



## PEMANFAATAN ALGORITMA LSTM DALAM DEEP LEARNING UNTUK PREDIKSI CUACA MENGGUNAKAN BAHASA PEMROGRAMAN PYTHON

<sup>1</sup> Fionita Fahra Azzahra, <sup>2</sup> Muhammad Restu Alvykya, <sup>3</sup> Aulia Rafi Hermawan, <sup>4</sup> Fifin Dewi Ratnasari

<sup>1,2,3,4</sup> Program Studi Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam,

Universitas Negeri Semarang,  
Semarang, Indonesia

Email: *corresponding* [fifin\\_fisika@mail.unnes.ac.id](mailto:fifin_fisika@mail.unnes.ac.id)

Corresponding Author: Fifin Dewi Ratnasari, S.Si., M.Sc

### ABSTRACT

*The phenomenon of global warming has precipitated anomalous climate change. Since the onset of the industrial era, the Earth's temperature has exhibited an annual increase of approximately 1°C. This issue is further compounded by the limitations of conventional prediction systems in processing voluminous datasets. Consequently, the integration of technological solutions into weather forecasting is imperative to mitigate the risks posed by erratic weather patterns and support the process of disaster mitigation. In this particular instance, deep learning of the LSTM type is employed for the processing of voluminous datasets. The system's capacity to process data through the utilization of system layers, including the forget gate and the memory cell, enables the storage of crucial information and the elimination of erroneous data. The present study employed two predictive steps: firstly, data processing with LSTM, and secondly, prediction of results using classification on the most influential parameters on weather. The prediction results indicate a system accuracy rate of 73.1%, suggesting that the system is capable of performing processing operations with a satisfactory degree of precision. The enhancement of potential development can be achieved through the incorporation of layers into LSTM, the augmentation of epochs, or the integration of other systems to ensure enhanced accuracy.*

**Keywords:** *Global Warming, Deep Learning, LSTM*

### Article History

Received: Mei 2025

Reviewed: Mei 2025

Published: Mei 2025

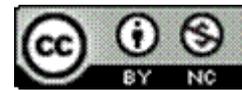
Plagiarism Checker No  
235

Prefix DOI :

[10.8734/Koehsi.v1i2.365](https://doi.org/10.8734/Koehsi.v1i2.365)

Copyright : Author

Publish by : Koehsi



This work is licensed under a [Creative Commons Attribution NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)

### ABSTRAK

Pemanasan global berdampak pada perubahan iklim yang tidak menentu. Semenjak era industri, kenaikan suhu bumi mencapai  $1^{\circ}\text{C}$  setiap tahunnya. Hal ini, diperparah oleh sistem prediksi tradisional yang kurang mumpuni untuk mengolah dataset besar. Sehingga, prediksi cuaca dengan mengintegrasikan teknologi perlu dilakukan guna mengurangi resiko dan mendukung proses mitigasi bencana akibat perubahan cuaca yang tidak menentu. Deep learning jenis LSTM dalam hal ini digunakan untuk melakukan pemrosesan terhadap dataset besar. Kemampuannya dalam mengolah data dengan memanfaatkan layer sistem berupa *forget gate* dan *memory cell* memungkinkan untuk menyimpan data penting dan menghapus data tidak akurat. Pada penelitian ini, digunakan dua langkah prediksi berupa: pengolahan data dengan LSTM dan prediksi hasil menggunakan klasifikasi pada parameter paling berpengaruh terhadap cuaca. Hasil prediksi menunjukkan tingkat akurasi sistem sebesar 73.1% sehingga dapat disimpulkan bahwa sistem dapat melakukan pemrosesan dengan baik. Potensi pengembangan dapat dilakukan dengan penambahan layer pada LSTM, menaikkan *epoch*, maupun mengintegrasikan sistem lain sehingga akurasi dapat ditingkatkan.

**Kata kunci:** Pemanasan Global, Deep Learning, LSTM

### PENDAHULUAN

Kondisi iklim bumi kian mengkhawatirkan, pemanasan global menyebabkan kenaikan suhu permukaan bumi sekitar  $1^{\circ}\text{C}$  per tahun semenjak era industrial mungkin terlihat sepele namun kenyataannya akumulasi dari kenaikan suhu tersebut berdampak cukup signifikan pada beberapa bidang. Perairan, makanan, kesehatan, lingkungan, infrastruktur menjadi yang paling terdampak (NOAA, 2024). Fenomena ini bukan hanya sebuah bahasan namun masalah yang benar benar terjadi, penyebabnya adalah efek rumah kaca akibat banyaknya gas rumah kaca yang ada di atmosfer

Gas rumah kaca seperti metana, nitrogen oksida, gas fluorinasi, uap air dan karbon dioksida yang merupakan kontributor utama efek rumah kaca karena jumlahnya yang paling banyak di atmosfer. Gas rumah kaca bisa dihasilkan dari aktivitas

gunung berapi aktif, namun yang paling signifikan adalah aktivitas manusia (Pratama. R., 2019)

Pemanasan global turut memicu peningkatan kejadian dan kekuatan gelombang panas (*heatwaves*). Suhu yang sangat tinggi bisa berdampak serius, dan di berbagai wilayah dengan iklim ekstrim, angka kematian saat musim dingin cenderung lebih besar dibandingkan musim panas. Dampak perubahan iklim di Indonesia di masa mendatang dapat dikenali melalui beberapa indikator, yaitu naiknya suhu, bergesernya pola curah hujan, dan kondisi kelembaban udara sekitar. Perubahan-perubahan ini berpotensi mengubah jalur penyebaran mikroorganisme, mempengaruhi dinamika penularan penyakit, mengganggu agroekosistem dan siklus hidrologi, serta memberikan tekanan pada kondisi sosial-ekonomi, demografi, dan kesehatan masyarakat secara keseluruhan (Susilawati, 2021).

Salah satu dampak dari perubahan iklim adalah cuaca yang tak menentu, namun ternyata cuaca bisa kita prediksi dengan mempertimbangkan berbagai faktor yang mempengaruhinya seperti suhu, kelembaban, kecepatan angin, dan curah hujan (Wahyudi, E. dkk. 2024). Dengan bantuan deep learning dan data data faktor yang mempengaruhi cuaca tersebut kita bisa melakukan prediksi terhadap cuaca, Deep learning yaitu neural network multiple layer yang dikembangkan guna menjalankan suatu tugas seperti mengenali suara, menerjemahkan bahasa, mendeteksi objek dan lain lain (Putra, 2018).

Deep learning yang digunakan adalah Long short term memory (LSTM), merupakan bagian dari Recurrent Neural Network (RNN) yang dibuat untuk mengatasi kelemahan dalam mengingat data jangka panjang (H. Sepp & S. Jurgen 1997). Satu unit LSTM terdiri dari tiga gerbang utama yaitu forget gate, input gate dan output gate. LSTM bisa digunakan untuk berbagai hal seperti prediksi data, pengenalan suara, dan pengendali sistem. Prediksi cuaca yang dilakukan merupakan penerapan dari kemampuan prediksi data dari LSTM.

Sistem prediksi cuaca berbasis LSTM ini masih bisa dikembangkan lebih jauh untuk meningkatkan efisiensi dan akurasi nya, salah satu nya dengan diintegrasikan dengan internet sehingga bisa menjadi IoT yang dapat mengambil data dan memprediksi cuaca secara real time.

## **A. Tujuan**

1. Membuat program prediksi cuaca menggunakan deep learning LSTM

2. Mengetahui karakteristik deep learning LSTM yang digunakan untuk memprediksi cuaca

### **B. Rumusan Masalah**

1. Bagaimana algoritma program prediksi cuaca menggunakan deep learning LSTM
2. Bagaimana karakteristik deep learning LSTM yang digunakan untuk memprediksi cuaca

## **METODE**

### **A. Analisis Masalah**

Pada penelitian ini langkah pertama yang dilakukan adalah dengan mengidentifikasi masalah yang akan diselesaikan dan dibahas pada bagian Pembahasan. Rumusan masalah didapatkan dari penelitian yang telah dilakukan sebelumnya.

Metode konvensional seringkali memiliki keterbatasan dalam menangkap pola jangka panjang dan interaksi antar variabel cuaca. Penelitian ini bertujuan untuk mengimplementasikan algoritma Long Short-Term Memory (LSTM), salah satu bentuk Recurrent Neural Network (RNN) yang dirancang khusus untuk menangani data sekuensial dan memiliki kemampuan memori jangka panjang, guna memprediksi parameter cuaca. Penelitian tentang prediksi cuaca telah dilakukan oleh Eko (2020) mengenai Prediksi Parameter Cuaca Menggunakan *Deep Learning Long-Short Term Memory* (LSTM). Pada penelitian tersebut merancang algoritma LSTM dan di uji Partial Autocorrelation Function (PACF) yang digunakan untuk memprediksi cuaca. Hasil yang didapatkan dari penelitian tersebut adalah algoritma LSTM dapat digunakan untuk memprediksi cuaca dengan cukup baik.

Oleh karenanya, pada penelitian ini dilakukan strategi dengan mengubah perlakuan pengolahan terhadap data menggunakan Keras dan Tensorflow. Hasil dari perlakuan akan digunakan untuk menentukan kelayakan metode yang dilakukan.

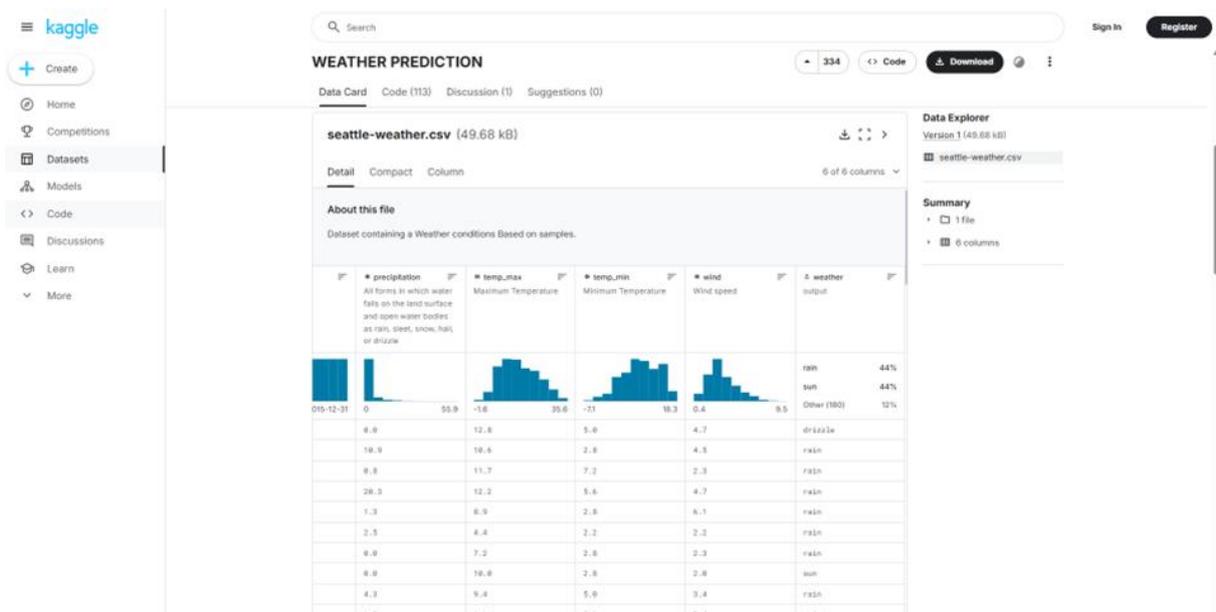
### **B. Studi Literatur**

Studi literatur dilakukan untuk memahami pendekatan-pendekatan yang telah digunakan sebelumnya dalam prediksi cuaca berbasis machine learning dan deep learning. LSTM terbukti unggul dalam menangani data time-series dibanding metode klasik karena kemampuannya mengingat informasi historis penting dalam data sekuensial. Selain itu, beberapa (Lara-Benítez, Carranza-García and Riquelme,

2021). Literatur yang ditinjau meliputi publikasi ilmiah, jurnal, dan proyek open-source yang relevan, termasuk implementasi LSTM dalam domain prediksi suhu dan curah hujan. Studi literatur dilakukan untuk memberikan pemahaman lebih atas topik penelitian. Studi literatur juga sebagai landasan serta instrumen pembandingan dari penelitian yang akan dilakukan.

### C. Pengumpulan Data

Pengumpulan data dilakukan melalui website <https://www.kaggle.com/>. Data yang dikumpulkan terdiri dari parameter temperatur maksimal, temperatur minimal, kecepatan angin, dan presipitasi. Data berisi rentang waktu antara tahun 2012 hingga 2015. Data yang digunakan pada penelitian ini merupakan data tiap hari. Total data dari setiap parameter yang digunakan adalah 1.462. Data ini nantinya akan dibagi sebagai data *training* yang digunakan sebagai data yang dilatih menggunakan model LSTM.



Gambar 1 Pengumpulan Data Pada Website Kaggle

### D. Pengolahan Data

Data yang telah dikumpulkan dari website Kaggle kemudian melalui proses pengolahan untuk memastikan kualitas dan kesesuaian sebelum digunakan dalam

pelatihan model Long Short-Term Memory (LSTM). Pengolahan data merupakan mengubah input dan output data menjadi bentuk lain yang telah disesuaikan (Nawassyarif, M. Julkarnain dan Rizki Ananda, 2020).

### **1) Uji Missing Value**

Pengolahan pertama yang dilakukan adalah mencari missing value (data kosong). Missing value merupakan kondisi di mana sebagian data dalam sebuah dataset tidak tersedia atau tidak tercatat, yang menyebabkan informasi pada kolom tertentu menjadi tidak lengkap. Hal ini umum terjadi dalam data eksperimen, survei, atau data sensor seperti cuaca.

Pengisian missing value perlu dilakukan agar nantinya pembuatan arsitektur LSTM tidak dipengaruhi. Salah satu cara untuk mengisi Missing Value yaitu dengan menggunakan metode interpolasi.

Data yang didapat dari web Kaggle memiliki rentang waktu satu hari. Setelah dilakukan pengujian tidak terdapat missing value sehingga tidak perlu dilakukan perlakuan missing data.

### **2) Normalisasi**

Setelah memastikan bahwa data bebas dari *missing value*, langkah berikutnya dalam proses pengolahan data adalah melakukan normalisasi terhadap setiap parameter cuaca, yaitu temperatur maksimum, temperatur minimum, kecepatan angin, dan presipitasi. Normalisasi bertujuan untuk menyetarakan skala data, sehingga setiap fitur memiliki kontribusi yang seimbang dalam proses pelatihan model, khususnya pada algoritma berbasis jaringan saraf seperti Long Short-Term Memory (LSTM). Metode normalisasi yang digunakan dalam penelitian ini adalah Min-Max Normalization, yang mengubah nilai data ke dalam rentang 0 hingga 1. Formula yang digunakan adalah sebagai berikut:

$$\underline{x} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Di mana  $\underline{x}$  adalah nilai setelah dinormalisasi,  $x_{min}$  adalah nilai minimum dalam

dataset, dan adalah nilai maksimum. Dengan cara ini, semua nilai parameter cuaca akan berada dalam rentang 0 hingga 1, yang membantu proses pelatihan model LSTM menjadi lebih cepat dan stabil.

Dalam implementasinya, normalisasi dilakukan menggunakan library scikit-learn dengan `MinMaxScaler`, di mana data setiap parameter akan dinormalisasi secara individual sebelum dibentuk menjadi urutan (sequence) sebagai input untuk model LSTM.

#### **E. Perancangan Model Long Short-Term Memory**

Perancangan model Long Short-Term Memory (LSTM) pada penelitian ini bertujuan untuk memprediksi masing-masing parameter cuaca, yaitu temperatur maksimum, temperatur minimum, kecepatan angin, dan presipitasi, secara individual. Untuk setiap parameter, dilakukan pembentukan data sekuensial berdasarkan jendela waktu (*window size*) selama tujuh hari. Data historis ini digunakan sebagai input bagi model untuk mempelajari pola dan hubungan temporal antar data harian. Setelah data sekuens terbentuk, dilakukan pembagian data menjadi tiga bagian, yakni data latih sebesar 70%, data validasi 15%, dan data uji 15%. Proses ini dilakukan tanpa pengacakan (non-shuffled) untuk menjaga kontinuitas urutan waktu yang penting dalam pemodelan deret waktu.

Arsitektur model yang dirancang terdiri atas tiga lapisan LSTM bertingkat (stacked LSTM), masing-masing memiliki 64 unit memori. Dua lapisan pertama untuk meneruskan seluruh urutan ke lapisan berikutnya, sedangkan lapisan ketiga untuk menghasilkan representasi akhir dari sekuens. Setelah lapisan LSTM, model dilanjutkan dengan satu lapisan Dense berjumlah 32 neuron dengan fungsi aktivasi ReLU (Rectified Linear Unit), kemudian diakhiri dengan lapisan keluaran (output) berupa satu neuron yang menghasilkan nilai prediksi.

Model dilatih selama 50 epoch dengan batch size 32. Selama proses pelatihan, dilakukan validasi menggunakan data validasi untuk memantau potensi overfitting. Hasil dari pelatihan divisualisasikan dalam grafik yang menunjukkan nilai loss pada data latih dan validasi terhadap jumlah epoch. Visualisasi ini

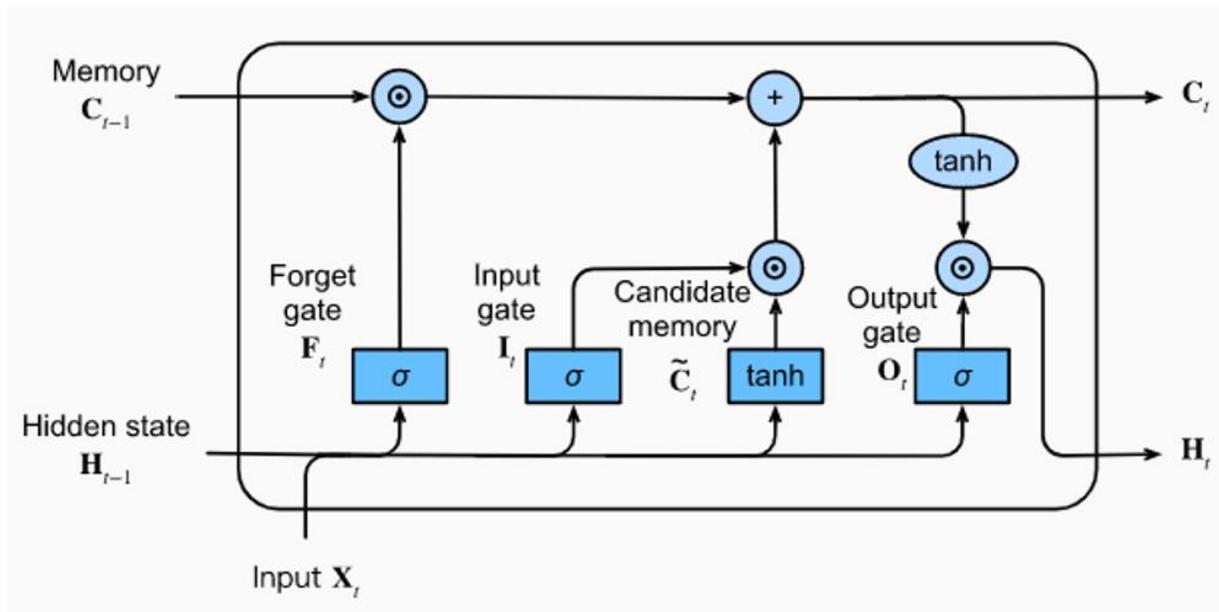
memberikan gambaran mengenai stabilitas dan konvergensi model selama proses pembelajaran. Setelah pelatihan selesai, model digunakan untuk melakukan prediksi terhadap data validasi dan data uji. Prediksi ini kemudian di-*inverse transform* untuk mengembalikan hasil ke skala data aslinya.

Evaluasi performa model dilakukan dengan menghitung tiga metrik utama, yaitu Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien determinasi ( $R^2$ ). Hasil prediksi dibandingkan secara visual dengan data aktual baik pada validation set maupun test set untuk masing-masing parameter cuaca. Visualisasi ini bertujuan untuk melihat sejauh mana model mampu mengikuti pola tren yang sebenarnya. Data hasil prediksi kemudian disimpan dalam format CSV untuk dokumentasi dan analisis lebih lanjut.

## **HASIL DAN DISKUSI**

Deep learning merupakan cabang dari machine learning yang menggunakan jaringan syaraf tiruan (JST) dengan beberapa layer (lapisan) untuk melakukan analisis data. JST dalam hal ini memiliki fungsi sebagai alat untuk mengekstrak fitur dari input data dari setiap layer. Sehingga, memungkinkan model untuk belajar dengan baik dari data yang diberikan. Pada prediksi cuaca, digunakan model Long Short Term Memory (LSTM) yang dirancang untuk mengatasi masalah RNN tradisional berupa kesulitan merekam informasi berupa urutan data dalam jangka waktu lama (Makamo, 2023).

LSTM sangat efektif untuk pengembangan pemantauan iklim berbasis waktu real time. Model ini unggul dalam menangkap dependensi temporal pada data deret waktu. Penerapan model LSTM dalam prediksi cuaca memiliki beberapa kelebihan, diantaranya: dapat menangani ketergantungan temporal, dimana LSTM dirancang untuk mengingat informasi dalam jangka waktu yang lama. Kemampuan multi-input dan multi output LSTM juga sangat penting digunakan untuk memproses beberapa variabel cuaca secara bersamaan, apalagi dalam prediksi cuaca dipengaruhi oleh beberapa parameter (Cao, 2024; Harikishan, 2023)



Gambar 2 Layer LSTM (Long Short Term Memory)

Lapisan LSTM merupakan komponen fundamental yang dirancang untuk memproses data sekuensial. Berikut merupakan lapisan dari LSTM :

### A. Input Gate

Gerbang input digunakan sebagai tempat untuk masukan sistem. Pada penelitian ini, digunakan empat dimensi masukan berupa (temperatur minimum, temperatur maksimum, *humidity*, serta *wind speed*). Pada step selanjutnya, gerbang input memiliki peran untuk memutuskan informasi yang akan ditambahkan. Hal ini, akan menggabungkan input saat ini dengan *hidden state* sebelumnya untuk membuat nilai kandidat, yang kemudian difilter oleh gerbang input.

$$I_t = \sigma(W_i \cdot [H_{t-1}, X_t] + b_i)$$

$$C'_t = \tanh(W_c \cdot [H_{t-1}, X_t] + b_c)$$

dengan,

$I_t$  = input gate

$C'_t$  = kandidat memori baru

$W_i, W_c$  = bobot masing-masing

$b_i, b_c$  = bias masing-masing

### B. Forget Gate

Gerbang ini menentukan informasi yang akan dibuang, dengan memanfaatkan fungsi sigmoid, forget gate akan memberikan output berupa nilai antara 0 dan 1, yang menunjukkan berapa banyak status sel sebelumnya yang harus dipertahankan atau dibuang.

$$F_t = \sigma (W_f \cdot [H_{t+1}, X_t] + b_f)$$

dimana,

$F_t$  = vektor forget gate (nilai antara 0 dan 1)

$\sigma$  = fungsi sigmoid

$W_f$  = bobot forget gate

$H_{t+1}$  = hidden state

$X_t$  = input pada waktu t

$b_f$  = bias forget gate

### C. Output Gate

Gerbang keluaran akan mengontrol informasi yang dikirim kepada lapisan berikutnya. Menggunakan status sel yang diperbarui untuk menghasilkan *hidden state*.

$$O_t = \sigma (W_o \cdot [H_{t-1}, X_t] + b_o)$$

dengan hidden state:

$$H_t = O_t \cdot \tanh(C_t)$$

### D. Cell State Update

Sel ini berinteraksi dengan tiga gerbang (*forget gate, input gate, dan output gate*) untuk mengelola aliran informasi. Memungkinkan LSTM untuk mempelajari dependensi jangka panjang, yang sangat penting dalam tugas pemrosesan bahasa alami. Dengan mempertahankan informasi yang relevan dari waktu ke waktu, sel akan membantu model membuat prediksi yang lebih baik berdasarkan konteks seluruh urutan (Abdillah, 2023).

$$C_t = F_t \cdot C_{t-1} + I_t \cdot C_t'$$

persamaan ini digunakan untuk memperbarui cell state, dimana:

$C_{t-1}$  = cell state sebelumnya

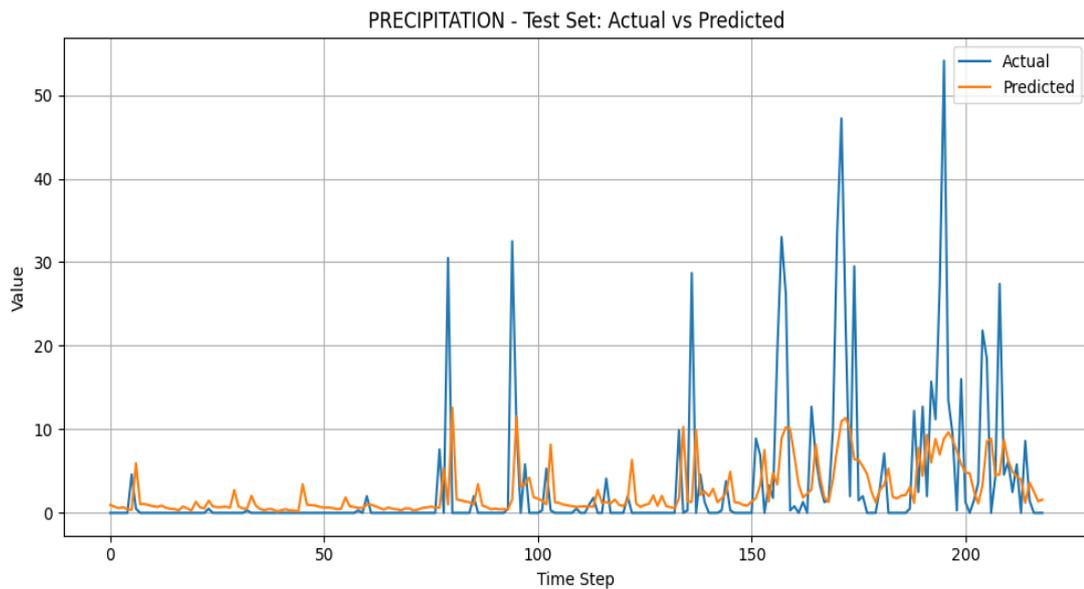
$C_t$  = cell state sekarang

Pembuatan sistem prediksi cuaca menggunakan dua tahap, yaitu prediksi nilai parameter langkah ke-n berbasis LSTM dan prediksi cuaca didasarkan parameter yang dihasilkan.

### E. Prediksi Parameter berbasis LSTM

Setelah dilakukan pelatihan model menggunakan arsitektur Long Short-Term Memory (LSTM), proses prediksi dilakukan terhadap masing-masing parameter cuaca, yaitu *precipitation*, *temp\_max*, *temp\_min*, dan *wind*. Hasil prediksi kemudian dibandingkan dengan data aktual pada data uji (*test set*) untuk mengevaluasi performa model secara visual maupun kuantitatif.

#### 1) Prediksi Presipitasi



Gambar 3 Grafik Prediksi Parameter Presipitasi

Hasil prediksi *precipitation* menunjukkan adanya perbedaan yang cukup besar antara data aktual dan hasil prediksi, terutama saat terjadi lonjakan curah hujan. Grafik memperlihatkan bahwa model cenderung menghasilkan prediksi yang lebih rata dan gagal menangkap nilai-nilai ekstrem.

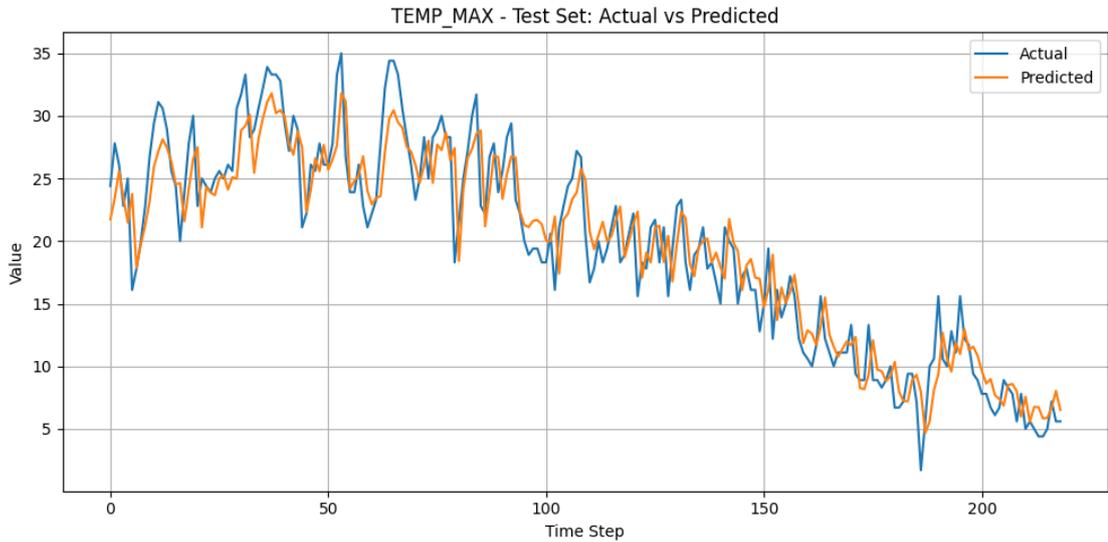
Tabel 1 Nilai Evaluasi Parameter Presipitasi

Evaluator	Nilai
MAE	2.1641
RMSE	2.7208
$R^2$	0.8877

Hal ini ditunjukkan secara kuantitatif melalui nilai Mean Absolute Error (MAE) sebesar 3.6511, Root Mean Squared Error (RMSE) sebesar 7.4031, dan

koefisien determinasi  $R^2$  hanya sebesar 0.1919. Nilai  $R^2$  yang rendah menunjukkan bahwa model hanya mampu menjelaskan sekitar 19% variasi dalam data aktual, yang menandakan bahwa performa model dalam memprediksi curah hujan masih jauh dari optimal. Hal ini kemungkinan besar disebabkan oleh karakteristik data curah hujan yang bersifat sporadis dan memiliki distribusi yang tidak merata.

**2) Prediksi Temperatur Maksimal**



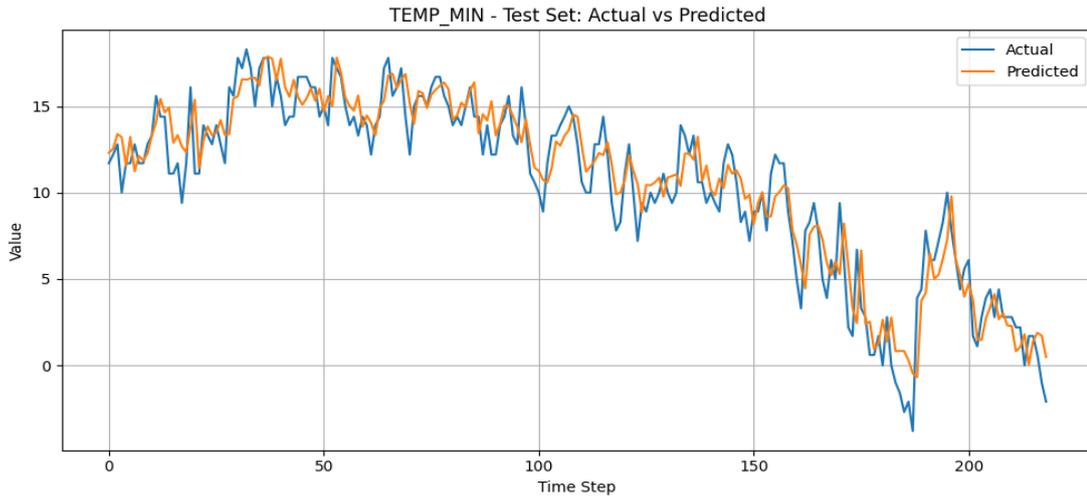
*Gambar 4 Grafik Prediksi Parameter Temperatur Maksimal*

*Tabel 2 Nilai Evaluasi Parameter Temperatur Maksimal*

Evaluator	Nilai
MAE	2.1641
RMSE	2.7208
$R^2$	0.8877

Evaluasi kuantitatif mendukung hal ini, dengan nilai MAE sebesar 2.1641, RMSE sebesar 2.7208, dan nilai  $R^2$  sebesar 0.8877. Nilai  $R^2$  yang tinggi menunjukkan bahwa hampir 89% variabilitas data aktual dapat dijelaskan oleh model. Ini menandakan bahwa suhu maksimum memiliki pola temporal yang stabil dan dapat ditangkap dengan baik oleh arsitektur LSTM.

**3) Prediksi Temperatur Minimal**



*Gambar 5 Grafik Prediksi Parameter Temperatur Minimal*

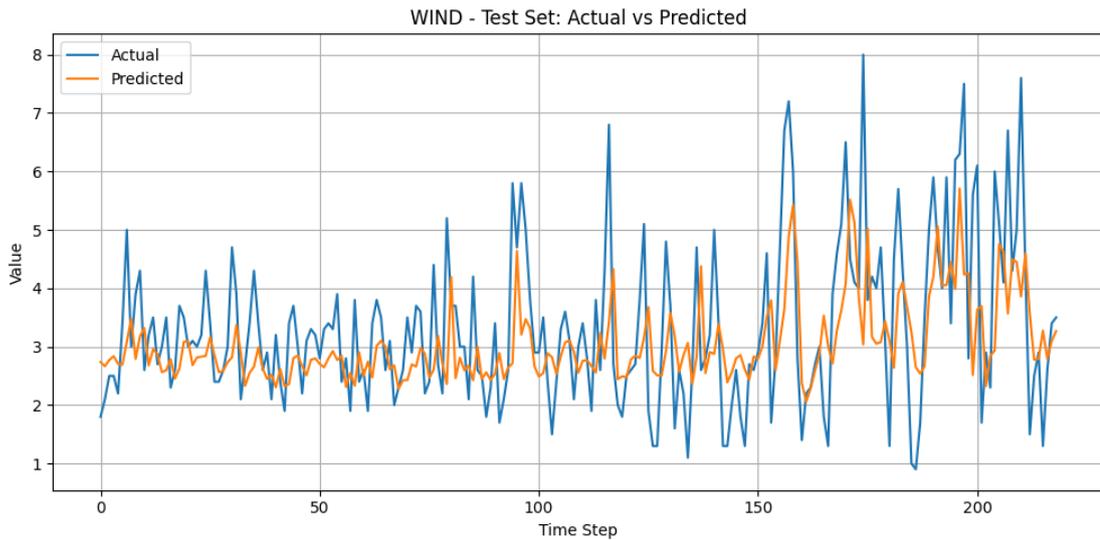
Serupa dengan suhu maksimum, prediksi terhadap suhu minimum juga menunjukkan hasil yang sangat memuaskan. Grafik aktual dan prediksi menunjukkan kemiripan pola yang tinggi, dengan deviasi kecil di beberapa titik.

*Tabel 3 Nilai Evaluasi Parameter Temperatur Minimal*

Evaluator	Nilai
MAE	1.3545
RMSE	1.6821
$R^2$	0.8909

Secara numerik, nilai MAE adalah 1.3545, RMSE 1.6821, dan  $R^2$  sebesar 0.8909. Dengan akurasi yang tinggi ini, dapat disimpulkan bahwa suhu minimum juga merupakan variabel yang dapat diprediksi secara andal dengan LSTM, karena pola musiman dan fluktuasi hariannya cukup teratur.

#### 4) Prediksi Kecepatan Angin



Gambar 6 Grafik Prediksi Parameter Kecepatan Angin

Berbeda dari parameter suhu, prediksi kecepatan angin menunjukkan performa yang kurang optimal. Meskipun kurva prediksi berhasil mengikuti tren umum, namun gagal menangkap variasi tajam dan lonjakan yang sering terjadi pada data aktual.

Tabel 4 Nilai Evaluasi Parameter Kecepatan Angin

Evaluator	Nilai
MAE	0.9065
RMSE	1.2268
$R^2$	0.1842

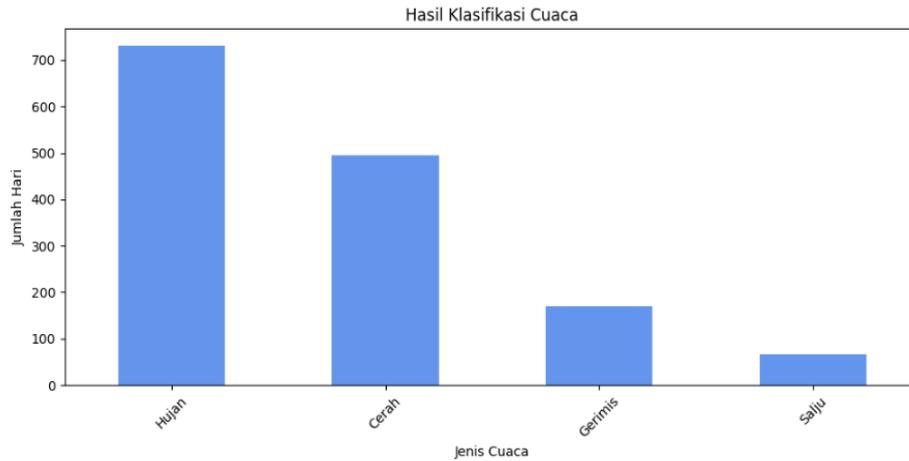
Nilai MAE sebesar 0.9065 dan RMSE sebesar 1.2268 tergolong cukup rendah secara absolut, tetapi nilai  $R^2$  hanya sebesar 0.1842, menandakan bahwa model hanya mampu menjelaskan sekitar 18% dari total variasi dalam data aktual. Rendahnya nilai  $R^2$  ini menunjukkan bahwa kecepatan angin memiliki karakteristik yang lebih acak dan kompleks dibandingkan parameter lainnya, sehingga lebih sulit dipelajari oleh model LSTM tanpa tambahan fitur.

#### F. Klasifikasi Cuaca berdasar Parameter

Dari hasil prediksi pada langkah a, kemudian data dikumpulkan dalam bentuk tabel excel. Nilai-nilai parameter yang digunakan berupa Temp. Max, Temp. Min, Humidity, dan Wind. Parameter tersebut dianalisis menggunakan pemrograman python yang didasarkan pada persamaan berikut :

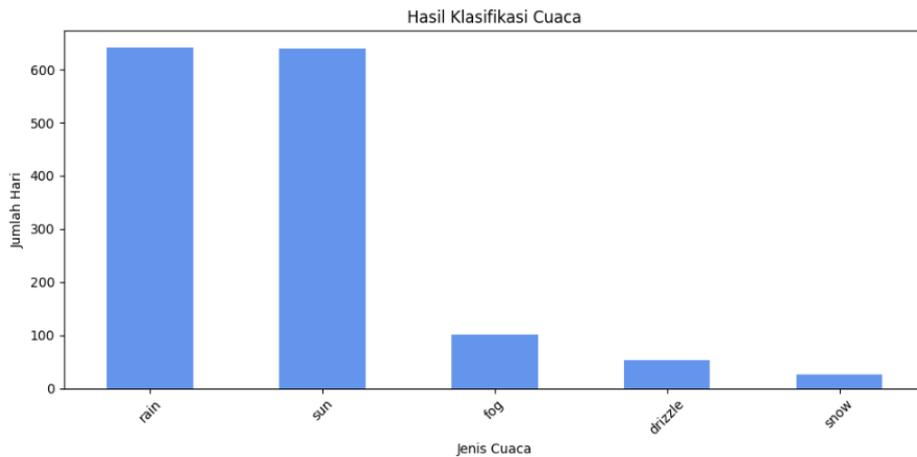
$$Y = AX_1 + BX_2 + CX_3 + DX_4$$

Dimana, nilai A, B, C, dan D adalah parameter hasil prediksi LSTM. Sedangkan,  $X_1$ ,  $X_2$ ,  $X_3$ , dan  $X_4$  adalah bobot. Pembobotan dihitung menggunakan data asli yang sudah memiliki string keterangan cuaca, serta tinjauan literatur. Nilai bobot tersebut berdasar pada parameter yang paling berpengaruh pada cuaca. Berikut merupakan hasil prediksi cuaca:



Gambar 7 Hasil klasifikasi cuaca berdasar parameter prediksi LSTM

Tren hasil klasifikasi cuaca tersebut, tidak jauh berbeda dengan prediksi cuaca asli yaitu sebagai berikut:



Gambar 8 Klasifikasi cuaca aktual

Perbedaan jumlah hasil prediksi dengan data asli bisa jadi dikarenakan adanya bias pada sistem LSTM. Selain itu, klasifikasi yang dilakukan hanya didasarkan pada empat jenis cuaca sehingga berpengaruh pada hasil. Akurasi dapat dihitung dengan membandingkan hasil klasifikasi dengan data yang ada.

$$\begin{aligned} \text{Error} &= \frac{|Data\ aktual - Data\ Prediksi|}{Data\ aktual} \times 100\% \\ \text{Error} &= \frac{|731 - 641| + |494 - 640| + |169 - 53| + |67 - 26|}{1461} \times 100\% \\ \text{Error} &= 26.9\% \\ \text{Accuracy} &= 100\% - 26.9\% \\ &= 73.1\% \end{aligned}$$

Sehingga, dapat dianalisis bahwa klasifikasi cuaca berdasar parameter prediksi pada LSTM mampu memprediksi cuaca dengan baik dengan tingkat akurasi sebesar 73.1%.

## **KESIMPULAN**

Penelitian ini berhasil menunjukkan bahwa penggunaan metode *Deep Learning* jenis *Long Short-Term Memory* (LSTM) dalam prediksi cuaca merupakan langkah yang tepat untuk mendukung mitigasi bencana berbasis data dan teknologi. LSTM dipilih karena kemampuannya dalam mengingat informasi jangka panjang melalui tiga gerbang utama: input gate, forget gate, dan output gate. Pengumpulan data dilakukan melalui *Kaggle*, dengan total 1.462 data. Data ini kemudian diolah menggunakan metode normalisasi *Min-Max Scaling* ke dalam rentang 0–1 untuk memastikan kestabilan proses pelatihan model. Model LSTM yang dirancang terdiri dari tiga lapisan LSTM bertingkat, masing-masing berisi 64 unit memori, diikuti dengan lapisan dense berisi 32 neuron ReLU, dan satu neuron output. Data dibagi ke dalam 70% data latih, 15% data validasi, dan 15% data uji tanpa pengacakan (*non-shuffled*) untuk menjaga kontinuitas temporal. Model dilatih selama 50 epoch dengan ukuran *batch* 32. Hasil pelatihan menunjukkan bahwa model mampu belajar dengan baik dari data tanpa overfitting, sebagaimana terlihat dari grafik konvergensi loss. Setelah diuji terhadap data validasi dan data uji, hasil prediksi menunjukkan tingkat akurasi yang cukup baik dengan akurasi keseluruhan sebesar 73,1%. Ini membuktikan bahwa model LSTM mampu mengenali pola dalam data cuaca dan memberikan hasil

prediksi yang dapat diandalkan.

### **UCAPAN TERIMA KASIH**

Terima kasih kepada semua pihak yang terlibat pada penelitian ini. Terima kasih yang sebesar-besarnya kepada dosen pengampu Mata Kuliah Pengolahan Data Digital Fifin Dewi Ratnasari, S.Si., M.Sc, terima kasih juga kepada owner Burjo Boim Sekaran atas kesempatan untuk melaksanakan diskusi pemecahan masalah dalam melakukan penelitian, serta rekan-rekan sejawat yang telah memberikan dukungan dan sumbangsih tenaga maupun pikiran.

### **REFERENSI**

Abdillah, M. F., & Kusnawi, K. (2023). Comparative Analysis of Long Short-Term Memory Architecture for text Classification. *ILKOM Jurnal Ilmiah*, 15(3), 455–464. <https://doi.org/10.33096/ilkom.v15i3.1906.455-464>

- Cao, J. (2024). Exploring the potential of deep learning models in weather prediction: case studies on sandy weather, wind speed, and rainfall. *Science and Technology of Engineering Chemistry and Environmental Protection*, 1(8). <https://doi.org/10.61173/bxv36n72>
- Harikishan, S., Kumar, G. M., Joseph, F. J. J., & Sathiyarayanan, M. (2023). Weather Prediction on Different LSTM Techniques for Time Series Data in Chennai, India. *Journal Technology*, 1–6. <https://doi.org/10.1109/iccams60113.2023.10525779>
- Lara-Benítez, P., Carranza-García, M., & Riquelme, J. C. (2021). An Experimental Review on Deep Learning Architectures for Time Series Forecasting. *International Journal of Neural Systems*, 31(3), 1–25. <https://doi.org/10.1142/S0129065721300011>
- Makamo, S. (2023). Predicting Style Factor Returns and Group/sector Returns Using Long and Short-term Memory ('LSTM') Deep Learning Neural Networks. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4542403>
- Nawassyarif, M. Julkarnain, & Rizki Ananda, K. (2020). Sistem Informasi Pengolahan Data Ternak Unit Pelaksana Teknis Produksi Dan Kesehatan Hewan Berbasis Web. *Jurnal Informatika, Teknologi Dan Sains*, 2(1), 32–39. <https://doi.org/10.51401/jinteks.v2i1.556>
- Supriyadi, E. (2021). Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (Lstm). *Jurnal Meteorologi Dan Geofisika*, 21(2), 55. <https://doi.org/10.31172/jmg.v21i2.619>
- Putra. (2018). Pengenalan Konsep Pembelajaran Mesin Dan Deep Learning. 1.0. Tokyo: Tokyo Institute of Technology. [https://www.researchgate.net/publication/323700644\\_Pengenalan\\_Pembelajaran\\_Mesin\\_dan\\_Deep\\_Learning](https://www.researchgate.net/publication/323700644_Pengenalan_Pembelajaran_Mesin_dan_Deep_Learning)
- Okut, Hayrettin. (2021). Deep Learning: Long-Short Term Memory. [https://www.researchgate.net/publication/352383391\\_Deep\\_Learning\\_Long-Short\\_Term\\_Memory](https://www.researchgate.net/publication/352383391_Deep_Learning_Long-Short_Term_Memory)
- Susilawati. (2021). Dampak Perubahan Iklim Terhadap Kesehatan. Magister Ilmu Lingkungan Program Pasca Sarjana Universitas Jambi. <https://doi.org/10.22437/esehad.v2i1.13749>
- Riza Pratama. (2019). Efek Rumah Kaca Terhadap Bumi. Mahasiswa Fakultas Teknik, Universitas Islam Sumatera Utara. <https://doi.org/10.30743/but.v14i2.1096>
- Baktiar Leu (2021). DAMPAK PEMANASAN GLOBAL DAN UPAYA PENGENDALIANNYA MELALUI PENDIDIKAN LINGKUNGAN HIDUP DAN PENDIDIKAN ISLAM. <https://journal.staidk.ac.id/index.php/attadbir/issue/view/49>

Wahyudi, M., Afivah, L., Rahmadai, N., Sari, D., Iswardani, F., Sudarti, S., & Mahmudi, K. (2024). Analisis Pengaruh Cuaca terhadap Kualitas Berbagai Jenis Tembakau. *Jurnal Ilmiah Wahana Pendidikan*, 10(11), 448-453. <https://doi.org/10.5281/zenodo.12742154>