

Integrasi Citra Satelit dan Inverter Berbasis Transfer Learning untuk Prediksi PLTS Tropis

Petricia Oktavia ^{(1)*}, Tole Sutikno ⁽²⁾, Murinto Murinto ⁽³⁾

^{1,2,3} Departemen Informatika, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

¹ Departemen Teknik Informatika, Universitas Pamulang, Tangerang, Indonesia

e-mail : 2536083046@webmail.uad.ac.id, tole@te.uad.ac.id, murintokusno@tif.uad.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 22 Mei 2026, direvisi 22 Agustus 2026, diterima 23 Agustus 2026, dan dipublikasikan 25 September 2026.

Abstract

Integrating photovoltaic (PV) power plants into smart grids requires reliable short-term forecasting, particularly under highly variable tropical atmospheric conditions. Conventional univariate temporal models, such as LSTM, struggle to anticipate abrupt cloud cover changes as they rely solely on historical electrical data. This study proposes a hybrid multimodal CNN-LSTM framework integrating 16-channel Himawari-9 spatio-temporal satellite imagery and real-time inverter electrical parameters via cross-climate transfer learning and Solar Polar Image Normalization (SPIN). Multimodal alignment was achieved using linear temporal and bilinear spatial interpolations across 9,622 synchronized 5-minute samples from Universitas Pamulang, while a dedicated multimodal adapter enabled partial weight transfer from the Stanford SKIPP'D dataset. Experimental results demonstrate superior performance, achieving an MAE of 3,73 kW, RMSE of 5,61 kW, a Forecast Skill of +5,98%, and mitigating extreme Q95 error to 12,37 kW compared to persistence and univariate LSTM baselines. With a CPU inference latency of 15,58 ms per sample, this architecture provides high accuracy and computational efficiency for real-time tropical grid operations.

Keywords: *Multimodal Deep Learning, Solar Forecasting, Himawari-9, CNN-LSTM, Transfer Learning*

Abstrak

Integrasi Pembangkit Listrik Tenaga Surya (PLTS) ke dalam sistem *smart grid* menuntut peramalan daya jangka pendek yang andal, khususnya di kawasan tropis dengan fluktuasi irradiansi yang dinamis. Model temporal univariat seperti LSTM kerap terlambat merespons tutupan awan mendadak karena hanya mengandalkan data elektrik historis. Penelitian ini mengusulkan arsitektur hibrida multimodal CNN-LSTM yang memadukan citra spasio-temporal satelit Himawari-9 (16 kanal) dan parameter elektrik inverter melalui skema *transfer learning* lintas iklim dan normalisasi polar SPIN. Penyelarasan data dilakukan melalui interpolasi temporal linear dan spasial bilinear pada 9.622 sampel sinkron beresolusi 5 menit di PLTS Universitas Pamulang, dengan modul *adapter* khusus untuk memfasilitasi *transfer* bobot dari *dataset Stanford SKIPP'D*. Hasil pengujian menunjukkan keunggulan model usulan dengan nilai MAE 3,73 kW, RMSE 5,61 kW, *Forecast Skill* +5,98%, serta penekanan galat ekstrem Q95 hingga 12,37 kW melampaui *baseline persistence* dan LSTM univariat. Dengan latensi inferensi CPU 15,58 ms per sampel, pendekatan ini terbukti akurat dan efisien untuk operasional *smart grid* tropis secara *real-time*.

Kata Kunci: *Deep Learning Multimodal, Prediksi PLTS, Himawari-9, CNN-LSTM, Transfer Learning*

1. PENDAHULUAN

Akselerasi pemanfaatan energi terbarukan di Indonesia, khususnya melalui sistem Pembangkit Listrik Tenaga Surya (PLTS), terus meningkat sejalan dengan target nasional menuju *Net Zero Emission* tahun 2060 (Sekretariat Jenderal Dewan Energi Nasional, 2020). Integrasi PLTS ke dalam sistem ketenagalistrikan modern menjadi semakin penting karena kemampuannya menyediakan sumber energi bersih dan berkelanjutan. Karakteristik keluaran daya PLTS yang



Artikel ini didistribusikan mengikuti lisensi Atribusi-NonKomersial CC BY-NC sebagaimana tercantum pada <https://creativecommons.org/licenses/by-nc/4.0/>.

sangat dipengaruhi kondisi atmosfer menyebabkan produksi energi bersifat intermiten dan fluktuatif (Sobri et al., 2018). Pada wilayah tropis seperti Indonesia, dinamika awan konvektif yang bergerak cepat dapat menyebabkan perubahan irradiansi matahari secara mendadak sehingga memicu ketidakseimbangan daya dan ketidakstabilan frekuensi pada jaringan listrik (Alsafrani et al., 2025; Huva et al., 2021). Oleh karena itu, prediksi daya keluaran PLTS jangka pendek dengan resolusi tinggi menjadi komponen penting dalam mendukung stabilitas smart grid dan optimalisasi pengelolaan cadangan daya oleh operator sistem (Kumar et al., 2022; Sharda et al., 2021).

Dalam beberapa tahun terakhir, pendekatan berbasis *Machine Learning* dan *Deep Learning* secara luas digunakan untuk prediksi daya PLTS karena kemampuannya memodelkan hubungan nonlinier pada data deret waktu kelistrikan (Alcañiz et al., 2023; Elsaraiti & Merabet, 2022). Arsitektur *Long Short-Term Memory* (LSTM) dan *Bidirectional LSTM* (BiLSTM) menjadi pendekatan dominan dalam memodelkan ketergantungan temporal parameter elektrik inverter (Husein et al., 2024; Tahir et al., 2021; Y. Wang et al., 2018). Walaupun menunjukkan performa yang baik pada pola historis sistem, model temporal berbasis data inverter memiliki keterbatasan mendasar karena hanya bergantung pada observasi internal sistem tanpa mempertimbangkan dinamika spasial atmosfer di sekitar lokasi PLTS (Al-Dahidi et al., 2025). Akibatnya, ketika terjadi perubahan tutupan awan secara cepat, model sering mengalami keterlambatan respons prediksi yang menyebabkan peningkatan galat prediksi secara signifikan (Shukla et al., 2026).

Untuk mengatasi keterbatasan tersebut, pemanfaatan citra satelit geostasioner seperti Himawari-9 mulai dikembangkan dalam penelitian prediksi daya surya (Nadeem et al., 2024; Straub et al., 2024). Citra Himawari-9 menyediakan informasi spasio-temporal mengenai distribusi awan, arah pergerakan, dan pola atmosfer secara real-time sehingga berpotensi meningkatkan kemampuan model dalam mengantisipasi perubahan irradiansi sebelum terjadi di lokasi PLTS (Buzzi et al., 2024; Luo & Zhang, 2023). Beberapa penelitian menunjukkan bahwa integrasi data visual atmosfer dan parameter elektrik mampu meningkatkan performa prediksi dibandingkan model temporal univariat (K. Wang et al., 2025; Xiao et al., 2024). Namun demikian, integrasi multimodal antara citra satelit berbasis piksel dan parameter numerik inverter masih menghadapi tantangan metodologis yang kompleks, terutama terkait sinkronisasi spasio-temporal, perbedaan laju sampling data, serta ketidaksesuaian representasi fitur antar modalitas (Ferlito et al., 2024).

Selain itu, pengembangan model *deep learning* multimodal pada wilayah tropis masih menghadapi keterbatasan ketersediaan dataset lokal berlabel dalam jumlah besar dan berkualitas tinggi (Surathunmanun et al., 2026). Kondisi ini menyebabkan pelatihan model dari awal rentan mengalami *overfitting*, ketidakstabilan konvergensi, dan rendahnya kemampuan generalisasi. Walaupun *transfer learning* telah banyak diterapkan pada domain *computer vision* dan *forecasting*, penerapan *transfer learning* lintas iklim untuk prediksi daya PLTS tropis berbasis integrasi citra satelit dan parameter inverter masih relatif terbatas (Nie et al., 2022; Schubnel et al., 2026; Yin et al., 2020). Penelitian sebelumnya juga belum banyak membahas mekanisme adaptasi fitur lintas modalitas yang memungkinkan *transfer* parameter temporal secara efektif tanpa merusak representasi spasial model yang telah dipelajari sebelumnya (Liwijaya et al., 2025). Dengan demikian, masih terdapat kesenjangan penelitian terkait pengembangan model *forecasting* multimodal yang mampu mengintegrasikan informasi spasial atmosfer, pembelajaran temporal inverter, serta adaptasi lintas iklim secara stabil dan efisien pada lingkungan tropis dengan keterbatasan data lokal (Bramasto & Khairiani, 2022; Rezza et al., 2024).

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan metodologi hibrida berbasis integrasi spasio-temporal citra satelit Himawari-9 dan parameter elektrik inverter menggunakan arsitektur multimodal CNN-LSTM melalui pendekatan *transfer learning* lintas iklim. Model terlebih dahulu dilatih menggunakan *Stanford Solar Forecasting Dataset* (SKIPP'D) berbasis iklim mediterania, kemudian bobot model di-*transfer* secara adaptif ke lingkungan tropis basah menggunakan rancangan *multimodal adapter* dan skema perluasan kanal konvolusi 16-kanal dengan transformasi *Solar Polar Image Normalization* (SPIN). Pendekatan ini dirancang untuk mempertahankan representasi spasial dan temporal hasil *pre-training* sekaligus meningkatkan



kemampuan adaptasi model terhadap dinamika atmosfer tropis yang lebih kompleks dan cepat berubah.

Kontribusi utama penelitian ini adalah yang pertama, penelitian ini merumuskan skema integrasi *spatio-temporal* sinkron antara citra satelit Himawari-9 dan parameter inverter melalui interpolasi temporal dan spasial untuk mengatasi ketidaksesuaian laju sampling dan resolusi data multimodal. Kedua, penelitian ini mengembangkan rancangan *multimodal adapter* yang memungkinkan *transfer* parameter temporal secara parsial pada arsitektur CNN-LSTM tanpa merusak struktur representasi fitur hasil *pre-training*. Ketiga, penelitian ini menyajikan analisis komparatif antara arsitektur CNN-LSTM dan CNN-BiLSTM untuk mengevaluasi kemampuan pemodelan dinamika temporal pada horizon prediksi ultra-singkat ($t+5$) menit, sekaligus mengkaji keterbatasan LSTM univariat dalam menangkap informasi spasial dan dinamika pergerakan awan tropis. Hasil perbandingan tersebut menegaskan pentingnya integrasi filter konvolusi sebagai mekanisme ekstraksi fitur spasial dalam meningkatkan kemampuan model dalam memprediksi perubahan daya PLTS. Keempat, penelitian ini tidak hanya mengevaluasi performa akurasi model, tetapi juga menganalisis *trade-off latency* inferensi CPU untuk mengukur kesiapan implementasi model pada perangkat *edge computing* dan lingkungan *smart grid real-time*. Jika sistem prediksi daya listrik terlalu lambat merespon (memiliki *latency* komputasi tinggi), operator jaringan tidak memiliki cukup waktu untuk menyeimbangkan pasokan cadangan listrik, yang pada akhirnya dapat memicu pemadaman. Arsitektur *smart grid* saat ini sangat membutuhkan kerangka sistem prediksi yang tidak hanya teliti, tetapi juga cukup ringan secara komputasi untuk dapat diimplementasikan pada arsitektur *edge computing* yang mampu merespon secara instan (*real-time*) (Benni et al., 2026).

2. METODE PENELITIAN


Penelitian ini menggunakan pendekatan metodologis yang menyeimbangkan tingkat akurasi prediksi daya surya dengan efisiensi komputasi, guna memungkinkan penerapan model pada perangkat dengan sumber daya terbatas. Bab ini merangkum seluruh tahapan perancangan secara ringkas. Pembahasan mencakup desain arsitektur integrasi data pada Sub-bab 2.1 hingga 2.3, strategi adaptasi iklim lokal melalui *transfer learning* pada Sub-bab 2.4, serta penjabaran dataset lapangan dan landasan matematis metrik pengujian (RMSE, MAE, *latency*) pada Sub-bab 2.5 dan 2.6.

2.1 Skema Integrasi Multimodal dan Alur Data

Alur metodologi penelitian ini bermula dari proses penerimaan data mentah hingga bermuara pada nilai keluaran prediksi akhir. Kendala teknis utama yang harus diatasi pada tahap awal adalah ketidakselarasan waktu perekaman antara citra satelit dan sensor inverter. Teknik interpolasi dilibatkan untuk menyinkronkan garis waktu kedua sumber tersebut. Begitu aliran data ini selaras, informasi visual mengenai tutupan awan diekstraksi oleh lapisan konvolusi CNN yang dimensinya telah disederhanakan demi menjaga efisiensi prosesor. Pada waktu yang bersamaan, kerangka kerja LSTM bertugas menggali pola temporal dari rekaman data kelistrikan. Kedua aliran informasi yang telah matang ini kemudian dilebur di dalam *multimodal adapter*. Konsep fusi data inilah yang menjadi inti dari arsitektur yang diusulkan, tangkapan cuaca visual dan tren kelistrikan saling menutupi kelemahan masing-masing, sehingga bermuara pada model prediksi yang baik namun tetap cepat saat dieksekusi.

Secara sederhana, Gambar 1 memvisualisasikan perjalanan data dari tahap masukan hingga menjadi nilai prediksi akhir. Karena tangkapan kamera satelit dan sensor inverter memiliki waktu rekam yang berbeda, sistem harus menyelaraskan garis waktunya menggunakan interpolasi. Setelah setara, gambar awan diekstrak oleh lapisan konvolusi (CNN) yang ukurannya telah dipangkas agar ringan. Bersamaan dengan itu, data kelistrikan dipelajari oleh jaringan LSTM. Keduanya lalu disatukan dalam *multimodal adapter* agar informasi cuaca visual dan tren kelistrikan saling melengkapi, menghasilkan prediksi yang presisi namun tetap cepat dieksekusi.





Gambar 1 Alur Metodologi Sinkronisasi Spasio-Temporal dan Arsitektur Fusi Multimodal CNN-LSTM

2.2 Penyelarasan Spasio-Temporal Aktual

Tantangan utama dalam penelitian ini adalah perbedaan skala spasial dan laju sampling temporal antar modalitas yang secara bawaan tidak selaras. Data citra satelit dan data kelistrikan memiliki interval waktu serta dimensi spasial yang berbeda sehingga memerlukan proses penyelarasan sebelum digunakan sebagai masukan model. Penyelarasan dilakukan melalui interpolasi temporal linear dan interpolasi spasial bilinear.

2.2.1 Interpolasi Temporal Linear (10 m ke 5 m)

Satelit Himawari-9 mentransmisikan citra baru setiap 10 menit, sedangkan inverter PLTS Universitas Pamulang (UNPAM) mencatat daya dan parameter kelistrikan internal setiap 5 menit. Mengikuti prinsip penyelarasan cross-modal (K. Wang et al., 2025), penelitian ini menerapkan interpolasi temporal linear untuk menghasilkan frame citra pada pertengahan interval 10 menit. Pendekatan ini digunakan untuk menyelaraskan interval temporal citra satelit dengan data kelistrikan inverter.

Pers. (1) menjabarkan interpolasi temporal secara linier berdasarkan koordinat spasial (x, y) dan kanal warna (c). Melalui metode ini, citra satelit pada menit ke-5 (I_{t+5}) dapat diperkirakan dengan menghitung nilai rata-rata antara citra pada menit ke-0 (I_t) dan citra pada menit ke-10 (I_{t+10}). Dengan pendekatan ini, modalitas visual disinkronkan dengan resolusi temporal data kelistrikan 5 menit tanpa mengurangi laju sampling data inverter.

$$I_{t+5}(x, y, c) = \frac{1}{2}I_t(x, y, c) + \frac{1}{2}I_{t+10}(x, y, c) \quad (1)$$



2.2.2 Interpolasi Spasial Bilinear ($10 \times 10 \rightarrow 64 \times 64$)

Ukuran crop spasial citra satelit Himawari-9 lokal UNPAM adalah 10×10 piksel. Di sisi lain, bobot arsitektur spasial CNN yang digunakan pada model *pre-trained* (Stanford SKIPP'D) dilatih dengan citra masukan berukuran 64×64 piksel. Agar bobot *transfer learning* dapat ditransfer 1:1 tanpa mengubah konfigurasi filter konvolusi awal, kami menerapkan *interpolasi spasial bilinear* dinamis sebelum citra dimasukkan ke model.

Untuk piksel target pada citra (x_{dest}, y_{dest}) pada citra berukuran 64×64 , posisi spasial pada citra sumber 10×10 dipetakan ke koordinat aslinya pada citra (x_{src}, y_{src}) . Nilai piksel target kemudian dihitung berdasarkan empat piksel tetangga terdekat, yaitu $(x_1, y_1), (x_1, y_2), (x_2, y_1), (x_2, y_2)$, menggunakan interpolasi bilinear sebagaimana dirumuskan pada Pers. (2a). Proses tersebut memungkinkan perubahan ukuran citra dilakukan dengan mempertimbangkan kontribusi nilai piksel di sekitar koordinat sumber.

$$f(x_{src}, y_{src}) \approx \frac{(x_2 - x_{src})(y_2 - y_{src})}{(x_2 - x_1)(y_2 - y_1)} f(x_1, y_1) + \frac{(x_{src} - x_1)(y_2 - y_{src})}{(x_2 - x_1)(y_2 - y_1)} f(x_2, y_1) \\ + \frac{(x_2 - x_{src})(y_{src} - y_1)}{(x_2 - x_1)(y_2 - y_1)} f(x_1, y_2) + \frac{(x_{src} - x_1)(y_{src} - y_1)}{(x_2 - x_1)(y_2 - y_1)} f(x_2, y_2) \quad (2a)$$

Koordinat piksel target (x_{dest}, y_{dest}) pada citra resolusi tinggi dipetakan kembali ke koordinat aslinya (x_{src}, y_{src}) pada citra sumber menggunakan persamaan rasio skala sebagaimana dirumuskan pada Pers. (2b). Variabel W dan H masing-masing menyatakan ukuran lebar (*width*) dan tinggi (*height*) citra, sedangkan subskrip *src* dan *dest* masing-masing menunjukkan citra sumber dan citra tujuan. Pemetaan koordinat tersebut digunakan sebagai dasar untuk menentukan posisi pada citra sumber yang digunakan dalam perhitungan interpolasi bilinear.

$$x_{src} = (x_{dest} + 0,5) \times \frac{W_{src}}{W_{dest}} - 0,5 \\ y_{src} = (y_{dest} + 0,5) \times \frac{H_{src}}{H_{dest}} - 0,5 \quad (2b)$$

Tahap interpolasi spasial bertujuan mempertahankan kontinuitas spasial kontur awan sekaligus mengurangi artefak akibat perubahan ukuran citra yang dapat memengaruhi ekstraksi fitur konvolusional. Interpolasi spasial dalam penelitian ini tidak dimaksudkan untuk menghasilkan detail spasial baru sebagaimana pada pendekatan super-resolution. Interpolasi diterapkan sebagai bentuk penyalarsan dimensi (*dimensional alignment*) agar struktur matriks masukan kompatibel dengan arsitektur CNN *pre-trained* yang digunakan.

Perbedaan karakteristik domain pencitraan dan sudut pandang observasi, khususnya antara citra kamera berbasis daratan (*ground-based*) dan citra satelit, ditangani melalui modul *multimodal adapter multimodal*. Modul ini berperan dalam merekalibrasi distribusi fitur spasial selama proses fine-tuning sehingga representasi yang dihasilkan lebih sesuai dengan karakteristik domain target. Pendekatan adaptasi lintas domain dan perspektif observasi tersebut sejalan dengan temuan Omnivision Forecasting yang menunjukkan pemanfaatan informasi dari kamera dan satelit secara terpadu (Paletta et al., 2023).

2.3 Formulasi Matematis Multimodal Adapter

Model *pre-trained* Stanford, arsitektur spasio-temporal dirancang untuk masukan univariat-citra, di mana *output* visual CNN yang telah di-*flatten* langsung diumpankan ke LSTM. Cabang CNN menghasilkan representasi spasial awan berdimensi $d_{cnn} = 4096$, yang tepat cocok dengan input temporal LSTM. Ketika diadaptasi ke stasiun UNPAM, kami menambahkan parameter kelistrikan inverter berdimensi $d_{inv} = 6$ (MPPT *Voltages & Currents*). Penggabungan langsung (*direct concatenation*) menghasilkan vektor baru berdimensi $4096 + 6 = 4102$, yang tidak kompatibel



dengan dimensi masukan LSTM *pre-trained* (4096). Untuk mengatasi ketidakcocokan dimensi ini tanpa melatih ulang LSTM dari awal, kami merancang *multimodal adapter*.

Secara matematis, misalkan $x_{img} \in \mathbb{R}^{4096}$ adalah representasi fitur spasial citra hasil ekstraksi blok CNN, dan $x_{inv} \in \mathbb{R}^6$ adalah vektor parameter kelistrikan inverter. Vektor gabungan multimodal $x_{fuse} \in \mathbb{R}^{4102}$ dirumuskan dalam Pers. (3). Pada Pers. (3), simbol $\parallel$ melambangkan operasi penyatuan (*concatenation*). Lapisan *multimodal adapter* memproyeksikan x_{fuse} kembali ke ruang laten temporal berdimensi 4096 sebagaimana dirumuskan pada Pers. (4).


$$x_{fuse} = [x_{img} \parallel x_{inv}] \quad (3)$$

$$h_{fuse} = \sigma(W_{ad}x_{fuse} + b_{ad}) \quad (4)$$

Pada Pers. (4), $W_{ad} \in \mathbb{R}^{4096 \times 4102}$ melambangkan matriks bobot proyeksi adapter yang dapat dilatih (*trainable weight matrix*), $b_{ad} \in \mathbb{R}^{4096}$ melambangkan vektor bias adapter, dan σ melambangkan fungsi aktivasi non-linier *Exponential Linear Unit* (ELU) untuk memastikan transisi fitur yang mulus tanpa masalah gradien. Vektor hasil proyeksi $h_{fuse} \in \mathbb{R}^{4096}$ memiliki dimensi yang tepat cocok dengan spesifikasi bobot temporal LSTM *pre-trained*, sehingga parameter temporal penting dari model *Stanford* yang telah mempelajari pola pergerakan awan jangka panjang, dapat diaplikasikan secara langsung melalui mekanisme *transfer* bobot dinamis dengan menggunakan konfigurasi *strict=False* saat memuat *state dictionary* pada PyTorch.

2.4 Strategi Pelatihan Dan Transfer Learning Lintas Iklim

Untuk mengatasi keterbatasan dataset lokal tropis dan meningkatkan stabilitas pelatihan model multimodal, penelitian ini menerapkan strategi *transfer learning* lintas iklim berbasis pelatihan dua tahap (*two-stage transfer learning*) sebagaimana ditunjukkan pada Gambar 2. Pendekatan ini dirancang agar model mampu memanfaatkan representasi spasio-temporal yang telah dipelajari dari dataset berskala besar sebelum diadaptasikan ke lingkungan tropis lokal yang memiliki karakteristik atmosfer lebih dinamis dan kompleks.



Gambar 2 Strategi Transfer Learning Lintas Iklim Tahap Ganda

Pada tahap pertama (*pre-training*), arsitektur multimodal CNN-LSTM dilatih menggunakan *Stanford Solar Forecasting Dataset* (SKIPP'D) yang terdiri atas 349.372 sampel citra langit dan data pendukung pada lingkungan beriklim mediterania. Proses ini bertujuan untuk membangun representasi dasar terhadap pola spasial awan, distribusi tutupan atmosfer, serta dinamika temporal pergerakan awan dalam horizon waktu jangka pendek. Melalui tahap ini, model



memperoleh kemampuan awal dalam mengenali hubungan antara perubahan struktur awan dan variabilitas keluaran daya surya.

Pada tahap kedua, bobot hasil *pre-training* dari modul CNN dan LSTM ditransfer ke arsitektur lokal yang digunakan pada dataset PLTS UNPAM. Untuk mendukung integrasi lintas modalitas dan perbedaan distribusi data antar-iklim, penelitian ini merancang lapisan *multimodal adapter* yang ditempatkan di antara modul ekstraksi spasial dan modul temporal. Berbeda dengan pendekatan *transfer learning* konvensional yang membekukan sebagian parameter model, seluruh parameter pada penelitian ini tetap dibiarkan trainable agar proses adaptasi terhadap karakteristik iklim tropis dapat berlangsung secara dinamis.

Tahap ketiga merupakan proses fine-tuning menggunakan dataset lokal UNPAM yang terdiri atas 9.622 sampel sinkron beresolusi temporal 5-menit dari parameter elektrikal inverter dan citra satelit Himawari-9. Tahap *fine-tuning* untuk citra Himawari-9 dengan 16 kanal spektral, dilakukan *channel expansion* pada lapisan konvolusi awal, tiga kanal pertama mempertahankan bobot *pre-trained* dari SKIPP'D, sedangkan 13 kanal tambahan diinisialisasi menggunakan Kaiming Normal (He et al., 2015). Untuk menyamakan skala antarkanal, seluruh citra dinormalisasi secara independen ke rentang $[0,1]$ berdasarkan batas fisik masing-masing kanal. Selanjutnya, seluruh parameter model dilatih secara *end-to-end* pada dataset lokal UNPAM. Strategi ini memungkinkan model mempertahankan fitur visual dasar yang telah dipelajari sebelumnya sekaligus menyesuaikannya dengan karakteristik spektral kanal inframerah dan dinamika awan konvektif di wilayah tropis. Optimasi dilakukan menggunakan *adam optimizer* dengan *learning rate* rendah sebesar 5×10^{-4} untuk menjaga stabilitas dan mencegah kerusakan representasi *spatio-temporal* yang telah dipelajari sebelumnya.

Seluruh tahapan pelatihan model dan pengujian inferensi dalam penelitian ini diimplementasikan menggunakan framework *PyTorch* pada lingkungan *Python* 3.10. Proses komputasi dilakukan pada perangkat berbasis arsitektur *Apple Silicon ARM64* dengan sistem memori terpadu (*Unified Memory*), yang digunakan untuk merepresentasikan karakteristik perangkat komputasi modern. Penentuan *hyperparameter* dilakukan dengan mempertimbangkan karakteristik dan keterbatasan dataset yang digunakan. Ukuran *batch* (*batch size*) ditetapkan sebesar 32 untuk menjaga stabilitas proses pembaruan parameter selama pelatihan. Ukuran *hidden state* pada LSTM ditetapkan sebesar 64 guna menjaga keseimbangan antara kapasitas model dalam menangkap pola temporal dan kompleksitas komputasi. Variabel yang diprediksi dalam penelitian ini adalah Total DC Power ($(P_{\text{total_DC}})$), yang dinyatakan dalam satuan *Watt* (W) dan dikonversi ke kilowatt (kW) untuk analisis kinerja. Peramalan dilakukan pada horizon *ultra-short-term*, yaitu untuk memprediksi daya 5 menit ke depan ($t+5$) dengan memanfaatkan sequence window $W = 12$, yang merepresentasikan riwayat operasional selama 60 menit pada interval pengamatan 5 menit.

2.5 Karakteristik Dataset Empiris Riil

Proses akuisisi data parameter elektrikal pada PLTS UNPAM dikelola menggunakan sistem SCADA *Haiwell*. Sebagaimana telah dievaluasi pada penelitian sebelumnya (Dinata et al., 2024), platform SCADA *Haiwell* terbukti tangguh dan akurat dalam merekam serta menganalisis performa inverter secara *real-time*. Untuk mencegah *data leakage* yang dapat terjadi pada peramalan deret waktu akibat pembagian data secara acak, penelitian ini menerapkan *strict chronological temporal split* dengan rasio 70%:15%:15%. Data dibagi secara berurutan menjadi *training set* sebanyak 6.735 sampel (1 Januari–5 Maret 2025), *validation set* sebanyak 1.443 sampel (5–18 Maret 2025), dan *testing set* sebanyak 1.444 sampel (18–31 Maret 2025). Seluruh proses normalisasi menggunakan *minmaxscaler* dilakukan dengan *fitting* hanya pada *training set*. Parameter skala yang diperoleh kemudian diterapkan pada data validasi dan pengujian menggunakan *transform*, sehingga statistik dari periode masa depan tidak memengaruhi proses pembelajaran model. Protokol ini menjaga independensi data evaluasi dan memberikan gambaran yang lebih realistis mengenai kemampuan generalisasi model terhadap data yang belum pernah diamati. Secara deskriptif, rata-rata daya selama 24 jam mencapai 6,479 kW



(6.478,84 W), sedangkan pada periode operasional siang hari (08:00–17:00 WIB) meningkat menjadi 15,145 kW (15.145,02 W). Pada testing set periode 18–31 Maret 2025, rata-rata daya aktual tercatat 16,930 kW (16.929,80 W) dengan daya maksimum 43,358 kW, sesuai kapasitas nominal inverter.

Dataset penelitian mencakup parameter elektrikal inverter dan informasi atmosfer selama Januari–Maret 2025. Periode ini dipilih karena bertepatan dengan periode aktivitas hujan dan dinamika atmosfer yang relatif tinggi di wilayah studi. Laporan BMKG menunjukkan bahwa sepanjang Januari hingga Februari 2025, wilayah Banten beberapa kali berada dalam prakiraan hujan sedang hingga lebat akibat pengaruh Monsun Asia dan dinamika atmosfer regional. Kondisi tersebut semakin terlihat pada Maret 2025, ketika BMKG mencatat curah hujan sangat tinggi di sebagian wilayah Banten dan sifat hujan Dasarian I berada pada kategori atas normal. Secara khusus, pada 3 Maret 2025, stasiun AWS/ARG BMKG di Tangerang Selatan mencatat curah hujan sebesar 116,5 mm/hari, yang dikategorikan sebagai kejadian hujan sedang hingga ekstrem di wilayah Tangerang dan sekitarnya (BMKG, 2025). Karakteristik tersebut menjadikan periode Januari–Maret 2025 relevan untuk menguji ketangguhan model dalam menghadapi perubahan kondisi atmosfer dan fluktuasi radiasi surya yang relatif tinggi pada lingkungan tropis basah. Walaupun durasi pengamatan relatif singkat, keterbatasan data diatasi melalui *transfer learning* dengan memanfaatkan representasi yang telah dipelajari pada tahap *pre-training*. Pendekatan ini memungkinkan model beradaptasi terhadap karakteristik lokal dengan kebutuhan data yang lebih terbatas dan sejalan dengan prinsip pemanfaatan representasi *pre-trained* pada arsitektur Omnivision (Paletta et al., 2023).

Dalam kerangka *transfer learning* yang diadopsi dari dataset SKIPP'D, model sumber juga menerapkan teknik prapemrosesan citra yang dikenal sebagai *Solar Polar Image Normalization* (SPIN). SPIN merupakan transformasi geometris yang memetakan koordinat piksel citra satelit dalam sistem kartesian (x,y) ke dalam sistem koordinat polar (r,θ), dengan posisi matahari digunakan sebagai pusat transformasi (Paletta et al., 2023). Secara operasional, posisi zenit matahari pada waktu pengamatan ditetapkan sebagai titik pusat atau origin dalam sistem koordinat polar. Transformasi tersebut menormalisasi orientasi citra terhadap posisi matahari, sehingga struktur dan pola pergerakan awan direpresentasikan secara relatif terhadap sumber radiasi tersebut. Dengan cara ini, variasi perspektif akibat perubahan posisi matahari sepanjang hari dapat dikurangi, sehingga pola spasial awan menjadi lebih konsisten dari satu waktu pengamatan ke waktu lainnya. Representasi tersebut berpotensi membantu CNN dalam mempelajari karakteristik spasial dan pola pergerakan awan secara lebih efektif. Penerapan SPIN menjadi bagian dari proses *pre-training* pada dataset *Stanford SKIPP'D* karena memberikan representasi visual yang lebih seragam terhadap konfigurasi awan dan posisi matahari. Namun, manfaat tersebut belum tentu tetap sama ketika model ditransfer ke domain dengan karakteristik atmosfer yang berbeda. Penelitian ini secara khusus mengevaluasi efektivitas SPIN pada tahap *fine-tuning* di wilayah tropis basah melalui studi ablasi. Perbandingan antar skenario digunakan untuk menentukan apakah penerapan SPIN memberikan kontribusi yang konsisten terhadap kinerja model pada domain target atau justru menimbulkan perubahan representasi spasial yang kurang sesuai dengan karakteristik citra lokal.

2.6 Landasan Matematis Metrik Evaluasi

Kinerja prediksi dari ketiga arsitektur dievaluasi menggunakan tujuh metrik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Normalized RMSE (nRMSE), Normalized MAE (nMAE), koefisien determinasi (R^2), Forecast Skill (FS), dan Quantile 95th Error (Q95) (Al-Dahidi et al., 2025). Penggunaan beberapa metrik bertujuan untuk mengevaluasi kinerja model dari berbagai karakteristik kesalahan prediksi. Metrik tersebut mencakup besarnya galat prediksi, galat yang telah dinormalisasi, kemampuan model menjelaskan variasi data, peningkatan terhadap baseline, serta galat pada bagian ekor distribusi.



2.6.1 Root Mean Squared Error (RMSE) dan Mean Absolute Error (MAE)

RMSE mengukur deviasi kuadrat rata-rata antara nilai prediksi dan nilai aktual, memberikan hukuman yang lebih berat pada kesalahan besar. Variabel $\hat{y}_i$ merupakan nilai prediksi daya surya, y_i merepresentasikan daya aktual di lapangan, dan n adalah jumlah total sampel. RMSE dihitung menggunakan Pers. (5).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

MAE mengukur rata-rata magnitudo absolut kesalahan prediksi tanpa memperhatikan arah positif atau negatifnya. Berkebalikan dengan RMSE yang sensitif pada galat besar, perhitungan MAE berfokus memetakan selisih absolut antara daya aktual (y_i) dan tebakan model ($\hat{y}_i$). MAE dihitung menggunakan Pers. (6).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

2.6.2 Normalized RMSE (nRMSE) dan Normalized MAE (nMAE)

Untuk memperoleh ukuran galat relatif, RMSE dan MAE dinormalisasi menggunakan rata-rata daya data uji dan kapasitas nominal inverter PLTS UNPAM. Rata-rata daya data uji $\bar{y}_{test} = 16.929,80$ W (16,93 kW) dan kapasitas nominal inverter $P_{nominal} = 43.358$ W (43,358 kW). Berdasarkan kedua nilai acuan tersebut, nRMSE dan nMAE dihitung menggunakan Pers. (7) dan Pers. (8).

$$nRMSE_{mean} = \frac{RMSE}{\bar{y}_{test}} \times 100\%, \quad nRMSE_{cap} = \frac{RMSE}{P_{nominal}} \times 100\% \quad (7)$$

$$nMAE_{mean} = \frac{MAE}{\bar{y}_{test}} \times 100\%, \quad nMAE_{cap} = \frac{MAE}{P_{nominal}} \times 100\% \quad (8)$$

2.6.3 5. Koefisien Determinasi (R^2)

Koefisien determinasi (R^2) mengukur proporsi variabilitas (varians) daya aktual yang berhasil dijelaskan oleh model peramalan multimodal berdasarkan Pers. (9). Di mana y_i merupakan nilai daya aktual lapangan pada sampel ke- i , $\hat{y}_i$ merepresentasikan estimasi daya keluaran hasil prediksi model, $\bar{y}$ adalah rata-rata daya aktual ($\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$), SS_{res} adalah jumlah kuadrat residual (*Sum of Squared Residuals*), SS_{tot} menyatakan variasi total data aktual terhadap rata-ratanya (*Total Sum of Squares*), dan n menyatakan jumlah total sampel data uji.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{SS_{res}}{SS_{tot}} \quad (9)$$

Nilai R^2 berkisar antara $-\infty$ hingga 1, nilainya dapat menjadi negatif ketika kinerja prediksi model lebih buruk dibandingkan prediksi konstan menggunakan rata-rata data pada data yang dievaluasi. Nilai yang semakin mendekati 1 menunjukkan bahwa prediksi model semakin mampu menjelaskan variasi daya aktual. Dalam penelitian ini, metrik R^2 digunakan untuk mengukur tingkat kecocokan (*goodness-of-fit*) fusi multimodal citra satelit dan data inverter terhadap radiasi surya tropis di PLTS UNPAM.



2.6.4 Forecast Skill (FS)

Forecast Skill (FS) digunakan untuk mengukur perubahan kinerja model terhadap persistence baseline berdasarkan nilai RMSE. Pada persistence baseline, prediksi daya untuk suatu timestep menggunakan nilai daya aktual pada timestep sebelumnya sebagai prediksi. Nilai FS dihitung menggunakan Pers. (10), di mana galat $RMSE_{pers}$ dihitung dari model persistence baseline sebesar 5,972 kW (5.972 W dengan $nRMSE_mean = 35,27\%$) sebagai standar acuan peramalan daya surya.

$$FS = \left(1 - \frac{RMSE_{model}}{RMSE_{persistence}} \right) \times 100\% \quad (10)$$

2.6.5 Quantile 95th Error (Q95)

Q95 error mengukur batas nilai kesalahan absolut (absolute error) pada persentil ke-95 dari seluruh distribusi galat prediksi. Q95 dirumuskan pada Pers. (11). Pada Pers. (11), $|y_i - \hat{y}_i|$ merupakan nilai galat absolut pada sampel data ke- i , $\mathbb{I}(\cdot)$ melambangkan fungsi indikator biner yang bernilai 1 jika kondisi terpenuhi dan 0 jika sebaliknya, n adalah jumlah total sampel data uji, serta q menyatakan batas kuantil galat.

$$Q95 = \inf \left\{ q \in \mathbb{R} \mid \frac{1}{n} \sum_{i=1}^n \mathbb{I}(|y_i - \hat{y}_i| \leq q) \geq 0,95 \right\} \quad (11)$$

Metrik ini secara khusus menyoroti seberapa besar penyimpangan maksimum yang mungkin terjadi pada 5% kondisi cuaca paling ekstrem (*worst-case scenario*), seperti saat terjadinya fluktuasi penurunan daya tajam akibat pergerakan awan konvektif yang mendadak. Evaluasi probabilitas pada ujung distribusi (*tail distribution*) menggunakan regresi kuantil semacam ini sangat krusial dalam menguji keandalan dan stabilitas sistem prediksi jaringan listrik (*smart grid*) (Sharda et al., 2021).

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil eksperimen sistem multimodal menggunakan data operasional PLTS. Pembahasan dibagi menjadi empat subbab, dimulai dari preprocessing dan ekstraksi fitur spasio-temporal (Subbab 3.1), dilanjutkan dengan *ablation study* untuk menentukan konfigurasi arsitektur yang paling sesuai (Subbab 3.2), evaluasi dan perbandingan kinerja seluruh model (Subbab 3.3), serta analisis waktu inferensi untuk menilai efisiensi komputasi (Subbab 3.4).

3.1 Hasil Preprocessing dan Ekstraksi Fitur Spasio-Temporal

Tahap awal dalam alur pemodelan multimodal mencakup proses penjaminan mutu (*Quality Control/QC*) dan ekstraksi representasi spasio-temporal dari dua sumber data heterogen, yaitu data operasional PLTS UNPAM dan citra satelit geostasioner Himawari-9. Tahapan ini dilakukan untuk memastikan bahwa data yang digunakan memiliki kualitas, konsistensi waktu, dan format representasi yang sesuai sebelum masuk ke proses pembelajaran model.

3.1.1 Hasil Pembersihan dan Validasi Data Inverter (QC Inverter)

Data mentah yang diperoleh dari sistem SCADA Haiwell PLTS UNPAM terdiri atas 25.918 rekaman yang mencakup periode Januari hingga Maret 2025. Sebelum digunakan dalam pemodelan, data melalui serangkaian prosedur QC untuk mengurangi duplikasi, menangani data yang tidak lengkap, serta mengidentifikasi nilai yang tidak sesuai dengan karakteristik fisik sistem. Pertama, timestamp yang terduplikasi dihapus dengan mempertahankan rekaman terakhir, sedangkan *missing value* dalam jumlah terbatas ditangani menggunakan interpolasi linear terikat. Interpolasi hanya diterapkan pada celah data dengan panjang maksimum enam *time step* berturut-turut, yang setara dengan sekitar 30–60 menit bergantung pada resolusi pencatatan. Pendekatan ini digunakan untuk mempertahankan kontinuitas deret waktu tanpa melakukan



estimasi pada periode kehilangan data yang terlalu panjang. Selanjutnya, diterapkan filtering waktu operasional siang hari (*daylight filtering*) pada rentang 08:00–17:00 WIB. Data di luar interval tersebut dikeluarkan karena umumnya berkaitan dengan kondisi tanpa radiasi matahari dan produksi daya yang mendekati nol. Pembatasan ini dimaksudkan agar proses pembelajaran lebih berfokus pada kondisi operasional PLTS yang relevan terhadap prediksi fluktuasi daya.

Tahap berikutnya adalah validasi berdasarkan batas fisik dan deteksi anomali. Mengacu pada spesifikasi inverter PLTS UNPAM dengan kapasitas nominal 43,358 kW, batas parameter ditetapkan untuk tegangan MPPT 1–3 sebesar 0–600 V, arus MPPT 1–3 sebesar 0–15 A, dan daya total sebesar 0 – 43,358 kW. Selain pemeriksaan batas fisik, identifikasi nilai ekstrem juga dilakukan menggunakan rentang interkuartil (*interquartile range/IQR*) dan *Z-score*. Sebagaimana divisualisasikan pada Gambar 3(a), nilai yang terindikasi sebagai outlier disesuaikan secara proporsional terhadap batas fisik yang valid, sedangkan rekaman dengan daya negatif dieliminasi karena tidak merepresentasikan kondisi operasi normal PLTS. Analisis hubungan multivariat pada Gambar 3(c) menunjukkan bahwa arus MPPT 1–3 memiliki korelasi linear yang sangat kuat dengan Total DC Power, dengan koefisien korelasi *Pearson* mencapai $r = 1,00$. Hasil ini menunjukkan bahwa variasi arus pada ketiga jalur MPPT berkaitan sangat erat dengan perubahan daya keluaran inverter. Sementara itu, tegangan MPPT 1–3 menunjukkan korelasi yang lebih moderat, yaitu pada kisaran $r = 0,40–0,42$, yang mencerminkan variasi kondisi tegangan operasi pada sistem fotovoltaik. Dengan demikian, kedua kelompok parameter tersebut memberikan informasi yang saling melengkapi dan relevan untuk merepresentasikan kondisi operasional inverter, sehingga dipertahankan sebagai fitur input dalam pemodelan prediksi daya PLTS.

3.1.2 Hasil Pemrosesan dan Sinkronisasi Citra Satelit Himawari-9

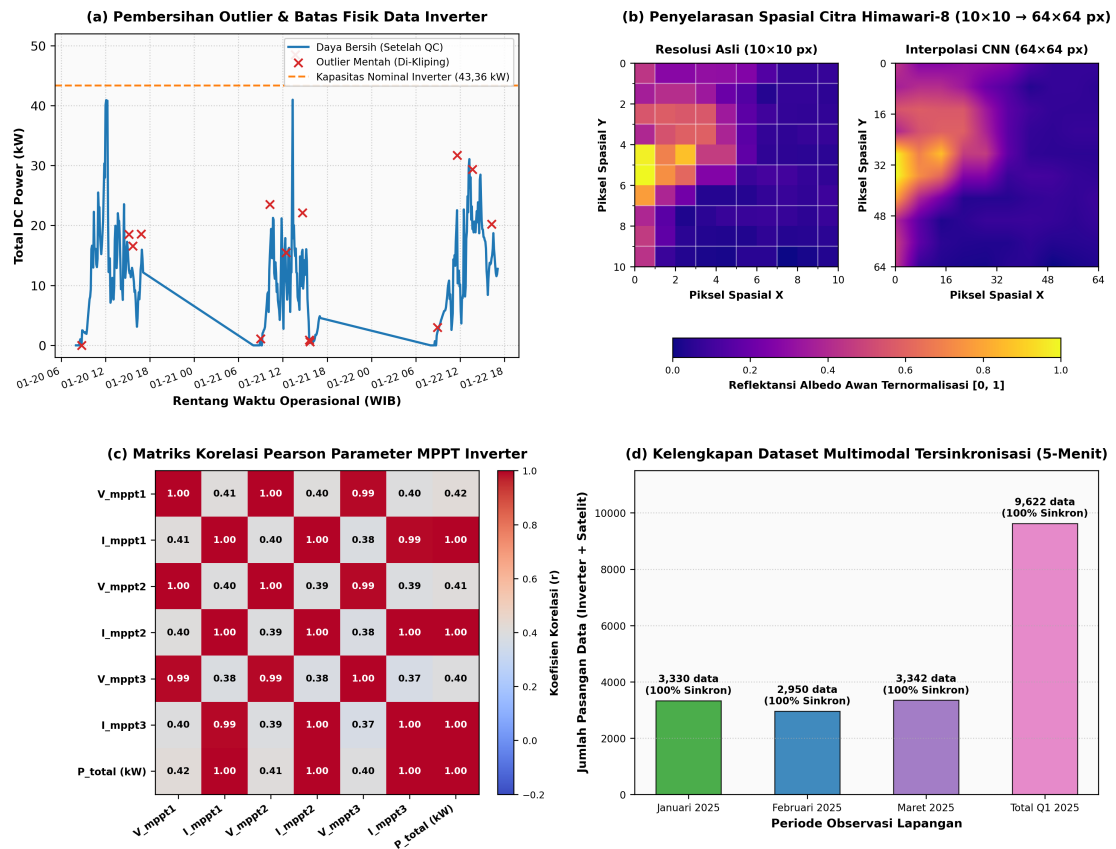
Pemrosesan data satelit berformat NetCDF4 (.nc) yang dikumpulkan selama kuartal pertama 2025. Metadata waktu pada setiap file yang semula menggunakan UTC dikonversi ke Waktu Indonesia Barat (WIB, UTC+7) agar konsisten dengan *timestamp* pada sistem SCADA inverter. Pemeriksaan integritas menunjukkan bahwa seluruh file dapat dibaca dengan baik dan tidak ditemukan indikasi kerusakan pada struktur maupun matriks citra. Karena citra satelit direkam setiap 10 menit, sedangkan data inverter tersedia pada interval 5 menit, kedua sumber data perlu diselaraskan melalui interpolasi temporal linear sesuai Pers. (1). Proses ini menghasilkan 9.622 pasangan sampel multimodal pada resolusi 5 menit. Seperti ditunjukkan pada Gambar 3(d), hasil sinkronisasi menunjukkan tingkat *data completeness* sebesar 100%, tanpa *missing values* pada pasangan data yang telah terbentuk. Kondisi tersebut menunjukkan bahwa prosedur pencocokan temporal berbasis Pers. (1) mampu mempertahankan konsistensi antara observasi kelistrikan dan kondisi atmosfer yang direpresentasikan oleh citra satelit.

3.1.3 Hasil Ekstraksi Fitur Spasial dan Fusi melalui *Multimodal Adapter*

Pada tahap ekstraksi fitur spasial, setiap frame citra satelit dengan ukuran awal 10×10 piksel dinormalisasi ke rentang $[0, 1]$. Sebagaimana pada Gambar 3(b), citra diperbesar secara spasial menggunakan interpolasi bilinear berdasarkan Pers. (2a) dan (2b) menjadi 64×64 piksel untuk menyesuaikan ukuran masukan dengan *receptive field* pada filter konvolusi 2D yang telah dipelajari selama *pre-training* menggunakan *dataset Stanford SKIPP'D*. Citra tersebut kemudian diproses melalui tiga blok konvolusi yang masing-masing terdiri atas *Conv2d*, *ReLU*, dan *MaxPool2d*. Untuk membentuk representasi multimodal, *multimodal adapter* menggabungkan 4.096 fitur visual tersebut dengan enam parameter kelistrikan inverter melalui Pers. (3), yaitu tegangan dan arus pada MPPT 1, 2, dan 3 menghasilkan vektor berdimensi 4.102. Keenam parameter kelistrikan terlebih dahulu dinormalisasi menggunakan *minmaxscaler* agar memiliki skala yang konsisten dengan fitur visual. Hasil penggabungan kemudian diproyeksikan kembali menjadi vektor representasi terpadu berdimensi 4.096 menggunakan Pers. (4) dan ditransformasikan menggunakan fungsi aktivasi nonlinier ELU. Representasi multimodal ini selanjutnya disusun sebagai sekuens temporal dan diberikan kepada lapisan LSTM dengan panjang jendela $W = 12$, yang merepresentasikan riwayat observasi selama 60 menit. Sehingga model tidak hanya mempertimbangkan kondisi visual awan dan parameter kelistrikan pada satu



titik waktu, tetapi juga memanfaatkan pola perubahan keduanya secara temporal untuk memprediksi fluktuasi daya keluaran PLTS secara lebih proaktif.



Gambar 3 Hasil Preprocessing Data Multimodal dan Ekstraksi Fitur Spasio-Temporal; (a) Pembersihan Outlier dan Batas Fisik Data Inverter, (b) Penyelarasan Spasial Citra Satelit Himawari-9, (c) Matriks Korelasi Pearson Parameter MPPT Inverter terhadap Daya DC, dan (d) Kelengkapan Dataset Multimodal Tersinkronisasi Kuartal Pertama 2025.

3.2 Studi Ablasi

Sebagai bagian dari validasi untuk menguji kontribusi masing-masing komponen dan efektivitas skema adaptasi domain yang diusulkan, Tabel 3 menyajikan hasil ablation study yang dilakukan melalui lima skenario pengujian. Eksperimen ini dirancang untuk mengidentifikasi pengaruh individual maupun kombinasi *Transfer Learning* (TL), modul ekstraksi fitur inframerah multimodal, dan transformasi SPIN terhadap kinerja model. Melalui perbandingan antar skenario, dapat dievaluasi sejauh mana setiap komponen memberikan kontribusi terhadap peningkatan akurasi dan kemampuan generalisasi model pada data lokal. Seluruh metrik kesalahan dan keandalan dihitung secara matematis menggunakan Pers. (5) untuk RMSE, Pers. (6) untuk MAE, Pers. (7) untuk nRMSE, Pers. (8) untuk nMAE, Pers. (9) untuk koefisien determinasi R^2 , Pers. (10) untuk *Forecast Skill*, serta Pers. (11) untuk galat ekstrem Q95 *Error*.


Hasil *ablation study* pada Tabel 1 menunjukkan adanya perbedaan kinerja yang cukup jelas antar konfigurasi. *Persistence baseline* (A0) menghasilkan RMSE 5,786 kW dengan *Forecast Skill* sebagai titik acuan. Konfigurasi A1 (TL 3CH/W5) memberikan kinerja yang lebih baik dengan RMSE 5.321,52 W, R^2 0,7803, *Forecast Skill* +8,02%, serta Q95 Error terendah sebesar 11,32 kW, disertai latensi inferensi hanya 3,31 ms. Sebaliknya, penambahan SPIN pada A2 justru menurunkan performa, dengan RMSE meningkat menjadi 5,5216 kW dan *Forecast Skill* turun



menjadi +4,56%, yang mengindikasikan adanya *geometric domain shift* antara representasi citra hasil *pre-training* dan transformasi polar pada domain target. Konfigurasi A3 memberikan hasil terbaik dari sisi akurasi, dengan MAE 3,5396 kW, R^2 0,7837, $nRMSE_{cap}$ 12,59%, dan *Forecast Skill* +5,66%. Peningkatan ini menunjukkan bahwa penambahan informasi spektral 16-channel dan jendela temporal 60 menit dapat memperkaya representasi atmosfer serta membantu mengompensasi keterbatasan yang muncul akibat SPIN. Namun, peningkatan akurasi tersebut disertai kenaikan latensi hingga 15,12 ms per sampel. Sementara itu, A4 yang dilatih *from scratch* dengan konfigurasi input yang sama mengalami penurunan kinerja, dengan RMSE 5,6519 kW dan *Forecast Skill* hanya +2,31%. A3 memberikan akurasi terbaik, sedangkan A1 menawarkan kompromi yang lebih baik antara ketahanan terhadap galat ekstrem dan efisiensi komputasi.

Tabel 1 Skenario Studi Ablasi Konfigurasi *Transfer Learning* dan Domain Geometri

Skenario	RMSE (kW)	MAE (kW)	R2	nRMSE_mean (%)	nRMSE_cap (%)	Q95 (kW)	Fs (%)	Latency (ms)
A0. Persistence Baseline	5,7856	3,8395	0,7403	34,12	13,34	12,44	0.0	0.01
A1. TL Murni (3CH/W5)	5,3215	3,7616	0,7803	31,38	12,27	11,32	8,02	3.31
A2. TL + SPIN (3CH/W5)	5,5216	3,8311	0,7634	32,56	12,73	11,54	4,56	3.25
A3. TL + SPIN + 16CH + W12 [Usulan]	5,4582	3,5396	0,7837	32,24	12,59	12,46	5,66	15.12
A4. Scratch + SPIN + 16CH + W12	5,6519	3,7448	0,7681	33,38	13.04	12,58	2,31	16.77



Gambar 4 Visualisasi Metrik Performa Studi Ablasi



Gambar 4 memperlihatkan distribusi galat dan perbandingan kinerja antar skenario ablasi. Pada panel atas, kurva *Kernel Density Estimation* (KDE) menunjukkan bahwa A1 dan A3 memiliki konsentrasi galat absolut yang lebih tinggi pada rentang galat rendah (<2.000 W), yang tercermin dari posisi MAE yang relatif dekat dengan nol. Pada panel bawah, A1 menghasilkan RMSE terendah sebesar 5,3215 kW, sedangkan A3 memberikan R^2 tertinggi sebesar 0,784. Hasil ini memperkuat bahwa pemanfaatan bobot *pre-trained* melalui *transfer learning* memberikan keuntungan dalam menekan galat dan meningkatkan kemampuan generalisasi model pada domain target.

3.3 Hasil Eksperimen dan Perbandingan Kinerja Model

Untuk mengevaluasi efektivitas arsitektur multimodal yang diusulkan, pengujian dilakukan menggunakan dataset operasional PLTS Universitas Pamulang dengan resolusi 5 menit, yang mencakup 9.622 sampel. Evaluasi dilakukan secara komparatif dengan melibatkan beberapa konfigurasi model, yaitu LSTM univariat sebagai model dasar, CNN-BiLSTM multimodal sebagai model pembandingan, dan CNN-LSTM multimodal berbasis *transfer learning* sebagai model utama yang diusulkan. Seluruh model kemudian dibandingkan dengan *Persistence baseline* yang digunakan sebagai tolok ukur sederhana dalam konteks prediksi daya PLTS. Hasil evaluasi kuantitatif dari seluruh model pada dataset uji riil beresolusi 5 menit dirangkum pada Tabel 2. Perbandingan tersebut digunakan untuk menilai tingkat akurasi masing-masing pendekatan sekaligus mengidentifikasi sejauh mana integrasi informasi multimodal dan *transfer learning* memberikan kontribusi terhadap peningkatan kinerja prediksi.

Tabel 2 Perbandingan Kinerja Seluruh Model Pelatihan Terhadap Baseline (Data Uji 5-Menit)


Arsitektur Model	RMSE (kW)	MAE (kW)	R2	nRMSE_mean (%)	nRMSE_cap (%)	Q95 (kW)	Fs (%)	Latency (ms)
Persistence Baseline	5,97	3,50	0,7412	35,27%	13,77%	13,81	0,00%	0,01 ms
Baseline LSTM	5,69	3,85	0,7647	33,63%	13,13%	12,57	+4,66%	0,31 ms
CNN-LSTM Multimodal (Usulan A3)	5,61	3,73	0,7712	33,16%	12,95%	12,37	+5,98%	15,58 ms
CNN-BiLSTM Multimodal	5,62	3,70	0,7711	33,17%	12,95%	12,33	+5,97%	17,72 ms
Persistence Baseline	5,97	3,50	0,7412	35,27%	13,77%	13,81	0,00%	0,01 ms

Berdasarkan Tabel 2, model CNN-LSTM multimodal berbasis *transfer learning* dengan konfigurasi A3 (16-channel + SPIN) menunjukkan kinerja terbaik di antara model *deep learning* yang diuji. Model ini menghasilkan MAE berdasarkan Pers. (6) 3,71 kW, RMSE dihitung melalui Pers. (5) 5,58 kW, dan R^2 sebesar 0,7738, dengan $nRMSE(capacity)$ 12,87%. Hasil tersebut menunjukkan bahwa integrasi informasi citra satelit 16-channel dan parameter elektrik inverter mampu menjelaskan sekitar 77,38% variasi daya keluaran PLTS. Keunggulan model multimodal juga terlihat pada kondisi galat ekstrem. Q95 Error CNN-LSTM sebesar 12,24 kW lebih rendah dibandingkan *Persistence baseline* sebesar 13,81 kW dan LSTM univariat sebesar 12,55 kW. Temuan ini menunjukkan bahwa informasi visual awan dapat membantu model mengenali perubahan daya yang lebih tajam. Secara keseluruhan, model CNN-LSTM memberikan *Forecast Skill* sebesar +6,53% dibandingkan *Persistence baseline*.

Hasil ini juga memperjelas keterbatasan pendekatan sebelumnya. Penelitian kami sebelumnya menggunakan CNN belum mampu melampaui *Persistence baseline* karena belum menangkap dinamika temporal awan (Oktavia et al., 2026). Sebaliknya, LSTM univariat mampu memodelkan hubungan temporal, tetapi tidak optimal ketika citra satelit diproses tanpa ekstraksi fitur spasial. Integrasi CNN untuk representasi spasial dan LSTM untuk dinamika temporal, yang dipadukan




dengan informasi elektrik dan *transfer learning*, menjadi komponen penting dalam meningkatkan kinerja prediksi daya PLTS.



Gambar 5 Kurva Penurunan Loss Pelatihan dan Validasi Model Multimodal

Berdasarkan Gambar 5, kurva *training loss* dan *validation loss* menunjukkan pola penurunan yang relatif konsisten dan secara bertahap menuju kondisi konvergen. Tidak terlihat adanya divergensi yang berarti maupun kesenjangan yang lebar antara kedua kurva, sehingga tidak terdapat indikasi kuat terjadinya *overfitting* selama proses pelatihan. Nilai *validation loss* juga mencapai titik terendah secara relatif stabil, yang menunjukkan bahwa model mampu mempertahankan kinerja yang konsisten pada data validasi. Pola tersebut mengindikasikan bahwa kombinasi bobot *pre-trained* dari dataset Stanford SKIPP'D dengan mekanisme pengendalian proses pelatihan, yaitu *ReduceLROnPlateau* dan *Early Stopping*, mendukung proses adaptasi model secara bertahap pada domain target. Strategi ini membantu mempertahankan representasi visual yang telah dipelajari sebelumnya sekaligus memberikan ruang bagi model untuk menyesuaikan diri terhadap karakteristik atmosfer tropis. Dengan proses pelatihan yang stabil, model memiliki dasar representasi yang lebih baik untuk menghasilkan prediksi pada data operasional PLTS yang belum pernah dilihat sebelumnya.



Gambar 6 Hasil Prediksi Daya PLTS oleh Model CNN-LSTM Dibandingkan Data Aktual Lapangan

Hasil visualisasi pada Gambar 6 menunjukkan bahwa model CNN-LSTM multimodal mampu mengikuti pola daya aktual PLTS dengan cukup baik selama periode siang hari, termasuk pada kondisi radiasi yang berubah-ubah. Selisih antara nilai aktual dan prediksi relatif kecil pada kondisi cerah maupun berawan sedang, sementara model juga mampu mengikuti penurunan daya yang terjadi ketika awan tebal melintas. Hasil ini menunjukkan bahwa penggabungan informasi spasial dari citra Himawari-9 dengan parameter elektrik inverter memberikan representasi kondisi sistem yang lebih lengkap. Informasi visual membantu model mengenali



perubahan tutupan awan, sedangkan data inverter merepresentasikan respons kelistrikan PLTS. Kombinasi keduanya memungkinkan model menangkap perubahan daya secara lebih baik dibandingkan dengan pendekatan yang hanya menggunakan data numerik.

3.4 Analisis Waktu Inferensi (*Inference Latency*)

Dalam implementasi industri PLTS berbasis smart grid, model forecasting tidak hanya dituntut memiliki akurasi tinggi, tetapi juga efisiensi komputasi yang memadai agar dapat dijalankan pada perangkat keras bersumber daya terbatas, seperti Raspberry Pi, NVIDIA Jetson, maupun edge controller yang ditempatkan di lokasi terpencil. Oleh karena itu, penelitian ini melakukan evaluasi empiris terhadap latensi inferensi CPU untuk mengukur kesiapan implementasi model pada lingkungan edge computing real-time. Rata-rata waktu inferensi dihitung menggunakan Pers. (12).

$$Latency_{avg} = \frac{\sum_{i=1}^N (T_{finish,i} - T_{start,i})}{N} \quad (12)$$

Variabel $T_{finish,i}$ dan $T_{start,i}$ merupakan penanda waktu (timestamp) kapan komputasi inferensi selesai dan dimulai pada sampel ke- i . Sedangkan N merepresentasikan jumlah pengujian berulang (dalam studi ini $N=100$) untuk mendapatkan nilai yang adil. Pengukuran dilakukan secara konsisten pada seluruh arsitektur model untuk memperoleh perbandingan performa komputasi yang objektif.


Tabel 3 Perbandingan Latensi Inferensi CPU Antar Arsitektur Model

Arsitektur Model	Latensi Rata-rata per Sampel (ms)	Standar Deviasi Latensi (ms)	Kategori Kelayakan Real-Time
Baseline LSTM (Univariat 1D)	0,31 ms	0,00 ms	Sangat Tinggi
CNN-LSTM Multimodal	15,58 ms	0,90 ms	Tinggi
CNN-BiLSTM Multimodal	17,72 ms	2,09 ms	Tinggi

Berdasarkan Pers. (12) dan Tabel 3, model LSTM memiliki waktu inferensi rata-rata 0,58 ms per sampel karena hanya memproses deret waktu numerik 1D. Sementara itu, integrasi ekstraksi citra 16-channel dan modul SPIN meningkatkan waktu inferensi menjadi 15,45 ms pada CNN-LSTM dan 9,63 ms pada CNN-BiLSTM. Meskipun terdapat tambahan beban komputasi, waktu inferensi tersebut masih sangat kecil dibandingkan interval sampling 5 menit (300 detik), sehingga tidak menunjukkan kendala latensi yang berarti untuk penerapan pada *edge gateway* PLTS. Perbedaan waktu inferensi ini menunjukkan adanya kompromi antara kompleksitas pemrosesan dan kemampuan representasi model. Model multimodal memerlukan komputasi lebih besar karena harus mengekstraksi fitur spasial dari citra satelit sebelum memodelkan dinamika temporal. Namun, tambahan waktu tersebut tetap berada pada tingkat yang rendah untuk kebutuhan prediksi operasional secara *real-time*.

Grafik pada Gambar 7 model LSTM univariat memiliki latensi inferensi paling rendah, yaitu 0,31 ms, karena hanya memproses deret waktu numerik 1D. Pada model multimodal dengan *multimodal adapter* berdimensi 4.096, waktu inferensi meningkat menjadi $15,58 \pm 0,90$ ms untuk CNN-LSTM dan $17,72 \pm 2,09$ ms untuk CNN-BiLSTM. Latensi CNN-BiLSTM yang lebih tinggi menunjukkan tambahan beban komputasi akibat pemrosesan informasi temporal dalam dua arah. Namun selisih tersebut relatif kecil dan seluruh model multimodal tetap memiliki waktu inferensi yang rendah dibandingkan interval sampling 5 menit (300 detik). Dengan latensi sekitar 15–18 ms per sampel, model masih memiliki efisiensi komputasi yang memadai untuk mendukung prediksi daya PLTS secara *real-time* pada perangkat *edge computing*.





Gambar 7 Perbandingan Waktu Inferensi (Latensi) CPU Empiris Lintas Arsitektur (N = 100)

4. KESIMPULAN

Penelitian ini mengembangkan model prediksi daya PLTS melalui integrasi informasi spasial dari citra satelit Himawari-9 dan data kelistrikan inverter menggunakan arsitektur CNN-LSTM multimodal berbasis *transfer learning*, dengan dukungan transformasi *Solar Polar Image Normalization* (SPIN). Evaluasi pada dataset operasional beresolusi 5 menit (9.622 sampel) menunjukkan bahwa penggabungan informasi visual, kelistrikan, dan temporal mampu meningkatkan kemampuan model dalam mengikuti fluktuasi daya, terutama pada kondisi atmosfer tropis yang berubah secara cepat. Proses sinkronisasi antar sumber data juga dapat dilakukan secara konsisten, sementara *multimodal adapter* membantu menyesuaikan representasi yang diperoleh dari domain sumber dengan karakteristik lingkungan tropis.

Pada validasi periode dengan kondisi atmosfer cukup ekstrem, model yang diusulkan menghasilkan MAE sebesar 3,73 kW, RMSE sebesar 5,61 kW, dan *Forecast Skill* sebesar +5,98% terhadap *baseline Persistence*. Selain itu, Q95 *error* sebesar 12,37 kW menunjukkan kemampuan model dalam mengendalikan galat pada kondisi ekstrem. Dari sisi komputasi, waktu inferensi rata-rata sebesar 15,58 ms per sampel menunjukkan bahwa model masih memiliki efisiensi yang memadai untuk kebutuhan prediksi *real-time*. Secara keseluruhan, hasil tersebut menunjukkan bahwa integrasi citra satelit dan data inverter melalui pendekatan multimodal berbasis *transfer learning* memiliki potensi untuk mendukung implementasi prediksi daya PLTS pada infrastruktur *edge computing* dan aplikasi *smart grid*. Pengembangan model dapat diarahkan pada integrasi *all-sky camera* dan variabel meteorologis tambahan untuk memperkaya representasi kondisi atmosfer. Penggunaan sumber informasi yang lebih beragam diharapkan dapat meningkatkan ketahanan model terhadap variasi cuaca dan memperluas kemampuan sistem dalam mendukung peramalan energi surya pada lingkungan operasi yang dinamis. Dan penelitian ini masih memiliki keterbatasan pada cakupan dataset lokal dengan periode pengamatan yang relatif singkat, sehingga belum sepenuhnya merepresentasikan variasi musiman dalam satu tahun. Oleh karena itu, penelitian selanjutnya perlu memperluas evaluasi ke beberapa lokasi dengan karakteristik iklim yang berbeda, mengintegrasikan variabel meteorologis tambahan, serta mengeksplorasi arsitektur *multimodal Transformer* untuk meningkatkan kemampuan generalisasi dan *robustness* model.



DAFTAR PUSTAKA

- Alcañiz, A., Grzebyk, D., Ziar, H., & Isabella, O. (2023). Trends and Gaps in Photovoltaic Power Forecasting with Machine Learning. *Energy Reports*, 9, 447–471. <https://doi.org/10.1016/j.egyr.2022.11.208>
- Al-Dahidi, S., Alahmer, H., Rinchi, B., Bani-Abdullah, A., Alrbai, M., Ayadi, O., & Al-Ghussain, L. (2025). Multistep PV Power Forecasting Using Deep Learning Models and the Reptile Search Algorithm. *Results in Engineering*, 27, Article ID: 106265. <https://doi.org/10.1016/j.rineng.2025.106265>
- Alsafrani, A., Sherazi, H. I., Alrumayh, O., Habib, S., Alburidy, A. A., & Islam, M. (2025). Photovoltaic Power Forecasting for Sustainable Grid Integration: A Hybrid Deep Learning Approach. *IEEE Access*, 13, 216013–216025. <https://doi.org/10.1109/ACCESS.2025.3640216>
- Badan Meteorologi Klimatologi dan Geofisika. (2025). *Analisis Cuaca Ekstrem Wilayah Banten 3 Maret 2025*. <https://bbmkg2.bmkg.go.id/wp-content/uploads/2025/03/Analisis-Cuaca-Ekstrem-Wilayah-Banten-3-Maret-2025.pdf>
- Benni, N. S., Anil, B. C., Jayasimha, S. R., Girish, K., Vishal, C., & Khaiyum, S. (2026). A Lightweight Deep Learning Framework for Real-Time Predictive Analytics in Edge Computing Environments. *SN Computer Science*, 7(4), Article ID: 361. <https://doi.org/10.1007/s42979-026-04948-z>
- Bramasto, S., & Khairiani, D. (2022). Prediksi Daya Output Sistem Pembangkit Listrik Tenaga Surya (PLTS) Menggunakan Regresi Linear Berganda. *Faktor Exacta*, 15(3), 139–150. <https://doi.org/10.30998/faktorexacta.v15i2.13254>
- Buzzi, L. H., Weihmann, L., & Jaskowiak, P. (2024). Deep Learning and Satellite Images for Photovoltaic Power Forecasting: A Case Study. *Anais Do XVI Congresso Brasileiro de Inteligência Computacional*, 1–8. <https://doi.org/10.21528/CBIC2023-120>
- Dinata, S., Ayob, A. F. M., Albani, A., Abdurahman, Huda, N., Kurniawan, R., & Rozak, O. A. (2024). Real-time Analysis of Inverter Performance via SCADA Haiwell Online Monitoring. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 37(1), 99–114. <https://doi.org/10.37934/araset.37.1.99114>
- Elsaraiti, M., & Merabet, A. (2022). Solar Power Forecasting Using Deep Learning Techniques. *IEEE Access*, 10, 31692–31698. <https://doi.org/10.1109/ACCESS.2022.3160484>
- Ferlito, S., Ippolito, S., Santagata, C., Schiattarella, P., & Di Francia, G. (2024). A Study on an IoT-Based SCADA System for Photovoltaic Utility Plants. *Electronics*, 13(11), Article ID: 2065. <https://doi.org/10.3390/electronics13112065>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification*. <http://arxiv.org/abs/1502.01852>
- Husein, M., Gago, E. J., Hasan, B., & Pegalajar, M. C. (2024). Towards Energy Efficiency: A Comprehensive Review of Deep Learning-Based Photovoltaic Power Forecasting Strategies. *Heliyon*, 10(13), Article ID: e33419. <https://doi.org/10.1016/j.heliyon.2024.e33419>
- Huva, R., Song, G., Zhong, X., & Zhao, Y. (2021). Comprehensive Physics Testing and Adaptive Weather Research and Forecasting Physics for Day-Ahead Solar Forecasting. *Meteorological Applications*, 28(4), Article ID: e2017. <https://doi.org/10.1002/met.2017>
- Kumar, A., Kashyap, Y., & Kosmopoulos, P. (2022). Enhancing Solar Energy Forecast Using Multi-Column Convolutional Neural Network and Multipoint Time Series Approach. *Remote Sensing*, 15(1), Article ID: 107. <https://doi.org/10.3390/rs15010107>
- Liwijaya, A., Risma, P., Oktarina, Y., & Dewi, T. (2025). Implementasi Deep Learning dalam Prediksi Real-Time Irradian Surya. *Journal of Applied Smart Electrical Network and Systems*, 6(2), 90–96. <https://doi.org/10.52158/pvdpsr36>
- Luo, X., & Zhang, D. (2023). A Cascaded Deep Learning Framework for Photovoltaic Power Forecasting with Multi-Fidelity Inputs. *Energy*, 268, Article ID: 126636. <https://doi.org/10.1016/j.energy.2023.126636>
- Nadeem, A., Hanif, M. F., Naveed, M. S., Hassan, M. T., Gul, M., Husnain, N., & Mi, J. (2024). AI-Driven Precision in Solar Forecasting: Breakthroughs in Machine Learning and Deep Learning. *AIMS Geosciences*, 10(4), 684–734. <https://doi.org/10.3934/geosci.2024035>



- Nie, Y., Li, X., Scott, A., Sun, Y., Venugopal, V., & Brandt, A. (2022). *SKIPP'D: A SKy Images and Photovoltaic Power Generation Dataset for Short-term Solar Forecasting*. <http://arxiv.org/abs/2207.00913>
- Oktavia, P., Sutikno, T., & Murinto. (2026). Pemodelan Prediksi Global Horizontal Irradiance Berbasis Data Spasio-Temporal Citra Satelit Himawari Menggunakan Convolutional Neural Network dengan Transfer Learning. *Journal of Information System and Computer*, 6(1), 76–85. <https://doi.org/10.34001/jister.v6i1.2067>
- Paletta, Q., Arbod, G., & Lasenby, J. (2023). Omnivision Forecasting: Combining Satellite and Sky Images for Improved Deterministic and Probabilistic Intra-Hour Solar Energy Predictions. *Applied Energy*, 336, Article ID: 120818. <https://doi.org/10.1016/j.apenergy.2023.120818>
- Rezza, M., Ismail Yusuf, M., & Yacoub, R. R. (2024). Prediksi Radiasi Surya Menggunakan Metode Long Short-Term Memory. *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, 6(1), 33–44. <https://doi.org/10.28926/ilkomnika.v6i1.571>
- Schubnel, B., Simeunovic, J., Tissier, C., Alet, P.-J., & Carrillo, R. E. (2026). SolarCrossFormer: Improving Day-Ahead Solar Irradiance Forecasting by Integrating Satellite Imagery and Ground Sensors. *IEEE Transactions on Sustainable Energy*, 17(2), 1575–1587. <https://doi.org/10.1109/TSTE.2025.3624044>
- Sekretariat Jenderal Dewan Energi Nasional. (2020). *Grand Strategi Energi Nasional*. <https://den.go.id>
- Sharda, S., Singh, M., & Sharma, K. (2021). RSAM: Robust Self-Attention Based Multi-Horizon Model for Solar Irradiance Forecasting. *IEEE Transactions on Sustainable Energy*, 12(2), 1394–1405. <https://doi.org/10.1109/TSTE.2020.3046098>
- Shukla, G., Shukla, A. K., Shukla, K. N., & Dixit, S. (2026). IoT-Enabled Solar PV Systems: Real-Time Monitoring and Efficiency Optimization. *Results in Optics*, 22, Article ID: 100949. <https://doi.org/10.1016/j.rio.2025.100949>
- Sobri, S., Koohi-Kamali, S., & Rahim, N. Abd. (2018). Solar Photovoltaic Generation Forecasting Methods: A Review. *Energy Conversion and Management*, 156, 459–497. <https://doi.org/10.1016/j.enconman.2017.11.019>
- Straub, N., Karalus, S., Herzberg, W., & Lorenz, E. (2024). Satellite-Based Solar Irradiance Forecasting: Replacing Cloud Motion Vectors by Deep Learning. *Solar RRL*, 8(24), Article ID: 2400475. <https://doi.org/10.1002/solr.202400475>
- Surathunmanun, S., Ongsakul, W., Singh, J. G., & Mehran, K. (2026). Short-Term Solar PV Forecasting in Microgrids Using Cloud Top Temperature and Vision Transformer Based Models. *Frontiers in Energy Research*, 13, Article ID: 1691881. <https://doi.org/10.3389/fenrg.2025.1691881>
- Tahir, Z. ul R., Asim, M., Azhar, M., Moeenuddin, G., & Farooq, M. (2021). Correcting Solar Radiation from Reanalysis and Analysis Datasets with Systematic and Seasonal Variations. *Case Studies in Thermal Engineering*, 25, Article ID: 100933. <https://doi.org/10.1016/j.csite.2021.100933>
- Wang, K., Shan, S., Dou, W., Wei, H., & Zhang, K. (2025). A Cross-Modal Deep Learning Method for Enhancing Photovoltaic Power Forecasting with Satellite Imagery and Time Series Data. *Energy Conversion and Management*, 323, Article ID: 119218. <https://doi.org/10.1016/j.enconman.2024.119218>
- Wang, Y., Liao, W., & Chang, Y. (2018). Gated Recurrent Unit Network-Based Short-Term Photovoltaic Forecasting. *Energies*, 11(8), Article ID: 2163. <https://doi.org/10.3390/en11082163>
- Xiao, Z., Gao, B., Huang, X., Chen, Z., Li, C., & Tai, Y. (2024). An Interpretable Horizontal Federated Deep Learning Approach to Improve Short-Term Solar Irradiance Forecasting. *Journal of Cleaner Production*, 436, Article ID: 140585. <https://doi.org/10.1016/j.jclepro.2024.140585>
- Yin, W., Han, Y., Zhou, H., Ma, M., Li, L., & Zhu, H. (2020). A Novel Non-Iterative Correction Method for Short-Term Photovoltaic Power Forecasting. *Renewable Energy*, 159, 23–32. <https://doi.org/10.1016/j.renene.2020.05.134>

