

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Penelitian Relevan**

Berbagai penelitian terdahulu telah dilakukan untuk mengembangkan metode kecerdasan buatan dalam sistem kelistrikan dan klasifikasi pola. Tinjauan terhadap penelitian-penelitian ini menjadi landasan penting dalam merancang model integrasi pada skripsi ini.

Terkait dengan pengenalan pola konsumsi energi, Sangadji dan Arvio (2019) dalam konferensi internasional IEEE telah mengembangkan pendekatan clustering yang efisien untuk mengidentifikasi pola pemakaian energi listrik. Penelitian ini memberikan wawasan fundamental bahwa beban listrik memiliki karakteristik pola tertentu yang dapat dipetakan secara akurat. Lebih lanjut, Sangadji (2019) juga merancang sebuah *Smart Home Controller* berbasis ADALINE (*Adaptive Linear Neuron*). Mengingat ADALINE memiliki arsitektur yang serupa dengan Perceptron, penelitian ini memperkuat landasan bahwa algoritma jaringan saraf tiruan sederhana sangat andal digunakan sebagai eksekutor keputusan adaptif pada sistem kendali otomatis.

Dalam domain klasifikasi pola menggunakan metode *Learning Vector Quantization* (LVQ), Abdurrasyid, Susanti, dan Indrianto (2023) membuktikan efektivitas metode ini melalui publikasi standar IEEE. Meskipun diterapkan pada kasus diagnosis medis (ISPA), penelitian tersebut menunjukkan bahwa LVQ memiliki akurasi yang sangat tinggi (mencapai 97,50%) dalam memetakan input data multivariabel ke dalam kelas-kelas diagnosis yang spesifik. Keandalan komputasi yang ditunjukkan oleh Abdurrasyid *et al.* ini menjadi validasi kuat untuk menerapkan LVQ dalam mengklasifikasikan dinamika beban listrik yang fluktuatif. Hal ini juga didukung oleh penelitian Sari dan Nugroho (2021), yang secara spesifik menguji LVQ untuk prediksi beban listrik jangka pendek dengan akurasi mencapai 91%, menegaskan kemampuan metode ini dalam mengenali pola data energi.

Aspek efisiensi energi dan manajemen distribusi juga menjadi fokus utama penelitian di lingkungan Institut Teknologi PLN. Puji Catur Siswipraptini *et al.* (2022)

dalam Jurnal Energi dan Kelistrikan meneliti penerapan algoritma Perceptron untuk deteksi gangguan pada sistem distribusi. Hasilnya menunjukkan bahwa Perceptron efektif mendeteksi anomali beban, yang relevan dengan fungsi safety pada sistem *discharging*. Selain itu, Aziza, Siswipraptini, dan Siregar (2021) mengembangkan sistem otomatisasi rumah berbasis IoT dan *Cloud* untuk efisiensi energi, yang sejalan dengan tujuan penelitian ini dalam mengoptimalkan penggunaan daya. Pentingnya manajemen penyimpanan energi juga ditekankan oleh Diantari dan Erlina (2017), yang menyatakan bahwa pemantauan karakteristik *charging-discharging* baterai sangat krusial untuk menjaga kontinuitas suplai daya.

Meskipun banyak metode telah dikembangkan, seperti penggunaan LSTM untuk peramalan beban oleh Anindita S. Surya *et al.* (2021) atau pendekatan *deep learning* lainnya (Akhtar *et al.*, 2023), sebagian besar penelitian tersebut masih menerapkan metode klasifikasi dan metode kontrol secara terpisah. Belum banyak penelitian yang mengintegrasikan kemampuan klasifikasi pola dari LVQ secara langsung dengan unit eksekusi keputusan biner berbasis Perceptron dalam satu arsitektur model hibrida untuk menangani dinamika *discharging* beban listrik. Oleh karena itu, penelitian ini hadir untuk mengisi celah tersebut dengan mengembangkan model integrasi yang menghubungkan klasifikasi status beban dengan mekanisme pengambilan keputusan pemutusan arus secara otomatis.

Selain penelitian di lingkungan internal kampus, tren penggunaan kecerdasan buatan dalam manajemen energi juga mendapatkan perhatian luas di kancah global. Lipu *et al.* (2024) dalam studi literatur komprehensif pada jurnal *Renewable and Sustainable Energy Reviews* menegaskan bahwa penerapan *Artificial Neural Network* (ANN) pada *Battery Management System* (BMS) telah menjadi standar baru untuk meningkatkan akurasi estimasi kondisi baterai. Hal ini dibuktikan secara praktis oleh Vidal *et al.* (2020), yang berhasil mengimplementasikan algoritma *Multilayer Perceptron* (MLP) untuk estimasi *State of Charge* (SoC) baterai secara real-time dengan komputasi yang ringan.

Pengembangan metode hibrida juga terus dilakukan untuk menangani kompleksitas sistem kelistrikan modern. Al-Ootaibi *et al.* (2022) menunjukkan bahwa pendekatan *Hybrid Deep Learning* mampu memberikan akurasi prediksi yang jauh lebih

baik dibandingkan model tunggal pada sistem *Smart Grid*. Temuan ini diperkuat oleh riset terbaru dari Makhadmeh *et al.* (2024) yang menggunakan teknik *Ensemble Learning* (gabungan beberapa model) untuk estimasi kapasitas baterai Li-Ion dengan presisi tinggi. Sementara itu, untuk optimasi jaringan distribusi, Balyk *et al.* (2025) membuktikan bahwa penggunaan *Deep Neural Networks* dapat secara efektif mengelola rugi-rugi energi (*energy losses*) dan mendukung pengambilan keputusan cerdas dalam jaringan distribusi. Kelima penelitian internasional ini semakin memperkuat urgensi pengembangan model integrasi hibrida LVQ-Perceptron yang diusulkan dalam skripsi ini.

Tabel 2.1 Penelitian relevan

| No | Nama Peneliti                       | Judul Penelitian                                                                   | Sumber Data           | Metode Pengembangan | Kesimpulan                                                                                               |
|----|-------------------------------------|------------------------------------------------------------------------------------|-----------------------|---------------------|----------------------------------------------------------------------------------------------------------|
| 1. | Sangadji & Arvio (2019)             | <i>An Efficient Clustering Approach in Electrical Energy Consumption Patterns</i>  | Data konsumsi energi  | LVQ                 | Membuktikan bahwa beban listrik memiliki pola karakteristik unik, menjadi landasan awal pengenalan pola. |
| 2. | Abdurasyid <i>et al.</i> (2023)     | Sistem Diagnosis ISPA Menggunakan Metode <i>Learning Vector Quantization</i> (LVQ) | Gejala klinis pasien  | LVQ                 | Metode LVQ terbukti memiliki akurasi tinggi (97,50%) dalam mengklasifikasikan pola data multivariabel.   |
| 3. | Siswiprapti ni <i>et al.</i> (2023) | Algoritma Perceptron Menggunakan Teknik <i>Machine Learning</i> Untuk Model        | Data gangguan listrik | Perceptron          | Algoritma ini efektif mendeteksi anomali beban dan relevan sebagai fungsi safety pada sistem distribusi. |

|    |                                 |                                                                                  |                              |                                    |                                                                                                                              |
|----|---------------------------------|----------------------------------------------------------------------------------|------------------------------|------------------------------------|------------------------------------------------------------------------------------------------------------------------------|
| 4. | Vidal <i>et al.</i> (2020)      | <i>Online Estimation of Lithium-</i>                                             | Data Baterai                 | <i>Multilayer Perceptron (MLP)</i> | Membuktikan keandalan algoritma                                                                                              |
| 5. | Al-Ootaibi <i>et al.</i> (2022) | <i>Hybrid Deep Learning Applied on Saudi Smart Grids</i>                         | Data beban <i>Smart Grid</i> | <i>Hybrid Deep Learning</i>        | Pendekatan <i>Hybrid</i> (integrasi) terbukti memberikan akurasi prediksi yang jauh lebih baik dibandingkan model tunggal.   |
| 6. | Penelitian Ini (2026)           | Pengembangan Model Integrasi LVQ dan Perceptron pada Dinamika <i>Discharging</i> | Historis Beban Listrik       | Integrasi LVQ-Perceptron           | Menggabungkan keunggulan klasifikasi pola (LVQ) dan eksekusi keputusan (Perceptron) untuk respon otomatis yang lebih akurat. |

## 2.2 Landasan Teori

Studi ini menitikberatkan pada perancangan model serta optimasi manajemen pengisian (*charging*) dan pengosongan (*discharging*) energi guna merespons fluktuasi konsumsi beban yang bersifat dinamis. Sebagai upaya memperkuat kerangka berpikir penelitian, bagian landasan teori ini akan memaparkan berbagai konsep fundamental yang saling berkaitan, mencakup prinsip sistem tenaga listrik, analisis karakteristik beban, hingga eksplorasi teknologi baterai dan beragam metodologi optimasi yang relevan.

### 2.2.1 Profil Dinamika Beban Listrik pada Smart Greenhouse

*Smart Greenhouse* atau rumah kaca cerdas adalah infrastruktur pertanian modern yang mengintegrasikan teknologi pengendalian lingkungan mikro untuk menunjang pertumbuhan tanaman secara presisi. Berbeda dengan bangunan residensial biasa, *Greenhouse* memiliki karakteristik beban listrik yang unik karena beroperasi selama 24 jam penuh untuk menjaga parameter lingkungan seperti suhu, kelembaban, dan pencahayaan.

malam) serta kebutuhan fisiologis tanaman. Secara umum, beban listrik terbagi menjadi dua kategori utama berdasarkan waktu operasionalnya:

- 1) Beban Pendinginan (*Cooling Load*): Pada siang hari, terjadi Pola konsumsi energi pada *Greenhouse* sangat dipengaruhi oleh siklus diurnal (siang-peningkatan suhu ruang akibat radiasi termal matahari. Oleh karena itu, konsumsi energi didominasi oleh operasional kipas ventilasi (*Exhaust Fans*) dan sistem pompa pendingin. Studi oleh Goo et al. (2021) menunjukkan bahwa beban pendinginan merupakan komponen konsumsi energi terbesar pada fase siang hari guna mencegah *overheating* pada tanaman.
- 2) Beban Penerangan (*Lighting Load*): Pada malam hari atau kondisi cuaca mendung, beban energi beralih ke sistem pencahayaan buatan (*artificial lighting*). Penggunaan lampu tipe LED Grow Lights diperlukan untuk memanipulasi durasi penyinaran (*photoperiodism*) yang krusial bagi fase vegetatif dan generatif tanaman, sebagaimana dijelaskan dalam riset Al-Amri et al. (2023).

Adanya pola fluktuasi beban yang kontras namun berulang antara siang (dominasi pendinginan) dan malam (dominasi penerangan) ini menjadikan *Smart Greenhouse* objek yang sangat relevan untuk penerapan metode klasifikasi pola berbasis *Machine Learning*, seperti *Learning Vector Quantization* (LVQ).

### **2.2.2 Karakteristik (PLTS) dan waktu efektif**

Pembangkit Listrik Tenaga Surya (PLTS) merupakan teknologi konversi energi yang memanfaatkan efek fotovoltaiik untuk mengubah iradiasi matahari menjadi energi listrik arus searah (*Direct Current*). Dalam implementasi sistem energi terbarukan, kinerja keluaran daya PLTS berbanding lurus dengan intensitas radiasi matahari yang diterima oleh permukaan modul surya.

Di wilayah beriklim tropis seperti Indonesia, efisiensi penyerapan energi sangat bergantung pada jendela waktu penyinaran efektif atau yang dikenal sebagai Peak Sun Hours (PSH). Berdasarkan analisis teknik tenaga listrik, durasi efektif penyinaran matahari di Indonesia umumnya terpusat pada rentang pukul 09.00 hingga 15.00 WIB. Dalam rentang waktu tersebut, intensitas radiasi matahari mencapai titik optimal untuk

proses konversi energi, dengan densitas daya tertinggi biasanya tercatat antara pukul 11.00 hingga 13.00 WIB. Fenomena ini divalidasi oleh penelitian Subrata, Sutikno, et al. (2019) yang menekankan pentingnya pelacakan titik daya maksimum (Maximum Power Point Tracking) pada jam-jam efektif tersebut untuk mengoptimalkan efisiensi sistem.

Karakteristik waktu operasional ini menjadi parameter fundamental dalam perancangan algoritma manajemen energi. Sistem kendali cerdas harus dirancang untuk memprioritaskan mode pengisian baterai (charging) pada periode Peak Sun Hours tersebut. Strategi ini bertujuan untuk memaksimalkan penyimpanan energi saat sumber daya tersedia melimpah, sehingga ketergantungan terhadap suplai jala-jala (grid) pada waktu beban puncak dapat diminimalisir.

### **2.2.3 Battery (Baterai)**

Sebagai komponen vital dalam penyimpanan energi, baterai berfungsi mengubah energi kimia menjadi energi listrik melalui mekanisme elektrokimia. Di antara berbagai jenis yang tersedia, baterai Lithium-Ion (Li-Ion) mendominasi penggunaan pada perangkat elektronik portabel dan kendaraan listrik. Keunggulan utamanya terletak pada densitas energi yang tinggi serta masa pakai (cycle life) yang lebih panjang dibandingkan teknologi baterai konvensional.

Mekanisme kerja Li-Ion melibatkan perpindahan ion litium di antara dua elektroda. Pada fase pengisian (charging), arus listrik memaksa ion litium berpindah dari katoda (positif) menuju anoda (negatif) untuk disimpan. Sebaliknya, saat fase pengosongan (discharging), ion-ion tersebut mengalir kembali ke katoda, melepaskan energi listrik yang digunakan untuk menyalakan beban.

Dalam perancangan sistem manajemen energi, terdapat beberapa parameter baterai yang krusial untuk dipantau:

- Kapasitas Nominal: Total muatan listrik yang mampu ditampung baterai saat penuh, umumnya satuan Ampere-hour (Ah).
- *State of Charge* (SoC): Persentase sisa energi dalam baterai dibandingkan dengan kapasitas totalnya, yang menjadi indikator utama ketersediaan daya.

- Tegangan Operasional: Baterai Li-Ion biasanya beroperasi pada tegangan nominal rata-rata 3,6V hingga 3,7V per sel.

#### 2.2.4 Prediksi dan Klasifikasi Beban Listrik

Estimasi kebutuhan energi melalui prediksi beban memegang peranan vital dalam menjaga stabilitas pasokan listrik. Secara teoritis, karakteristik beban dibedakan menjadi Beban Dasar (*Base Load*) yang cenderung stabil dan Beban Puncak (*Peak Load*) yang fluktuatif akibat lonjakan aktivitas. Pemahaman mendalam mengenai pola ini menjadi landasan utama dalam pengembangan model cerdas. Identifikasi profil beban yang presisi menggunakan machine learning sangat krusial untuk mencegah kegagalan distribusi. Dengan mengklasifikasikan beban ke dalam kategori Rendah, Sedang, dan Tinggi, sistem mampu memberikan peringatan dini terhadap risiko overload, sehingga mekanisme discharging dapat dieksekusi secara efektif untuk menjaga keamanan sistem. (Németh & Tornai, 2023)

#### 2.2.5 Kecerdasan Buatan

Kecerdasan Buatan atau *Artificial Intelligence* (AI) merupakan bidang ilmu komputer yang berkonsentrasi pada penciptaan sistem cerdas dengan kapabilitas kognitif yang menyerupai manusia, khususnya dalam hal pembelajaran (*learning*) dan pengambilan keputusan (*decision making*). Di tengah pesatnya perkembangan sistem kelistrikan modern yang kompleks, implementasi AI menjadi instrumen vital untuk mengolah data mentah menjadi informasi strategis yang memiliki nilai guna.

Kecerdasan Buatan atau *Artificial Intelligence* (AI) merupakan domain ilmu komputer yang berfokus pada pengembangan sistem cerdas dengan kemampuan yang menyerupai kognisi manusia, terutama dalam aspek pembelajaran (*learning*) dan pengambilannya keputusan (*decision making*). Dalam menghadapi kompleksitas data pada sistem kelistrikan modern, penerapan AI menjadi sangat krusial untuk mentransformasi data mentah informasi yang bernilai guna (Raza & Khosravi, 2015).

#### 2.2.6 Machine Learning

Machine learning merupakan salah satu pilar utama dalam bidang Kecerdasan Buatan (*Artificial Intelligence*) yang diimplementasikan secara spesifik dalam

penelitian ini. Teknologi ini menitikberatkan pada pengembangan algoritma yang memiliki kemampuan untuk mengekstraksi pola secara mandiri dari sekumpulan data historis tanpa memerlukan instruksi pemrograman yang kaku atau eksplisit. Secara konseptual, *Machine Learning* didefinisikan sebagai disiplin ilmu yang memungkinkan sistem komputer untuk belajar dari pengalaman atau data guna meningkatkan kinerjanya dalam menyelesaikan tugas tertentu secara adaptif. Dalam konteks sistem tenaga listrik, teknologi ini menjadi instrumen vital untuk mentransformasi data mentah menjadi informasi strategis yang memiliki nilai guna bagi manajemen energi.

Berdasarkan mekanisme pembelajarannya, machine learning dalam studi ini dikategorikan menjadi beberapa bagian utama:

- 1) *Supervised Learning*: Merupakan metode pembelajaran di mana algoritma menggunakan pasangan data masukan (input) dan label target yang sudah diketahui. Karakteristik ini tercermin pada fase kerja jaringan Perceptron dalam mengenali klasifikasi beban listrik berdasarkan data historis yang telah terlabeli.
- 2) *Unsupervised Learning*: Merupakan metode yang bertujuan untuk menemukan struktur tersembunyi atau kemiripan antar data tanpa adanya label awal. Secara teoretis, hal ini berkaitan dengan mekanisme kompetitif pada algoritma *Learning Vector Quantization* (LVQ) dalam mengelompokkan pola beban pada tahap awal.
- 3) Metode Hibrida (Integrasi): Merupakan pendekatan yang menggabungkan dua atau lebih algoritma untuk menutupi keterbatasan satu metode dengan keunggulan metode lainnya. Penerapan integrasi LVQ dan Perceptron dalam skripsi ini merupakan manifestasi dari teknik hibrida untuk menghasilkan model klasifikasi yang akurat sekaligus responsif terhadap dinamika beban secara *real-time*.

Penerapan integrasi *Learning Vector Quantization* (LVQ) dan Perceptron dalam skripsi ini merupakan manifestasi dari teknik Machine Learning yang bertujuan untuk menghasilkan model klasifikasi beban listrik yang tidak hanya akurat, tetapi juga responsif terhadap perubahan dinamika beban secara *real-time*. (Raza & Khosravi, 2015)


### **2.2.7 Jaringan Syaraf Tiruan (Artificial Neural Network)**

Jaringan Syaraf Tiruan (JST) atau *Artificial Neural Network* (ANN) merupakan metodologi dalam machine learning yang mengadopsi prinsip kerja jaringan saraf biologis manusia. Struktur ini terdiri dari sekumpulan unit komputasi dasar, yang dikenal sebagai neuron buatan, yang saling terinterkoneksi dalam susunan lapisan dan beroperasi secara paralel dalam mengolah data. Mekanisme kerja ANN menitikberatkan pada pemetaan data masukan (*input*) menjadi luaran (*output*) melalui siklus pembelajaran, di mana terjadi penyesuaian bobot antar neuron secara berkelanjutan berdasarkan nilai galat (*error*) yang diperoleh. (Muñoz-Zavala et al., 2024)

### **2.2.8 Learning Vector Quantization (LVQ)**

*Learning Vector Quantization* (LVQ) merupakan algoritma jaringan syaraf tiruan berbasis pembelajaran kompetitif terawasi (*supervised competitive learning*) untuk klasifikasi pola. Metode ini bekerja dengan melatih lapisan kompetitif untuk mengelompokkan data input ke dalam kelas-kelas yang telah ditentukan melalui perhitungan jarak antar vektor.

Proses utamanya mengandalkan vektor bobot referensi atau vektor prototipe. Selama pelatihan, jaringan mengidentifikasi neuron dengan jarak Euclidean terdekat dari input, lalu mengoptimalkan posisi prototipe tersebut secara iteratif untuk menghasilkan batas keputusan (*decision boundary*) yang akurat. Dalam penelitian ini, LVQ berfungsi sebagai pengolah fitur yang mengelompokkan dinamika beban menjadi kategori terstruktur sebelum diproses oleh unit pengambilan keputusan. (Setyowati & Mariani, 2021)



Gambar 1. Arsitektur LVQ

Pada algoritma LVQ, proses klasifikasi didasarkan pada pencarian jarak minimum antara vektor input dan vektor bobot. Jarak terdekat ini berfungsi untuk menentukan kelas pemenang (winning unit). Secara matematis, pengukuran jarak tersebut diselesaikan menggunakan pendekatan jarak Euclidean (Euclidean Distance) sebagaimana ditunjukkan pada persamaan di bawah ini:

- Rumus Jarak Euclidean (LVQ):

$$d_j = \sqrt{\sum_{i=1}^n (x_i - w_{ji})^2}$$

Keterangan:

- $d_j$ : Jarak Euclidean ke-j
- $x_i$ : Vektor input variabel ke-i
- $w_{ji}$  Vektor bobot untuk kelas ke-j variabel ke-i.

Setelah pemenang (*winning unit*) ditemukan, pembaruan bobot dilakukan dengan aturan sebagai berikut:

Rumus Pembaruan Bobot (LVQ):

1. Jika kelas input sama dengan kelas pemenang :

$$w_j(\text{baru}) = w_j(\text{lama}) + \alpha [x - w_j(\text{lama})]$$

2. Jika kelas input tidak sama dengan kelas pemenang :

$$w_j(\text{baru}) = w_j(\text{lama}) - \alpha[x - w_j(\text{lama})]$$

Di mana  $\alpha$  adalah learning rate yang bernilai antara 0 sampai 1.

### 2.2.9 Algoritma Perceptron

Perceptron merupakan salah satu model dasar dalam jaringan syaraf yang diperkenalkan oleh Frank Rosenblatt (1958). Prinsip kerjanya adalah menghitung hasil perkalian bobot dan input, kemudian menentukan kelas berdasarkan fungsi aktivasi. Meskipun terlihat sederhana, Perceptron dapat diperluas menjadi *multi-layer perceptron* (MLP) untuk memproses data yang kompleks. Dalam sistem tenaga listrik, algoritma ini dapat digunakan untuk deteksi gangguan dan klasifikasi beban.

Model Perceptron bekerja dengan menghitung jumlah bobot dari input yang masuk dan melewatkannya ke sebuah fungsi aktivasi. (Siswipraptini et al., 2023).

Output dari perceptron ( $y$ ) dirumuskan sebagai:

$$y = f(\text{net}) = f\left(\sum_{i=1}^n x_i w_i + b\right)$$

Pada algoritma LVQ, proses klasifikasi didasarkan pada pencarian jarak minimum antara vektor input dan vektor bobot. Jarak terdekat ini berfungsi untuk menentukan kelas pemenang (*winning unit*). Secara matematis, pengukuran jarak tersebut diselesaikan menggunakan pendekatan jarak Euclidean (*Euclidean Distance*) sebagaimana ditunjukkan pada persamaan di bawah ini:


Keterangan:

- $x_i$ : Input ke-i
- $w_i$  : Bobot ke-i
- $b$  : Bias
- $f$  : Fungsi aktivasi (biasanya menggunakan *Hard limit* atau *Sigmoid*)

Proses pembaruan bobot pada Perceptron dilakukan jika terdapat selisih antara target ( $t$ ) dan output ( $y$ ):

$$\Delta w = \alpha(t - y)x$$

$$w_{\text{new}} = w_{\text{old}} + \Delta w$$



Gambar 2.1 Arsitektur Perceptron

#### 2.2.10 Model Hibrida LVQ-Perceptron

Model hibrida dalam bidang kecerdasan buatan didefinisikan sebagai sistem komputasi yang menggabungkan dua atau lebih algoritma pembelajaran mesin untuk menyelesaikan masalah yang kompleks. Menurut Raza & Khosravi (2015), pendekatan hibrida dikembangkan untuk mengatasi keterbatasan yang dimiliki oleh metode tunggal (*single method*), di mana integrasi berbagai teknik dapat meningkatkan ketahanan (*robustness*) serta akurasi prediksi pada data yang bersifat stokastik seperti beban listrik. (Raza & Khosravi, 2015)

Dalam penelitian ini, model hibrida disusun dengan struktur sekuensial, di mana LVQ berperan sebagai pengolah fitur awal dan Perceptron sebagai eksekutor keputusan. Sinergi ini bertujuan untuk memanfaatkan kemampuan klasifikasi pola dari LVQ dan kemampuan pembelajaran adaptif dari Perceptron. Efektivitas pendekatan ini sejalan dengan temuan Moayedi et al. (2021), yang menyimpulkan bahwa integrasi model jaringan syaraf tiruan mampu meminimalisir ambiguitas data dan menurunkan tingkat kesalahan (*error rate*) secara signifikan dibandingkan penggunaan algoritma secara mandiri. (Moayedi et al., 2021).

Secara keseluruhan, model hibrida ini menggabungkan kecepatan LVQ dalam mengenali karakteristik pola dengan ketegasan Perceptron dalam mengeksekusi logika keputusan, sehingga menghasilkan sistem klasifikasi yang lebih andal terhadap dinamika beban listrik. Dalam konteks manajemen energi, model hibrida ini dirancang untuk meminimalkan risiko kesalahan pemutusan arus.

#### 2.2.11 Normalisasi Data

Normalisasi memegang peranan penting dalam tahap pra-pemrosesan data, khususnya untuk menyetarakan skala antar atribut numerik tanpa mengubah distribusi aslinya. Prosedur ini sangat vital bagi algoritma sensitif seperti Jaringan Syaraf Tiruan, guna mencegah atribut dengan rentang nilai besar mendominasi proses pembelajaran model.

Salah satu pendekatan yang paling sering diadopsi adalah *Min-Max Normalization*. Teknik ini mentransformasikan data asli ke dalam rentang skala baru yang spesifik, umumnya antara 0 hingga 1. Secara matematis, transformasi ini dirumuskan sebagai berikut:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

Dimana  $x'$  merepresentasikan nilai hasil normalisasi, sedangkan  $\min(x)$  dan  $\max(x)$  adalah batas nilai terendah dan tertinggi pada fitur data yang bersangkutan.

#### 2.2.12 Confusion Matrix

Untuk mengukur keandalan model klasifikasi, digunakan instrumen evaluasi yang disebut Confusion Matrix. Matriks ini menyajikan perbandingan *head-to-head* antara kelas prediksi yang dihasilkan model dengan kelas sebenarnya (*actual class*) dari data uji.

Dalam skenario klasifikasi biner, hasil prediksi dikategorikan ke dalam empat kuadran:


- *True Positive* (TP): Keadaan di mana model secara tepat memprediksi kelas positif.

- *True Negative* (TN): Keadaan di mana model secara tepat memprediksi kelas negatif.
- *False Positive* (FP): Kesalahan prediksi di mana data negatif dianggap sebagai positif (dikenal sebagai Type I Error).
- *False Negative* (FN): Kesalahan prediksi di mana data positif dianggap sebagai negatif (dikenal sebagai Type II Error).

Dari komponen-komponen tersebut, metrik Akurasi dapat dikalkulasi untuk memberikan gambaran persentase keberhasilan prediksi model secara keseluruhan:

$$\text{Akurasi} = \frac{TP+TN}{\text{TotalData}(TP+TN+FP+FN)}$$

### 2.2.13 CRISP-DM



Gambar 2.2 CRISP-DM

*Cross-Industry Standard Process for Data Mining* (CRISP-DM) merupakan standar metodologi yang diakui secara global sebagai panduan sistematis dalam proyek penggalian data. Kerangka kerja ini dirancang untuk menjamin bahwa hasil analisis data tetap selaras dengan kebutuhan dan strategi bisnis organisasi.

Mengacu pada standar Chapman et al. (2000), siklus hidup CRISP-DM mencakup enam tahapan yang saling terkait dan bersifat iteratif:

1. *Business Understanding*: Tahap mendasar untuk mengidentifikasi tujuan proyek serta menerjemahkan kebutuhan bisnis menjadi definisi masalah teknis.
2. *Data Understanding*: Proses awal pengumpulan data, termasuk eksplorasi untuk menemukan wawasan awal dan mendeteksi kualitas data.
3. *Data Preparation*: Fase konstruksi dataset akhir, meliputi pembersihan data (*cleaning*), seleksi fitur, hingga transformasi data agar siap diproses oleh model.
4. *Modeling*: Penerapan algoritma pembelajaran mesin yang sesuai, disertai kalibrasi parameter untuk mendapatkan performa terbaik.
5. *Evaluation*: Penilaian menyeluruh terhadap model untuk memastikan akurasi memenuhi kriteria kesuksesan proyek.
6. *Deployment*: Tahap implementasi model ke dalam lingkungan operasional agar dapat digunakan dalam pengambilan keputusan sehari-hari.

#### 2.2.14 Google Colab



Gambar 2.3 Logo Google Colab

Google Colaboratory (Colab) sebagai platform utama dalam tahap pengembangan dan pengujian model hibrida ini. Layanan berbasis cloud milik Google ini dipilih karena menyediakan lingkungan pemrograman interaktif yang dapat diakses melalui antarmuka Jupyter Notebook secara daring. peneliti menggunakan Google Colaboratory (Colab) sebagai lingkungan pengembangan utama. Layanan berbasis cloud dari Google ini dipilih karena kemampuannya dalam menyediakan platform pemrograman interaktif melalui antarmuka Jupyter Notebook secara daring. Penggunaan Colab dinilai sangat efektif untuk meminimalkan hambatan teknis karena peneliti dapat menulis dan

mengeksekusi kode Python tanpa harus melakukan konfigurasi perangkat keras secara lokal (Nelson & Hoover, 2020).

### 2.2.15 Python




Gambar 2.4 Logo Python

Penelitian ini menetapkan bahasa pemrograman Python sebagai instrumen utama dalam pengembangan model hibrida. Pemilihan ini didasari oleh efektivitas Python dalam ranah data science berkat sifatnya yang open-source serta struktur sintaksis yang intuitif, sehingga mempermudah penyusunan logika integrasi antara algoritma LVQ dan Perceptron. Relevansi penggunaannya juga terlihat pada pemanfaatan ekosistem pustaka standar seperti NumPy dan Pandas yang memfasilitasi manipulasi dinamika beban listrik secara efisien. Selain itu, fleksibilitas Python dalam menggabungkan unit klasifikasi dan keputusan secara sekuensial, ditambah dengan keandalannya dalam aspek skalabilitas, menjamin performa model tetap optimal saat menangani komputasi data historis yang kompleks dan berskala besar. (Kedia et al., 2023).

## 2.3 Kerangka Teori

Berdasarkan penelitian-penelitian terdahulu dan teori yang telah dijelaskan, maka penelitian ini mengadopsi pendekatan integratif antara metode *Learning Vector Quantization* (LVQ) dan Perceptron untuk membangun model klasifikasi dan prediksi beban listrik. Hasil klasifikasi ini menjadi input bagi model perceptron untuk menghasilkan respon keputusan. Kombinasi ini diharapkan mampu meningkatkan akurasi klasifikasi serta respons adaptif terhadap perubahan pola beban, sebagaimana ditunjukkan oleh penelitian relevan sebelumnya.



Gambar 2.5 Kerangka Teori