

## Prediksi Temperatur Maksimum di Kota Tanjungpinang Menggunakan Model CNN-LSTM

Nurfalinda<sup>1</sup>, Mia Al Fiani<sup>2</sup>, Muhamad Radzi Rathomi<sup>3</sup>

<sup>1,2,3</sup> Program Studi Teknik Informatika, Universitas Maritim Raja Ali Haji  
E-mail : miaalfiani13@gmail.com<sup>2</sup>

### Abstrak

Prediksi temperatur maksimum memiliki peran penting dalam mendukung pengambilan keputusan terkait aktivitas masyarakat dan mitigasi dampak perubahan iklim. Penelitian ini bertujuan untuk menilai kinerja metode kombinasi CNN-LSTM untuk peramalan temperatur maksimum di Kota Tanjungpinang dengan menggunakan kelembapan rata-rata dan curah hujan sebagai variabel masukan. Data historis cuaca diperoleh melalui website BMKG, dengan periode 1 Januari 2022 hingga 30 November 2024 digunakan sebagai dataset penelitian. Model CNN-LSTM dikembangkan dengan mengoptimalkan keunggulan CNN dalam mengenali pola spasial serta kemampuan LSTM dalam menangkap pola temporal. Model dilatih menggunakan konfigurasi optimal yang terdiri dari 128 filter CNN, ukuran kernel 7, 200 unit LSTM, batch size 16, dan 120 epoch. Evaluasi kinerja dilakukan menggunakan dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) sebesar 1,65 dan *Mean Absolute Percentage Error* (MAPE) sebesar 4,19%. Hasil penelitian menunjukkan bahwa model ini dapat digunakan untuk melakukan prediksi temperatur maksimum berdasarkan data historis cuaca yang tersedia. Selain itu, model telah diimplementasikan dalam sebuah platform berbasis web yang memungkinkan pengguna untuk memasukkan data historis serta memilih periode prediksi dalam rentang 1, 3, 7, hingga 10 hari ke depan. Hasil prediksi disajikan dalam bentuk tabel dan visualisasi grafik guna memudahkan pengguna dalam memahami serta mengevaluasi informasi yang dihasilkan.

**Kata kunci** : CNN-LSTM, Prediksi, Temperatur Maksimum, RMSE, MAPE

## Maximum Temperature Prediction in Tanjungpinang City Using the CNN-LSTM Model

### Abstract

*The prediction of maximum temperature is important for supporting decision process related to public activities and reducing the consequences of climate change. The goal of this study is to analyze the performance of the CNN-LSTM hybrid method in forecasting maximum temperature in Tanjungpinang City by utilizing average humidity and rainfall as input variables. Historical weather data was obtained through the BMKG website, covering the period from January 1, 2022, to November 30, 2024, and was used as the research dataset. The CNN-LSTM model was developed by optimizing the advantages of CNN in recognizing spatial patterns and the capability of LSTM in capturing temporal patterns. The model was trained using an optimal configuration consisting of 128 CNN filters, a kernel size of 7, 200 LSTM units, a batch size of 16, and 120 epochs. Performance evaluation was conducted using two key metrics: Root Mean Squared Error (RMSE) of 1.65 and Mean Absolute Percentage Error (MAPE) of 4.19%. The findings indicate that the model can be used to predict maximum temperature based on available historical weather data. Additionally, the model has been implemented in a web-based platform that allows users to input historical data and select prediction periods ranging from 1, 3, 7, to 10 days ahead. The prediction results are presented in tables and graphical visualizations to facilitate users in understanding and evaluating the generated information.*

**Keywords** : CNN-LSTM, Prediction, Maximum Temperature, RMSE, MAPE

## 1. Pendahuluan

Indonesia memiliki pola iklim tropis dengan dua musim utama, yaitu musim hujan dan musim kemarau. Letaknya yang berada di sekitar garis khatulistiwa menyebabkan suhu udara cenderung hangat dan kelembapan yang tinggi sepanjang tahun. Namun, dampak perubahan iklim global semakin nyata, ditandai dengan peningkatan suhu rata-rata serta kejadian cuaca ekstrem yang lebih sering terjadi. Fenomena seperti gelombang panas dan banjir telah berdampak signifikan terhadap berbagai sektor, termasuk kesehatan manusia, ketahanan pangan, serta stabilitas ekonomi dan sosial masyarakat. Perubahan suhu juga berkontribusi pada peningkatan resiko penyebaran penyakit zoonosis serta mengganggu sistem pertanian dan ketahanan pangan [1]. Dampak perubahan suhu ini juga dirasakan di Tanjungpinang, Kepulauan Riau, di mana suhu udara mengalami peningkatan signifikan pada tahun 2021, dengan rata-rata mencapai 31,33 derajat celsius akibat posisi matahari dekat khatulistiwa dan minimnya awan [2].

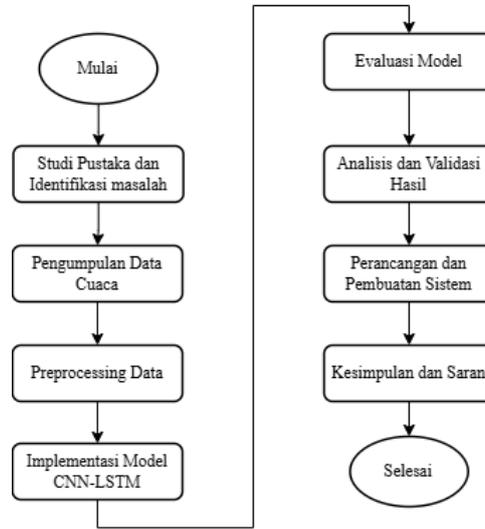
Suhu maksimum yang tinggi diketahui dapat memicu curah hujan ekstrem melalui proses konveksi uap air [3]. Selain itu, terdapat hubungan negatif antara suhu maksimum dan kelembapan relative, yang menunjukkan bahwa peningkatan suhu berbanding terbalik dengan tingkat kelembapan, sehingga berdampak pada pola perubahan suhu secara keseluruhan [4]. Suhu udara merupakan salah satu factor meteorologi yang memiliki pengaruh signifikan terhadap berbagai sektor, seperti kesehatan, pertanian, energi, transportasi, dan kondisi cuaca secara umum. Oleh karena itu, prediksi suhu yang akurat sangat penting dalam mendukung perencanaan dan pengambilan keputusan di sektor-sektor tersebut [5].

Dalam ranah prediksi suhu dan analisis data meteorologi, machine learning menjadi pendekatan yang semakin banyak diterapkan karena kemampuannya dalam mengolah data dalam jumlah besar serta mengatasi pola nonlinear yang sulit diselesaikan menggunakan metode konvensional. Algoritma jaringan syaraf tiruan (*Artificial Neural Network*) dan turunannya, seperti *Recurrent Neural Network (RNN)*, *Long Short-Term Memory (LSTM)*, *Bidirectional LSTM (BiLSTM)*, *Convolutional GRU (BiGRU)*, telah menunjukkan efektivitas dalam meningkatkan akurasi prediksi data deret waktu (*time-series*) karena kemampuannya dalam mempelajari pola data yang dinamis [6]. Berbagai penelitian sebelumnya telah mengeksplorasi penerapan metode jaringan syaraf dalam memprediksi kondisi cuaca. Sebagai contoh, LSTM terbukti lebih efisien dalam memperkirakan curah hujan di Kota Surabaya jika dibandingkan dengan metode RNN dan GRU, dengan nilai *Mean Squared Error (MSE)* sebesar 0,489, *Mean Absolute Error (MAE)* sebesar 0,537, dan koefisien determinasi ( $R^2$ ) sebesar 0,497 [7]. Selain itu, metode CNN-LSTM juga telah diterapkan dalam prediksi curah hujan di Kota Medan, dengan hasil yang menunjukkan nilai RMSE yang rendah, yaitu 0,08 [8]. Penelitian lain yang membandingkan model prediksi suhu berbasis LSTM menemukan bahwa CNN-LSTM menghasilkan prediksi yang lebih baik dibandingkan metode lainnya, dengan nilai loss pada data pelatihan sebesar 0,0079, loss pada data pengujian sebesar 0,0048, dan MAPE sebesar 3,42% [1].

Berdasarkan kajian sebelumnya, metode CNN-LSTM memiliki potensi yang menjanjikan dalam meningkatkan akurasi prediksi suhu maksimum. Namun, penerapan model ini untuk memprediksi temperatur maksimum di Kota Tanjungpinang masih belum banyak dikaji secara spesifik. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model prediksi temperature maksimum di Tanjungpinang dengan menggunakan metode kombinasi CNN-LSTM. Model ini akan dievaluasi menggunakan metrik RMSE dan MAPE untuk menilai performanya dalam memprediksi suhu maksimum berdasarkan data cuaca historis yang tersedia. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam upaya peramalan suhu yang lebih akurat, yang dapat dimanfaatkan untuk mendukung mitigasi dampak perubahan iklim serta pengambilan keputusan di berbagai

Penelitian ini bertujuan untuk memperoleh prediksi temperatur maksimum yang lebih tepat dengan menggabungkan metode CNN dan LSTM. Hasil penelitian ini diharapkan dapat memberikan wawasan lebih lanjut mengenai penerapan model CNN-LSTM dalam analisis suhu maksimum serta menghasilkan perkiraan suhu maksimum di Tanjungpinang yang lebih optimal.

2. Metodologi



Gambar 1. Prosedur Penelitian

2.1 Studi Pustaka dan identifikasi masalah

Studi kepustakaan bertujuan untuk memperoleh data sekunder sebagai landasan teoritis dalam penelitian ini. Data tersebut dikumpulkan dari berbagai sumber, seperti jurnal ilmiah, tesis, buku, dan lainnya. Fokus utama penelusuran adalah topik prediksi cuaca, khususnya prediksi temperatur maksimum, serta metode yang digunakan, yaitu CNN-LSTM. Melalui studi literatur ini, dilakukan analisis untuk memahami kelebihan metode prediksi temperature sebelumnya untuk mengidentifikasi gap penelitian yang ada. Pendekatan yang dilakukan dalam penelitian memanfaatkan keunggulan CNN dalam mengekstraksi fitur spasial serta kemampuan LSTM dalam mengenali pola temporal, dengan harapan dapat meningkatkan akurasi dalam memprediksi temperatur maksimum.

2.2 Pengumpulan data cuaca

Penelitian ini memanfaatkan data yang tersedia melalui situs web BMKG (<https://dataonline.bmkg.go.id/data-harian>). Data bersumber dari Stasiun Meteorologi Raja Haji Fisabilillah Tanjungpinang. Variabel dependen dan independent digunakan dalam penelitian ini. Variabel independen terdiri dari curah hujan dan kelembapan rata-rata, yang digunakan sebagai input untuk memengaruhi atau menjelaskan nilai variabel dependen. Temperatur maksimum yang menjadi target prediksi adalah variable dependen. Dalam penelitian ini, digunakan 912 data yang mencakup rentang waktu dari Januari 2022 hingga Juni 2024 untuk melatih dan menguji model. Selain itu, data periode Juli-November 2024 diterapkan khusus untuk menghasilkan prediksi langsung pada website, sebagai implementasi model yang telah dibangun.

2.3 Preprocessing data

Tahap pembersihan data mencakup penanganan nilai yang hilang (*missing value*) dan *outlier*, serta normalisasi untuk memastikan data siap diolah oleh model CNN-LSTM. Normalisasi dilakukan menggunakan metode *Min-Max Scaling*, yang mengonversi nilai data ke dalam rentang [0,1].

$$x'_t = \left( \frac{x_t - (\min(x))}{\max(x) - \min(x)} \right) \tag{1}$$

Dimana :

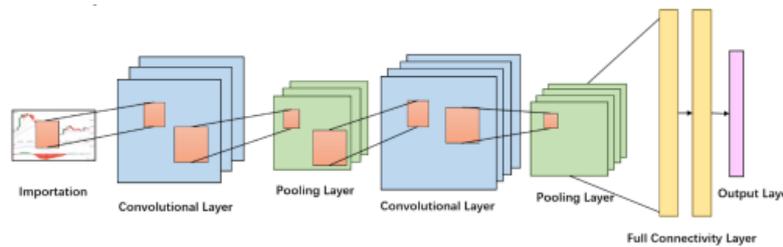
- $x'_t$  : data yang telah dinormalisasi
- $x_t$  : data sebelum dinormalisasi
- $\min(x)$  : nilai terendah data aktual
- $\max(x)$  : nilai tertinggi data aktual

**2.4 Implementasi Model CNN-LSTM**

Merancang model CNN-LSTM untuk melakukan prediksi temperatur maksimum serta mengevaluasi efektivitasnya pada dataset pelatihan dan pengujian.

**A. Convolutional Neural Network (CNN)**

*Convolutional Neural Network* adalah tipe model *Artificial Neural Network* (ANN) yang dikembangkan untuk mengidentifikasi pola dalam berbagai jenis data, baik itu gambar maupun data kontinu. Struktur CNN meliputi lapisan input, konvolusi, fungsi aktivasi, *pooling*, *fully connected layer*, dan output. Lapisan konvolusi mengekstraksi fitur, sedangkan *pooling* mengurangi dimensi spasial untuk mencegah *overfitting*. Karakteristik utama CNN adalah berbagi bobot dan koneksi lokal, yang meningkatkan efisiensi dan akurasi prediksi [9].



**Gambar 2.** Struktur Model CNN

Lapisan konvolusi pada CNN memproses representasi fitur dari lapisan sebelumnya menggunakan kernel konvolusi. Proses ini dilakukan berdasarkan rumus pada persamaan 2:

$$x_j^L = f\left(\sum_{i \in m_j} x_i^{L-1} \times k_{ij}^L + b_j^L\right) \tag{2}$$

Dimana :

- $x_j^L$  : peta fitur output ke-j pada lapisan ke-L
- $x_i^{L-1}$  : peta fitur output ke-i pada lapisan sebelumnya
- $m_j$  : pilihan peta masukan yang digunakan
- $k_{ij}^L$  : bobot koneksi antara peta ke-i dan peta output ke-j pada lapisan ke-L
- $*$  : operasi konvolusi yang diterapkan
- $b_j^L$  : bias lapisan ke-L
- $f()$  : Fungsi aktivasi ReLU pada hasil keluaran.

*Pooling layer* memiliki peran dalam menyederhanakan struktur model dengan cara melakukan subsampling. Salah satu metode yang digunakan adalah *max pooling*, yang dapat dijelaskan dengan rumus berikut:

$$x_j^L = f(\partial_j^L \text{down}(x_j^{L-1}) + b_j^L) \tag{3}$$

Dimana :

- $\text{down}()$  : fungsi subsampling pada *max pooling*
- $x_j^{L-1}$  : peta fitur input ke-j dari lapisan sebelumnya (lapisan ke-(L-1))
- $b_j^L$  : faktor bias pada lapisan ke-L

Setelah langkah tersebut, lapisan fully connected menghitung vektor output akhir menggunakan rumus:

$$x^L = f(w^L x^{L-1} + b^L) \tag{4}$$

Dimana:

- $x^L$  : vektor hasil keluaran lapisan ke-L

- $w^L$  : bobot yang menghubungkan lapisan ke-(L-1) dan lapisan ke-L
- $x^{L-1}$  : vektor *input* dari lapisan sebelumnya (lapisan ke-(L-1))
- $b^L$  : faktor bias pada lapisan ke-L.

**B. Long Short-Term Memory (LSTM)**

*Long Short-Term Memory* adalah variasi metode *Recurrent Neural Network* (RNN) [10] yang dibuat khusus agar bisa mengatasi permasalahan *vanishing gradient* yang muncul dalam memproses data berurutan [1]. Dengan mekanisme internal yang kompleks, LSTM efektif untuk prediksi dan klasifikasi data berbasis waktu [11].

LSTM memproses input melalui beberapa langkah. Pertama, *forget gate* ( $f_t$ ) menentukan informasi yang perlu dihapus:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{5}$$

Kedua, *input gate* ( $i_t$ ) dan kandidat *cell state* ( $\tilde{C}_t$ ) menentukan informasi baru yang disimpan.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{6}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{7}$$

*Cell state* diperbarui dengan:

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \tag{8}$$

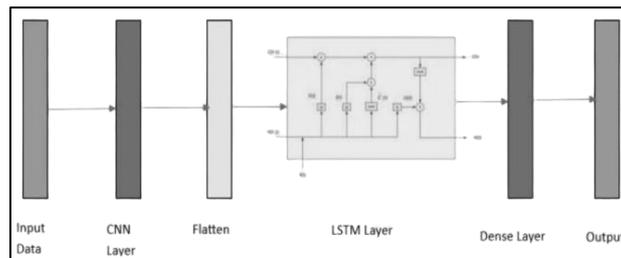
Terakhir, *output gate* ( $O_t$ ) menghasilkan *output* untuk *timestep* saat ini:

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{9}$$

$$h_t = O_t \times \tanh(C_t) \tag{10}$$

**C. CNN-LSTM**

Model CNN-LSTM menggabungkan kemampuan CNN dalam mengekstrak pola spasial dan LSTM dalam menangkap ketergantungan temporal, sehingga mampu menghasilkan prediksi berbasis waktu yang lebih tepat dibandingkan dengan penggunaan CNN atau LSTM secara terpisah. [12].



**Gambar 3.** Arsitektur Model CNN-LSTM

**D. Denormalisasi**

Denormalisasi mengembalikan nilai prediksi ke rentang aslinya untuk memastikan hasil sesuai dengan data sebenarnya [13].

$$x_t = Y(x_{\max} - x_{\min}) + x_{\min} \tag{11}$$

Dimana:

- $x_t$  : Nilai data asli
- $Y$  : Output prediksi
- $x_{\max}$  : Nilai tertinggi data asli
- $x_{\min}$  : Nilai terendah data asli

**2.5 Evaluasi Model**

Penelitian ini menerapkan RMSE dan MAPE sebagai metrik untuk menilai kinerja model. RMSE digunakan untuk mengukur tingkat kesalahan prediksi dengan menghitung akar kuadrat rata-rata selisih antara nilai aktual dan prediksi [14].

$$\sqrt{\frac{\sum_i^n (y_i - \hat{y}_i)^2}{n}} \tag{12}$$

MAPE menghitung persentase deviasi antara nilai aktual dan prediksi:

$$100 \times \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \tag{13}$$

Prediksi dengan MAPE rendah menunjukkan kualitas hasil yang baik [15].

**Tabel 1.** Pengukuran MAPE

Tingkat Akurasi	Keterangan Akurasi
<10%	Sangat baik
10 – 20%	Baik
20-50%	Cukup
>50%	Tidak baik

**2.6 Analisis dan validasi hasil**

Pada tahap analisis dan validasi hasil, dilakukan perbandingan antara hasil prediksi model CNN-LSTM dengan data suhu maksimum aktual untuk menilai akurasinya. Evaluasi ini menggunakan metrik seperti RMSE dan MAPE guna mengukur tingkat kesalahan prediksi. Jika nilai error masih tinggi, maka dilakukan analisis lebih lanjut untuk mengidentifikasi faktor yang memengaruhi performa model, seperti kualitas data atau parameter yang digunakan. Analisis ini menilai keakuratan model dan menentukan kesiapan penerapannya atau perlunya perbaikan sebelum digunakan.

**2.7 Perancangan dan pembuatan sistem**

Membangun serta menerapkan sistem peramalan yang menggabungkan metode CNN-LSTM untuk membantu pengguna sistem dalam memprediksi temperatur maksimum berdasarkan data input berupa kelembapan rata-rata dan curah hujan.

**2.8 Kesimpulan dan saran**

Bagian ini berisi ringkasan hasil penelitian dan evaluasi model yang telah dibuat. Selain itu, diberikan saran untuk pengembang lebih lanjut agar penelitian ke depan bisa lebih baik.

**3. Hasil dan Pembahasan**

**3.1 Analisis Performa Model CNN-LSTM**

Model CNN-LSTM dievaluasi untuk memprediksi temperatur maksimum di Tanjungpinang. CNN digunakan untuk mengambil fitur spasial dari data. Sedangkan LSTM berfokus pada pola perubahan waktu. Beberapa parameter dalam model, seperti jumlah filter, kernel size, unit pada LSTM, batch size, dan jumlah epoch, dioptimalkan untuk mendapatkan hasil prediksi yang akurat. Proses evaluasi model menggunakan metrik RMSE dan MAPE.

Model: "sequential"

Layer (type)	Output Shape	Param #
conv1d (Conv1D)	(None, 10, 128)	1,920
max_pooling1d (MaxPooling1D)	(None, 5, 128)	0
lstm (LSTM)	(None, 200)	263,200
dense (Dense)	(None, 1)	201

Total params: 265,321 (1.01 MB)  
 Trainable params: 265,321 (1.01 MB)  
 Non-trainable params: 0 (0.00 B)

**Gambar 4.** Model CNN-LSTM

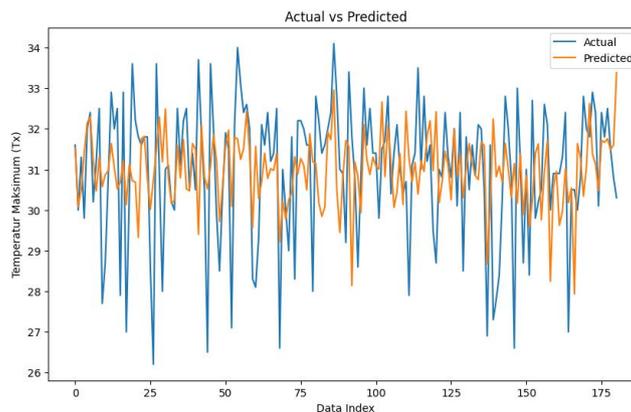
Model CNN-LSTM mencakup lapisan Conv1D, MaxPooling1D, LSTM, dan Dense, yang digunakan secara berurutan dalam arsitektur jaringan, dan masing-masing memiliki peran dalam mengolah data untuk menghasilkan prediksi. Conv1D dengan 128 filter mengekstraksi fitur, MaxPooling1D mengurangi panjang data, LSTM dengan 200 unit menangkap pola temporal, dan Dense menghasilkan prediksi. Model memiliki 265.321 parameter dan dievaluasi menggunakan RMSE dan MAPE untuk meningkatkan akurasi prediksi temperatur maksimum.

**Tabel 2.** Output Pelatihan Model

No	Jumlah filter	Kernel Size	LSTM Layer	Batch Size	Jumlah Epoch	Nilai RMSE	Nilai MAPE
1	32	3	100	16	200	1.792	4.53%
2	32	5	100	16	25	1.637	4.29%
3	32	7	100	32	50	1.691	4.20%
4	32	3	100	64	60	1.772	4.39%
5	32	3	100	32	100	1.635	4.26%
6	64	5	150	32	80	1.787	4.42%
7	64	7	150	64	60	1.645	4.31%
8	64	3	100	16	100	1.725	4.32%
<b>9</b>	<b>128</b>	<b>7</b>	<b>200</b>	<b>16</b>	<b>120</b>	<b>1.65</b>	<b>4.19%</b>
10	128	3	200	64	100	1.71	4.25%

### 3.2 Hasil Pemodelan CNN-LSTM

Gambar 5 menunjukkan perbandingan antara nilai prediksi yang dihasilkan oleh model CNN-LSTM dan nilai temperatur maksimum (Tx) yang sesungguhnya. Pada grafik ini, sumbu horizontal mewakili urutan data, sedangkan sumbu vertikal menampilkan temperatur maksimum yang tercatat. Garis biru menandakan nilai aktual, sedangkan garis oranye mencerminkan prediksi yang dibuat oleh hasil model. Secara umum, model ini secara efektif mengikuti tren variasi temperature maksimum. Namun, ada sedikit perbedaan antara nilai aktual dan hasil prediksi, menunjukkan adanya beberapa kesalahan prediksi. Agar dapat menilai lebih jelas seberapa tepat prediksi yang dihasilkan oleh model, evaluasi lebih lanjut dengan menggunakan metrik RMSE dan MAPE perlu dilakukan. Grafik ini memberi indikasi bahwa model CNN-LSTM cukup potensial dalam memprediksi temperatur maksimum, meskipun masih ada beberapa area yang bisa diperbaiki agar lebih akurat.



**Gambar 5.** Grafik perbandingan aktual dan prediksi

### 3.3 Penerapan Model CNN-LSTM pada Website

Situs web yang dikembangkan memberikan akses bagi pengguna untuk mengunggah data terbaru sesuai kebutuhan, khususnya setelah periode Juni 2024, untuk menghasilkan prediksi terkini. Pengguna dapat

memilih durasi prediksi, seperti 1, 3, 7, atau 10 hari yang akan datang sesuai kebutuhan. Data input (kelembapan rata-rata dan curah hujan) selama 10 hari terakhir perlu diinputkan sebagai dasar prediksi. Sistem ini dirancang agar fleksibel dan dapat memberikan hasil yang relevan berdasarkan kondisi terbaru.



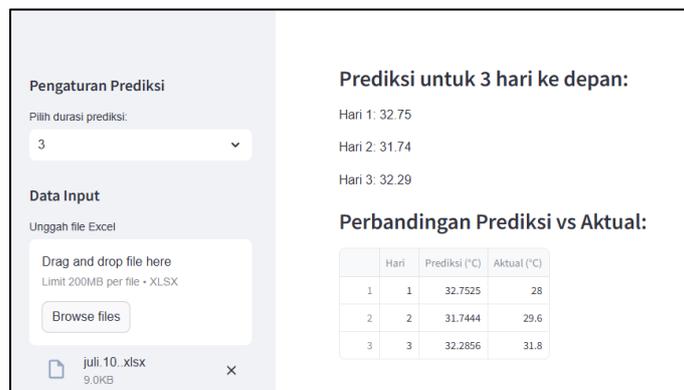
Gambar 6. Grafik Hasil prediksi temperatur maksimum

Setelah data input dari sepuluh hari terakhir dimasukkan oleh pengguna, informasi tersebut akan ditampilkan dalam bentuk tabel untuk memastikan keakuratan data yang dimasukkan.



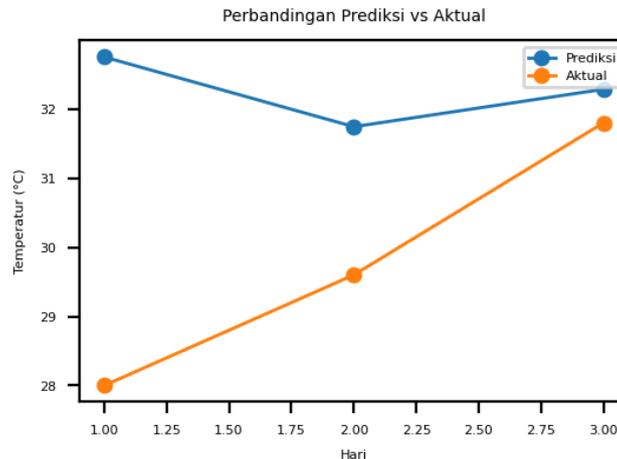
Gambar 7. Halaman tampilan data yang diunggah

Selanjutnya, antarmuka pengguna sistem prediksi temperatur maksimum menampilkan bagian "Pengaturan Prediksi" untuk memilih durasi prediksi. Setelah pengguna mengunggah file Excel, model CNN-LSTM akan memproses data dan menampilkan hasil prediksi dalam bentuk tabel dan teks, yang memperlihatkan perbandingan antara nilai prediksi dan data aktual.



Gambar 8. Halaman hasil prediksi website

Grafik berikut menunjukkan perbandingan antara nilai prediksi dan data aktual untuk temperatur maksimum.



**Gambar 9.** Halaman hasil prediksi website

Gambar 9 memperlihatkan perbandingan antara nilai prediksi dan data aktual temperatur maksimum. Sumbu horizontal menunjukkan hari-hari dalam periode prediksi, sedangkan sumbu vertikal menunjukkan temperatur maksimum (°C). Garis biru mewakili nilai prediksi dari model CNN-LSTM, sementara garis oranye menunjukkan data aktual. Grafik ini membantu pengguna mengevaluasi akurasi prediksi dengan membandingkan kedua garis tersebut.

#### 4. Kesimpulan

Penelitian ini mengembangkan system prediksi temperature maksimum di Tanjungpinang menggunakan kombinasi CNN dan LSTM, yang menunjukkan kinerja yang baik dengan nilai RMSE 1,65 dan MAPE 4,19%. Dengan menggunakan konfigurasi 128 filter pada lapisan konvolusi, ukuran kernel 7, dan 200 unit di bagian LSTM, serta pengaturan *batch size* 16 dan 120 *epoch*, model ini dapat memprediksi temperatur maksimum dengan baik. Selain itu, model yang telah dibuat diterapkan pada website yang memungkinkan pengguna untuk memilih jangka waktu prediksi yang diinginkan, serta melihat hasilnya dalam bentuk tabel dan grafik. Hal ini memudahkan pengguna untuk memahami dan mengevaluasi hasil prediksi dengan lebih mudah. Untuk pengembangan penelitian selanjutnya, disarankan untuk menambah jumlah data, baik dengan memperpanjang periode pengambilan data atau menambahkan lokasi lain, serta mengoptimalkan parameter model dan mempertimbangkan faktor lain seperti kecepatan angin dan tekanan udara untuk meningkatkan akurasi serta kemampuan generalisasi model.

#### Daftar Pustaka

- [1] T. Chen, "A series of models based on long short-term memory for temperature prediction," *Highlights in Science, Engineering and Technology, CMLAI 2023*, vol. 39, 2023, pp. 1041-1048.
- [2] KepriProv, "Peningkatan suhu panas di Kepri dipengaruhi posisi matahari," 1 Maret 2021. Diakses dari <https://kepriprov.go.id/berita/pemprov-kepri/peningkatan-suhu-panas-di-kepri-dipengaruhi-posisi-matahari>.
- [3] P. Ganguli dan B. Merz, "Observational evidence reveals compound humid heat stress-extreme rainfall hotspots in India," *Earth's Future*, vol. 12, 2024, e2023EF004074.
- [4] A. M. Osagie dan E. P. Ogheneofejiro, "Cross correlation analysis on the relationship between maximum temperature and relative humidity in Bida, Niger State," *International Journal of Agricultural Economics*, vol. 1, no. 3, pp. 62–66, 2016.
- [5] P. R. Naskar dan S. Naskar, "A new neurocomputing approach for medium-range temperature prediction," *Mausam*, vol. 73, no. 3, pp. 537–554, 2022.
- [6] M. Mushliha, "Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia," *Jambura Journal of Mathematics*, vol. 6, no. 2, pp. 195–203, 2024.

- 
- [7] J. Badriyah, A. Fariza, dan T. Harsono, "Prediksi curah hujan menggunakan long short-term memory," *Jurnal Media Informatika Budidarma*, vol. 6, no. 3, 2022, pp. 1297–1303.
- [8] M. Alfandi, Pristiwanto, dan A. M. H. Sihite, "Penerapan Metode CNN-LSTM Dalam Memprediksi Hujan Pada Wilayah Medan," *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 6, no. 1, 2022, pp. 490-499.
- [9] J. Li, "Gold price prediction based on CNN-LSTM," *Financial Engineering and Risk Management*, vol. 7, no. 2, 2024.
- [10] P. A. Qori, D. S. Oktafani, dan I. Kharisudin, "Analisis Peramalan dengan Long Short Term Memory pada Data Kasus Covid-19 di Provinsi Jawa Tengah," *PRISMA*, vol. 5, pp. 752–758, 2022
- [11] N. K. Agusmawati, F. Khoiriyah, dan A. Tholib, "Prediksi harga emas menggunakan metode LSTM dan GRU," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 11, no. 3, 2023.
- [12] K. Jyothi, H. L. Raksha, S. Raksha, G. Upadhya Rakshitha, dan C. B. Sowmyashree, "Food Delivery Time Prediction Using CNN-LSTM," *International Journal of Scientific Research in Engineering and Management (IJSREM)*, vol. 8, no. 5, 2024.
- [13] F. K. T. Putri dan A. D. Wowor, "Implementasi algoritma long short-term memory dalam prediksi konsentrasi gas metana (CH<sub>4</sub>) di Kota Salatiga," *JTIK (Jurnal Teknologi Informasi dan Komunikasi)*, vol. 8, no. 2, pp. 2580-1643, 2024.
- [14] M. D. A. Carnegie dan Chairani, "Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi curah hujan," *Jurnal Media Informatika Budidarma*, vol. 7, no. 3, pp. 1022–1032, 2023.
- [15] Andre dan T. Handhayani, "Implementasi algoritma LSTM untuk memprediksi temperatur di wilayah Ternate, Maluku Utara," *Jurnal Esensi Infokom*, vol. 8, no. 1, pp. 26-32, 2024.
-