

Implementasi Model LSTM, CNN+LSTM Hybrid, dan Transformer untuk Prediksi Cuaca Harian Berbasis Data Multivariat

Heptyana Sri Wulandari, RZ Abdul Aziz*

Megister Teknik Informatika, Institut Informatika dan Bisnis Darmajaya, Lampung, Indonesia

Email : ¹heptyana.2321211034P@mail.darmajaya.ac.id, ^{2,*}rz_aziz@darmajaya.ac.id

Email Penulisan Korespondensi: rz_aziz@darmajaya.ac.id

Submitted: 20/06/2025; Accepted: 01/09/2025; Published: 02/09/2025

Abstrak—Perubahan iklim global dan peningkatan frekuensi kejadian cuaca ekstrem menuntut adanya sistem prediksi cuaca yang lebih akurat dan adaptif. Penelitian ini bertujuan untuk mengimplementasikan dan membandingkan tiga model deep learning, yaitu Long Short-Term Memory (LSTM), Convolutional Neural Network (CNN)+LSTM Hybrid, dan Transformer, dalam memprediksi kejadian cuaca esok hari berbasis data multivariat meteorologi harian. Data yang digunakan diperoleh dari Stasiun Klimatologi Kelas IV Lampung dengan cakupan unsur suhu udara, curah hujan, kelembapan, penyinaran matahari, tekanan udara, arah dan kecepatan angin, yang dikumpulkan dalam format CSV dari Februari 2000 hingga Maret 2025. Hasil analisis menunjukkan bahwa model CNN+LSTM Hybrid menghasilkan performa terbaik dengan nilai RMSE sebesar 1.158, MAE sebesar 0.521, R² Score sebesar 0.323, akurasi 75%, dan skor Macro F1 sebesar 0.75. Model LSTM menunjukkan kinerja cukup baik namun masih di bawah CNN+LSTM Hybrid, sementara model Transformer menunjukkan performa paling rendah di antara ketiga model. Temuan ini mengindikasikan bahwa penggabungan kemampuan ekstraksi fitur spasial dari CNN dan pemrosesan sekuensial dari LSTM mampu meningkatkan kualitas prediksi cuaca jangka pendek berbasis data multivariat. Penelitian ini diharapkan dapat menjadi referensi dalam pengembangan sistem prakiraan cuaca berbasis kecerdasan buatan di Indonesia, khususnya untuk keperluan mitigasi bencana hidrometeorologi.

Kata Kunci: Prediksi Cuaca; Multivariat Meteorologi; LSTM; CNN+LSTM; Transformer; Deep Learning

Abstract—Global climate change and the increasing frequency of extreme weather events demand more accurate and adaptive weather prediction systems. This study aims to implement and compare three deep learning models, Long Short-Term Memory (LSTM), Convolutional Neural Network (CNN)+LSTM Hybrid, and Transformer for predicting next-day weather events using daily multivariate meteorological data. The dataset was obtained from the Climatology Station Class IV Lampung and includes air temperature, rainfall, humidity, solar radiation, air pressure, wind direction, and wind speed, collected in CSV format from February 2000 to March 2025. The analysis results indicate that the CNN+LSTM Hybrid model achieved the best performance, with an RMSE of 1.158, MAE of 0.521, R² Score of 0.323, accuracy of 75%, and Macro F1 score of 0.75. The LSTM model demonstrated moderate performance, while the Transformer model yielded the lowest results among the three. These findings suggest that combining CNN's spatial feature extraction with LSTM's sequential processing enhances the prediction quality of short-term weather forecasts based on multivariate data. This study is expected to contribute to the development of AI-based weather forecasting systems in Indonesia, particularly for hydrometeorological disaster mitigation.

Keywords: Weather Prediction; Multivariate Meteorology; LSTM; CNN+LSTM; Transformer; Deep Learning

1. PENDAHULUAN

Prediksi cuaca merupakan salah satu elemen penting dalam proses mitigasi bencana, perencanaan sektor pertanian, transportasi, serta manajemen sumber daya air. Di Indonesia, yang merupakan negara tropis dengan keragaman topografi dan dinamika atmosfer yang kompleks, perubahan cuaca dapat berlangsung secara cepat dan tidak terduga. Fenomena atmosfer global seperti El Niño–Southern Oscillation (ENSO), Indian Ocean Dipole (IOD), serta dinamika monsun Asia dan Australia turut mempengaruhi variabilitas dan intensitas cuaca harian di berbagai wilayah, termasuk Provinsi Lampung. Provinsi Lampung merupakan salah satu wilayah yang sangat berpengaruh terhadap aktifitas sosial baik darat maupun laut karena letak geografis nya yang menghubungkan dari pulau Jawa dan Sumatera hal inilah yang menjadi latar belakang betapa penting nya informasi cuaca untuk menunjang aktifitas harian.

Seiring berkembangnya teknologi dan ketersediaan data meteorologi multivariat yang semakin lengkap, kebutuhan akan sistem prediksi cuaca yang akurat dan responsif juga meningkat. Model prediksi tradisional berbasis statistik seperti regresi atau ARIMA cenderung memiliki keterbatasan dalam menangkap pola non-linier dan dinamika temporal yang kompleks dalam data cuaca harian. Oleh karena itu, pendekatan berbasis *Deep Learning* mulai banyak digunakan karena mampu menangani ketergantungan jangka panjang (long-term dependencies) dan pola kompleks pada data deret waktu.

Long Short-Term Memory (LSTM) telah terbukti efektif dalam berbagai studi untuk menangani prediksi deret waktu meteorologi seperti curah hujan, suhu, dan kelembapan [1]. Namun, LSTM murni memiliki keterbatasan dalam menangkap informasi spasial, sehingga muncul pendekatan hybrid seperti CNN+LSTM yang menggabungkan kekuatan ekstraksi fitur spasial oleh Convolutional Neural Network (CNN) dengan kemampuan memori jangka panjang dari LSTM [2]. Lebih lanjut, Transformer, yang awalnya dikembangkan untuk pemrosesan bahasa alami, kini mulai dieksplorasi dalam bidang meteorologi karena kemampuannya memproses dependensi jarak jauh secara paralel dan efisien [3].

Dalam beberapa tahun terakhir, penggunaan pendekatan deep learning dalam prediksi cuaca semakin mendapat perhatian karena kemampuannya dalam mengolah data multivariat dan kompleksitas hubungan temporal antar variabel meteorologi. Model CNN+LSTM, misalnya, telah digunakan secara efektif untuk memprediksi suhu dan

curah hujan dengan mempertimbangkan fitur spasial dan temporal secara bersamaan [4]. Sementara itu, Transformer telah menunjukkan performa unggul dalam menangani data urutan panjang tanpa memerlukan pemrosesan sekuensial seperti pada RNN, sehingga mempercepat waktu pelatihan dan memberikan akurasi yang kompetitif dalam berbagai aplikasi cuaca [5],[6]. Selain itu, integrasi data multivariat seperti suhu, kelembapan, tekanan, angin, dan curah hujan dalam satu kerangka prediktif berbasis deep learning terbukti meningkatkan keandalan hasil prediksi jika dibandingkan dengan model prediksi berbasis variabel tunggal [7]. Oleh karena itu, penerapan kombinasi model LSTM, CNN+LSTM, dan Transformer dalam prediksi cuaca harian berbasis data multivariat di wilayah tropis seperti Lampung menjadi sangat relevan dan penting untuk dikaji lebih lanjut.

Dalam beberapa tahun terakhir, model deep learning telah menunjukkan kinerja yang menjanjikan dalam meningkatkan akurasi prediksi cuaca, khususnya melalui pendekatan berbasis data deret waktu. Salah satu arsitektur yang menonjol adalah Long Short-Term Memory (LSTM), yang dirancang untuk mengatasi masalah vanishing gradient dalam model Recurrent Neural Network (RNN) konvensional. Penelitian oleh [8] menunjukkan bahwa model LSTM memiliki performa unggul dalam memprediksi curah hujan harian dan suhu udara dengan akurasi yang lebih tinggi dibandingkan model RNN biasa, terutama ketika diaplikasikan pada data multivariat meteorologi. Selain itu, studi oleh D phan pada tahun 2025 mengkonfirmasi bahwa LSTM mampu mempertahankan informasi historis penting dalam data iklim dan secara signifikan mengurangi error prediksi, terutama pada musim dengan variabilitas tinggi seperti musim peralihan [9]. Keandalan LSTM dalam menangkap pola musiman dan fluktuasi iklim jangka panjang membuatnya relevan dalam studi prediksi cuaca berbasis AI di wilayah tropis dan subtropis.

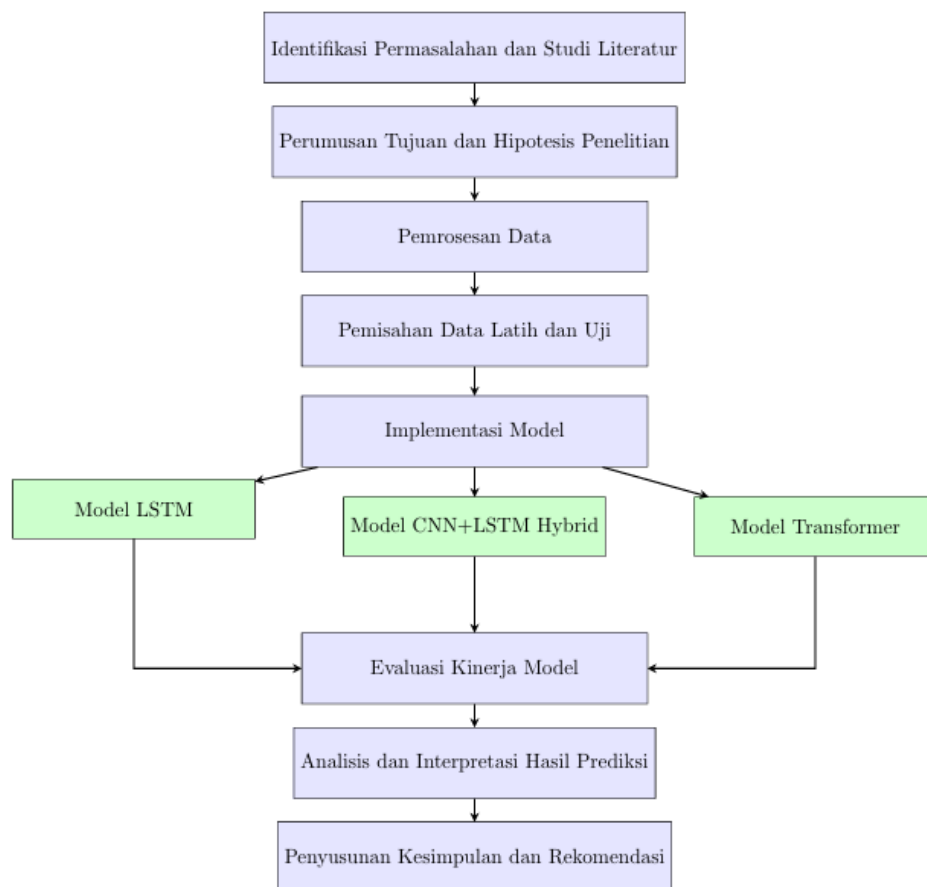
Model hybrid yang menggabungkan Convolutional Neural Network (CNN) dan LSTM juga telah banyak digunakan dalam penelitian terbaru untuk meningkatkan akurasi prediksi cuaca. CNN digunakan untuk mengekstraksi fitur spasial dari input citra atau grid data, sementara LSTM menangani hubungan temporal dalam data sekuensial. Studi yang dilakukan P.shu dkk di tahun 2025 mengembangkan model CNN-LSTM untuk prediksi parameter cuaca harian multivariat, dan hasilnya menunjukkan peningkatan akurasi signifikan dibandingkan model tunggal [10]. CNN-LSTM tidak hanya mampu mendeteksi pola jangka pendek, tetapi juga menyesuaikan diri dengan fluktuasi cuaca harian yang sangat dinamis. Hal ini menjadikan pendekatan hybrid ini relevan untuk diterapkan dalam prediksi kejadian cuaca seperti hujan, angin kencang, dan suhu ekstrem. Transformer, sebagai arsitektur baru yang berbasis mekanisme self-attention, menjadi alternatif yang menjanjikan untuk pemodelan data deret waktu meteorologi. [11] membuktikan bahwa Transformer dapat menghasilkan prediksi suhu dan curah hujan harian dengan akurasi yang kompetitif, sekaligus mempercepat proses pelatihan dibandingkan model sekuensial tradisional. Keunggulan utama Transformer adalah kemampuannya dalam memahami dependensi jangka panjang tanpa proses pelatihan sekuensial, serta fleksibilitasnya dalam menangani data multivariat. Beberapa studi juga mengembangkan variasi model seperti Informer atau Temporal Fusion Transformer (TFT) yang diklaim lebih efisien dan akurat dalam aplikasi prediksi cuaca. Secara umum, literatur menunjukkan bahwa tidak ada satu model yang secara mutlak unggul dalam semua aspek prediksi cuaca. LSTM unggul dalam ketergantungan temporal, CNN-LSTM menguatkan aspek spasial-temporal, dan Transformer menghadirkan efisiensi serta pemahaman global terhadap data deret waktu. Oleh karena itu, penting untuk melakukan kajian komparatif terhadap ketiga pendekatan ini dalam konteks prediksi kejadian cuaca esok hari berbasis data multivariat meteorologi [12], [13]. Transformer digunakan untuk memodelkan hubungan temporal dari data meteorologi multivariat. Misalnya, [14] menunjukkan bahwa penggunaan LSTM yang dikombinasikan dengan fitur eksternal seperti suhu permukaan laut dan tekanan atmosfer memberikan hasil prediksi hujan harian yang lebih akurat dibandingkan metode tradisional. Selain itu, model Transformer terbukti unggul dalam mengelola dependensi data jangka panjang dengan efisiensi komputasi yang lebih baik dibandingkan RNN. Menurut [15], pendekatan hybrid yang menggabungkan LSTM dengan CNN juga mampu meningkatkan akurasi prediksi suhu dan kelembapan harian, terutama dalam kondisi atmosfer yang tidak stabil. Pendekatan ini memberikan arah baru dalam pengembangan sistem prediksi cuaca yang cepat, efisien, dan adaptif terhadap dinamika atmosfer di wilayah tropis seperti Indonesia. Penerapan deep learning dalam prediksi cuaca telah berkembang pesat dengan penggunaan berbagai arsitektur seperti Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM), hingga Transformer. Setiap arsitektur memiliki kekuatan masing-masing: CNN unggul dalam ekstraksi fitur spasial, LSTM unggul dalam menangani data deret waktu, dan Transformer memiliki kemampuan atensi yang kuat untuk menangkap hubungan jangka panjang. Menurut [16], model deep learning yang dikembangkan oleh DeepMind menunjukkan performa yang sangat kompetitif dibandingkan sistem prakiraan numerik konvensional, terutama untuk prediksi hujan jangka pendek berbasis radar. Oleh karena itu, integrasi deep learning dalam sistem prakiraan cuaca modern menjadi pendekatan yang menjanjikan untuk meningkatkan akurasi dan resolusi spasio-temporal prediksi cuaca. Penelitian ini berkontribusi dalam memberikan pemahaman lebih dalam mengenai performa relatif masing-masing model dalam skenario lokal di wilayah tropis seperti Provinsi Lampung, serta mengidentifikasi potensi integrasi atau optimalisasi lanjutan.

Berangkat dari latar belakang tersebut, penelitian ini bertujuan untuk mengimplementasikan dan membandingkan kinerja tiga model *Deep Learning* mutakhir, yaitu LSTM, CNN+LSTM Hybrid, dan Transformer dalam melakukan prediksi kejadian cuaca esok hari berbasis data multivariat meteorologi di Provinsi Lampung. Model akan dilatih menggunakan parameter meteorologi seperti suhu, kelembapan, tekanan udara, arah dan kecepatan angin, serta curah hujan.

2. METODOLOGI PENELITIAN

2.1 Tahap Penelitian

Gambar 1 merupakan tahapan penelitian dengan menggunakan 3 implementasi model yaitu model LSTM, model CNN+LSTM hybrid, dan model Transformer untuk prediksi cuaca di wilayah Lampung. Proses penelitian diawali dengan mengidentifikasi permasalahan yang ingin diselesaikan, melakukan studi literatur untuk memahami konteks permasalahan, menemukan celah penelitian sebelumnya, serta memperoleh landasan teori dan metodologi yang relevan. Setelah memahami permasalahan, peneliti merumuskan tujuan yang ingin dicapai dalam penelitian ini, disertai dengan hipotesis yang dapat diuji. Tahapan ini menjadi dasar untuk menentukan arah dan metode yang akan digunakan. Data meteorologi yang telah dikumpulkan akan diproses agar siap digunakan dalam model, Tahapan ini dapat mencakup pembersihan data, normalisasi, transformasi format, dan penanganan data hilang. Tujuannya adalah untuk meningkatkan kualitas data dan menghindari bias dalam model. Data yang telah diproses kemudian dibagi menjadi dua bagian yaitu data latih (training data) untuk membangun model, dan data uji (testing data) untuk mengukur kinerja model terhadap data yang belum pernah dilihat sebelumnya. Selanjut nya data dapat diimplementasikan untuk melakukan prediksi dengan menggunakan 3 model deep learning, selanjutnya adalah mengevaluasi kinerjanya menggunakan metrik evaluasi yang sesuai, seperti MAE (Mean Absolute Error), RMSE (Root Mean Squared Error), atau akurasi, tergantung pada jenis output yang dihasilkan.



Gambar 1. Tahapan Penelitian

Hasil dari evaluasi model dianalisis secara menyeluruh untuk memahami seberapa baik model melakukan prediksi serta mengidentifikasi kelebihan dan kelemahan masing-masing model yang diuji. rdasarkan seluruh hasil dan analisis, peneliti menyusun kesimpulan yang menjawab tujuan penelitian, serta memberikan rekomendasi untuk penelitian lanjutan atau implementasi nyata dalam bidang meteorologi atau sistem prediksi cuaca.

2.2 Metode Pengumpulan Data

Penelitian ini menggunakan data kuantitatif dalam bentuk data meteorologi multivariat yang terdiri atas berbagai unsur cuaca, seperti suhu udara, kelembapan relatif, tekanan udara, arah dan kecepatan angin, serta curah hujan. Seluruh data tersebut bersifat numerik dan diambil secara sistematis untuk dianalisis menggunakan pendekatan deep learning. Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari arsip laporan bulanan FKLIM (Formulir Klimatologi) yang disusun oleh Stasiun Klimatologi Lampung. FKLIM merupakan produk resmi dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) yang menyajikan rekapitulasi data hasil pengamatan cuaca harian yang dilakukan secara rutin. Pengumpulan data dilakukan berdasarkan hasil observasi unsur-unsur cuaca yang

dicatat setiap jam oleh petugas pengamat di stasiun klimatologi dan pos pengamatan cuaca. Observasi dilakukan sesuai dengan standar operasional prosedur yang telah ditetapkan oleh BMKG, menggunakan instrumen meteorologi terkalibrasi seperti thermometer dry & wet bulb, barometer, anemometer, dan ombrometer.

2.3 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data kuantitatif sekunder yang diperoleh dalam format Comma Separated Values (.csv), dengan struktur yang telah disesuaikan untuk keperluan pengolahan model prediksi berbasis deep learning. Data ini terdiri dari beberapa unsur cuaca utama yang diamati secara harian, yaitu suhu udara, curah hujan, penyinaran matahari, kelembapan udara, tekanan udara, arah angin, dan kecepatan angin dengan jumlah data 165.438 data dimana data penelitian dan pengujian berjumlah 156.247 data dan data target berjumlah 9.191 data. Unsur-unsur tersebut merupakan variabel meteorologi yang saling berkaitan dan sangat penting dalam membentuk dinamika atmosfer harian yang menjadi dasar bagi sistem prediksi cuaca. Cakupan wilayah data berfokus pada Kecamatan Tegineneng, Kabupaten Pesawaran, Provinsi Lampung, yang secara administratif termasuk dalam wilayah pengamatan Stasiun Klimatologi Klas IV Lampung. Wilayah ini dipilih karena merupakan lokasi UPT tempat pengamatan dilakukan secara konsisten, serta mencerminkan karakteristik iklim lokal yang dinamis. Adapun rentang waktu data yang digunakan mencakup periode Februari 2000 hingga Maret 2025, yang memberikan cakupan historis yang cukup panjang untuk melatih dan menguji performa model prediksi. Data yang kaya dan berkelanjutan ini memungkinkan dilakukannya proses analisis prediktif terhadap pola kejadian cuaca esok hari secara akurat dan berkesinambungan.

2.4 Implementasi Model LSTM, CNN+LSTM Hybrid, dan Transformer

Implementasi model prediksi cuaca berbasis deep learning dalam penelitian ini dilakukan melalui platform Google Colab, yang menyediakan infrastruktur cloud computing dengan dukungan GPU sehingga memungkinkan pelatihan model dalam skala besar secara efisien. Dataset unsur cuaca multivariat yang telah dikumpulkan dalam format .csv, mencakup data harian seperti suhu udara, curah hujan, penyinaran matahari, kelembapan, tekanan udara, arah angin, dan kecepatan angin, diunggah ke dalam sesi Google Colab dan digunakan sebagai input bagi ketiga model, yaitu LSTM, CNN+LSTM Hybrid, dan Transformer. Proses dimulai dari tahap pembersihan dan normalisasi data, dilanjutkan dengan pembuatan urutan data (sequence) berdurasi tujuh hari terakhir sebagai basis prediksi cuaca untuk hari berikutnya.

Model LSTM dibangun dengan arsitektur dasar yang mengandalkan kemampuan untuk menangkap dependensi temporal dari data sekuensial. Model ini menggunakan pendekatan oversampling SMOTE untuk menangani ketidakseimbangan kelas, serta class weight untuk memperbaiki bobot pelatihan. LSTM dengan 64 unit digunakan, disertai lapisan dropout untuk mengurangi overfitting. Model kemudian dilatih menggunakan data yang telah diolah dan diuji untuk mengukur akurasi, presisi, dan stabilitas prediksi kejadian cuaca. Hasil pelatihan divisualisasikan dalam bentuk grafik akurasi dan loss, serta dianalisis melalui confusion matrix dan classification report. Long Short-Term Memory (LSTM) adalah arsitektur jaringan saraf tiruan yang dikembangkan untuk mengatasi kelemahan utama dari Recurrent Neural Network (RNN), yaitu permasalahan vanishing dan exploding gradient saat mempelajari hubungan jangka panjang dalam data sekuensial. LSTM menggunakan mekanisme memori internal melalui tiga gerbang utama, forget gate, input gate, dan output gate yang secara dinamis mengontrol aliran informasi untuk disimpan, diperbarui, atau dibuang dari memori jangka panjang. Pendekatan ini membuat LSTM sangat cocok untuk menangani permasalahan prediksi deret waktu yang kompleks, seperti data cuaca harian dan parameter meteorologi multivariat yang dipengaruhi oleh pola musiman dan variabilitas temporal. Menurut [17], LSTM secara konsisten menunjukkan performa yang unggul dalam memprediksi data iklim dan cuaca dibandingkan model tradisional dan beberapa arsitektur deep learning lainnya. Dalam studi terkini, LSTM telah digunakan secara luas untuk memodelkan dan memprediksi berbagai fenomena atmosfer, termasuk curah hujan, suhu, kelembapan, dan kecepatan angin. Salah satu keunggulan LSTM adalah kemampuannya untuk mempertahankan konteks historis data cuaca dan memperhitungkan efek waktu tunda (lag) antarparameter input. Hal ini menjadikannya sangat efektif dalam skenario prediksi cuaca jangka pendek hingga menengah. Penelitian oleh [18] menunjukkan bahwa LSTM mampu memberikan akurasi tinggi dalam prediksi curah hujan harian di India, dengan peningkatan performa signifikan dibandingkan pendekatan berbasis regresi dan metode machine learning konvensional seperti Random Forest dan Support Vector Machine. Dengan performa yang adaptif terhadap fluktuasi data dan kompleksitas temporal, LSTM menjadi fondasi yang kuat dalam pengembangan sistem prakiraan cuaca berbasis kecerdasan buatan.

Rumus LSTM:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \text{ (Forget Gate)} \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \text{ (Input Gate)} \quad (2)$$

$$\hat{C}_t = \tan h(W_C \cdot [h_{t-1}, x_t] + b_C) \text{ (Candidate Cell State)} \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{C}_t \text{ (New Cell State)} \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \text{ (Output State)} \quad (5)$$

$$h_t = o_t \cdot \tan h(C_t) \text{ (Hidden State / Output)} \quad (6)$$

Penjelasan mengenai rumus LSTM di atas dimana dalam arsitektur jaringan saraf konvolusional dan Long Short-Term Memory (LSTM), terdapat sejumlah parameter dan komponen penting yang berperan dalam proses pembelajaran dan prediksi. Parameter W merepresentasikan bobot dari filter konvolusi yang digunakan untuk mengekstraksi fitur spasial dari data input, sedangkan b merupakan bias yang ditambahkan pada hasil konvolusi untuk meningkatkan fleksibilitas model. Pada bagian LSTM, x_t adalah input pada waktu ke- t dan h_{t-1} adalah hidden state dari waktu sebelumnya yang membawa informasi dari langkah sebelumnya. Komponen f_t berfungsi sebagai forget gate yang menentukan seberapa banyak informasi dari cell state sebelumnya (C_{t-1}) yang harus dilupakan, sedangkan i_t adalah input gate yang mengatur informasi baru yang akan dimasukkan ke dalam cell state. Kandidat nilai baru yang diusulkan untuk ditambahkan ke cell state dilambangkan dengan \hat{C}_t , yang kemudian digabungkan melalui mekanisme gating untuk memperbarui nilai cell state saat ini (C_t). Kombinasi komponen-komponen ini memungkinkan LSTM untuk mempertahankan informasi yang relevan dalam jangka waktu panjang dan mengabaikan informasi yang tidak diperlukan, sehingga sangat efektif dalam memproses data deret waktu seperti data cuaca multivariat.

Model CNN+LSTM Hybrid dirancang untuk menggabungkan kekuatan konvolusi spasial dalam CNN dengan kemampuan deteksi pola temporal LSTM. CNN pertama kali digunakan untuk mengekstraksi fitur lokal dari data urut waktu, dilanjutkan dengan Bidirectional LSTM guna menangkap pola cuaca dari dua arah waktu (past dan future context). Proses pelatihan melibatkan dua blok konvolusi, pooling, dan batch normalization, serta dilakukan oversampling menggunakan SMOTE untuk mengatasi ketidakseimbangan. Evaluasi model dilakukan terhadap data uji dan disajikan dalam bentuk metrik klasifikasi dan grafik performa pelatihan. Hybrid model yang menggabungkan Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM) telah menjadi pendekatan populer dalam prediksi cuaca karena keunggulannya dalam menangani data spasial-temporal secara simultan. CNN memiliki kemampuan dalam mengekstraksi fitur spasial dari data masukan seperti citra satelit atau peta parameter meteorologi, sementara LSTM unggul dalam menangkap pola temporal jangka panjang dari data deret waktu. Kombinasi keduanya menciptakan sistem prediksi yang lebih komprehensif dalam mengenali pola kompleks pada data cuaca. Dalam penelitian yang dilakukan oleh [19], [20], model CNN-LSTM berhasil meningkatkan akurasi prediksi suhu permukaan dan curah hujan dengan menggabungkan representasi spasial dan temporal, mengungguli model konvensional dan deep learning tunggal seperti standalone CNN atau LSTM. Studi lain oleh [21] menunjukkan bahwa model hybrid CNN-LSTM juga efektif dalam prediksi presipitasi berbasis data radar dan numerik, terutama dalam menangani variabilitas spasial dari awan konvektif dan pola hujan ekstrem. Model ini mampu mengurangi Root Mean Square Error (RMSE) dan meningkatkan koefisien determinasi (R^2) secara signifikan dibanding model tunggal. Integrasi CNN dalam tahap awal arsitektur memungkinkan pemodelan struktur spasial dari atmosfer, sedangkan LSTM melanjutkan analisis untuk memprediksi evolusi temporal dari sistem cuaca. Oleh karena itu, arsitektur hybrid CNN-LSTM sangat potensial digunakan dalam prakiraan cuaca harian berbasis data multivariat meteorologi, khususnya di wilayah tropis dengan dinamika atmosfer yang sangat fluktuatif seperti Indonesia.

Rumus CNN Block:

$$Z = ReLU(W \cdot X + b) \quad (7)$$

$$Z_{pooled} = max(Z_{kernel}) \quad (8)$$

Persamaan (7) input data X diproses melalui operasi konvolusi menggunakan bobot filter W dan bias, menghasilkan output aktivasi. Fungsi aktivasi ReLU (Rectified Linear Unit) diterapkan untuk memperkenalkan non-linearitas, di mana nilai negatif akan diubah menjadi nol, dan nilai positif tetap dipertahankan. Hasilnya adalah fitur teraktivasi Z . Selanjutnya, untuk persamaan (8) max pooling diterapkan pada hasil aktivasi Z . Pooling bertujuan untuk mereduksi dimensi spasial (mengurangi jumlah parameter dan komputasi) sambil mempertahankan fitur penting. Operasi ini memilih nilai maksimum dari setiap area kecil (kernel) dari fitur peta.

Rumus LSTM:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \text{ (Forget Gate)} \quad (9)$$

Gate ini menentukan informasi apa dari cell state sebelumnya (C_{t-1}) yang perlu dilupakan. Input berupa gabungan dari state tersembunyi sebelumnya h_{t-1} dan input saat ini x_t . Fungsi aktivasi sigmoid σ membatasi output antara 0 dan 1.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \text{ (Input Gate)} \quad (10)$$

Gate ini mengontrol berapa banyak informasi baru yang akan ditambahkan ke cell state. Lagi-lagi, masukan gabungan dari h_{t-1} dan x_t diproses oleh fungsi sigmoid.

$$\hat{C}_t = \tan h(W_c \cdot [h_{t-1}, x_t] + b_c) \text{ (Candidate Cell State)} \quad (11)$$

Ini adalah kandidat nilai baru untuk ditambahkan ke memori internal (cell state). Fungsi aktivasi tanh menghasilkan output antara -1 dan 1, memungkinkan penyimpanan nilai positif dan negatif.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{C}_t \text{ (New Cell State)} \quad (12)$$

Cell state diperbarui dengan menggabungkan memori lama yang telah "difilter" oleh forget gate, dan memori baru yang dikontrol oleh input gate. Ini menjaga informasi penting dari masa lalu sambil menerima informasi baru.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \text{ (Output State)} \quad (13)$$

Output gate menentukan bagian dari cell state yang akan digunakan untuk menghitung output (state tersembunyi) saat ini. Kombinasi h_{t-1} dan x_t kembali diproses melalui fungsi sigmoid.

$$h_t = o_t \cdot \tanh(C_t) \text{ (Hidden State / Output)} \quad (14)$$

Hidden state atau output saat ini h_t dihasilkan dengan mengalikan output gate O_t dengan cell state C_t yang telah distandarisasi oleh fungsi tanh. Nilai ini kemudian digunakan baik sebagai output jaringan maupun sebagai masukan ke langkah waktu berikutnya. Setelah melewati CNN, hasil dikirim ke LSTM dan diproses sesuai mekanisme LSTM. Output akhirnya menggunakan softmax:

$$\bar{y} = \text{softmax}(W_h \cdot h + b_h) \quad (15)$$

Persamaan ini merupakan tahap akhir dari model, di mana \bar{y} adalah vektor probabilitas dari setiap kelas prediksi (misalnya: cerah, hujan, berawan). Fungsi softmax mengubah hasil linier ini menjadi probabilitas, yaitu nilai antara 0 dan 1 yang jumlah totalnya adalah 1, sehingga bisa diinterpretasikan sebagai prediksi untuk setiap kelas. Dengan kata lain, fungsi ini mengonversi output model menjadi prediksi kelas akhir berdasarkan distribusi probabilitas.

Adapun model Transformer, yang merupakan pendekatan paling mutakhir, menggunakan arsitektur attention-based yang tidak bergantung pada urutan data secara eksplisit. Model ini dibangun dengan positional encoding untuk menginformasikan urutan temporal data, dua blok Multi-Head Self Attention, dan jaringan feed-forward untuk pemrosesan fitur. Training dilakukan selama 20 epoch dengan menggunakan optimisasi Adam dan fungsi loss categorical crossentropy. Model ini juga dievaluasi dengan confusion matrix dan classification report, serta divisualisasikan performanya menggunakan kurva akurasi dan loss. Melalui penerapan tiga pendekatan ini, penelitian ini bertujuan untuk membandingkan efektivitas model dalam memprediksi cuaca esok hari berbasis data multivariat meteorologi secara komprehensif. Model Transformer merupakan arsitektur deep learning yang awalnya dikembangkan untuk pemrosesan bahasa alami, namun belakangan ini juga menunjukkan kinerja yang menjanjikan dalam pemodelan data deret waktu, termasuk prediksi cuaca. Keunggulan utama Transformer terletak pada mekanisme *self-attention*, yang memungkinkan model untuk mengidentifikasi dependensi jangka panjang antar waktu secara paralel, tanpa menggunakan pendekatan sekuensial seperti pada RNN dan LSTM. Dalam konteks meteorologi, kemampuan ini sangat penting karena peristiwa cuaca sering dipengaruhi oleh kondisi yang tersebar dalam waktu dan ruang. [22] mengembangkan model Informer (Improved Transformer for Long Sequence Forecasting) yang mampu menangani prediksi cuaca jangka panjang dengan efisiensi komputasi yang lebih baik, menunjukkan performa unggul dibandingkan arsitektur LSTM dalam berbagai eksperimen deret waktu. Dalam aplikasi konkret prediksi cuaca, Transformer telah digunakan untuk memodelkan hubungan kompleks antar variabel meteorologi seperti suhu, kelembapan, tekanan udara, dan angin. Penelitian oleh [23], [24] menunjukkan bahwa model Transformer dengan konfigurasi multi-head attention dan positional encoding berhasil meningkatkan akurasi prediksi suhu permukaan harian dan kejadian ekstrem dibanding model LSTM tradisional. Selain itu, arsitektur Transformer lebih fleksibel untuk diintegrasikan dengan sumber data heterogen seperti data pengamatan, output model numerik, serta citra satelit. Hal ini menjadikan Transformer sebagai pendekatan yang sangat potensial untuk pengembangan sistem prakiraan cuaca esok hari berbasis data multivariat, khususnya dalam skenario data besar (*big data*) meteorologi. Arsitektur Transformer memanfaatkan mekanisme Self-Attention dan Positional Encoding tanpa menggunakan RNN. Positional Encoding:

$$PE_{(pos,2i)} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (16)$$

$$PE_{(pos,2i)} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (17)$$

Positional Encoding (PE) digunakan dalam model Transformer untuk memberikan informasi posisi urutan input, karena tidak seperti RNN, Transformer tidak memproses data secara sekuensial. Fungsi sinus digunakan untuk dimensi genap, dan cosinus untuk dimensi ganjil. Kombinasi ini menciptakan pola unik pada setiap posisi dan memungkinkan model menangkap hubungan posisi relatif antar elemen dalam sekuens, tanpa perlu pembelajaran posisi secara eksplisit. Positional Encoding menambahkan "rasa urutan" ke dalam data sehingga Transformer bisa memahami struktur data berurutan seperti teks atau deret waktu.

Scaled Dot-Product Attention:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (18)$$

Mekanisme self-attention, yang memungkinkan model Transformer untuk memperhatikan bagian penting dari input saat memproses setiap elemen dalam sekuens. Perkalian $\left(\frac{QK^T}{\sqrt{dk}}\right)$ menghasilkan skor kedekatan atau relevansi antara elemen query dengan seluruh key dalam sekuens, hasil skor dibagi untuk mencegah nilai besar yang dapat membuat softmax terlalu tajam (overconfidence) kemudian fungsi softmax mengubah skor menjadi bobot probabilitas, bobot ini dikalikan dengan V , menghasilkan representasi akhir yang menekankan bagian penting dari input.

Output Layer:

$$\bar{y} = \text{softmax}(W_0 \cdot \text{GlobalAveragePolling}(X) \cdot b) \quad (19)$$

Persamaan ini merupakan tahap akhir dalam model deep learning, Global average pooling menyaring fitur utama dari seluruh peta fitur, lalu dikalikan bobot dan ditambahkan bias. Fungsi softmax kemudian menghasilkan vektor \bar{y} , yang menunjukkan probabilitas dari setiap kelas prediksi (misalnya: hujan, cerah, mendung).

2.5 Metode Evaluasi Model

Evaluasi model merupakan tahap penting dalam proses implementasi machine learning atau deep learning untuk memastikan bahwa model tidak hanya mampu belajar dari data pelatihan, tetapi juga dapat melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya. Dalam penelitian ini, kinerja model Long Short-Term Memory (LSTM), CNN+LSTM Hybrid, dan Transformer dalam memprediksi kejadian cuaca esok hari dievaluasi menggunakan lima metrik utama, yaitu Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Coefficient of Determination (R^2 Score), Accuracy, dan Macro F1-Score. Pemilihan kelima metrik ini dilakukan untuk memberikan gambaran yang menyeluruh tentang performa model dari sisi regresi maupun klasifikasi.

RMSE digunakan untuk mengukur seberapa besar rata-rata galat kuadrat antara nilai prediksi dan nilai aktual dalam skala asli data. Semakin kecil nilai RMSE, semakin baik performa model dalam memprediksi nilai yang mendekati data aktual. MAE menghitung rata-rata dari selisih absolut antara prediksi dan observasi tanpa memberikan bobot lebih besar pada kesalahan besar, sehingga metrik ini cenderung lebih stabil terhadap outlier. Sementara itu, R^2 Score mengukur proporsi variansi data yang dapat dijelaskan oleh model. Nilai R^2 yang mendekati 1 menandakan model mampu menjelaskan variasi data dengan sangat baik, sedangkan nilai mendekati 0 mengindikasikan bahwa model tidak mampu menjelaskan variasi secara signifikan.

Selain evaluasi berbasis regresi, penelitian ini juga menerapkan evaluasi berbasis klasifikasi untuk menilai seberapa akurat model dalam mengklasifikasikan kategori cuaca esok hari. Accuracy digunakan untuk mengukur persentase prediksi yang benar terhadap keseluruhan data uji. Namun, dalam kasus data yang tidak seimbang antar kelas, akurasi saja seringkali tidak cukup. Oleh karena itu, Macro F1-Score digunakan sebagai metrik tambahan untuk mengevaluasi keseimbangan antara presisi dan recall dari masing-masing kelas, dengan memberikan bobot yang sama pada semua kelas. F1-Score yang tinggi mengindikasikan bahwa model tidak hanya akurat, tetapi juga andal dalam mendeteksi semua kategori cuaca secara konsisten. Kombinasi dari metrik regresi dan klasifikasi ini diharapkan mampu memberikan penilaian yang lebih holistik terhadap performa prediktif masing-masing model.

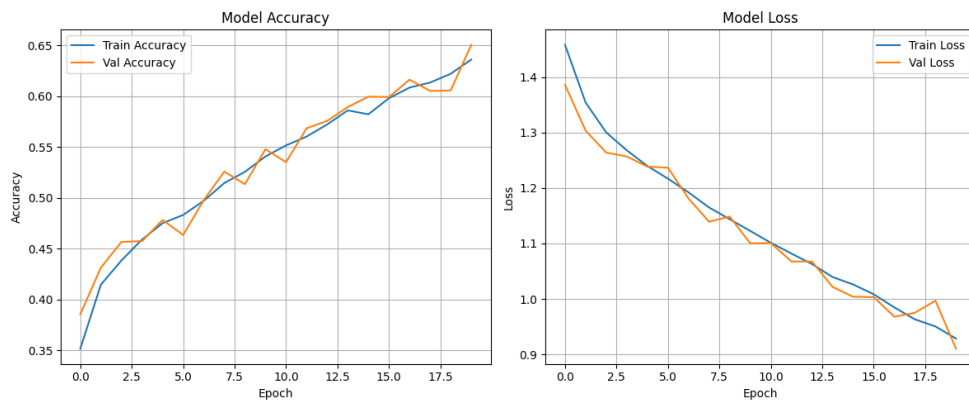
3. HASIL DAN PEMBAHASAN

3.1 Model Prediksi LSTM

Model Long Short-Term Memory (LSTM) dalam penelitian ini dibangun untuk melakukan klasifikasi kejadian cuaca esok hari berdasarkan data multivariat meteorologi harian. Data yang digunakan pada Gambar 2 telah diproses terlebih dahulu menjadi sekuens berdurasi 7 hari sebagai masukan model, yang bertujuan menangkap dinamika temporal jangka pendek dari fenomena cuaca. Untuk menangani permasalahan ketidakseimbangan kelas dalam data target, metode SMOTE (Synthetic Minority Over-sampling Technique) digunakan untuk melakukan oversampling data minoritas, sehingga distribusi target menjadi lebih seimbang. Proses oversampling dilakukan setelah meratakan (flatten) data sekuens 3D menjadi 2D, kemudian dikembalikan lagi ke bentuk sekuensial 3D untuk pelatihan model. Selain itu, class weight juga dihitung dan digunakan dalam proses pelatihan guna memperkuat kontribusi dari kelas yang kurang representatif.

Struktur arsitektur LSTM yang digunakan terdiri atas satu layer LSTM dengan 64 unit sel, diikuti oleh dropout sebesar 30% untuk mencegah overfitting, serta dua layer dense sebagai lapisan klasifikasi akhir. Aktivasi softmax digunakan pada layer output untuk mengklasifikasikan input ke dalam beberapa kelas kejadian cuaca. Model dikompilasi menggunakan fungsi loss categorical_crossentropy dan dioptimasi dengan algoritma Adam, dengan metrik evaluasi utama berupa akurasi. Proses pelatihan dilakukan selama 20 epoch dengan batch size 32, menggunakan 20% data pelatihan sebagai data validasi. Gambar 1 menunjukkan hasil penelitian bahwa tren akurasi model terus meningkat baik pada data latih maupun validasi, dengan penurunan nilai loss yang konsisten pada kedua subset data. Hal ini mengindikasikan bahwa model mampu belajar secara progresif dan stabil terhadap pola cuaca yang disajikan selama proses pelatihan. Secara keseluruhan, implementasi model LSTM ini menunjukkan performa pembelajaran yang baik dari sisi stabilitas dan konsistensi akurasi. Proses pengolahan data yang melibatkan pendekatan time series windowing, teknik penyeimbangan kelas, serta regularisasi melalui dropout menjadi

komponen penting dalam meningkatkan kualitas generalisasi model. Langkah-langkah ini juga mendukung kemampuan LSTM dalam menangani kompleksitas data meteorologi yang bersifat nonlinier dan berskala waktu. Analisis kuantitatif hasil prediksi model ini akan dibahas lebih lanjut pada bagian evaluasi model di subbab berikutnya.

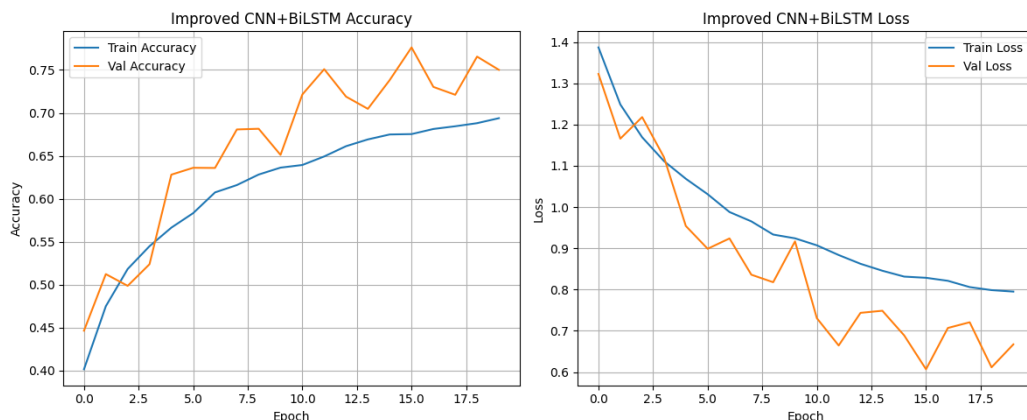


Gambar 2. Model Accuracy & Model Loss Model LSTM

3.2 Model Prediksi CNN+LSTM Hybrid

Model CNN+LSTM Hybrid yang digunakan dalam penelitian ini merupakan gabungan antara kemampuan ekstraksi fitur spasial dari Convolutional Neural Network (CNN) dan pemahaman temporal dari Long Short-Term Memory (LSTM). Data yang digunakan pada Gambar 3 merupakan sekuens cuaca multivariat selama 7 hari berturut-turut, yang kemudian dibentuk ke dalam format 3 dimensi (samples, timesteps, features). Mengingat kemungkinan ketidakseimbangan distribusi kelas pada target prediksi, dilakukan proses oversampling dengan teknik SMOTE. Proses ini diterapkan pada data pelatihan setelah direduksi ke dalam bentuk dua dimensi, dan kemudian dikembalikan ke bentuk 3 dimensi agar kompatibel dengan input jaringan CNN+LSTM. Struktur arsitektur hybrid yang dibangun terdiri dari dua blok Conv1D sebagai lapisan awal. Blok pertama menggunakan 64 filter dan blok kedua menggunakan 128 filter, masing-masing dengan aktivasi ReLU, batch normalization, dan dropout 30% untuk regularisasi. MaxPooling digunakan untuk menurunkan dimensi spasial dan menyoroti fitur dominan. Setelah lapisan konvolusional, data dilanjutkan ke lapisan Bidirectional LSTM berjumlah 64 unit dengan return_sequences=True, yang memungkinkan model memahami urutan dari dua arah (forward dan backward). Output dari LSTM diringkas menggunakan GlobalAveragePooling1D, yang bertugas merata-ratakan seluruh fitur dari waktu ke waktu, sehingga menghasilkan representasi ringkas yang tetap mempertahankan esensi temporal data.

Model ini disusun menggunakan framework TensorFlow Keras dan dikompilasi dengan fungsi loss categorical_crossentropy serta optimizer adam. Proses pelatihan dilakukan selama 20 epoch dengan batch size 32, menggunakan 20% data sebagai data validasi. Grafik hasil pelatihan pada Gambar 3 menunjukkan tren peningkatan akurasi dan penurunan loss pada data pelatihan dan validasi, yang menjadi indikasi awal bahwa model mampu mempelajari pola cuaca dengan baik dan memiliki kecenderungan generalisasi yang stabil. Analisis performa kuantitatif lebih rinci terkait model ini akan dibahas pada bagian evaluasi model. Kombinasi CNN dan LSTM ini menawarkan keunggulan struktural dalam menangani data meteorologi yang bersifat multivariat dan sekuensial. CNN berperan penting dalam mendeteksi pola-pola lokal dari berbagai parameter cuaca seperti suhu, kelembapan, dan tekanan, sementara LSTM mampu memproses evolusi pola-pola tersebut dari waktu ke waktu. Dengan integrasi dua pendekatan ini, model memiliki potensi lebih besar dalam mengenali transisi cuaca yang kompleks dan menghasilkan prediksi yang lebih adaptif terhadap dinamika atmosfer.




Gambar 3. Model Accuracy & Model Loss Model CNN+LSTM Hybrid

3.3 Model Prediksi Transformer

Model Transformer yang digunakan dalam penelitian ini dirancang untuk menangkap kompleksitas data meteorologi harian berbasis multivariat dengan pendekatan attention mechanism. Berbeda dengan arsitektur berurutan seperti LSTM atau CNN+LSTM hybrid, model Transformer memanfaatkan kemampuan self-attention untuk memahami hubungan antar fitur dan antar waktu secara lebih fleksibel dan paralel. Arsitektur ini sangat ideal untuk mengelola dinamika data cuaca yang memiliki ketergantungan lintas waktu dan lintas variabel, seperti suhu, kelembapan, tekanan udara, dan kecepatan angin, dalam satu bingkai pemrosesan yang utuh. Langkah awal dalam pengembangan model adalah penerapan positional encoding, yang bertujuan untuk menambahkan informasi urutan waktu ke dalam input karena Transformer sendiri tidak memiliki struktur berurutan secara eksplisit. Positional encoding ini diberikan dalam bentuk vektor sinusoidal yang digabungkan langsung dengan input data. Setelah itu, input diproses melalui dua lapisan transformer block, masing-masing terdiri dari multi-head self-attention, layer normalization, dan feed-forward network. Setiap blok ini membantu dalam mengidentifikasi kontribusi masing-masing elemen dalam deret waktu terhadap target prediksi, tanpa harus mengikuti urutan tetap seperti RNN.

Setelah melalui proses atensi, output dari blok transformer diringkas menggunakan GlobalAveragePooling1D, yang bertugas menyatukan informasi representasi dari seluruh urutan waktu. Tahap ini diikuti oleh dense layer untuk ekstraksi fitur nonlinier dan diakhiri dengan softmax sebagai layer output yang mengklasifikasikan cuaca esok hari ke dalam kelas-kelas prediktif. Proses pelatihan dilakukan selama 20 epoch dengan optimasi adam, dan penanganan ketidakseimbangan kelas diperkuat dengan pemberian class_weight saat training. Grafik hasil pelatihan yang ditampilkan pada Gambar 4 menunjukkan tren pembelajaran yang cukup stabil baik pada akurasi maupun nilai loss. Secara keseluruhan, arsitektur Transformer pada penelitian ini dirancang untuk menyempurnakan proses prediksi cuaca berbasis deret waktu dengan meningkatkan efisiensi pemrosesan dan menangkap ketergantungan temporal yang tersebar, yang mungkin tidak ditangkap optimal oleh model sekuensial tradisional. Meskipun memerlukan sumber daya komputasi yang relatif tinggi, pendekatan ini menunjukkan potensi signifikan dalam menginterpretasikan dinamika atmosfer yang kompleks, terutama saat variabel masukan bersifat heterogen dan volume data cukup besar. Evaluasi performa model ini secara kuantitatif akan dibahas secara terpisah pada bagian evaluasi model.



Gambar 4. Model Accuracy & Model Loss Model Transformer

3.4 Evaluasi Model

Evaluasi performa dalam Tabel 1 dari ketiga model yang digunakan dalam penelitian ini yaitu LSTM, CNN+LSTM Hybrid, dan Transformer, menunjukkan variasi tingkat akurasi dalam memprediksi kejadian cuaca esok hari berbasis data multivariat meteorologi. Berdasarkan metrik Root Mean Squared Error (RMSE), model CNN+LSTM Hybrid mencatatkan nilai terendah sebesar 1.158, yang menunjukkan bahwa model ini memiliki kesalahan prediksi rata-rata yang paling kecil dibandingkan LSTM (1.198) dan Transformer (1.243). Nilai RMSE yang rendah pada CNN+LSTM Hybrid mengindikasikan bahwa model ini lebih konsisten dalam meminimalisasi kesalahan besar, sebuah karakteristik yang sangat penting dalam sistem prediksi yang sensitif terhadap outlier seperti cuaca ekstrem. Dari sisi Mean Absolute Error (MAE), yang mengukur rata-rata selisih absolut antara nilai aktual dan prediksi tanpa memperhitungkan arah kesalahan, CNN+LSTM Hybrid juga kembali menunjukkan performa terbaik dengan nilai 0.521. Ini berarti model hybrid ini menghasilkan deviasi yang lebih kecil dan stabil dalam skenario prediksi harian. Model LSTM memperoleh nilai MAE sebesar 0.62, sementara Transformer mendapatkan nilai tertinggi yaitu 0.656, yang menunjukkan bahwa Transformer cenderung menghasilkan prediksi yang lebih menyimpang secara absolut dari nilai aktual. Hasil ini dapat dikaitkan dengan kecenderungan model Transformer yang membutuhkan data latih dalam jumlah besar dan struktur sekuensial yang kompleks untuk mencapai konvergensi optimal.

Metrik R^2 Score atau koefisien determinasi memberikan gambaran tentang seberapa besar proporsi variansi target yang dapat dijelaskan oleh model. CNN+LSTM Hybrid menunjukkan nilai tertinggi sebesar 0.323, diikuti oleh LSTM (0.276) dan Transformer (0.22). Dengan nilai R^2 yang lebih tinggi, CNN+LSTM Hybrid dinilai memiliki kemampuan yang lebih baik dalam menjelaskan variabilitas data cuaca multivariat. Hal ini mengindikasikan bahwa kombinasi antara ekstraksi fitur spasial dari CNN dan kemampuan sekuensial LSTM berhasil menangkap pola

temporal dan spasial dengan lebih efektif. Secara keseluruhan, CNN+LSTM Hybrid terbukti sebagai model yang paling unggul dalam penelitian ini berdasarkan semua indikator evaluasi utama. Meskipun model LSTM memiliki performa yang cukup baik dan relatif stabil, model Transformer masih menunjukkan performa yang kurang optimal pada data ini, kemungkinan disebabkan oleh keterbatasan volume data, tingginya kompleksitas model, dan kebutuhan akan tuning yang lebih mendalam. Oleh karena itu, CNN+LSTM Hybrid dapat direkomendasikan sebagai arsitektur yang paling andal untuk diterapkan dalam sistem prediksi cuaca esok hari di wilayah dengan data multivariat meteorologi terbatas namun kompleks seperti di Provinsi Lampung.

Tabel 1. Hasil Evaluasi Model

Model	RMSE	MAE	R ² Score
LSTM	1.198	0.62	0.276
CNN+LSTM Hybrid	1.158	0.521	0.323
Transformer	1.243	0.656	0.22

Hasil evaluasi berdasarkan akurasi yang terdapat pada Tabel 1 menunjukkan bahwa model CNN+LSTM Hybrid memberikan performa paling tinggi dengan tingkat akurasi sebesar 75%, disusul oleh model LSTM dan Transformer yang masing-masing memperoleh akurasi sebesar 66%. Nilai akurasi yang tinggi pada CNN+LSTM Hybrid mengindikasikan bahwa proporsi prediksi yang tepat terhadap total prediksi sangat baik, mencerminkan kemampuannya dalam menangani kompleksitas pola data multivariat cuaca harian dengan lebih akurat dibandingkan dua model lainnya. Hal ini juga memperkuat hasil sebelumnya pada metrik error (RMSE dan MAE), di mana CNN+LSTM Hybrid juga menunjukkan nilai terendah.

Selain akurasi, evaluasi menggunakan Macro F1-score memberikan gambaran lebih seimbang terhadap kinerja model pada masing-masing kelas cuaca, tanpa bias terhadap frekuensi kelas. CNN+LSTM Hybrid mencatat nilai Macro F1 tertinggi sebesar 0.75, menunjukkan bahwa model ini tidak hanya akurat secara keseluruhan, tetapi juga memiliki kemampuan yang merata dalam memprediksi semua kategori cuaca. Sebaliknya, LSTM memperoleh skor 0.65 dan Transformer 0.64, yang berarti performa keduanya masih kurang optimal terutama dalam klasifikasi kategori cuaca minoritas yang mungkin lebih jarang muncul dalam data pelatihan.

Berdasarkan kombinasi seluruh metrik evaluasi yang telah dianalisis yakni RMSE, MAE, R² Score, Accuracy, dan Macro F1, dapat disimpulkan bahwa model CNN+LSTM Hybrid merupakan model terbaik dalam penelitian ini. Model ini menunjukkan performa superior dalam semua aspek evaluasi, baik dalam meminimalkan kesalahan prediksi maupun dalam mempertahankan akurasi dan kesetaraan klasifikasi antar kelas. Oleh karena itu, CNN+LSTM Hybrid sangat direkomendasikan untuk digunakan sebagai pendekatan utama dalam pengembangan sistem prediksi kejadian cuaca esok hari berbasis data multivariat meteorologi di wilayah studi ini.

Tabel 2. Hasil Akurasi Model

Model	Accuracy	Macro F1
LSTM	66%	0.65
CNN+LSTM Hybrid	75%	0.75
Transformer	66%	0.64

Berdasarkan Tabel 2 hasil akurasi model terbaik dalam penelitian ini terdapat bahwa prediksi yang menggunakan data baru dengan model CNN+LSTM Hybrid yang telah teridentifikasi sebagai model terbaik. dalam penelitian ini, maka sesuai dengan Tabel 3 terlampir di bawah diperoleh pola bahwa mayoritas prediksi cuaca diklasifikasikan ke dalam kelas 0, yaitu kategori “Cerah Berawan - Berawan”. Dari total 23 data uji, hanya terdapat dua data yang diprediksi berbeda dari kelas mayoritas, yaitu satu kasus diprediksi sebagai kelas 2 (“Berpotensi Hujan”) dan sisanya menunjukkan prediksi stagnan pada kelas 0. Padahal, pada kolom Target, variasi kejadian cuaca cukup beragam, termasuk keberadaan kelas 2, 3, dan bahkan 4 (“Berpotensi Hujan Sedang - Lebat Disertai Petir dan Angin Kencang”), yang tidak berhasil dikenali dengan baik oleh model.

Fenomena ini menunjukkan bahwa meskipun CNN+LSTM Hybrid unggul secara statistik dalam evaluasi umum dengan nilai RMSE sebesar 1.158, MAE sebesar 0.521, R² sebesar 0.323, serta akurasi dan macro F1 score tertinggi di antara semua model, generalisasi model terhadap data baru belum sepenuhnya optimal. Model tampak mengalami kecenderungan bias terhadap kelas mayoritas, yang kemungkinan besar disebabkan oleh distribusi data pelatihan yang tidak seimbang meski telah dilakukan oversampling menggunakan SMOTE. Ketidaksesuaian antara nilai target aktual dan hasil prediksi menandakan bahwa model masih memerlukan penyempurnaan, seperti tuning hyperparameter, penyesuaian threshold probabilitas prediksi, atau pendekatan ensemble dan fine-tuning ulang terhadap representasi fitur yang lebih mendalam. Dengan demikian, meskipun CNN+LSTM menunjukkan performa terbaik secara kuantitatif, validitas prediksi pada data operasional perlu ditingkatkan agar benar-benar dapat diandalkan sebagai sistem pendukung keputusan dalam prakiraan cuaca berbasis multivariat.

Tabel 3. Hasil Prediksi Model Terbaik (CNN+LSTM Hybrid)

Tanggal	Target	Prediksi Cuaca Model Terbaik (CNN+LSTM Hybrid)
1-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan

Tanggal	Target	Prediksi Cuaca Model Terbaik (CNN+LSTM Hybrid)
2-Apr-25	Hujan	Cerah Berawan - Berawan
3-Apr-25	Hujan	Cerah Berawan - Berawan
4-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
5-Apr-25	Hujan, Petir	Cerah Berawan - Berawan
6-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
7-Apr-25	Hujan	Cerah Berawan - Berawan
8-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
9-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
10-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
11-Apr-25	Hujan	Cerah Berawan - Berawan
12-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
13-Apr-25	Hujan	Cerah Berawan - Berawan
14-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
15-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
16-Apr-25	Hujan	Cerah Berawan - Berawan
17-Apr-25	Cerah Berawan - Berawan	Berpotensi Hujan
18-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan
19-Apr-25	Hujan Lebat Disertai Petir	Cerah Berawan - Berawan
20-Apr-25	Hujan, Petir	Cerah Berawan - Berawan
21-Apr-25	Hujan	Cerah Berawan - Berawan
22-Apr-25	Hujan	Cerah Berawan - Berawan
23-Apr-25	Cerah Berawan - Berawan	Cerah Berawan - Berawan

4. KESIMPULAN

Penelitian ini mengkaji implementasi tiga model deep learning—Long Short-Term Memory (LSTM), CNN+LSTM Hybrid, dan Transformer untuk memprediksi kejadian cuaca esok hari berbasis data multivariat meteorologi harian. Setiap model dilatih menggunakan data observasi unsur cuaca seperti suhu udara, kelembapan, curah hujan, tekanan udara, angin, dan penyinaran matahari. Data diolah dalam format sekuens selama 7 hari terakhir dan diseimbangkan menggunakan SMOTE. Hasil evaluasi menunjukkan bahwa CNN+LSTM Hybrid unggul dalam seluruh metrik utama, mencatat nilai RMSE terendah (1.158), MAE terendah (0.521), R^2 tertinggi (0.323), akurasi sebesar 75%, dan macro F1 sebesar 0.75, yang menunjukkan performa prediksi yang lebih baik dibandingkan LSTM dan Transformer. Dengan demikian, CNN+LSTM Hybrid dapat disimpulkan sebagai model paling optimal dalam mendukung prakiraan cuaca harian berbasis data observasi di wilayah dengan karakteristik dinamis seperti Provinsi Lampung. Keunggulan model ini terletak pada kemampuannya dalam mengekstraksi fitur spasial dan temporal secara bersamaan, menjadikannya alternatif yang efektif untuk melengkapi atau mendukung sistem prakiraan numerik yang ada. Rekomendasi lanjutan dari penelitian ini adalah pengembangan dengan penambahan data spasial dari lebih banyak lokasi dan integrasi data satelit untuk meningkatkan akurasi dan jangkauan prediksi.

UCAPAN TERIMAKASIH

Penulis mengucapkan rasa terima kasih kepada BMKG Stasiun Klimatologi Lampung atas ketersediaan data dukung penelitian.

REFERENCES

- [1] B. R. Reddy, S. Anchuri, K. Santhi, P. Perugu, S. Depuru, and M. S. Kumar, "Enhancing Cloudburst Prediction System Using Bi-LSTM in Realtime: Machine Learning," *Commun. Appl. Nonlinear Anal.*, vol. 32, no. 1s, pp. 221–231, 2025, doi: 10.52783/cana.v32.2161.
- [2] S. Salma and A. Ashwitha, "Hybrid Cnn-Lstm Model: Rainfall Analysis and Prediction for Karnataka Region," *J. Theor. Appl. Inf. Technol.*, vol. 100, no. 22, pp. 6715–6716, 2022.
- [3] C. O. De Burgh-Day and T. Leeuwenburg, "Machine learning for numerical weather and climate modelling: A review," *Geosci. Model Dev.*, vol. 16, no. 22, pp. 6433–6477, 2023, doi: 10.5194/gmd-16-6433-2023.
- [4] H. S. Kim, K. M. Han, J. Yu, J. Kim, K. Kim, and H. Kim, "Development of a CNN+LSTM Hybrid Neural Network for Daily PM2.5 Prediction," *Atmosphere (Basel)*, vol. 13, no. 12, 2022, doi: 10.3390/atmos13122124.
- [5] X. Kong *et al.*, *Deep learning for time series forecasting: a survey*, no. 0123456789. Springer Berlin Heidelberg, 2025. doi: 10.1007/s13042-025-02560-w.
- [6] M. A. A. Al-qaness *et al.*, "ResInformer: Residual Transformer-Based Artificial Time-Series Forecasting Model for PM2.5 Concentration in Three Major Chinese Cities," *Mathematics*, vol. 11, no. 2, pp. 1–17, 2023, doi: 10.3390/math11020476.
- [7] O. S. Ojo and S. T. Ogunjo, "Machine learning models for prediction of rainfall over Nigeria," *Sci. African*, vol. 16, p. e01246, 2022, doi: 10.1016/j.sciaf.2022.e01246.
- [8] W. Wang, T. Ji, and J. Sun, "Prediction of Sea Clutter Based on Recurrent Neural Network," *J. Phys. Conf. Ser.*, vol. 1735,



- no. 1, pp. 1–17, 2021, doi: 10.1088/1742-6596/1735/1/012008.
- [9] D. Pan, Y. Deng, and S. X. Yang, “Recent Advances in Remote Sensing and Artificial Intelligence for River Water Quality Forecasting: A Review,” *Water*, vol. 17, no. 1, pp. 23–25, 2025, doi: 10.3390/w17010023.
- [10] P. Shu, X. Duan, C. Shao, J. Liu, Y. Tian, and S. Li, “Precipitation Spatio-Temporal Forecasting in China via Deep Learning Approaches,” *Water*, vol. 17, no. 9, pp. 1–20, 2025, doi: 10.3390/w17091381.
- [11] O. Ogunfowora and H. Najjaran, A Transformer-Based Framework for Multi-Variate Time Series: A Remaining Useful Life Prediction Use Case, arXiv, vol. abs/2308.09884, Aug. 2023, doi:10.1109/TMC.2023.3327097.
- [12] Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang, and P. S. Yu, “A Comprehensive Survey on Graph Neural Networks,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 32, no. 1, pp. 4–24, 2021, doi: 10.1109/TNNLS.2020.2978386.
- [13] S. Li *et al.*, “Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting,” *Adv. Neural Inf. Process. Syst.*, vol. 32, no. NeurIPS, 2019, doi: 10.48550/arXiv.1907.00235
- [14] S. Poornima and M. Pushpalatha, “Prediction of rainfall using intensified LSTM based recurrent Neural Network with Weighted Linear Units,” *Atmosphere (Basel)*, vol. 10, no. 11, 2019, doi: 10.3390/atmos10110668.
- [15] B. Ladjal *et al.*, “Hybrid deep learning CNN-LSTM model for forecasting direct normal irradiance: a study on solar potential in Ghardaia, Algeria,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–16, 2025, doi: 10.1038/s41598-025-94239-z.
- [16] C. Cambier van Nooten *et al.*, “Improving Precipitation Nowcasting for High-Intensity Events Using Deep Generative Models with Balanced Loss and Temperature Data: A Case Study in the Netherlands,” *Artif. Intell. Earth Syst.*, vol. 2, no. 4, pp. 1–16, 2023, doi: 10.1175/aies-d-23-0017.1.
- [17] F. Karim, S. Majumdar, H. Darabi, and S. Chen, “LSTM Fully Convolutional Networks for Time Series Classification,” *IEEE Access*, vol. 6, pp. 1662–1669, 2017, doi: 10.1109/ACCESS.2017.2779939.
- [18] B. Nemade, R. Mishra, P. Jangid, S. Dubal, V. Bharadi, and V. Kaul, “Improving Rainfall Prediction Accuracy Using an LSTM-Driven Model Enhanced by M-PSO Optimization,” *J. Electr. Syst.*, vol. 19, no. 3, pp. 164–180, 2023, doi: 10.52783/jes.664.
- [19] S. Tsokov, M. Lazarova, and A. Aleksieva-Petrova, “A Hybrid Spatiotemporal Deep Model Based on CNN and LSTM for Air Pollution Prediction,” *Sustain.*, vol. 14, no. 9, 2022, doi: 10.3390/su14095104.
- [20] A. Anshuka, R. Chandra, A. J. V. Buzacott, D. Sanderson, and F. F. van Ogtrop, “Spatio temporal hydrological extreme forecasting framework using LSTM deep learning model,” *Stoch. Environ. Res. Risk Assess.*, vol. 36, no. 10, pp. 3467–3485, 2022, doi: 10.1007/s00477-022-02204-3.
- [21] S. Khaki, L. Wang, and S. V. Archontoulis, “A CNN-RNN Framework for Crop Yield Prediction,” *Front. Plant Sci.*, vol. 10, no. January, pp. 1–14, 2020, doi: 10.3389/fpls.2019.01750.
- [22] H. Zhou *et al.*, “Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. BT - Thirty-Fifth AAAI Conference on Artificial Intelligence, AAAI 2021, Thirty-Third Conference on Innovative Applications of Artificial Intelligence, 2021, pp. 11106–11115, doi:10.1609/AAAI.V35I12.17325.
- [23] H. Kong, “Preprint not peer reviewed,” *The Lancet Psychiatry*, vol. 1, no. 1, pp. 1–35, 2022, doi:10.2139/ssrn.3627326.
- [24] A. Casolaro, V. Capone, G. Iannuzzo, and F. Camastra, “Deep Learning for Time Series Forecasting: Advances and Open Problems,” *Inf.*, vol. 14, no. 11, 2023, doi: 10.3390/info14110598.