

Penerapan Algoritma Long Short Term Memory Untuk Memprediksi Pola Kenaikan Suhu Di Kota Jakarta Pusat

Alvian Ibnu Farhan¹, Ahmad Haitami Hatta², Dzulfikar Ramazan³, Fernando B Siahaan⁴, Syaiful Anwar⁵, Felix Wuryo Handono⁶

^{1,2,3,4,5,6}Sistem Informasi, Universitas Bina Sarana Informatika

Jl. SMA Kapin No.292A, Kec. Duren Sawit, Kota Jakarta Timur, DKI Jakarta

e-mail: ¹ibnufarhan830@gmail.com, ²ahmadhaitamihatta@gmail.com, ³dzulfikar27.r@gmail.com, fernando.fbs@bsi.ac.id⁴, syaiful.sfa@bsi.ac.id⁵, felix@bsi.ac.id⁶

Artikel Info : Diterima : 30-04-2025 | Direvisi : 10-05-2025 | Disetujui : 25-06-2025

Abstrak - Pemanasan global yang mengacu pada eskalasi suhu rata-rata permukaan bumi di darat, laut, dan udara yang menyebabkan perubahan kondisi lingkungan termasuk naiknya permukaan air laut dan fenomena cuaca ekstrem. Menurut BMKG, beberapa wilayah di Indonesia telah mengalami heat waves di akhir-akhir ini. Diperkirakan terjadi dari bulan Juni hingga Agustus. Kondisi ini meningkatkan suhu udara di beberapa tempat. Namun, di daerah DKI Jakarta suhu tertinggi diperkirakan mencapai 35 derajat celcius. Tujuan penelitian ini adalah untuk memprediksi pola kenaikan suhu selama satu tahun ke masa depan di Wilayah Jakarta Pusat berdasarkan data historis iklim harian dari website resmi BMKG dengan memanfaatkan algoritma LSTM. Penelitian ini menggunakan data iklim dari tanggal 1 Januari 2013 hingga 02 Februari 2024 yang terdiri dari 4049 data. Model LSTM pada penelitian ini dibuat dengan menggunakan 90% data pelatihan, *learning rate* 0,0098, 96 unit LSTM, ukuran *batch* 32, dan 75 *epoch* dengan da terendah sebesar 0,0080, model ini memberikan skor MAPE sebesar 1.98% dan skor RMSE sebesar 0.8765. Hasil prediksi menunjukkan adanya pola kenaikan suhu dengan anomali sebesar 1.02 derajat celcius yang akan berdampak buruk bagi masyarakat. Hasil penelitian diharapkan memberikan kontribusi terhadap kajian perubahan iklim di Jakarta Pusat.

Kata Kunci : Pemanasan Global, Temperatur, Model LSTM

Abstracts - Global warming refers to the escalation of the average temperature of the Earth's surface on land, sea and air that causes changes in environmental conditions including rising sea levels and extreme weather phenomena. According to BMKG, several regions in Indonesia have experienced heat waves recently. It is expected to occur from June to August. This condition increases the air temperature in some places. However, in the DKI Jakarta area the highest temperature is expected to reach 35 degrees celcius. The purpose of this study is to predict the pattern of temperature increase for one year into the future in the Central Jakarta Region based on historical daily climate data from the BMKG official website by utilising the LSTM algorithm. This research uses climate data from 1 January 2013 to 02 February 2024 consisting of 4049 data. The LSTM model in this study was created using 90% training data, *learning rate* 0.0098, 96 LSTM units, batch size 32, and 75 epochs with the lowest loss function of 0.0080, this model provides a MAPE value of 1.98% and an RMSE value of 0.8765. The prediction results show a pattern of temperature increase with an anomaly of 1.02 degrees centigrade which will have a negative impact on society. The research results are expected to contribute to the study of climate change in Central Jakarta.

Keywords : Global Warming, Temperature, LSTM Model

PENDAHULUAN

Eskalasi suhu rata-rata permukaan bumi di darat, laut, dan udara dikenal sebagai pemanasan global. Semua kehidupan di bumi terpengaruh oleh pemanasan global. Diperkirakan bahwa peningkatan temperatur global akan menyebabkan perubahan kondisi lingkungan termasuk naiknya permukaan air laut, fenomena cuaca ekstrem, dan punahnya berbagai spesies (Mira, 2022). Menurut BMKG, beberapa wilayah di Indonesia telah mengalami *heat waves* akhir-akhir ini. Diperkirakan tetap terjadi dari bulan Juni hingga Agustus. BMKG memperkirakan kemungkinan curah hujan mengalami penurunan karena kondisi atmosfer akan semakin kering di bagian selatan



Indonesia. Di siang hari, kondisi ini meningkatkan suhu udara di beberapa tempat. Namun, di daerah DKI Jakarta suhu tertinggi diperkirakan mencapai 35 derajat celsius (Kharismaningtyas, 2024).



Sumber: BMKG, 2024

Gambar 1. Tren Suhu Tertinggi Di Jakarta Pusat

Berdasarkan Gambar 1. pada tahun 2022 hingga 2024, suhu tertinggi mengalami kenaikan sebesar 0,8 derajat celsius. Menurut Meehl (2007) Eskalasi suhu udara akan meningkatkan ancaman bencana di masa depan. Salah satu cara untuk mengantisipasi masalah ini adalah dengan membuat prediksi suhu (Habibulloh & Sofro, 2023).

Dalam penelitian yang dilakukan oleh Akbar, Santoso dan Warsito yaitu “Memprediksi Tingkat Temperatur Kota Semarang dengan menggunakan Metode LSTM” (Akbar et al., 2023). Penelitian ini dapat menghasilkan model LSTM yang cukup mumpuni dengan dibuktikan dengan skor MAPE hanya sebesar 1.89% dan skor RMSE sebesar 0.725 yang menunjukkan bahwa model LSTM mampu secara akurat untuk memprediksi data *time series*.

Peneliti berikutnya adalah Faisal Muhammad dan Irawan yaitu “Implementasi *Long Short-Term Memory* untuk Prediksi Intensitas Curah Hujan Studi Kasus: Kabupaten Malang” (Faisal Muhammad & Irawan, 2023). Studi ini menyimpulkan bahwa model *deep learning* LSTM berhasil memberikan kinerja paling optimal dengan nilai kesalahan RMSE dan MAE paling rendah, yaitu 0.98162 dan 0.68847, yang menandakan keakuratan prediksi yang lebih tinggi dengan nilai error yang lebih kecil.


Menurut Kinanti (2021) Teknik *Deep Learning* mengacu pada metode yang sering diaplikasikan dalam memprediksi data deret waktu, sebab mampu menemukan pola data dengan cepat. *Long Short-Term Memory* jenis pengembangan dari RNN adalah sebuah teknik *deep learning* yang bisa diimplementasikan untuk melakukan prediksi data deret waktu. Model pengembangan dari jaringan saraf tiruan yaitu RNN. Karena jaringan saraf tiruan tidak dapat melakukan pelatihan cepat pada data yang besar, pengembangan RNN diperlukan. RNN didesain untuk memproses data bersambung atau berurutan. Akan tetapi, kelemahan RNN terletak pada ketidakmampuannya untuk mempertahankan informasi dari data yang lebih lama. Guna mengatasi masalah ketergantungan data lama, LSTM memiliki keuntungan. Model LSTM, yang diajukan oleh Sepp Hochreiter dan Jurgen Schmidhuber (1997) menggunakan susunan sel memori khusus untuk menggantikan neuron lapisan tersembunyi dari RNN (Akbar et al., 2023).

Pengolahan data *time series* diperlukan untuk mengetahui pola kenaikan suhu di Jakarta Pusat untuk satu tahun ke depan. Salah satu teknik pengolahan data tersebut adalah *deep learning* yang menggunakan algoritma LSTM. Tujuan dari penelitian ini adalah untuk memprediksi pola kenaikan suhu selama satu tahun ke depan di Wilayah Jakarta berdasarkan data historis iklim harian dari situs resmi Badan Meteorologi Klimatologi Geofisika dengan memanfaatkan kemampuan algoritma LSTM. Selain itu, diharapkan penelitian ini dapat membantu memberikan strategi pencegahan terhadap dampak perubahan suhu di Jakarta Pusat yang semakin panas setiap tahunnya bagi masyarakat dan pemerintah.

METODE PENELITIAN

Deep learning merujuk pada salah satu teknik dari berbagai metode pembelajaran mesin dan dianggap sebagai evolusi dari teknik-teknik pembelajaran mesin sebelumnya yang memanfaatkan jaringan saraf tiruan dengan struktur yang lebih mendalam dan proses perhitungan yang lebih rumit melalui lapisan non-linear berlapis. Ketika digunakan untuk deteksi wajah, pemrosesan gambar, sistem rekomendasi, pemrosesan bahasa natural, dan prediksi rangkaian waktu, beberapa model berbasis *deep learning* sangat akurat (Sanjaya & Budi, 2020). Menurut Junifer Pangaribuan dan Lestari (2020) Sebuah kumpulan algoritma yang dikenal sebagai *Neural Network* berupaya mengidentifikasi hubungan penting dalam data melalui proses yang meniru fungsi otak manusia (Saputro & Swanjaya, 2023). RNN merujuk pada jenis jaringan saraf tiruan yang ideal untuk mendeteksi pola dalam data berurutan termasuk teks, video, suara, bahasa, genom, dan data berbasis waktu. RNN sendiri telah banyak

diterapkan dalam proses peramalan dan prediksi (Raharjo, 2022). Menurut Yadav, Jha, dan Sharan (2020) LSTM ialah peningkatan terbaru dari RNN yang sangat sesuai untuk tugas pengolahan, dan prediksi data deret waktu, terutama ketika ada jeda waktu yang tidak terdefinisi antara *event-event* kritis dalam seri tersebut (Khumaidi et al., 2020). Ilustrasi berikut ini memperlihatkan konfigurasi LSTM yang mencakup lapisan masukan, lapisan keluaran, serta lapisan yang tidak terlihat.



Sumber: Wiranda & Sadikin (2019)

Gambar 2. Arsitektur LSTM

Lapisan yang tidak terlihat terdiri dari beberapa sel memori, di mana setiap sel dilengkapi dengan tiga jenis gerbang: gerbang masukan, gerbang hapus, dan gerbang keluaran. Gerbang masukan menentukan jumlah informasi yang perlu disimpan dalam kondisi sel untuk menghindari penumpukan data yang tidak esensial. Gerbang keluaran menetapkan seberapa banyak isi atau nilai dari sel memori yang diperlukan untuk menghasilkan *output*, sedangkan gerbang hapus mengatur berapa banyak nilai yang dipertahankan dalam sel memori. Pada gambar di atas menampilkan detail dari *hidden layer* LSTM, yaitu *cell memory*. Sel memori dalam jaringan LSTM memiliki kemampuan untuk menyimpan nilai atau kondisi, yang juga dikenal sebagai sel kondisi, untuk periode waktu yang panjang maupun pendek (Wiranda & Sadikin, 2019). Berikut adalah penjelasan mengenai fungsi dari masing-masing *gate* yang terdapat pada sel memori LSTM:

1. Gerbang masukan (i_t)

Gerbang masukan menerima data masukan yang baru dan yang telah ada sebelumnya, kemudian memprosesnya dengan lapisan *sigmoid*. Gerbang ini menghasilkan nilai antara 0 atau 1. Rumus matematis berikut digunakan untuk menghitung informasi tersebut (Faishol et al., 2020).

$$i_t = \sigma(W_i S_{t-1} + W_i X_t)$$

Keterangan:

W_i = Bobot gerbang masukan

S_{t-1} = Keadaan sebelumnya

X_t = Masukan pada waktu t

σ = Fungsi aktivasi *sigmoid*

Nilai dari *gate* masukan dikalikan dengan hasil dari *layer* kandidat ($\tilde{C}$), dan rumus matematika untuk ($\tilde{C}$) dijelaskan dalam rumus di bawah ini.

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

$$c_t = (i_t * \tilde{C} + f_t * c_{t-1})$$

Keterangan:

$\tilde{C}$ = Kondisi Sel Sementara

W_c = Bobot yang terkait dengan sel kondisi.

S_{t-1} = Kondisi sebelumnya atau kondisi pada waktu $t-1$

X_t = Data masukan pada waktu t

2. Gerbang Lupa (f_t)

Gerbang lupa atau gerbang hapus menghasilkan keluaran melalui lapisan *sigmoid* yang memproses *input* dari waktu t hingga 1 dan mengintegrasikannya dengan fungsi aktivasi *sigmoid*. Akibat fungsi *sigmoid*, hasil keluaran dari Gerbang Lupa bisa berupa 0 atau 1. Jika $f_t = 0$, maka kondisi sebelumnya akan dihapus, namun jika $f_t = 1$, maka kondisi sebelumnya tetap dipertahankan. Rumus matematika untuk f_t disajikan sebagai berikut

(Mizdrakovic et al., 2024).

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

Keterangan:

W_f = Bobot dari gerbang masukan

S_{t-1} = Kondisi sebelumnya atau kondisi pada waktu t-1

X_t = Data masukan pada waktu t

σ = Fungsi aktivasi *sigmoid*

3. Gerbang Lupa (f_t)

Mirip dengan gerbang lainnya, gerbang keluaran menentukan jumlah kondisi yang diizinkan masuk ke dalamnya, yang kemudian menciptakan kondisi sel yang baru (h_t). Rumus dari O_t dan h_t adalah sebagai berikut (Choudhary & Chauhan, 2023).

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

$$h_t = O_t * \tanh(c_t)$$

Keterangan:


W_o = Bobot dari gerbang masukan

S_{t-1} = Kondisi sebelumnya atau kondisi pada waktu t-1

X_t = Data masukan pada waktu t

σ = Fungsi aktivasi *sigmoid*

Diagram berikut menggambarkan secara ringkas tahapan yang dilakukan dalam penelitian ini.



Sumber: Penelitian (2024)

Gambar 4. Tahapan Penelitian

Untuk memastikan bahwa penelitian ini dapat dilakukan dan menghasilkan hasil yang sesuai dengan tujuan. Tahapan penelitian diuraikan sebagai berikut:

1. Studi Literatur

Studi ini memulai dengan memeriksa literatur untuk memahami penelitian sebelumnya yang relevan. Penulis kemudian mencari literatur dan mempelajari data dari studi kasus, jurnal penelitian, dan situs web online.

2. Pengumpulan Data

Data studi ini diperoleh dari web resmi BMKG dengan <https://dataonline.bmkg.go.id>. Data historis iklim harian yang digunakan adalah data iklim harian dari tanggal 1 Januari 2013 s.d 2 Februari 2024 yang berjumlah 4049 record dengan objek penelitian Stasiun Meteorologi Kemayoran Jakarta Pusat.

3. Pre-processing Data

Data yang terkumpul kemudian diproses untuk mengisi nilai yang hilang dan mengatasi masalah lainnya. Pre-processing memastikan data siap digunakan oleh model.

4. Ekplorasi Data Analisis

Ekplorasi Data Analisis digunakan oleh para *data scientist* untuk menganalisis dan memahami kumpulan data serta meringkas karakteristik utamanya, yang sering kali menggunakan metode visualisasi data.

5. Membagi Data

Data terbagi menjadi dua yaitu data pelatihan dan data pengujian dengan skala pembagian sebesar 90% data pelatihan dan sebanyak 10% data pengujian.

6. Data Pelatihan

Data pelatihan dimanfaatkan oleh LSTM untuk pelatihan model yang kemudian dilanjutkan ke tahap normalisasi data.

7. Data Pengujian

Data pengujian dimanfaatkan oleh LSTM untuk pelatihan model yang kemudian dilanjutkan ke tahap normalisasi data.

8. Normalisasi Data

Nilai aktual akan diubah menjadi nilai skala 0 sampai dengan 1. Tujuan normalisasi data yaitu untuk model LSTM bisa bekerja lebih efektif dalam mempelajari pola data pelatihan. Untuk mencari nilai normalisasi data menggunakan metode *min-max scaler*.

9. Pelatihan LSTM

Model LSTM dilatih menggunakan data latih sebesar 90% dari dataset. Proses ini melibatkan parameter dalam model agar dapat memprediksi dengan akurat.

10. Model LSTM

Model yang sudah dilatih disimpan sehingga dapat digunakan kembali di masa depan tanpa perlu melatih ulang.

11. Prediksi

Model LSTM digunakan untuk melakukan prediksi berdasarkan data uji. Prediksi ini kemudian dibandingkan dengan nilai sebenarnya untuk mengevaluasi kinerja model LSTM.

12. Denormalisasi Data

Denormalisasi mengacu pada data yang akan diubah menjadi asli kembali.

13. Hasil Prediksi Suhu

Setelah melakukan denormalisasi data, peneliti melakukan analisa terkait hasil prediksi model LSTM.

14. Evaluasi Model LSTM

Penelitian ini mengevaluasi model menggunakan metrics MAE, MAPE dan RMSE.

15. Deployment

Model yang telah dilatih dan memiliki performa yang baik akan di deploy ke sebuah *website* menggunakan layanan *streamlit cloud community*.

HASIL DAN PEMBAHASAN

Proses pembangunan model prediksi melibatkan penggunaan *Google Colaboratory* sebagai platform pengembangan dan bahasa pemrograman Python sebagai alat utama. Spesifikasi detail platform dan bahasa pemrograman yang digunakan disajikan dalam Tabel 1:

Tabel 1. Spesifikasi Sistem

No	Jenis Kebutuhan	Spesifikasi
1	Sistem Operasi Komputer	Windows 10
2	Browser	Google Chrome
3	Tools	Google Colaboratory
4	Bahasa Pemrograman	Python 3.11.4
5	Machine Learning Backend	Tensorflow 2.16.1
6	Deep Learning Framework	Keras 3.3.3
7	Library Pendukung	Pandas 2.1.3 Numpy 1.26.1 Scikit-learn 1.5.0 Matplotlib 3.8.2

Kemudian dilakukan pembuatan model LSTM menggunakan pustaka *Keras* dalam bahasa pemrograman


python dengan mengatur parameter yang tercantum pada Tabel 2:

No	Jenis	Nilai
1	Layer	4
2	Activation	Relu
3	Optimization	Adam
4	Batch Size	32
5	Epoch	75

Pemodelan LSTM yang dibangun pada penelitian ini menggunakan empat layer dengan rincian dua LSTM layer, satu layer *dropout* dan satu layer *dense* sebagai keluaran. Pada layer LSTM pertama yang menjadi *input* layer diisi sebanyak 64 *neuron* dengan menggunakan *Rectified Linear Unit* yang dikenal sebagai *relu* sebagai fungsi aktivasi dan bentuk *input shape* ditentukan oleh dimensi data latih (3630 sampel data, 14 *timesteps*, 6 variabel) selanjutnya pada hidden layer LSTM kedua diisi dengan *neuron* sebanyak 32 unit dengan fungsi aktivasi ‘*relu*’ (*Rectified Linear Unit*). Penambahan layer *Dropout* dengan tingkat 0.2 ditambahkan untuk mengurangi ‘*overfitting*’. Lapisan ini bekerja dengan mematikan 20% unit *neuron* secara acak selama waktu pelatihan dan Lapisan *dense* sebagai lapisan keluaran memiliki satu unit *neuron* yang sesuai dengan dimensi keluaran dari *trainY*. Beberapa parameter yang digunakan adalah bawaan dari pustaka *Keras* termasuk fungsi aktivasi *relu* dan *Optimization*. Variabel dataset lainnya merupakan variabel terpilih setelah dilakukan proses seleksi menggunakan *RFE* (*Recursive Feature Elimination*). Deskripsi Model LSTM yang digunakan disajikan dalam tabel 3:

Model: Sequential()		
Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 14, 64)	18176
lstm (LSTM)	(None, 32)	12416
dropout (Dropout)	(None, 32)	0
dense (Dense)	(None, 1)	33
Total params: 30,625		
Trainable params: 30,625		
Non-trainable params: 0		

Proses pelatihan model dengan *epoch* 75 dan *batch size* 32 membutuhkan waktu sekitar 15 menit dan hasil yang didapatkan menunjukkan *learning rate* dengan sebesar 0.0080 yang menunjukkan bahwa model bisa belajar dari data pelatihan dengan sangat baik dengan tingkat *loss/error* yang sangat kecil yang bisa dilihat pada gambar 5.



Sumber: Penelitian (2024)

Gambar 5. Kinerja Pelatihan Model


Grafik diatas menunjukkan dua garis yang melacak *loss* pelatihan dan validasi. Sumbu-x melambangkan jumlah *epochs* yang merupakan proses iterasi dari dataset, sedangkan sumbu-y melambangkan *loss* yang nantinya akan menunjukkan performa yang lebih baik dicapai dengan nilai yang lebih rendah.. Garis biru menunjukkan *loss* pelatihan yang menurun tajam pada awal proses pelatihan dan kemudian mendatar yang menunjukkan bahwa model dengan cepat belajar dari data pelatihan.

Garis merah menunjukkan *loss* validasi yang menurun bersamaan dengan *loss* pelatihan tetapi tetap relatif konstan selama *epoch-epoch* berikutnya. Konsistensi ini menunjukkan bahwa model memiliki performa pelatihan

yang baik dan tidak mengalami *overfitting* yang signifikan. Dari Gambar 5. dapat disimpulkan bahwa model LSTM telah belajar dengan efektif dari data pelatihan dan menunjukkan kinerja yang stabil pada data validasi yang merupakan indikator positif untuk kinerja model prediksi pada data yang tidak pernah dilihat oleh model.

Setelah performa model dirasa cukup baik langkah selanjutnya adalah menguji model yang sudah dilatih untuk memprediksi suhu selama satu tahun ke masa depan menggunakan data pengujian dengan hasil prediksi bisa dilihat pada tabel 4. dan gambar berikut ini:

Tanggal	Prediksi
01/02/2024	32.26233
02/02/2024	31.83695
03/02/2024	31.49782
04/02/2024	30.94968
05/02/2024	31.47065
...	...
28/01/2025	32.61951
29/01/2025	32.83123
30/01/2025	32.38062
31/01/2025	31.99045
01/02/2025	31.69642




Sumber: Penelitian (2024)

Gambar 6. Visualisasi Hasil Prediksi

Grafik di atas menunjukkan dua garis yaitu garis biru yang mewakili data historis dan garis oranye mewakili data prediksi. Sumbu-x menunjukkan Tahun dari data dan sumbu-y menunjukkan suhu dalam derajat celsius. Terlihat pada grafik visualisasi di atas suhu pada tahun 2024 s.d 2025 mengalami kenaikan yang cukup signifikan dengan fluktuasi suhu berkisar antara 33 s.d 36 derajat celsius. Grafik hasil prediksi ini memberikan wawasan berharga bagi peneliti mengenai potensi kenaikan suhu di masa depan yang dapat membantu para peneliti, masyarakat atau pemerintah dalam mempersiapkan dan merespon terhadap perubahan iklim dan kondisi cuaca yang tiap tahun nya semakin panas. Untuk menganalisa hasil prediksi lebih lanjut peneliti akan mencari selisih kenaikan suhu antara tahun 2024 dengan tahun 2025 pada tabel berikut ini:

No	Suhu rata-rata 2024-2025	Suhu rata-rata 2013-2024	Anomali
1	33.34	32.33	1.02

Menurut perhitungan BMKG, anomali suhu sebesar 1.02 derajat sudah diatas normal dari kenaikan suhu udara rata-rata indonesia pada bulan Mei 2024 sebesar 0.8 derajat (Sudirman, 2024). Untuk memastikan apakah hasil prediksi tersebut akurat, peneliti akan melakukan evaluasi kinerja pelatihan dan pengujian model LSTM menggunakan *metrics* MAE, MAPE dan RMSE.



Sumber: Penelitian (2024)


Gambar 7. Tingkat Akurasi Data Pelatihan Aktual dengan Data Pelatihan Prediksi

Dari grafik di atas bisa terlihat bahwa hasil prediksi model sudah sangat mendekati nilai aktual nya. Namun, terdapat juga area dimana garis prediksi sedikit menyimpang dari garis aktual yang menunjukkan adanya perbedaan antara nilai prediksi oleh model dan nilai sebenarnya. Untuk mengevaluasi model lebih lanjut peneliti akan menggunakan beberapa *metrics* evaluasi seperti MAE, MAPE, dan RMSE untuk mengukur lebih pasti seberapa baik kinerja dari model pelatihan seperti pada tabel dibawah ini:

Tabel 6. Evaluasi Kinerja Pelatihan Model

No	Metrics	Nilai
0	MAE	0.6545
1	MAPE	1.9845
2	RMSE	0.8765

Hasil evaluasi kinerja pelatihan yang ditampilkan pada *output* di atas menunjukkan nilai MAE yang rendah sekitar 0.6545 yang mengindikasikan bahwa model tersebut memiliki tingkat kesalahan yang kecil dalam prediksi. Skor MAPE sebanyak 1.98% menunjukkan bahwa model rata-rata memiliki kesalahan prediksi kurang dari 2.0% dari nilai sebenarnya yang menunjukkan indikator kinerja yang baik. Nilai RMSE juga menunjukkan nilai yang rendah sekitar 0.8765 yang menunjukkan bahwa model memiliki kesalahan variasi prediksi yang relatif kecil dari nilai aktual nya. Dari hasil evaluasi kinerja model pelatihan ini bisa disimpulkan bahwa selama proses pelatihan, model sudah bisa bekerja dengan sangat efektif dibuktikan oleh ketiga *metrics* evaluasi yang semuanya menunjukkan nilai kesalahan prediksi yang relatif kecil. Selanjutnya adalah mengevaluasi Kinerja Pengujian Model.



Sumber: Penelitian (2024)

Gambar 1. Tingkat Akurasi Data Pengujian Aktual dengan Data Pengujian Prediksi

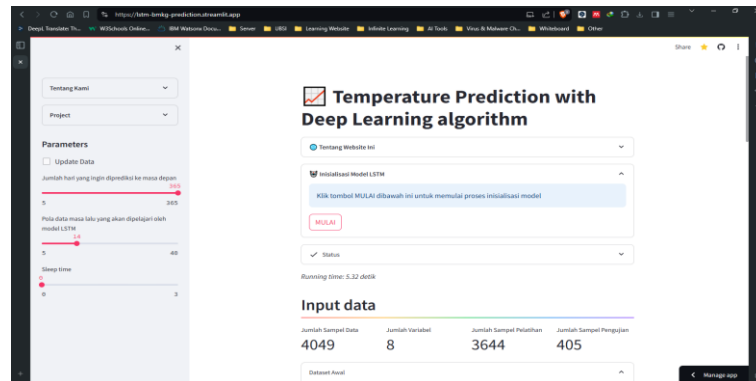
Dari grafik di atas menunjukkan bahwa performa pengujian model untuk memprediksi sudah hampir mendekati nilai aktual nya. Namun memang masih terdapat divergensi yang lebar dibandingkan dengan grafik performa set pelatihan sebelumnya. Untuk mengukur lebih akurat hasil evaluasi dari performa pengujian ini peneliti akan menggunakan beberapa *metrics* evaluasi seperti MAE, MAPE dan RMSE untuk mengukur lebih pasti seberapa baik performa pengujian model seperti pada tabel berikut ini:

Tabel 7. Evaluasi Kinerja Pengujian Model

No	Metrics	Nilai
0	MAE	0.9607
1	MAPE	3.0141
2	RMSE	1.2733

Hasil evaluasi kinerja pengujian yang ditampilkan pada *output* di atas masih menunjukkan nilai MAE yang terbilang cukup rendah sekitar 0.9607 yang menunjukkan bahwa model tersebut mempunyai tingkat kesalahan yang relatif kecil. dalam prediksi. Skor MAPE sebanyak 3.01% juga menunjukkan bahwa model rata-rata memiliki kesalahan prediksi hanya sekitar 4.0% dari nilai sebenarnya yang menunjukkan indikator kinerja yang baik. Nilai RMSE juga menunjukkan nilai yang terbilang rendah sekitar 1.2733 yang menunjukkan bahwa model memiliki kesalahan variasi prediksi yang juga relatif kecil dari nilai aktual nya. Dari hasil evaluasi kinerja pengujian model ini bisa disimpulkan bahwa selama proses pengujian, model sudah bisa bekerja dengan cukup efektif dibuktikan oleh ketiga *metrics* evaluasi yang semuanya menunjukkan nilai kesalahan prediksi yang masih relatif kecil.

Proses *deployment* merupakan langkah akhir untuk mempublikasikan model LSTM yang telah dilatih sehingga dapat diakses oleh publik secara luas. Berikut adalah tampilan antarmuka pengguna dari *dashboard website* yang telah dikembangkan.



Sumber: Penelitian (2024)

Gambar 9. Halaman *Dashboard Temperature Prediction with Deep Learning Algorithm*

KESIMPULAN

Model sudah bisa memprediksi dengan cukup akurat, hasil RMSE sebesar 0.8765 yang menunjukkan bahwa model memiliki kesalahan variasi prediksi yang relatif kecil dari nilai aktualnya dan MAPE sebesar 1.98% menunjukkan bahwa model rata-rata memiliki kesalahan prediksi kurang dari 2% dari nilai sebenarnya yang menunjukkan indikator kinerja yang baik. Hasil Prediksi menunjukkan selisih atau anomali sebesar 1.02 derajat celsius yang akan berdampak buruk bagi kesehatan masyarakat di Jakarta Pusat dan kenaikan suhu tersebut juga bisa mengganggu produktivitas masyarakat. Dari hasil prediksi tersebut solusi yang mungkin bisa dilakukan oleh pemerintah adalah lebih mendorong masyarakat di Jakarta untuk beralih dari menggunakan bahan bakar bensin menjadi kendaraan yang bebas emisi, mungkin dengan cara subsidi untuk energi terbarukan dan regulasi yang membatasi emisi industri, dan saran untuk masyarakat di Jakarta Pusat adalah untuk selalu tetap menjaga kesehatan tubuh saat bekerja dalam situasi panas dengan cara minum cukup banyak air putih agar tubuh tetap terhidrasi. Untuk penelitian selanjutnya yang mengadopsi metode serupa dapat membandingkan LSTM dengan RNN. Serta beberapa arah untuk penelitian mendatang yaitu memperluas kumpulan data, variabel, dan parameter penelitian. Hal ini diharapkan dapat menghasilkan perbandingan model yang lebih efektif dan akurat dalam memprediksi perubahan pola suhu di Jakarta Pusat atau di lokasi penelitian yang lain.

REFERENSI

- Akbar, R., Santoso, R., & Warsito, B. (2023). Prediksi Tingkat Temperatur Kota Semarang Menggunakan Metode Long Short-Term Memory (LSTM). *Jurnal Gaussian*, 11(4), 572–579. <https://doi.org/10.14710/j.gauss.11.4.572-579>
- Choudhary, P., & Chauhan, S. (2023). An intelligent chatbot design and implementation model using long short-

- term memory with recurrent neural networks and attention mechanism. *Decision Analytics Journal*, 9, 100359. <https://doi.org/10.1016/j.dajour.2023.100359>
- Faisal Muhammad, T. A., & Irawan, M. I. (2023). Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang). *Jurnal Sains Dan Seni ITS*, 12(1). <https://doi.org/10.12962/j23373520.v12i1.106892>
- Faishol, M. A., Endroyono, E., & Irfansyah, A. N. (2020). Prediksi Polusi Udara Perkotaan Di Surabaya Menggunakan Recurrent Neural Network – Long Short Term Memory. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 18(2), 102. <https://doi.org/10.12962/j24068535.v18i2.a988>
- Habibulloh, W., & Sofro, A. (2023). Prediksi Suhu Udara Di Jawa Tengah Menggunakan Extreme Value Theory. *MATHunesa: Jurnal Ilmiah Matematika*, 11(3), 489–495. <https://doi.org/10.26740/mathunesa.v11n3.p489-495>
- Kharismaningtyas. (2024). *BMKG Ungkap Cuaca Panas Akan Terjadi Hingga Agustus, Diprediksi Suhu Jakarta Capai 35 Derajat C*. KompasTV. <https://www.kompas.tv/video/504656/bmkg-ungkap-cuaca-panas-akan-terjadi-hingga-agustus-diprediksi-suhu-jakarta-capai-35-derajat-c>
- Khumaidi, A., Raafi'udin, R., & Solihin, I. P. (2020). Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung. *Jurnal Telematika*, 15(1), 13–18. <https://journal.ithb.ac.id/telematika/article/view/340>
- Mira, T. D. N. B. (2022). Game Edukasi “Global Warming” Sebagai Media Pembelajaran Untuk Anak Kelas VI Sekolah Dasar. *Prosiding SEMMAU*, 14–20.
- Mizdrakovic, V., Kljajic, M., Zivkovic, M., Bacanin, N., Jovanovic, L., Deveci, M., & Pedrycz, W. (2024). Forecasting bitcoin: Decomposition aided long short-term memory based time series modeling and its explanation with Shapley values. *Knowledge-Based Systems*, 299, 112026. <https://doi.org/10.1016/j.knosys.2024.112026>
- Raharjo, B. (2022). *Deep Learning dengan Python* (J. T. Santoso (ed.); 1st ed.). Yayasan Prima Agus Teknik.
- Sanjaya, D., & Budi, S. (2020). Prediksi Pencapaian Target Kerja Menggunakan Metode Deep Learning dan Data Envelopment Analysis. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2), 288–300. <https://doi.org/10.28932/jutisi.v6i2.2678>
- Saputro, D., & Swanjaya, D. (2023). Analisa Prediksi Harga Saham Menggunakan Neural Network Dan Net Foreign Flow. *Generation Journal*, 7(2), 96–104. <https://doi.org/10.29407/gj.v7i2.20001>
- Sudirman, M. (2024). *Fakta Perubahan Iklim Mei 2024*. Badan Meteorologi Klimatologi Geofisika. <https://www.bmkg.go.id/iklim/fakta-perubahan-iklim.bmkg?p=fakta-perubahan-iklim-6&tag=&lang=ID>
- Wiranda, L., & Sadikin, M. (2019). Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 8(3), 184–196. <https://ejournal.undiksha.ac.id/index.php/janapati/article/view/19139>