PREDIKSI PRODUKSI DAYA DC PLTS MENGGUNAKAN *PHYSICS-INFORMED MACHINE LEARNING*

Muhammad Zidni Rizqan Fauzan (13321058) | Dosen Pembimbing: Dr. Irsyad Nashirul Haq, S.T., M.T. dan Dr. Ing. Thomas Budiarto, S.T., M.T.

Program Studi Teknik Fisika
Fakultas Teknologi Industri
Institut Teknologi Bandung

1 LATAR BELAKANG

PT PLN (Persero) merancang **Rencana Usaha Penyediaan Tenaga Listrik 2021-2030** » **20,9 GW** target pemanfaatan dari **Sumber Energi Terbarukan**.

Namun berdasarkan data **Ditjen EBTKE** dan **HEESI** pada tahun 2023 menunjukan bahwa **0,6 GW** dari total potensi → **3.294 GW** energi surya yang baru dimanfaatkan di Indonesia, atau sekitar **0,02%** saja.

Meski sangat potensial, **fluktuasi iradiansi matahari** yang sangat acak menyebabkan **Intermitensi Cuaca** → dengan parameter cuaca yang berpengaruh pada daya adalah: **Iradiansi**, **Humiditas**, **Temperatur**, **WindSpeed**

Diperlukan pemodelan **prediksi daya DC** untuk mengatasi berbagai faktor **internal** dan **eksternal (cuaca)** yang polanya sulit dideteksi secara fisis dan matematis.

↳ Dikembangkan pendekatan baru yang diharapkan dapat **meningkatkan akurasi** dan nilai output yang sesuai dengan **kondisi nyata** secara fisis. » ***Physics-Informed Machine Learning*** — Sebuah pendekatan yang mengintegrasikan informasi fisika sebagai *prior knowledge* pada pemodelan.

Dibutuhkan pemodelan hibrida PIML pada PLTS CAS 10 kWp untuk melihat pengaruh parameter fisik terhadap pemodelan berbasis data (konvensional).

2 ALGORITMA PEMBELAJARAN MESIN

Physics-Informed Machine Learning

Skema umum *informed-machine learning*

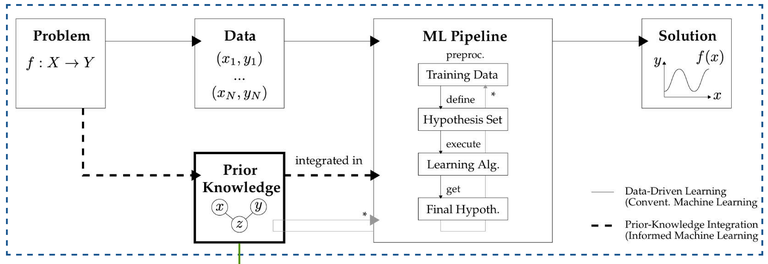

Filter data berdasarkan kaidah fisika

No	Fitur	Batas Ambang Bawah	Batas Ambang Atas
1	P_dc	0	2.520 W
2	I_dc	0	8,26 A
3	V_dc	0	309,96 V
4	solarRad	0	1.100 W/m²
5	Temp	15°C	36°C
6	Humidity	42%	100%
7	Pdc_PVlib	0	2.520 W
8	T_cell	-40°C	85°C

Data Spesifikasi Sistem PLTS

Data Cuaca Lokal

Augmentasi fitur

Daya DC PVlib (model fisika)

$$P_{dc} = \frac{G_{poaeff}}{1000} P_{dc0}\left(1 + \gamma_{pdc}(T_{cell} - T_{ref})\right)$$

Temperatur Panel

$$T_{cell} = T_{ambient} + G \times \frac{(NOCT - 20°C)}{800\ W/m^2}$$

Algoritma CNN-LSTM

***Convolutional Neural Network* (CNN)**

Dapat **mendeteksi pola cuaca** yang variabilitasnya tinggi

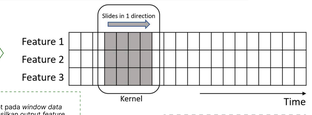

Cara Kerja
1. Kernel mengalikan bobot pada window data (multi-fitur) lalu menghasilkan output *feature map*.
2. Kernel berpindah ke kanan, memproses pola secara berurutan sepanjang *time-series*.
3. Memodelkan korelasi antar fitur sekaligus pola temporal, cocok untuk data PLTS multivariat.

Persamaan pada algoritma CNN →

$$h_{ij}^k = f\left(\left((W^k * x)\right)_{ij} + b_k\right)$$

***Long-Short Term Memory* (LSTM)**

Dapat memodelkan prediksi daya yang bersifat *time-series*

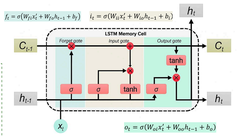

Cara Kerja
1. *Forget Gate*: melupakan *cell state* (c_t) yang tidak penting yang masuk dari sel sebelumnya.
2. *Input Gate*: menentukan informasi baru apa yang akan ditambahkan ke memori.
3. *Output Gate*: memutuskan apa yang akan dijadikan output sebagai *hidden state* (h_t).

Metrik Evaluasi

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2}$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|y_i - \hat{y}_i|$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{N}(y_i - \bar{y}_i)^2}$$

3 METODOLOGI PENELITIAN

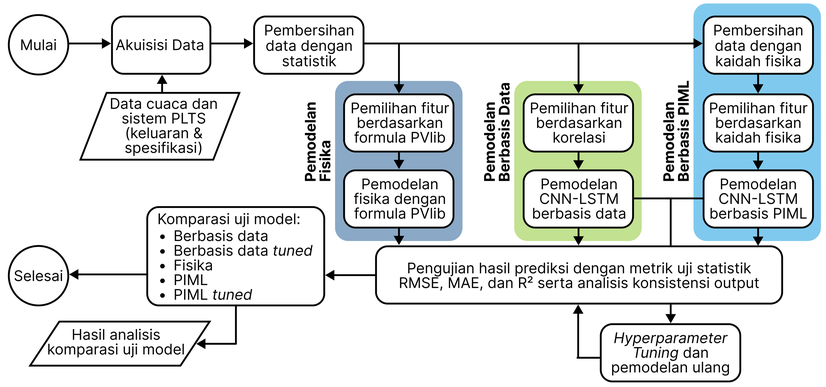

4 HASIL DAN ANALISIS

***Cross Industry Standard Process for Data Mining* (CRISP-DM)**

Pemahaman Bisnis

Manfaat
1. Mengembangkan pemodelan dengan akurasi lebih tinggi.
2. Melihat pengaruh integrasi fisika yang dapat menjadi acuan pada pemodelan lainnya.

Persiapan Data

Variabel	Jumlah *Outlier*		Persentase Reduksi *Outlier*	*Missing Values*
	Sebelum diolah	Setelah diolah		
solarRad	15.586	152	99,02%	0
outsideTemp	50	0	100%	0
outsideHumidity	1.058	234	77.89%	0
windSpeed	13.465	11.590	13,93%	0
P_str1	11.462	0	100%	0
I_str1	12.901	17	99,87%	0
V_str1	0	1.117	-	0

Pemahaman Data

Sebaran hubungan iradiansi dan daya DC dengan pengaruh temperatur

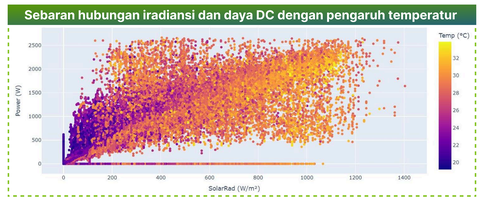

Sebaran hubungan iradiansi dan daya DC dengan pengaruh humiditas

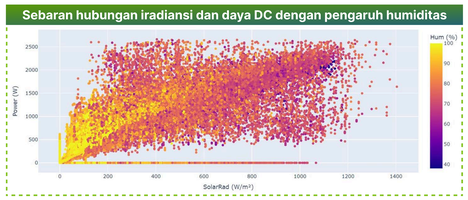

Sebaran hubungan iradiansi dan daya DC dengan pengaruh kecepatan angin

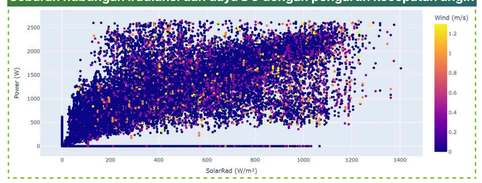

- Data dikumpulkan **November 2024–Februari 2025** dengan resolusi 1 menit, jumlah total 118.832 sampel fokus pada variabel cuaca dan daya DC PLTS.
- **Daya DC meningkat dengan iradiasi** namun **menurun pada suhu tinggi** (>32 °C) sesuai karakter penurunan efisiensi modul ~0,5%/°C.
- Kelembapan tinggi (>70%) **menggeser distribusi daya ke nilai lebih rendah** akibat pengaruh optik atmosfer dibanding kelembapan sedang (40–60%).
- Rentang kecepatan angin rendah (0–1,2 m/s) **tidak menunjukkan efek signifikan** terhadap daya DC meski secara teori membantu pendinginan modul.

Pemodelan

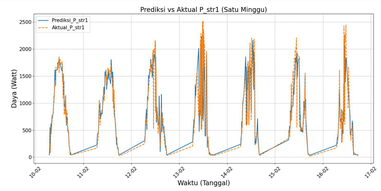

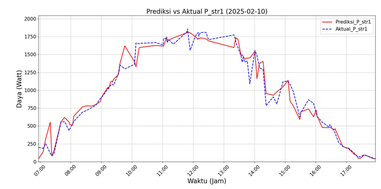

Evaluasi

Uji Metrik pada Daya *String* 1

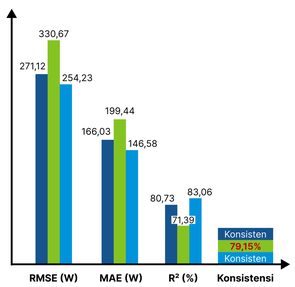

Uji Metrik pada Daya *String* 3

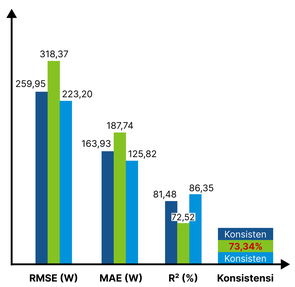

Pemodelan Berbasis Data | Pemodelan Berbasis Fisika | Pemodelan Berbasis PIML *Tuned*

Pada *string* 1, model PIML dengan *tuning* menunjukkan RMSE & MAE terendah serta R^2 tertinggi, mengungguli model berbasis data dan fisika.

Pada *string* 3, PIML tuned juga konsisten unggul dengan RMSE turun 14% dari model berbasis data, MAE 23% lebih rendah, dan R^2 naik 5 poin.

Model fisika memiliki galat terbesar dan konsistensi prediksi paling rendah (>70% tidak sesuai kaidah fisika).

PIML dengan *tuning* terbukti paling stabil baik akurasi maupun keselarasan dengan kaidah fisis di dua skenario data.

5 KESIMPULAN

1. Penelitian ini berhasil mengembangkan tiga model prediksi daya DC PLTS
- Pemodelan dengan pendekatan berbasis data, berbasis fisika, dan *physics-informed machine learning* (PIML).
- *Pipeline* pemodelan konsisten mulai dari pra-pemrosesan hingga evaluasi konsistensi output.

2. Pendekatan PIML dengan *tuning* menunjukkan performa terbaik
- Performa uji statistik RMSE terendah (223,20 W) dan R^2 tertinggi (86,35%) tanpa adanya pelanggaran fisika.
- Model berbasis data cenderung sensitif terhadap pengurangan lapisan arsitektur dan model fisika menunjukkan akurasi terendah.

3. Integrasi informasi fisika terbukti efektif menaikan performa model
- Ditunjukan dengan adanya penurunan RMSE sebesar 14,14% dan kenaikan R^2 sebesar 5,98% dengan mempertahankan konsistensi output terhadap kaidah fisika.
- Membuktikan bahwa penambahan domain pengetahuan fisika dapat meningkatkan akurasi pemodelan serta mengurangi eror dengan tetap mempertahankan konsistensi output.