

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Penelitian Terdahulu

Pada penelitian ini, peneliti melakukan penelusuran literasi untuk mencari rujukan terkait kasus dan permasalahan yang serupa dengan penelitian ini, yaitu:

Sebuah penelitian yang dilakukan oleh Aziz [2] menggunakan teknik jaringan syaraf tiruan (JST) dengan algoritma *backpropagation* untuk melakukan peramalan kebutuhan energi listrik jangka menengah di kabupaten Rokan Hulu. Hasil penelitian menunjukkan bahwa model JST yang dioptimasi dengan 30 lapisan tersembunyi, 100 *epoch*, dan *learning rate* sebesar 0,01 menghasilkan tingkat kesalahan sekitar 23% dengan *mean squared error* (MSE) sebesar 0,00003323. Studi ini menggarisbawahi pentingnya memilih parameter yang tepat dalam melatih model ANN untuk mencapai akurasi yang lebih tinggi.

Pada penelitian lain Tiana [3] melakukan untuk memprediksi penggunaan listrik di wilayah Balikpapan Utara dengan menggunakan pendekatan *Extreme Learning Machine* (ELM). Tujuan penelitian ini adalah untuk memprediksi konsumsi daya dan mencapai pasokan daya yang optimal tanpa gangguan. Data yang dipakai adalah data historis PLN Balikpapan untuk kategori pelanggan “Rumah Tangga Kecil dan Menengah” pada tahun 2011 hingga tahun 2019. Temuan penelitian menunjukkan *mean squared error* (MSE) yang diperoleh pada kecepatan latihan eksperimen 9,72 detik adalah sebesar 0,03313. Menampilkan 6 lapisan tersembunyi. Akurasi prediksi menggunakan kriteria MAPE dengan nilai 7,79%, memperlihatkan bahwa model prediksi yang dibangun sangat baik (kriteria

MAPE < 10% = sangat baik).

Akbar [4] melakukan penelitian tentang analisis komparatif keakuratan prediksi konsumsi daya menggunakan *Extreme Learning Machine* (ELM) dan algoritma *Backpropagation*. Penelitian ini memiliki tujuan menganalisis keakuratan hasil prediksi konsumsi daya menggunakan kedua algoritma tersebut, dengan sasaran data konsumsi daya bulanan pada tahun 2016 hingga 2022. Penelitian menunjukkan bahwa algoritma *backpropagation* menghasilkan MAPE . Persentase kesalahannya sebesar 2,27% lebih rendah dibandingkan dengan algoritma ELM yang memiliki nilai MAPE sebesar 4,67%. Hal ini menunjukkan bahwa algoritma *backpropagation* lebih akurat dalam memprediksi konsumsi daya.

Deltania dan Primadiyono [5] melakukan penelitian untuk meramalkan kebutuhan listrik di wilayah Jawa Tengah dengan memakai pendekatan *Backpropagation neural network* (JST) dan ekstrapolasi linier. Kajian tersebut bertujuan untuk meramalkan permintaan energi listrik pada tahun 2022 hingga 2027 dengan mempertimbangkan faktor-faktor seperti pertumbuhan penduduk, jumlah pelanggan PLN, dan PDRB. Berdasarkan hasil penelitian, model JST dengan arsitektur fungsi pembelajaran LEARNGDM dan fungsi pembelajaran TRAINDX dengan 30 *neuron* menghasilkan nilai MAPE (*Mean Absolute Percentage Error*) sebesar 5,4% lebih tinggi dibandingkan dengan metode ekstrapolasi linier yang memiliki tingkat kesalahan nilai MAPE sebesar 10,7%. Studi ini menyoroti pentingnya penggunaan teknik jaringan saraf propagasi mundur untuk memperkirakan permintaan listrik karena memberikan hasil yang lebih akurat dan andal dalam perencanaan energi masa depan.

Berdasarkan penelitian sebelumnya mengenai prediksi menggunakan ANN, penggunaan jaringan syaraf tiruan (JST) dengan algoritma *backpropagation* merupakan pendekatan yang efektif untuk memprediksi konsumsi energi listrik khususnya pada bidang kesehatan. Dengan pertimbangan tersebut penulis melaksanakan penelitian ini dengan judul **“Prediksi Konsumsi Energi Listrik di Rumah Sakit Mata Undaan Surabaya Menggunakan Jaringan Syaraf Tiruan”**. Penelitian ini memakai data konsumsi listrik tahun 2022 hingga 2024 dan data konsumsi air bersih tahun 2022 hingga 2024 sebagai representasi data populasi pasien untuk memprediksi konsumsi listrik tahun depan. Dan sebagai data sekunder, digunakan data suhu dan kelembaban udara yang diperoleh dari tahun 2022 hingga 2024 berasal dari data BMKG. Penelitian ini bertujuan untuk memberikan kontribusi terhadap manajemen energi listrik Rumah Sakit Mata Undaan Surabaya dengan memberikan estimasi akurat pola konsumsi energi listrik pada tahun 2022 hingga 2024. Hasil penelitian ini diharapkan dapat membantu manajemen rumah sakit dalam perencanaan dan pengelolaan kebutuhan listrik, serta mendukung pengambilan keputusan yang tepat ketika meningkatkan kapasitas listrik sesuai kebutuhan operasional.

## **2.2 Teori Dasar**

### **2.2.1 Definisi Listrik**

Listrik merupakan bentuk energi yang dihasilkan oleh pergerakan muatan listrik, terutama elektron dalam suatu konduktor, dan dapat dibedakan menjadi listrik statis yang merupakan akumulasi muatan pada permukaan benda, dan listrik dinamis yaitu aliran muatan listrik yang diukur dalam ampere (A). Listrik memiliki

sifat-sifat penting seperti tegangan (perbedaan potensial diukur dalam *volt*), arus (aliran muatan), resistansi (hambatan terhadap aliran arus diukur dalam *ohm*), dan daya (kecepatan penggunaan energi diukur dalam *watt*). Sumber energi listrik bisa juga berasal dari sumber terbarukan seperti tenaga surya dan angin, serta sumber fosil dan energi nuklir.

Dalam sektor kesehatan, listrik sangat penting untuk operasional rumah sakit, menyediakan daya untuk peralatan medis, penerangan, dan sistem utilitas lainnya, serta memastikan keamanan dan efisiensi energi dalam pengelolaan konsumsi listrik. Pemahaman yang mendalam tentang listrik dan cara kerjanya sangat penting untuk pengelolaan yang efisien, terutama dalam konteks rumah sakit yang memerlukan pasokan energi yang stabil dan dapat diandalkan [6].

### **2.2.2 Pengertian Daya Listrik**

Daya adalah besaran energi yang digunakan atau diproduksi dalam sebuah sistem kelistrikan. Sumber energi seperti tegangan, menghasilkan energi listrik, dan beban yang terhubung menyerap energi ini. Dengan kata lain, daya mencerminkan besaran jumlah konsumsi energi dalam suatu sistem rangkaian listrik. Berdasarkan konsep usaha, daya dapat didefinisikan sebagai jumlah usaha yang dilakukan per satuan waktu untuk memindahkan suatu muatan, atau jumlah energi listrik yang dikonsumsi setiap detik. [7] . Dari definisi ini, rumus daya listrik dapat dijelaskan pada rumus sebagai berikut:

$$P = \frac{E}{t} \quad (2.1)$$

Di mana:

$P$  = Daya Listrik (*watt*)

$E$  = Energi (*Joule*)

$t$  = Waktu

Daya listrik dibagi menjadi tiga jenis, yaitu:

1. **Daya Nyata ( $P$ ):** adalah daya yang benar-benar dikonsumsi oleh beban listrik untuk melakukan kerja nyata, seperti memutar motor, menghasilkan panas, atau menyalakan lampu. Daya nyata diukur dalam satuan *watt* (W).

Rumus daya nyata untuk sistem 1 fasa adalah:

$$P = V \cdot I \cdot \cos \theta$$

Rumus daya nyata untuk sistem 3 fasa adalah:

$$P = \sqrt{3} \cdot V_L \cdot I_L \cdot \cos \theta \quad (2.2)$$

Keterangan:

$P$ : Daya nyata (*Watt*, W)

$V$ : Tegangan RMS (*Volt*, V)

$I$ : Arus RMS (*Ampere*, A).

$\cos \theta$ : Faktor daya (cosinus dari sudut fasa antara tegangan dan arus)



2. **Daya Semu (S)**: Daya listrik yang mengalir melalui penghantar transmisi atau distribusi. Rumusnya adalah  $S = V \times I$  untuk satu fasa, dan untuk tiga fasa,

$$S = \sqrt{3} \times V \times I \quad (2.3)$$

Di mana:

$$S = \text{Daya semu (VA)}$$

3. **Daya Reaktif (Q)**: Selisih antara daya semu yang masuk ke penghantar dan daya nyata pada penghantar. Rumusnya adalah

$$Q = V \times I \times \sin \phi \quad (2.4)$$

untuk satu fasa, dan untuk tiga fasa sebagai berikut:

$$Q = \sqrt{3} \times V \times I \times \sin \phi \quad (2.5)$$

Daya reaktif (Q) berhubungan dengan daya nyata (P) dan daya semu (S) dalam segitiga daya.

### 2.2.3 Kebutuhan Energi di Rumah Sakit

Kebutuhan energi di rumah sakit merupakan satu aspek yang sangat penting dan kompleks, karena rumah sakit berfungsi sebagai fasilitas kesehatan yang menyediakan berbagai layanan medis dan perawatan kepada pasien. Kebutuhan energi ini dapat bervariasi secara signifikan berdasarkan beberapa faktor utama:

- a. Jumlah Pasien: Total banyaknya pasien di rumah sakit dan secara langsung mempengaruhi konsumsi energi. Semakin banyak pasien yang dirawat, semakin banyak peralatan medis yang digunakan, seperti monitor pasien,

ventilator, dan mesin pencitraan. Selain itu, kebutuhan untuk penerangan, pemanasan, dan pendinginan juga meningkat seiring dengan bertambahnya jumlah pasien.

- b. Jenis layanan yang diberikan: Berbagai jenis layanan medis memerlukan tingkat konsumsi energi yang berbeda. Misalnya, ruang operasi dan unit perawatan intensif (*ICU*) biasanya memiliki kebutuhan energi yang lebih tinggi dibandingkan dengan ruang rawat inap biasa, karena peralatan medis yang lebih canggih dan kebutuhan untuk menjaga lingkungan yang steril dan nyaman. Layanan diagnostik seperti MRI dan *CT scan* juga memerlukan energi yang signifikan untuk beroperasi.
- c. Waktu Operasional: Operasional Rumah sakit 24 jam dalam satu hari, 7 hari seminggu, yang berarti bahwa konsumsi energi tidak hanya terjadi pada jam-jam sibuk, tetapi juga pada malam hari dan saat akhir pekan. Pola konsumsi energi dapat bervariasi tergantung pada waktu, dengan puncak konsumsi sering terjadi pada jam-jam tertentu ketika lebih banyak prosedur medis dilakukan atau ketika lebih banyak pasien dirawat.
- d. Musim dan Cuaca: Faktor eksternal seperti musim dan cuaca juga mempengaruhi kebutuhan energi. Misalnya, pada musim kemarau, penggunaan pendingin udara meningkat, sedangkan pada musim hujan, pemanas ruangan menjadi lebih aktif. Perubahan suhu eksternal dapat mempengaruhi kenyamanan pasien dan staf, sehingga mempengaruhi pengaturan suhu di dalam rumah sakit.
- e. Efisiensi Energi dan Teknologi: Penggunaan teknologi yang efisien dan

praktik manajemen energi yang baik dapat membantu mengurangi konsumsi energi. Misalnya, penggunaan lampu LED, peralatan medis yang hemat energi, dan sistem manajemen energi yang canggih dapat membantu rumah sakit mengelola konsumsi energi dengan lebih baik.

- f. Regulasi dan Kebijakan: Kebijakan pemerintah dan regulasi terkait efisiensi energi dan pengurangan emisi juga dapat mempengaruhi cara rumah sakit mengelola konsumsi energi. Rumah sakit mungkin perlu mematuhi standar tertentu yang ditetapkan pemerintah atau lembaga kesehatan, yang dapat mempengaruhi investasi dalam teknologi energi terbarukan atau sistem efisiensi energi [9],[10].

Dengan mempertimbangkan semua faktor ini, pemahaman yang baik tentang pola konsumsi listrik di rumah sakit sangat penting untuk pengelolaan yang efisien. Analisis data historis dan penggunaan model prediktif seperti Jaringan Syaraf Tiruan (JST), Ini membantu manajemen rumah sakit merencanakan kebutuhan energi, mengidentifikasi pola penggunaan, dan membuat keputusan pengelolaan sumber daya energi yang lebih efisien. Hal tersebut tidak hanya dapat mengurangi biaya operasi tetapi juga meningkatkan kualitas layanan medis bagi pasien.

### **2.3 Prediksi Energi Listrik**

Prediksi atau dengan kata lain peramalan adalah proses untuk memperkirakan suatu kejadian atau kondisi di masa yang akan datang [18]. Dalam konteks energi listrik, prediksi merujuk pada upaya untuk memperkirakan kebutuhan energi listrik untuk penggunaan di masa mendatang dengan



memanfaatkan data historis serta penerapan ilmu statistik dan metode perhitungan yang relevan. Prediksi ini dapat dilakukan dalam berbagai tahapan waktu, seperti hitungan tahun, bulan, atau minggu. Tujuan dari hasil prediksi ini adalah untuk merencanakan kebutuhan energi listrik dan menambah kemampuan/kapasitas pembangkit jika diperlukan di masa depan, sehingga dapat meminimalkan risiko kekurangan daya yang diperlukan untuk operasional.

Prediksi beban listrik dapat dikelompokkan berdasarkan jangka waktu sebagai berikut:

#### A. Prediksi Beban Jangka Panjang

Peramalan jangka panjang bertujuan untuk memprediksi keperluan energi listrik dalam 1 hingga 10 tahun ke depan. Metode ini memanfaatkan data historis konsumsi daya dan memilih variabel pendukung yang mempunyai dampak signifikan terhadap konsumsi daya, seperti: pertumbuhan ekonomi, penambahan penduduk, dan kapasitas daya terpasang. Peramalan jangka panjang biasanya diterapkan untuk memprediksi kebutuhan listrik dalam skala besar, seperti negara, negara bagian, distrik, dan pusat kota dengan permintaan listrik yang tinggi. Hasil perkiraan digunakan untuk merencanakan respons permintaan dan perluasan pasokan listrik.

#### B. Prediksi Beban Jangka Menengah

Peramalan jangka menengah dipergunakan untuk memprediksi penggunaan listrik dalam periode bulan hingga satu tahun. Pendekatan ini banyak diterapkan untuk memprediksi kebutuhan listrik di suatu wilayah pedesaan dan kota besar/pusat. Peramalan jangka menengah adalah penting dalam

perencanaan pengaturan dan pembagian beban pada jaringan antar gardu induk, perluasan jaringan distribusi, dan perencanaan operasional pembangkit.

### C. Prediksi Beban Jangka Pendek

Peramalan jangka pendek ditujukan untuk memperkirakan konsumsi daya dalam jangka waktu beberapa jam hingga satu minggu. Prakiraan jangka pendek berfokus pada wilayah yang lebih kecil, seperti pusat kota atau wilayah pembangkit listrik tertentu. Tujuan dari peramalan beban daya jangka pendek adalah untuk menentukan jumlah energi listrik yang akan disediakan oleh generator untuk memenuhi kebutuhan konsumen dalam beberapa hari mendatang, dan untuk memastikan distribusi energi listrik merata di setiap wilayah. Meminimalkan risiko pemadaman listrik. Data yang digunakan mencakup data historis konsumsi listrik per jam, serta variabel lain seperti data cuaca, beban puncak, dan catatan pemadaman [2].

#### 2.3.1 Metode Prediksi

Dalam proses prediksi energi, pemilihan metode yang tepat sangatlah penting dan bergantung pada jenis data yang tersedia dan tujuan analisis yang ingin dicapai. Metode yang dipilih akan memengaruhi hasil akhir, sehingga pendekatan analisis terhadap data harus dilakukan secara sistematis dan pragmatis, dengan tujuan untuk meningkatkan tingkat keyakinan dan akurasi hasil prediksi. Terdapat beberapa metode yang umumnya digunakan untuk meramalkan permintaan energi listrik, dapat dibagi menjadi dua kategori menurut sifatnya, yaitu:

#### A. Metode Kualitatif

Model kualitatif menggunakan data yang tidak berbentuk angka dan didasarkan pada pemikiran, pendapat, pengetahuan, dan pengalaman intuitif penulis, sedangkan model prediktif memperhitungkan faktor subjektif.

Metode kualitatif terdapat dua jenis:

- 1 Metode Eksploratoris: Dimulai dengan menganalisis data masa lalu dan masa kini sebagai titik awal dan melanjutkan secara heuristik, mempertimbangkan semua kemungkinan.
- 2 Metode Normatif: Dimulai dengan menentukan tujuan masa depan dan lakukan evaluasi apakah tujuan tersebut dapat dicapai mengingat keterbatasan, sumber daya, dan teknologi yang tersedia.

#### B. Metode Kuantitatif

Metode kuantitatif mempergunakan data dalam bentuk numerik serta menggunakan pola matematika dan statistik yang dipakai untuk menghitung variabel data. Peramalan kuantitatif mengasumsikan bahwa pola yang terjadi di masa lalu akan terjadi lagi di masa depan karena adanya hubungan erat antara variabel-variabel tersebut. Metode kuantitatif dibagi menjadi dua kategori:

1. Metode deret periodik (*time series*) : Metode ini didasarkan pada nilai variabel masa lalu dan kesalahan yang terjadi di masa lalu. Sasarannya adalah menganalisis data yang ada untuk membuat prediksi dan mengekstrapolasi ke masa depan. Teknik ini menggunakan data deret waktu sebagai dasar untuk memprediksi data aktual masa mendatang.

Teknik prediksi yang termasuk dalam kategori ini meliputi teknik smoothing, teknik *Box Jenkins*, teknik estimasi regresi, dan teknik jaringan saraf tiruan *backpropagation* (JSTBP).

2. Metode Kausal: Metode ini mengasumsikan bahwa variabel prediktor mempunyai hubungan sebab akibat dengan satu atau lebih variabel bebas. Contoh teknik peramalan yang menggunakan pendekatan kausal antara lain metode korelasi regresi dan metode ekonometrik. [2].

Penelitian ini menggunakan metode Jaringan Syaraf Tiruan (JST) dengan algoritma *backpropagation*, yang dilatih menggunakan data historis dari tahun 2022 hingga 2024, untuk memprediksi konsumsi energi listrik untuk periode 2025 hingga 2027.

Model ini mengoptimalkan penggunaan fungsi aktivasi *sigmoid* di *hidden layer* dan menggunakan normalisasi data untuk input agar performa model dapat meningkat.

#### **2.4 Jaringan Syaraf Tiruan**

Jaringan Syaraf Tiruan (JST) adalah kecerdasan buatan dan biasa juga disebut *Artificial Intelligence* (AI). *Artificial Neural Network* (ANN) adalah bagian dari JST yang dapat digunakan untuk perkiraan beban jangka pendek. Karakteristik ANN meniru cara kerja otak manusia, apabila dilatih terlebih dahulu diharapkan menjadi akurat ketika proses pengujian. Kesesuaian model Jaringan Syaraf Tiruan semakin baik jika MSE mendekati 0 dan R mendekati 1 [18].

Jaringan Saraf Tiruan (JST) terdiri atas unit pemroses yaitu *neuron* yang saling berhubungan dalam struktur berlapis yang memiliki berbagai aplikasi,

termasuk pengenalan gambar, pengolahan suara, serta prediksi dan klasifikasi data, menjadikannya alat yang sangat berharga dalam pengembangan kecerdasan buatan dan aplikasi komputasi modern.

Pada dasarnya, Jaringan Saraf Tiruan (JST) terdiri atas tiga lapisan, yaitu lapisan *input*, lapisan pemrosesan, dan lapisan *output*. Lapisan *input* berisi variabel data masukan, lapisan pemrosesan bertanggung jawab untuk langkah-langkah pengenalan objek, dan lapisan *output* menyajikan hasil dari pengenalan objek tersebut [4].


JST terbentuk oleh tiga elemen utama, yaitu:

- 1) Bentuk hubungan antar *neuron* yang dikenal sebagai arsitektur jaringan
- 2) Metode untuk menentukan bobot penghubung yang disebut metode pelatihan atau algoritma pembelajaran, dan
- 3) Fungsi aktivasi yang digunakan.

#### **2.4.1 Arsitektur JST**

Seperti halnya otak manusia, Jaringan Saraf Tiruan (JST) terdiri atas sejumlah *neuron* yang terorganisir didalam lapisan-lapisan dan mempunyai hubungan satu sama lain. *Neuron* adalah bagian dasar dalam pengolahan jaringan syaraf tiruan yang karakteristiknya menirukan cara kerja otak manusia. *Neuron* yang saling berhubungan membentuk asitektur *neural network*. *Neuron* dalam jaringan syaraf tiruan biasanya digambarkan sebagai sebuah *node* atau simpul dalam jaringan. Setiap *neuron* menerima *input*, memproses informasi, dan menghasilkan *output*. *Neuron* ini terhubung satu sama lain melalui sinapsis, yang dalam JST diwakili oleh bobot (*weights*).





Gambar 2. 1 Bentuk dasar Neuron

Gambar 2.1 menunjukkan bentuk dasar *neuron*, terbentuk atas beberapa bagian utama:

Masukan (*Input*) : *Neuron* menerima sinyal dari *neuron* lain atau dari data *input*. *Input* ini bisa berupa angka atau vektor yang merepresentasikan fitur dari data.

Bobot (*Weights*) : Setiap input yang diterima *neuron* memiliki bobot yang mengatur seberapa besar pengaruh input tersebut terhadap *output neuron*. Bobot ini adalah parameter yang dioptimalkan selama proses pelatihan.

Fungsi Aktivasi (*Activation Function*) : Setelah menjumlahkan semua *input* yang dikalikan dengan bobotnya, *neuron* menerapkan fungsi aktivasi untuk menentukan *output*. Fungsi aktivasi ini bisa berupa fungsi linear, *sigmoid*, ReLU (*Rectified Linear Unit*), atau fungsi lainnya. Fungsi ini membantu *neuron* untuk memperkenalkan non-linearitas ke dalam model.

Keluaran (*Output*):Setelah fungsi aktivasi diterapkan, *neuron* menghasilkan *output* yang dapat diteruskan ke *neuron* lain dalam jaringan atau menjadi hasil akhir dari model.

Bias : Bias adalah nilai tambahan yang ditambahkan ke hasil penjumlahan *input* yang telah dibobot. Bias membantu model untuk lebih fleksibel dan dapat menyesuaikan diri dengan data yang lebih baik.

Berdasar pada penjelasan diatas dapat disimpulkan bahwa, *Neuron* dalam jaringan syaraf tiruan dapat diartikan sebagai model yang menyederhanakan cara kerja *neuron* biologis. Dengan memahami bagian-bagian dan proses kerja *neuron*, kita dapat lebih baik memahami bagaimana jaringan syaraf tiruan berfungsi dalam memproses informasi dan belajar dari data. *Neuron-neuron* ini saling terhubung membentuk jaringan yang kompleks, yang memungkinkan model untuk belajar dan membuat prediksi berdasarkan data yang diberikan.

Dalam jaringan saraf, neuron dikelompokkan menjadi beberapa lapisan *neuron*. Umumnya *neuron-neuron* pada suatu lapisan terkoneksi dengan lapisan sebelumnya atau berikutnya, terkecuali lapisan *input* dan *output*. Informasi yang dikirimkan ke jaringan saraf diteruskan dari satu lapisan menuju lapisan lainnya, dari lapisan masukan melalui lapisan tersembunyi ke lapisan keluaran. Algoritma pembelajaran menentukan arah penyediaan informasi [11].

Pengaturan bobot yang digunakan dalam *input* dapat diaplikasikan melalui dua metode,yaitu :

a. Pelatihan Terbimbing (*supervised training*)

Yaitu pola penyesuaian bobot untuk mencapai nilai kesalahan minimum pada hasil perkiraan dengan nilai sesungguhnya. Pelatihan terbimbing memerlukan sampel *input-output*. Sejumlah data disediakan untuk melatih jaringan hingga mendapat bobot yang diinginkan. Pada proses pelatihan suatu *input training* diberikan ke jaringan kemudian diproses dan menghasilkan *output training*.

b. Pelatihan Tak Terbimbing (*unsupervised training*)

Pelatihan tak terbimbing (*unsupervised training*) merupakan proses pembelajaran tanpa sampel *input-output*. Proses pelatihannya berdasarkan parameter tertentu dan jaringan dimodifikasi sesuai parameter untuk menghasilkan bobot yang diinginkan.


Terdapat tiga jenis lapisan dalam JST:

- 1) Lapisan *Input*: Di mana unit di dalamnya disebut *input unit*, berfungsi untuk menerima data masukan dari luar yang mencerminkan sebuah masalah.
- 2) Lapisan *Hidden Layer*: Di mana *output* dari unit-unit di dalamnya tidak dapat diamati secara langsung.
- 3) Lapisan *Output*: Yang berisi unit-unit untuk memberikan solusi pada permasalahan yang ada.

Berdasarkan jumlah lapisan, arsitektur JST dapat diklasifikasikan menjadi 3 klasifikasi yaitu Tunggal, Jamak dan Kompetitif:

- 1) Jaringan Lapisan Tunggal/satu lapis, dimana seluruh unit masukan dihubungkan ke seluruh unit keluaran, meskipun dengan bobot yang berbeda-beda, jaringan satu lapis merupakan model dasar jaringan syaraf tiruan yang dapat digunakan untuk tugas klasifikasi sederhana. Meskipun memiliki keterbatasan dalam hal kompleksitas, model ini memberikan dasar yang baik untuk memahami konsep jaringan syaraf dan dapat diperluas menjadi arsitektur yang lebih kompleks seperti jaringan lapisan ganda (*multi-layer networks*) atau jaringan syaraf dalam (*deep neural networks*). Arsitektur Jaringan Lapisan Tunggal sangat sederhana dan

hanya terdiri hanya dari satu lapis sebagaimana pada Gambar 2.2 di bawah ini:




Gambar 2. 2 Jaringan Lapisan Tunggal

- 2) Jaringan Lapisan Banyak (*multi-layer network*), adalah jenis arsitektur jaringan saraf yang terdiri dari lebih dari satu lapisan. Dalam jaringan ini, lapisan *input* menerima data masukan, sedangkan lapisan *output* menghasilkan prediksi atau klasifikasi. Lapisan tersembunyi berfungsi sebagai pengolah informasi yang memungkinkan jaringan untuk menangkap pola yang lebih kompleks dalam data. Dengan menambahkan lapisan tersembunyi, jaringan dapat mempelajari representasi yang lebih abstrak dari data, yang meningkatkan kemampuannya dalam menyelesaikan tugas-tugas yang lebih rumit, seperti pengenalan gambar, pemrosesan bahasa alami, dan banyak aplikasi lainnya.

Keberadaan *neuron* tersembunyi dalam jaringan lapisan jamak memungkinkan model untuk melakukan transformasi non-linear pada data masukan. Setiap *neuron* dalam lapisan tersembunyi menerima *input*

dari *neuron* di lapisan sebelumnya, menerapkan fungsi aktivasi, dan kemudian meneruskan *output*nya ke lapisan berikutnya. Proses ini memungkinkan jaringan untuk membangun hierarki fitur, di mana lapisan awal mungkin menangkap fitur dasar, sementara lapisan yang lebih dalam dapat menangkap fitur yang lebih kompleks dan spesifik. Dengan demikian, jaringan lapisan jamak memiliki kemampuan yang lebih besar untuk generalisasi dan mempelajari hubungan yang rumit dalam data, menjadikannya alat yang sangat efektif dalam berbagai aplikasi kecerdasan buatan. Gambar 2.3 di bawah ini menunjukkan bagaimana arsitektur Jaringan Lapisan Jamak (*multi-layer network*).




Gambar 2. 3 Jaringan Lapisan Jamak

3) Jaringan lapisan kompetitif adalah jaringan yang mirip dengan jaringan lapisan tunggal atau multi-lapisan, tetapi aliran sinyalnya berbeda. Dalam jaringan ini, *neuron* keluaran mengirimkan sinyal kembali ke unit masukan. Hal ini sering disebut *loop* umpan balik dan memungkinkan sinyal mengalir dalam dua arah: maju dan mundur. Arsitektur jaringan kompetitif terdiri dari sejumlah besar *neuron* yang saling bersaing agar mendapatkan hak untuk menjadi aktif. Prinsip



“pemenang mengambil segalanya” diterapkan, dengan hanya *neuron* paling kompetitif yang bekerja. Algoritma yang menggunakan metode ini adalah *Learning Vector Quantization* (LVQ). Jaringan dengan lapisan kompetisi seringkali memiliki struktur yang sangat besar dan tidak seperti jaringan lainnya, koneksi antar *neuron* dalam suatu lapisan tidak dapat direpresentasikan dengan jelas dalam arsitektur. Jaringan Lapisan Kompetitif (*Competitive Layer*) ditunjukkan pada Gambar 2.4 berikut:



Gambar 2. 4 Jaringan lapisan kompetitif

#### 2.4.2 Kelebihan dan Kekurangan JST

Jaringan Saraf Tiruan (JST) memiliki sejumlah kelebihan serta kekurangan sebagai alat pemecah masalah. Beberapa keunggulan JST meliputi:

1. Kemampuan untuk memecahkan masalah yang sulit disimulasikan dengan teknik analitis tradisional.
2. Dapat memahami data yang tidak lengkap atau terpengaruh gangguan.
3. Mampu belajar dari pengalaman, yang sulit dicapai dengan pendekatan simbolik/logika.
4. Lebih hemat biaya dan nyaman dibandingkan dengan penulisan program konvensional, karena hanya memerlukan pelatihan jaringan dengan data

kasus.

5. Dapat diintegrasikan dengan teknologi lain untuk menciptakan sistem hibrida yang efektif, seperti kombinasi dengan sistem pakar, logika *fuzzy*, atau algoritma genetika.

Namun, pada JST juga terdapat beberapa kelemahan, antara lain:

1. Kurang cocok untuk aritmatika dan pengolahan data.
2. Masih memerlukan intervensi manusia untuk memberikan pengetahuan dan melakukan pengujian data.
3. Belum ada metode yang paling efektif untuk merepresentasikan data input, pemilihan arsitektur, atau penentuan banyaknya *neuron* dan lapisan, sehingga sering menggunakan metode *trial and error*.
4. Kurang mampu menjelaskan hasil, sehingga mungkin tidak tepat untuk aplikasi yang memerlukan penjelasan aturan, seperti penolakan aplikasi pinjaman bank. Namun, JST sangat sesuai untuk aplikasi yang lebih fokus pada hasil, seperti prediksi pola pasar saham.


## 2.5 Backpropagation

*Backpropagation* adalah metode sistematis untuk melatih jaringan *multilayer*, yang mampu memodelkan hubungan kompleks antara *input* dan *output*. Metode ini relatif lebih mudah dalam menyelesaikan berbagai masalah dan memiliki tingkat akurasi yang tinggi. Salah satu keunggulan dari *Backpropagation* adalah proses pembelajarannya yang dilakukan secara berulang, sehingga akan dapat menghasilkan sistem yang konsisten dan lebih efektif.

Algoritma pelatihan ANN menggunakan *backpropagation* terdiri dari dua

langkah: *feedforward* dan *backpropagation*. Kedua langkah ini diterapkan dalam jaringan selama proses pelatihan untuk suatu pola tertentu. Jaringan *backpropagation* terdiri dari tiga lapisan. Perbedaannya terletak pada jumlah lapisan tersembunyi, yang dapat mencakup satu lapisan atau lebih.

Metode *backpropagation* adalah metode pelatihan terawasi untuk jaringan saraf. Metode ini adalah bertujuan untuk meminimalisir kesalahan pada *output* yang dihasilkan oleh jaringan. Pada Gambar 2.5, unit masukan diwakili oleh X, unit tersembunyi oleh Z, dan unit keluaran oleh Y.



Gambar 2. 5 Arsitektur *Backpropagation*

*Backpropagation* memanfaatkan kesalahan *output* untuk penyesuaian bobot dalam arah mundur, setelah terlebih dahulu menjalani tahapan perambatan maju (*forward propagation*). Pada tahap ini, *neuron* dilakukan aktivasi menggunakan fungsi aktivasi *sigmoid*. Perlu diperhatikan bahwa fungsi aktivasi *sigmoid* yang dipergunakan pada *backpropagation* memiliki kriteria yang harus terpenuhi, seperti kontinu, mudah terdiferensiasi, dan tidak menurun. Fungsi umum ketiga kriteria tersebut adalah fungsi *sigmoid* biner, memiliki rentang nilai dari 0 sampai 1.

## 2.6 Fungsi Aktivasi

Fungsi aktivasi adalah sebuah fungsi yang mengubah masukan dirubah menjadi sebuah keluaran. Dalam jaringan syaraf tiruan (JST), informasi diterima melalui masukan. Masukan ini diproses menggunakan fungsi propagasi yang menambahkan beberapa masukan. Hasil penjumlahan ini dibandingkan dengan ambang batas tertentu menggunakan fungsi aktivasi masing-masing *neuron*. Ketika nilai yang dihasilkan melebihi ambang batas, *neuron* akan diaktifkan. Jika tidak, *neuron* akan menjadi tidak aktif. Artinya, *neuron* menghasilkan keluaran hanya jika nilai yang dihasilkan melebihi ambang batas. Beberapa fungsi aktivasi  $f(x)$  = keluaran fungsi aktivasi, dan  $x$  yang sering dipakai adalah sebagai berikut :

1. Fungsi *Sigmoid Biner*: adalah fungsi aktivasi dengan nilai antara 0 dan 1.
2. Fungsi *Sigmoid bipolar*: Fungsi *Sigmoid bipolar* hampir sama dengan *Sigmoid Biner*, tetapi *output* dari fungsi ini memiliki range -1 sampai 1;
3. Fungsi Linier: Fungsi Linier memiliki besaran/nilai *output* yang sama dengan *input*nya. Sehingga nilai *input* dan *output* akan menghasilkan satu garis lurus jika divisualisasikan pada grafik.

## 2.7 Transformasi Data

Normalisasi data adalah memodifikasi data jika perlu untuk mengurangi ukurannya. Transformasi ini adalah alat untuk praproses penambangan data. Regularisasi membantu proses penggunaan jaringan saraf. Data dinormalisasi ke interval yang lebih kecil dalam interval  $[0,1]$ . yang dapat dinyatakan dalam persamaan:

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.6)$$

Keterangan:

$x_{\text{norm}}$  = Data Normalisasi

$x$  = Data Real

$x_{\min}$  = Nilai Minimum Data

Denormalisasi Data adalah untuk mengembalikan data yang sudah di normalisasi ke nilai aslinya (denormalisasi), kita perlu menggunakan rumus *invers* dari normalisasi tersebut. Rumus untuk denormalisasi adalah:

$$X = X_n \times (X_{\max} - X_{\min}) + X_{\min} \quad (2.7)$$

Keterangan:

$X$  = data asli (yang akan dihitung kembali),

$x_n$  = data yang sudah dinormalisasi,

$x_{\min}$  = nilai minimum data asli,

$x_{\max}$  = nilai maksimum data asli.

## 2.8 Akurasi Prediksi

Validasi metode peramalan, terutama yang menggunakan metode di atas, tidak dapat dipisahkan dari jenis indikator yang digunakan untuk mengukur akurasi peramalan. Terdapat berbagai indikator yang dapat digunakan untuk menilai



kesesuaian suatu metode prediksi. Secara umum, ketepatan (akurasi) mencerminkan sejauh mana model prediksi dapat memproses data yang telah diberikan. Beberapa pengukuran akurasi yang umum digunakan adalah:

1. *Mean Absolute Deviation* (MAD)

*Mean Absolute Deviation* (MAD) adalah ukuran sederhana untuk menilai akurasi prediksi dengan menghitung rata-rata dari nilai absolut kesalahan prediksi, di mana setiap prediksi memiliki nilai absolut untuk setiap kesalahannya[2].

2. *Mean Squared Error* (MSE)

*Mean Squared Error* (MSE) adalah ukuran statistik standar yang menghitung rata-rata dari kesalahan kuadrat. Nilai MSE menunjukkan tingkat akurasi. MSE tidak selalu memiliki standar klasifikasi yang pasti, karena bergantung pada konteks dan jenis data yang dianalisis. Secara umum, semakin kecil nilai MSE, semakin akurat ramalan yang dihasilkan. Untuk melakukan perhitungan MSE dari suatu proses peramalan, diperlihatkan dengan persamaan:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.8)$$

Di mana:

$N$  = jumlah data uji

$y_i$  = adalah nilai target yang sebenarnya,

$\hat{y}_i$  = nilai yang diprediksi oleh model

Berikut ini adalah pedoman umum yang digunakan dalam banyak literatur untuk menilai kualitas model berdasarkan nilai MSE:

Tabel 2. 1 Klasifikasi umum nilai MSE

Rentang Nilai MSE	Interpretasi Model
$\leq 1$	Sangat Baik
1 – 5	Baik
5 – 20	Cukup
$> 20$	Buruk

### 3. *Mean Absolute Percentage Error (MAPE)*

Persentase kesalahan absolut rata-rata, atau yang dikenal sebagai *Mean Absolute Percentage Error (MAPE)*, adalah takaran yang digunakan untuk menilai kesalahan relatif. MAPE menunjukkan besarnya nilai penyimpangan dalam prediksi dibandingkan dengan nilai aktual, dengan menampilkan persentase penyimpangan dari hasil prediksi pada suatu periode dan persentase kesalahan yang ditunjukkan oleh MAPE lebih sesuai untuk laporan non teknis karena lebih mudah dipahami..Ini memberikan informasi mengenai apakah penyimpangan tersebut terlalu besar atau terlalu kecil. Untuk mengevaluasi keakuratan masing-masing jaringan, MAPE dihitung dengan melihat rata-rata kesalahan bulanan dimana kesalahan mengacu pada nilai persentase [12]. Untuk melakukan perhitungan MAPE dari suatu proses peramalan, diperlihatkan dengan persamaan:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (2.9)$$

Di mana:

$n$  = jumlah data uji

$y_i$  = nilai aktual konsumsi energi listrik

$\hat{y}_i$  = nilai yang diprediksi oleh model

Interpretasi rentang nilai MAPE yang umum digunakan untuk mengukur nilai yang dihasilkan seperti pada tabel berikut:

Tabel 2. 2 Kriteria nilai MAPE

Nilai MAPE	Akurasi Prediksi
$MAPE < 10\%$	Sangat akurat
$10\% \leq MAPE < 20\%$	Akurat
$20\% \leq MAPE < 50\%$	Dalam kewajaran
$MAPE \geq 50\%$	Tidak akurat

Hyndman & Koehler [6], memberikan penjelasan teoretis dan matematis tentang cara perhitungan MSE dan MAPE serta beberapa kekurangan dari masing-masing metode, tetapi tidak ada klasifikasi nilai MAPE dan MSE secara eksplisit dan sumber ini memberikan pemahaman lebih dalam tentang cara menghitung dan menginterpretasikan MAPE dan MSE sebagai ukuran kesalahan absolut, namun klasifikasi ini lebih sering digunakan sebagai pedoman praktis yang disesuaikan dengan kebutuhan industri atau penelitian tertentu dan merupakan praktik umum yang digunakan oleh praktisi untuk mengevaluasi kualitas model prediksi.

## 2.9 Penggunaan Neural Network dalam Sektor Kesehatan

Dalam sektor kesehatan, pengelolaan energi yang efisien sangat penting karena rumah sakit beroperasi 24 jam sehari dan mengandalkan berbagai peralatan medis yang memerlukan pasokan energi yang stabil dan andal. Penggunaan model prediksi untuk konsumsi energi di rumah sakit, khususnya dengan memanfaatkan Jaringan Saraf Tiruan (*Neural Network*), menjadi sangat relevan. Model ini dapat menganalisis pola konsumsi energi berdasarkan data historis dan faktor-faktor eksternal seperti jumlah pasien, jenis layanan, dan waktu operasional. Dengan demikian, rumah sakit dapat merencanakan konsumsi energi secara lebih optimal, mengurangi pemborosan, dan memastikan bahwa pasokan energi selalu mencukupi untuk mendukung layanan kesehatan yang kritis.