BAB II
TINJAUAN PUSTAKA

2.1 Penelitian Relevan

Penelitian mengenai PLTS berbasis data umumnya diarahkan untuk memahami perubahan keluaran akibat kondisi lingkungan dan menghasilkan informasi yang dapat mendukung pengelolaan sistem. (Gufron et al., 2022) memprediksi *output* energi pembangkit listrik tenaga surya berkapasitas 1 kWp menggunakan data deret waktu dengan *Support Vector Machine* (SVM). Hasil kumulatif bulanan menunjukkan *MAPE* sebesar 4,13% untuk *SVM* dan 5,56% untuk regresi linier berganda. (Bramasto & Khairiani, 2022) menggunakan regresi linier berganda berdasarkan kerangka kerja CRISP-DM untuk meramalkan *output* daya pembangkit listrik tenaga surya dengan memanfaatkan data intensitas radiasi matahari, suhu modul, dan suhu lingkungan. Kedua penelitian tersebut menunjukkan bahwa data lingkungan dapat diolah menjadi informasi tentang kondisi keluaran PLTS, tetapi tujuan utamanya masih berupa peramalan daya atau energi.

Penggunaan jaringan saraf untuk peramalan PLTS juga telah dikaji dengan arsitektur yang lebih kompleks. (Adeyemi et al., 2022) menggunakan *Multilayer Perceptron Neural Network* untuk memperkirakan pembangkitan energi fotovoltaik harian dan memperoleh kinerja yang lebih baik dibandingkan model regresi nonlinier serta *Generalized Regression Neural Network.* (Januari et al., 2026) menggunakan *Long Short-Term Memory* untuk memprediksi daya PLTS satu jam ke depan berdasarkan iradiansi, suhu, kelembapan, dan kecepatan angin. Model tersebut memperoleh *MAPE* 5,5% dan *RMSE* 7,8% dari kapasitas nominal. Kajian-kajian tersebut menunjukkan kemampuan *machine learning* dalam mempelajari data PLTS yang fluktuatif, tetapi memiliki tujuan, variabel, dan arsitektur yang berbeda dari klasifikasi tingkat suplai dalam penelitian ini.

Pada lingkungan Institut Teknologi PLN, (Haris et al., 2020) mengembangkan konsep kendali dan pemantauan PLTS menggunakan pendekatan jaringan saraf tiruan dan *data mining*. Penelitian tersebut menekankan perlunya sistem terkomputerisasi

untuk membantu analisis, pemantauan, dan kendali kondisi pembangkit. Hubungannya dengan penelitian ini terletak pada penggunaan pengolahan data untuk merepresentasikan kondisi PLTS. Perbedaannya, penelitian ini tidak merancang sistem pemantauan maupun kendali perangkat keras, tetapi membatasi hasil pada klasifikasi tingkat suplai berbasis iradiansi dan label rekomendasi status.

Pengelompokan data energi menjadi kondisi tertentu telah diterapkan oleh (Siswipraptini et al., 2020) dan (Kusuma et al., 2025). (Siswipraptini et al., 2020) menggunakan K-Means untuk membagi konsumsi listrik rumah pintar menjadi kelompok konsumsi tinggi dan rendah, dengan nilai Davies-Bouldin Index sebesar 0,417103167. (Kusuma et al., 2025) membandingkan K-Means dan *Fuzzy Subtractive Clustering* untuk membentuk pola konsumsi energi pelanggan bisnis dan industri. Kedua penelitian dosen ITPLN tersebut menunjukkan bahwa data kelistrikan dapat direpresentasikan sebagai kelompok kondisi, sedangkan penelitian ini membentuk tiga tingkat suplai PLTS menggunakan ADALINE.

Penerapan beberapa algoritma secara berurutan telah dilakukan pada bidang lain. (Prasatya et al., 2020) menggabungkan K-Means untuk mengelompokkan data kontinu dan C4.5 untuk membentuk keputusan, dengan akurasi 72. (Jatnika et al., 2021) menggunakan K-Medoids untuk membentuk kelompok wilayah berdasarkan kemiripan data, sedangkan (Nur et al., 2021) menggunakan Perceptron untuk mengklasifikasikan kualitas air berdasarkan masukan suhu dan pH dengan akurasi 98,06%. Walaupun objek penelitiannya berbeda, ketiga penelitian dosen ITPLN tersebut menjadi ilustrasi metodologis bahwa keluaran pengolahan data dapat digunakan untuk membentuk kategori atau keputusan.

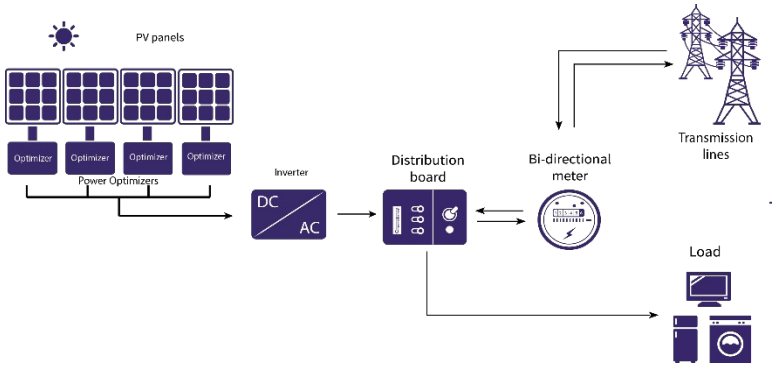
Berdasarkan sumber yang ditelaah, penelitian sebelumnya lebih banyak membahas peramalan keluaran PLTS, pengelompokan pola energi, pemantauan sistem, atau klasifikasi pada objek selain PLTS. Belum ditemukan pada sumber tersebut susunan sederhana yang menempatkan ADALINE untuk menghasilkan nilai kontinu yang diinterpretasikan menjadi tiga kategori tingkat suplai, kemudian meneruskan seluruh nilai kontinu tersebut kepada Perceptron untuk menghasilkan rekomendasi biner. Oleh karena itu, unsur pembeda penelitian ini terletak pada pembagian fungsi kedua algoritma secara berurutan, penggunaan satu fitur berupa nilai masukan PLTS,

serta pembatasan keluaran sebagai klasifikasi tingkat suplai dan label rekomendasi *on-grid* atau *off-grid* dalam simulasi.

2.2 LANDASAN TEORI

Landasan teori merupakan acuan konseptual yang digunakan untuk mendukung pelaksanaan dan pembahasan penelitian. Teori yang digunakan berkaitan dengan Pembangkit Listrik Tenaga Surya (PLTS), iradiansi matahari, *machine learning*, jaringan saraf tiruan, tahapan pengolahan data, serta algoritma ADALINE dan Perceptron. Selain itu, dibahas pula pengertian sistem PLTS *on-grid* dan *off-grid* sebagai dasar dalam menentukan label rekomendasi yang digunakan dalam penelitian.

2.2.1 Pembangkit Listrik Tenaga Surya (PLTS)



Gambar 2.1 PLTS

PLTS atau pembangkit listrik tenaga surya adalah sistem pembangkit listrik yang memanfaatkan radiasi matahari sebagai sumber energi utama untuk diubah menjadi energi listrik menggunakan sel surya. Sel surya terbuat dari bahan semikonduktor yang dapat menghasilkan arus listrik saat terkena energi foton dari sinar matahari. Panel surya menghasilkan listrik dalam bentuk arus searah (DC). Listrik DC ini dapat dimanfaatkan secara langsung, disimpan dalam baterai, atau diubah menjadi arus bolak-balik (AC) menggunakan inverter.

Komponen umum dari sistem tenaga surya mencakup beberapa elemen utama: panel surya, pengatur pengisian daya surya, baterai, inverter, sistem keamanan, dan beban listrik. Energi surya ditangkap oleh panel surya dan diubah menjadi energi listrik. Pengatur pengisian daya surya digunakan untuk mengatur pengisian baterai, sedangkan inverter digunakan untuk mengubah listrik DC menjadi listrik AC agar dapat digunakan

oleh peralatan listrik. Cara penggunaan masing-masing komponen bervariasi tergantung pada jenis sistem tenaga surya yang Anda terapkan dan konfigurasinya.

Energi listrik yang disuplai oleh sistem tenaga surya dapat dikonsumsi secara langsung atau disimpan dalam baterai, terutama pada sistem mandiri atau sistem *off-grid*. Sistem tenaga surya memiliki potensi yang signifikan untuk diterapkan di daerah terpencil karena energi surya tersedia hampir di mana-mana, terutama di Indonesia yang terletak di garis khatulistiwa. Namun, kinerja sistem tenaga surya umumnya belum optimal karena jumlah energi surya yang diterima panel surya bersifat fluktuatif. Selain itu, posisi panel surya yang tetap tidak selalu memungkinkan penyerapan sinar matahari dalam jumlah maksimal. Oleh karena itu, diperlukan sistem kontrol dan pemantauan untuk mendukung pengoperasian pembangkit listrik tenaga surya agar lebih optimal dan efisien.(Haris et al., 2020).

2.2.2 *Machine Learning*

Pembelajaran mesin (*machine learning*) merujuk pada subbidang Kecerdasan Buatan (AI) yang berfokus pada perancangan sistem atau algoritma yang memungkinkan komputer mempelajari pola dari data dan meningkatkan kinerjanya tanpa perlu menuliskan semua aturan pemrosesannya secara eksplisit. Metode pembelajaran ini dapat dimanfaatkan dalam pembelajaran mesin untuk mendeteksi pola, melakukan pengelompokan (clustering), menghasilkan klasifikasi, serta membuat prediksi atau penilaian berdasarkan data yang tersedia.

Data merupakan dasar pembuatan model dalam algoritma pembelajaran mesin. Data yang digunakan pada fase pelatihan mencakup pola atau hubungan antara masukan dan target yang akan dipelajari oleh model. Setelah pelatihan selesai, model siap digunakan untuk menghasilkan keluaran untuk data yang ditentukan. Tingkat keberhasilan model bergantung pada kualitas data, pemilihan fitur, metode pemrosesan data, parameter pembelajaran, dan metode evaluasi. Pembelajaran mesin dapat diklasifikasikan menjadi pembelajaran terawasi, pembelajaran tak terawasi, dan pembelajaran penguatan berdasarkan proses pembelajarannya. Pembelajaran terawasi bekerja dengan data yang memiliki target atau label. Pembelajaran tak terawasi digunakan untuk menemukan struktur atau pola dalam data tanpa target. Sebaliknya,

pembelajaran penguatan mempelajari tindakan tertentu melalui imbalan dan hukuman. ADALINE dan Perceptron yang digunakan dalam penelitian ini didasarkan pada teknik pembelajaran terawasi karena keduanya menggunakan nilai target dalam proses pelatihan. Dalam praktiknya, pembelajaran mesin telah digunakan secara luas di berbagai sektor, seperti perawatan kesehatan, energi, manufaktur, pendidikan, dan sistem cerdas. Pembelajaran mesin dapat digunakan untuk mengubah data menjadi informasi yang dapat membantu proses pengambilan keputusan yang lebih terstruktur dan didorong oleh data (Prasatya et al., 2020). Penelitian ini memanfaatkan pembelajaran mesin untuk menilai pola radiasi matahari, yang direpresentasikan sebagai tingkat *output* pembangkit listrik tenaga surya, serta untuk memberikan rekomendasi mengenai status *on-grid* atau *off-grid*.

2.2.3 *Artificial Neural Network (ANN)*

Jaringan Saraf Tiruan (JST) adalah teknik pembelajaran mesin yang meniru cara kerja dasar jaringan saraf biologis. JST terdiri dari sejumlah elemen komputasi sederhana yang disebut neuron tiruan. Setiap neuron menerima nilai masukan, mengalikannya dengan bobot, menjumlahkan semua hasil perkalian tersebut, menambahkan bias, dan menghasilkan keluaran.

Jaringan saraf tiruan belajar dengan mengaitkan data masukan dengan keluaran. Sebagai bagian dari proses ini, bobot dan bias dimodifikasi berdasarkan kesalahan yang timbul akibat selisih antara keluaran model dan nilai target. Modifikasi ini dilakukan secara berulang sehingga nilai kesalahan diminimalkan dan keluaran yang dihasilkan semakin mendekati tujuan yang diinginkan.

Secara umum, ANN memiliki lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Lapisan masukan menerima variabel masukan, lapisan tersembunyi mentransformasi informasi, dan lapisan keluaran menghasilkan keluaran model. Namun, tidak semua jaringan saraf tiruan harus memiliki lapisan tersembunyi. Desain sederhana seperti ADALINE dan Perceptron mungkin hanya memiliki lapisan masukan dan unit keluaran tanpa lapisan tersembunyi.

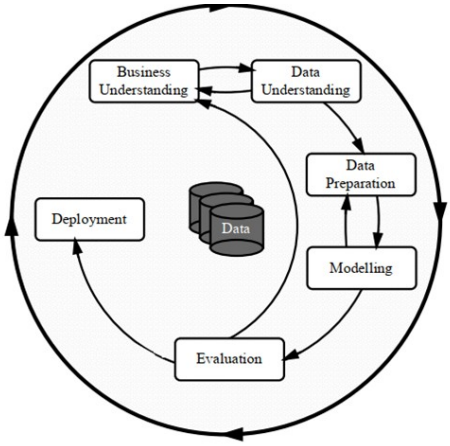
Keluaran sebuah neuron ditentukan dengan menerapkan fungsi aktivasi pada hasil penjumlahan tertimbang. Fungsi aktivasi yang paling populer adalah fungsi linier,

fungsi sigmoid, fungsi tangen hiperbolik, fungsi ReLU, dan fungsi ambang batas. Pemilihan fungsi aktivasi bergantung pada karakteristik masalah dan jenis keluaran yang akan dihasilkan. Jaringan saraf tiruan (JST) telah digunakan untuk berbagai macam tugas, termasuk prediksi, klasifikasi, pengenalan pola, dan optimisasi (Muñoz-Zavala et al., 2024).

Dalam penelitian ini, jaringan saraf tiruan diterapkan melalui algoritma ADALINE dan Perceptron. ADALINE menghasilkan nilai-nilai kontinu melalui fungsi keluaran linier, sedangkan Perceptron menghasilkan keputusan biner menggunakan fungsi ambang batas. Karakteristik yang berbeda ini dimanfaatkan untuk merancang rangkaian pemrosesan data guna menganalisis tingkat pasokan dan memberikan rekomendasi mengenai status fasilitas tenaga surya.

.

2.2.4 CRISP-DM



Gambar 2.2 Alur CRISP-DM

Cross-Industry Standard Process for Data Mining (CRISP-DM) merupakan kerangka kerja yang digunakan untuk mengarahkan proses pengolahan data dan pembangunan model secara sistematis. CRISP-DM bersifat fleksibel dan dapat diterapkan dalam berbagai jenis penelitian berbasis data. Kerangka kerja ini membantu peneliti memahami masalah, mengenali karakteristik data, menyiapkan data, membangun model, serta mengevaluasi hasil model (Schröer et al., 2021). CRISP-DM terdiri atas enam tahapan utama sebagai berikut.

1) *Business Understanding*: Tahap ini digunakan untuk memahami permasalahan, tujuan, kebutuhan, dan keluaran yang diharapkan dari penelitian. Dalam penelitian ini, permasalahan yang dikaji adalah perubahan iradiansi matahari yang menyebabkan tingkat suplai PLTS tidak selalu tetap. Tujuan pengolahan data adalah menghasilkan klasifikasi tingkat suplai dan rekomendasi status *on-grid* atau *off-grid* berbasis simulasi.
2) *Data Understanding*: Tahap ini meliputi pengumpulan dan pemahaman terhadap data yang digunakan. Kegiatannya mencakup pemeriksaan atribut, tipe data, jumlah data, rentang nilai, data kosong, data yang tidak sesuai, serta karakteristik distribusi data. Pemahaman tersebut diperlukan agar proses pengolahan dilakukan dengan metode yang sesuai.
3) *Data Preparation*: Ini adalah tahap di mana Anda mempersiapkan data agar dapat digunakan untuk melatih model. Kegiatan yang dilakukan meliputi pembersihan data, pemilihan fitur, penanganan data yang hilang, konversi tipe data, pembentukan target, dan normalisasi. Kualitas pembelajaran bergantung pada persiapan data, karena model mempelajari pola-pola berdasarkan data yang telah disiapkan.
4) *Modeling*: Tahap ini meliputi pemilihan dan penerapan algoritma, penentuan parameter, pelatihan, dan pengujian model. Penelitian ini menggunakan ADALINE untuk menghasilkan nilai kontinu yang merepresentasikan tingkat suplai dan Perceptron untuk menghasilkan rekomendasi biner status *on-grid* atau *off-grid*.
5) *Evaluation*: Tahap ini digunakan untuk menilai hasil model berdasarkan ukuran evaluasi yang ditentukan dan kesesuaiannya dengan tujuan penelitian. ADALINE dapat dievaluasi menggunakan *Mean Squared Error*, sedangkan Perceptron dapat dievaluasi menggunakan *confusion matrix*, akurasi, presisi, *recall*, dan *F1-score.*
6) *Deployment*: Tahap ini berkaitan dengan penerapan atau penyajian model agar dapat digunakan, misalnya dalam bentuk program, aplikasi, laporan, visualisasi, atau prototipe. Penelitian ini berfokus pada pembangunan dan

evaluasi program simulasi sehingga hasilnya belum digunakan untuk melakukan pengendalian atau *switching* jaringan listrik secara fisik.

2.2.5 Normalisasi

Normalisasi merupakan prosedur penting dalam proses persiapan data pada metodologi CRISP-DM, yang merupakan salah satu bentuk transformasi data. Prosedur ini bertujuan untuk menstandarkan skala nilai di seluruh atribut, sehingga tidak ada satu pun fitur yang mendominasi proses pemodelan hanya karena memiliki rentang nilai yang lebih luas. Prosedur normalisasi membantu meningkatkan konsistensi data dan memastikan bahwa semua atribut memiliki pengaruh yang seimbang dalam proses analisis, terutama pada pendekatan berbasis jarak seperti klasifikasi atau pengelompokan. Salah satu proses tersulit dalam persiapan data adalah transformasi data, khususnya normalisasi, karena sangat bergantung pada model yang digunakan dan jenis data yang diteliti. Dalam hal ini, peran normalisasi merupakan aspek penting dalam upaya meningkatkan kualitas dan efektivitas model prediksi. Teknik ini telah diakui sebagai langkah penting dalam fase persiapan data. (Schröer et al., 2021)

$$x_{\text{normalisasi}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{2.1}$$

Keterangan:

1. x : nilai asli
2. $x_{\min}$: nilai minimum
3. $x_{\max}$: nilai maksimum
4. $x_{\text{Normalisasi}}$: nilai setelah dinormalisasi

2.2.6 *Google Colaboratory*



Gambar 2.3 Google Colaboratory

Google Colab adalah lingkungan pemrograman berbasis *cloud* yang ditawarkan oleh Google, yang juga dikenal sebagai *Google Colaboratory*. Google Colab adalah produk yang memungkinkan pengguna menjalankan kode *Python* di peramban web tanpa perlu menginstal lingkungan pemrograman secara langsung di perangkat mereka. Program dibuat dan dijalankan dalam bentuk *notebook* yang terdiri dari sel kode dan sel teks.

Google Colab menyediakan sumber daya komputasi berupa CPU, serta dukungan GPU dan TPU pada beberapa konfigurasi. Platform ini juga mendukung berbagai pustaka *Python,* termasuk *Numpy*, *Pandas, Matplotlib, Scikit-learn, TensorFlow*, dan *PyTorch*. Pengguna dapat mengunggah *dataset*, melakukan pengolahan data, melatih model, menampilkan visualisasi, dan menyimpan hasil pemrosesan dalam satu lingkungan kerja.

Penggunaan Google Colab memberikan kemudahan dalam proses eksperimen karena program dapat dijalankan melalui perangkat yang berbeda selama terhubung dengan internet. Selain itu, bentuk *notebook* memungkinkan kode, penjelasan, hasil perhitungan, dan visualisasi ditempatkan dalam satu dokumen sehingga proses penelitian lebih mudah didokumentasikan (Nelson & Hoover, 2020). Dalam penelitian ini, Google Colab digunakan untuk membaca data, melakukan prapemrosesan, melatih model ADALINE dan Perceptron, menghitung hasil evaluasi, serta menampilkan visualisasi hasil pengujian.

2.2.7 *Python*



Gambar 2.4 Python

Python adalah bahasa pemrograman tingkat tinggi dan sumber terbuka yang dapat digunakan untuk berbagai tugas pengembangan perangkat lunak. *Python* memiliki *sintaks* yang sederhana dan mudah dipahami. Bahasa ini banyak digunakan di bidang analisis data, pembelajaran mesin, kecerdasan buatan, pengembangan aplikasi, dan komputasi ilmiah.

Terdapat beberapa pustaka di *Python* yang dapat membantu Anda memproses data dan mengembangkan model. Anda dapat menggunakan pustaka *Pandas* untuk membaca dan memproses data tabel. *NumPy* digunakan untuk komputasi numerik dan pemrosesan matriks. Untuk visualisasi, kami menggunakan *Matplotlib* dan *Seaborn.* Kami memanfaatkan fungsi-fungsi dari *Scikit-learn* untuk pembagian data, normalisasi, metrik evaluasi, serta pengembangan berbagai model pembelajaran mesin. Bahasa Python juga memungkinkan implementasi algoritma secara manual. Oleh karena itu, proses perhitungan nilai keluaran, perhitungan kesalahan, pembaruan bobot, dan pembaruan bias dalam model ADALINE dan Perceptron dapat dirumuskan dengan jelas.

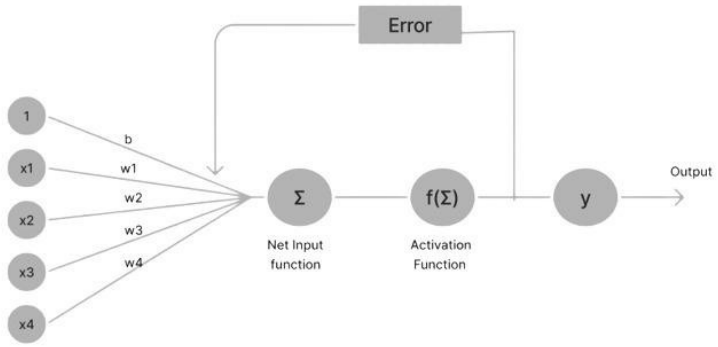
. Implementasi manual membantu peneliti memahami proses pembelajaran algoritma dan memudahkan penelusuran hasil perhitungan pada setiap iterasi (Kedia et al., 2023). Dalam penelitian ini, Python digunakan untuk mengolah data iradiansi matahari, melakukan normalisasi, membentuk data pelatihan dan pengujian, menjalankan pelatihan ADALINE dan Perceptron, serta menghitung hasil evaluasi model.

2.2.8 ADALINE (Adaptive Linear Neuron)

Adaptive Linear Neuron (ADALINE) adalah model jaringan saraf tiruan lapis tunggal (*single-layer neural network*) yang pertama kali diperkenalkan oleh Bernard Widrow dan Marcian E. Hoff Jr. pada tahun 1960. Model ini merupakan tonggak sejarah yang luar biasa dalam perkembangan kecerdasan buatan karena memperkenalkan konsep pembelajaran adaptif yang didasarkan pada minimisasi kesalahan matematis. Istilah ‘Adaptif’ berarti model ini mampu secara terus-menerus mengubah parameter internalnya (bobot dan bias) berdasarkan data yang diterimanya, sehingga memungkinkan model tersebut beradaptasi dengan pola data yang berubah-ubah (Salsabila, 2025).

Secara arsitektural, ADALINE terdiri dari tiga bagian utama: lapisan masukan, unit pemrosesan linier, dan satu lapisan keluaran. *Input* jaringan, Ynet, diperoleh dengan mengalikan setiap sinyal *input*, xi, dengan bobot koneksi yang sesuai, wi, menjumlahkan hasil perkalian tersebut, dan kemudian menambahkan bias, b. ADALINE menggunakan fungsi aktivasi linier (identitas) selama proses pelatihan, berbeda dengan Perceptron yang menggunakan fungsi langkah pada outputnya. Dengan demikian, *output* ADALINE adalah bilangan kontinu (bilangan real) yang sebanding dengan besarnya kesalahan.

Rumus pembaruan bobot pada ADALINE dinyatakan sebagai berikut:



Gambar 2.5 Adaline

$$Ynet = (x_1 . w_2) + (x_1 . w_2) + ... + (x_n . w_n) + b = \sum (x_i . w_i) + b \quad (2.2)$$

Keterangan:

Ynet = hasil penjumlahan terbobot (*net input*)

Xi = nilai *input* ke-1

Wi = bobot koneksi ke-1

b = nilai bias

n = jumlah *input*

Keunggulan utama ADALINE terletak pada metode pembaruan bobot, yaitu *Delta Rule*, yang sering dikenal sebagai *Least Mean Square* (LMS). *Delta Rule* didasarkan pada gagasan untuk meminimalkan jumlah kuadrat kesalahan (SSE) antara keluaran jaringan dan nilai target yang diprediksi. Peminimalan ini dilakukan melalui metode *Gradient Descent*, di mana bobot-bobot diperbarui secara berulang ke arah yang berlawanan dengan gradien fungsi kesalahan.

Nilai kesalahan (error) pada setiap iterasi dihitung dengan persamaan:

$$E = Target - Ynet \tag{2.3}$$

Pembaruan bobot dan bias dilakukan menggunakan aturan *Delta Rule* sebagai berikut:

$$w_i(baru) = w_i(lama) + a \,.\, E \,.\, x_i \tag{2.4}$$

$$b(baru) = b(lama) + a \,.\, E \tag{2.5}$$

w_i *(baru)* : bobot yang diperbarui

w_i *(lama)* : bobot sebelum diperbarui

α : laju pembelajaran (*learning rate*), $0 < \alpha \leq 1$

E : nilai kesalahan (error) = Target − Ynet

x_i : nilai *input* ke-i

Bobot-bobot diperbarui secara berulang untuk setiap titik data pelatihan dalam satu *epoch*. Model dianggap telah konvergen ketika kesalahan kuadrat rata-rata (MSE) telah mencapai ambang batas minimum yang telah ditentukan sebelumnya atau ketika

jumlah *epoch* telah mencapai batas maksimum yang ditetapkan. Poin utamanya adalah laju pembelajaran (α), di mana nilai yang terlalu tinggi akan menyebabkan bobot-bobot berosilasi dan tidak konvergen, sedangkan nilai yang terlalu rendah akan memperlambat proses pembelajaran.

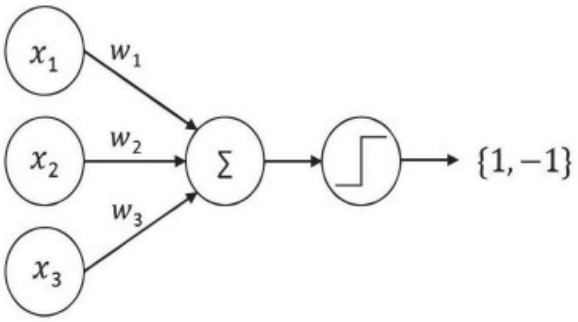
Dalam penelitian ini, ADALINE menerima satu fitur masukan berupa nilai iradiansi matahari yang telah dinormalisasi. ADALINE mempelajari hubungan antara iradiansi dan target tingkat suplai, kemudian menghasilkan nilai keluaran kontinu. Nilai kontinu tersebut digunakan untuk merepresentasikan tingkat suplai PLTS dan dipetakan secara interpretatif ke dalam kategori rendah, sedang, dan tinggi.

Kategori tingkat suplai bukan merupakan keputusan akhir status jaringan. Kategori tersebut hanya digunakan untuk memberikan interpretasi terhadap nilai keluaran ADALINE. Seluruh nilai keluaran kontinu ADALINE, baik yang termasuk kategori rendah, sedang, maupun tinggi, tetap diteruskan sebagai masukan ke Perceptron. Dengan demikian, keputusan *on-grid* atau *off-grid* tidak ditetapkan secara langsung hanya berdasarkan kategori tingkat suplai.

2.2.9 Perceptron

Perceptron adalah model jaringan saraf tiruan yang diperkenalkan oleh Frank Rosenblatt pada tahun 1958 sebagai model komputasional pertama yang mensimulasikan kemampuan neuron biologis dalam mengambil keputusan. Perceptron merupakan bentuk paling mendasar dari jaringan saraf tiruan dan menjadi fondasi bagi pengembangan arsitektur jaringan yang lebih kompleks. Dari segi fungsionalitas, Perceptron dirancang untuk melakukan klasifikasi biner, yaitu memisahkan data menjadi dua kelas yang dapat dipisahkan secara linier (Nur et al., 2021).

Arsitektur Perceptron terdiri dari tiga bagian utama: (1) lapisan masukan yang menerima vektor fitur masukan; (2) unit komputasi yang menjumlahkan semua masukan dengan bobot; dan (3) fungsi langkah yang mengubah hasil penjumlahan tersebut menjadi keputusan biner (0 atau 1). Setiap koneksi antara lapisan masukan dan unit komputasi memiliki bobot wi, yang menentukan seberapa besar variabel tersebut memengaruhi keputusan akhir.



Gambar 2.6 Perceptron

Persamaan *net input* Perceptron dinyatakan sebagai berikut:

$$z=(w_1.x_1)+(w_2.x_2)+...+(x_n.w_n)+b=\sum(w_i.x_i)+b \quad (2.6)$$

z : nilai *net input*

w_i : bobot koneksi ke-i

x_i : nilai *input* ke-i

b : nilai bias

Fungsi Aktivasi:

$$\acute{y}=\{1, jika\, z\geq\theta(threshold))\vee 0, jika\, z<\theta\} \quad (2.7)$$

$\hat{y}$: keluaran prediksi Perceptron (0 atau 1)

z : nilai *net input*

θ : nilai ambang batas (*threshold*), umumnya θ = 0

Proses pembelajaran Perceptron bekerja berdasarkan Aturan Pembelajaran Perceptron, di mana bobot-bobotnya hanya diperbarui ketika model melakukan kesalahan dalam prediksinya (ketika keluaran yang diprediksi (ŷ) tidak sama dengan label target (y)). Hal ini berbeda dengan ADALINE, di mana bobot-bobotnya diperbarui pada setiap iterasi menggunakan ukuran kesalahan yang berkelanjutan.

Aturan pembaruan bobot dan bias Perceptron adalah:

$$w_i(baru) = w_i(lama) + \eta . (y - \acute{y}) . x_i \tag{2.8}$$

$$b(baru) = b(lama) + \eta . (y - \acute{y}) \tag{2.9}$$

w_i *(baru)* : bobot yang diperbarui
w_i *(lama)* : bobot sebelum diperbarui
η : laju pembelajaran (*learning rate*)
y : label target aktual (0 atau 1)
$\hat{y}$: keluaran prediksi model (0 atau 1)
x_i : nilai *input* ke-i

Proses pelatihan Perceptron akan berhenti ketika seluruh data latih berhasil diklasifikasikan dengan benar (*zero misclassification*), atau ketika jumlah *epoch* maksimum telah tercapai. Teorema konvergensi Perceptron menyatakan bahwa algoritma ini dijamin konvergen apabila data latih bersifat *linearly separable*. Namun apabila data tidak dapat dipisahkan secara linier, Perceptron tidak akan konvergen dan memerlukan transformasi fitur atau penggunaan arsitektur yang lebih kompleks.

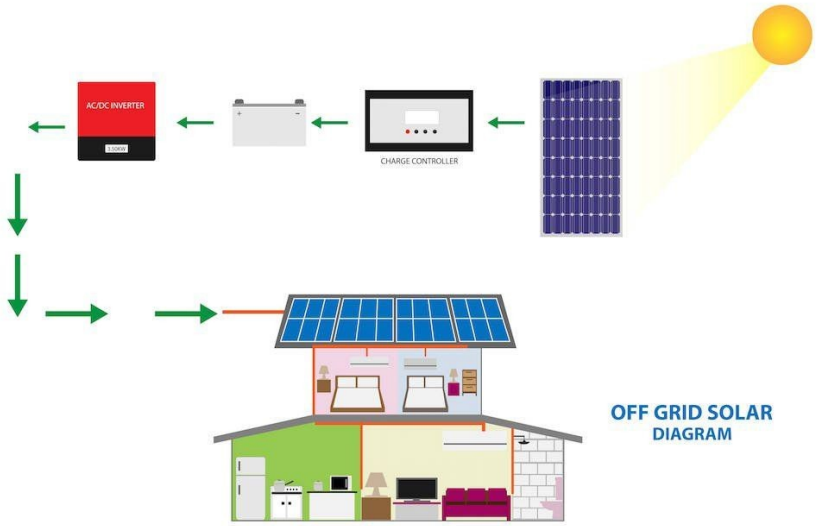
Dalam penelitian ini, Perceptron digunakan setelah proses ADALINE. Masukan Perceptron berasal dari nilai keluaran kontinu ADALINE untuk setiap sampel. Perceptron kemudian mempelajari target keputusan biner dan menghasilkan rekomendasi status *on-grid* atau *off-grid*.

Seluruh data tetap melewati proses perhitungan Perceptron. Dengan demikian, data yang dikategorikan sebagai suplai rendah tidak langsung ditetapkan sebagai *off-grid* dan data yang dikategorikan sebagai suplai tinggi tidak langsung ditetapkan sebagai *on-grid*. Keputusan akhir tetap diperoleh dari hasil perhitungan nilai aktivasi, bobot, bias, dan fungsi ambang Perceptron.

Keluaran Perceptron pada penelitian ini merupakan rekomendasi berbasis simulasi. Nilai tersebut tidak digunakan untuk mengaktifkan kontaktor, mengendalikan

inverter, menghubungkan PLTS ke jaringan listrik, atau memutuskan jaringan secara fisik.

2.2.10 Off Grid



Gambar 2.7 *Off-Grid*

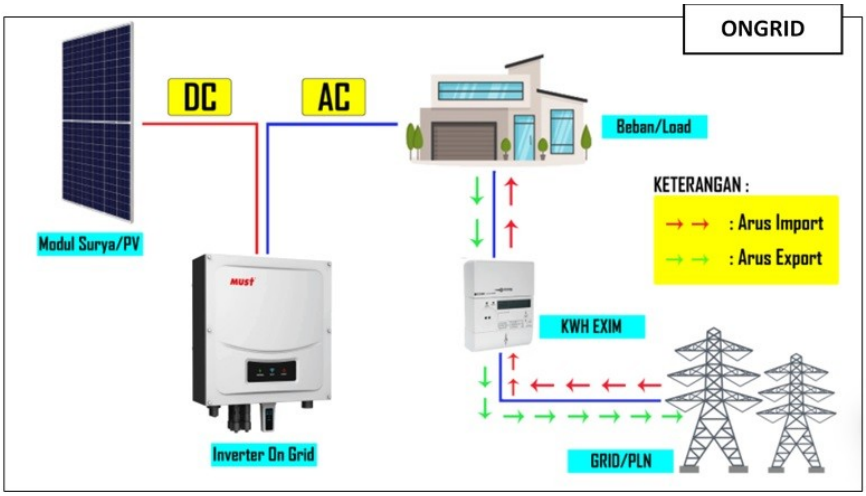
Sistem tenaga surya *off-grid* adalah sistem pasokan listrik mandiri yang tidak terhubung ke jaringan listrik. Panel surya menyediakan daya untuk memenuhi kebutuhan beban, dan daya tersebut dapat disimpan dalam baterai untuk digunakan saat intensitas sinar matahari tidak mencukupi. Teknologi ini umumnya digunakan di daerah terpencil atau tempat-tempat yang belum terhubung ke jaringan listrik utama (Hayusman & Saputera, 2022).

Unsur-unsur dasar sistem tenaga surya *off-grid* terdiri dari panel surya, pengatur pengisian daya surya, baterai, inverter, sistem keamanan, dan beban. Panel surya mengisi daya baterai dengan listrik arus searah (DC). Pengatur pengisian daya surya mengelola proses pengisian daya. Inverter mengubah arus baterai menjadi listrik arus bolak-balik (AC), atau baterai dapat digunakan secara langsung untuk menyalakan beban DC.

Karena tidak ada sambungan ke jaringan listrik utama, panel surya dan baterai harus disesuaikan dengan kebutuhan beban pada sistem *off-grid*. Jika energi yang dihasilkan oleh panel dan disimpan dalam baterai tidak mencukupi, beban dapat mengalami kekurangan pasokan listrik.

Dalam penelitian ini, istilah *off-grid* tidak menunjukkan bahwa sistem PLTS benar-benar diputus dari jaringan listrik. Istilah tersebut digunakan sebagai salah satu label rekomendasi yang dihasilkan oleh Perceptron berdasarkan pola data yang dipelajari.

2.2.11 On Grid



Gambar 2.8 *On-Grid*

Apa itu sistem tenaga surya terhubung jaringan? Sistem tenaga surya terhubung jaringan adalah sistem tenaga surya yang terhubung ke jaringan listrik utama. Energi yang dihasilkan oleh panel surya dapat dimanfaatkan untuk memenuhi kebutuhan beban, dan kekurangan energi apa pun dapat dipenuhi oleh jaringan listrik utama. Dalam skenario tertentu, apabila konfigurasi peralatan dan peraturan yang berlaku mengizinkannya, kelebihan energi dari sistem tenaga surya tersebut dapat disalurkan ke jaringan listrik.

Sistem PLTS *on-grid* umumnya menggunakan *grid-tie inverter*. *Inverter* mengubah arus searah (DC) dari panel surya menjadi arus bolak-balik (AC) yang memiliki tegangan, frekuensi, dan fasa yang sama dengan jaringan listrik. Sistem ini perlu disinkronkan agar dapat beroperasi dengan aman saat terhubung ke jaringan listrik utama (David et al., 2024).

Sistem *on-grid* juga memerlukan perangkat proteksi. Prosedur perlindungan gangguan jaringan utama diterapkan untuk mencegah situasi yang dapat membahayakan peralatan atau manusia. Perlindungan *anti-islanding* merupakan mekanisme perlindungan yang sangat penting, yang memungkinkan *inverter* menghentikan

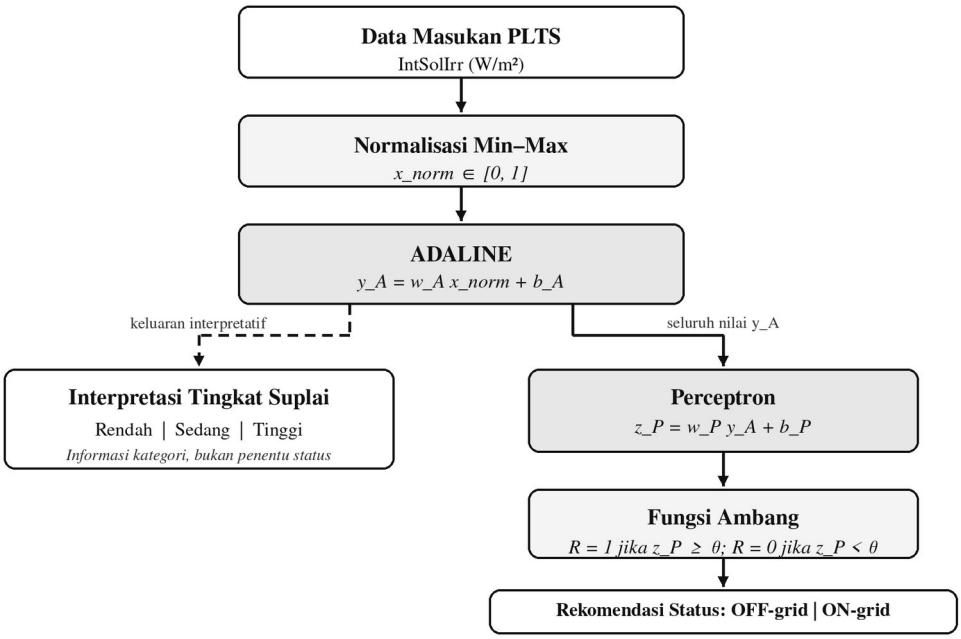
penyaluran daya ke jaringan ketika jaringan listrik utama tidak tersedia. Sistem yang terhubung ke jaringan dapat mengurangi penggunaan daya dari jaringan ketika pembangkit listrik tenaga surya menghasilkan energi yang cukup. Namun, pengoperasian sistem ini harus mempertimbangkan spesifikasi *inverter*, kualitas daya, sistem proteksi, dan ketentuan interkoneksi yang berlaku.

Dalam penelitian ini, istilah *on-grid* digunakan sebagai label rekomendasi berbasis simulasi. Hasil penelitian tidak digunakan untuk melakukan sinkronisasi inverter atau menghubungkan PLTS dengan jaringan listrik utama secara langsung.

2.2.12 Integrasi ADALINE dan Perceptron

Urutan model ADALINE-Perceptron merupakan kombinasi dari dua teknik jaringan saraf tiruan yang digunakan secara berurutan. Pada tahap pertama, ADALINE digunakan untuk menghasilkan nilai kontinu yang menunjukkan tingkat pasokan pembangkit listrik tenaga surya. Pada tahap kedua, Perceptron digunakan untuk memberikan rekomendasi biner berupa ‘*on-grid*’ atau ‘*off-grid*’.

Perbedaan sifat keluaran inilah yang menjadi alasan penggunaan kedua algoritma tersebut. ADALINE didasarkan pada fungsi linier dan proses pembelajaran yang menggunakan *mean squared error*, sehingga cocok untuk pengembangan representasi kontinu. Sebaliknya, Perceptron menggunakan fungsi ambang batas yang membuatnya ideal untuk menghasilkan keluaran dengan dua kategori. Dengan demikian, ADALINE digunakan untuk menyajikan tingkat pasokan yang lebih stabil, sedangkan Perceptron digunakan untuk menghasilkan rekomendasi akhir.



Gambar 2.9 Arsitektur Integrasi ADALINE dan Perceptron

Tahap pertama dimulai dengan memasukkan nilai-nilai masukan yang telah dinormalisasi dari sistem PV ke dalam ADALINE. Nilai-nilai masukan tersebut dikalikan dengan bobot-bobot dan ditambahkan istilah bias untuk mendapatkan keluaran linier. Secara sederhana, keluaran ADALINE untuk satu fitur dapat ditulis sebagai berikut:

$$yA = wA\ x + bA \tag{2.10}$$

yA = keluaran kontinu ADALINE;

x = nilai iradiansi yang telah dinormalisasi;

wA = bobot ADALINE;

bA = bias ADALINE.

Oleh karena itu, keluaran kontinu dari ADALINE diinterpretasikan sebagai tingkat pasokan rendah, sedang, dan tinggi. Pemetaan ini—bukan pilihan akhir dari jaringan—memudahkan pemahaman terhadap kondisi pasokan. Ambang batas numerik masing-masing kategori dibahas dalam Bab III karena merupakan bagian dari rancangan dan pelaksanaan penelitian.

Output kontinu dari ADALINE kemudian dimasukkan ke dalam Perceptron. Semua sampel diberikan kepada Perceptron tanpa menganggap kategori rendah, sedang,

atau tinggi sebagai penilaian akhir. Nilai aktivasi Perceptron dapat ditulis sebagai berikut:

$$zP = wP\ yA + bP \tag{2.11}$$

zP = nilai aktivasi Perceptron;

yA = keluaran kontinu ADALINE;

wP = bobot Perceptron;

bP = bias Perceptron.

Keluaran rekomendasi ditentukan melalui fungsi ambang sebagai berikut.

$$R = 1 \text{ jika } zP \geq \theta;\ R = 0 \text{ jika } zP < \theta \tag{2.12}$$

R = hasil rekomendasi;

R = 1 merepresentasikan rekomendasi *on-grid*;

R = 0 merepresentasikan rekomendasi *off-grid*;

θ = nilai ambang Perceptron.

Seluruh keluaran ADALINE disalurkan ke Perceptron sehingga setiap titik data tetap melalui proses perhitungan. Dengan demikian, kesimpulan akhir tidak ditentukan secara langsung oleh kategori klasifikasi. Namun, nilai-nilai kontinu ADALINE dapat berbeda meskipun dua titik data termasuk dalam kategori tingkat pasokan yang sama. Hal ini berarti bahwa proses Perceptron akan tetap memperhitungkan hasil perhitungan dari setiap titik data.

Alur kerja model dalam penelitian ini melibatkan data radiasi matahari, proses normalisasi, pelatihan ADALINE, pembangkitan nilai kontinu, interpretasi tingkat pasokan rendah, sedang, atau tinggi, serta proses klasifikasi biner dengan Perceptron. Hasil program berupa kategori tingkat pasokan dan saran apakah sistem tersebut sebaiknya terhubung ke jaringan (*on-grid*) atau tidak terhubung ke jaringan (*off-grid*).

ADALINE dilatih dengan memanfaatkan metrik kesalahan seperti MSE dan grafik tren kesalahan selama proses pelatihan. Sementara itu, Perceptron dapat dievaluasi menggunakan matriks kebingungan, akurasi, presisi, *recall*, dan skor F1. Pengujian ini dilakukan untuk menentukan kemampuan model dalam mempelajari kategori target yang didefinisikan dalam data penelitian.

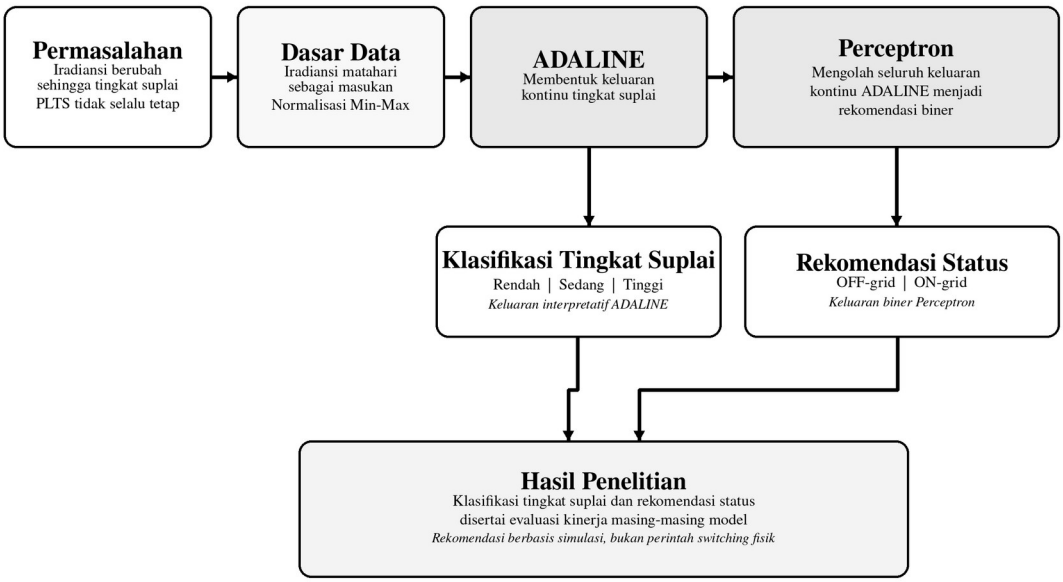
Keterbatasan dari saran yang diperoleh Penelitian ini hanya memasukkan radiasi matahari sebagai fitur. Model ini tidak memperhitungkan hal-hal berikut sebagai masukan: kondisi baterai, permintaan beban, tegangan, arus, daya keluaran panel aktual,

efisiensi inverter, dan status jaringan energi. Oleh karena itu, hasil '*on-grid*' atau '*off-grid*' harus ditafsirkan sebagai label rekomendasi berbasis simulasi, bukan keputusan operasional untuk mengalihkan jaringan fisik.

2.3 Kerangka Berpikir

Perubahan iradiansi matahari menyebabkan potensi suplai energi PLTS berubah dari waktu ke waktu. Dalam penelitian ini, nilai iradiansi digunakan sebagai indikator masukan untuk memperoleh dua bentuk informasi yang berbeda, yaitu klasifikasi tingkat suplai secara bertahap dan rekomendasi status jaringan secara biner. Kebutuhan tersebut menjadi dasar penggunaan dua algoritma yang memiliki karakteristik keluaran berbeda dan saling melengkapi.

Nilai iradiansi terlebih dahulu dinormalisasi menggunakan Min-Max. ADALINE kemudian menghasilkan keluaran kontinu yang diinterpretasikan menjadi tingkat suplai rendah, sedang, atau tinggi. Seluruh keluaran kontinu ADALINE diteruskan ke Perceptron untuk menghasilkan rekomendasi *OFF-grid* atau *ON-grid*. Hubungan antara permasalahan, pendekatan, dan keluaran penelitian ditunjukkan pada Gambar 2.10.



Gambar 2.10 Kerangka Berpikir Penelitian

Kerangka berpikir tersebut menegaskan bahwa kategori tingkat suplai tidak menentukan rekomendasi secara langsung. Perceptron tetap mengolah keluaran kontinu ADALINE pada setiap data. Kinerja keluaran ADALINE dan Perceptron selanjutnya dievaluasi untuk menilai kemampuan model menjawab tujuan penelitian. Rekomendasi yang dihasilkan terbatas pada simulasi perangkat lunak dan tidak merupakan perintah untuk melakukan *switching* jaringan listrik secara fisik.