



## Implementasi Deep Learning Dalam Prediksi Real time Iridian Surya

Angga Liwijaya<sup>1</sup>, Pola Risma<sup>2</sup>, Tresna Dewi<sup>3</sup>, Yurni Oktarina<sup>4</sup>

<sup>1</sup>Departement of Electrical Engineering

Politeknik Negeri Sriwijaya

Jalan Sriwijaya Negara

Palembang, Indonesia

<sup>1</sup>[bbm360909@gmail.com](mailto:bbm360909@gmail.com)<sup>\*</sup>, <sup>2</sup>[polarisma@polsri.ac.id](mailto:polarisma@polsri.ac.id), <sup>3</sup>[tresna\\_dewi@polsri.ac.id](mailto:tresna_dewi@polsri.ac.id), <sup>4</sup>[yurni\\_oktarina@polsri.ac.id](mailto:yurni_oktarina@polsri.ac.id)

### Abstract

Accurate prediction of solar irradiance plays a critical role in the planning and operation of renewable energy systems, particularly for photovoltaic integration and energy management. This study investigates the use of a deep learning approach based solely on Convolutional Neural Networks (CNN) to forecast short-term solar irradiance values. The model is trained using normalized multivariate time series data, which include several meteorological parameters as input features. The CNN architecture is designed to extract temporal patterns from the input sequences and predict radiation intensity at the next time step. Experimental results show that the proposed model achieves strong predictive performance, with a Mean Squared Error (MSE) of 0.0006, Root Mean Squared Error (RMSE) of 0.0242, Mean Absolute Error (MAE) of 0.0184, and a coefficient of determination ( $R^2$ ) of 0.9607. These findings demonstrate that CNN, despite its simplicity, is capable of effectively learning complex temporal relationships in solar irradiance data. Furthermore, the loss curves for both training and validation sets indicate stable convergence without signs of overfitting. The results suggest that CNN-based forecasting models can offer a lightweight and accurate solution for real-time solar prediction applications, especially when computational resources are limited. This study highlights that a lightweight standalone CNN can achieve stable and competitive performance without relying on recurrent architectures, making it suitable for real-time solar irradiance forec

**Keywords:** Solar Irradiance Forecasting, Convolutional Neural Network, Deep Learning, Time Series Prediction, Renewable Energy.

### Abstrak

Prediksi yang akurat dari iradian surya memainkan peran penting dalam perencanaan dan pengoperasian sistem energi terbarukan, terutama untuk integrasi fotovoltaik dan manajemen energi. Studi ini menyelidiki penggunaan pendekatan pembelajaran mendalam yang hanya didasarkan pada Jaringan Saraf Tiruan (CNN) untuk meramalkan nilai iradian surya jangka pendek. Model ini dilatih menggunakan data deret waktu multivariat yang dinormalisasi, yang mencakup beberapa parameter meteorologi sebagai fitur input. Arsitektur CNN dirancang untuk mengekstrak pola temporal dari urutan *input* dan memprediksi intensitas radiasi pada langkah waktu berikutnya. Hasil eksperimen menunjukkan bahwa model yang diusulkan mencapai kinerja prediktif yang kuat, dengan *Mean Squared Error* (MSE) sebesar 0.0006, *Root Mean Squared Error* (RMSE) sebesar 0.0242, *Mean Absolute Error* (MAE) sebesar 0.0184, dan koefisien determinasi ( $R^2$ ) sebesar 0.9607. Temuan ini menunjukkan bahwa CNN, terlepas dari kesederhanaannya, mampu secara efektif mempelajari hubungan temporal yang kompleks dalam data peninjauan matahari. Selain itu, kurva kerugian untuk *set* pelatihan dan validasi menunjukkan konvergensi yang stabil tanpa tanda-tanda *overfitting*. Hasil penelitian menunjukkan bahwa model prakiraan berbasis CNN dapat menawarkan solusi yang ringan dan akurat untuk aplikasi prediksi matahari secara *real-time*, terutama ketika sumber daya komputasi terbatas. Penelitian ini menegaskan bahwa CNN standalone yang ringan mampu memberikan performa prediksi yang stabil tanpa bergantung pada arsitektur rekuren, sehingga berpotensi diterapkan untuk prediksi iradian surya secara waktu nyata.

Kata Kunci: Prakiraan Iridian Surya, Jaringan Saraf Konvolusi, Pembelajaran Mendalam, Prediksi Deret Waktu, Energi Terbarukan.

Diterima Redaksi : 03-06-2025 | Selesai Revisi : 30-12-2025 | Diterbitkan Online : 31-12-2025

### 1. Pendahuluan

CNN dipilih dalam penelitian ini karena kemampuannya mengekstraksi pola temporal lokal secara efisien tanpa memerlukan memori jangka

panjang seperti pada LSTM atau GRU. Pada prediksi iradian surya jangka pendek, fluktuasi cepat akibat perubahan kondisi atmosfer dan pola harian lebih dominan dibandingkan ketergantungan temporal jangka

panjang, sehingga CNN menjadi alternatif yang lebih prediksi iradian surya jangka pendek berbasis CNN. ringan dan efisien dengan kompleksitas komputasi rendah serta sesuai untuk aplikasi waktu nyata. Di sisi lain, pemanfaatan energi terbarukan seperti surya, angin, dan biogas menjadi solusi penting untuk meningkatkan akses energi, khususnya di daerah dengan rasio elektrifikasi rendah seperti Tulakan, Jawa Timur. Simulasi menunjukkan bahwa kombinasi sumber energi terbarukan tersebut mampu menghasilkan output energi yang signifikan dan mendukung pencapaian elektrifikasi hingga 100%. [1]. Selain itu, kemajuan dalam pemodelan prediktif dan teknik pembelajaran mesin memiliki potensi untuk merevolusi cara kita meramalkan iradian surya, sehingga meningkatkan efisiensi sistem fotovoltaik. Dengan memanfaatkan data cuaca historis dan kondisi atmosfer secara *real-time*, teknologi ini dapat memberikan prakiraan yang lebih akurat yang dapat beradaptasi dengan perubahan faktor lingkungan, yang pada akhirnya menghasilkan solusi manajemen dan penyimpanan energi yang lebih baik. Sebagai contoh, di Indonesia, di mana energi surya melimpah namun kurang dimanfaatkan, penerapan sistem prediktif semacam itu dapat secara signifikan meningkatkan kelayakan proyek tenaga surya, selaras dengan tujuan pemerintah untuk mencapai 23% penggunaan energi terbarukan pada tahun 2025 [2]. Selain itu, mengintegrasikan model-model prediktif ini dengan teknologi smart grid dapat memfasilitasi infrastruktur energi yang lebih tangguh, yang mampu merespons fluktuasi pasokan dan permintaan secara dinamis sekaligus mengurangi ketergantungan pada bahan bakar fosil [3]. Sebagai alternatif, pendekatan berbasis machine learning dapat digunakan untuk meningkatkan akurasi prediksi [4].

Model ini diharapkan dapat meningkatkan akurasi prediksi dan membantu dalam pengambilan keputusan terkait penggunaan energi terbarukan [8]. Tidak seperti pendekatan hibrida yang menggabungkan CNN dengan model lain seperti LSTM, studi ini mengeksplorasi efektivitas CNN secara mandiri dalam memprediksi nilai radiasi menggunakan data lingkungan multivariat. Meskipun CNN dapat memberikan hasil yang menjanjikan, penting untuk mempertimbangkan potensi penggabungan dengan model lain untuk meningkatkan akurasi prediksi [9]. Model diuji menggunakan data historis yang telah dinormalisasi, dengan target untuk memprediksi nilai radiasi pada langkah waktu berikutnya. Evaluasi dilakukan menggunakan metrik kuantitatif seperti MSE, RMSE, MAE, dan koefisien determinasi *R-squared* ( $R^2$ ) untuk memberikan gambaran yang komprehensif tentang kinerja model, serta analisis visual terhadap kurva *loss* dan hasil prediksi [12]. Tujuan dari penelitian ini akan mengidentifikasi potensi CNN dalam mengoptimalkan penggunaan energi terbarukan dengan memanfaatkan data iradian surya yang akurat dan tepat waktu, serta penelitian ini diharapkan dapat memberikan wawasan baru mengenai penerapan teknologi CNN dalam peramalan data yang dapat meningkatkan efisiensi sistem energi pintar berbasis IoT [13], [10]. Penelitian ini juga bertujuan untuk memberikan kontribusi terhadap literatur dengan menawarkan pendekatan yang harapkan dapat meningkatkan pemahaman dan aksesibilitas bagi peneliti dan praktisi yang ingin menerapkan teknologi dalam analisis data [11].

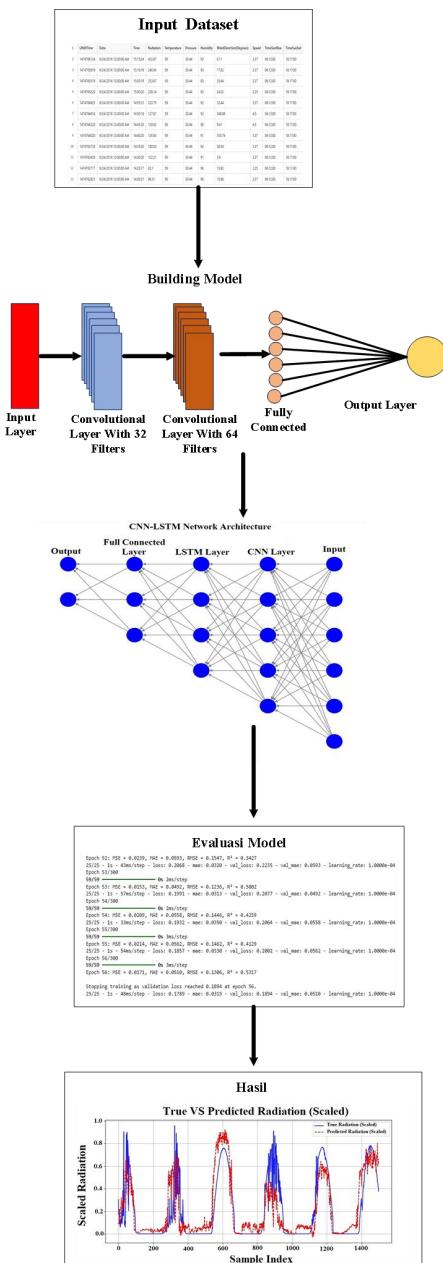
Oleh karena itu, penelitian ini berfokus pada evaluasi penggunaan Convolutional Neural Network (CNN) standalone berarsitektur sederhana untuk prediksi iradian surya jangka pendek. Berbeda dengan penelitian sebelumnya yang menggunakan model rekuren atau pendekatan hibrida yang kompleks, penelitian ini menunjukkan bahwa CNN dengan kompleksitas rendah mampu mencapai konvergensi yang stabil dan performa prediksi yang tinggi. Pendekatan ini diharapkan menjadi solusi yang efisien dan layak untuk prediksi waktu nyata pada sistem energi pintar dengan keterbatasan sumber daya komputasi. [5]. Dalam beberapa tahun terakhir, pendekatan pembelajaran mendalam (*deep learning*) telah menunjukkan potensi yang besar dalam memodelkan data deret waktu, termasuk untuk prediksi cuaca dan energi. CNN telah terbukti efektif dalam berbagai aplikasi, dan adaptasinya untuk analisis deret waktu menunjukkan hasil yang menjanjikan dalam prediksi yang lebih akurat [6]. Dengan kemampuan ini, CNN menjadi alat yang sangat efektif dalam berbagai aplikasi, termasuk pengenalan suara dan analisis video [7]. Penelitian ini berfokus pada pengembangan dan evaluasi model

Kontribusi utama dari penelitian ini adalah menunjukkan bahwa model Convolutional Neural Network (CNN) standalone dengan arsitektur yang sederhana mampu mencapai performa prediksi yang stabil dan kompetitif untuk prediksi iradian surya jangka pendek. Berbeda dengan sebagian besar penelitian sebelumnya yang mengandalkan model rekuren seperti LSTM/GRU atau arsitektur hibrida yang lebih kompleks, penelitian ini menekankan bahwa dependensi temporal jangka panjang tidak selalu diperlukan untuk prediksi iradian surya *real-time*. Pemilihan transformasi fitur berbasis Conv1D dengan kernel size kecil memungkinkan model mencapai kompleksitas komputasi yang rendah tanpa mengorbankan akurasi secara signifikan. Dengan demikian, kontribusi penelitian ini bersifat implementatif dan kontekstual, khususnya untuk sistem energi pintar dan perangkat edge dengan keterbatasan sumber daya komputasi..

## 2. Metode Penelitian

Penelitian ini menggunakan pendekatan deep learning berbasis *Convolutional Neural Network* (CNN) untuk melakukan prediksi nilai iradian surya berdasarkan data historis multivariat. Metode ini memungkinkan analisis yang lebih akurat dan efisien terhadap pola iradian

surya dengan memanfaatkan kemampuan CNN dalam variabel lingkungan seperti suhu, kelembapan, kecepatan angin, dan tekanan udara, dengan kolom Proses penelitian mencakup tahapan persiapan data, arsitektur model, pelatihan, evaluasi, dan visualisasi hasil. Setiap tahapan tersebut memiliki peran penting dalam memastikan kualitas dan akurasi dari model yang dihasilkan [15]. Diagram blok keseluruhan proses ditunjukkan pada Gambar 1.



Gambar 1. Diagram Blok Keseluruhan CNN

## 2.1. Dataset dan Pra-Pemrosesan

Data iradian surya yang digunakan dalam penelitian ini berasal dari dua berkas CSV, yaitu *Radiation\_test.csv* untuk data latih dan *Radiation\_valid.csv* untuk data uji. Data ini akan dianalisis untuk memahami pola iradian surya yang dapat berpengaruh terhadap berbagai fenomena lingkungan [16]. Kedua dataset berisi

lingkungan seperti suhu, kelembapan, kecepatan angin, dan tekanan udara, dengan kolom target berupa nilai iradian surya. Data ini akan membantu dalam menganalisis hubungan antara variabel lingkungan dan iradian surya yang diterima [17]. Sebelum digunakan dalam pelatihan model, data mengalami beberapa tahapan pra-pemrosesan:

**Penghapusan kolom Irrelevant:** Kolom seperti *UNIXTime*, *Data*, *Time*, *TimeSunRise*, dan *TimeSunSet* dihapus karena tidak memberikan kontribusi langsung terhadap proses prediksi.

**Pemisahan Fitur dan Target:** Data dibagi menjadi variabel *input* (X) dan target *output* (y), di mana *Radiation* dijadikan sebagai variabel target.

**Normalisasi:** Untuk memastikan semua fitur berada pada skala yang sama, digunakan *MinMaxScaler* untuk mereduksi nilai ke rentang [0, 1].

Normalisasi dilakukan baik untuk fitur *input* maupun target *output*. **Reshape Data:** Dataset diubah ke dalam format tiga dimensi [samples, time steps, features] untuk memenuhi struktur *input* yang dibutuhkan oleh *layer CNN 1D*.

## 2.2. Arsitektur Model CNN

Model CNN dibangun menggunakan framework *TensorFlow* dan Keras untuk memudahkan implementasi dan pelatihan model *deep learning*. *TensorFlow* dan Keras menyediakan alat yang fleksibel untuk pengembangan aplikasi berbasis jaringan saraf [18]. Arsitektur yang digunakan terdiri dari beberapa lapisan utama, yaitu:

**Conv1D Layer:** Digunakan untuk mengekstraksi fitur lokal dari data input deret waktu. Layer ini menggunakan 16 filter dengan ukuran kernel 1 dan aktivasi ReLU. Pemilihan kernel size sebesar 1 bertujuan untuk melakukan transformasi fitur pada setiap time step tanpa mencampurkan informasi temporal antar waktu. Pendekatan ini memungkinkan CNN untuk fokus pada hubungan antar fitur lingkungan pada satu titik waktu, sekaligus mengurangi kompleksitas komputasi. Desain ini sesuai untuk prediksi iradian surya jangka pendek, di mana perubahan cepat antar fitur lebih dominan dibanding ketergantungan temporal jangka panjang. Layer ini berfungsi untuk meningkatkan kemampuan model dalam mengenali pola yang lebih kompleks dalam data deret waktu [19].

**Dropout Layer:** *Dropout* sebesar 10% diterapkan setelah *Conv1D* untuk mengurangi *overfitting*, dan teknik ini telah terbukti efektif dalam meningkatkan kinerja model pada berbagai tugas pembelajaran terawasi [20].

**Flatten Layer:** Lapisan ini mengubah keluaran dari dimensi 3D menjadi 1D agar dapat diteruskan ke *layer Dense*.

*Dense Layer:* Dua *layer dense* digunakan, yaitu satu dengan 32 unit dan aktivasi ReLU, serta satu *layer output* dengan satu neuron tanpa fungsi aktivasi untuk menghasilkan prediksi akhir. Penambahan *layer* ini bertujuan untuk meningkatkan akurasi model dalam klasifikasi data, sejalan dengan temuan bahwa fungsi aktivasi ReLU menunjukkan kinerja yang lebih baik dalam *neural network* [21], [22].

Model dikompilasi menggunakan *Adam Optimizer* dengan learning rate sebesar 0.0005 dan menggunakan *Mean Squared Error* (MSE) sebagai fungsi *loss*. Model ini diharapkan dapat meningkatkan akurasi deteksi mengingat *Adam Optimizer* telah terbukti efektif dalam pelatihan model klasifikasi sebelumnya [23], [24].

### 2.3. Proses Pelatihan dan Validasi

Model dilatih selama 20 *epoch* dengan batch size sebesar 64, menggunakan data latih dan divalidasi terhadap data uji. Proses pelatihan dilakukan tanpa *early stopping*, namun jumlah *epoch* dibatasi untuk menghindari *overfitting* dan menjaga stabilitas proses *training*. Hasil evaluasi menunjukkan bahwa model mampu mencapai akurasi yang memuaskan pada data uji [30].

Selama pelatihan, nilai *loss* untuk data pelatihan dan validasi dicatat untuk dianalisis dan divisualisasikan. Evaluasi model dilakukan berdasarkan hasil prediksi terhadap data uji, kemudian dibandingkan dengan nilai aktual untuk menghitung metrik performa. Proses ini penting untuk memahami seberapa baik model dapat menangkap pola dalam data yang lebih besar [25].

### 2.4. Evaluasi Model

Evaluasi dilakukan dalam skala normalisasi [0–1] menggunakan beberapa metrik umum untuk regresi, yaitu:

#### Mean Squared Error (MSE)

MSE menghitung rata-rata dari kuadrat selisih antara nilai aktual ( $y_i$ ) dan prediksi model ( $\hat{y}_i$ ). Karena selisihnya dikuadratkan, MSE sangat peka terhadap *outlier* atau kesalahan besar. Nilai MSE yang rendah menunjukkan bahwa rata-rata kesalahan kuadrat prediksi terhadap data aktual kecil. Berikut rumus MSE:

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

#### Root Mean Squared Error (RMSE)

RMSE adalah akar kuadrat dari MSE. Keunggulannya adalah satuannya sama dengan target output (misalnya jika prediksi dalam satuan  $W/m^2$ , maka RMSE juga dalam  $W/m^2$ ). RMSE sering digunakan dalam analisis kinerja sistem MIMO (*multiple input, multiple output*) untuk memberikan gambaran yang lebih jelas tentang kesalahan prediksi dibandingkan dengan MSE, karena satuan yang konsisten dengan *output* target [26]. RMSE memberikan gambaran tentang seberapa jauh prediksi

model menyimpang dari nilai sebenarnya secara rata-rata. Nilai lebih kecil = prediksi lebih akurat. Berikut rumus RMSE:

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

#### Mean Absolute Error (MAE)

MAE mengukur rata-rata selisih absolut (tanpa arah) antara prediksi dan nilai aktual. Tidak seperti MSE dan RMSE, MAE tidak mengkuadratkan selisih, sehingga tidak terlalu dipengaruhi oleh outlier. Nilai MAE mudah diinterpretasi: berapa rata-rata "jarak" antara prediksi dan data aktual. MAE merupakan metrik yang sering digunakan dalam evaluasi model prediksi untuk memberikan gambaran yang lebih jelas tentang akurasi model [27]. Berikut rumus MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

#### Koefisien Determinasi ( $R^2$ )

$R^2$  menunjukkan berapa proporsi variasi dalam data aktual yang bisa dijelaskan oleh model,  $\hat{y}_i$  adalah nilai rata – rata dari seluruh aktual,  $R^2$  Menggambarkan sejauh mana model mampu menjelaskan variansi dari data aktual; semakin mendekati 1, semakin baik kemampuan prediktif model tersebut. Berikut rumus  $R^2$ :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Nilainya berkisar antara 0 dan 1:

$R^2 = 1 \rightarrow$  prediksi sempurna.

$R^2 = 0 \rightarrow$  model tidak lebih baik dari rata-rata.

Bisa negatif jika model sangat buruk.

Selain evaluasi numerik, juga dilakukan visualisasi hasil berupa grafik perbandingan antara *loss* pelatihan dan validasi, serta grafik prediksi terhadap nilai aktual untuk menilai kemampuan model dalam mengikuti pola temporal iradian surya. Grafik ini diharapkan dapat memberikan wawasan yang lebih mendalam mengenai performa model serta area yang perlu diperbaiki untuk meningkatkan akurasi prediksi [28]. Dengan demikian, analisis ini akan menjadi langkah penting dalam pengembangan model yang lebih *robust* dan adaptif terhadap perubahan pola radiasi [29].

### 3. Hasil dan Pembahasan

Penelitian ini mengevaluasi kinerja model CNN dalam memprediksi nilai iradian surya berdasarkan data waktu nyata yang telah dinormalisasi. Hasil pengujian dilakukan pada data uji yang terpisah dan tidak digunakan selama proses pelatihan. Evaluasi mencakup metrik numerik dan analisis visual terhadap grafik loss serta grafik prediksi.

### 3.1. Hasil Evaluasi Model

Model CNN dilatih selama 20 *epoch* dengan *batch size* sebesar 64. Setelah pelatihan, prediksi dilakukan terhadap data uji, dan hasilnya dibandingkan dengan data aktual menggunakan empat metrik evaluasi. Ringkasan hasil evaluasi ditampilkan pada Tabel 1.

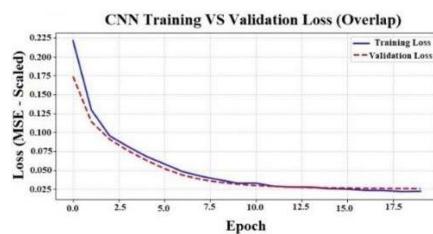
Tabel 1. Hasil evaluasi model CNN pada data uji (skala normalisasi)

| Metrik                          | Nilai  |
|---------------------------------|--------|
| Mean Squared Error (MSE)        | 0.0006 |
| Root Mean Squared Error (RMSE)  | 0.0242 |
| Mean Absolute Error (MAE)       | 0.0184 |
| Koefisien Determinasi ( $R^2$ ) | 0.9607 |

Nilai RMSE sebesar 0.0242 menunjukkan bahwa rata-rata kesalahan prediksi berada pada tingkat yang rendah dalam skala 0–1. Demikian pula, nilai MAE sebesar 0.0184 menunjukkan bahwa kesalahan mutlak rata-rata dalam prediksi juga tergolong kecil. Nilai  $R^2$  sebesar 0.9607 mengindikasikan bahwa model mampu menjelaskan sekitar 96% variasi data aktual, menandakan performa yang sangat baik dalam menangkap pola temporal iradian surya. Nilai RMSE sebesar 0.0242 menunjukkan bahwa rata-rata kesalahan prediksi berada pada tingkat yang rendah dalam skala 0–1. Demikian pula, nilai MAE sebesar 0.0184 menunjukkan bahwa kesalahan mutlak rata-rata dalam prediksi juga tergolong kecil. Nilai  $R^2$  sebesar 0.9607 mengindikasikan bahwa model mampu menjelaskan sekitar 96% variasi data aktual, menandakan performa yang sangat baik dalam menangkap pola temporal iradian surya.

### 3.2. Analisis Kurva Loss

Untuk mengevaluasi stabilitas pelatihan, dilakukan analisis terhadap grafik loss selama pelatihan, baik pada data latih maupun validasi. Grafik disajikan pada Gambar 2.



Gambar 1. Grafik *Training* dan *Validation Loss*

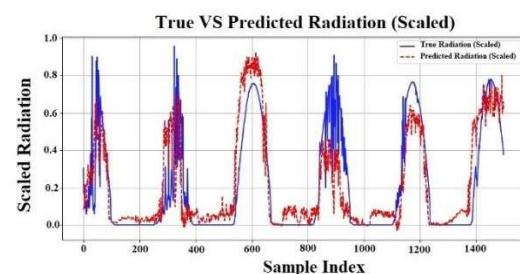
Grafik menunjukkan bahwa *training loss* dan *validation loss* mengalami penurunan yang stabil dan konvergen. Tidak ditemukan perbedaan mencolok antara keduanya, yang menandakan bahwa model tidak mengalami *overfitting*. *Validasi loss* bergerak sejajar dengan *training loss* hingga akhir pelatihan, menunjukkan bahwa model dapat melakukan generalisasi terhadap data yang belum pernah dilihat.

dengan *training loss* hingga akhir pelatihan, menunjukkan bahwa model dapat melakukan generalisasi terhadap data yang belum pernah dilihat. Konvergensi yang cepat dan stabil ini juga didukung oleh penggunaan *learning rate* rendah dan *layer dropout* sebesar 10%, yang berfungsi untuk mencegah model terlalu bergantung pada pola tertentu dalam data latih. Grafik menunjukkan bahwa *training loss* dan *validation loss* mengalami penurunan yang stabil dan konvergen. Tidak ditemukan perbedaan mencolok antara keduanya, yang menandakan bahwa model tidak mengalami *overfitting*. *Validasi loss* bergerak sejajar dengan *training loss* hingga akhir pelatihan, menunjukkan bahwa model dapat melakukan generalisasi terhadap data yang belum pernah dilihat.

Konvergensi yang cepat dan stabil ini juga didukung oleh penggunaan *learning rate* rendah dan *layer dropout* sebesar 10%, yang berfungsi untuk mencegah model terlalu bergantung pada pola tertentu dalam data latih.

### 3.3. Visualisasi Hasil Prediksi

Untuk menilai kemampuan model secara visual, dilakukan perbandingan antara hasil prediksi dan data aktual. Grafik hasil prediksi terhadap data aktual ditampilkan pada Gambar 3.



Gambar 2. Grafik perbandingan nilai aktual dan prediksi iradian surya

Dari Gambar 2, terlihat bahwa prediksi model (garis putus-putus) mengikuti pola data aktual (garis solid) dengan sangat baik. Puncak-puncak pada siang hari dan penurunan mendadak pada sore atau pagi hari berhasil ditangkap dengan akurat oleh model. Pola periodik harian dan variasi jangka pendek akibat kondisi cuaca seperti awan juga terlihat dapat diakomodasi oleh CNN.

Deviasi kecil, terutama saat terjadi perubahan ekstrem off yang seimbang antara akurasi dan kompleksitas, yang cepat (misalnya lonjakan atau penurunan mendadak dalam waktu singkat). Hal ini umum terjadi pada model deret waktu dan dapat diatasi dengan memasukkan fitur tambahan seperti kelembapan, tutupan awan, atau indeks UV.

### 3.4. Pembahasan

Hasil evaluasi menunjukkan bahwa model CNN memiliki kapabilitas yang tinggi dalam melakukan prediksi jangka pendek terhadap data iradian surya. Meskipun CNN tidak memiliki mekanisme memori jangka panjang seperti LSTM atau GRU, arsitektur ini tetap mampu menangkap pola temporal secara efektif karena data disiapkan dengan representasi fitur yang cukup lengkap serta didukung oleh proses normalisasi yang tepat. Hasil eksperimen juga memperlihatkan bahwa CNN mampu mengenali pola periodik harian dan fluktuasi cepat iradian surya dengan baik, yang mengindikasikan bahwa pada prediksi iradian surya jangka pendek, dependensi temporal jangka panjang tidak selalu menjadi faktor dominan. Pola lokal dan perubahan cepat yang tercermin dalam fitur meteorologi terbukti sudah cukup informatif untuk menghasilkan prediksi yang akurat.

Arsitektur CNN yang relatif dangkal dan tidak bersifat rekuren memberikan keuntungan dari sisi efisiensi komputasi. Tidak adanya proses backpropagation through time mengurangi beban komputasi selama pelatihan maupun inferensi. Hal ini menjadi keunggulan penting untuk aplikasi prediksi waktu nyata, khususnya pada sistem dengan keterbatasan sumber daya seperti perangkat edge atau sistem energi berbasis IoT.

Performa tinggi dengan kompleksitas model yang relatif rendah menunjukkan bahwa CNN berpotensi menjadi solusi efisien untuk sistem prediksi waktu nyata, khususnya pada perangkat dengan keterbatasan sumber daya komputasi seperti *edge devices* atau *IoT node*.

Meskipun menunjukkan performa yang baik, model CNN memiliki beberapa keterbatasan. CNN kurang efektif dalam menangkap dependensi temporal jangka panjang dan variasi musiman yang kompleks dibandingkan model rekuren. Selain itu, pada kondisi ekstrem seperti perubahan cuaca yang sangat cepat atau tingkat awan tinggi, deviasi prediksi masih dapat terjadi. Arsitektur dan hyperparameter yang digunakan juga belum dieksplorasi secara menyeluruh. Oleh karena itu, pengembangan lebih lanjut seperti penggunaan model hibrida CNN-LSTM, mekanisme attention, atau optimasi hyperparameter otomatis dapat menjadi arah penelitian selanjutnya.

## 4. Kesimpulan

Temuan utama penelitian ini adalah bahwa CNN dengan arsitektur sederhana dapat memberikan trade-

Penelitian ini menunjukkan bahwa model deep learning berbasis *Convolutional Neural Network* (CNN) dapat digunakan secara efektif untuk melakukan prediksi jangka pendek terhadap nilai iradian surya. Dengan memanfaatkan data *historis multivariat* yang telah dinormalisasi dan diproses dalam *format deret waktu*, model CNN yang dikembangkan berhasil mencapai kinerja yang tinggi, ditandai dengan nilai RMSE sebesar 0.0242, MAE sebesar 0.0184, dan *koefisien determinasi* ( $R^2$ ) sebesar 0.9607 pada data uji.

Model mampu mengenali pola periodik dan fluktuasi harian iradian surya secara konsisten, serta menunjukkan kurva pelatihan dan validasi yang stabil tanpa indikasi overfitting. Hal ini membuktikan bahwa arsitektur CNN, meskipun sederhana dan ringan, tetap memiliki kemampuan yang baik dalam mengekstraksi fitur temporal dari data lingkungan.

Temuan ini mengindikasikan bahwa CNN dapat menjadi alternatif efisien untuk prediksi energi surya berbasis waktu nyata, khususnya dalam penerapan di sistem energi pintar atau perangkat IoT yang memiliki keterbatasan sumber daya. Ke depan, pengembangan model dapat ditingkatkan melalui penambahan fitur eksternal, optimasi arsitektur, serta penggunaan teknik *hybrid* dan *attention mechanism* untuk menangani prediksi dalam kondisi cuaca yang lebih kompleks.

## Daftar Rujukan

- [1] Husnayain, F. (2023). Studi Tekno-Ekonomi Sistem Fotovoltaik On-Grid Pada Bangunan Industri Kontrol Satelit. *Electrices: Jurnal Otomasi Kelistrikan Dan Energi Terbarukan*. <https://doi.org/10.32722/ees.v5i1.5778>.
- [2] Failaq, M. R. F., & Nusantara, I. A. P. (2024). Irisan Penguasaan Negara dan Desentralisasi dalam Prospek Pengaturan Energi Terbarukan di Indonesia. *Jurnal Konstitusi*. <https://doi.org/10.31078/jk2117>.
- [3] Bala, R., & Singh, R. (2022). Prediction of Incident Solar Radiation Using a Hybrid Kernel Based Extreme Learning Machine. *International Journal on Artificial Intelligence Tools*. <https://doi.org/10.1142/s0218213023500045>
- [4] Li, L., Huang, S.-W., Ouyang, Z., & Li, N. (2022, May 20). A Deep Learning Framework for Non-stationary Time Series Prediction. 2022 3rd International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications (CVIDL & ICCEA). <https://doi.org/10.1109/cvidlceea56201.2022.9824863>
- [5] Tzelepi, M., Symeonidis, C., Nousi, P., Kakaletsis, E., Tosidis, P., Nikolaidis, N., & Tefas, A. (2023). Deep Learning for Energy Time-Series Analysis and Forecasting. *arXiv.Org*. <https://doi.org/10.48550/arXiv.2306.09129>
- [6] Wibawa, A. P., Putra Utama, A. B., Elmunsyah, H., Pujianto, U., Dwiyanto, F. A., & Hernandez, L. (2022). Time-series analysis with smoothed Convolutional Neural Network. *Journal of Big Data*. <https://doi.org/10.1186/s40537-022-00599-y>

- [7] Yuzer, E. O., & Bozkurt, A. (2022). Deep learning model for regional solar radiation estimation using satellite images. *Ain Shams Engineering Journal*. <https://doi.org/10.1016/j.asej.2022.102057>
- [8] Shenton-Taylor, C. (2023). A convolutional neural network algorithm developed for shielded multi-isotope identification. *Journal of Instrumentation*. <https://doi.org/10.1088/1748-0221/18/05/P05043>
- [9] Rhouma, A., & Said, Y. (2023). Solar Energy Forecasting Based on Complex Valued Auto-encoder and Recurrent Neural Network. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2023.0140443>
- [10] Schipper, F., van Sloun, R. J. G., Grassi, A., Overeem, S., & Fonseca, P. (2023). A deep-learning approach to assess respiratory effort with a chest-worn accelerometer during sleep. *Biomedical Signal Processing and Control*. <https://doi.org/10.1016/j.bspc.2023.104726>
- [11] Henderson, K., McDermott, T., Van Aken, E. M., & Salado, A. (2022). Towards Developing Metrics to Evaluate Digital Engineering. *Systems Engineering*. <https://doi.org/10.1002/sys.21640>
- [12] Prawiyogi, A. G., & Anwar, A. S. (2023). Perkembangan Internet of Things (IoT) pada Sektor Energi : Sistematik Literatur Review. <https://doi.org/10.34306/mentari.v1i2.254>
- [13] Alizamir, M., Shiri, J., Fakheri Fard, A., Kim, S., Docheshmeh Gorgij, A., Heddam, S., & Singh, V. P. (2023). Improving the accuracy of daily solar radiation prediction by climatic data using an efficient hybrid deep learning model: Long short-term memory (LSTM) network coupled with wavelet transform. *Engineering Applications of Artificial Intelligence*. <https://doi.org/10.1016/j.engappai.2023.106199>
- [14] The Main Stages of the Research Process - A Review of the Literature. (2023). *International Journal of Research and Review*. <https://doi.org/10.52403/ijrr.20230779>
- [15] Sevli, O., & Okatan, E. (2023). Predicting Solar Radiation Based on Meteorological Data Using Machine Learning Techniques: A Case Study of Isparta. *Uluslararası Mühendislik Araşturma ve Geliştirme Dergisi*. <https://doi.org/10.29137/umagd.1268055>
- [16] Gupta, P., & Tomar, A. (2023). Multi-model approach applied to meteorological data for solar radiation forecasting using data-driven approaches. *Optik*. <https://doi.org/10.1016/j.ijleo.2023.170957>
- [17] CNN Models Acceleration Using Filter Pruning and Sparse Tensor Core. (2022). [https://doi.org/10.15803/ijnc.12.2\\_270](https://doi.org/10.15803/ijnc.12.2_270)
- [18] Convolutional Neural Networks for Time-dependent Classification of Variable-length Time Series. (2022, July 18). *2022 International Joint Conference on Neural Networks (IJCNN)*. <https://doi.org/10.1109/ijcnn55064.2022.9892605>
- [19] Liu, Z., Xu, Z., Jin, J., Shen, Z., & Darrell, T. (2023). Dropout Reduces Underfitting. *arXiv.Org*. <https://doi.org/10.48550/arXiv.2303.01500>
- [20] Dense Prediction with Attentive Feature Aggregation. (2023, January 1). *2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. <https://doi.org/10.1109/wacv56688.2023.00018>
- [21] Firmansyah, I., & Hayadi, B. H. (2022). Komparasi Fungsi Aktivasi Relu Dan Tanh Pada Multilayer Perceptron. *JKO (Jurnal Informatika Dan Komputer)*. <https://doi.org/10.26798/jko.v6i2.600>
- [22] Reyad, M. M., Sarhan, A., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-023-08568-z>
- [23] Anggara, D., Suarna, N., & Wijaya, Y. A. (2023). Analisa perbandingan performa optimizer adam, sgd, dan rmsprop pada model h5. *Networking Engineering Research Operation*. <https://doi.org/10.21107/nero.v8i1.19226>
- [24] Cabot, J., & Gyang Ross, E. (2023). Evaluating prediction model performance. *Surgery*. <https://doi.org/10.1016/j.surg.2023.05.023>
- [25] Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*. <https://doi.org/10.5194/gmd-15-5481-2022>
- [26] Robeson, S. M., & Willmott, C. J. (2023). Decomposition of the mean absolute error (MAE) into systematic and unsystematic components. *PLOS ONE*. <https://doi.org/10.1371/journal.pone.0279774>
- [27] Benkirane, S., Guezzaz, A., Azrour, M., & Beni-Hssane, A. (2023). A Novel Machine Learning Approach for Solar Radiation Estimation. *Sustainability*. <https://doi.org/10.3390/su151310609>
- [28] Gao, Y., Miyata, S., & Akashi, Y. (2022). Interpretable deep learning models for hourly solar radiation prediction based on graph neural network and attention. *Applied Energy*. <https://doi.org/10.1016/j.apenergy.2022.119288>
- [29] Golan, T., Siegelman, M., Kriegeskorte, N., & Baldassano, C. (2022). Testing the limits of natural language models for predicting human language judgments. *arXiv.Org*. <https://doi.org/10.48550/arXiv.2204.03592>