

Model Prediksi Deep Learning dengan Pendekatan Feedforward Neural Network

Lukman Nul Hakim¹, Tresna Dewi¹, Pola Risma¹, Yurni Oktarina¹

¹Jurusan Teknik Elektro, Politeknik Negeri Sriwijaya
Palembang, Indonesia

Penulis yang berkorelasi: tresna_dewi@polsri.ac.id

Abstrak— Penelitian ini bertujuan untuk menerapkan model deep learning, khususnya Feedforward Neural Network (FNN), dalam meramalkan nilai irradiance berdasarkan data waktu. Solar irradiance sangat penting dalam pengembangan sistem energi terbarukan seperti panel surya untuk meningkatkan efisiensi sistem tenaga surya dan mengoptimalkan perencanaan sumber daya energi. Penggunaan model ini diharapkan dapat memberikan prediksi yang lebih akurat dan handal, sehingga mendukung pengambilan keputusan dalam pengelolaan energi terbarukan secara berkelanjutan. Untuk meningkatkan akurasi prediksi, penelitian ini menerapkan teknik preprocessing data yang mencakup penghapusan nilai hilang dan normalisasi menggunakan MinMaxScaler guna meningkatkan stabilitas pelatihan model. Model FNN yang diusulkan terdiri dari beberapa lapisan tersembunyi dengan aktivasi non-linear untuk menangkap pola kompleks dalam data, serta lapisan output untuk menghasilkan prediksi akhir. Pelatihan model dilakukan menggunakan algoritma optimasi seperti Adam, dengan fungsi aktivasi ReLU untuk meningkatkan konvergensi. Evaluasi model dilakukan menggunakan metrik RMSE, MSE, MAE, dan R-squared (R^2) sebagai indikator utama keakuratan model dalam peramalan irradiance. Hasil evaluasi menunjukkan bahwa model ini mampu memberikan prediksi yang akurat terhadap pola irradiance, dengan nilai RMSE dan MAE yang rendah serta R^2 mendekati satu, menandakan kinerja yang sangat baik dalam menangkap dinamika data.

Kata kunci— Deep Learning, Feedforward Neural Network, Peramalan Waktu, Data Irradiance.

Abstract— This study presents the implementation of a deep learning model using the Feedforward Neural Network (FNN) architecture for predicting solar irradiance based on time-series data. Solar irradiance is a key parameter in the development of renewable energy systems, particularly for optimizing photovoltaic (PV) performance and improving energy resource management. Accurate irradiance forecasting enables better planning and operational efficiency of solar power generation systems. To enhance the accuracy and reliability of the prediction model, data preprocessing techniques were applied, including the removal of missing values and data normalization using MinMaxScaler. This process aims to improve data consistency and support stable model training. The proposed FNN model is designed with multiple hidden layers employing non-linear activation functions to capture complex patterns and temporal variations in the data. The output layer generates the predicted irradiance values. The training process utilizes the Adam optimization algorithm and ReLU activation function to improve learning convergence and model performance. Model evaluation was conducted using several statistical metrics, namely Root Mean Square Error (RMSE), Mean Square Error (MSE), Mean Absolute Error (MAE), and the coefficient of determination (R^2), to assess the accuracy and effectiveness of the model. The experimental results indicate that the developed FNN model is capable of producing accurate irradiance predictions, demonstrated by low error values and an R^2 value approaching one. These findings highlight the potential of the FNN-based deep learning approach as a reliable forecasting tool to support decision-making processes in the planning and management of renewable energy systems.

Keyword— Deep Learning, Feedforward Neural Network, Peramalan Waktu, Irradiance.

I. PENDAHULUAN

Kebutuhan akan sistem energi terbarukan yang efisien dan berkelanjutan telah mendorong kemajuan pesat dalam bidang prediksi energi berbasis kecerdasan buatan, khususnya *deep learning* [1], [2]. Di antara sumber daya terbarukan, tenaga surya memiliki potensi terbesar, tetapi kinerjanya sangat dipengaruhi oleh variabilitas radiasi matahari [3], [4]. Oleh karena itu, akurasi dalam memprediksi nilai irradiance menjadi faktor krusial dalam mengoptimalkan output sistem fotovoltaik (PV) dan perencanaan manajemen energi [5], [6].

Feedforward Neural Network (FNN) sebagai bagian dari arsitektur *deep learning* menawarkan pendekatan yang sederhana namun efektif dalam menangkap pola non-linear pada data deret waktu [7], [8]. FNN menjadi alternatif menarik dibandingkan model klasik karena mampu melakukan pemetaan fungsi kompleks tanpa umpan balik eksplisit [7]. Studi-studi

sebelumnya juga menunjukkan bahwa FNN dapat menghasilkan performa prediktif yang kompetitif bila dipadukan dengan strategi pelatihan dan prapemrosesan data yang tepat [8], [9].

Dalam konteks prediksi irradiance, sejumlah pendekatan telah diuji, mulai dari jaringan konvolusional (CNN) dan CNN-LSTM [4], [1]. hingga pendekatan hybrid dan augmentasi data deret waktu [10]. Namun, sebagian besar studi lebih menekankan arsitektur kompleks dan kurang mengeksplorasi efektivitas model dasar seperti FNN secara mendalam. Padahal, dengan konfigurasi yang optimal dan data yang telah dinormalisasi serta dibersihkan dari nilai hilang [11], [12]. FNN berpotensi memberikan hasil prediksi yang akurat dengan kompleksitas komputasi yang lebih rendah.

Evaluasi performa model dalam studi ini akan menggunakan metrik regresi seperti RMSE, MSE, MAE, dan koefisien determinasi R^2 , yang telah digunakan secara luas dalam literatur untuk menilai kualitas prediksi model pembelajaran mesin [7], [13]. Di samping itu, isu efisiensi energi dan jejak karbon dari pelatihan model juga menjadi pertimbangan penting, sebagaimana diangkat dalam studi oleh [14] dan [8], yang menekankan pentingnya keseimbangan antara akurasi prediksi dan biaya lingkungan dalam riset *deep learning* modern.

Dengan latar belakang tersebut, penelitian ini bertujuan untuk merancang dan mengevaluasi model prediksi irradiance berbasis FNN dengan menerapkan teknik prapemrosesan data yang sistematis serta strategi pelatihan model yang efisien. Fokus utama terletak pada bagaimana FNN dapat dimaksimalkan performanya dalam skenario prediksi deret waktu untuk mendukung optimalisasi sistem energi surya yang cerdas dan adaptif.

II. METODOLOGI


Metodologi menjelaskan secara sistematis tahapan-tahapan yang dilakukan dalam proses pengembangan model prediksi irradiance berbasis *Feedforward Neural Network* (FNN). Pemilihan FNN sebagai arsitektur inti dalam penelitian ini didasarkan pada karakteristiknya yang sederhana, efisien secara komputasi, namun tetap memiliki kemampuan untuk menangkap pola-pola non-linear dalam data deret waktu [5], [6]. Penggunaan FNN juga dinilai relevan mengingat fokus utama penelitian bukan hanya pada kompleksitas arsitektur, tetapi lebih kepada efisiensi pemodelan dan akurasi prediksi dalam konteks energi terbarukan [8], [7].

Secara umum, metodologi penelitian ini terdiri dari lima tahapan utama, yaitu: (1) pengumpulan dan eksplorasi data irradiance, (2) proses *preprocessing* data, (3) perancangan arsitektur FNN, (4) proses pelatihan dan pengujian model, serta (5) evaluasi performa model menggunakan metrik evaluasi standar.

Pada tahap awal, dilakukan proses akuisisi data irradiance berbasis deret waktu, yang diperoleh dari sumber dataset terbuka atau hasil pengukuran lapangan. Data yang terkumpul kemudian diproses untuk memastikan kualitas dan kelayakannya digunakan dalam pelatihan model. Tahapan *preprocessing* meliputi penanganan *missing values* [11], normalisasi menggunakan MinMaxScaler [12], dan konversi format data agar sesuai dengan kebutuhan input model.

Selanjutnya, arsitektur FNN dirancang dengan sejumlah *hidden layer* dan *activation function* non-linear (ReLU) untuk menangkap karakteristik data yang kompleks [3]. Proses pelatihan model dilakukan menggunakan algoritma optimasi Adam, yang telah terbukti efektif dalam mempercepat konvergensi pembelajaran [1].

Akhirnya, performa model dievaluasi menggunakan metrik RMSE, MSE, MAE, dan R^2 [7], [9], untuk menilai sejauh mana model mampu merepresentasikan dinamika pola irradiance. Secara keseluruhan, metodologi yang digunakan diharapkan mampu menghasilkan model prediksi yang tidak hanya akurat, tetapi juga ringan, stabil, dan aplikatif untuk kebutuhan manajemen energi berbasis tenaga surya.



Gambar 1 Diagram Blok Proses Pengolahan Data

A. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini berasal dari file CSV:

- DATA_IRRADIANCE_TEST.csv digunakan sebagai data pelatihan.
- DATA_IRRADIANCE_VALIDASI.csv digunakan sebagai data pengujian.

Setiap dataset hanya memanfaatkan satu fitur, yaitu kolom IRRADIANCE, sebagai variabel input.

B. Pra Pemrosesan Data

Sebelum data digunakan untuk pelatihan model, dilakukan beberapa tahapan preprocessing:

- Normalisasi Data: Menggunakan MinMaxScaler dari sklearn.preprocessing untuk mengubah nilai data ke rentang [0,1].
- Pembagian Data: Data IRRADIANCE dibagi menjadi data pelatihan dan data pengujian berdasarkan file yang telah disediakan.

C. Building Model

Model yang dibangun menggunakan TensorFlow dan Keras dengan arsitektur sebagai berikut:

- Lapisan Input: 1 neuron sesuai dengan jumlah fitur input.
- Lapisan Tersembunyi:
 - 64 neuron dengan aktivasi ReLU.
 - 32 neuron dengan aktivasi ReLU.
- Lapisan Output: 1 neuron untuk memprediksi nilai IRRADIANCE.

D. Evaluasi Model

Setelah pelatihan, model dievaluasi menggunakan data uji. Metrik yang digunakan untuk menilai kinerja model meliputi:

1. *Root Mean Squared Error (RMSE)* adalah salah satu metrik yang umum digunakan untuk mengevaluasi kinerja model *regresi*, termasuk model yang digunakan untuk peramalan data waktu. Berikut rumus RMSE:

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

RMSE adalah akar dari MSE dan memiliki satuan yang sama dengan data aslinya.

2. *Mean Squared Error (MSE)* adalah metrik mengukur rata-rata kuadrat perbedaan antara nilai yang diprediksi dan nilai sebenarnya. Berikut rumus MSE:

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

Keterangan:

y_i = Nilai actual.

y'_i = Nilai prediksi.

n = Jumlah sample.

3. *Mean Absolute Error* (MAE) adalah metrik mengukur rata-rata *absolut* perbedaan antara nilai yang diprediksi dan nilai sebenarnya. Berikut rumus MAE:

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

MAE mengukur rata-rata kesalahan absolut antara prediksi dan nilai actual.

4. *R-squared* (R^2) adalah metrik mengukur proporsi varian dalam data yang dapat dijelaskan oleh model. Berikut rumus R^2 :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - y''_i)^2}$$

Keterangan:

y''_i = Nilai rata – rata dari aktual.

R^2 = Menunjukkan seberapa baik model menjelaskan variabilitas data (semakin mendekati 1, semakin baik modelnya).

Hasil evaluasi ini memberikan gambaran tentang seberapa baik model dalam meramalkan nilai *irradiance* berdasarkan data waktu. Visualisasi hasil prediksi juga dilakukan untuk membandingkan nilai yang diprediksi dengan nilai sebenarnya, sehingga memberikan pemahaman yang lebih baik tentang kinerja model.

E. Prediksi Data

Model dilatih, Setelah model dilatih, model digunakan untuk memprediksi data pengujian. Data pengujian juga dinormalisasi sebelum digunakan untuk prediksi. Dan menggabungkan Hasil Prediksi dengan Data Asli Hasil prediksi ditambahkan ke DataFrame asli untuk analisis lebih lanjut. Ini memungkinkan perbandingan antara nilai yang diprediksi dan nilai sebenarnya.

F. Hasil Evaluasi Grafik

Visualisasi Hasil Prediksi vs Nilai Sebenarnya: hasil prediksi dibandingkan dengan nilai sebenarnya untuk setiap fitur. Ini membantu dalam memahami seberapa baik model dalam memprediksi data.

Plot Loss, RMSE, MAE, dan MSE: Plot yang menunjukkan loss pelatihan dan validasi, serta RMSE, MAE, dan MSE selama epoch, memberikan gambaran tentang kinerja model selama pelatihan.

G. Pseudocode FNN untuk Prediksi Data Irradiance

Tabel 1 Pseudocode FNN untuk Prediksi Data Irradiance

No	Pseudocode
1.	Training model BEGIN LOAD train_data from 'DATA_IRRADIANCE_TEST.csv' LOAD test_data from 'DATA_IRRADIANCE_VALIDASI.csv' SELECT IRRADIANCE column from train_data and test_data NORMALIZE train_data and test_data using MinMaxScaler MODEL = Sequential() MODEL.add(Dense(64, input_dim=1, activation='ReLU')) MODEL.add(Dense(32, activation='ReLU')) MODEL.add(Dense(1)) # Output layer COMPILE model using optimizer='adam', loss='mse', metrics=['mae'] TRAIN model on train_data for 100 epochs with batch_size=8 PREDICT IRRADIANCE using model on test_data COMPUTE evaluation metrics: RMSE, MSE, MAE, R^2 PLOT true vs predicted IRRADIANCE END

H. Tabel Funcion

Tabel 2 Tabel Funcion

Layer Name	Type	Output Shape	Parameters
Input layer	Input	(None, 1)	0
Dense_1	Dense (ReLU)	(None, 64)	$64 * 1 + 64$
Dense_2	Dense (ReLU)	(None, 32)	$32 * 64 + 32$
Output Layer	Dense (Linear)	(None, 1)	$1 * 32 + 1$

Diatas ini merupakan tabel function dari kodingan yang digunakan Model yang digunakan adalah Feedforward Neural Network (FNN), yaitu jenis jaringan saraf tiruan yang mengalirkan data hanya ke satu arah, dari lapisan input ke lapisan output tanpa umpan balik. Model ini terdiri dari tiga jenis lapisan utama: lapisan input, lapisan tersembunyi (hidden layers), dan lapisan output. Lapisan input menerima data IRRADIANCE, yang kemudian diproses oleh dua lapisan tersembunyi, yaitu Dense_1 dengan 64 neuron dan Dense_2 dengan 32 neuron. Setiap neuron dalam lapisan tersembunyi menggunakan fungsi aktivasi ReLU untuk membantu jaringan memahami pola dalam data secara lebih efisien. Setelah melalui tahap pemrosesan ini, hasil akhirnya dihasilkan oleh lapisan output dalam bentuk prediksi nilai IRRADIANCE.

Model ini memiliki total 2.241 parameter yang dipelajari selama proses pelatihan. Parameter ini terdiri dari bobot dan bias yang menentukan bagaimana model menyesuaikan dirinya untuk menghasilkan prediksi yang akurat. Dengan memanfaatkan fungsi aktivasi ReLU, model dapat menangani hubungan kompleks dalam data tanpa mengalami masalah seperti hilangnya gradien. Secara sederhana, FNN ini bekerja seperti mesin pintar yang belajar dari data IRRADIANCE sebelumnya, menemukan pola di dalamnya, dan menggunakan pola tersebut untuk melakukan prediksi terhadap nilai IRRADIANCE di masa depan.


Pemilihan hyperparameter seperti jumlah neuron, epoch, dan batch size sangat berpengaruh terhadap hasil pelatihan model. Model menggunakan dua lapisan tersembunyi dengan masing-masing 64 dan 32 neuron, penggunaan layer Dense dengan 64 dan 32 neuron bertujuan agar model bisa mempelajari pola-pola dari data iradiansi yang sudah dinormalisasi. Pada layer pertama, 64 neuron digunakan agar model punya cukup kemampuan untuk mengenali pola yang kompleks, meskipun input-nya hanya satu fitur. Aktivasi ReLU di sini membantu proses belajar jadi lebih efisien dan menghindari masalah seperti vanishing gradient. Kemudian, layer kedua dengan 32 neuron digunakan untuk menyaring dan merangkum informasi dari layer sebelumnya, jadi model bisa fokus pada fitur-fitur yang benar-benar penting. Untuk data dengan satu fitur seperti IRRADIANCE tujuannya adalah agar model bisa memahami pola-pola yang kompleks. output layer hanya punya satu neuron karena yang diprediksi cuma satu nilai, yaitu iradiansi. Model dilatih selama 100 epoch merupakan jumlah iterasi standar untuk awal pelatihan. Ukuran batch-nya adalah 8, yang artinya model memperbarui bobot setiap 8 data. Ukuran kecil seperti ini bisa membantu model belajar lebih detail.

III. HASIL DAN PEMBAHASAN

Nilai irradiance atau jumlah energi matahari yang diterima permukaan bumi dipengaruhi oleh berbagai faktor eksternal seperti cuaca, waktu, musim, lokasi geografis, ketinggian tempat, dan polusi udara. Misalnya, cuaca yang buruk, seperti awan atau hujan, dapat mengurangi jumlah cahaya matahari yang sampai ke permukaan bumi. Selain itu, waktu dalam sehari dan musim juga berperan besar; irradiance biasanya lebih tinggi di tengah hari dan pada musim panas, sementara di pagi atau sore hari, atau di musim dingin, nilainya cenderung lebih rendah. Lokasi geografis juga mempengaruhi irradiance daerah yang lebih dekat ke khatulistiwa atau berada di ketinggian lebih tinggi cenderung menerima lebih banyak cahaya matahari.

Untuk memprediksi irradiance dengan lebih akurat, model deep learning seperti Feedforward Neural Network (FNN) perlu mempertimbangkan faktor-faktor eksternal ini. Dengan menambahkan input tambahan seperti suhu, kelembaban, waktu (misalnya jam, bulan), indeks UV, dan data cuaca lainnya, model dapat menangkap variasi yang lebih kompleks dalam pola cahaya matahari. Dengan memasukkan informasi cuaca dan faktor lingkungan lainnya, model FNN dapat lebih baik mengakomodasi fluktuasi irradiance yang dipengaruhi oleh kondisi eksternal, sehingga hasil prediksi menjadi lebih akurat dan lebih adaptif dalam menghadapi berbagai kondisi nyata.

Hasil Gambar dibawah ini menunjukkan grafik fitur irradiance yang ada pada dataset yang diberikan sebelum di training menggunakan metode deep learning model FNN.



Gambar 2 Data IRRADIANCE sebelum training

Dari pola gambar grafik 2 ada lonjakan-lonjakan tinggi yang berulang dengan jarak tertentu. Ini menunjukkan bahwa intensitas cahaya matahari naik dan turun secara berkala, mengikuti siklus siang dan malam. Saat matahari terbit, iradiasi meningkat, mencapai puncak di siang hari, lalu turun lagi mendekati nol saat malam.

Tabel 3 Matriks Evaluasi Sebelum Training

Matriks	Irradiance
RMSE	158.6565
MSE	25171.8738
MAE	79.0352
R ²	0.3659

Tabel 3 menyajikan Matriks Evaluasi Sebelum Training, yang menunjukkan kualitas prediksi model sebelum dilakukan pelatihan (training). Berikut penjelasan dari masing-masing metrik evaluasi dalam konteks Irradiance (radiasi matahari atau energi cahaya yang diterima per satuan luas):

1. Root Mean Square Error (RMSE) = 158.6565
 - RMSE mengukur rata-rata kesalahan prediksi model dalam satuan yang sama dengan data aslinya.
 - Nilai 158.6565 menunjukkan bahwa prediksi model sebelum training masih memiliki tingkat kesalahan yang cukup tinggi dibandingkan dengan nilai sebenarnya.
2. Mean Squared Error (MSE) = 25171.8738
 - MSE adalah rata-rata kuadrat dari selisih antara nilai prediksi dan nilai sebenarnya.
 - Nilai yang besar menunjukkan adanya error yang cukup besar dalam prediksi sebelum pelatihan.
3. Mean Absolute Error (MAE) = 79.0352
 - MAE menunjukkan rata-rata selisih absolut antara prediksi dan nilai sebenarnya.
 - Nilai 79.0352 berarti bahwa secara rata-rata, prediksi sebelum training memiliki kesalahan sebesar ± 79.0352 unit.
4. R² (Koefisien Determinasi) = 0.3659
 - R² mengukur seberapa baik model menjelaskan variabilitas data target.
 - Nilai 0.3659 berarti hanya sekitar 36.59% variabilitas dari Irradiance yang dapat dijelaskan oleh model sebelum training, menunjukkan bahwa model masih belum cukup baik dalam menangkap pola data.

Dari hasil evaluasi ini, dapat disimpulkan bahwa sebelum training, model masih memiliki tingkat kesalahan yang tinggi (RMSE dan MAE besar) dan performanya masih rendah (R^2 kecil). Oleh karena itu, diperlukan proses pelatihan (training) agar model dapat meningkatkan akurasi prediksinya dan menghasilkan hasil yang lebih baik.

Model yang digunakan dalam penelitian ini adalah FNN (Feedforward Neural Network) dengan optimisasi menggunakan metrik RMSE, MSE, MAE, dan koefisien determinasi R^2 . Pelatihan model dilakukan selama 100 epoch. Hasil dari pelatihan menunjukkan bahwa model mampu mencapai akurasi yang memuaskan, dengan nilai metrik evaluasi yang mendekati target yang diinginkan. Berikut adalah tabel yang merangkum nilai RMSE, MSE, MAE, dan R^2 setelah training.

Tabel 4 Matriks Evaluasi Setelah Training

Matriks	Irradiance
RMSE	0.00370441
MSE	1.3722699
MAE	0.00362477
R^2	0.99963397

Tabel ini menunjukkan hasil evaluasi model setelah training, yang mencerminkan peningkatan kinerja model dibandingkan sebelum training. Berikut adalah penjelasan dari masing-masing metrik:

1. Root Mean Square Error (RMSE) = 0.00370441
 - RMSE yang jauh lebih kecil dibandingkan sebelum training menunjukkan bahwa kesalahan prediksi model telah berkurang secara signifikan.
 - Ini berarti bahwa model lebih akurat dalam memprediksi nilai irradiance.
2. Mean Squared Error (MSE) = 1.3722699
 - MSE menunjukkan rata-rata kesalahan kuadrat.
 - Penurunan nilai MSE menunjukkan bahwa error model semakin kecil setelah training.
3. Mean Absolute Error (MAE) = 0.00362477
 - MAE yang rendah menunjukkan bahwa rata-rata kesalahan absolut dalam prediksi model telah berkurang drastis, sehingga model menjadi lebih presisi.
4. R^2 (Koefisien Determinasi) = 0.99963397
 - Nilai R^2 yang sangat mendekati 1 menunjukkan bahwa model dapat menjelaskan hampir 99.96% variabilitas data irradiance.
 - Ini menandakan bahwa model memiliki kinerja yang sangat baik dalam menangkap pola data.


Setelah training, model mengalami peningkatan performa yang signifikan. Nilai RMSE, MSE, dan MAE yang kecil menunjukkan bahwa error dalam prediksi sudah sangat minim, sedangkan nilai R^2 yang mendekati 1 menandakan bahwa model hampir sepenuhnya dapat menjelaskan variasi dalam data irradiance. Hal ini mengindikasikan bahwa model berhasil dilatih dengan baik dan dapat digunakan untuk prediksi dengan akurasi tinggi.

Tabel 5 Perbandingan Matriks Evaluasi Setelah Training Menggunakan Metode CNN dan LSTM

	CNN	LSTM
Matriks	Irradiance	
RMSE	124.2	104.1
MSE	15443.0	10850.1
MAE	48.8	44.1
R^2	0.59	0.71

Tabel 5 menampilkan hasil evaluasi dua model deep learning, yaitu CNN dan LSTM, dalam memprediksi data iradiansi menggunakan data validasi yang belum pernah dilihat sebelumnya oleh model. Dari hasil evaluasi, terlihat bahwa model LSTM memberikan hasil yang lebih baik dibandingkan CNN. Nilai RMSE pada LSTM tercatat sebesar 104.1, lebih rendah dibandingkan CNN yang sebesar 124.2. Begitu juga dengan metrik lainnya, seperti MSE dan MAE, di mana LSTM mencatat angka yang lebih kecil (10850.1 dan 44.1) dibandingkan CNN (15443.0 dan 48.8). Skor R^2 pada LSTM juga lebih tinggi, yaitu 0.71, dibandingkan CNN yang hanya mencapai 0.59, namun dibandingkan dengan hasil yang didapatkan menggunakan model deep learning FNN hasil akurasi kurang memuaskan.


Pada Grafik Training dan Validasi Loss, terlihat bahwa nilai *loss* pada data pelatihan dan validasi menurun secara konsisten seiring bertambahnya *epoch* dapat dilihat pada Gambar 3 Grafik Hasil *Training Loss*.



Gambar 3 Grafik Training dan Validasi Loss

Pada grafik gambar 3 hasil *training dan validasi loss* mengindikasikan bahwa model mampu belajar pola dalam data dengan efektif tanpa *overfitting* yang signifikan, terlihat dari garis *loss* pelatihan dan validasi yang berdekatan.

Grafik hasil prediksi perbandingan antara nilai aktual dan prediksi menunjukkan keselarasan yang cukup baik di sebagian besar titik data.



Gambar 4 Grafik Prediksi vs Nilai Sebenarnya

Secara keseluruhan, model FNN (Feedforward Neural Network) menunjukkan performa yang cukup baik dalam memprediksi nilai irradiance. Model ini mampu mengenali pola naik dan turun dari data dengan cukup akurat, yang terlihat dari kemiripan antara nilai prediksi dan nilai sebenarnya pada grafik. Namun, terdapat beberapa peluang untuk peningkatan, seperti tuning hiperparameter lebih lanjut, peningkatan jumlah data latih, atau penggunaan augmentasi data untuk mengurangi error pada nilai puncak dan lembah.

Tabel 4 Matriks Evaluasi Setelah pengaturan hyperparameter

Matriks	Irradiance
RMSE	0.00208
MSE	0.24826
MAE	0.001239
R ²	0.999883

Tabel 4 menyajikan Matriks Evaluasi setelah dilakukan pengaturan pada hyperparameter. Untuk meningkatkan akurasi prediksi model FNN khususnya saat menghadapi nilai ekstrem seperti irradiance sangat tinggi atau rendah kita bisa melakukan beberapa langkah perbaikan pertama, menyesuaikan pengaturan model (hiperparameter) seperti menambah lapisan/neuron atau mengoptimalkan learning rate agar model lebih responsif; kedua, memperbanyak data pelatihan yang mencakup kondisi ekstrem sehingga model belajar mengenali pola lebih beragam; ketiga, melakukan augmentasi data dengan teknik seperti noise injection untuk memperkaya variasi data tanpa pengumpulan manual.

Selain itu, nilai R² yang diperoleh menunjukkan bahwa meskipun model telah mampu menangkap sebagian besar pola dalam data, masih terdapat faktor eksternal yang mempengaruhi nilai irradiance yang belum sepenuhnya terakomodasi dalam prediksi.

Penggunaan metode ini dapat membuka peluang bagi penelitian lebih lanjut dalam pengembangan model prediksi yang lebih akurat, serta memberikan kontribusi yang lebih besar dalam pemahaman tentang faktor-faktor yang mempengaruhi dinamika irradiance.

IV. KESIMPULAN

Model Feedforward Neural Network (FNN) telah berhasil digunakan untuk memprediksi nilai irradiance dengan tingkat akurasi yang cukup baik. Hasil analisis menunjukkan bahwa model mampu menangkap pola temporal dari data, yang terlihat dari kesesuaian antara nilai prediksi dan nilai sebenarnya pada grafik. Namun, masih terdapat beberapa perbedaan terutama pada nilai puncak dan lembah, yang mengindikasikan adanya peluang untuk peningkatan performa model. Evaluasi menggunakan metrik seperti MSE, RMSE, MAE, dan R² menunjukkan bahwa meskipun model sudah cukup efektif, masih terdapat faktor eksternal yang belum sepenuhnya terakomodasi dalam prediksi.

Secara keseluruhan, penelitian ini memberikan kontribusi terhadap pengembangan model prediksi irradiance berbasis kecerdasan buatan. Dengan peningkatan lebih lanjut, model ini dapat diterapkan dalam berbagai bidang seperti pemantauan energi surya dan peramalan cuaca, sehingga dapat mendukung efisiensi dan optimalisasi pemanfaatan sumber daya energi terbarukan.

REFERENSI

- [1] F. Elmaz, R. Eyckerman, W. Casteels, S. Latre, and P. Hellinckx, "CNN-LSTM architecture for predictive indoor temperature modeling," *Building and Environment*, vol. 203, p. 108327, 2021. [Online]. <https://doi.org/10.1016/j.buildenv.2021.108327>
- [2] J. Thaker and R. Höller, "A comparative study of time series forecasting of solar energy based on irradiance classification," *Energies*, 2022. https://www.academia.edu/79698075/A_Comparative_Study_of_Time_Series_Forecasting_of_Solar_Energy_Based_on_Irradiance_Classification
- [3] C Li, X., Zhang, Y., & Wang, L. (2021). Deep learning model for photovoltaic power generation 5 forecasting. *Applied Energy*, 306, 118092. <https://www.sciencedirect.com/science/article/pii/S0360544221004898>
- [4] Y. (2023). Deep learning-based PV power prediction using 7 convolutional neural networks. *Energy Reports*, 9, 345–359. <https://www.sciencedirect.com/science/article/abs/pii/S2352467723000334>
- [5] A. Mielke, *Classical models vs deep learning: Time series analysis*, 2022. [Online]. https://doi.org/10.1007/978-3-031-23749-9_26
- [6] L. Amarpuri, N. Yadav, G. Kumar, and S. Agrawal, "Prediction of CO₂ emissions using deep learning hybrid approach: A case study in Indian context," in *Proc. 2019 12th Int. Conf. on Contemporary Computing (IC3)*, 2019, pp. 1–6. https://www.researchgate.net/publication/335945786_Prediction_of_CO_2_emissions_using_deep_learning_hybrid_approach_A

Case_Study_in_Indian_Context

- [7] V. Pelveris, G. Solorzano, N. Bakas, and M. A. Ben Seghier, "Investigation of performance metrics in regression analysis and machine learning-based prediction models," in *8th Eur. Congr. Comput. Methods Appl. Sci. and Eng.*, Jan. 2022. [Online]. <https://doi.org/10.23967/eccomas.2022.155>
- [8] L. F. W. Anthony, B. Kanding, and R. Selvan, "Carbontracker: Tracking and predicting the carbon footprint of training deep learning models," *arXiv preprint arXiv:2007.03051*, 2020. https://www.researchgate.net/publication/342763375_Carbontracker_Tracking_and_Predicting_the_Carbon_Footprint_of_Training_Deep_Learning_Models
- [9] V. S. M. Robeson and C. J. Willmott, "Decomposition of the mean absolute error (MAE) into systematic and unsystematic components," *PLOS ONE*, Jan. 2023. [Online]. <https://doi.org/10.1371/journal.pone.0279774>
- [10] ao, Q. (2021). CNN-based photovoltaic power prediction with time-11 series data augmentation. *IEEE Transactions on Sustainable Energy*, 12(3), 876–885. <https://www.sciencedirect.com/science/article/pii/S2096511724000860>
- [11] L. Ren, T. Wang, A. Sekloui, H. Zhang, and A. Bouras, "Missing values for classification of machine learning in medical data," May 2022. <https://www.semanticscholar.org/paper/Missing-Values-for-Classification-of-Machine-in-Ren-Wang/7d0a98886e09fbaf4c20b64a77c97e6ec8bd5466>
- [12] R. Wadhvani, "Adaptive wind data normalization to improve the performance of forecasting models," *Wind Engineering*, vol. 46, no. 5, pp. 1606–1617, 2022. <https://journals.sagepub.com/doi/abs/10.1177/0309524X221093908>
- [13] G. Hughes, J. Reed, and N. McRoberts, "Information graphs: Incorporating predictive values of disease forecasts," *Entropy*, vol. 22, no. 3, p. 361, 2020. [Online]. <https://doi.org/10.3390/e22030361>
- [14] L. E. Strubell, A. Ganesh, and A. McCallum, "Energy and policy considerations for modern deep learning research," in *Proc. AAAI Conf. on Artificial Intelligence*, vol. 34, pp. 13693–13696, 2020. <https://aclanthology.org/P19-1355/>
- [15] Zhang, C., Li, X., & Yang, J. (2021). PSA: A Novel Pyramid Split Attention Module for Effective Feature Extraction. *Pattern Recognition Letters*, 146, 67–73. <https://doi.org/10.1016/j.patrec.2021.03.008>
- [16] L. "PV power prediction using 7 convolutional neural networks," *Energy Reports*, vol. 9, pp. 345–359, 2023. <https://www.sciencedirect.com/science/article/abs/pii/S2352467723000334>
- [17] C. Wang, N. Yang, W. Xu, J. Wang, J. Sun, and X. Chen, "Research on a text data preprocessing method suitable for clustering algorithm," Jul. 2022. [Online]. <https://doi.org/10.1109/ISPDS56530.2022.9874172>
- [18] "Prediction of solar energy using time series methods," in *2022 Int. Conf. on Automation, Computing and Renewable Systems (ICACRS)*, Dec. 2022. [Online]. <https://doi.org/10.1109/icacrs55517.2022.10028997>
- [19] Zhao, M., Liu, J., & Feng, H. (2020). LSTM-based recurrent network for solar power 13 forecasting. *Solar Energy*, 205, 230–245. <https://ieeexplore.ieee.org/document/6844831>
- [20] T., Chen, M., & Huang, P. (2022). A deep learning approach for solar power forecasting. *Renewable Energy*, 195, 1234–1248. <https://www.sciencedirect.com/science/article/abs/pii/S0959652622049885>