

ANALISIS SENSITIVITAS ARSITEKTUR LONG SHORT-TERM MEMORY UNTUK PREDIKSI PENYINARAN MATAHARI

Nor Faiza ¹, Agung Teguh Wibowo Almais ², Usman Pagalay ³, Ririen Kusumawati ⁴,
Yunifa Miftachul Arif ⁵, Ahmad Zarkoni ⁶, Mohammad Mamba'ul Ulum ⁷

^{1,2,3,4,5} Program Studi Magister Informatika, Fakultas Sains & Teknologi,

Universitas Islam Negeri Maulana Malik Ibrahim Malang

^{6,7} Stasiun Geofisika Malang, Badan Meteorologi Klimatologi dan Geofisika.

Jalan Gajayana No.50, Dinoyo, Lowokwaru, Kota Malang, Indonesia

agung.twa@ti.uin-malang.ac.id

ABSTRAK

Prediksi parameter meteorologi merupakan tantangan yang kompleks dalam bidang informatika karena tingginya variabilitas dan sifat non-linier data atmosfer. Permasalahan utama dalam studi ini adalah fluktuasi data penyinaran matahari yang sulit diidentifikasi oleh model konvensional, serta adanya risiko degradasi performa model akibat konfigurasi arsitektur dan pembagian data yang tidak optimal. Penelitian ini bertujuan untuk mengevaluasi efektivitas arsitektur jaringan *Long Short-Term Memory* (LSTM) dalam memprediksi kondisi cuaca harian melalui variabel *Solar Radiation Average* (SR Avg), *Solar Radiation Maximum* (SR Max), dan durasi penyinaran. Metode yang digunakan adalah eksperimen kuantitatif dengan membandingkan tiga variasi arsitektur (Model A: lapisan tunggal, Model B: *stacked layer*, dan Model C: *deep stacked*) serta pengujian terhadap tiga skenario rasio pembagian data, yaitu 70:30, 80:20, dan 90:10. Hasil eksperimen menunjukkan bahwa rasio data 70:30 menghasilkan performa paling stabil, di mana Model B menjadi arsitektur paling optimal dengan nilai *Mean Absolute Error* (MAE) terendah sebesar 0,072510, sementara Model A mencatat *Root Mean Square Error* (RMSE) terbaik sebesar 0,114368. Sebaliknya, penggunaan proporsi data latih yang ekstrem (90:10) memicu penurunan kinerja signifikan akibat gejala *overfitting*, sehingga pemilihan kedalaman arsitektur yang moderat dan keseimbangan distribusi data menjadi faktor kunci dalam akurasi prediksi.

Kata kunci: Prediksi Cuaca, LSTM, Penyinaran Matahari, Optimasi Hiperparameter, Deep Learning.

1. PENDAHULUAN

Akselerasi perkembangan teknologi dan eskalasi kebutuhan terhadap informasi meteorologi yang presisi telah memicu kemajuan signifikan dalam sistem prediksi cuaca modern yang krusial bagi berbagai sektor strategis, termasuk pertanian, transportasi, dan manajemen risiko bencana [1].

Di wilayah tropis seperti Indonesia, variabilitas cuaca yang ekstrem menimbulkan tantangan serius terhadap stabilitas sosial dan ekonomi, sehingga peningkatan akurasi prediksi menjadi prioritas strategis nasional [2].

Penyinaran matahari merupakan parameter fundamental dalam pemodelan atmosfer, namun sifat data yang fluktuatif dan non-linear menyebabkan model fisik konvensional seringkali mengalami degradasi performa [3].

Dalam domain sains data, arsitektur *Long Short-Term Memory* (LSTM) telah membuktikan keunggulannya dalam menangani data deret waktu (*time-series*) melalui mekanisme *gate* yang mampu mereduksi masalah *vanishing gradient* dan memodelkan ketergantungan temporal jangka panjang secara efektif [4].

Meskipun potensi *deep learning* sangat menjanjikan, tantangan prediksi di Indonesia tetap kompleks akibat keterbatasan jaringan pengamatan yang merata serta minimnya studi sistematis yang mengevaluasi sensitivitas arsitektur LSTM dan pengaruh distribusi data terhadap variabel penyinaran

matahari di wilayah kepulauan. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi efektivitas arsitektur LSTM dalam memprediksi parameter penyinaran matahari (SR Avg, SR Max, dan Durasi Penyinaran) secara harian, serta mengidentifikasi konfigurasi model dan rasio pembagian data yang paling optimal guna menghasilkan sistem prediksi yang adaptif dan akurat.

Rencana penyelesaian masalah ini diimplementasikan melalui pendekatan kuantitatif berbasis eksperimen terhadap data sekunder periode Januari hingga Desember 2023 yang diperoleh dari portal BMKG. Alur penelitian meliputi tahapan pra-pemrosesan data menggunakan teknik interpolasi linear dan normalisasi *Min-Max Scaling*, diikuti dengan pengembangan tiga variasi arsitektur (Model A, B, dan C) dengan tingkat kedalaman lapisan yang berbeda. Model-model tersebut kemudian diuji menggunakan tiga skenario pembagian data (70:30, 80:20, dan 90:10) dan dievaluasi secara komprehensif menggunakan metrik *Mean Absolute Error* (MAE) serta *Root Mean Square Error* (RMSE) untuk menjamin kapabilitas generalisasi model dan memitigasi risiko *overfitting*.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Implementasi teknologi *machine learning* dan *deep learning* telah menunjukkan kemajuan signifikan dalam meningkatkan akurasi prediksi parameter

meteorologi pada berbagai wilayah. Penelitian oleh Nugroho menerapkan jaringan syaraf tiruan *Multi-Layer Perceptron* (MLP) untuk memprediksi durasi penyinaran matahari di Kota Bandung, yang membuktikan efektivitas model dalam mendukung sektor pertanian dan energi surya [5]. Sementara itu, Supriyadi (2020) mengevaluasi penggunaan *Long Short-Term Memory* (LSTM) untuk prediksi parameter cuaca sinoptik di Stasiun Maritim Tanjung Priok, yang menunjukkan bahwa model LSTM dengan pembaruan data aktual menghasilkan nilai RMSE yang lebih rendah untuk prakiraan jangka pendek dibandingkan tanpa pembaruan [6].

Di wilayah tropis Sri Lanka, mengembangkan model LSTM multivariat yang berhasil memprediksi suhu dengan tingkat kesalahan sangat rendah (RMSE 1,37482°F), menegaskan kemampuan model dalam mengidentifikasi pola non-linier yang kompleks dibandingkan metode konvensional.[7].

Eksplorasi terhadap variasi arsitektur jaringan saraf juga dilakukan oleh Yunita, yang menemukan bahwa model hibrida berbasis LSTM, seperti LSTM-GRU dan LSTM-RNN, secara konsisten menunjukkan kinerja lebih unggul dibandingkan model standar lainnya untuk peramalan deret waktu [7].

Dalam konteks radiasi matahari, Boubaker membandingkan beberapa model *deep learning* di Arab Saudi dan mencatatkan koefisien korelasi hingga 96% dalam memprediksi *Global Horizontal Irradiation* (GHI) harian. Selain itu, inovasi arsitektur terus berkembang melalui pengembangan model *Spatial Feature Attention-LSTM* (SFA-LSTM) oleh Suleman & Shridevi untuk menangkap hubungan spasial-temporal pada perubahan cuaca mendadak [8]. serta pendekatan *ensemble transfer learning* oleh Andrew Gahwera yang berhasil mengatasi kelangkaan data meteorologi dengan akurasi klasifikasi curah hujan mencapai 0,989 [9].

Keberhasilan berbagai model ini juga terlihat pada penerapan sistem peramalan dua tahap oleh Alghushairy menggunakan *Bidirectional Gated Recurrent Units* (BiGRU) di Arab Saudi[10], serta pengusulan *Transductive LSTM* (T-LSTM) oleh Karevan & Suykens (2020) yang memanfaatkan lokalisasi fungsi tujuan untuk meningkatkan performa prediksi [11].

Terakhir, Singhal membuktikan bahwa integrasi prakiraan cuaca dengan algoritma *XGBoost* mampu menghasilkan nilai R^2 sebesar 0,92 dalam prediksi energi surya [12]. Berbagai studi ini secara kolektif menyimpulkan bahwa varian LSTM dan kombinasi hibridanya menawarkan akurasi, efisiensi komputasi, dan stabilitas yang lebih baik dalam menghadapi dinamika atmosfer, sehingga sangat relevan untuk diterapkan dalam penelitian prediksi cuaca berbasis penyinaran matahari ini.

2.2. Long Short-Term Memory

Long Short-Term Memory (LSTM) merupakan salah satu jenis *Recurrent Neural Network* (RNN)

yang dikembangkan oleh Hochreiter dan Schmidhuber pada tahun 1997. RNN mampu memproses data sekuensial yang panjang dan kompleks. RNN biasanya menggunakan model backpropagation yang mirip dengan jaringan saraf, dan rantai yang terlalu panjang dalam topologi. RNN cenderung mengalami penurunan gradien (*vanishing gradient*) [13]

Long Short-Term Memory (LSTM) dikembangkan untuk mengatasi *vanishing gradient* pada RNN[13]. LSTM telah dimodifikasi dengan menambahkan *memory cell* sehingga dapat menyimpan informasi dalam jangka waktu yang lebih lama. Keuntungan dari LSTM adalah adanya *memory block* yang menentukan nilai mana yang akan dipilih sebagai *output* yang relevan untuk input yang diberikan[13].

Berikut persamaan dari *Long-Short Term Memory*.

$$f_t = \sigma(W_f S_{t-1} + W_f X_t) \quad (1)$$

$$I_t = \sigma(W_i S_{t-1} + W_i X_t) \quad (2)$$

$$\tilde{C} = \tanh(W_c S_{t-1} + W_c X_t) \quad (3)$$

$$C_t = (i_t * \tilde{C}_t + f_t * C_{t-1}) \quad (4)$$

$$O_t = \sigma(W_o S_{t-1} + W_o X_t) \quad (5)$$

Keterangan:

W_f = Bobot dari *Forget Gate*.

W_i = Bobot dari *Input Gate*.

$\tilde{C}$ = *Intermediate cell state*.

W_c = Bobot dari *cell state*.

W_t = Bobot dari *output Gate*

S_{t-1} = *State* sebelumnya atau *state* pada waktu $t - 1$.

X_t = *Input* pada waktu t .

σ = Fungsi aktivasi *sigmoid*.

2.3. Mean Absolute Error (MAE)

MAE mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi[14]. Metrik ini memberikan gambaran yang jelas tentang seberapa besar kesalahan prediksi secara umum, tanpa terpengaruh oleh arah selisihnya. MAE cenderung lebih stabil dan tidak terlalu sensitif terhadap data pencilan (*outlier*). Nilai MAE yang rendah mengindikasikan tingkat kesalahan prediksi yang rendah [15].

Rumus yang digunakan adalah:

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

Keterangan:

n = Jumlah data

y_i = Nilai aktual

$\hat{y}_i$ = nilai prediksi

2.4. Root Mean Squared Error (RMSE)

RMSE menghitung akar dari rata-rata kuadrat selisih antara nilai aktual dan prediksi[14].

Metrik ini memberikan penekanan lebih besar pada kesalahan yang signifikan karena selisihnya dikuadratkan sebelum dirata-ratakan. Oleh karena itu, RMSE lebih sensitif terhadap data pencilan. Nilai RMSE yang rendah menunjukkan bahwa prediksi model konsisten mendekati nilai aktual [15].

Rumus yang digunakan adalah:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

Keterangan:

n = jumlah data
 y_i = nilai aktual
 $\hat{y}_i$ = nilai prediksi

3. METODE PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif berbasis eksperimen data time-series. Alur penelitian dimulai dari akuisisi data, pra-pemrosesan, perancangan arsitektur jaringan *Long Short-Term Memory* (LSTM), hingga evaluasi performa model menggunakan metrik statistic seperti pada gambar 1



Gambar 1. Desain Penelitian

3.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa deret waktu (*time series*) penyinaran matahari yang diperoleh dari data online BMKG (Badan Meteorologi, Klimatologi, dan Geofisika) yang diakses melalui <https://dataonline.bmkg.go.id>. Rentang data meliputi periode 1 Januari hingga 30 Desember 2023, dengan total 730 catatan harian. Terdapat tiga fitur utama yang digunakan sebagai input model:

- Rata-rata penyinaran matahari (Sr Avg): Intensitas radiasi harian rata-rata (w/m^2),
- Penyinaran Matahari Maksimum (SR Max): Nilai puncak radiasi harian (w/m^2),
- Durasi Penyinaran: Durasi matahari bersinar dalam satuan jam per hari.

3.2. Pemrosesan Data

Untuk memastikan stabilitas pelatihan model dan meningkatkan akurasi, data mentah melalui serangkaian tahapan pra-pemrosesan berikut:

3.3. Pembersihan Data

Data diperiksa untuk mendeteksi nilai yang hilang (*missing values*) atau anomali. Nilai yang hilang ditangani menggunakan teknik Interpolasi Linear guna menjaga kontinuitas temporal dari data deret waktu tanpa mengubah distribusi data secara drastis[14].

3.4. Normalisasi Data

Mengingat LSTM menggunakan fungsi aktivasi *sigmoid* dan *tanh* yang sensitif terhadap skala *input*, dilakukan normalisasi menggunakan metode *min-max scaling* [15].

Transformasi ini mengubah seluruh nilai ke dalam rentang $[0, 1]$ dengan rumus:

$$x^1 = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$


Dimana x^1 adalah nilai hasil normalisasi, $x_{\min}$ adalah nilai minimum, dan $x_{\max}$ adalah nilai maximum pada dataset.

3.5. Transformasi Windowing

Data diubah menjadi format *supervised learning* dengan menerapkan teknik *sliding window*. Model dikonfigurasi untuk mempelajari pola dari n hari sebelumnya untuk memprediksi kondisi cuaca pada hari berikutnya ($t + 1$).

3.6. Desain Sistem

Desain sistem dalam penelitian ini dirancang untuk membentuk alur kerja yang terintegrasi mulai dari pengumpulan data hingga prediksi cuaca menggunakan model *Long Short-Term Memory* (LSTM). Sistem ini terdiri dari beberapa komponen utama, yaitu pengumpulan data, pra-pemrosesan data, pelatihan model LSTM, validasi dan evaluasi model.



Gambar 2. Desain Sistem

Rincian dari masing-masing tahapan pada gambar 2 sebagai berikut:

- Input: Data diperoleh dari situs resmi BMKG (<https://dataonline.bmkg.go.id/>) sebagai sumber utama informasi cuaca yang relevan untuk kebutuhan penelitian.
- Processing: meliputi *cleaning* data untuk mengatasi nilai hilang, duplikasi, dan inkonsistensi, serta *normalization* data agar setiap variabel berada pada skala seragam.

- c. Pemodelan dengan LSTM: data hasil *preprocessing* dilatih dan diuji menggunakan model LSTM yang unggul dalam pengolahan data berurutan (*time series*), serta menentukan *hyperparameter tuning*.
- d. Output: Prediksi cuaca merupakan luaran (*output*) berupa nilai estimasi atau perkiraan dari parameter cuaca yang diuji. Kualitas dari hasil prediksi ini dievaluasi secara kuantitatif menggunakan metrik seperti MAE (*Mean Absolute Error*) dan RMSE (*Root Mean Squared Error*) yang berfungsi untuk mengukur performa model.

3.7. Pemodelan dengan LSTM

Tahap pemodelan merupakan inti dari penelitian ini, di mana arsitektur *Long Short-Term Memory* (LSTM) dikonfigurasi untuk mempelajari pola sekuensial dari data penyinaran matahari. Proses ini dibagi menjadi dua tahap utama: pembagian data (*Data Splitting*) dan optimasi parameter (*Hyperparameter Tuning*).

3.8. Training & Tasting

Untuk mengevaluasi performa dan generalisasi model terhadap data yang belum pernah dilihat sebelumnya, dilakukan pembagian dataset menjadi data latih (*training*) dan data uji (*testing*) [16]. Penelitian ini menerapkan skema eksperimen dengan tiga rasio pembagian yang berbeda seperti pada table 1 untuk menguji ketahanan (*robustness*) model terhadap variasi volume data.

Table 1. Pembagian Data

Ratio	Data Latih	Data Uji
70:30	506	217
80:10	578	145
90:10	650	73

3.9. Hyperparameter Tuning

Optimasi model dilakukan dengan menyesuaikan berbagai hiperparameter untuk mencapai nilai konvergensi yang optimal dan menghindari kondisi *overfitting* atau *underfitting* [17]. Parameter yang dikonfigurasi seperti pada table berikut.

Table 2. hyperparameter Tuning

Parameter	Model A	Model B	Model C
Struktur	Single Layer	Stacked Layer	Deep Sacked
Unit LSTM	32	64 (L1), 32 (L2)	128 (L1), 64(L2), 32 (L3)
Dropout Rate	0,3	0,2	0,1
Dense Layer	-	-	16 units
Optimizer	Adam	Adam	Adam
Learning Layer	0,0005	0,0005	0,0005

4. HASIL DAN PEMBAHASAN

Tujuan utama dari penelitian ini adalah meminimalkan nilai kesalahan prediksi, khususnya


Mean Absolute Error (MAE) dan *Root Mean Square Error* (RMSE), dengan melakukan optimasi kombinasi variabel pada arsitektur LSTM. Variabel yang dimodifikasi meliputi jumlah data latih, jumlah *neuron* (unit) dan tingkat *dropout*. Proses tuning pada hiperparameter seperti *learning rate*, jumlah iterasi (*epoch*), dan rasio pembagian data latih serta uji sangat krusial untuk menghasilkan pola prediksi dengan tingkat akurasi yang tinggi dan eror yang rendah.

Studi ini menggunakan dataset parameter meteorologi yang dikumpulkan dari stasiun AWS Stageof dan Staklim Malang. Dataset tersebut mencakup variabel waktu, radiasi matahari rata-rata (SR Average), radiasi matahari maksimum (SR Maximum), dan durasi penyinaran matahari. Setiap perubahan pada variabel hiperparameter membentuk tiga model pola data yang berbeda, yaitu Model A, Model B, dan Model C. Tabel I dan II menyajikan rincian konfigurasi variabel untuk masing-masing model tersebut.

4.1. Analisis Hasil Prediksi pada Ratio 70:30

Evaluasi visual dilakukan untuk membandingkan efektivitas tiga arsitektur LSTM yang berbeda dalam memprediksi data penyinaran matahari. Gambar A, B, dan C menunjukkan perbandingan *time-series* antara data aktual (biru) dan hasil prediksi (merah).


4.2. Model A



Gambar 3. Learning Curve Model A (70:30)

Pada gambar 3, Model A dengan lapisan tunggal 32-unit menunjukkan kestabilan yang cukup baik. Meskipun strukturnya paling sederhana, model ini mampu mengikuti tren utama harian. Celah garis (*line gap*) terlihat konsisten, namun terdapat sedikit deviasi pada titik-titik fluktuasi tajam di siang hari. Model ini menghasilkan RMSE sebesar 0.114368, yang mengindikasikan bahwa untuk data cuaca dengan pola berulang yang stabil, arsitektur ringan sudah cukup memadai.

4.3. Model B




Gambar 4. Learning Curve Model B (70:30)

Gambar 4 merepresentasikan performa Model B (*stacked layer* 64 & 32-unit). Secara visual, kurva prediksi merah hampir berhimpit sempurna dengan

kurva aktual biru. Model B menunjukkan kemampuan superior dalam menangkap lonjakan intensitas radiasi maksimum (SR Max). Hal ini tercermin dari perolehan MAE terendah sebesar 0.072510. Penggunaan dua lapisan LSTM memungkinkan model untuk mengekstraksi fitur temporal yang lebih abstrak, sehingga menghasilkan prediksi yang paling presisi dibandingkan model lainnya.

4.4. Model C




Gambar 5. Learning Curve Model C (70:30)

Pada Gambar 5, Model C dengan tiga lapisan mendalam (128, 64, 32-unit) menunjukkan hasil yang menarik. Meskipun arsitekturnya paling kompleks, terlihat adanya sedikit pergeseran atau ketidakselarasan pada beberapa puncak kurva dibandingkan Model B. Fenomena ini mengindikasikan adanya gejala awal *overfitting* ringan atau kompleksitas yang berlebihan (*over parameterization*) untuk ukuran dataset 70:30. Akibatnya, peningkatan jumlah lapisan dan unit pada Model C tidak serta merta menurunkan galat, melainkan menyebabkan degradasi akurasi dibandingkan Model B.

4.5. Analisis Hasil Prediksi pada Ratio 80:30

Peningkatan proporsi data latih menjadi 80% bertujuan untuk memberikan ruang pembelajaran yang lebih luas bagi model LSTM. Namun, hasil visualisasi pada model A, B, dan C menunjukkan dinamika yang berbeda dibandingkan dengan skenario 70:30 sebelumnya.


4.6. Model A



Gambar 6. Learning Curve Model A (80:20)

Pada Gambar 6, Model A tetap mempertahankan performa yang cukup stabil. Dengan rasio 80:20, garis prediksi (merah) masih mampu mengikuti pola dasar harian. Meskipun demikian, celah garis (*line gap*) mulai menunjukkan sedikit pelebaran pada titik-titik transisi intensitas cahaya rendah ke tinggi. Hal ini mengindikasikan bahwa meskipun data latih bertambah, kapasitas 32unit pada Model A mulai mencapai batas optimalnya dalam melakukan generalisasi.


4.7. Model B



Gambar 7. Learning Curve Model B (80:20)

Gambar 7 menunjukkan bahwa Model B tetap menjadi arsitektur yang paling andal. Penambahan data latih hingga 80% dimanfaatkan dengan baik oleh struktur *stacked* (64 & 32 unit) untuk mempertajam akurasi pada nilai puncak (*peak values*). Terlihat bahwa garis merah hampir menempel sempurna pada garis biru, menunjukkan bahwa Model B memiliki resiliensi yang kuat terhadap perubahan rasio data tanpa kehilangan kemampuan generalisasi.

4.8. Model C




Gambar 8. Learning Curve Model C (80:20)

Hasil pada Gambar 8 menunjukkan fenomena yang menarik. Meskipun memiliki data latih yang lebih banyak (80%), Model C menunjukkan fluktuasi prediksi yang lebih kasar pada beberapa titik dibandingkan Model B. Fenomena ini sering dikaitkan dengan *overfitting*, di mana model dengan parameter yang sangat besar (128-64-32 unit) cenderung mempelajari noise pada data latih secara berlebihan. Akibatnya, pada saat validasi dengan 20% data uji, model menunjukkan deviasi yang lebih terlihat pada grafik.

4.9. Analisis Hasil Prediksi pada Ratio 90:10

Skenario terakhir menggunakan proporsi data latih terbesar (90%) untuk menguji apakah peningkatan volume data secara ekstrem dapat meningkatkan akurasi. Namun, hasil visualisasi pada Gambar A, B, dan C menunjukkan anomali yang signifikan dibandingkan dua skenario sebelumnya.

4.10. Model A




Gambar 9. Learning Curve Model A (90:10)

Pada Gambar 9, terlihat bahwa Model A mulai kesulitan mengikuti pola fluktuatif dari radiasi matahari aktual. Garis prediksi (merah) tampak lebih

kaku dan sering kali gagal mencapai titik puncak yang sesuai dengan data aktual. Fenomena ini mengindikasikan bahwa dengan data uji yang hanya 10%, model tidak memiliki cukup referensi untuk melakukan validasi terhadap variabilitas data baru, sehingga menyebabkan peningkatan nilai RMSE.


4.11. Model B



Gambar 10. Learning Curve Model B (90:10)

Meskipun Model B merupakan model terbaik pada rasio lainnya, Gambar 10 menunjukkan bahwa pada rasio 90:10, garis merah mulai menjauh dari garis biru (*line gap* melebar). Terjadi deviasi yang cukup besar terutama pada fase penurunan radiasi. Penurunan kinerja ini tercermin dari kenaikan nilai MAE hingga mencapai sekitar 0.104900, yang membuktikan bahwa kelebihan data latih tanpa diimbangi data uji yang memadai justru merusak kemampuan generalisasi model.

4.12. Model C



Gambar 11. Learning Curve Model C (90:10)

Gambar 11 menunjukkan visualisasi prediksi yang paling tidak stabil. Garis merah tampak sangat tidak selaras dengan pola biru pada beberapa periode waktu. Pada arsitektur kompleks seperti Model C, rasio 90:10 memicu terjadinya *overfitting* yang parah, model terlalu menyesuaikan diri dengan detail kecil pada data latih (termasuk *noise*) sehingga kehilangan kemampuan untuk memprediksi data uji yang sangat terbatas secara akurat.

4.13. Hasil Evaluasi Model

Hasil evaluasi model menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) terhadap seluruh skenario pengujian disajikan pada table 3 dan 4.


Tabel 3. Hasil Root Mean Square Error

Ratio	Model A	Model B	Model C
70:30	0.114368	0.115406	0.119184
80:20	0.129074	0.133030	0.135366
90:10	0.164426	0.166714	0.174113

Table 4. Hasil Mean Absolute Error

Ratio	Model A	Model B	Model C
70:30	0.075125	0.072510	0.077886
80:20	0.081784	0.079022	0.085281
90:10	0.103067	0.104900	0.110044

Hasil evaluasi statistik menggunakan metrik *Root Mean Square Error* (RMSE) terhadap seluruh skenario pengujian disajikan pada Gambar 12. Visualisasi ini memberikan gambaran komprehensif mengenai stabilitas arsitektur Model A, B, dan C dalam menghadapi variasi distribusi data latih dan data uji.



Gambar 12. Perbandingan Model

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa penggunaan arsitektur Long Short-Term Memory (LSTM) sangat efektif dalam memprediksi parameter penyinaran matahari, dengan performa yang dipengaruhi oleh konfigurasi arsitektur dan rasio pembagian data. Hasil eksperimen menunjukkan bahwa Model B, yang menggunakan *stacked layer* (64 dan 32 unit) dengan *dropout* 0,2, merupakan arsitektur paling optimal karena mampu menghasilkan nilai *Mean Absolute Error* (MAE) terendah sebesar 0,075103. Dari sisi distribusi data, rasio pembagian 70:30 terbukti memberikan hasil paling stabil dan akurat bagi seluruh model dibandingkan rasio lainnya. Sebaliknya, penggunaan proporsi data latih yang terlalu besar (rasio 90:10) justru memicu penurunan performa signifikan akibat gejala *overfitting*, di mana model kehilangan kemampuan generalisasi karena kurangnya data uji sebagai referensi validasi. Dengan demikian, pemilihan kedalaman arsitektur yang moderat dan keseimbangan distribusi data menjadi faktor kunci dalam pengembangan sistem prediksi cuaca berbasis *deep learning* yang presisi.

Berdasarkan temuan penelitian, terdapat beberapa saran strategis untuk pengembangan studi di masa mendatang. Pertama, eksplorasi teknik optimasi *hyperparameter* seperti *learning rate scheduler* atau algoritma di luar Adam perlu dilakukan untuk menekan nilai galat pada arsitektur yang lebih dalam. Kedua, penelitian selanjutnya disarankan memperluas cakupan temporal data melampaui satu tahun guna menangkap pola musiman dan anomali iklim jangka panjang yang kompleks. Selain itu, integrasi variabel

tambahan seperti tutupan awan, kelembapan, dan kecepatan angin direkomendasikan untuk menghasilkan prediksi yang lebih komprehensif. Terakhir, pengujian model di berbagai wilayah geografis di luar Malang sangat penting untuk memvalidasi ketahanan serta adaptabilitas model terhadap variasi mikroklimat.

DAFTAR PUSTAKA

- [1] Z. A. Dwiyantri and C. Prianto, "Prediksi Cuaca Kota Jakarta menggunakan Metode Random Forest : Studi Optimalitas," *J. Tekno Insentif*, vol. 17, no. 2, pp. 127–137, 2023.
- [2] A. Damayanti and A. Prabowo, "Analisis Perubahan Iklim: Frekuensi Bencana Alam dan Kerugian Ekonomi Menggunakan Google," *Pros. Semin. Nas. Sains Data*, vol. 4, no. 1, pp. 662–668, 2024, doi: 10.33005/senada.v4i1.299.
- [3] dewa A. K. Wida, K. Sumaja, and H. Wiguna, "The Relationship Analysis of Radiation Intensity and Sunshine Duration With Weather Parameters At Meteorological Station Ngurah Rai and Their Effect on the Potential of Solar Power Plants in South Bali," *Bul. Meteo Ngurah Rai*, vol. 5, no. 1, pp. 1–7, 2019.
- [4] A. Yunita *et al.*, "Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid models," *MethodsX*, vol. 15, p. 103462, 2025, doi: 10.1016/j.mex.2025.103462.
- [5] P. A. Nugroho, "Implementasi Jaringan Syaraf Tiruan Multi-Layer Perceptron Untuk Prediksi Penyinaran Matahari Kota Bandung," *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 1, pp. 83–90, 2023, doi: 10.34010/komputa.v12i1.9419.
- [6] E. Supriyadi, "Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (LSTM) Weather Parameters Prediction Using Deep Learning Long-Short Term Memory (LSTM)," *J. Meteorol. dan Geofis.*, vol. 21, no. 2, pp. 55–67, 2020, [Online]. Available: <http://bmkgsoft.database.bmkg.go.id>.
- [7] K. M. S. A. Hennayake, R. DInalankara, and D. Y. Mudunkotuwa, "Machine Learning Based Weather Prediction Model for Short Term Weather Prediction in Sri Lanka," *2021 10th Int. Conf. Inf. Autom. Sustain. ICIAfS 2021*, pp. 299–304, 2021, doi: 10.1109/ICIAfS52090.2021.9606077.
- [8] M. A. R. Suleman and S. Shridevi, "Short-Term Weather Forecasting Using Spatial Feature Attention Based LSTM Model," *IEEE Access*, vol. 10, no. August, pp. 82456–82468, 2022, doi: 10.1109/ACCESS.2022.3196381.
- [9] T. Andrew Gahwera, O. Steven Eyobu, M. Isaac, S. Kakuba, and D. S. Han, "Transfer Learning-Based Ensemble Approach for Rainfall Class Amount Prediction," *IEEE Access*, vol. 13, no. February, pp. 48318–48334, 2025, doi: 10.1109/ACCESS.2025.3551737.
- [10] O. Alghushairy, R. Alsini, A. Yafoz, S. Yonbawi, and X. Ma, "Two-Stages Weather Forecasting System for Optimizing Supply Chain Operations in Saudi Arabia Using BiGRU and Fox Metaheuristics Algorithms," *Arab. J. Sci. Eng.*, 2025, doi: 10.1007/s13369-025-10464-8.
- [11] Z. Karevan and J. A. K. Suykens, "Transductive LSTM for time-series prediction: An application to weather forecasting," *Neural Networks*, vol. 125, pp. 1–9, 2020, doi: 10.1016/j.neunet.2019.12.030.
- [12] R. Singhal, P. Singhal, and S. Gupta, "Solar-Cast: Solar Power Generation Prediction from Weather Forecasts using Machine Learning," 2022. doi: 10.1109/PIICON56320.2022.10045237.
- [13] A. Khumaidi and I. A. Nirmala, *Algoritma Long Short Term Memory dengan Hyperparameter Tuning: Prediksi Penjualan Produk*. 2022.
- [14] J. Shi, S. Wang, P. Qu, and J. Shao, "Time series prediction model using LSTM-Transformer neural network for mine water inflow," *Sci. Rep.*, vol. 14, no. 1, pp. 1–16, 2024, doi: 10.1038/s41598-024-69418-z.
- [15] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," *Geosci. Model Dev.*, vol. 15, no. 14, pp. 5481–5487, 2022, doi: 10.5194/gmd-15-5481-2022.
- [16] W. Musu *et al.*, "Pengaruh Komposisi Data Training dan Testing terhadap Akurasi Algoritma C4 . 5," *Pros. Semin. Ilm. Sist. Inf. dan Teknol. Inf.*, vol. X, no. 1, pp. 186–195, 2021.
- [17] J. A. Ilemobayo, O. Durodola, A. Ogungbire, and A. Osinuga, "Hyperparameter Tuning in Machine Learning : A Comprehensive Review," *J. Eng. Res. Reports Vol.*, vol. 26, no. 6, pp. 388–395, 2024.