTL PT PLN (Persero) Tahun 2021 s.d. 2030 .....	15
2.6 Analisis Hasil Prakiraan .....	16
2.7 Kajian Pustaka.....	17
<b>BAB III.....</b>	<b>21</b>

3.1	Alur Penelitian .....	21
3.2	Studi Literatur .....	30
3.3	Alat dan Bahan .....	30
3.4	Pengumpulan Data .....	30
<b>BAB IV .....</b>		<b>32</b>
4.1	Perbandingan Arsitektur Jaringan .....	32
4.2	Pelatihan Jaringan Menggunakan Satu <i>Hidden Layer</i> .....	34
4.2.1	Pelatihan Arsitektur Jaringan Model Ke-1 .....	34
4.2.2	Pelatihan Arsitektur Jaringan Model Ke-2 .....	37
4.2.3	Pelatihan Arsitektur Jaringan Model Ke-3 .....	39
4.2.4	Pelatihan Arsitektur Jaringan Model Ke-4 .....	42
4.2.5	Pelatihan Arsitektur Jaringan Model Ke-5 .....	45
4.3	Perbandingan <i>Error Output</i> Pelatihan Jaringan 1 <i>Hidden Layer</i> .....	47
4.4	Prakiraan Kebutuhan Listrik Sektoral .....	48
4.5	Prakiraan Kebutuhan Listrik Keseluruhan .....	49
4.6	Validasi Hasil Prakiraan dengan Nilai Aktual .....	50
<b>BAB V .....</b>		<b>53</b>
5.1	Kesimpulan .....	53
5.2	SARAN .....	53
<b>DAFTAR PUSTAKA .....</b>		<b>54</b>
<b>Lampiran A Data Awal Penelitian .....</b>		<b>58</b>
<b>Lampiran B Listing Code .....</b>		<b>59</b>



## DAFTAR GAMBAR

Gambar 2.1 Arsitektur <i>Backpropogation</i> .....	13
Gambar 2.2 Alur Kerja Jaringan Propagasi Balik.....	14
Gambar 2.3 Proses Penyusunan RUPTL .....	16
Gambar 3.1 Diagram Alir Penelitian .....	21
Gambar 3.2 Arsitektur Jaringan Syaraf Tiraun .....	24
Gambar 4.1 Pelatihan Jaringan Model ke-1 .....	35
Gambar 4.2 Grafik <i>Performance</i> Pelatihan Jaringan Model Ke-1.....	35
Gambar 4.3 <i>Plot Regression Output</i> Pelatihan Jaringan Model Ke-1 .....	36
Gambar 4.4 Pelatihan Jaringan Model Ke-2 .....	37
Gambar 4.5 Grafik <i>Performance</i> Pelatihan Jaringan Model Ke-2.....	38
Gambar 4.6 <i>Plot Regression Output</i> Pelatihan Jaringan Model Ke-2 .....	38
Gambar 4.7 Hasil Pelatihan Jaringan Model Ke-3.....	40
Gambar 4.8 Grafik <i>Performance</i> Hasil Pelatihan Jaringan Model Ke-3 .....	40
Gambar 4.9 <i>Plot Regression Output</i> Pelatihan Jaringan Model Ke-3 .....	41
Gambar 4.10 Hasil Pelatihan Jaringan Model Ke-4.....	42
Gambar 4.11 Grafik <i>Performance</i> Pelatihan Jaringan Model Ke-4.....	43
Gambar 4.12 <i>Plot Regression Output</i> Pelatihan Jaringan Model Ke-4 .....	43
Gambar 4.13 Pelatihan Jaringan Model Ke-5 .....	45
Gambar 4.14 Grafik <i>Performance</i> Pelatihan Jaringan Model Ke-5.....	45
Gambar 4.15 <i>Plot Regression Output</i> Pelatihan Jaringan Model Ke-5 .....	46
Gambar 4.16 Grafik Validasi Prakiraan Sektoral .....	51
Gambar 4.17 Grafik Validasi Prakiraan Keseluruhan.....	52

## DAFTAR TABEL

Tabel 3.1 Data Masukan Pelatihan Jaringan Syaraf Tiruan.....	22
Tabel 3.2 Data Target Pelatihan Jaringan Syaraf Tiruan .....	22
Tabel 3.3 Data <i>Input</i> Sampel Prakiraan Sektoral .....	23
Tabel 3.4 Parameter Jaringan .....	27
Tabel 4.1 Arsitektur Jaringan Menggunakan Satu <i>Hidden Layer</i> .....	32
Tabel 4.2 Arsitektur Jaringan Menggunakan Dua <i>Hidden Layer</i> .....	33
Tabel 4.3 Arsitektur Jaringan Menggunakan Tiga <i>Hidden Layer</i> .....	33
Tabel 4.4 <i>Output</i> Pelatihan Jaringan Model Ke-1 Normalisasi .....	36
Tabel 4.5 <i>Output</i> Pelatihan Jaringan Model Ke-1 Denormalisasi (GWh) .....	37
Tabel 4.6 <i>Output</i> Pelatihan Jaringan Model Ke-2 Normalisasi .....	39
Tabel 4.7 <i>Output</i> Pelatihan Jaringan Model Ke-2 Denormalisasi (GWh) .....	39
Tabel 4.8 <i>Output</i> Pelatihan Jaringan Model Ke-3 Normalisasi .....	41
Tabel 4.9 <i>Output</i> Pelatihan Jaringan Model Ke-3 Denormalisasi (GWh) .....	42
Tabel 4.10 <i>Output</i> Pelatihan Jaringan Model Ke-4 Normalisasi .....	44
Tabel 4.11 <i>Output</i> Pelatihan Jaringan Model Ke-4 Denormalisasi (GWh) .....	44
Tabel 4.12 <i>Output</i> Pelatihan Jaringan Model Ke-5 Normalisasi .....	46
Tabel 4.13 <i>Output</i> Pelatihan Jaringan Model Ke-5 Denormalisasi (GWh) .....	47
Tabel 4.14 Perbandingan Nilai <i>Error Output</i> Pelatihan Jaringan .....	47
Tabel 4.15 Perbandingan Prakiraan Sektoral RUPTL dengan JST .....	48
Tabel 4.16 Perbandingan Prakiraan Keseluruhan RUPTL dengan JST.....	50
Tabel 4.17 Validasi Prakiraan Sektoral JST dan RUPTL.....	51
Tabel 4.18 Validasi Hasil Prakiraan Keseluruhan JST dan RUPTL.....	52

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Energi listrik memegang peran yang sangat penting dalam kehidupan masyarakat modern saat ini. Sejalan dengan perkembangan teknologi, seringkali muncul tantangan dalam sektor ketenagalistrikan, di antaranya adalah meningkatnya kebutuhan akan tenaga listrik. Pertumbuhan kebutuhan energi listrik tidak hanya dipengaruhi oleh jumlah penduduk di suatu wilayah, tetapi juga oleh perkembangan aktivitas ekonomi masyarakat yang terus meningkat guna memenuhi kebutuhan sehari-hari mereka. Semakin tinggi tingkat aktivitas ekonomi, semakin besar pula permintaan akan energi listrik. Dalam konteks ini, dapat dinyatakan bahwa seiring dengan perkembangan masyarakat modern, kebutuhan akan energi listrik secara keseluruhan akan meningkat sejalan dengan pertumbuhan aktivitas ekonomi dan populasi di wilayah tersebut [1].

Kebutuhan energi listrik yang tersedia dimasa depan memerlukan perencanaan dan peramalan yang baik. Membuat prediksi tentang beban listrik di masa depan merupakan bagian penting dalam pengembangan model perencanaan sistem tenaga. Dengan melakukan peramalan kebutuhan beban listrik, hal ini dapat membantu dalam perencanaan pembangkitan dan pendistribusian tenaga listrik yang efisien, sehingga perlu adanya peramalan untuk mengetahui ketersediaan genset dan seluruh komponen peralatan pendukung lainnya dan menyeimbangkan ketersediaan dan permintaan. Sangat penting mencari keseimbangan antara *supply* dan *demand*, karena jika energi yang dihasilkan lebih banyak dari yang dikonsumsi maka akan terbuang percuma, dan jika energi yang dihasilkan lebih sedikit dari yang dikonsumsi maka listrik harus diputus. Listrik juga mempunyai ciri yang sampai saat ini sulit untuk disimpan dalam skala besar, sehingga besarnya energi yang dihasilkan itulah yang akan disalurkan kepada konsumen listrik. Oleh karena itu, peramalan beban listrik yang akurat penting dilakukan untuk menghindari kerugian dikemudian hari [2].

Ketersediaan energi listrik dimasa depan mempengaruhi pertumbuhan ekonomi dan kesejahteraan masyarakat dimasa depan. Oleh karena itu, perusahaan

penyedia energi listrik perlu melakukan peramalan konsumsi energi listrik dalam jangka waktu tertentu, sehingga perusahaan penyedia listrik dapat mengambil kebijakan yang lebih baik dimasa mendatang [3]. Konsumsi listrik di Indonesia khususnya di Provinsi Banten, salah satu Provinsi yang memiliki kawasan industri yang besar, tidak hanya konsumsi listrik disektor rumah tangga yang meningkat, namun industri dan sektor lainnya juga ikut tumbuh seiring dengan perkembangan perekonomian [4]. Tingkat konsumsi energi listrik juga dapat menjadi tolak ukur tingkat pendapatan dan kesejahteraan suatu negara atau daerah. Mengingat peranan ketenagalistrikan dalam perekonomian, maka industri ketenagalistrikan merupakan industri hulu, sehingga berkembangnya industri ketenagalistrikan dapat mendorong industri lain untuk menggunakan energi listrik sebagai inputnya [5]. Proses peramalan kebutuhan energi listrik harus mempertimbangkan faktor ekonomi sebagai salah satu parameternya. Oleh karena itu, perlu dilakukan perencanaan kebutuhan energi listrik dengan menggunakan parameter keekonomian [6].

Dalam industri tenaga listrik, peramalan sering kali berbentuk peramalan beban, termasuk peramalan beban puncak dan peramalan permintaan listrik. Prakiraan berdasarkan jangka waktu dapat diklasifikasikan menjadi tiga jenis, yaitu jangka pendek, jangka menengah, dan jangka panjang [7]. PT. PLN (Persero) untuk peramalan kebutuhan energi listrik jangka panjang selama ini menggunakan metode konvensional dengan regresi linier. Peramalan kebutuhan setiap provinsi dilakukan dengan menggunakan regresi ekonometrik dengan menggunakan aplikasi statistik Simple-E, dengan mempertimbangkan pertumbuhan ekonomi, jumlah penduduk, target laju elektrifikasi, harga listrik, potensi konsumsi yang besar, data kinerja penjualan tenaga listrik, jumlah pelanggan dan daya tersambung, kemudian dibentuk persamaan model regresi untuk memprediksi pertumbuhan dimasa depan [8].

Perencanaan kebutuhan listrik memiliki berbagai metode yang dapat digunakan. Salah satu metode yang dapat digunakan untuk memproyeksikan kebutuhan energi listrik melibatkan metode statistik konvensional, serta metode statistik modern yang memanfaatkan pendekatan kecerdasan buatan [4]. Metode peramalan yang sering digunakan dalam konteks kecerdasan buatan adalah

Jaringan Syaraf Tiruan (JST) dan logika Fuzzy, seperti yang banyak dibuktikan dalam penelitian sebelumnya yang menerapkan kedua metode tersebut. Beberapa studi telah menginvestigasi peramalan konsumsi listrik, termasuk penggunaan logika Fuzzy untuk meramalkan beban listrik dalam jangka pendek, dengan tingkat kesalahan berkisar antara 10,09% hingga 16,9% [9]. Menerapkan metode regresi linier untuk peramalan konsumsi listrik jangka panjang di Provinsi Lampung dengan perhitungan manual, menghasilkan rata-rata tingkat kesalahan sebesar 16,8%. Sementara itu, dalam peramalan beban listrik menggunakan metode propagasi balik, namun belum melibatkan normalisasi data sehingga nilai keluaran sebenarnya belum dihitung. Selain itu, perlu dicatat bahwa tingkat kesalahan saat ini masih cukup tinggi, yakni mencapai 17,09% [10]. Secara umum, perusahaan penyedia energi listrik biasanya akan mengakui adanya tingkat kesalahan sebesar 10% dalam peramalan jangka panjang [11]. Dalam salah satu studi peramalan kebutuhan listrik jangka pendek di wilayah Kota Serang yang menggunakan Jaringan Syaraf Tiruan (JST), ditemukan bahwa rata-rata kesalahan (*error*) sebesar 3,37% [12].

*Artificial Neural Network* (ANN) didasarkan pada konsep pemrosesan algoritmis yang telah dimodelkan untuk menyerupai struktur dan fungsi otak manusia dalam bentuk jaringan syaraf buatan yang saling berhubungan [13]. Syaraf-syaraf yang saling berhubungan ini mengolah informasi dengan merespons rangsangan eksternal dan mampu mempelajari pola dari respons tersebut. Oleh karena itu, *Artificial Neural Network* (ANN) juga dikenal sebagai alat pembelajaran mesin karena kemampuannya untuk belajar dari data yang telah terekam sebelumnya [14]. Salah satu jenis metode dalam Jaringan Syaraf Tiruan (JST) adalah metode propagasi balik (*backpropagation*). Metode ini sering digunakan karena ketika keluaran JST tidak sesuai dengan target yang diharapkan, maka keluaran tersebut akan dikembalikan melalui lapisan tersembunyi ke lapisan masukan, sehingga memberikan umpan balik yang memungkinkan jaringan untuk memperbaiki diri sendiri dan memvalidasi hasil yang dihasilkan oleh ANN. Ini memungkinkan jaringan untuk terus memperbaiki dirinya sendiri melalui iterasi dan pelatihan ulang. [15]. Dalam bidang *forecasting* metode *JST backpropagation* dapat diaplikasikan dengan baik [16].

Penelitian ini memanfaatkan metode Jaringan Syaraf Tiruan dengan teknik *backpropagation* untuk melakukan perkiraan konsumsi energi listrik. Ramalan tersebut digunakan untuk menghitung estimasi konsumsi energi listrik di Provinsi Banten dari tahun 2021 hingga tahun 2030. Data yang digunakan dalam penelitian ini berasal dari sumber data statistik dan Rencana Usaha Penyediaan Tenaga Listrik (RUPTL) yang diterbitkan oleh PT. PLN (persero).

## 1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana implementasi metode Jaringan Syaraf Tiruan *backpropagation* dalam memprakirakan kebutuhan listrik di Provinsi Banten dari tahun 2021 s.d. 2030 menggunakan perangkat lunak MATLAB?
2. Bagaimana hasil prakiraan kebutuhan energi listrik di Provinsi Banten tahun 2020 s.d. 2030 mendatang?
3. Bagaimana akurasi prakiraan kebutuhan energi listrik dengan menggunakan metode Jaringan Syaraf Tiruan *backpropagation*?

## 1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui model arsitektur terbaik metode Jaringan Syaraf Tiruan *backpropagation* untuk menganalisis perkiraan kebutuhan listrik Provinsi Banten tahun 2021 s.d. 2030.
2. Mengetahui prakiraan pertumbuhan konsumsi energi listrik Provinsi Banten pada tahun 2021 s.d. 2030.
3. Menganalisis tingkat akurasi metode Jaringan Syaraf Tiruan dalam proses prakiraan kebutuhan listrik.

## 1.4 Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah dapat memberikan gambaran mengenai kebutuhan energi listrik serta mempermudah perencanaan dan pengembangan bidang ketenagalistrikan di Provinsi Banten sampai tahun 2030, sehingga menjamin keseimbangan antara penyediaan dan permintaan energi

listrik. Penelitian ini juga diharapkan mampu menjadi metode alternatif dalam melakukan prakiraan kebutuhan energi listrik yang didasarkan pada perkembangan perekonomian, pertumbuhan penduduk dan jumlah pelanggan listrik.

### **1.5 Batasan Masalah**

Pembatasan masalah diperlukan agar ruang lingkup penelitian tidak menjauhi tujuan yang sudah ditentukan. Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Lokasi prakiraan kebutuhan listrik adalah wilayah Provinsi Banten.
2. Prakiraan kebutuhan listrik dilakukan dari tahun 2021 s.d. 2030 secara keseluruhan dan sektoral yang dijabarkan pertahun.
3. Data historis yang digunakan adalah data kelistrikan, kependudukan, dan perekonomian Provinsi Banten tahun 2011 s.d. 2020.
4. Validasi hasil pelatihan dilakukan terhadap data historis tahun 2011 s.d. 2020 dan hasil prakiraan terhadap data aktual tahun 2021 yang diambil dari Banten Dalam Angka 2022 yang diterbitkan oleh Badan Pusat Statistik (BPS) Provinsi Banten.
5. Analisis hasil prakiraan dilakukan terhadap Rencana Usaha Penyediaan Tenaga Listrik (RUPTL) Tahun 2021 s.d. 2030.
6. Perangkat lunak yang digunakan adalah MATLAB versi R2020a.

### **1.6 Sistematika Penulisan**

Penulisan skripsi ini mengikuti sistem penulisan sebagai berikut:

Bagian awal dari skripsi mencakup halaman judul, halaman persetujuan, kata pengantar, indeks isi, serta daftar gambar dan tabel. Skripsi ini disusun dalam lima bab dengan konten sebagai berikut:

1. Bab I: Pendahuluan
  - Bab pertama akan membahas latar belakang masalah.
  - Cara mengemukakan masalah akan dijelaskan.
  - Batasan masalah akan diuraikan.
  - Tujuan dari penelitian ini akan disampaikan.

- Manfaat dari penelitian ini akan dipaparkan.
  - Sistematika penelitian akan dijabarkan.
2. Bab II: Tinjauan Pustaka
- Bab ini akan memaparkan penelitian-penelitian sebelumnya yang relevan.
  - Landasan teori yang digunakan dalam penelitian ini akan diuraikan.
3. Bab III: Metodologi Penelitian
- Bab ini akan mencakup tahapan-tahapan penelitian yang dilakukan dalam penelitian ini.
4. Bab IV: Hasil dan Pembahasan
- Bab ini akan menjelaskan hasil perhitungan perkiraan yang diperoleh melalui analisis.
5. Bab V: Penutup
- Bab terakhir akan memuat kesimpulan dari seluruh yang telah dibahas dalam bab-bab sebelumnya.
  - Saran-saran untuk pengembangan penelitian selanjutnya akan disampaikan.



## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Peramalan Beban Listrik**

Energi listrik yang dihasilkan tidak dapat disimpan dan harus langsung digunakan oleh konsumen. Produksi energi harus selalu seimbang dengan konsumsi energi konsumen. Ketika produksi listrik tidak mencukupi permintaan konsumen, frekuensi dalam sistem akan turun. Sebaliknya, jika produksi melebihi permintaan, frekuensi sistem akan naik. Penyedia listrik seperti PLN harus menjaga frekuensi energi listrik tetap konstan, yaitu pada 50 Hz atau 60 Hz, dengan batas deviasi yang diperbolehkan.

Permintaan energi listrik konsumen selalu berubah, dan untuk menjaga frekuensi tetap pada 50 Hz atau 60 Hz, daya yang dihasilkan di pusat jaringan akan bervariasi seiring waktu untuk menyesuaikan dengan kondisi frekuensi. Oleh karena itu, diperlukan perencanaan operasi produksi yang kompleks dan efisien yang juga mempertimbangkan biaya bahan bakar yang rendah. Peramalan beban atau peramalan kebutuhan listrik konsumen sangat penting sebagai dasar perencanaan operasional.

Peramalan beban listrik sangat berperan dalam pengendalian beban, terutama dalam situasi real-time dalam pengoperasian jaringan listrik. Ini memainkan peran kunci dalam menjaga keseimbangan antara produksi dan konsumsi energi. Peramalan beban listrik, sebagai bagian dari perencanaan dan pengoperasian jaringan listrik, memiliki peran penting yang diatur oleh peraturan pemerintah terkait produk listrik dan jaringan sistem tenaga listrik.

Tujuan dari peramalan beban listrik meliputi berbagai aspek yang mencakup pengendalian dan pengelolaan sistem tenaga listrik yang efisien. Hal ini dilakukan sesuai dengan peraturan yang berlaku, seperti Peraturan Menteri ESDM Nomor 03 Tahun 2007 tentang Produk Listrik Jawa-Madura-Bali, serta peraturan lainnya yang berkaitan dengan perencanaan dan operasi sistem tenaga listrik sebagai berikut [17]:

1. Peramalan kebutuhan listrik jangka panjang melibatkan analisis dalam periode waktu yang melampaui satu tahun. Faktor-faktor makroekonomi,

yang terletak di luar kendali penyedia listrik, memiliki pengaruh utama dalam menentukan arah peramalan kebutuhan listrik ini. Informasi ini sangat penting dalam perencanaan energi untuk masa depan..

2. Peramalan beban jangka menengah melibatkan periode satu bulan sampai satu tahun. Manajemen perusahaan merupakan penentu utama dalam perkiraan biaya jangka menengah.
3. Peramalan kebutuhan listrik jangka pendek berfokus pada jangka waktu yang lebih singkat, biasanya dari beberapa jam hingga satu minggu. Perkiraan per jam dari konsumsi energi ditentukan dengan mempertimbangkan pola historis dari penggunaan energi, dengan memperhitungkan berbagai faktor yang dapat memengaruhi tingkat konsumsi sistem. Peramalan kebutuhan listrik jangka pendek ini sering digunakan untuk mengoptimalkan penggunaan energi dan meningkatkan efisiensi dalam pengoperasian sistem listrik..

## **2.2 Jenis Beban Listrik**

Energi listrik yang disalurkan ke pelanggan digunakan untuk kebutuhan penerangan malam hari dan untuk menyalakan alat-alat elektronik seperti AC, televisi, lemari es, dan lain-lain, kegiatan ini biasa dilakukan oleh pelanggan perumahan. Sumber listrik untuk pelanggan industri Selain sistem kelistrikan dan penerangan perkantoran, sumber listrik juga sering digunakan untuk mengoperasikan mesin-mesin pabrik dengan kemampuan penyerapan energi yang tinggi. Semakin besar kebutuhan listrik maka semakin tinggi pula harga listrik yang harus dibayar oleh penyedia energi listrik. Pelanggan listrik berdasarkan harga listrik dapat dibedakan menjadi empat kelompok, yaitu [18]:

1. Rumah tangga, khususnya beban listrik, meliputi peralatan rumah tangga seperti lampu, kipas angin, televisi, lemari es, AC, dan lain-lain..
2. Komersial atau bisnis, khususnya beban listrik termasuk bangunan komersial seperti pertokoan, pusat perbelanjaan dan gedung perkantoran.
3. Industri khususnya beban listrik meliputi industri kecil dan industri besar.

4. Umum, khususnya beban listrik yang meliputi area atau bangunan pelayanan masyarakat seperti rumah sakit daerah, gedung pemerintah, dan sistem penerangan jalan.

### 2.3 Metode Prakiraan Kebutuhan Energi Listrik

Perkiraan permintaan energi listrik terbatas pada model pendekatan statistik, Seiring berkembangnya teknologi, metode peramalan permintaan energi listrik pun ikut berkembang. Model peramalan energi listrik berbasis kecerdasan buatan saat ini banyak digunakan. Beberapa model peramalan kebutuhan listrik berbasis kecerdasan buatan yang saat ini digunakan adalah sebagai berikut [3]:

1. Jaringan Syaraf Tiruan (JST)

Jaringan syaraf tiruan menyediakan mekanisme alternatif untuk peramalan berbasis deret waktu. ANN merupakan sistem pengolah informasi yang fungsinya mirip dengan sistem syaraf biologis. Sederhananya, ANN mengenali pola dari data masukan dan kemudian menghasilkan keluaran umum berdasarkan pola data masukan tersebut.

2. *Support Vector Machine* (SVM)

SVM merupakan salah satu metode kecerdasan buatan yang dapat digunakan untuk melakukan regresi dan klasifikasi data linier dan *non* linier. Prinsip pengoperasian SVM adalah memperoleh model generalisasi terbaik dari data pelatihan, dimana kumpulan data tertentu yang melatih model tersebut sering disebut vektor pendukung. Kelemahan SVM adalah komputasinya intensif, memerlukan waktu dan perangkat keras yang sesuai.

3. Logika Fuzzy

Logika Fuzzy merupakan pengembangan logika Boolean menjadi suatu himpunan dengan nilai anggota dan menunjukkan sifat ambiguitas antara 0 dan 1 yang dikaitkan dengan rentang kualitatif tertentu. Logika Fuzzy disebut juga dengan logika samar-samar dan cocok untuk membuat prediksi terhadap suatu sistem yang mempunyai ambiguitas atau ketidakpastian..

4. Algoritma genetika

Algoritma genetika adalah algoritma optimasi yang digunakan untuk menemukan solusi terbaik terhadap suatu permasalahan komputasi. Metode ini dapat digunakan untuk menyelesaikan permasalahan *non* linier.

5. Sistem pakar

Sistem pakar adalah program komputer yang mempunyai kemampuan untuk menafsirkan, memahami, dan memperluas informasi yang diketahuinya atau basis pengetahuan hingga menjadi informasi baru. Sistem pakar menggabungkan aturan dan prosedur yang digunakan manusia untuk memecahkan masalah.

Metode di atas merupakan metode berbasis kecerdasan buatan untuk meramalkan kebutuhan energi listrik. Selain metode-metode tersebut, terdapat juga metode peramalan konvensional yang proses perhitungannya didasarkan pada hubungan antar variabel sehingga membentuk persamaan matematis. Metode konvensional ini dapat digunakan sebagai proyeksi prakiraan pertama yang berbasis kecerdasan buatan, khususnya pada prakiraan menggunakan logika fuzzy dan ANN. Ada beberapa metode peramalan tradisional, yaitu [18]:

1. Metode analitis

Metode ini dibuat dengan menggunakan data pengguna akhir dari setiap wilayah pelanggan listrik. Secara umum, data yang digunakan dalam metode ini memberikan gambaran tentang kegunaan spesifik peralatan listrik di masyarakat.

2. Metode ekonometri

Metode ini merupakan metode yang didasarkan pada indikator ekonomi. Metode ini mengasumsikan bahwa permintaan energi listrik berjalan seiring dengan peningkatan pendapatan masyarakat, harga dan daya beli.

3. Metode *time series*

Cara ini mengandalkan *trend* yang terjadi di masa lalu tanpa memperhatikan penyebab yang mempengaruhinya seperti perubahan iklim, perubahan besar teknologi, dan pandemi global. Cara ini terbagi menjadi beberapa jenis yaitu [19]:

a. *Trend* setengah rata-rata

*Trend* ini juga dikenal sebagai metode *trend* linier. Data tersebut dibagi menjadi dua bagian, yaitu bagian 1 ( $K_1$ ) dan bagian 2 ( $K_2$ ). Setiap bagian mempunyai tahun dasar ( $D_1$  dan  $D_2$ ) yang terletak di tengah-tengah setiap bagian. *Tren* ini dibentuk oleh persamaan (2.1), persamaan (2.2) dan persamaan (2.3) [19].

$$Y' = a + bx \quad (2.1)$$

$Y'$  pada Persamaan (2.1) merupakan nilai prakiraan *trend* setengah rata-rata pada periode ke- $x$  yang didapat dengan menjumlahkan  $a$  yaitu nilai rata-rata dari data historis bagian 1 atau bagian 2 yang dijumlahkan dengan  $b$  yaitu nilai perubahan.

$$a = \frac{\Sigma Y}{n} \quad (2.2)$$

Nilai  $a$  didapat dengan menggunakan Persamaan (2.2) dimana  $\Sigma Y$  yaitu jumlah data dibagi dengan  $n$  yaitu banyaknya data.

$$b = \frac{K_1 - K_2}{D_1 - D_2} \quad (2.3)$$

Nilai  $b$  didapat dengan menggunakan Persamaan (2.3) dimana hasil pengurangan  $K_1$  yaitu data bagian pertama dan  $K_2$  yaitu data bagian kedua dibagi dengan pengurangan  $D_1$  yaitu tahun dasar data bagian pertama dengan  $D_2$  yaitu tahun dasar data bagian kedua.

b. *Trend* kuadrat terkecil

*Trend* ini diperoleh dengan menentukan jumlah kuadrat terkecil dari kuadrat selisih antara data asli dan data *trend*. *Trend* kuadrat terkecil dibangun menurut persamaan (2.4), persamaan (2.5) dan persamaan (2.6) [19].

$$Y' = a + bx \quad (2.4)$$

$Y'$  pada Persamaan (2.4) merupakan nilai prakiraan *trend* kuadrat terkecil pada periode ke- $x$  yang didapat dengan menjumlahkan  $a$  yaitu nilai rata-rata dari data historis yang dijumlahkan dengan  $b$  yaitu nilai perubahan.

$$a = \frac{\Sigma Y}{n} \quad (2.5)$$

Nilai  $a$  didapat dengan menggunakan Persamaan (2.5) dimana  $\Sigma Y$  yaitu jumlah data dibagi dengan  $n$  yaitu banyaknya data.

$$b = \frac{\Sigma XY}{\Sigma X^2} \quad (2.6)$$

Nilai  $b$  yaitu perubahan data didapat dengan menggunakan Persamaan (2.6) dimana  $\Sigma XY$  yaitu jumlah hasil kali data historis dengan periodenya dibagi dengan  $\Sigma X^2$  yaitu jumlah kuadrat periode.

c. *Trend* eksponensial

*Trend* ini dirumuskan dengan Persamaan (2.7) [19].

$$Y' = a(1 - b)^x \quad (2.7)$$

$Y'$  pada Persamaan (2.7) merupakan nilai prakiraan *trend* eksponensial pada periode ke- $x$ . Nilai  $a$  merupakan nilai  $Y$  pada periode ke-1, nilai  $b$  merupakan nilai perubahan dan nilai  $x$  merupakan periode.

d. *Trend* kuadratis

Metode ini tidak linier karena trendnya bisa naik atau turun secara konstan. *Trend* ini dibentuk oleh persamaan (2.8), persamaan (2.9), persamaan (2.10) dan persamaan (2.11) [19].

$$Y' = a + bx + cx^2 \quad (2.8)$$

$Y'$  pada Persamaan (2.8) merupakan nilai prakiraan *trend* kuadratis pada periode ke- $x$ . nilai  $x$  melambangkan periode dan  $Y$  merupakan data historis.

$$a = \frac{\Sigma Y(\Sigma X^4) - (\Sigma X^2 Y)(\Sigma X^2)}{n(\Sigma X^4) - (\Sigma X^2)^2} \quad (2.9)$$

Nilai  $a$  merupakan konstanta yang diperoleh dengan menggunakan Persamaan (2.9).

$$b = \frac{\Sigma XY}{\Sigma X^2} \quad (2.10)$$

Nilai  $b$  merupakan koefisien 1 yang diperoleh dengan menggunakan Persamaan (2.10).

$$c = \frac{n(\Sigma X^2 Y) - (\Sigma X^2)(\Sigma Y)}{n(\Sigma X^4) - (\Sigma X^2)^2} \quad (2.11)$$

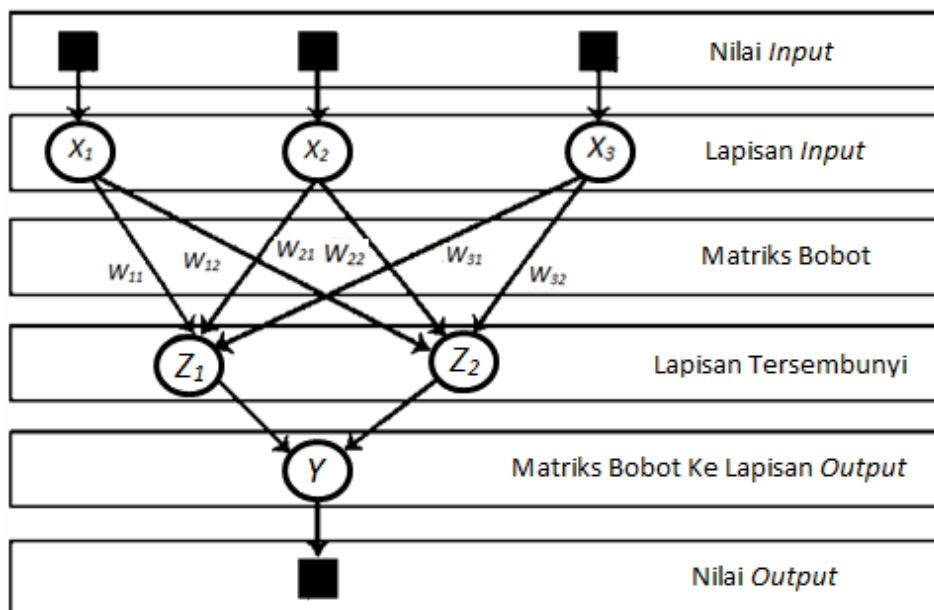
Nilai  $c$  merupakan koefisien 2 yang diperoleh dengan menggunakan Persamaan (2.11).

#### 4. Metode gabungan

Metode ini merupakan gabungan dari metode analitik, ekonometrika, dan *trend*. Metode ini memanfaatkan seluruh kelebihan dari ketiga metode sebelumnya antara lain indikator ekonomi, pola penggunaan peralatan listrik, dan kemajuan teknologi.

#### 2.4 *Backpropagation Neural Network*

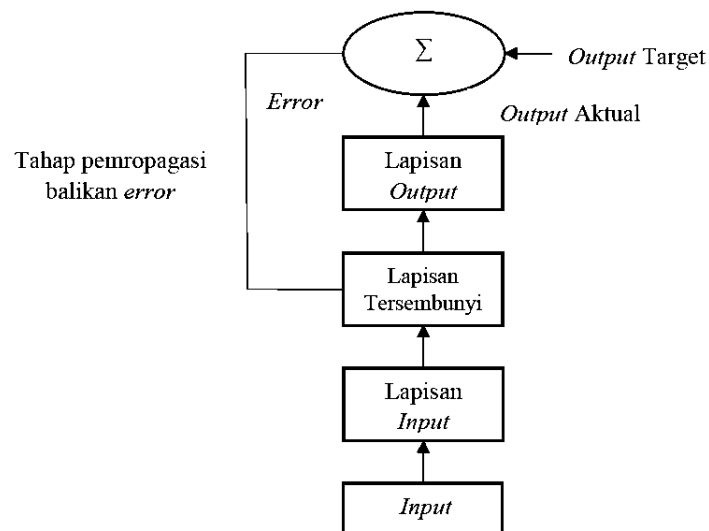
*Backpropagation* adalah metode yang sangat efektif dalam jaringan syaraf tiruan untuk menangani masalah pengenalan pola yang kompleks. Nama *backpropagation* berasal dari karakteristik kunci metode ini, yaitu perhitungan koreksi kesalahan dari unit tersembunyi yang dihasilkan melalui penyebaran kembali kesalahan yang terkait dengan unit keluaran. Penting untuk dicatat bahwa nilai target untuk unit tersembunyi tidak ditentukan secara eksplisit dalam metode ini. Gambaran arsitektur ANN propagasi balik dapat dilihat pada Gambar 2.1.



Gambar 2.1 Arsitektur *Backpropagation*

Dalam Gambar 2.1 dapat dilihat bagaimana arsitektur ANN *backpropagation* beroperasi.  $W_{jt}$  mengacu pada bobot awal yang diinisialisasi dalam jaringan antara layer input ( $X_i$ ) dan layer tersembunyi ( $Z_j$ ), sedangkan bobot  $W_j$  mengacu pada bobot awal yang diinisialisasi antara layer tersembunyi ( $Z_j$ ) dan layer keluaran ( $Y$ ).

Untuk membuat ANN menggunakan metode *backpropagation*, langkah pertama adalah memberikannya pelatihan dengan memasukkan sekumpulan contoh pelatihan yang dikenal sebagai *set* pelatihan. Proses pelatihan ini digambarkan dengan vektor masukan yang dikaitkan dengan keluaran yang menjadi target dalam proses pelatihan. Tujuannya adalah untuk membuat ANN beradaptasi dengan karakteristik dari sampel dalam set pelatihan ini dengan memodifikasi bobot-bobot dalam jaringan. Ini adalah proses *backpropagation* dalam ANN, yang digambarkan dalam Gambar 2.2.



Gambar 2.2 Alur Kerja Jaringan Propagasi Balik

Gambar 2.2 mengilustrasikan cara kerja *backpropagation* dalam jaringan syaraf tiruan (ANN) sebagai berikut:

1. Inisialisasi Bobot: Jaringan awalnya diinisialisasi dengan bobot-bobot menggunakan angka acak.
2. Pelatihan dengan Sampel: Sampel pelatihan dimasukkan ke dalam jaringan. Sampel pelatihan terdiri dari pasangan vektor masukan dan vektor keluaran target yang diinginkan.
3. Perbandingan dengan Target: Keluaran jaringan dibandingkan dengan vektor keluaran target untuk menentukan apakah hasil aktual cocok dengan yang diharapkan, yaitu apakah hasil aktual sama dengan hasil yang diinginkan.

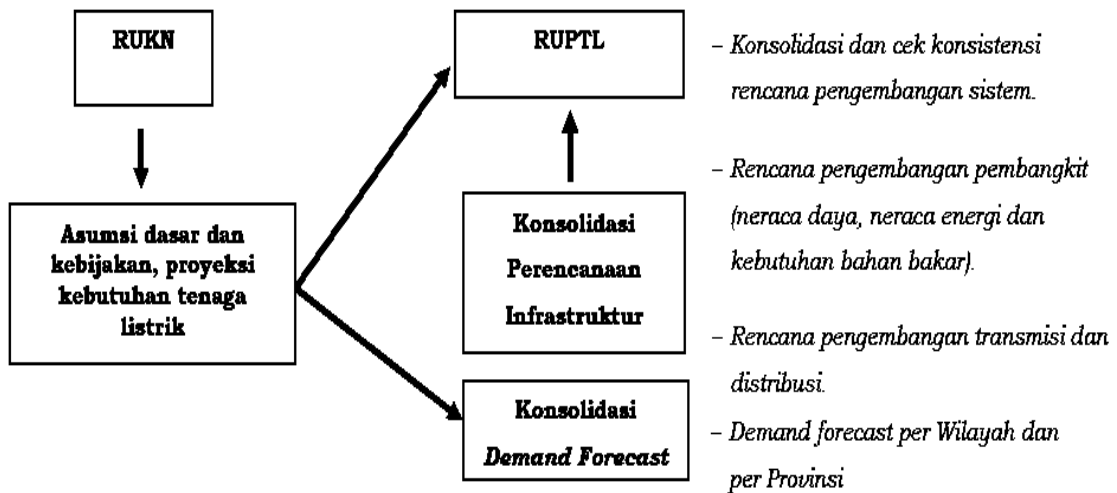


4. Perhitungan Kesalahan: Kesalahan yang disebabkan oleh perbedaan antara hasil aktual dan target dihitung. Kesalahan ini digunakan untuk memperbarui bobot-bobot terkait dalam jaringan.
5. Perubahan Bobot: Perubahan bobot yang dihasilkan bertujuan untuk mengurangi kesalahan. Setiap kali siklus pelatihan seperti ini dijalankan pada semua sampel pelatihan, bobot-bobot diperbarui.
6. Iterasi Pelatihan: Proses ini berulang hingga kinerja jaringan mencapai tingkat yang diinginkan atau hingga kondisi penghentian tertentu terpenuhi. Kondisi penghentian bisa berupa mencapai jumlah epoch tertentu atau memenuhi ambang batas tertentu.
7. Pengujian Kinerja: Setelah proses pelatihan selesai, jaringan diuji untuk kinerjanya dengan memasukkan tes suite sebagai masukan. Set pengujian ini hanya digunakan sebagai input tanpa keluaran target yang diinginkan.

Hasil respons jaringan selama pengujian dinilai berdasarkan kemampuannya untuk mengingat dan menggeneralisasi dari apa yang telah dipelajarinya selama pelatihan. Dengan kata lain, seberapa baik jaringan mampu memprediksi hasil berdasarkan pola yang telah dipelajarinya selama proses pelatihan. [20].

## **2.5 RUPTL PT PLN (Persero) Tahun 2021 s.d. 2030**

RUPTL ini menjelaskan proyek-proyek pengembangan ketenagalistrikan di seluruh wilayah kegiatan PT PLN (Persero). Penyusunan RUPTL dibagi ke beberapa wilayah operasional antara lain Sumatera, Jawa, Madura dan Bali, Kalimantan, Sulawesi, Maluku, Papua, dan Nusa Tenggara. Selain itu, RUPTL ini juga memaparkan rencana pengembangan sistem ketenagalistrikan masing-masing provinsi. Berikut gambar proses penyusunan RUPTL yang ditunjukkan pada gambar 2.3.



Gambar 2.3 Proses Penyusunan RUPTL

Berdasarkan Gambar 2.3 prakiraan permintaan tiap provinsi dilakukan dengan menggunakan regresi ekonometrik menggunakan aplikasi statistik Simple-E. Dengan mempertimbangkan pertumbuhan ekonomi, populasi, target tingkat elektrifikasi, harga listrik, potensi konsumen besar, data penjualan listrik aktual, jumlah pelanggan dan energi terkoneksi, maka persamaan model regresi kemudian dibentuk untuk memperkirakan pertumbuhan di masa depan [21].

## 2.6 Analisis Hasil Perkiraan

*Mean absolute percentage error* (MAPE) merupakan penghitungan kesalahan yang menggunakan nilai kesalahan absolut setiap periode waktu dan membaginya dengan nilai awal periode waktu tersebut, kemudian dirata-ratakan kesalahannya menjadi nilai persentase absolut. MAPE akan lebih akurat dibandingkan MSE. Untuk menghitung MAPE dari proses peramalan dapat dilakukan dengan menggunakan persamaan (2.12) berikut [22].

$$\text{MAPE} = \frac{\sum_{t=1}^n \frac{|x_t - f_t|}{x_t}}{n} \times 100\% \quad (2.12)$$

Persamaan (2.12) digunakan untuk menghitung nilai MAPE (Mean Absolute Percentage Error). Dalam interpretasi rentang nilai MAPE yang dihasilkan, berikut adalah maknanya:

1. MAPE < 10% = Peramalan sangat akurat, yang berarti bahwa peramalan sangat mendekati nilai aktual.

2.  $10\% \leq \text{MAPE} < 20\%$  = Peramalan akurat, yang menunjukkan bahwa peramalan memiliki tingkat akurasi yang baik.
3.  $20\% \leq \text{MAPE} < 50\%$  = Peramalan masih dalam kewajaran, yang berarti peramalan memiliki tingkat akurasi yang dapat diterima, meskipun ada sedikit penyimpangan.
4.  $\text{MAPE} \geq 50\%$  = Peramalan tidak akurat, yang menunjukkan bahwa peramalan memiliki tingkat ketidakakuratan yang signifikan dan tidak dapat diandalkan.

Dengan demikian, MAPE digunakan untuk mengevaluasi seberapa akurat peramalan dibandingkan dengan nilai aktual, dan interpretasinya bergantung pada nilai persentase kesalahan relatif terhadap nilai aktual.

## 2.7 Kajian Pustaka

Penelitian pertama ini fokus pada peramalan kebutuhan energi listrik PT PLN (Persero) UP3 Semarang dari tahun 2020 hingga 2025 menggunakan model Jaringan Syaraf Tiruan (JST) yang dikembangkan dengan metode propagasi balik menggunakan perangkat lunak MATLAB. Arsitektur pelatihan ANN melibatkan tiga lapisan, yaitu lapisan masukan, lapisan tersembunyi, dan lapisan keluaran, dengan setiap lapisan memiliki jumlah neuronnya sendiri. Penelitian ini menggunakan enam variabel masukan dan satu variabel keluaran. Antara lapisan masukan dan lapisan keluaran, terdapat 1 hingga 5 lapisan tersembunyi, dan setiap lapisan tersembunyi memiliki jumlah neuron yang bervariasi, yaitu 6, 12, 18, 24, dan 30. Selama proses pelatihan dan pengujian, digunakan parameter pencarian seperti fungsi pelatihan, termasuk *traingd*, *traingdm*, *traingda*, dan *traingdx*. Hasil perhitungan menunjukkan bahwa model dengan 24 *neuron* dan menggunakan *traigdx* dengan fungsi pembelajaran *learngd* memiliki rata-rata kesalahan sebesar 0,7%. Model dengan 24 *neuron* menggunakan *traigdx* dan fungsi pembelajaran *learngdm* juga memiliki rata-rata kesalahan sebesar 0,7%. Sementara itu, model dengan 30 *neuron* menggunakan *traigdx* dan fungsi pembelajaran *learngdm* memiliki rata-rata kesalahan sebesar 1,3%. Model terbaik adalah model dengan 24 *neuron* menggunakan *traigdx* dan fungsi pembelajaran *learngdm*, dengan selisih kesalahan sebesar 0,4%. Hasil prediksi dari model ini menunjukkan peningkatan

rata-rata sebesar 2,7% per tahun, sedangkan data sebenarnya dari PT PLN (Persero) UP3 Semarang menunjukkan peningkatan rata-rata sebesar 3,2%. Penilaian ini didasarkan pada perbedaan antara tahun ke-n dengan tahun sebelumnya, yang kemudian diubah menjadi persentase [23].

Penelitian kedua ini berfokus pada prediksi kebutuhan energi listrik dalam jangka pendek menggunakan metode jaringan syaraf tiruan propagasi balik dengan bantuan perangkat lunak MATLAB R2015B. Data yang digunakan dalam penelitian ini melibatkan historis penggunaan energi yang terjual (kWh) selama 10 tahun terakhir, dengan berbagai variabel termasuk rumah tangga, dunia usaha, pelanggan sosial, industri, pertumbuhan penduduk, dan produk domestik bruto regional (PDB). Hasil penelitian ini memberikan perkiraan kebutuhan energi listrik untuk periode 3 tahun ke depan, mulai dari tahun 2022 hingga tahun 2024. Model terbaik yang dihasilkan dalam penelitian ini memiliki arsitektur dengan 6 lapisan masukan, 6 lapisan tersembunyi, dan 1 lapisan keluaran dengan nilai positif palsu dan kuadrat rata-rata terkecil sebesar 0,003312731. Model ini juga memiliki rata-rata Nilai Persentase Kesalahan Absolut sebesar 6%. Penelitian ini memiliki dampak yang signifikan bagi pemangku kepentingan dalam pengambilan keputusan terkait penyediaan energi listrik. Dengan model ini, mereka dapat membuat tindakan yang lebih terinformasi dan efisien dalam memenuhi kebutuhan energi masyarakat [24].

Penelitian ketiga ini dilakukan untuk melakukan prediksi dan mengevaluasi tingkat akurasi menggunakan jaringan saraf tiruan dengan metode backpropagation. Data yang digunakan dalam penelitian ini adalah besarnya beban listrik yang dihasilkan di Kota Banjarbaru selama 9 tahun dengan 12 unit input.

Hasil dari penelitian ini menunjukkan bahwa dalam tahap pelatihan jaringan syaraf tiruan dengan simulasi 4 lapisan tersembunyi, telah diperoleh arsitektur jaringan yang cukup baik. Arsitektur ini terdiri dari 12 lapisan masukan, 12 lapisan tersembunyi, dan 1 lapisan keluaran, dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 6,597% dan *Root Mean Square Error* (RMSE) sebesar 0,032222. Ini menunjukkan tingkat akurasi yang baik dalam memprediksi

beban listrik. Namun, pada tahap pengujian, ditemukan bahwa nilai MAPE sebesar 7,918 dan RMSE sebesar 0,070479. Meskipun hasilnya masih cukup baik, ada sedikit peningkatan kesalahan dalam prediksi beban listrik dibandingkan dengan tahap pelatihan. Pada tahap peramalan, terdapat peningkatan yang signifikan dalam kesalahan prediksi, dengan nilai MAPE sebesar 12,366% dan RMSE sebesar 0,113272. Hal ini menunjukkan bahwa hasil peramalan kurang baik, kemungkinan disebabkan oleh fluktuasi yang signifikan dalam jumlah listrik yang dihasilkan pada bulan Desember 2018 dan Januari 2019. Secara keseluruhan, penelitian ini memberikan wawasan tentang penggunaan jaringan saraf tiruan untuk prediksi beban listrik, meskipun tingkat akurasi dapat bervariasi tergantung pada tahap analisis (pelatihan, pengujian, atau peramalan) dan fluktuasi dalam data [25].

Penelitian keempat ini bertujuan untuk menggunakan jaringan syaraf tiruan dengan algoritma pembelajaran propagasi balik untuk memprediksi kebutuhan beban listrik. Hasil dari pemodelan ini menunjukkan bahwa prediksi kebutuhan beban listrik dengan metode propagasi balik memiliki tingkat akurasi yang cukup baik. Berdasarkan hasil simulasi, dalam tahap pelatihan untuk memprediksi kebutuhan beban listrik di Kota Pontianak, tingkat kesalahan diukur menggunakan *Mean Squared Error* (MSE) sebesar 4,2173 dan *Mean Absolute Percentage Error* (MAPE) sebesar 2,5760. Ini menunjukkan bahwa model ini memiliki tingkat akurasi yang baik dalam tahap pelatihan. Namun, dalam tahap peramalan, di mana model digunakan untuk memprediksi kebutuhan beban listrik di Kota Pontianak, tingkat kesalahan meningkat. MSE dalam tahap peramalan sebesar 2353,3 dan MAPE sebesar 217,2369. Tingkat kesalahan yang lebih tinggi ini mungkin disebabkan oleh faktor-faktor yang sulit diprediksi atau fluktuasi yang signifikan dalam data aktual selama periode peramalan. Secara keseluruhan, penelitian ini menunjukkan potensi penggunaan jaringan syaraf tiruan dengan algoritma propagasi balik dalam memprediksi kebutuhan beban listrik, meskipun tingkat akurasi dapat bervariasi tergantung pada tahap analisis dan kompleksitas data [26].

Kajian kelima Berdasarkan hasil pengolahan dan analisis data, disimpulkan bahwa jumlah kebutuhan energi listrik di Kota Subulussalam meningkat sangat

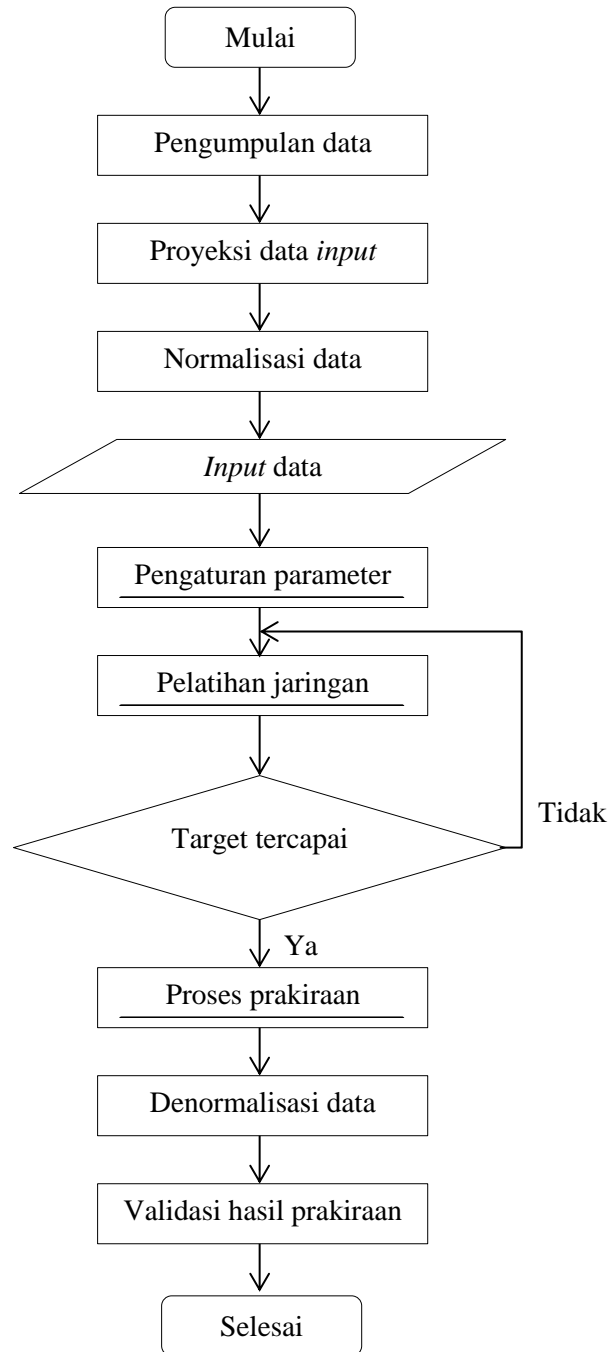
signifikan antara tahun 2016 hingga tahun 2020. Pada tahun 2016, jumlah kebutuhan energi listrik sebesar 2.644.468.563 kWh. Pada tahun 2020, jumlah listrik diperkirakan meningkat menjadi 3.470.887.446 kWh. Dari data tersebut terlihat bahwa laju pertumbuhan listrik mengalami peningkatan yang cukup signifikan [5].

## BAB III

### METODELOGI PENELITIAN

#### 3.1 Alur Penelitian

Diagram alir penelitian berguna dalam memberikan informasi dari awal hingga akhir penelitian. Langkah-langkah yang dilakukan dalam proses penelitian dijelaskan secara singkat pada gambar 3.1.



Gambar 3.1 Diagram Alir Penelitian

Berdasarkan diagram alir penelitian pada Gambar 3.1 langkah-langkah penelitian adalah sebagai berikut:

1. Penentuan data masukan dan data target

Data masukan penelitian berupa data masukan dan data target, data masukan dijadikan variabel pada lapisan masukan sedangkan data target dijadikan variabel pada lapisan keluaran. Ini adalah data masukan yang ditunjukkan pada tabel 3.1.

Tabel 3.1 Data Masukan Pelatihan Jaringan Syaraf Tiruan

Tahun	PDRB	Penduduk	Pelanggan Listrik (ribu)			
			RT	Bisnis	Publik	Industri
2011	290545838,9	11005518	1659	74	39	5.2
2012	310385592,4	11248947	1795	84	42	5.3
2013	331099105,5	11452491	1992	93	45	5.6
2014	349584667,8	11704877	2178	101	47	5.7
2015	369209288,1	11955243	2399	111	52	6
2016	389543932,3	12203148	2548	132	56	6.1
2017	412639618,3	12448160	2712	152	62	6.3
2018	436581428,1	12689736	2894	174	62	6.3
2019	459828497,4	12927316	3078	175	76	6.7
2020	445672956,7	11904562	3224	191	76	6.8

Berdasarkan Tabel 3.1 data masukan yang akan diolah pada sistem JST *backpropagation* memuat enam variabel yaitu data masukan pelatihan berupa demografi, Pendapatan Domestik Regional Bruto (PDRB), jumlah pengunjung barang pengguna listrik pada rumah tangga, bisnis, publik dan industri. Data target akan disajikan pada tabel 3.2.

Tabel 3.2 Data Target Pelatihan Jaringan Syaraf Tiruan

Tahun	Konsumsi listrik (GWh)			
	RT	Bisnis	Publik	Industri
2011	3681	1931	404,02	11471
2012	4050	1755	410,52	12353
2013	3640	2299	419,08	12920
2014	3892	2243	438,00	12569
2015	4370	2147	440,65	11645
2016	4543	2344	469,10	12811
2017	4599	2521	500,63	13623
2018	4825	2736	543,67	14803
2019	5231	2930	587,46	14601
2020	5794	2890	556,62	13027



Berdasarkan Tabel 3.2 pelatihan model JST *backpropagation* menggunakan empat variabel sebagai sasaran pelatihan berupa data aktual penjualan tenaga listrik pada sektor rumah tangga, bisnis, industri, dan umum. Data target diatas merupakan nilai output yang diinginkan dari proses pelatihan JST *backpropagation*. Nilai keluaran pelatihan dikatakan baik jika mendekati nilai target atau memiliki nilai *error* yang kecil dibandingkan nilai target.

## 2. Proyeksi data *input*

Data proyeksi masukan tersebut dijadikan sebagai contoh data yang akan digunakan dalam proses peramalan kebutuhan energi listrik. Contoh nilai *input* perkiraan sektoral ditunjukkan pada tabel 3.3.

Tabel 3.3 Data *Input* Sampel Prakiraan Sektoral

Tahun	PDRB	Penduduk	Pelanggan Listrik (ribu)			
			RT	Bisnis	Publik	Industri
2021	497393409,9	12951609,05	3631	231	84	7,1
2022	524011559,3	13144004,51	3930	262	92	7,3
2023	552129116,8	13339435,09	4257	298	100	7,6
2024	581834581,2	13537951,33	4614	341	110	7,9
2025	613221904,2	13739604,62	5005	390	120	8,1
2026	646390839,7	13944447,25	5434	448	132	8,4
2027	681447317,1	14152532,45	5904	517	145	8,8
2028	718503838,9	14363914,36	6420	598	159	9,1
2029	757679905,1	14578648,07	6987	694	176	9,4
2030	799102466	14796789,65	7609	808	194	9,8

Berdasarkan Tabel 3.3 sampel data masukan prakiraan industri diperoleh dari masukan data prakiraan menggunakan *trend* eksponensial dengan menggunakan persamaan (2.7). Hasil peramalan menggunakan *trend* eksponensial setiap variabel sebagai sampel nilai *input* untuk *input* data pada proses peramalan industri dari tahun 2021 hingga tahun 2030.

## 3. Normalisasi data


Normalisasi adalah teknik desain database logis yang mengelompokkan atribut hubungan untuk membentuk struktur hubungan yang baik tanpa redundansi yang dapat menghilangkan sebagian besar ambiguitas. Semua data *input*, target, dan sampel dikonversi ke rentang (-1,1). Normalisasi data dilakukan menggunakan Persamaan (3.1).

$$X_n = 2 * (X - X_{min}) / (X_{max} - X_{min}) - 1 \quad (3.1)$$

Nilai  $X_n$  merupakan nilai data normalisasi yang diperoleh menggunakan Persamaan (3.1). Nilai  $X$  merupakan nilai data *real*, nilai  $X_{min}$  merupakan nilai minimum data, nilai  $X_{max}$  merupakan nilai maksimum data.

#### 4. Perancangan arsitektur *backpropagation*

Arsitektur jaringan adalah representasi visual dari koneksi antara berbagai lapisan yang digunakan dalam proses pembelajaran. Di bawah ini adalah desain dari arsitektur model yang telah dikembangkan dalam gambar 3.2.



Gambar 3.2 Arsitektur Jaringan Syaraf Tiraun

Gambar 3.2 menggambarkan jaringan propagasi balik. Setiap unit di lapisan masukan terhubung dengan setiap unit di lapisan tersembunyi. Unit di lapisan tersembunyi juga terhubung ke setiap unit di lapisan keluaran. Arsitektur yang akan digunakan adalah jaringan *multilayer* yang terdiri dari:

- a. Terdiri dari beberapa *input neuron* yang disesuaikan dengan pola masukan di dalam satu lapisan masukan.
- b. Lapisan tersembunyi akan melibatkan proses trial and error dalam penelitian ini, dengan membandingkan tiga model arsitektur berbeda. Model-model ini adalah:
  - Arsitektur dengan 1 lapisan tersembunyi yang memiliki sejumlah neuron yang merupakan kelipatan dari jumlah neuron pada lapisan masukan.
  - Arsitektur dengan 2 lapisan tersembunyi yang juga memiliki sejumlah neuron yang merupakan kelipatan dari jumlah neuron pada lapisan masukan.

- Arsitektur dengan 3 lapisan tersembunyi yang juga memiliki sejumlah neuron yang merupakan kelipatan dari jumlah neuron pada lapisan masukan.

Proses trial and error akan digunakan untuk menentukan model arsitektur yang paling optimal, termasuk mengevaluasi jumlah neuron dalam setiap lapisan tersembunyi tersebut..

- c. Terdapat satu lapisan keluaran yang dapat memiliki beberapa neuron, tergantung pada jumlah keluaran yang diinginkan atau yang diperlukan dalam model ini.

#### 5. Pengaturan parameter jaringan

Proses pembentukan jaringan menggunakan parameter-parameter berikut:

- a. Jumlah *hidden layer* dan *node* pada *hidden layer*

Lapisan tersembunyi berfungsi sebagai tempat untuk memberikan bobot pada masukan yang diterima dari lapisan masukan di setiap *node*. Penentuan jumlah lapisan tersembunyi dan jumlah *node* yang tepat dalam suatu jaringan seringkali tidak dapat dijelaskan dengan rumus matematis tertentu. Dalam penelitian ini, jumlah lapisan tersembunyi ditentukan melalui metode *trial and error*, dengan membandingkan 1 lapisan tersembunyi, 2 lapisan tersembunyi, dan 3 lapisan tersembunyi untuk mencari hasil terbaik yang memiliki tingkat akurasi yang memadai dan sekaligus proses yang lebih cepat. Pemilihan jumlah *node* dalam penelitian ini juga dilakukan melalui pendekatan *trial and error*. Jumlah *node* memiliki dampak signifikan dalam membentuk jaringan yang tepat dan efektif.

- a. Fungsi pelatihan

Fungsi pelatihan memiliki peran penting dalam melatih jaringan untuk memahami pola-pola dalam data dan melakukan peramalan dengan tingkat akurasi yang tinggi. Dalam perangkat lunak MATLAB, terdapat total 12 fungsi pelatihan yang dapat digunakan, antara lain Lavenberg-Marquardt (LM), BFGS Quasi-Newton (BFG), Gradient Descent with Momentum (GDM), Gradient Descent with Momentum and Adaptive Learning (GDX), serta Bayesian Regularization (BR).

Dalam penelitian ini, pemilihan fungsi pelatihan Lavenberg-Marquardt (LM) didasarkan pada hasil percobaan yang dilakukan oleh MATLAB terhadap berbagai fungsi pembelajaran lainnya, serta berdasarkan temuan dalam penelitian sebelumnya.

b. Fungsi aktivasi

Nilai-nilai yang sebelumnya terdapat di dalam *node* lapisan tersembunyi telah diproses dan dihitung. Proses komputasi selama pemrosesan data dilakukan melalui penggunaan fungsi aktivasi. Setiap lapisan tersembunyi menggunakan fungsi aktivasi tertentu untuk melakukan perhitungan dan mengirimkan hasilnya ke lapisan keluaran. Dalam penelitian ini, fungsi aktivasi yang digunakan pada lapisan tersembunyi adalah tansigmoid (Tansig). Pemilihan fungsi ini didasarkan pada fakta bahwa data penelitian telah dinormalisasi ke dalam rentang skala (-1,1) sebelum dimasukkan ke dalam jaringan. Sementara itu, lapisan keluaran hanya menggunakan fungsi *Pureline*.

c. Fungsi performa

Fungsi performa pada jaringan saraf tiruan menggunakan metode *Mean Squared Error* (MSE). Fungsi performa ini berperan dalam menghitung tingkat kesalahan dengan membandingkan selisih antara nilai data asli dan nilai yang dihasilkan oleh proses pelatihan. Dengan menggunakan fungsi performa ini, kita dapat mengukur kinerja proses peramalan dan menentukan metode yang memberikan hasil peramalan terbaik berdasarkan tingkat kesalahan yang ditemukan.

d. Fungsi pembelajaran

Penentuan seberapa cepat jaringan saraf tiruan dapat belajar dan bagaimana gradien yang sesuai untuk mengubah bobot adalah faktor penting dalam mencapai prediksi yang akurat. Jaringan saraf tiruan memiliki fungsi pembelajaran yang memainkan peran kunci dalam proses ini. Dalam konteks ini, terdapat dua fungsi pembelajaran yang digunakan, yaitu *learn*gd dan *learn*gdm.

Dibawah ini adalah tabel yang berisi parameter-parameter jaringan yang digunakan selama proses pelatihan untuk mengatur bagaimana jaringan belajar dan mengoptimalkan bobot ditunjukkan pada Tabel 3.4.

Tabel 3.4 Parameter Jaringan

Parameter	Spesifikasi
Jumlah <i>Neuron</i> Lapisan <i>Input</i>	6
<i>Neuron</i> Pada <i>Hidden Layer</i> 1	6, 12, 18, 24 dan 30
<i>Neuron</i> Pada <i>Hidden Layer</i> 2	6, 12, 18, 24 dan 30
<i>Neuron</i> Pada <i>Hidden Layer</i> 3	6, 12, 18, 24 dan 30
Jumlah <i>Neuron</i> Lapisan <i>Output</i>	4
Fungsi Aktifasi <i>Hidden Layer</i> 1	<i>Tansig</i>
Fungsi Aktifasi <i>Hidden Layer</i> 2	<i>Tansig</i>
Fungsi Aktifasi <i>Hidden Layer</i> 3	<i>Tansig</i>
Fungsi Aktifasi <i>Output Layer</i>	<i>Pureline</i>
Jumlah Iterasi	1000
<i>Goal</i>	0,01
<i>Time</i>	<i>Infinite</i>
<i>Learning rate</i>	0,001

Berdasarkan Tabel 3.4 dapat dilihat parameter jaringan yang digunakan pada proses pelatihan JST *backpropagation*. Parameter pelatihan yang digunakan adalah sebagai berikut.

- a. Batas maksimum *epoch* yang digunakan adalah 1000. Ini berarti proses pelatihan akan berhenti setelah mencapai 1000 iterasi melalui seluruh set data pelatihan, kecuali jika kriteria lain yang telah ditentukan terpenuhi sebelum mencapai batas tersebut. *Epoch* merupakan salah satu parameter penting dalam pelatihan jaringan dan dapat memengaruhi tingkat akurasi dan kecepatan konvergensi jaringan.
- b. Nilai target yang ditetapkan adalah 0,01. Artinya, proses pelatihan akan terus berlanjut hingga nilai error yang dihasilkan oleh jaringan mencapai atau mendekati 0,01, atau pelatihan akan berhenti jika parameter lain yang telah ditentukan tercapai sebelum mencapai nilai target tersebut. Penetapan nilai goal ini penting untuk mengontrol tingkat akurasi yang ingin dicapai oleh jaringan selama proses pelatihan.

- c. *Time* pada pelatihan jaringan saraf merupakan parameter waktu selama proses pelatihan. Pengaturan ini bertindak sebagai pengatur waktu selama pelatihan. Waktu percobaan diatur tidak terbatas sehingga parameter penghentian bergantung pada parameter lainnya.
  - d. Nilai skala learning rate yang digunakan adalah 0,001. Pengaturan nilai learning rate ini memiliki dampak yang signifikan dalam proses pelatihan. Nilai learning rate yang terlalu tinggi dapat menyebabkan konvergensi yang cepat tetapi dapat melewati minimum lokal, sedangkan nilai learning rate yang terlalu rendah dapat menyebabkan pelatihan berjalan sangat lambat atau bahkan tidak konvergen sama sekali. Penggunaan nilai learning rate 0,001 bertujuan untuk meminimalkan perubahan nilai bobot agar dapat mencapai hasil pelatihan yang maksimal dengan menghindari masalah yang disebutkan di atas. Dengan kata lain, nilai ini dipilih agar proses pelatihan berjalan stabil dan konvergen ke minimum global dengan baik..
6. Pelatihan model
- Proses pelatihan model dilakukan dengan tujuan untuk meminimalkan nilai error sehingga model jaringan dapat cocok dan digunakan untuk keperluan prediksi. Dalam pelatihan ini, data dari tahun 2010 hingga 2021 digunakan sebagai data latih untuk mengembangkan model Jaringan Syaraf Tiruan (JST) dengan algoritma backpropagation. Data pelatihan yang digunakan mencakup berbagai informasi seperti data kependudukan, Produk Domestik Regional Bruto (PDRB), dan jumlah pelanggan listrik pada sektor domestik, komersial, publik, dan industri. Sementara itu, target pelatihan adalah data penjualan listrik aktual pada sektor rumah tangga, bisnis, publik, dan industri. Proses pelatihan ini dilakukan secara iteratif, di mana setiap data target diolah satu per satu dengan data masukan yang sama. Tujuannya adalah untuk mengoptimalkan bobot dan parameter jaringan sehingga model dapat melakukan prediksi dengan akurasi yang tinggi berdasarkan data yang diberikan. Dengan demikian, pelatihan model JST backpropagation dapat membantu dalam menghasilkan prediksi yang lebih baik dalam konteks energi listrik.

7. Proses prakiraan

Pelatihan terhadap masing-masing kelompok pelanggan dilakukan untuk mendapatkan nilai bobot dan bias yang kemudian digunakan untuk meramalkan konsumsi listrik. Proses selanjutnya adalah data jumlah pelanggan listrik yang diharapkan dan PDRB atau sampelnya menjadi masukan untuk simulasi pada jaringan yang dilatih. Nilai bobot dan bias yang digunakan untuk pelatihan dan simulasi yang dihasilkan diasumsikan sama untuk mencari nilai konsumsi energi listrik tahun 2021 hingga tahun 2030 semua sektor wilayah pelanggan.

8. Denormalisasi data

Denormalisasi dilakukan untuk memulihkan data yang dinormalisasi lebih lanjut dalam skala (-1,1). Proses ini berdampak pada terciptanya nilai yang telah dinormalisasi ke nilai aslinya. Proses denormalisasi dilakukan dengan menggunakan rumusan Persamaan (3.2).

$$X = 0.5 * (X_n + 1) * (X_{max} - X_{min}) + X_{min} \quad (3.2)$$

Nilai  $X$  merupakan nilai data denormalisasi yang diperoleh menggunakan Persamaan (3.2) nilai  $X_n$  merupakan nilai hasil normalisasi data, nilai  $X_{min}$  merupakan nilai minimum data dan nilai  $X_{max}$  merupakan nilai maksimum data.

9. Validasi dengan data aktual

Eksperimen terhadap data nyata dilakukan untuk mengetahui keakuratan ramalan dengan menurunkan nilai MAPE menggunakan persamaan (2.12). Data aktual yang digunakan dalam proses validasi adalah data aktual yang diketahui pada tahun 2021. Data aktual tahun 2021 dijadikan sebagai data peramalan tahun 2021 dengan menggunakan metode *neural network backpropagation* dan RUPTL PLN tahun 2021 hingga tahun 2030 telah diketahui.

10. Kesimpulan dan saran

Tujuan dari penelitian ini adalah untuk mengevaluasi kinerja Jaringan Syaraf Tiruan dengan algoritma *backpropagation* dalam meramalkan kebutuhan energi listrik. Hasil yang diharapkan dari penelitian ini adalah pengembangan model yang mampu memberikan nilai *Mean Absolute*

*Percentage Error* (MAPE) yang rendah. MAPE digunakan sebagai ukuran untuk menilai tingkat ketepatan atau kemampuan model dalam mencapai nilai target atau nilai yang diharapkan dalam konteks peramalan kebutuhan energi listrik. Semakin kecil nilai MAPE, semakin baik kinerja model dalam meramalkan kebutuhan energi listrik dengan akurasi yang tinggi.

### **3.2 Studi Literatur**

Penelitian ini dilakukan dengan cara membaca dan memahami buku, jurnal, serta literatur-literatur terkait yang berkaitan dengan topik peramalan energi listrik. Literatur penelitian ini bertujuan untuk memahami teori-teori khusus dan teori pendukung yang relevan dalam pengolahan data peramalan kebutuhan listrik. Hasil dari penelitian literatur ini digunakan sebagai bahan perbandingan dan referensi dalam melakukan peramalan kebutuhan listrik di Provinsi Banten.

### **3.3 Alat dan Bahan**

Alat dan bahan yang digunakan dalam penelitian skripsi ini terdiri dari:

1. Laptop Lenovo X250 dengan Processor Intel Core i5 2.4 GHz, dan sistem operasi Windows 10, digunakan sebagai media perancangan dan pengujian simulasi.
2. Data-data dari beberapa referensi jurnal yang dijadikan sebagai sumber pendukung dalam penelitian skripsi ini.
3. Perangkat lunak Microsoft Office (Excel 2010 dan Word 2010) digunakan untuk pengolahan dan perhitungan data serta pembuatan laporan berdasarkan hasil perhitungan.
4. Perangkat lunak MATLAB R2020a merupakan perangkat lunak utama yang digunakan dalam perancangan dan perhitungan simulasi penelitian ini, dan sudah terinstal di unit laptop.

### **3.4 Pengumpulan Data**

Pengumpulan data dalam penelitian ini melibatkan beberapa instansi dan perusahaan yang menyediakan informasi yang diperlukan untuk perhitungan dalam rangka menghasilkan prakiraan kebutuhan energi listrik. Data historis



tentang kebutuhan energi listrik di wilayah Provinsi Banten diperoleh dari PT. PLN (Persero) sesuai dengan Rencana Usaha Penyediaan Tenaga Listrik (RUPTL) PLN 2021 hingga tahun 2030. Data demografi dan Produk Domestik Regional Bruto (PDRB) diperoleh dari catatan historis Badan Pusat Statistik (BPS) Provinsi Banten. Selain itu, dalam proses pengumpulan data, dilakukan wawancara dan observasi lapangan untuk mengakses dokumen dan teori yang terkait dengan peramalan kebutuhan energi listrik. Data statistik ketenagalistrikan Provinsi Banten yang digunakan dalam penelitian ini juga diperoleh dari PT. PLN (Persero) dan mencakup rentang tahun dari 2011 hingga 2021. Penelitian ini membutuhkan data sebagai dasar untuk melakukan peramalan. Data yang digunakan untuk menghitung peramalan berasal dari berbagai perusahaan yang memiliki dampak signifikan terhadap permintaan energi listrik. Dalam rangka penelitian ini, data yang diperlukan telah diperoleh melalui observasi terhadap beberapa perusahaan dan instansi, dengan sumber informasi utama berasal dari PT. PLN (Persero) dan Badan Pusat Statistik (BPS) Provinsi Banten. Berikut adalah jenis-jenis data yang dikumpulkan:

1. Data pelanggan PLN jenis rumah tangga.
2. Data pelanggan PLN jenis bisnis.
3. Data pelanggan PLN jenis industri.
4. Data pelanggan PLN jenis publik.
5. Jumlah energi yang terjual di sektor rumah tangga.
6. Jumlah energi yang terjual di sektor bisnis.
7. Jumlah energi yang terjual di sektor publik.
8. Jumlah energi yang terjual di sektor industri.
9. Data jumlah penduduk.
10. Data Produk Domestik Regional Bruto (PDRB).

Data-data ini digunakan sebagai sumber informasi untuk melakukan analisis dan peramalan kebutuhan energi listrik dalam penelitian ini.

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1 Perbandingan Arsitektur Jaringan

Penelitian ini menggunakan arsitektur *JST backpropagation multilayer*, yang melibatkan lebih dari satu lapisan dalam satu jaringan. Proses pelatihan data dilakukan beberapa kali dengan metode *trial and error*, di mana ada percobaan dengan tiga arsitektur jaringan yang berbeda. Perbedaan utamanya terletak pada jumlah *hidden layer* yang digunakan untuk mencari arsitektur terbaik dalam model yang dikembangkan.

Pada arsitektur pertama, hanya terdapat satu *hidden layer* yang memiliki lima model jaringan yang berbeda dengan jumlah *neuron* pada *hidden layer* yang berbeda pula, yaitu 6, 12, 18, 24, dan 30 *neuron*. Berikut ini adalah hasil dari pelatihan arsitektur jaringan dengan satu *hidden layer* yang akan ditampilkan dalam tabel 4.1.

Tabel 4.1 Arsitektur Jaringan Menggunakan Satu *Hidden Layer*

Jumlah Neuron	Epoch	Regresi	MSE	Time (s)
6 Neuron	7	0,99859	0,000505	4,9
12 Neuron	4	0,99943	0,000215	4,86
18 Neuron	4	0,99078	0,003308	4,93
24 Neuron	4	0,99997	0,000017	5,37
30 Neuron	3	0,99996	0,000013	4,71
Average	4,4	0,997746	0,000812	4,954

Berdasarkan Tabel 4.1 dapat dilihat untuk rata-rata *epoch* model arsitektur menggunakan satu *hidden layer* diperoleh rata-rata 4,4 *epoch*. Rata-rata nilai regresi yang diperoleh oleh model arsitektur dengan menggunakan satu *hidden layer* adalah 0,997746 karna nilai regresi mendekati 1 dapat dikatakan baik. Rata-rata nilai MSE model arsitektur dengan menggunakan satu *hidden layer* yaitu sebesar 0,000812. Rata-rata waktu komputasi yang didapat model arsitektur dengan menggunakan satu *hidden layer* yaitu sebesar 4,9528 detik.

Arsitektur ke-2 menggunakan 3 *hidden layer* dimana terdapat 5 model jaringan yang berbeda dan setiap model pada *hidden layer* pertama dan kedua memiliki jumlah *neuron* yang sama, jumlah *neuron* yang digunakan yaitu 6, 12,

18, 24 dan 30 *neuron*. Berikut merupakan hasil pelatihan arsitektur jaringan dengan 2 *hidden layer* yang akan ditunjukkan pada Tabel 4.2.

Tabel 4.2 Arsitektur Jaringan Menggunakan Dua *Hidden Layer*

Jumlah Neuron	Epoch	Regresi	MSE	Time (s)
6 Neuron	8	0,99146	0,002981	4,52
12 Neuron	4	0,99137	0,003282	4,65
18 Neuron	4	0,99956	0,00015	4,61
24 Neuron	3	0,99067	0,003316	6,31
30 Neuron	3	0,99922	0,000417	4,68
Average	4,4	0,9944	0,002	4,9534

Berdasarkan Tabel 4.2 dapat dilihat untuk rata-rata *epoch* model arsitektur menggunakan dua *hidden layer* diperoleh rata-rata 4,4 *epoch*. Rata-rata nilai regresi yang diperoleh oleh model arsitektur dengan menggunakan dua *hidden layer* adalah 0,9944 karna nilai regresi mendekati 1 dapat dikatakan baik. Rata-rata nilai MSE model arsitektur dengan menggunakan dua *hidden layer* yaitu sebesar 0,002. Rata-rata waktu komputasi yang didapat model arsitektur dengan menggunakan dua *hidden layer* yaitu sebesar 4,9534 detik.

Arsitektur ke-3 menggunakan 3 *hidden layer* dimana terdapat 5 model jaringan yang berbeda dan setiap model pada *hidden layer* pertama, kedua dan ketiga memiliki jumlah *neuron* yang sama, jumlah *neuron* yang digunakan yaitu 6, 12, 18, 24 dan 30 *neuron*. Berikut merupakan hasil pelatihan arsitektur jaringan dengan 3 *hidden layer* yang ditunjukkan pada Tabel 4.3.

Tabel 4.3 Arsitektur Jaringan Menggunakan Tiga *Hidden Layer*

Jumlah Neuron	Epoch	Regresi	MSE	Time (s)
6 Neuron	8	0,99448	0,001883	5,56
12 Neuron	5	0,99285	0,00376	4,89
18 Neuron	4	0,99825	0,000608	4,65
24 Neuron	3	0,99182	0,003166	5,08
30 Neuron	4	0,9982	0,000611	4,85
Average	4,8	0,9951	0,002	5,0056

Berdasarkan Tabel 4.3 dapat dilihat untuk rata-rata *epoch* model arsitektur menggunakan tiga *hidden layer* diperoleh rata-rata 4,8 *epoch*. Rata-rata nilai regresi yang diperoleh oleh model arsitektur dengan menggunakan tiga *hidden layer* adalah 0,9951 karna nilai regresi mendekati 1 dapat dikatakan baik. Rata-

rata nilai MSE model arsitektur dengan menggunakan tiga *hidden layer* yaitu sebesar 0,002. Rata-rata waktu komputasi yang didapat model arsitektur dengan menggunakan tiga *hidden layer* yaitu sebesar 5,0056 detik.


Percobaan *trial and error* yang telah dilakukan dapat disimpulkan bahwa model arsitektur dengan menggunakan 1 *hidden layer* merupakan arsitektur terbaik yang dibandingkan dengan 2 dan 3 *hidden layer*. Model arsitektur dengan satu *hidden layer* selanjutnya dilakukan *trail and error* kembali untuk menentukan jumlah *neuron* terbaik yang digunakan.

## **4.2 Pelatihan Jaringan Menggunakan Satu Hidden Layer**

Ada lima model arsitektur yang digunakan dalam penelitian, dan berikut adalah rincian dari masing-masing model, model arsitektur ke-1 terdiri dari 6 neuron pada input layer, 6 neuron pada hidden layer, dan 4 neuron pada output layer. Model arsitektur ke-2 terdiri dari 6 neuron pada input layer, 12 neuron pada hidden layer, dan 4 neuron pada output layer. Model arsitektur ke-3 terdiri dari 6 neuron pada input layer, 18 neuron pada hidden layer, dan 4 neuron pada output layer. Model arsitektur ke-4 terdiri dari 6 neuron pada input layer, 24 neuron pada hidden layer, dan 4 neuron pada output layer. Model arsitektur ke-5 terdiri dari 6 neuron pada input layer, 30 neuron pada hidden layer, dan 4 neuron pada output layer. Selanjutnya, hasil MAPE dari kelima model arsitektur tersebut dibandingkan untuk mengevaluasi kinerja masing-masing model dalam melakukan peramalan atau prediksi.


### **4.2.1 Pelatihan Arsitektur Jaringan Model Ke-1**

Pada model pelatihan pertama, terdapat satu lapisan masukan dengan enam *neuron*, satu lapisan tersembunyi dengan enam *neuron*, dan empat *neuron* pada lapisan keluaran. Ilustrasi hasil pelatihan jaringan ini dapat dilihat pada jendela keluaran pelatihan seperti yang ditunjukkan dalam Gambar 4.1.




Gambar 4.1 Pelatihan Jaringan Model ke-1

Berdasarkan Gambar 4.1 menunjukkan bahwa jaringan diatur untuk maksimal dapat melakukan hingga 1000 *epoch*, namun pada percobaan yang telah dilakukan berhenti pada *epoch* ke-5 dengan durasi yang diperlukan selama 1 detik. Bentuk grafik *performance* pelatihan model arsitektur ke-1 dapat dilihat pada Gambar 4.2.

Gambar 4.2 Grafik *Performance* Pelatihan Jaringan Model Ke-1

Berdasarkan Gambar 4.2 dapat dilihat tampilan grafik proses *training* terbaik arsitektur jaringan model ke-1 menghasilkan *best validation performance* 0,0045388 yang diperoleh pada *epoch* ke-5. Hasil *plot regression* pelatihan arsitektur jaringan ke-1 ditampilkan pada Gambar 4.3.



Gambar 4.3 *Plot Regression Output* Pelatihan Jaringan Model Ke-1

Grafik pelatihan pada Gambar 4.3 menunjukkan bahwa koefisien Regresi (R) adalah sebesar 0,99445. Nilai regresi pelatihan yang mendekati 1 mengindikasikan hasil yang sangat baik. Selain itu, grafik yang mendekati garis putus-putus juga menandakan bahwa proses pelatihan berjalan dengan baik. Berikut adalah hasil keluaran dari pelatihan model pertama yang ditampilkan dalam Tabel 4.4.

Tabel 4.4 *Output* Pelatihan Jaringan Model Ke-1 Normalisasi

Tahun	RT	Bisnis	Publik	Industri
2011	-0,80575	-0,76383	-1,04374	-0,84554
2012	-0,67548	-0,90621	-0,8589	-0,55683
2013	-1,03895	-0,04219	-0,81887	-0,24547
2014	-0,65604	-0,26261	-0,66548	-0,30576
2015	-0,35251	-0,29881	-0,60793	-0,90301
2016	-0,18361	-0,0719	-0,26501	-0,30237
2017	-0,06849	0,358467	0,146694	0,247642
2018	0,06632	0,638765	0,497668	0,993479
2019	0,449989	0,964327	0,982384	0,884421
2020	0,972415	0,942358	0,661574	-0,11743

Berdasarkan Tabel 4.4 di atas data hasil *output* pelatihan jaringan masih dalam bentuk normalisasi, sehingga perlu dilakukan proses denormalisasi menjadi bentuk aslinya. Berikut merupakan hasil denormalisasi pelatihan jaringan model ke-1 yang ditunjukkan pada Tabel 4.5

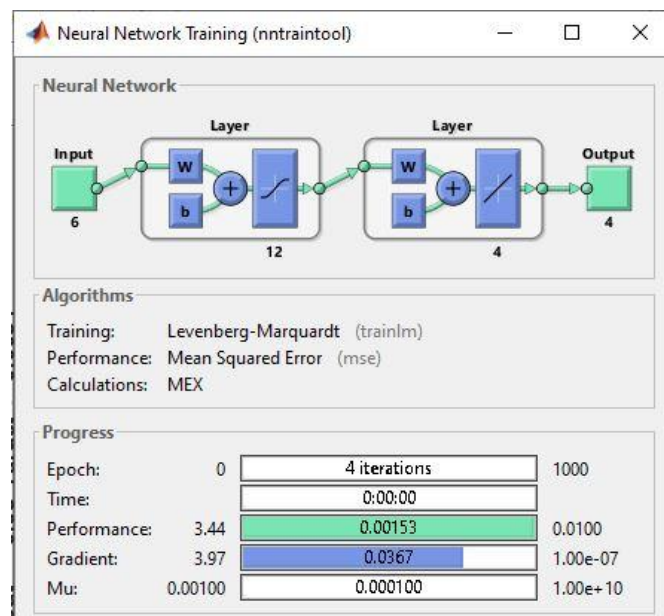
Tabel 4.5 *Output* Pelatihan Jaringan Model Ke-1 Denormalisasi (GWh)

Tahun	RT	Bisnis	Publik	Industri
2011	3849,20	1893,75	400,01	11728,33
2012	3989,51	1810,10	416,96	12209,32
2013	3598,05	2317,72	420,63	12728,04
2014	4010,44	2188,21	434,70	12627,60
2015	4337,34	2166,95	439,98	11632,59
2016	4519,25	2300,26	471,43	12633,26
2017	4643,23	2553,10	509,19	13549,57
2018	4788,43	2717,77	541,39	14792,14
2019	5201,64	2909,04	585,84	14610,45
2020	5764,29	2896,14	556,42	12941,36

Berdasarkan tabel 4.5 dapat dilihat hasil pelatihan jaringan model ke-1 dengan JST *backpropagation* yang telah didenormalisasi dalam nilai sebenarnya atau dalam satuan GWh menggunakan Persamaan (3.2).

#### 4.2.2 Pelatihan Arsitektur Jaringan Model Ke-2


Dalam model arsitektur pelatihan ke-2, terdapat satu lapisan *input* dengan 6 *neuron*, satu lapisan tersembunyi dengan 12 *neuron*, dan 4 *neuron* pada lapisan *output*. Berikut adalah tampilan hasil pelatihan jaringan untuk model ini yang diperlihatkan dalam Gambar 4.4.



Gambar 4.4 Pelatihan Jaringan Model Ke-2


Berdasarkan Gambar 4.4 dapat dilihat bahwa jaringan diatur untuk maksimal dapat melakukan hingga 1000 *epoch*, namun pada percobaan yang telah dilakukan

berhenti pada *epoch* ke-4 dengan durasi yang diperlukan selama 0 detik. Bentuk grafik *performance* pelatihan arsitektur jaringan model ke-2 dapat dilihat pada Gambar 4.5.



Gambar 4.5 Grafik *Performance* Pelatihan Jaringan Model Ke-2

Berdasarkan Gambar 4.5 dapat dilihat tampilan grafik proses *training* terbaik arsitektur jaringan model ke-2 menghasilkan *best validation performance* 0,0015284 yang diperoleh pada *epoch* ke-4. Hasil *plot regression* arsitektur jaringan model ke-2 ditampilkan pada Gambar 4.6.



Gambar 4.6 *Plot Regression Output* Pelatihan Jaringan Model Ke-2

Dari Gambar 4.6 terlihat bahwa grafik pelatihan untuk arsitektur jaringan model ke-2 memiliki nilai Regresi (R) sebesar 0,99829. Nilai Regresi yang mendekati 1



menunjukkan hasil yang sangat baik, dan grafik yang mendekati garis putus-putus juga menunjukkan bahwa pelatihan berjalan dengan lancar. Berikut adalah hasil output pelatihan untuk model jaringan ke-2 yang ditampilkan dalam Tabel 4.6.

Tabel 4.6 *Output* Pelatihan Jaringan Model Ke-2 Normalisasi

Tahun	RT	Bisnis	Publik	Industri
2011	-1,02049	-0,75725	-0,96551	-1,07016
2012	-0,73654	-1,03706	-0,85707	-0,60173
2013	-1,08581	-0,0896	-0,78279	-0,23082
2014	-0,80166	-0,17752	-0,605	-0,38757
2015	-0,31175	-0,33455	-0,60393	-0,8912
2016	-0,15499	-0,00028	-0,28293	-0,1927
2017	-0,12036	0,302343	0,074982	0,276208
2018	0,088847	0,669771	0,542291	0,982427
2019	0,431779	1,004217	1,045561	0,820441
2020	0,993858	0,919754	0,687627	-0,0738

Berdasarkan Tabel 4.6 di atas data hasil *output* pelatihan jaringan masih dalam bentuk normalisasi, sehingga perlu dilakukan proses denormalisasi menjadi bentuk aslinya. Berikut merupakan hasil denormalisasi pelatihan jaringan model ke-2 yang ditunjukkan pada Tabel 4.7.

Tabel 4.7 *Output* Pelatihan Jaringan Model Ke-2 Denormalisasi (GWh)

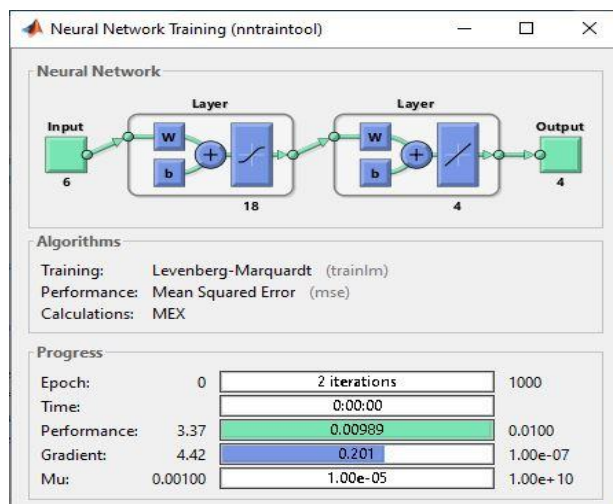
Tahun	RT	Bisnis	Publik	Industri
2011	3617,93	1897,62	407,18	11354,12
2012	3923,75	1733,23	417,13	12134,52
2013	3547,58	2289,86	423,94	12752,45
2014	3853,61	2238,21	440,25	12491,32
2015	4381,25	2145,95	440,35	11652,26
2016	4550,07	2342,33	469,79	12815,97
2017	4587,37	2520,13	502,62	13597,16
2018	4812,69	2735,99	545,48	14773,72
2019	5182,03	2932,48	591,64	14503,85
2020	5787,39	2882,86	558,81	13014,05

Berdasarkan Tabel 4.7 dapat dilihat hasil pelatihan jaringan model ke-2 dengan JST *backpropagation* yang telah didenormalisasi dalam nilai sebenarnya atau dalam satuan GWh menggunakan Persamaan (3.2).

### 4.2.3 Pelatihan Arsitektur Jaringan Model Ke-3


Model arsitektur pelatihan ke-3 menggunakan satu lapisan *input* dengan 6 *neuron*, satu lapisan tersembunyi dengan 18 *neuron*, dan empat *neuron* pada

lapisan *output*. Berikut adalah hasil pelatihan yang ditampilkan dalam jendela pelatihan pada Gambar 4.7.




Gambar 4.7 Hasil Pelatihan Jaringan Model Ke-3

Berdasarkan Gambar 4.7 menunjukkan bahwa jaringan diatur untuk maksimal dapat melakukan hingga 1000 *epoch*, namun pada percobaan yang telah dilakukan berhenti pada *epoch* ke-2 dengan durasi yang diperlukan selama 0 detik. Bentuk gambar grafik *performance* dapat dilihat pada Gambar 4.8.



Gambar 4.8 Grafik *Performance* Hasil Pelatihan Jaringan Model Ke-3

Berdasarkan Gambar 4.8 dapat dilihat tampilan grafik proses *training* arsitektur jaringan ke-3 terbaik dengan menghasilkan *best validation performance* 0,0098935 yang diperoleh pada *epoch* ke-2. Hasil *plot regression* ditampilkan pada Gambar 4.9.



Gambar 4.9 *Plot Regression Output* Pelatihan Jaringan Model Ke-3

Dilihat dari Gambar 4.9 dapat disimpulkan bahwa grafik pelatihan untuk arsitektur jaringan model ke-3 menunjukkan nilai Regresi (R) sebesar 0,99136. Ini menandakan bahwa pelatihan berjalan dengan baik, karena semakin mendekati nilai 1, semakin baik. Selain itu, grafik yang mendekati garis putus-putus juga mengindikasikan performa pelatihan yang baik. Hasil output dari pelatihan jaringan model ke-3 dapat ditemukan yang disediakan dalam Tabel 4.8.

Tabel 4.8 *Output* Pelatihan Jaringan Model Ke-3 Normalisasi

Tahun	RT	Bisnis	Publik	Industri
2011	-0,97035	-0,69842	-1,02239	-0,91037
2012	-0,65621	-0,97005	-0,93669	-0,4106
2013	-1,02297	-0,08732	-0,83005	-0,10652
2014	-0,77911	-0,1924	-0,61451	-0,34017
2015	-0,32309	-0,33266	-0,58992	-0,89644
2016	-0,15226	0,004493	-0,28098	-0,19732
2017	-0,08962	0,307466	0,073618	0,302008
2018	0,134528	0,666559	0,568037	1,0458
2019	0,490572	1,000393	1,057321	0,960132
2020	1,000023	0,941141	0,680618	-0,05678

Berdasarkan Tabel 4.8 di atas data hasil *output* pelatihan jaringan masih dalam bentuk normalisasi, sehingga perlu dilakukan proses denormalisasi menjadi bentuk aslinya. Berikut merupakan hasil denormalisasi pelatihan jaringan model ke-3 yang ditunjukkan pada Tabel 4.9.


Tabel 4.9 *Output* Pelatihan Jaringan Model Ke-3 Denormalisasi (GWh)

Tahun	RT	Bisnis	Publik	Industri
2011	3671,93	1932,18	401,97	11620,32
2012	4010,26	1772,60	409,83	12452,94
2013	3615,26	2291,20	419,61	12959,54
2014	3877,90	2229,47	439,38	12570,28
2015	4369,04	2147,06	441,63	11643,53
2016	4553,01	2345,14	469,97	12808,26
2017	4620,48	2523,14	502,49	13640,14
2018	4861,89	2734,10	547,84	14879,30
2019	5245,35	2930,23	592,72	14736,58
2020	5794,02	2895,42	558,17	13042,40

Berdasarkan Tabel 4.9 dapat dilihat hasil pelatihan jaringan model ke-3 dengan JST *backpropagation* yang telah didenormalisasi dalam nilai sebenarnya atau dalam satuan GWh menggunakan Persamaan (3.2).

#### 4.2.4 Pelatihan Arsitektur Jaringan Model Ke-4


Arsitektur jaringan pada pelatihan ke-4 menggunakan 1 lapisan *input* dengan 6 *neuron*, 1 lapisan tersembunyi dengan 24 *neuron*, dan 4 *neuron* pada lapisan *output*. Berikut adalah tampilan hasil pelatihan dari jaringan ini yang ditunjukkan dalam Gambar 4.10.



Gambar 4.10 Hasil Pelatihan Jaringan Model Ke-4


Berdasarkan Gambar 4.10 menunjukkan bahwa jaringan diatur untuk maksimal dapat melakukan hingga 1000 *epoch*, namun pada percobaan yang telah dilakukan

berhenti pada *epoch* ke-3 dengan durasi yang diperlukan selama 0 detik. Bentuk gambar grafik *performance* dapat dilihat pada Gambar 4.11.



Gambar 4.11 Grafik *Performance* Pelatihan Jaringan Model Ke-4

Berdasarkan Gambar 4.11 dapat dilihat tampilan grafik proses *training* arsitektur jaringan model ke empat terbaik dengan menghasilkan *best validation performance* 0,00052236 yang diperoleh pada *epoch* ke-3. Hasil *plot regression* ditampilkan pada Gambar 4.12.



Gambar 4.12 *Plot Regression Output* Pelatihan Jaringan Model Ke-4

Berdasarkan Gambar 4.12, terlihat bahwa grafik pelatihan arsitektur jaringan model ke-4 memiliki nilai Regression (R) sebesar 0,9994. Hasil pelatihan ini menunjukkan performa yang sangat baik, karena nilai R mendekati 1. Grafik yang mendekati garis putus-putus juga menunjukkan bahwa pelatihan berjalan dengan baik. Berikut adalah hasil output pelatihan jaringan model ke-4 yang ditampilkan dalam Tabel 4.10.

Tabel 4.10 *Output* Pelatihan Jaringan Model Ke-4 Normalisasi

Tahun	RT	Bisnis	Publik	Industri
2011	-0,86257	-0,62191	-0,89038	-0,85298
2012	-0,53058	-0,85216	-0,83666	-0,35972
2013	-0,94635	0,015786	-0,78923	-0,08761
2014	-0,72709	-0,0918	-0,61043	-0,33292
2015	-0,30972	-0,2911	-0,60704	-0,90288
2016	-0,16065	0,011851	-0,29927	-0,21234
2017	-0,08419	0,318355	0,083638	0,304391
2018	0,114646	0,650459	0,546735	1,008151
2019	0,453937	0,910657	0,971187	0,840637
2020	1,047238	0,934813	0,78472	0,017958

Berdasarkan Tabel 4.10 di atas data hasil *output* pelatihan jaringan masih dalam bentuk normalisasi, sehingga perlu dilakukan proses denormalisasi menjadi bentuk aslinya. Berikut merupakan hasil denormalisasi pelatihan jaringan model ke-4 yang ditunjukkan pada Tabel 4.11.


Tabel 4.11 *Output* Pelatihan Jaringan Model Ke-4 Denormalisasi (GWh)

Tahun	RT	Bisnis	Publik	Industri
2011	3788,01	1977,13	414,07	11715,94
2012	4145,56	1841,86	419,00	12537,71
2013	3697,78	2351,77	423,35	12991,03
2014	3933,93	2288,57	439,75	12582,35
2015	4383,43	2171,48	440,06	11632,80
2016	4543,98	2349,46	468,29	12783,25
2017	4626,33	2529,53	503,41	13644,12
2018	4840,47	2724,64	545,89	14816,58
2019	5205,89	2877,51	584,82	14537,50
2020	5844,88	2891,70	567,71	13166,92

Berdasarkan Tabel 4.11 dapat dilihat hasil pelatihan jaringan model ke-4 dengan JST *backpropagation* yang telah didenormalisasi dalam nilai sebenarnya atau dalam satuan GWh menggunakan Persamaan (3.2).


#### 4.2.5 Pelatihan Arsitektur Jaringan Model Ke-5

Model arsitektur pelatihan ke-5 memiliki 1 lapisan *input* dengan 6 *neuron*, 1 lapisan tersembunyi dengan 30 *neuron*, dan 4 *neuron* pada lapisan *output*. Berikut adalah jendela hasil pelatihan jaringan yang ditampilkan pada Gambar 4.13.




Gambar 4.13 Pelatihan Jaringan Model Ke-5

Berdasarkan Gambar 4.13 menunjukkan bahwa jaringan diatur untuk maksimal dapat melakukan hingga 1000 *epoch*, namun pada percobaan yang telah dilakukan berhenti pada *epoch* ke-2 dengan durasi yang diperlukan selama 0 detik. Bentuk gambar grafik *performance* dapat dilihat pada Gambar 4.14.



Gambar 4.14 Grafik *Performance* Pelatihan Jaringan Model Ke-5

Berdasarkan Gambar 4.14 dapat dilihat tampilan grafik proses *training* arsitektur jaringan model ke-5 terbaik dengan menghasilkan *best validation performance* 0,0014614 yang diperoleh pada *epoch* ke-2. Hasil *plot regression* ditampilkan pada Gambar 4.15.



Gambar 4.15 *Plot Regression Output* Pelatihan Jaringan Model Ke-5

Grafik yang terlihat pada Gambar 4.15 mengindikasikan bahwa hasil pelatihan menunjukkan nilai Regresi (R) sebesar 0,99863. Hasil Regresi pelatihan ini dianggap baik karena semakin mendekati nilai 1. Grafik yang semakin mendekati garis putus-putus juga menandakan bahwa pelatihan telah berjalan dengan baik. Berikut adalah hasil output pelatihan jaringan untuk model ke-5 yang ditampilkan dalam Tabel 4.12.

Tabel 4.12 *Output* Pelatihan Jaringan Model Ke-5 Normalisasi

Tahun	RT	Bisnis	Publik	Industri
2011	-1,04435	-0,65539	-0,93421	-0,88176
2012	-0,67424	-0,92096	-0,82038	-0,4071
2013	-1,00363	-0,08037	-0,70761	-0,1934
2014	-0,77837	-0,10658	-0,52121	-0,3118
2015	-0,35918	-0,28971	-0,57635	-0,86711
2016	-0,15256	-0,00683	-0,2961	-0,17751
2017	-0,06516	0,330349	0,055179	0,319526
2018	0,164232	0,690941	0,518732	1,035388
2019	0,538268	1,029871	0,967196	0,913545
2020	0,96702	0,8944	0,686361	-0,06794



Berdasarkan Tabel 4.12 di atas data hasil *output* pelatihan jaringan masih dalam bentuk normalisasi, sehingga perlu dilakukan proses denormalisasi menjadi bentuk aslinya. Berikut merupakan hasil denormalisasi pelatihan jaringan model ke-5 yang ditunjukkan pada Tabel 4.13.

Tabel 4.13 *Output* Pelatihan Jaringan Model Ke-5 Denormalisasi (GWh)

Tahun	RT	Bisnis	Publik	Industri
2011	3592,24	1957,46	410,05	11667,99
2012	3990,84	1801,43	420,49	12458,78
2013	3636,09	2295,28	430,84	12814,80
2014	3878,70	2279,88	447,93	12617,53
2015	4330,17	2172,30	442,88	11692,39
2016	4552,69	2338,49	468,58	12841,27
2017	4646,82	2536,58	500,80	13669,33
2018	4893,88	2748,43	543,32	14861,96
2019	5296,71	2947,55	584,45	14658,97
2020	5758,48	2867,96	558,69	13023,81

Berdasarkan Tabel 4.13 dapat dilihat hasil pelatihan jaringan model ke-5 dengan *JST backpropagation* yang telah didenormalisasi dalam nilai sebenarnya atau dalam satuan GWh menggunakan Persamaan (3.2).

### 4.3 Perbandingan *Error Output* Pelatihan Jaringan 1 *Hidden Layer*

Tujuan dari pelatihan jaringan adalah untuk mengamati bagaimana jaringan merespons dan diharapkan agar hasilnya mendekati data target. Berikut ini adalah perbandingan nilai kesalahan untuk setiap model pelatihan jaringan, yang terdokumentasikan dalam Tabel 4.14.

Tabel 4.14 Perbandingan Nilai *Error Output* Pelatihan Jaringan

Jumlah <i>Neuron</i>	MAPE(%)
6	1,081856
12	0,661699
18	0,360308
24	1,055625
30	0,890641

Berdasarkan Tabel 4.14 dapat dilihat perbandingan nilai *error* hasil *output* pelatihan jaringan dari masing-masing model pelatihan. Dengan menggunakan MAPE sebagai indikator, didapat presentase error dari masing-masing fungsi pelatihan dengan hasil nilai *error* terkecil terdapat pada model pelatihan ke-3 yang

menggunakan 18 *neuron* pada *hidden layer* dengan presentase kesalahan sebesar 0,360308% sementara nilai presentase error terbesar terdapat pada model pelatihan ke-1 yang menggunakan 6 *neuron* pada *hidden layer* dengan presentase kesalahan sebesar 1,081856%. Sehingga didapat model pelatihan terbaik yang digunakan untuk proses peramalan yaitu model pelatihan ke-1 karena memiliki nilai presentase error MAPE terkecil dibandingkan dengan model pelatihan lainnya.

#### 4.4 Prakiraan Kebutuhan Listrik Sektoral

Hasil dari pelatihan memberikan informasi tentang model pelatihan terbaik yang akan digunakan dalam proses prediksi. Proses pelatihan menggunakan data dari tahun 2011 hingga 2020 untuk memprediksi data dari tahun 2021 hingga 2030. Setelah proses pelatihan selesai, hasil prediksi kebutuhan energi listrik dengan menggunakan model terbaik digunakan untuk membandingkannya dengan data yang terdapat dalam Rencana Usaha Penyediaan Tenaga Listrik (RUPTL). Tujuan dari perbandingan ini adalah untuk mengevaluasi tingkat error prediksi, yang dapat ditemukan yang disajikan dalam Tabel 4.15.

Tabel 4.15 Perbandingan Prakiraan Sektoral RUPTL dengan JST

Tahun	RT (GWh)		Bisnis (GWh)		Publik(GWh)		Industri (GWh)	
	RUPTL	JST	RUPTL	JST	RUPTL	JST	RUPTL	JST
2021	6133	6048,90	3090	3022,13	632	617,57	13088	14293,07
2022	6428	6368,24	3328	3096,44	671	650,35	13293	14436,07
2023	6736	6548,10	3583	3193,56	709	681,96	13498	14580,82
2024	7058	6684,67	3852	3257,38	748	712,42	13705	14733,88
2025	7393	6851,17	4136	3323,54	788	741,56	13939	14919,91
2026	7741	7063,18	4436	3432,75	830	772,20	14194	15194,92
2027	8099	7306,85	4754	3623,41	876	806,15	14356	15633,07
2028	8467	7492,72	5086	3891,76	924	825,45	14499	16227,77
2029	8845	7560,01	5428	4140,07	976	827,11	14633	16768,75
2030	9256	7575,62	5798	4278,77	1028	820,21	14806	17057,67
MAPE(%)	8,04		17,49		8,09		9,80	

Berdasarkan Tabel 4.15, terlihat hasil prakiraan kebutuhan energi listrik untuk setiap sektor di Provinsi Banten menggunakan metode JST *backpropagation* dibandingkan dengan data RUPTL. Hasil prakiraan untuk sektor rumah tangga Provinsi Banten menunjukkan perkiraan kenaikan dari 6048,90 GWh pada tahun

2021 menjadi 7575,62 GWh pada tahun 2030 menggunakan metode JST *backpropagation*. Sementara itu, hasil prakiraan RUPTL untuk sektor rumah tangga Provinsi Banten memperkirakan peningkatan dari 6133 GWh pada tahun 2021 menjadi 9256 GWh pada tahun 2030. Kesalahan rata-rata prakiraan sektor rumah tangga menggunakan metode JST *backpropagation* dibandingkan dengan RUPTL sebesar 8,04%..

Hasil prakiraan dengan metode JST *backpropagation* untuk sektor bisnis Provinsi Banten menunjukkan estimasi kenaikan dari 3022,13 GWh pada tahun 2021 menjadi 4278,77 GWh pada tahun 2030. Sementara itu, hasil prakiraan RUPTL untuk sektor bisnis Provinsi Banten memperkirakan peningkatan dari 3090 GWh pada tahun 2021 menjadi 5798 GWh pada tahun 2030. Kesalahan rata-rata prakiraan untuk sektor bisnis menggunakan metode JST *backpropagation* dibandingkan dengan RUPTL adalah sebesar 17,49%.

Hasil prakiraan dengan metode JST *backpropagation* untuk sektor publik Provinsi Banten menunjukkan estimasi kenaikan dari 617,57 GWh pada tahun 2021 menjadi 820,21 GWh pada tahun 2030. Sementara itu, hasil prakiraan RUPTL untuk sektor publik Provinsi Banten memperkirakan peningkatan dari 632 GWh pada tahun 2021 menjadi 1028 GWh pada tahun 2030. Kesalahan rata-rata prakiraan untuk sektor publik menggunakan metode JST *backpropagation* dibandingkan dengan RUPTL adalah sebesar 8,09%.

hasil prakiraan dengan metode JST *backpropagation* untuk sektor industri Provinsi Banten menunjukkan estimasi kenaikan dari 14293,07 GWh pada tahun 2021 menjadi 17057,67 GWh pada tahun 2030. Hasil prakiraan RUPTL untuk sektor industri Provinsi Banten memperkirakan peningkatan dari 13088 GWh pada tahun 2021 menjadi 14806 GWh pada tahun 2030. Kesalahan rata-rata prakiraan untuk sektor industri menggunakan metode JST *backpropagation* dibandingkan dengan RUPTL adalah sebesar 9,80%.

#### **4.5 Prakiraan Kebutuhan Listrik Keseluruhan**

Hasil prakiraan konsumsi energi listrik keseluruhan Provinsi Banten tahun 2021 hingga 2030 dapat dilihat pada Tabel 4.16, yang merupakan hasil penjumlahan prakiraan konsumsi energi listrik dari berbagai sektor, yaitu sektor

rumah tangga, sektor bisnis, sektor publik, dan sektor industri. Tabel 4.16 menunjukkan estimasi total konsumsi energi listrik di Provinsi Banten dalam periode tersebut.

Tabel 4.16 Perbandingan Prakiraan Keseluruhan RUPTL dengan JST *Backpropagation*

Tahun	JST (GWh)	RUPTL (GWh)
2021	23981,67	22943
2022	24551,11	23720
2023	25004,44	24526
2024	25388,36	25363
2025	25836,18	26256
2026	26463,04	27201
2027	27369,49	28085
2028	28437,70	28976
2029	29295,95	29882
2030	29732,27	30888
MAPE (%)	2,45	

Berdasarkan Tabel 4.16, hasil prakiraan konsumsi energi listrik keseluruhan Provinsi Banten menggunakan metode JST *backpropagation* menunjukkan peningkatan dari 23.981,67 GWh pada tahun 2021 menjadi 29.732,27 GWh pada tahun 2030. Sementara itu, hasil prakiraan RUPTL menunjukkan peningkatan dari 22.943 GWh pada tahun 2021 menjadi 30.888 GWh pada tahun 2030. Kesalahan rata-rata prakiraan menggunakan metode JST terhadap RUPTL sebesar 2,45%.

Hal ini mengindikasikan bahwa metode JST *backpropagation* memberikan prakiraan yang cukup akurat dalam memprediksi konsumsi energi listrik keseluruhan Provinsi Banten, dengan kesalahan rata-rata sekitar 2,45%.

#### 4.6 Validasi Hasil Prakiraan dengan Nilai Aktual

Perbandingan hasil prakiraan sektoral dan keseluruhan dengan data aktual pada tahun 2021 yang datanya diambil dari Banten Dalam Angka 2022. hal ini dikarenakan pembangkitan energi listrik yang dilakukan oleh PLN didasarkan pada kebutuhan energi listrik secara umum dan bukan membangkitkan energi listrik sejumlah kebutuhan sektor tertentu. Oleh karena itu, perlu dijumlahkan untuk mengetahui seberapa baik hasil prakiraan sektoral terhadap RUPTL. Hasil validasi untuk prakiraan sektoral antara metode Jaringan Syaraf Tiruan

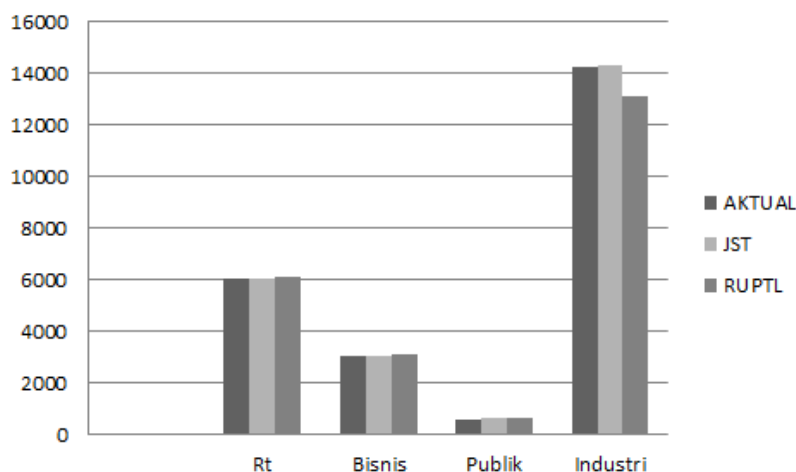
*backpropagation* dan RUPTL PT. PLN (Persero) dengan data aktual pada tahun 2021 dapat dilihat pada Tabel 4.17.

Tabel 4.17 Validasi Prakiraan Sektorial JST dan RUPTL

SEKTOR	AKTUAL (GWh)	JST (GWh)	RUPTL (GWh)	MAPE (%)	
				JST	RUPTL
Rt	6014,22	6048,90	6133	0,58	1,97
Bisnis	3009,44	3022,13	3090	0,42	2,68
Publik	573,55	617,57	632	7,67	10,19
Industri	14233,05	14293,07	13088	0,42	8,05
Rata-Rata <i>Error</i>				2,27	5,72

Berdasarkan Tabel 4.17, dapat dilihat perbandingan hasil prakiraan sektorial antara metode Jaringan Syaraf Tiruan (JST) *backpropagation* dan RUPTL PT. PLN pada tahun 2021 terhadap data aktual pada tahun yang sama. Kesalahan prakiraan sektorial dengan metode JST *backpropagation* rata-rata sebesar 2,27%, sedangkan RUPTL PT. PLN memiliki kesalahan rata-rata sebesar 5,72%.

Kedua metode tersebut masuk ke dalam kategori baik, karena kesalahan rata-ratanya berada di bawah 10%. Grafik batang pada Gambar 4.16 juga menunjukkan perbandingan visual antara prakiraan sektorial metode JST *backpropagation* dan RUPTL PT. PLN terhadap data aktual pada tahun 2021. Hasil ini mengindikasikan bahwa metode JST *backpropagation* memiliki tingkat akurasi yang lebih baik dibandingkan RUPTL PT. PLN pada tahun tersebut.



Gambar 4.16 Grafik Validasi Prakiraan Sektorial


Terlihat pada Gambar 4.16 grafik antara nilai aktual dan JST terlihat tidak jauh berbeda sedangkan dengan hasil prakiraan RUPTL terlihat jelas perbedaannya

dimana pada prakiraan sektor rumah tangga, bisnis dan publik terlihat lebih besar sedangkan pada sektor industri terlihat lebih kecil. Validasi juga dilakukan terhadap prakiraan keseluruhan antara metode Jaringan Syaraf Tiruan *backpropagation* dan RUPTL PT. PLN (Persero) dengan data aktual pada tahun 2021, hasilnya dapat dilihat pada Tabel 4.18.

Tabel 4.18 Validasi Hasil Prakiraan Keseluruhan JST dan RUPTL

Tahun	Aktual (GWh)	JST (GWh)	RUPTL (GWh)
2021	23830,26	23981,67	22943
MAPE (%)		0,64	3,72

Berdasarkan Tabel 4.18 hasil prakiraan JST *backpropagation* memiliki nilai kesalahan yang lebih rendah 0,64% dibandingkan dengan RUPTL PT PLN sebesar 3,72%. Berdasarkan kriteria MAPE hasil prakiraan keseluruhan JST *backpropagation* dan RUPTL PT PLN berada pada kategori dapat diterima dan sangat baik. Berikut merupakan grafik perbandingan prakiraan secara keseluruhan antara metode Jaringan Syaraf Tiruan *backpropagation* dan RUPTL PT. PLN (Persero) dengan data aktual pada tahun yang terlihat dalam Gambar 4.17.



Gambar 4.17 Grafik Validasi Prakiraan Keseluruhan

Berdasarkan Gambar 4.17 dapat terlihat perbedaan hasil prakiraan keseluruhan dengan metode Jaringan Syaraf Tiruan *backpropagation* terhadap data aktual pada tahun 2021 terlihat lebih besar, sedangkan hasil prakiraan dengan RUPTL terlihat lebih kecil dibandingkan dengan data aktual dan JST *backpropagation*.

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Berdasarkan hasil penelitian yang telah dilakukan, dapat diambil kesimpulan sebagai berikut:

1. Hasil penelitian menunjukkan bahwa jaringan saraf tiruan *backpropagation* dapat memberikan cara lain untuk memprediksi permintaan energi listrik di masa depan.
2. Model arsitektur dengan satu lapisan tersembunyi merupakan model arsitektur terbaik dibandingkan dengan dua atau tiga lapisan tersembunyi.
3. Arsitektur jaringan yang terbaik adalah dengan menggunakan model pelatihan ke-3 dengan tingkat kesalahan rata-rata terkecil, yaitu memiliki 6 *neuron* pada lapisan *input*, 18 *neuron* pada lapisan tersembunyi, dan 4 *neuron* pada lapisan pertama keluar.
4. Penerapan metode JST *backpropagation* menghasilkan proyeksi bahwa konsumsi energi listrik Provinsi Banten akan meningkat dari 23,981,67 GWh pada tahun 2021 menjadi 29,732,27 GWh pada tahun 2030.
5. Metode JST *backpropagation* menghasilkan tingkat kesalahan yang lebih rendah, yaitu sebesar 0,64%, dibandingkan dengan RUPTL PT PLN yang memiliki tingkat kesalahan sebesar 3,72%.

#### **5.2 SARAN**

Rekomendasi untuk pengembangan tugas akhir ini mencakup penggalan lebih banyak data serta penerapan variabel data tambahan seperti data per bulan atau per hari, yang dapat berpotensi memengaruhi pemahaman kebutuhan energi listrik. Selain itu, penelitian selanjutnya dapat mempertimbangkan pendekatan gabungan seperti menggabungkan Metode Jaringan Syaraf Tiruan dengan Fuzzy *Clustering*, Metode Jaringan Syaraf Tiruan dengan Fuzzy *Inference System*, dan Metode Jaringan Syaraf Tiruan dengan Regresi Interval.

## DAFTAR PUSTAKA

- [1] Rajagukguk. A. S. F, M. Pakiding dan M. Rumbayan, “Kajian Perencanaan Kebutuhan dan Pemenuhan Energi Listrik di Kota Manado,” *Jurnal Teknik Elektro Dan Komputer*, vol. 4, no. 3, pp. 1–11, 2015.
- [2] Fauziah. N, S. Wahyuningsih dan Y. N. Nasution, “Peramalan Menggunakan Fuzzy Time Series Chen (Studi Kasus: Curah Hujan Kota Samarinda),” *Jurnal Statistika*, vol. 4, no. 2, pp. 52–61, 2016.
- [3] Binoto. M dan Y. Kristiawan, “Peramalan Energi Listrik Yang Terjual Dan Daya Listrik Tersambung Pada Sistem Ketenaglistrikan Untuk Jangka Panjang Di Solo Menggunakan Model *Artificial Neural Network*,” *Prosiding SNATIF Ke-2*, ISBN: 978-602-1180-21-1, 2015.
- [4] Hammad. M. A, B. Jereb, B. Rosi dan D. Dragan, “*Methods and Models for Electric Load Forecasting: A Comprehensive Review*,” *Journal Logistics & Sustainable Transport*, vol. 11, no. 1, pp. 51–76, 2020.
- [5] Hasibuan. A dan W. V. Siregar, “Prakiraan Kebutuhan Energi Listrik Kota Subulussalam Sampai Tahun 2020 Menggunakan Metode Analisis Regresi,” *Jurnal Teknik Elektro*, vol. 1, no. 2, pp. 57–61, 2019.
- [6] Ali. D, M. Yohanna, M. I. Puwu dan B. M. Garkida, “*Long-Term Load Forecast Modelling Using A Fuzzy Logic Approach*,” *Journal Pacific Science Review A: Natural Science and Engineering*, 2016.
- [7] Perdana. J. A, A. Soeprijanto dan R. S. Wibowo, “Peramalan Beban Listrik Jangka Pendek Menggunakan *Optimally Pruned Extreme Learning Machine* (OPELM ) pada Sistem Kelistrikan Jawa Timur,” *Jurnal Teknik ITS*, vol. 1, no. 1, 2012.
- [8] Johan. S dan A. M. Ginting, “Determinasi Konsumsi Listrik Di Indonesia,” *Jurnal Media Ekonomi*, vol. 30, no. 1, pp. 106–117, 2022.
- [9] Effendi. Hansi, “Aplikasi Logika *Fuzzy* Untuk Peramalan Beban Listrik Jangka,” *Jurnal SAINSTEK*, vol. XII, no. 1, pp. 52–58, 2009.
- [10] Samuel. I, T. Ojewola, A. Awelewa dan P. Amaize, “*Short-Term Load Forecasting Using The Time Series And Artificial Neural Network Methods*,” *IOSR Journal of Electrical and Electronics Engineering*, vol.



- 11, pp. 72-81, 2016.
- [11] Marsiana. S, Dwijanto dan Alamsyah “Aplikasi Jaringan Syaraf Tiruan *Backpropagation* Dalam Peramalan Beban Puncak Distribusi Listrik Di Wilayah Pematang,” *UNNES Journal of Mathematics*, vol. 3, no. 1, pp. 3–8, 2014.
- [12] Hartono. H, A. Marifa Ahmad dan M. Sadikin, “*Comparison Methods Of Short Term Electrical Load Forecasting*,” *ICIEE*, 2018.
- [13] Mohammed. N. A dan A. Al-Bazi, “*An Adaptive Backpropagation Algorithm For Long-Term Electricity Load Forecasting*,” *Jurnal Neural Computing and Applications*, 2022.
- [14] Veeramsetty. V dan R. Deshmukh, “*Electric Power Load Forecasting On A 33/11 Kv Substation Using Artificial Neural Networks*,” *Research Article*, 2019.
- [15] Setiabudi. Dodi, “Sistem Informasi Peramalan Beban Listrik Jangka Panjang Di Kabupaten Jember Menggunakan *JST Backpropagation*,” *Jurnal SMARTICS*, vol. 1, no. 1, pp. 1–5, 2015.
- [16] Lestari. T, A. Kudus dan S. Darwis, “Proses Pengelompokan Syaraf Menggunakan Jaringan Syaraf Tiruan (JST) dengan *Algoritme Self-Organizing Maps (SOM)*,” *Prosiding Statistika*, vol. 3, no. 2, 2017.
- [17] Dwiantoro. Bagus, “Berdasarkan Data Historis Menggunakan Metode *Generalized Autoregressive Conditional Heteroskedasticity (Garc)* Metode *Generalized Autoregressive Conditional*,” *Tugas Akhir*, Depok, 2012.
- [18] Almazrouee. A. I, A. M. Almeshal, A. S. Almutairi, M. R. Alenezi, S. N. Alhajeri dan F. M. Alshammari, “*Forecasting Of Electrical Generation Using Prophet And Multiple Seasonality Of Holt–Winters Models: A Case Study Of Kuwait*,” *Applied Science Article*, 2020.
- [19] Damara. D. B. O dan I. N. M. Yasa, “Analisis Faktor-Faktor Yang Mempengaruhi Permintaan Energi Listrik Di Provinsi Bali,” *Jurnal Ekonomi Pembangunan Universitas Udayana*, vol. 8, no. 1, pp. 211–238, 2019.
- [20] Sesa. S, H. Suyono dan R. Nur Hasanah, “Peramalan Beban Listrik Jangka Menengah Menggunakan Jaringan Syaraf Tiruan Pada Sistem Kelistrikan

- Kota Ambon,” *Elektronik Jurnal Arus Elektro Indonesia*, pp. 19–25, 2014.
- [21] Anonim, “Rencana Usaha Penyediaan Tenaga Listrik PT. PLN (PERSERO) 2019-2028,” PT. Perusahaan Listrik Negara, Jakarta, 2019.
- [22] Faysal. M, M. J. Islam, M. M. Murad, M. I. Islam dan M. R. Amin, “*Electrical Load Forecasting Using Fuzzy System*,” *Journal of Computer and Communication*, 2019.
- [23] Setyowati. D dan S. Sunardiyo, “Prakiraan Kebutuhan Energi Listrik Dengan Jaringan Syaraf Tiruan (*Artificial Neural Network*) Metode *Backpropagation* Tahun 2020-2025,” *Journal EECCIS*, 2020.
- [24] Pulungan. J dan R. Novita, “Prediksi Kebutuhan Energi Listrik Menggunakan Metode Jaringan Syaraf Tiruan,” *Jurnal BITS*, vol. 4, no. 1, pp. 294–302, 2022.
- [25] Fadilah. M. N, A. Yusuf dan N. Huda, “Prediksi Beban Listrik Di Kota Banjarbaru Menggunakan Jaringan Syaraf Tiruan *Backpropagation*,” *Jurnal Matematika Murni Dan Terapan Epsilon*, vol. 14, no. 2, p. 81, 2021.
- [26] Purwoharjono, “Penerapan Metode Jaringan Syaraf Tiruan Untuk Prediksi Kebutuhan Beban Listrik,” *Alinier Jurnal*, vol. 2, no. 1, pp. 36–42, 2021.

## **LAMPIRAN**

## Lampiran A Data Awal Penelitian

Tabel A.1 Energi Terjual PLN Menurut Jenis Tarif di Provinsi Banten (GWh)

2011 s.d. 2020

Tahun	Rt	Bisnis	Publik	Industri
2011	3681	1931	404.02	11471
2012	4050	1755	410.52	12353
2013	3640	2299	419.08	12920
2014	3892	2243	438.00	12569
2015	4370	2147	440.65	11645
2016	4543	2344	469.10	12811
2017	4599	2521	500.63	13623
2018	4825	2736	543.67	14803
2019	5231	2930	587.46	14601
2020	5794	2890	556.62	13027

Tabel A.2 Jumlah Pelanggan PLN Menurut Klasifikasi Tarif di Provinsi Banten

(Ribu) 2011 s.d. 2020

Tahun	Rt	Bisnis	Publik	Industri
2011	1659	74	39	5.2
2012	1795	84	42	5.3
2013	1992	93	45	5.6
2014	2178	101	47	5.7
2015	2399	111	52	6
2016	2548	132	56	6.1
2017	2712	152	62	6.3
2018	2894	174	62	6.3
2019	3078	175	76	6.7
2020	3224	191	76	6.8

Tabel A.3 Jumlah Penduduk dan PDRB Provinsi Banten 2011 s.d. 2020

Tahun	PDRB	Penduduk
2011	290545838.9	11005518
2012	310385592.4	11248947
2013	331099105.5	11452491
2014	349584667.8	11704877
2015	369209288.1	11955243
2016	389543932.3	12203148
2017	412639618.3	12448160
2018	436581428.1	12689736
2019	459828497.4	12927316
2020	445672956.7	11904562

## Lampiran B Listing Code

Lampiran *listing code* metode jaringan syaraf tiruan untuk mendapatkan nilai prakiraan kebutuhan energi listrik Provinsi Banten di MATLAB.

### B1. Training Code Model 1

```
% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O5:X14';

Data = xlsread(filename, sheet, xlRange);
data_latih = Data(:,1:6)';
target_latih = Data(:,7:10)';
[m,n] = size(data_latih);

% Pembuatan neural networks feedforward
net = newff(minmax(data_latih), [6 4], {'tansig', 'purelin'},
'trainlm');

net.performFcn = 'mse';
net.trainParam.goal = 0.01;
net.trainParam.show = 25;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.1;
net.trainParam.lr = 0.001;

% Proses training
[net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);

% Hasil setelah pelatihan
bobot_hidden = net_keluaran.IW{1,1};
bobot_keluaran = net_keluaran.LW{2,1};
bias_hiddan = net_keluaran.b{1,1};
bias_keluaran = net_keluaran.b{2,1};
jumlah_iterasi = tr.num_epochs;
nilai_keluaran = Y;
nilai_error = E;
error_MSE = (1/n)*sum(nilai_error.^2);

save('C:\Users\Lenovo\Documents\fix\pelatihan_6.mat')

% Hasil pelatihan
hasil_latih = sim(net_keluaran,data_latih);
% Performansi hasil pelatihan
target_latih_asli = target_latih;

figure,
plotregression(target_latih_asli,hasil_latih,'Regression')
figure,
plotperform(tr)
```

### Testing Code

```
%memanggil bobot dan bias hasil pelatihan
```

```

load('C:\Users\Lenovo\Documents\fix\pelatihan_6.mat')

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O21:T30';

Data = xlsread(filename, sheet, xlRange);
data_uji = Data(:,1:6)';
[m,n] = size(data_uji);

% Hasil PREDIKSI
hasil_uji = sim(net_keluaran,data_uji);

```

## **B2. Training Code Model 2**

```

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O5:X14';

Data = xlsread(filename, sheet, xlRange);
data_latih = Data(:,1:6)';
target_latih = Data(:,7:10)';
[m,n] = size(data_latih);

% Pembuatan neural networks feedforward backpropagation
net = newff(minmax(data_latih), [12 4], {'tansig', 'purelin'},
'trainlm');

net.performFcn = 'mse';
net.trainParam.goal = 0.01;
net.trainParam.show = 25;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.1;
net.trainParam.lr = 0.001;

% Proses training
[net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);

% Hasil setelah pelatihan
bobot_hidden = net_keluaran.IW{1,1};
bobot_keluaran = net_keluaran.LW{2,1};
bias_hiddan = net_keluaran.b{1,1};
bias_keluaran = net_keluaran.b{2,1};
jumlah_iterasi = tr.num_epochs;
nilai_keluaran = Y;
nilai_error = E;
error_MSE = (1/n)*sum(nilai_error.^2);

save('C:\Users\Lenovo\Documents\fix\pelatihan_12.mat')

% Hasil pelatihan
hasil_latih = sim(net_keluaran,data_latih);
% Performansi hasil pelatihan
target_latih_asli = target_latih;

```

```

figure,
plotregression(target_latih_asli,hasil_latih,'Regression')
figure,
plotperform(tr)

```

### *Testing Code*

```

%memanggil bobot dan bias hasil pelatihan
load('C:\Users\Lenovo\Documents\fix\pelatihan_12.mat')

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O21:T30';

Data = xlsread(filename, sheet, xlRange);
data_uji = Data(:,1:6)';
[m,n] = size(data_uji);

% Hasil PREDIKSI
hasil_uji = sim(net_keluaran,data_uji);

```

### **B3. Training Code Model 3**

```

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O5:X14';

Data = xlsread(filename, sheet, xlRange);
data_latih = Data(:,1:6)';
target_latih = Data(:,7:10)';
[m,n] = size(data_latih);

% Pembuatan neural networks feedforward backpropagation
net = newff(minmax(data_latih), [18 4], {'tansig', 'purelin'},
'trainlm');

net.performFcn = 'mse';
net.trainParam.goal = 0.01;
net.trainParam.show = 25;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.1;
net.trainParam.lr = 0.001;

% Proses training
[net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);

% Hasil setelah pelatihan
bobot_hidden = net_keluaran.IW{1,1};
bobot_keluaran = net_keluaran.LW{2,1};
bias_hiddan = net_keluaran.b{1,1};
bias_keluaran = net_keluaran.b{2,1};
jumlah_iterasi = tr.num_epochs;
nilai_keluaran = Y;
nilai_error = E;

```

```

error_MSE = (1/n)*sum(nilai_error.^2);

save('C:\Users\Lenovo\Documents\fix\pelatihan_18.mat')

% Hasil pelatihan
hasil_latih = sim(net_keluaran,data_latih);
% Performansi hasil pelatihan
target_latih_asli = target_latih;

figure,
plotregression(target_latih_asli,hasil_latih,'Regression')
figure,
plotperform(tr)

```

### ***Testing Code***

```

%memanggil bobot dan bias hasil pelatihan
load('C:\Users\Lenovo\Documents\fix\pelatihan_18.mat')

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O21:T30';

Data = xlsread(filename, sheet, xlRange);
data_uji = Data(:,1:6)';
[m,n] = size(data_uji);

% Hasil PREDIKSI
hasil_uji = sim(net_keluaran,data_uji);

```

### ***B4. Training Code Model 4***

```

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O5:X14';

Data = xlsread(filename, sheet, xlRange);
data_latih = Data(:,1:6)';
target_latih = Data(:,7:10)';
[m,n] = size(data_latih);

% Pembuatan neural networks feedforward backpropagation
net = newff(minmax(data_latih), [24 4], {'tansig', 'purelin'},
'trainlm');

net.performFcn = 'mse';
net.trainParam.goal = 0.01;
net.trainParam.show = 25;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.1;
net.trainParam.lr = 0.001;

% Proses training

```



```

[net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);

% Hasil setelah pelatihan
bobot_hidden = net_keluaran.IW{1,1};
bobot_keluaran = net_keluaran.LW{2,1};
bias_hidden = net_keluaran.b{1,1};
bias_keluaran = net_keluaran.b{2,1};
jumlah_iterasi = tr.num_epochs;
nilai_keluaran = Y;
nilai_error = E;
error_MSE = (1/n)*sum(nilai_error.^2);

save('C:\Users\Lenovo\Documents\fix\pelatihan_24.mat')

% Hasil pelatihan
hasil_latih = sim(net_keluaran,data_latih);
% Performansi hasil pelatihan
target_latih_asli = target_latih;

figure,
plotregression(target_latih_asli,hasil_latih,'Regression')
figure,
plotperform(tr)

```

### *Testing Code*

```

%memanggil bobot dan bias hasil pelatiha
load('C:\Users\Lenovo\Documents\fix\pelatihan_24.mat')

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O21:T30';

Data = xlsread(filename, sheet, xlRange);
data_uji = Data(:,1:6)';
[m,n] = size(data_uji);

% Hasil PREDIKSI
hasil_uji = sim(net_keluaran,data_uji);

```

### **B5. Training Code Model 5**

```

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O5:X14';

Data = xlsread(filename, sheet, xlRange);
data_latih = Data(:,1:6)';
target_latih = Data(:,7:10)';
[m,n] = size(data_latih);

% Pembuatan neural networks feedforward backpropagation
net = newff(minmax(data_latih), [30 4], {'tansig', 'purelin'},
'trainlm');

```

```

net.performFcn = 'mse';
net.trainParam.goal = 0.01;
net.trainParam.show = 25;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.1;
net.trainParam.lr = 0.001;

% Proses training
[net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);

% Hasil setelah pelatihan
bobot_hidden = net_keluaran.IW{1,1};
bobot_keluaran = net_keluaran.LW{2,1};
bias_hiddan = net_keluaran.b{1,1};
bias_keluaran = net_keluaran.b{2,1};
jumlah_iterasi = tr.num_epochs;
nilai_keluaran = Y;
nilai_error = E;
error_MSE = (1/n)*sum(nilai_error.^2);

save('C:\Users\Lenovo\Documents\fix\pelatihan_30.mat')

% Hasil pelatihan
hasil_latih = sim(net_keluaran,data_latih);
% Performansi hasil pelatihan
target_latih_asli = target_latih;

figure,
plotregression(target_latih_asli,hasil_latih,'Regression')
figure,
plotperform(tr)

```

### *Testing Code*

```

%memanggil bobot dan bias hasil pelatiha
load('C:\Users\Lenovo\Documents\fix\pelatihan_30.mat')

% Membaca data dari excel
filename = 'data_fix.xlsx';
sheet = 1;
xlRange = 'O21:T30';

Data = xlsread(filename, sheet, xlRange);
data_uji = Data(:,1:6)';
[m,n] = size(data_uji);

% Hasil PREDIKSI
hasil_uji = sim(net_keluaran,data_uji);

```