BAB II
TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Dalam penelitian terkait pembahasan mengenai prakiraan *output* daya PLTS yang sudah pernah dilakukan pada penelitian terdahulu, berikut beberapa penelitian tersebut :

1. Penelitian yang dilakukan oleh (Zhao, 2024) terbit pada jurnal *Journal of Electrotechnology, Electrical Engineering and Management* dengan judul "Urban Electricity Consumption Forecasting Based on SARIMA and *Random Forest* Modeling" membahas prakiraan konsumsi listrik perkotaan menggunakan model *Hybrid* yang menggabungkan metode statistik SARIMA dan algoritma *machine learning* Random Forest. Dalam penelitian ini, SARIMA digunakan untuk memodelkan pola tren dan musiman pada data time series, sedangkan *Random Forest* digunakan untuk menangkap hubungan non-linear antara konsumsi listrik dan faktor lingkungan. Hasil penelitian menunjukkan bahwa model *Hybrid* mampu meningkatkan akurasi prediksi dibandingkan model SARIMA tunggal, dengan penurunan nilai Mean Absolute Error (MAE) dari 944,903 menjadi 562,767 atau meningkat sekitar 40%. Hasil tersebut menunjukkan bahwa penggabungan metode statistik dan *machine learning* dapat menghasilkan model prakiraan energi yang lebih akurat[4].
2. Penelitian yang dilakukan oleh (Pombo et all., 2022) yang terbit pada jurnal *Sensors* dengan judul "*Physics-Informed Machine learning for Day-Ahead and Multi-Day-Ahead Forecasting of Photovoltaic Power Generation*", membahas mengenai prakiraan daya keluaran sisem *Photovoltaic* (PV) dengan memeanfaatkan pendekatan *Physics-Informed Machine learning* (PIML). Penelitian ini menggunakan data operasional PLTS yang dikombinasikan dengan beberapa parameter lingkungan seperti suhu, kecepatan angin, dan daya keluaran sistem PV. Dalam peneilitian ini, infomasi berbasis fisika sistem PV digunakan sebagai fitur tambahan untuk meningkatkan kemampuan model *machine learning* dalam melakukan prediksi. Beberapa algoritma yang digunakan antara lain *Random Forest, Support Vector Machine* (SVM), *Convolutional Neural Network* (CNN), *Long Short-*

Term Memory (LSTM), serta model *Hybrid* CNN-LSTM. Hasil penelitian menunjukkan penerapan pendekatan PIML mampu meningkatkan kinerja model prakiraan dengan nilai kesalahn prediksi *Root Mean Square Error* (RMSE) terbaik sekitar 7,5%, yang menunjukkan bahwa model mampu menghasilkan prediksi daya PV dengan Tingkat kesalahan relatif rendah[5].

3. Penelitian yang dilakukan oleh (Ardianto et all., 2022) yang diterbitkan pada jurnal BRILIANT dengan judul " *Random Forest Regression untuk Prediksi Produksi Daya Pembangkit Listrik Tenaga Surya*". Penelitian ini membahas mengenai prediksi produksi daya pada PLTS menggunakan metode *machine learning Random Forest Regression.* Data yang digunakan untuk penelitian ini berasal dari sistem SCADA dengan parameter lingkungan seperti radiasi matahari, suhu, dan kecepatan angin selama periode satu tahun. Penelitian ini juga membandingkan algoritma lain seperti *Linear Regression*, *Decision Tree Regression*, dan *Gradient Boosting Trees* untuk melihat metode yang memberikan hasil prediksi terbaik. Hasil penelitian menunjukkan dengan menggunakan *Random Forest Regression* performa prediksi yang diberikan sangat baik dengan nilai RMSE sebesar 0,0438 atau 4,38%, sehingga metode ini dinilai efektif dalam memprediksi produksi daya listrik sistem PLTS[6].
4. Penelitian yang dilakukan oleh (Kushwaha & Pindoriya, 2019) yang terbit pada jurnal *Renewable Energy* dengan judul *"A SARIMA–RVFL Hybrid Model Assisted by Wavelet Decomposition for Very Short-Term Solar PV Generation Forecast"*, membahas mengenai prakiraan daya keluaran sistem *Photovoltaic* (PV) dalam jangka waktu sangat pendek dengan memanfaatkan pendekatan model *Hybrid* yang menggabungkan metode statistik dan *machine learning*. Penelitian ini didasarkan pada meningkatnya pemanfaatan energi surya dengan tatangan fluktuasi daya keluaran PLTS akibat perubahan cuaca dan radiasi matahari. Penelitian ini mengusulkan pendekatan model *Hybrid* dengan *Seasonal Autoregressive Integrated Moving Average* (SARIMA), *Random Vector Functional Link* (RVFL), serta teknik *Wavelet Decomposition* sebagai tahap pra-pemrosesan pengolahan data. Hasil penelitian menunjukkan bahwa model *Hybrid* yang menggabungkan *wavelet decomposition*, SARIMA, dan RVFL mampu memberikan akurasi prakiraan yang lebih tinggi dibandingkan model tunggal. Model *persistence* menghasilkan tingkat

kesalahan yang relatif tinggi, sedangkan penggunaan model SARIMA dan RVFL mampu menurunkan nilai kesalahan prediksi secara signifikan. Setelah dikombinasikan dengan teknik *wavelet decomposition*, performa model semakin meningkat, dan model *Hybrid* yang diusulkan menghasilkan nilai kesalahan prediksi paling rendah dengan nilai MAPE sekitar 4–5%. Hal ini menunjukkan bahwa pendekatan *Hybrid* mampu menangkap pola *linear*, musiman, serta *non-linear* yang terdapat pada data produksi daya PV dengan lebih baik[7].

5. Penelitian yang dilakukan oleh (Kushwaha & Pindoriya, 2017) yang diterbikan pada konferensi IEEE dengan Judul "*Very Short-Term Solar Pv Generation Forecast Using SARIMA Model : A Case Study"*. Penelitian ini membahas mengenai prakiraan daya keluaran PLTS dalam jangka waktu sangat pendek dengan metode *Seasonal Autoregressive Integrated Moving Averange* (SARIMA). Data yang digunakan dalam penelitian ini berasal dari sistem PLTS di kampus IIT Gandhinagar, India, yang mencatat produksi daya dari beberapa instalasi PV seperti gedung akademik dan asrama mahasiswa dengan interval waktu 20 menit. Penelitian ini juga membandingkan kinerja model SARIMA dengan *persistence* model sebagai metode pembanding yang lebih sederhana. Hasil penelitian menunjukkan bahwa model SARIMA mampu memberikan performa prakiraan yang lebih baik dibandingkan *persistence* model dengan nilai *Modified Mean Absolute Percentage Error* (MAPE) sekitar 3,39% untuk prediksi satu langkah ke depan, sehingga metode ini dinilai cukup efektif untuk memprediksi *output* daya pada pembangkit listrik tenaga surya dalam jangka waktu sangat pendek[8].

Tabel 2. 1 Penelitian Terdahulu yang Digunakan

Judul	Objek	Metodologi	Hasil	Pembeda
Urban Electricity Consumption Forecasting Based on SARIMA and Random Forest Modeling	Peramalan konsumsi listrik perkotaan menggunakan dataset konsumsi listrik dari kota Tetouan, Maroko yang mencakup variabel lingkungan seperti suhu, kelembapan, dan kecepatan angin	Penelitian menggunakan pendekatan *Hybrid* antara model statistik SARIMA dan algoritma *machine learning* Random Forest. Penelitian ini juga menerapkan data preprocessing dan feature engineering.	Hasil penelitian menunjukkan bahwa model *Hybrid* mampu meningkatkan akurasi prediksi dibandingkan model tunggal. Nilai kesalahan *Mean Absolute Error* (MAE) pada model SARIMA sebesar 944.903, sedangkan pada model *Hybrid* menurun menjadi 562.767, atau meningkat sekitar 40% dalam hal akurasi prediksi	Penelitian ini menekankan bahwa penggabungan model statistik time series dengan algoritma *machine learning* mampu meningkatkan kemampuan model dalam menangkap pola *linear* dan non-*linear* pada data energi, sehingga menghasilkan prediksi yang lebih akurat.
Physics-Informed Machine learning for Day-Ahead and Multi-Day-Ahead Forecasting of Photovoltaic	Sistem pembangkit listrik tenaga surya (*Photovoltaic*/PV) u ntuk memprediksi daya keluaran berdasarkan data operasional dan kondisi lingkungan.	Menggunakan pendekatan *Physics-Informed Machine learning* (PIML) dengan algoritma *Random Forest*, SVM, CNN, LSTM, dan CNN-LSTM untuk	Model menghasilkan performa prediksi yang baik dengan nilai *Root Mean Square Error* (RMSE) terbaik sekitar 7,5%.	Penelitian ini menitikberatkan pada penerapan *Physics-Informed Machine learning* dengan berbagai algoritma *machine learning* untuk meningkatkan

Judul	Objek	Metodologi	Hasil	Pembeda
Power Generation		memprediksi daya PV dengan memanfaatkan fitur berbasis model fisika.		akurasi peramalan daya PV.
Random Forest Regression untuk Prediksi Produksi Daya Pembangkit Listrik Tenaga Surya	Produksi daya listrik PLTS menggunakan hisoris sistem SCADA selama satu tahun.	Menggunakan metode *machine learing* dengan membandingkan algoritma regresi yaitu *Random Forest Regresion* (RFR), *Gradient Boosting Tree* (GBT), *Decision Tree Regression* (DTR), *dan Linear Regression* (LR) untuk prediksi *output* daya PLTS berdasarkan data historis.	Hasil penelitian menunjukkan bahwa model *Random Forest Regression* Dan *Gradient Boosing Trees* memberikan performa terbaik dengan nilai RMSE sebesar 0,0438 atau 4,38% yang menunjukkan Tingkat akurasi prediksi yang sangai baik	Penelitian ini berfokus pada perbandingan beberapa algoritma *machine learning* untuk meningkatkan akurasi produksi energi surya pada sistem PLTS, dengan memanfaatkan data sensor serta berbagai skenario pengolahan data dalam proses pemodelan.
A SARIMA–RVFL Hybrid Model Assisted by	Peramalan daya keluaran sistem *Photovoltaic* (PV) pada PLTS	Model *Hybrid* yang menggabungkan *Sea sonal Autoregressive Integrated Moving*	Model *Hybrid* menghasilkan akurasi peramalan yang lebih baik dibandingkan model	Pemodelan dilakukan dengan mengombinasikan *w avelet decomposition*,

Judul	Objek	Metodologi	Hasil	Pembeda
Wavelet Decomposition for Very Short-Term Solar PV Generation Forecast	di Indian Institute of Technology Gandhinagar, India	*Average* (SARIMA), *Random Vector Functional Link* (RVFL), dan *Wavelet Decomposition* seba gai tahap pra-pemrosesan data	tunggal dengan nilai kesalahan prediksi sekitar 4–5% MAPE dan RMSE lebih rendah	SARIMA, RVFL untuk menangkap pola *linear*, musiman, dan *non-linear* pada data PV.
Very Short-Term Solar PV Generation Forecast Using SARIMA Model: A Case Study	Peramalan daya keluaran sistem *Photovoltaic* (PV) pada instalasi PLTS di kampus IIT Gandhinagar, India.	Menggunakan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) untuk melakukan peramalan multi-step dengan interval data 20 menit..	Model SARIMA mengha silkan performa prediksi yang lebih baik dibandingkan persistence model dengan nilai *Modified* MAPE sekitar 3,39% untuk prediksi satu langkah ke depan, menunjukkan bahwa metode ini cukup efektif untuk peramalan	Penelitian ini menggunakan pemod elan *time series* SARIMA untuk peramalan daya PV jangka pendek.

2.1.2 Pembangkit Listrik Tenaga Surya (PLTS)

Pembangkit Listrik Tenaga Surya (PLTS) adalah teknologi pembangkit listrik yang menggunakan energi radiasi matahari sebagai sumber utama. Sistem ini termasuk energi terbarukan karena sumbernya berasal dari matahari yang tersedia secara alami dan berkelanjutan. PLTS memanfaatkan teknologi fotovoltaik (*Photovoltaic*/PV) untuk mengubah energi cahaya matahari langsung menjadi listrik tanpa proses mekanik. Penggunaan PLTS semakin meluas karena memberikan solusi ramah lingkungan untuk kebutuhan listrik dan mengurangi ketergantungan pada energi fosil[9].

Prinsip kerja PLTS didasarkan pada efek fotovoltaik yang terjadi di sel surya. Sel surya merupakan semikonduktor yang biasanya terbuat dari silikon, dan mampu menyerap energi cahaya. Ketika cahaya matahari menyinari permukaan sel surya, foton yang terkandung di dalamnya mentransfer energinya ke elektron dalam semikonduktor. Energi ini menyebabkan elektron berpindah dari posisi awal, sehingga terbentuk pasangan elektron dan hole. Pergerakan elektron bebas menghasilkan arus listrik searah atau *Direct Current* (DC). Tegangan yang dihasilkan oleh satu sel surya relatif kecil sehingga, beberapa sel surya biasanya disusun secara seri dan paralel untuk membentuk modul atau panel surya yang dapat menghasilkan tegangan dan daya listrik lebih besar sesuai kebutuhan sistem.

Dalam sistem PLTS, terdapat beberapa komponen utama yang berperan dalam pembangkitan, pengolahan, dan penyimpanan listrik. Komponen pertama adalah panel surya berfungsi untuk menyerap energi radiasi matahari dan mengkonversinya menjadi energi listrik dalam bentuk DC (arus searah). Panel surya terdiri dari sejumlah sel fotovoltaik yang dirangkai dalam modul, sehingga mampu menghasilkan tegangan dan arus listrik tertentu. Kapasitas daya yang dihasilkan oleh panel bergantung pada jumlah sel, luas permukaan modul, dan intensitas cahaya matahari yang diterima.

Komponen berikutnya adalah inverter yang mengonversi arus listrik searah (DC) yang dihasilkan panel surya menjadi arus bolak-balik (AC). Proses ini penting karena sebagian besar peralatan listrik yang digunakan di rumah dan industri membutuhkan arus AC sebagai sumber energi. Selanjutnya, *charge controller* adalah komponen yang mengatur aliran listrik dari panel surya ke baterai atau beban. Perangkat ini menjaga kestabilan tegangan dan melindungi baterai dari kondisi pengisian berlebihan atau

pengosongan yang terlalu dalam. Dengan adanya *charge controller*, kinerja sistem PLTS menjadi lebih stabil dan umur pakai baterai bisa lebih lama. Sistem PLTS juga sering dilengkapi dengan penyimpanan energi berupa baterai. Baterai menyimpan listrik yang dihasilkan saat panel surya berada di kondisi maksimum. Energi yang tersimpan dapat digunakan ketika produksi listrik dari panel surya menurun, seperti di malam hari atau saat intensitas radiasi matahari rendah.

Pada sistem PLTS, konversi energi dimulai saat panel surya menyerap radiasi matahari dan mengubahnya menjadi listrik arus DC melalui efek fotovoltaik. Listrik tersebut kemudian dapat dimanfaatkan secara langsung, dikonversi menjadi arus AC melalui *inverter*, atau disimpan dalam baterai sebagai cadangan energi [9].

Output daya dari sistem PLTS tidak selalu konstan. Ini dipengaruhi oleh berbagai faktor lingkungan dan karakteristik sistem. Faktor utama adalah intensitas radiasi matahari, yang menentukan jumlah energi yang dapat diserap. Suhu permukaan panel juga memengaruhi efisiensi sel surya, peningkatan suhu umumnya mengurangi efisiensi konversi energi listrik. Faktor lain yang memengaruhi termasuk sudut kemiringan dan orientasi panel terhadap posisi matahari, kondisi cuaca seperti tutupan awan, dan kebersihan permukaan panel yang berpengaruh pada kemampuan penyerapan cahaya. Variasi faktor-faktor tersebut membuat *output* daya PLTS fluktuatif.

2.1.2.1 Variabel yang Mempengaruhi *Output* Daya Pada Sistem PLTS

Output daya pada sistem Pembangkit Listrik Tenaga Surya (PLTS) dipengaruhi oleh berbagai faktor, baik yang berasal dari kondisi lingkungan maupun dari karakteristik teknis sistem fotovoltaik itu sendiri. Beberapa variabel tersebut dapat dijelaskan sebagai berikut:

1. Intensitas Radiasi Matahari (*Solar Irradiance*)

   Produksi daya pada modul fotovoltaik sangat dipengaruhi oleh intensitas radiasi matahari. Besarnya radiasi yang diterima di permukaan bumi bervariasi antar lokasi, tergantung pada spektrum sinar matahari yang mencapai bumi. Peningkatan radiasi yang diterima panel akan meningkatkan energi listrik yang dihasilkan, yang biasanya dinyatakan dalam satuan W/m^2.[10].

2. Suhu Modul Surya

   Suhu permukaan modul memiliki pengaruh signifikan terhadap efisiensi panel. Pada teknologi *Photovoltaic* (PV), peningkatan suhu modul biasanya menyebabkan penurunan tegangan keluaran sehingga daya yang dihasilkan juga menurun. Kinerja maksimum panel surya dicapai pada suhu normal 25°C. Peningkatan suhu di atas nilai tersebut akan mengakibatkan penurunan tegangan open circuit, di mana setiap kenaikan 1°C dapat mengurangi daya keluaran hingga sekitar 0,5%[11].

3. Sudut Kemiringan dan Orientasi Panel

   Sudut kemiringan (*tilt angle*) dan orientasi panel surya merupakan faktor penting yang mempengaruhi jumlah radiasi matahari yang diterima oleh modul fotovoltaik. Penentuan sudut kemiringan yang sesuai dengan kondisi geografis lokasi pemasangan dapat membantu panel menerima radiasi matahari secara lebih optimal sepanjang waktu. Selain itu, arah orientasi panel terhadap matahari juga menentukan intensitas sinar matahari yang mengenai permukaan modul. Perbedaan sudut kemiringan dan orientasi panel dapat menyebabkan variasi pada jumlah energi listrik yang dihasilkan, sehingga pengaturan posisi panel yang tepat sangat penting untuk meningkatkan kinerja dan *output* daya sistem PLTS[12].

4. Kondisi Atmosfer dan Lingkungan

   Faktor lingkungan seperti tutupan awan, aerosol, dan debu turut mempengaruhi kinerja sistem PLTS. Awan dapat mengurangi jumlah radiasi matahari yang mencapai permukaan panel surya, sedangkan aerosol dan partikel debu di udara dapat menyerap maupun menghamburkan radiasi sebelum sampai ke modul fotovoltaik. Selain itu, debu yang menumpuk pada permukaan panel juga dapat menghalangi cahaya matahari yang diterima oleh sel surya. Hal tersebut menyebabkan efisiensi sistem menurun sehingga daya listrik yang dihasilkan oleh PLTS menjadi lebih kecil[13].

5. Kecepatan Tiupan Angin

   Kecepatan angin di sekitar panel surya berperan dalam membantu proses pendinginan alami pada permukaan panel. Aliran udara yang melewati permukaan modul dapat mengurangi peningkatan suhu yang terjadi akibat paparan radiasi matahari. Dengan adanya pendinginan ini, suhu panel dapat tetap berada pada kondisi yang lebih stabil dan tidak terlalu tinggi. Suhu panel yang lebih rendah dapat membantu menjaga

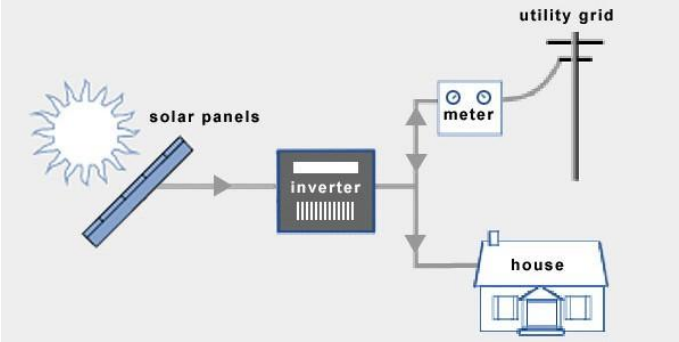
efisiensi kerja sel fotovoltaik sehingga kinerja sistem PLTS tetap optimal dan *output* daya yang dihasilkan tidak mengalami penurunan yang signifikan[6].

2.1.2.2 Klasifikasi PLTS Berdasarkan Jenis Sistem Operasinya

Sistem Pembangkit Listrik Tenaga Surya (PLTS) dapat dikelompokkan berdasarkan cara pengoperasiannya dalam sistem kelistrikan. Berdasarkan metode operasinya PLTS dibagi menjadi tiga jenis, yaitu PLTS *On-Grid*, PLTS *Off-grid* (*stand-alone*), dan PLTS *Hybrid*, yang masing-masing memiliki karakteristik dan mekanisme operasi yang berbeda dalam penyediaan energi listrik [14].

1. PLTS *On-Grid*

   PLTS *On-Grid* yang dikenal juga sebagai *grid-connected* PV, merupakan sistem tenaga surya yang terintegrasi langsung dengan jaringan listrik utama seperti PLN. Berdasarkan pola penyaluran energinya, sistem ini dibedakan menjadi dua jenis, yaitu *grid-connected* PV dengan baterai (*battery backup*) dan *grid-connected* PV tanpa baterai[11].



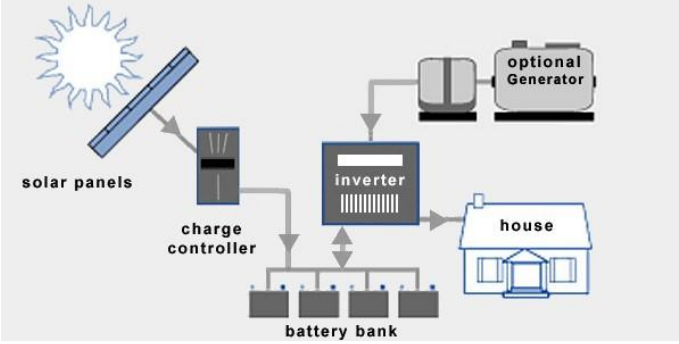
Gambar 2. 1 Skema PLTS *On-Grid*

   Berdasarkan penerapannya, PLTS *On-Grid* juga dibedakan menjadi *grid-connected distributed* PV yang umumnya dipasang pada bangunan skala kecil, dan *grid-connected centralized* PV yang digunakan sebagai pembangkit listrik terpusat dalam skala besar. Sistem ini memanfaatkan energi matahari untuk menghasilkan listrik yang ramah lingkungan, bebas emisi, serta memungkinkan pemanfaatan energi secara lebih optimal melalui integrasi dengan jaringan listrik.

2. PLTS *Off Grid*

   PLTS *Off-Grid* merupakan sistem tenaga surya yang bekerja secara independen tanpa koneksi ke jaringan listrik utama, seperti PLN, dan dikenal sebagai *stand-alone*

system. Sistem ini memanfaatkan energi matahari melalui modul fotovoltaik sebagai sumber utama energi listrik dan umumnya dipasang secara tersebar dengan kapasitas pembangkitan yang relatif kecil yang dilengkapi dengan batrai sebagai media penyimpanan.

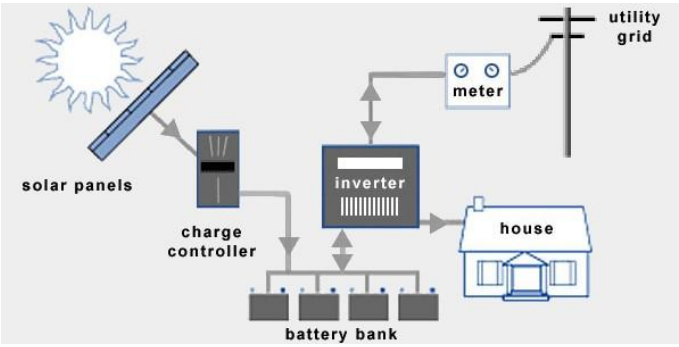


Gambar 2. 2 Skema PLTS *Off- Grid*

Sistem PLTS *off-grid* beroperasi tanpa terhubung dengan jaringan PLN karena energi listrik yang dihasilkan disimpan dalam baterai. Hal ini memungkinkan sistem tetap berjalan secara stabil meskipun terjadi pemadaman dari jaringan utama. Berdasarkan pemanfaatannya, sistem ini dibagi menjadi PLTS *off-grid* domestik untuk rumah tangga dan non-domestik untuk keperluan industri atau wilayah terpencil yang belum memiliki akses listrik PLN.

3. PLTS *Hybrid*

   PLTS *Hybrid* merupakan sistem pembangkit listrik tenaga surya yang menggabungkan dua atau lebih sumber pembangkit listrik dengan jenis energi yang berbeda dalam satu sistem operasi.



Gambar 2. 3 Skema PLTS *Hybrid*

Integrasi ini bertujuan untuk memanfaatkan keunggulan masing-masing sumber energi sehingga dapat meningkatkan keandalan, kestabilan pasokan listrik, serta efisiensi ekonomi dalam penyediaan energi. Beberapa contoh kombinasi yang umum digunakan dalam sistem PLTS *Hybrid* antara lain PLTS genset, PLTS *mikrohidro*, dan PLTS tenaga angin. Sistem ini memungkinkan pasokan listrik tetap stabil dan berkelanjutan meskipun salah satu sumber energi mengalami keterbatasan.

2.1.3 Iradiasi Matahari

Iradiasi matahari merupakan salah satu parameter penting dalam sistem Pembangkit Listrik Tenaga Surya (PLTS). Energi listrik yang dihasilkan oleh PLTS berasal dari radiasi matahari yang diterima oleh permukaan panel surya dan kemudian dikonversi menjadi energi listrik melalui proses fotovoltaik. Secara sederhana, iradiasi matahari dapat diartikan sebagai jumlah energi radiasi matahari yang diterima oleh suatu permukaan dalam satuan luas tertentu selama periode waktu tertentu. Besarnya iradiasi menunjukkan intensitas energi matahari yang tersedia di suatu wilayah dan sering digunakan sebagai salah satu parameter utama dalam analisis potensi energi surya[15].

Nilai iradiasi matahari umumnya dinyatakan dalam satuan watt per meter persegi (W/m^2). Satuan ini menunjukkan besarnya daya radiasi matahari yang diterima oleh setiap meter persegi permukaan. Pada kondisi langit cerah, nilai iradiasi yang mencapai permukaan bumi dapat mendekati sekitar 1000 W/m^2 pada siang hari. Nilai tersebut sering dijadikan sebagai kondisi standar dalam pengujian performa modul surya yang dikenal dengan istilah *Standard Test Condition* (STC). Dalam praktiknya, besarnya iradiasi matahari yang diterima oleh suatu permukaan tidak selalu konstan. Nilai ini dapat berubah-ubah karena dipengaruhi oleh beberapa faktor. Salah satu faktor yang paling berpengaruh adalah waktu. Intensitas radiasi matahari biasanya meningkat secara bertahap sejak pagi hari, mencapai nilai maksimum pada sekitar tengah hari, kemudian kembali menurun menjelang sore hari seiring dengan perubahan posisi matahari.

Dalam sistem PLTS, iradiasi matahari memiliki hubungan yang sangat erat dengan jumlah energi listrik yang dihasilkan. Secara umum, peningkatan nilai iradiasi akan diikuti oleh peningkatan *output* daya yang dihasilkan oleh panel surya. Sebaliknya, apabila nilai iradiasi menurun, maka energi listrik yang dihasilkan oleh sistem PLTS juga

akan mengalami penurunan. Oleh karena itu, iradiasi matahari sering digunakan sebagai salah satu variabel utama dalam analisis serta pengembangan model prakiraan daya keluaran energi listrik pada sistem PLTS.

2.1.4 Perhitungan Daya *Output* Panel Surya

Perhitungan daya keluaran panel surya merupakan bagian penting dalam analisis kinerja sistem Pembangkit Listrik Tenaga Surya (PLTS). Melalui perhitungan ini, dapat diperkirakan besarnya energi listrik yang dihasilkan oleh panel surya berdasarkan beberapa parameter fisik yang mempengaruhi proses konversi energi.

2.1.4.1 Model Fisika Perhitungan Daya *Output* PLTS

Secara umum, daya listrik yang dihasilkan oleh panel surya dapat diperkirakan menggunakan model fisika sederhana yang menghubungkan efisiensi panel dengan luas permukaan panel dan tingkat iradiasi matahari[3]. Hubungan tersebut dapat dinyatakan melalui persamaan berikut:

$$P = \eta \times A \times G \tag{2.1}$$

Keterangan:

P= daya keluaran panel surya (W)

η= efisiensi panel surya

A= luas permukaan panel (m^2)

G= iradiasi matahari (W/m^2)

Persamaan tersebut menunjukkan bahwa daya keluaran panel surya dipengaruhi secara langsung oleh nilai iradiasi matahari yang diterima serta luas permukaan panel yang digunakan. Semakin besar luas permukaan panel dan semakin tinggi nilai iradiasi yang diterima, maka energi listrik yang dihasilkan juga akan semakin besar. Selain itu, efisiensi panel surya menentukan seberapa besar energi radiasi matahari yang dapat dikonversi menjadi energi listrik.

2.1.4.2 Pengaruh Suhu Terhadap Daya *Output* PLTS

Dalam kondisi operasional sebenarnya, kinerja panel surya tidak hanya dipengaruhi oleh iradiasi matahari, tetapi juga oleh faktor suhu. Perubahan suhu pada

permukaan panel dapat mempengaruhi karakteristik listrik dari material semikonduktor yang digunakan. Umumnya, peningkatan suhu panel akan menyebabkan penurunan efisiensi konversi energi sehingga daya keluaran yang dihasilkan menjadi lebih kecil dibandingkan dengan kondisi standar. Untuk memperhitungkan pengaruh suhu terhadap daya keluaran panel, digunakan pendekatan perhitungan yang mengacu pada kondisi pengujian standar atau *Standard Test Condition* (STC). Kondisi ini biasanya ditetapkan pada iradiasi matahari sebesar 1000 W/m² dan suhu sel sebesar 25°C. Hubungan antara daya keluaran panel, iradiasi matahari, dan suhu dapat dinyatakan dalam persamaan berikut:

$$P = P_{STC} \times \frac{G}{1000} \times [1 + \gamma(T - 25)] \quad (2.3)$$

Keterangan:

P = Daya keluaran panel pada kondisi aktual (W)

P_{STC} = Daya maksimum panel pada kondisi standar (W)

G = Iradiasi matahari (W/m²)

γ = Koefisien temperatur panel surya

T = Suhu panel (°C)

Pada persamaan tersebut, nilai P_{STC} menunjukkan daya maksimum yang dapat dihasilkan panel surya pada kondisi pengujian standar. Koefisien temperatur (γ) menggambarkan tingkat perubahan daya keluaran akibat perubahan suhu panel. Dalam banyak kasus, nilai koefisien temperatur bersifat negatif, yang berarti peningkatan suhu panel akan menyebabkan penurunan daya yang dihasilkan.

2.1.5 Prakiraan (*Forecasting*)

Prakiraan (*forecasting*) merupakan suatu proses untuk memperkirakan nilai suatu variabel pada periode waktu yang akan datang dengan memanfaatkan informasi yang berasal dari data historis[16]. Dalam berbagai bidang, prakiraan digunakan sebagai alat bantu dalam proses pengambilan keputusan karena mampu memberikan gambaran mengenai kondisi yang mungkin terjadi di masa mendatang.

Secara umum, *forecasting* dapat diartikan sebagai proses memperkirakan nilai suatu variabel pada masa yang akan datang dengan memanfaatkan data historis serta metode analisis tertentu. Proses ini dilakukan dengan mengidentifikasi pola yang terdapat pada data masa lalu, seperti tren, pola musiman, maupun fluktuasi lainnya, kemudian menggunakan pola tersebut sebagai dasar untuk memprediksi nilai pada periode berikutnya.

2.1.5.1 Jenis *Forecasting*

Berdasarkan rentang waktu prediksi, metode prakiraan umumnya dibedakan menjadi tiga kategori utama, yaitu *short-term forecasting*, *medium-term forecasting*, dan *long-term forecasting*[17].

1. *Short-Term Forecasting*

   Short-term forecasting merupakan prakiraan jangka pendek yang dilakukan untuk periode waktu yang relatif singkat, mulai dari beberapa menit hingga beberapa hari ke depan. Dalam sistem energi, prakiraan jangka pendek biasanya digunakan untuk mendukung operasi harian sistem tenaga listrik, termasuk dalam memprediksi *output* daya dari pembangkit energi terbarukan seperti PLTS.

2. *Medium-Term Forecasting*

   Medium-term forecasting merupakan prakiraan jangka menengah yang dilakukan untuk periode waktu yang lebih panjang dibandingkan dengan prakiraan jangka pendek, umumnya berkisar antara beberapa minggu hingga beberapa bulan.

3. *Long-Term Forecasting*

   Long-term forecasting merupakan prakiraan jangka panjang yang digunakan untuk memperkirakan kondisi sistem energi dalam periode waktu yang lebih lama, seperti beberapa tahun ke depan. Prakiraan jenis ini biasanya dimanfaatkan dalam proses perencanaan pengembangan infrastruktur energi, pembangunan pembangkit listrik baru, serta penyusunan kebijakan energi jangka panjang.

2.1.5.2 Metode *Forecasting*

1. Metode Statistik

   Metode statistik merupakan pendekatan prakiraan yang memanfaatkan pola historis dari suatu data untuk memprediksi nilai di masa yang akan datang. Metode ini umumnya digunakan ketika data memiliki pola tertentu seperti tren, musiman, maupun

siklus. Contoh metode statistik yang sering digunakan antara lain *Autoregressive Integrated Moving Average* (ARIMA) dan *Seasonal ARIMA* (SARIMA)[18].

2. Metode *Machine Learning*

   Metode ini memanfaatkan algoritma pembelajaran dari data historis untuk membangun model prediksi yang lebih adaptif. Beberapa algoritma yang sering digunakan dalam prakiraan energi antara lain *Random Forest*, *Support Vector Regression* (SVR), dan *Artificial Neural Network* (ANN)[19].

3. Metode *Deep Learning*

   Metode *deep learning* merupakan pengembangan dari *machine learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan. Metode ini mampu menangani data dalam jumlah besar dan memiliki kemampuan dalam mempelajari pola temporal yang kompleks. Contoh metode *deep learning* yang sering digunakan dalam prakiraan deret waktu adalah *Long Short-Term Memory* (LSTM) dan *Recurrent Neural Network* (RNN)[10][17].

4. Metode *Hybrid*

   Metode *Hybrid* merupakan kombinasi dari dua atau lebih metode prakiraan dengan tujuan meningkatkan akurasi prediksi. Pendekatan ini menggabungkan kelebihan dari masing-masing metode sehingga mampu menghasilkan model yang lebih akurat[20].

2.1.6 *Machine Learning*

Machine learning merupakan salah satu cabang dari kecerdasan buatan (*Artificial Intelligence*) yang berfokus pada pengembangan algoritma yang mampu mempelajari pola dari data. Berbeda dengan metode pemrograman konvensional yang membutuhkan aturan yang dirancang secara detail, *machine learning* memungkinkan sistem untuk belajar secara otomatis dari data historis sehingga mampu melakukan prediksi atau pengambilan keputusan berdasarkan pola yang telah dipelajari[21].

Secara umum, proses penerapan *machine learning* dimulai dari pengumpulan data yang relevan, kemudian dilanjutkan dengan tahap pemrosesan data (*data preprocessing*) untuk memastikan kualitas data yang digunakan sudah baik dan siap dianalisis. Setelah itu dilakukan proses pelatihan model (*training*) untuk membangun hubungan antara

variabel *input* dan *output*. Model yang telah dilatih selanjutnya dapat digunakan untuk melakukan prediksi terhadap data baru yang belum pernah digunakan sebelumnya.

2.1.6.1 Jenis dan Contoh Metode *Machine Learning*

Dalam penerapannya, metode *machine learning* dapat diklasifikasikan ke dalam beberapa jenis berdasarkan cara sistem mempelajari data. Secara umum, metode tersebut dapat dibagi menjadi dua kategori utama, yaitu *supervised learning* dan *unsupervised learning*.

1. *Supervised Learning*

   Supervised learning merupakan metode pembelajaran mesin yang menggunakan data yang telah memiliki label atau target. Pada metode ini, model dilatih menggunakan pasangan data input dan *output* sehingga sistem dapat mempelajari hubungan di antara keduanya. Setelah proses pelatihan selesai, model dapat digunakan untuk memprediksi nilai *output* berdasarkan data input yang baru. Contoh metode yang termasuk dalam kategori ini antara lain *Linear Regression, Decision Tree, Random Forest*, dan *Support Vector Machine* (SVM).

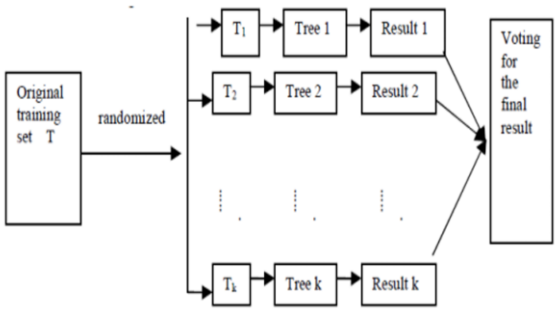
2. *Unsupervised Learning*

   Unsupervised learning merupakan metode yang tidak menggunakan data yang memiliki label atau target. Model pada metode ini bertujuan untuk menemukan pola atau struktur tertentu yang terdapat dalam kumpulan data. Teknik ini biasanya digunakan untuk melakukan pengelompokan data (*clustering*) atau menemukan hubungan tersembunyi antar variabel. Beberapa contoh metode yang termasuk dalam kategori ini adalah K-*Means Clustering, Hierarchical Clustering*, dan *Principal Component Analysis* (PCA)[22].

2.1.7 *Random Forest*

Random Forest merupakan algoritma *machine learning* berbasis *ensemble* yang mengombinasikan beberapa decision tree untuk meningkatkan akurasi prediksi. Setiap pohon menghasilkan prediksi yang kemudian digabungkan untuk memperoleh hasil akhir yang lebih andal. Pada penelitian ini, metode *Random Forest* digunakan dalam skema *regresi* untuk melakukan prakiraan daya keluaran PLTS.[23] Setiap *decision tree* dibangun menggunakan sebagian data pelatihan serta kombinasi variabel input yang

dipilih secara acak, seperti iradiasi matahari, suhu, waktu, dan data historis daya. Pendekatan tersebut memungkinkan model untuk menangkap hubungan yang kompleks antar variabel yang mempengaruhi produksi energi surya. Hasil prediksi akhir kemudian diperoleh melalui proses perataan (*averaging*) dari seluruh prediksi yang dihasilkan oleh masing-masing pohon keputusan.



Gambar 2. 4 Skema *Random Forest*

2.1.7.1 Konsep *Decision Tree Ensemble*

Konsep utama *Random Forest* didasarkan pada pendekatan *ensemble learning*, yaitu metode yang menggabungkan beberapa model prediksi untuk menghasilkan performa yang lebih baik dibandingkan menggunakan satu model tunggal. Dalam metode ini, sejumlah *decision tree* dibangun secara independen dengan menggunakan subset data pelatihan yang dipilih secara acak[24]. Proses ini menyebabkan setiap pohon keputusan memiliki struktur yang berbeda sehingga mampu mempelajari variasi pola yang terdapat dalam data. Pada permasalahan regresi, nilai keluaran biasanya diperoleh dari rata-rata hasil prediksi semua *decision tree*.

Pada proses pembentukan *decision tree*, pemilihan variabel pemisah pada setiap node dilakukan berdasarkan kriteria tertentu untuk meminimalkan kesalahan prediksi. Dalam regresi, kriteria yang sering digunakan adalah *Mean Squared Error* (MSE). Proses Training *Random Forest* secara umum dilakukan melalui beberapa tahapan sebagai berikut:

1. Pengambilan sampel data secara acak

   Dataset pelatihan akan diambil secara acak menggunakan teknik *bootstrap* untuk membentuk beberapa subset data yang berbeda.

2. Pembangunan *decision tree*

   Setiap subset data digunakan untuk membangun satu *decision tree*. Pada setiap node pohon, hanya sebagian fitur yang dipilih secara acak sebagai kandidat pemisah.

3. Pembentukan kumpulan pohon keputusan

   Proses ini diulang hingga terbentuk sejumlah *decision tree* yang membentuk satu model *random forest.*

4. Proses prediksi

   Untuk kasus regresi, hasil prediksi akhir diperoleh dengan menghitung rata-rata dari seluruh prediksi yang dihasilkan oleh setiap pohon dalam *random forest*.

2.1.8 *Seasonal Autoregressive Integrated Moving Average Hybrid* (SARIMAH)

Metode SARIMAH merupakan pengembangan dari model ARIMA yang digunakan untuk melakukan analisis dan prakiraan data deret waktu (*time series*) yang memiliki pola musiman. Dalam penelitian ini, model SARIMAH digunakan untuk memodelkan dan memprediksi keluaran daya pada sistem Pembangkit Listrik Tenaga Surya (PLTS), yang secara alami dipengaruhi oleh variasi waktu serta perubahan kondisi lingkungan yang bersifat musiman. Keunggulan utama metode ini dibandingkan model ARIMA konvensional adalah kemampuannya dalam menangkap pola musiman pada data secara lebih sistematis, sehingga model dapat menghasilkan prediksi yang lebih stabil dan akurat ketika data menunjukkan pola berulang, seperti pola harian atau bulanan pada produksi energi surya.

Model ARIMA secara umum dinyatakan dalam parameter (p, d, q), di mana p menunjukkan orde komponen *autoregressive,* d merupakan jumlah proses *differencing* yang dilakukan untuk mencapai kondisi stasioner, dan q menyatakan orde komponen *moving average*. Pada model SARIMAH, komponen tersebut diperluas dengan menambahkan unsur musiman sehingga dinyatakan dalam bentuk SARIMA (p, d, q)(P, D, Q)_s, dengan P, D, dan Q masing-masing merepresentasikan komponen musiman dari *autoregressive*, *differencing*, dan *moving average*, sedangkan s menunjukkan panjang periode musimannya[3]. Beberapa model dasar yang membentuk SARIMA antara lain sebagai berikut :

1. Model *Autoregressive* (AR)

   Model *Autoregressive* (AR) merupakan pendekatan dalam deret waktu yang menggambarkan bahwa nilai saat ini bergantung pada nilai-nilai di masa lalu. Jika suatu proses mengikuti model AR dengan orde p, maka model tersebut dapat dinyatakan sebagai:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \cdots + \beta_p Y_{t-p} + \varepsilon_t \qquad (2.5)$$

   Persamaan tersebut menunjukkan bahwa nilai Y_t merupakan kombinasi *linier* dari beberapa nilai sebelumnya hingga lag ke-p yang ditambah dengan komponen kesalahan ε_t. Komponen kesalahan diasumsikan bersifat independen, memiliki rata-rata nol, dan varian konstan.

2. Model *Moving Average* (MA)

   Model Moving Average (MA) merupakan model deret waktu yang memanfaatkan kesalahan (*error*) pada periode sebelumnya sebagai komponen dalam pembentukan nilai saat ini. Model MA dengan orde q dapat dinyatakan sebagai berikut:

$$Y_t = \beta_0 + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \cdots - \beta_q \varepsilon_{t-q} \qquad (2.6)$$

   Pada model ini, nilai pengamatan pada waktu t dibentuk dari kombinasi nilai kesalahan saat ini dan kesalahan pada beberapa periode sebelumnya yang diberikan bobot tertentu.

3. Model *Autoregressive Moving Average* (ARMA)

   Model ARMA (*Autoregressive Moving Average*) merupakan kombinasi antara model AR dan MA. Model ini digunakan untuk data deret waktu yang telah bersifat *stasioner*. Secara umum, model ARMA dengan orde (p,q) dapat dituliskan sebagai berikut:

$$Y_t = \mu + \beta_1 Y_{t-1} + \cdots + \beta_p Y_{t-p} + \varepsilon_t - \alpha_1 \varepsilon_{t-1} - \cdots - \alpha_q \varepsilon_{t-q} \qquad (2.7)$$

Model ini menggabungkan pengaruh nilai masa lalu (*autoregressive*) serta kesalahan prediksi pada periode sebelumnya (*moving average*) untuk memodelkan data deret waktu.

4. Model *Autoregressive Integrated Moving Average* (ARIMA)

   ARIMA(p,d,q) adalah model yang berasal dari ARMA(p,q) dengan penambahan proses *differencing* untuk membuat data menjadi stasioner. Bentuk model tersebut dinyatakan sebagai berikut:

   $$Yt = \mu + (\beta 1 + 1)Yt{-}1 + \cdots + (\beta\rho - \beta\rho - \beta\rho{-}1)Yt{-}\rho - \beta\rho Yt{-}\rho + \varepsilon t - \alpha 1\varepsilon t{-}1 - \cdots - \alpha q\varepsilon t{-}q \quad (2.8)$$

   Keterangan:

   Yt : data pada periode ke

   $t\ \mu$: konstanta model

   $\alpha 1 , \dots , \alpha q$: koefisien parameter *Moving Average*

   $\beta 1 , \dots , \beta p$: koefisien parameter *Autoregressive*

   εt : nilai kesalahan pada periode ke-t

   $\varepsilon t{-}q$: nilai kesalahan pada periode ke t – q

5. *Model Seasonal Autoregressive Integrated Moving Average* (SARIMA)

   Model SARIMA merupakan pengembangan lebih lanjut dari ARIMA dengan menambahkan komponen musiman pada model deret waktu. Model ini digunakan untuk memodelkan data yang memiliki pola periodik atau musiman. Secara umum model SARIMA dinyatakan dalam bentuk:

   $$SARIMA(p,d,q)(P,D,Q)_s \quad (2.9)$$

6. Model *Seasonal Autoregressive Integrated Moving Average Hybrid* (SARIMAH)

   SARIMAH (*Seasonal Autoregressive Integrated Moving Average Hybrid*) bukan model statistik murni seperti SARIMA. Dalam penelitian ini, SARIMAH adalah model gabungan (*Hybrid*) antara SARIMA dan *Random Forest*.

2.1.8.1 Identifikasi Model SARIMAH

Pada tahap ini dilakukan analisis terhadap data deret waktu untuk menentukan parameter yang sesuai pada model SARIMA sebagai komponen dasar dalam pendekatan *Hybrid*. Proses identifikasi dilakukan dengan menganalisis pola korelasi data menggunakan *Autocorrelation Function* dan *Partial Autocorrelation Function*. Kedua analisis ini digunakan untuk menentukan orde parameter p, d, q serta komponen musiman P, D, Q dalam model :

1. *Autocorrelation fungtion* (ACF)

   ACF digunakan untuk mengukur tingkat korelasi antara data deret waktu dengan nilai pada periode sebelumnya (*lag*). Analisis ACF membantu dalam menentukan orde *Moving Average* (MA) atau parameter q. Jika grafik ACF terpotong setelah *lag* tertentu, maka *lag* tersebut dapat menjadi indikasi nilai orde MA.

   Rumus ACF dapat dituliskan sebagai berikut:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \tag{2.14}$$

   keterangan:

   ρ_k : nilai *autokorelasi* pada *lag* ke-k

   γ_k : *kovarians* pada *lag* ke-k

   γ_0 : varians data

   Kovarians pada *lag* ke-k dihitung dengan persamaan:

$$\gamma_k = \frac{1}{n}\sum_{t=1}^{n-k}(Y_t - \bar{Y})(Y_{t+k} - \bar{Y}) \tag{2.15}$$

2. *Partial Autocorrelation Function* (PACF)

   PACF digunakan untuk mengukur korelasi antara suatu data dengan *lag* tertentu setelah pengaruh *lag* lainnya dihilangkan. Analisis PACF membantu dalam menentukan orde *Autoregressive* (AR) atau parameter p. Apabila grafik PACF terpotong setelah lag tertentu, maka nilai tersebut dapat digunakan sebagai orde AR.

   Secara umum, model regresi pada PACF dapat dituliskan sebagai:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \cdots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.16)$$

dengan keterangan:

Y_t : nilai deret waktu pada periode ke-t

ϕ_p : koefisien *autoregressive*

ε_t : *error* atau *residual*

Melalui analisis ACF dan PACF, diperoleh kandidat model SARIMA (p,d,q)(P,D,Q)_s yang selanjutnya digunakan sebagai komponen utama dalam model SARIMAH. *Residual* dari model tersebut kemudian dapat diproses menggunakan metode *machine learning* untuk menangkap pola *nonlinier* sehingga menghasilkan model prakiraan yang lebih akurat.

2.1.9 *Physics-Informed Machine Learning* (PIML)

2.1.9.1 Definisi *Physics-Informed Machine Learning*

Physics-Informed Machine learning merupakan pendekatan pengembangan model prediksi yang menggabungkan prinsip *machine learning* dengan pengetahuan berbasis hukum fisika[26]. Pada metode *machine learning* konvensional, model sepenuhnya mempelajari hubungan antar variabel dari data historis. Namun pada pendekatan *physics-informed,* proses pembelajaran model juga mempertimbangkan persamaan fisika yang menggambarkan perilaku sistem nyata.

Pendekatan ini banyak digunakan pada sistem energi karena karakteristik sistem tersebut umumnya telah memiliki model matematis yang jelas. Pada sistem *Photovoltaic System* misalnya, daya listrik yang dihasilkan sangat dipengaruhi oleh faktor fisik seperti iradiasi matahari, suhu modul, serta luas permukaan panel. Dengan memasukkan hubungan fisika tersebut ke dalam model, proses pembelajaran tidak hanya bergantung pada pola data, tetapi juga mengikuti prinsip kerja sistem yang sebenarnya.

2.1.9.2 Konsep Integrasi Hukum Fisika dengan *Machine Learning*

Konsep utama *Physics-Informed Machine learning* adalah mengintegrasikan model berbasis data dengan model berbasis fisika. Integrasi ini dapat dilakukan dengan beberapa cara, seperti menambahkan variabel hasil perhitungan fisika sebagai fitur *input*,

menerapkan batasan fisika pada proses pelatihan model, atau menggabungkan model statistik dengan persamaan fisika[27].

Dalam penelitian ini, integrasi dilakukan dengan menghitung daya teoritis panel surya berdasarkan persamaan fisika sistem PLTS, kemudian nilai tersebut digunakan sebagai fitur tambahan pada model *Random Forest*. Persamaan dasar yang digunakan untuk menghitung daya keluaran panel surya.

Nilai daya yang diperoleh dari persamaan digunakan sebagai fitur berbasis fisika (*physics-based feature*) yang kemudian dimasukkan ke dalam model *machine learning*. Dengan cara ini, model tidak hanya mempelajari pola dari data historis, tetapi juga mempertimbangkan hubungan fisis antara variabel lingkungan dan produksi daya PLTS.

2.1.9.3 Keunggulan Physics-Informed Machine Learning

Pendekatan *Physics-Informed Machine learning* memiliki beberapa keunggulan dalam pengembangan model prediksi, antara lain:

1. Meningkatkan akurasi prediksi

   Integrasi informasi fisika membantu model memahami hubungan antara variabel lingkungan dan keluaran daya secara lebih realistis.
2. Meningkatkan stabilitas model

   Adanya batasan dari persamaan fisika membuat model lebih konsisten ketika dihadapkan pada variasi kondisi data.
3. Mengurangi risiko *overfitting*

   Pengetahuan fisika yang dimasukkan ke dalam model berfungsi sebagai panduan sehingga model tidak hanya menyesuaikan diri secara berlebihan terhadap data pelatihan.

2.1.10 Model *Hybrid* Dalam *Machine Learning*

2.1.10.1 Definisi Model *Hybrid*

Model *Hybrid* merupakan pendekatan pemodelan yang menggabungkan dua atau lebih metode analisis untuk menghasilkan model prediksi yang lebih baik. Pendekatan ini digunakan karena setiap metode memiliki kelebihan dan keterbatasan dalam memodelkan suatu sistem. Dengan mengombinasikan beberapa metode, model *Hybrid* diharapkan

mampu menangkap karakteristik data secara lebih menyeluruh dibandingkan penggunaan metode tunggal.

Dalam penelitian ini, model *Hybrid* dibangun dengan menggabungkan metode deret waktu SARIMA yang dikembangkan menjadi pendekatan SARIMAH dengan algoritma *machine learning Random Forest* untuk meningkatkan kemampuan prediksi *output* daya pada sistem PLTS.

2.1.10.2 Tujuan Penggunaan Model *Hybrid*

Penggunaan model *Hybrid* bertujuan untuk meningkatkan kualitas hasil prakiraan dengan memanfaatkan karakteristik dari masing-masing metode. Model deret waktu digunakan untuk menangkap pola tren dan pola musiman dalam data historis, sedangkan metode *machine learning* digunakan untuk memodelkan hubungan *nonlinier* antara variabel yang mempengaruhi sistem.

Dengan menggabungkan kedua pendekatan tersebut, model diharapkan mampu menghasilkan prediksi yang lebih akurat dan lebih mampu menggambarkan kondisi sistem yang sebenarnya.

2.1.10.3 Keunggulan Model *Hybrid*

Beberapa keunggulan dari penggunaan model *Hybrid machine learning* ini ialah sebagai berikut:

1. Meningkatkan akurasi prediksi karena model dapat menangkap berbagai pola data secara lebih lengkap.
2. Memanfaatkan kelebihan masing-masing metode, di mana model statistik mampu menangkap pola deret waktu, sementara metode *machine learning* mampu memodelkan hubungan *nonlinier* yang kompleks.

2.1.11 Evaluasi Model Peralaman

Evaluasi dilakukan dengan membandingkan nilai hasil prediksi yang dihasilkan oleh model dengan nilai aktual yang diperoleh dari data pengukuran sistem. Melalui proses evaluasi ini dapat diketahui seberapa baik model dalam merepresentasikan pola data serta kemampuannya dalam melakukan prediksi pada periode waktu tertentu. Nilai kesalahan prediksi dihitung menggunakan beberapa metrik evaluasi. Pada penelitian ini,

metrik evaluasi yang digunakan adalah *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

2.1.11.1 Root Mean Square Error (RMSE)

RMSE adalah metrik evaluasi yang digunakan untuk mengetahui rata-rata kesalahan prediksi model dibandingkan dengan nilai aktual. Perhitungannya dilakukan dengan mengambil akar dari rata-rata kuadrat selisih antara nilai prediksi dan nilai sebenarnya. Nilai RMSE yang rendah menunjukkan performa model yang lebih akurat. Selain itu, RMSE memberikan penalti yang lebih besar pada error yang besar, sehingga sensitif terhadap deviasi antara prediksi dan data aktual.

2.1.11.2 *Mean Absolute Percentage Error* (MAPE)

MAPE merupakan salah satu teknik evaluasi yang digunakan untuk menilai besarnya kesalahan prediksi dalam satuan persentase[28]. MAPE merupakan rata-rata persentase selisih antara nilai aktual dan nilai hasil prediksi dibandingkan dengan nilai aktual. Metode ini sering digunakan dalam prakiraan energi karena memberikan interpretasi yang sederhana dalam bentuk persentase. Nilai MAPE yang lebih kecil menunjukkan performa model yang lebih baik. Berikut kriteria akurasi dalam penilaian MAPE[3], pada tabel 2.2

Tabel 2. 2 Kriteria *Mean Absolute Percentage Error* (MAPE)

***Mean Absolute Percentage Error* (MAPE)**	**Keterangan**
Nilai MAPE < 10%	Kemampuan prakiraan sangat baik
10% ≤ Nilai MAPE < 20%	Kemampuan prakiraan baik
20% ≤ Nilai MAPE < 50%	Kemampuan prakiraan cukup
Nilai MAPE ≥ 50%	Kemampuan prakiraan buruk