

Perkiraan Suhu Menggunakan Algoritma Recurrent Neural Network Long Short Term Memory

Ilham Zahidin, Bulkis Kanata, Lalu A Syamsul Irfan Akbar*

Fakultas Teknik, Teknik Elektro, Universitas Mataram, Mataram, Indonesia

Email: ¹ilhamzahidin21@gmail.com, ²uqikanata@unram.ac.id, ^{3,*}irfan@unram.ac.id

Email Penulis Korespondensi: ilhamzahidin21@gmail.com

Submitted: 11/11/2024; Accepted: 30/11/2024; Published: 30/11/2024

Abstrak—Suhu udara merupakan salah satu variabel penting dalam kondisi cuaca yang memengaruhi berbagai aspek kehidupan manusia, mulai dari kesehatan, pertanian, hingga ekonomi. Di Indonesia, khususnya di Kota Mataram yang terletak di wilayah tropis, perubahan suhu yang signifikan dapat berdampak pada sektor-sektor seperti pariwisata, pertanian, dan aktivitas harian masyarakat. Perkiraan suhu yang akurat dapat membantu masyarakat, industri, dan pemerintah dalam mengambil keputusan yang lebih tepat, baik untuk perencanaan jangka pendek maupun jangka panjang. Namun, cuaca di wilayah tropis seperti Mataram cenderung sulit diprediksi secara akurat karena sifatnya yang dinamis dan dipengaruhi oleh berbagai faktor atmosfer. Metode konvensional dalam memprediksi cuaca sering kali tidak dapat menangkap pola kompleks yang ada dalam data suhu historis, sehingga diperlukan metode yang lebih canggih untuk memperbaiki akurasi prediksi. *Recurrent Neural Network* (RNN), khususnya varian *Long Short-Term Memory* (LSTM), telah terbukti menjadi alat yang sangat efektif dalam memodelkan data deret waktu (time series) yang kompleks. Algoritma ini mampu mengingat informasi jangka panjang dan mengenali pola-pola dalam data yang berubah seiring waktu, sehingga sangat cocok untuk masalah prediksi suhu. Dalam penelitian ini, algoritma RNN-LSTM diterapkan untuk memprediksi suhu di Kota Mataram dengan tujuan meningkatkan keakuratan perkiraan dan memberikan hasil yang dapat digunakan untuk berbagai kepentingan. Model prediksi suhu menggunakan algoritma LSTM melalui beberapa langkah yaitu mengumpulkan data, normalisasi data, membagi data menjadi data uji dan data latih, selanjutnya membuat model LSTM dengan menentukan jumlah *epoch*, *layer* dan *batch size*. Tahap terakhir mengevaluasi model dengan RMSE. Terdapat 2 parameter yang mempengaruhi hasil perkiraan metode LSTM pada penelitian yang dilakukan yaitu *epoch* dan *batch size*. Epoch yang digunakan pada penelitian ini yaitu sebesar 5, 10, 20, 30, 40, 50 dan 100, batch size tetap sebesar 32. Algoritma LSTM yang digunakan menggunakan optimizer RMSProps. Model prediksi suhu menggunakan metode LSTM dengan akurasi terbaik rata-rata diperoleh dengan menggunakan batch size 32 dan epoch 50 dengan nilai RMSE 0.13 dan tingkat akurasi perkiraan sebesar 99.96% pada pengujian untuk memprediksi suhu Kota Mataram pada tahun 2023.

Kata Kunci: RNN; LSTM; Suhu; Perkiraan Suhu; Kota Mataram

Abstract—Air temperature is a critical variable in weather conditions that affects various aspects of human life, including health, agriculture, and the economy. In Indonesia, particularly in Mataram City, which is situated in a tropical region, significant temperature changes can impact sectors such as tourism, agriculture, and daily activities. Accurate temperature forecasting can aid the public, industries, and the government in making more informed decisions, both for short-term and long-term planning. However, weather in tropical regions like Mataram tends to be difficult to predict accurately due to its dynamic nature and the influence of multiple atmospheric factors. Conventional weather prediction methods often fail to capture the complex patterns in historical temperature data, necessitating more advanced methods to improve forecast accuracy. Recurrent Neural Networks (RNNs), particularly the Long Short-Term Memory (LSTM) variant, have proven to be highly effective tools for modeling complex time series data. This algorithm can retain long-term information and recognize patterns in data that change over time, making it well-suited for temperature prediction challenges. In this study, the RNN-LSTM algorithm is applied to forecast temperatures in Mataram City, aiming to improve forecast accuracy and produce results useful for various purposes. The temperature prediction model using the LSTM algorithm involves several steps: data collection, data normalization, splitting data into test and training sets, building the LSTM model by determining the number of epochs, layers, and batch size, and finally, evaluating the model with RMSE. Two parameters, epoch and batch size, influence the LSTM model's forecasting results in this study. Epochs used in this study are 5, 10, 20, 30, 40, 50, and 100, with a fixed batch size of 32. The LSTM algorithm employs the RMSProp optimizer. The temperature prediction model using the LSTM method achieved the best average accuracy with a batch size of 32 and 50 epochs, yielding an RMSE value of 0.13 and a prediction accuracy of 99.96% in forecasting Mataram City's temperature for the year 2023.

Keywords: RNN; LSTM; Temperature; Temperature Forecast; Mataram City

1. PENDAHULUAN

Suhu udara merupakan salah satu variabel penting dalam kondisi cuaca yang memengaruhi berbagai aspek kehidupan manusia, mulai dari kesehatan, pertanian, hingga ekonomi[1]. Di Indonesia, khususnya di Kota Mataram yang terletak di wilayah tropis, perubahan suhu yang signifikan dapat berdampak pada sektor-sektor seperti pariwisata, pertanian, dan aktivitas harian masyarakat. Perkiraan suhu yang akurat dapat membantu masyarakat, industri, dan pemerintah dalam mengambil keputusan yang lebih tepat, baik untuk perencanaan jangka pendek maupun jangka panjang. Namun, cuaca di wilayah tropis seperti Mataram cenderung sulit diprediksi secara akurat karena sifatnya yang dinamis dan dipengaruhi oleh berbagai faktor atmosfer. Metode konvensional dalam memprediksi cuaca sering kali tidak dapat menangkap pola kompleks yang ada dalam data suhu historis, sehingga diperlukan metode yang lebih canggih untuk memperbaiki akurasi prediksi.

Kecerdasan buatan (*Artificial Intelligence/AI*) adalah cabang ilmu komputer yang bertujuan untuk menciptakan mesin atau sistem yang dapat meniru kecerdasan manusia[2]. AI memungkinkan komputer untuk melakukan tugas-tugas yang biasanya memerlukan pemikiran manusia, seperti pengenalan suara, pemrosesan bahasa alami, pengambilan keputusan, dan pemecahan masalah. Dalam praktiknya, AI mencakup serangkaian teknologi seperti *machine learning*, *deep learning*, dan pemrosesan bahasa alami yang dirancang untuk mengoptimalkan kinerja berdasarkan data. AI dapat dibagi menjadi dua kategori: *narrow AI* dan *general AI*. *Narrow AI* dirancang untuk menjalankan tugas spesifik, seperti asisten virtual (contohnya Siri atau Google Assistant) yang dapat memahami perintah suara tetapi tidak dapat melakukan tugas di luar cakupan yang telah ditentukan. *General AI* adalah konsep AI yang memiliki kemampuan berpikir dan memahami layaknya manusia dalam berbagai konteks, meskipun masih dalam tahap pengembangan dan penelitian. Teknik AI yang umum digunakan meliputi algoritma *machine learning*, yang memungkinkan sistem belajar dari data historis, serta jaringan saraf tiruan (*neural networks*) yang meniru cara kerja otak manusia. Dalam perkembangannya, AI diterapkan dalam berbagai bidang seperti perawatan kesehatan, keuangan, transportasi, dan manufaktur, memberikan solusi yang lebih efisien, otomatisasi, dan analisis data yang lebih mendalam[3].

Machine learning (ML) adalah bidang dalam kecerdasan buatan yang memungkinkan komputer belajar dari data tanpa perlu diprogram secara eksplisit. Dengan menggunakan algoritma dan model statistik, *machine learning* memungkinkan sistem untuk mengidentifikasi pola, membuat prediksi, atau mengambil keputusan berdasarkan data historis[4]. Proses ini melibatkan pelatihan model dengan data, di mana sistem mengoptimalkan akurasi melalui proses iteratif untuk mencapai performa terbaik. *Machine learning* terbagi dalam beberapa jenis utama: *supervised learning*, *unsupervised learning*, dan *reinforcement learning*. *Supervised learning* menggunakan data berlabel untuk mengajarkan model membuat prediksi, seperti pada klasifikasi gambar dan prediksi harga. *Unsupervised learning* bekerja dengan data tanpa label, berfokus pada pengelompokan atau pengelompokan data yang mirip, seperti segmentasi pasar atau analisis kluster. *Reinforcement learning* melibatkan pembelajaran melalui percobaan dan umpan balik, digunakan dalam aplikasi seperti robotika dan permainan. Algoritma populer dalam *machine learning* mencakup *decision trees*, *k-nearest neighbors*, *support vector machines* (SVM), dan jaringan saraf tiruan (*neural networks*). Seiring dengan meningkatnya jumlah data dan kemajuan dalam komputasi, *machine learning* telah berkembang pesat dan diterapkan di berbagai bidang seperti kesehatan, keuangan, transportasi, dan pemasaran. Melalui *machine learning*, sistem dapat secara otomatis menyesuaikan diri dengan informasi baru, meningkatkan kemampuan prediksi, serta menawarkan solusi berbasis data dalam skala besar[5].

Deep learning adalah subbidang dari *machine learning* yang berfokus pada pengembangan algoritma dan arsitektur jaringan saraf tiruan (*neural networks*) dengan struktur yang mendalam atau berlapis-lapis[6]. Dalam jaringan saraf tiruan, *deep learning* menggunakan beberapa lapisan tersembunyi (*hidden layers*) yang memungkinkan sistem mempelajari pola kompleks dari data berukuran besar, baik data terstruktur maupun tidak terstruktur seperti gambar, teks, dan suara. Konsep dasar *deep learning* adalah pembelajaran berlapis di mana setiap lapisan belajar mengekstraksi fitur-fitur yang semakin abstrak dari lapisan sebelumnya. Salah satu keunggulan utama *deep learning* adalah kemampuannya dalam melakukan representasi fitur secara otomatis, yang menghilangkan kebutuhan untuk rekayasa fitur manual. Model *deep learning* seperti *Convolutional Neural Networks* (CNN) dan *Recurrent Neural Networks* (RNN) sering digunakan pada berbagai aplikasi seperti pengenalan gambar, pemrosesan bahasa alami, dan prediksi data deret waktu. CNN, misalnya, sangat efektif dalam mengenali pola dalam data visual, sementara RNN cocok untuk menangani data sekuensial. Keberhasilan *deep learning* sangat dipengaruhi oleh ketersediaan data yang besar dan peningkatan kekuatan komputasi. Dengan perkembangan teknologi GPU (*Graphics Processing Unit*) dan TPU (*Tensor Processing Unit*), proses pelatihan model *deep learning* menjadi lebih efisien. Algoritma ini menjadi dasar dalam banyak teknologi canggih, termasuk sistem rekomendasi, mobil otonom, dan asisten virtual[3].

Recurrent Neural Network (RNN), khususnya varian *Long Short-Term Memory* (LSTM), telah terbukti menjadi alat yang sangat efektif dalam memodelkan data deret waktu (*time series*) yang kompleks. Algoritma ini mampu mengingat informasi jangka panjang dan mengenali pola-pola dalam data yang berubah seiring waktu, sehingga sangat cocok untuk masalah prediksi suhu. Dalam penelitian ini, algoritma RNN-LSTM diterapkan untuk memprediksi suhu di Kota Mataram dengan tujuan meningkatkan keakuratan perkiraan dan memberikan hasil yang dapat digunakan untuk berbagai kepentingan[7].

Penelitian sebelumnya menunjukkan bahwa algoritma RNN-LSTM dalam prediksi suhu dapat memberikan hasil yang lebih akurat dibandingkan dengan metode tradisional. Misalnya, penelitian oleh Khumaidi, Ali dkk. (2019) menunjukkan bahwa penggunaan RNN-LSTM dalam memprediksi suhu udara harian dapat memberikan hasil yang cukup baik pada penelitiannya dengan judul "Penguji Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung"[8].

Namun, penggunaan algoritma RNN-LSTM dalam prediksi suhu di Kota Mataram masih belum banyak diteliti. Oleh karena itu, penelitian ini akan fokus pada pengembangan model prediksi suhu menggunakan algoritma RNN-LSTM untuk meningkatkan akurasi perkiraan suhu di Kota Mataram. Dengan memanfaatkan data suhu historis yang tersedia, diharapkan model ini dapat memberikan perkiraan suhu yang lebih akurat dan dapat diandalkan bagi masyarakat Kota Mataram dalam perencanaan aktivitas mereka.

Suhu udara adalah ukuran yang mencerminkan tingkat panas atau dingin dari udara di suatu tempat pada waktu tertentu. Ini diukur sebagai rata-rata energi kinetik molekul-molekul udara, yang menggambarkan seberapa cepat partikel-partikel udara bergerak. Suhu udara adalah salah satu elemen penting dalam meteorologi dan iklim, dan memiliki dampak langsung pada kehidupan sehari-hari, termasuk kenyamanan manusia, pertumbuhan tanaman, dan pola cuaca[9].

LSTM merupakan bagian dari metode RNN. Kelebihan metode LSTM dibandingkan dengan metode RNN yaitu, LSTM dapat mengingat data yang bersifat *time series* atau data dengan informasi *long term dependency* dan LSTM dapat menyimpan informasi terdahulu menggunakan sel yang terdapat pada LSTM. Terdapat 3 jenis *gate* pada LSTM yaitu *forget gate*, *input gate*, dan *output gate*. *Forget gate* merupakan gerbang yang memutuskan bagaimana menghapus informasi dari sel. *Input gate* merupakan gerbang yang menentukan nilai dari input yang akan di *update* dalam *state* memori. *Output gate* adalah gerbang yang memutuskan bagaimana menghasilkan *output* setelah memasuki memori sel[10].

Denormalisasi data dimana nilai hasil prediksi akan dikembalikan kedalam *range* sesungguhnya untuk mendapatkan nilai yang diharapkan dan dievaluasi dari model hasil evaluasi. Data asli yang dinormalisasi, dikembalikan ke data yang sebenarnya sehingga hasil perkiraan atau prediksi saat ini dapat ditemukan. Rumus denormalisasi pada range [0, 1] adalah sebagai berikut.

$$x_t = y(x_{max} - x_{min}) + x_{min} \tag{1}$$

Dimana pada persamaan (1) x_t merupakan nilai data asli, y hasil output, x_{max} ialah nilai maksimal data aktual, dan x_{min} adalah nilai minimal data aktual[8].

Penelitian oleh Lestari dan Irawan (2019) berjudul "Long Short-Term Memory Neural Network for Rainfall Prediction in Jakarta", penelitian ini menggunakan Long Short-Term Memory (LSTM), salah satu jenis RNN, untuk memprediksi curah hujan di Jakarta. Hasilnya menunjukkan bahwa LSTM dapat digunakan untuk memprediksi curah hujan dengan akurasi yang baik[11].


Penelitian oleh Khumaidi, Ali dkk. (2019) dengan judul "Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung" penelitian ini menunjukkan bahwa model menghasilkan tingkat akurasi cukup baik untuk 3 parameter (suhu, kelembaban, ISPU). Hal ini ditunjukkan dengan nilai RMSE prediksi yang lebih kecil dari nilai standar uji deviasi dataset[8].

Penelitian selanjutnya dilakukan oleh Andre dan Teny Handhayani (2024) berjudul "Implementasi Algoritma LSTM untuk Memprediksi Temperatur di Wilayah Ternate Maluku Utara", penelitian ini menunjukkan hasil prediksi bahwa Long Short Tern Memory (LSTM) sangat baik jika digunakan untuk melakukan prediksi, dalam kasus ini adalah prediksi temperature yang dibuktikan dengan nilai hasil evaluasi MAPE, MAE, RMSE, MSE yang cukup rendah dan menunjukkan bahwa tingkat akurasi dari prediksi cukup baik serta jumlah kesalahan yang dikatakan rendah[12].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Alur penelitian perkiraan suhu di Kota Mataram menggunakan algoritma LSTM disajikan pada gambar 1 berikut ini.



Gambar 1. Alur penelitian model perkiraan suhu Kota Mataram

Alur penelitian secara umum dapat dilihat pada Gambar 1 dimana proses awal dimulai dengan pengumpulan data dan normalisasi data suhu yang selanjutnya menghasilkan data training. Setelah itu proses pembuatan model LSTM dan dilakukan training model sampai terbentuk sebuah model LSTM untuk dilakukan pengujian. Jika model berjalan sesuai dengan skenario akan dilanjutkan dengan denormalisasi data lalu dilakukan evaluasi model LSTM menggunakan RMSE sehingga didapatkan model LSTM terbaik[13].

Data suhu (dataset) dibagi dua selama proses pelatihan yaitu data training dan data pengujian, 90% data digunakan untuk training dan 10% data digunakan untuk pengujian. Tujuannya adalah untuk memastikan bahwa model yang dilatih mendapatkan performa prediksi yang optimal[14].

2.2 Pengumpulan dan Pengolahan Data

Penelitian ini menggunakan data suhu harian yang diperoleh dari situs <https://power.larc.nasa.gov/data-access-viewer/> dalam format .csv dari tanggal 1 januari 2014 hingga 31 Desember 2023 (selama 108 bulan) di kota Mataram yang ditampilkan pada Tabel berikut ini.

Tabel 1. Sampel data suhu harian Kota Mataram Januari-Desember 2014

| Tanggal | Rata-Rata Suhu Harian (⁰ C) |
|------------|---|
| 01-01-2014 | 25.38 |
| 02-01-2014 | 25.42 |
| 03-01-2014 | 26.22 |
| ... | ... |
| 29-12-2014 | 26.65 |
| 30-12-2014 | 26.99 |
| 31-12-2014 | 26.41 |

Data pada Tabel 1 diolah sehingga berbentuk matriks satu dimensi dengan dua kolom berupa Date dan Temp dengan n baris sesuai jumlah data suhu dari tahun 2014 sampai tahun 2023. Pada saat normalisasi data, kolom Date digunakan sebagai indeks agar memudahkan model LSTM untuk membaca data tersebut.

Tabel 2. Perhitungan data suhu Kota Mataram

| Perhitungan | Nilai |
|--------------------|----------------------|
| Count | 3652 |
| Mean | 26.673256 |
| Standard Deviation | 1.038586 |
| Minimum | 23.62 ⁰ C |
| 25% Data | 25.93 ⁰ C |
| 50% Data | 26.64 ⁰ C |
| 75% Data | 27.36 ⁰ C |
| Maksimum | 30.08 ⁰ C |

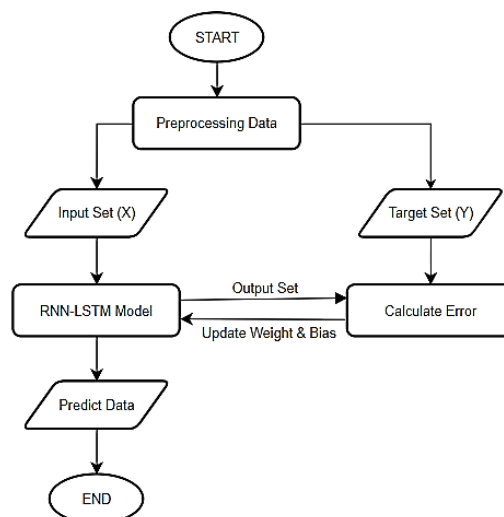
Sebelum digunakan sebagai data latih dan data uji kita mempelajari data tersebut lebih dalam dengan mencari nilai *count*, *mean*, *standard deviation*, nilai data paling kecil (minimum), nilai data paling besar (maksimum) dan sebaran data seperti yang disajikan pada Tabel 2.

2.3 Pelatihan Model LSTM

Root Mean Square Error (RMSE) digunakan untuk menghitung besaran error dalam memprediksi suatu data. RMSE menghitung perbedaan antara nilai sesungguhnya dan nilai yang diharapkan dan membagi hasil total penjumlahan yang diperoleh dengan banyaknya waktu prediksi dan menarik akarnya. Perhitungan RMSE dapat dilihat pada persamaan berikut ini[15].

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

Berdasarkan persamaan (2) *n* merupakan banyaknya data, \hat{y} nilai hasil prediksi, dan y_i nilai data sebenarnya. Pelatihan model LSTM dengan cara menghitung RMSE, ketika data output tidak sesuai dengan data target maka muncul nilai kesalahan (RMSE). Hasil kesalahan ini digunakan untuk memperbarui nilai bobot yang ada. Diperlukan sebuah algoritma optimasi untuk mengubah dan memperbaiki bobot yang ada. Algoritma optimasi yang digunakan adalah RMSProp *optimizer*[16]. Proses ini berlangsung sebanyak iterasi yang diinginkan.



Gambar 2. Flowchart proses pelatihan model LSTM

Pada Gambar 2 dapat dijelaskan alur pelatihan model LSTM dimulai dengan preprocessing data, kemudian data yang dihasilkan nantinya akan dibagi menjadi dua jenis yaitu input set (x) dan target set (y). data input set (x) akan di proses model LSTM dan akan dibandingkan dengan data target set (y) untuk dihitung RMSE nya. Selanjutnya model akan memprediksi data suhu yang merupakan tahap akhir dari proses pelatihan ini[17].

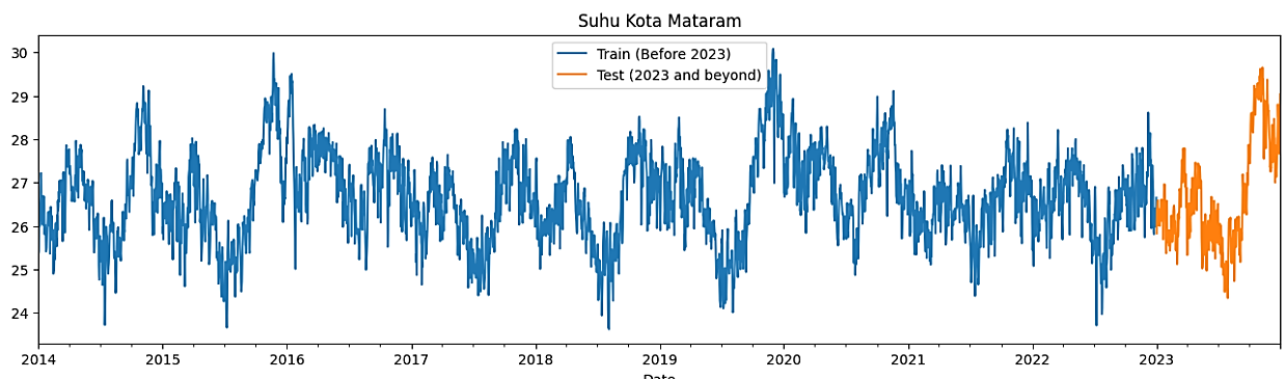
Data yang digunakan selama proses pelatihan dibagi menjadi dua macam yaitu data training dan data validasi, 90% data digunakan untuk training dan 10% data digunakan untuk validasi. Tujuannya adalah untuk memastikan bahwa model yang dilatih mendapatkan performa prediksi yang optimal.

3. HASIL DAN PEMBAHASAN

Data yang digunakan pada penelitian ini berupa data suhu kota mataram pada Tabel 1. Pengujian dilakukan dengan melakukan konfigurasi *epoch* yang berbeda dan menggunakan *batch size* 32. konfigurasi *epoch* yang digunakan yaitu 10, 20, 30, 40, 50 dan 100 yang bertujuan untuk menghasilkan model LSTM yang bekerja paling optimal dalam memprediksi suhu khususnya di Kota Mataram.

3.1 Pembahasan

Sebaran data yang digunakan pada penelitian ini setelah di buatkan plot. Untuk data latih berkisar antara tahun 2014 sampai 2022, untuk data uji menggunakan data suhu Kota Mataram tahun 2023. Untuk lebih jelasnya dapat dilihat pada gambar berikut ini.



Gambar 3. Plot sebaran data yang digunakan untuk model LSTM prediksi suhu Kota Mataram

Berdasarkan Gambar 3 dapat diketahui bahwa data pada penelitian ini dibagi menjadi dua yaitu data latih dan data uji. Hasil pengujian berdasarkan *epoch* yang berbeda untuk data tersebut menggunakan algoritma LSTM ditampilkan pada Tabel berikut ini.

Tabel 3. Perhitungan RMSE model LSTM dengan *epoch* yang berbeda

| <i>Epoch</i> | <i>Batch Size</i> | Jumlah <i>Layer</i> | RMSE |
|--------------|-------------------|---------------------|------|
| 5 | 32 | 2 | 0.27 |
| 10 | 32 | 2 | 0.18 |
| 20 | 32 | 2 | 0.13 |
| 30 | 32 | 2 | 0.13 |
| 40 | 32 | 2 | 0.13 |
| 50 | 32 | 2 | 0.13 |
| 100 | 32 | 2 | 0.13 |

Berdasarkan Tabel 3 dapat kita ketahui bahwa model LSTM yang sudah di training memiliki nilai RMSE paling kecil pada *epoch* 20 sampai *epoch* 100 yaitu sebesar 0.13. Sehingga penulis digunakan *epoch* 50 untuk pengujian model dengan pertimbangan mengambil jumlah epoch pertengahan di antara epoch yang memiliki nilai RMSE yang sama.

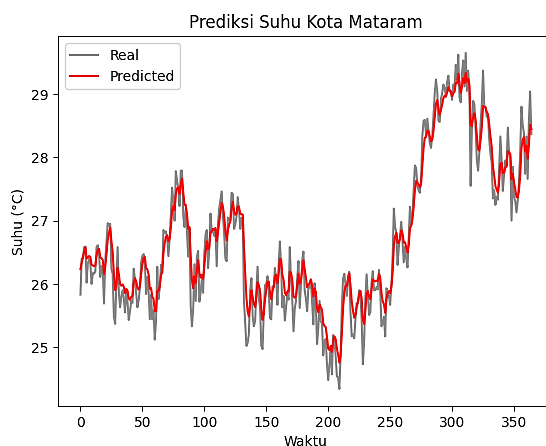
3.2 Hasil Uji Model LSTM

Pengujian model LSTM yang sudah di training menggunakan data suhu Kota Mataram tahun 2023. Pengujian dilakukan dengan memprediksi suhu harian dan dibandingkan dengan suhu sebenarnya untuk melihat Tingkat akurasi perkiraan suhu yang dihasilkan oleh model yang dibuat. Model yang digunakan adalah model yang paling optimal berdasarkan hasil training sebelumnya, yaitu model yang memiliki nilai RMSE paling kecil seperti yang ditunjuk pada Tabel 3.

Tabel 4. Uji coba model LSTM untuk prediksi suhu Kota Mataram


| Tanggal | Data Suhu Sebenarnya | Data Suhu Prediksi |
|------------|----------------------|--------------------|
| 01-01-2023 | 25.83 | 25.849903 |
| 02-01-2023 | 26.40 | 26.460327 |
| 03-01-2023 | 26.42 | 26.385645 |
| 04-01-2023 | 26.58 | 26.533895 |
| 05-01-2023 | 26.59 | 26.523861 |
| ... | ... | ... |
| 27-12-2023 | 28.33 | 28.231138 |
| 28-12-2023 | 27.66 | 27.578842 |
| 29-12-2023 | 28.56 | 28.464117 |
| 30-12-2023 | 29.04 | 28.758707 |
| 31-12-2023 | 28.37 | 28.141682 |

Pada Tabel 4 dapat kita ketahui tingkat akurasi perkiraan suhu pada tahun 2023 cukup tinggi dengan hanya memiliki persentase *error* sebesar 0.04% dengan tingkat akurasi sebesar 99.96%. Hasil plot untuk perkiraan suhu Kota Mataram pada tahun 2023 ditampilkan pada gambar-gambar berikut ini berdasarkan jumlah *epoch* yang digunakan untuk training data.




Gambar 4. Plot hasil prediksi suhu *epoch* 5

Berdasarkan Gambar 4 grafik prediksi dan grafik data sebenarnya sedikit menjauh, hal ini terjadi karena pada *epoch* 5 model LSTM yang dibuat memiliki angka RMSE sebesar 0.27 yang merupakan angka paling besar dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi yang lebih rendah di dibandingkan *epoch* lainnya yang digunakan dalam penelitian ini.




Gambar 5. Plot hasil prediksi suhu *epoch* 10

Berdasarkan Gambar 5 grafik prediksi dan grafik data sebenarnya sedikit menjauh namun lebih rapat kalau dibandingkan dengan epoch 5, hal ini terjadi karena pada *epoch* 10 model LSTM yang dibuat memiliki angka RMSE sebesar 0.18 yang merupakan angka paling besar kedua dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi yang lebih rendah kedua di dibandingkan *epoch* lainnya yang digunakan dalam penelitian ini.




Gambar 6. Plot hasil prediksi suhu *epoch* 20

Berdasarkan Gambar 6 grafik prediksi dan grafik data sebenarnya sangat rapat, bahkan di beberapa titik samapi bersinggungan, hal ini terjadi karena pada *epoch* 20 model LSTM yang dibuat memiliki angka RMSE sebesar 0.13 yang merupakan angka paling kecil dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi paling tinggi dalam penelitian ini.



Gambar 7. Plot hasil prediksi suhu *epoch* 30

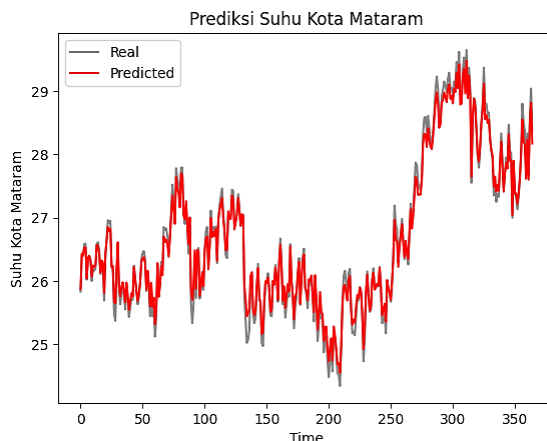
Berdasarkan Gambar 7 grafik prediksi dan grafik data sebenarnya sangat rapat, bahkan di beberapa titik samapi bersinggungan, hal ini terjadi karena pada *epoch* 30 model LSTM yang dibuat memiliki angka RMSE sebesar 0.13 yang merupakan angka paling kecil dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi paling tinggi dalam penelitian ini.



Gambar 8. Plot hasil prediksi suhu *epoch* 40

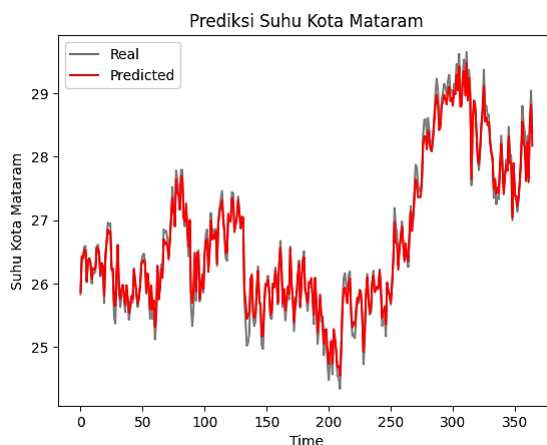
Berdasarkan Gambar 8 grafik prediksi dan grafik data sebenarnya sangat rapat, bahkan di beberapa titik samapi bersinggungan, hal ini terjadi karena pada *epoch* 40 model LSTM yang dibuat memiliki angka RMSE

sebesar 0.13 yang merupakan angka paling kecil dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi paling tinggi dalam penelitian ini.



Gambar 9. Plot hasil prediksi suhu *epoch* 50

Berdasarkan Gambar 9 dapat dilihat bahwa grafik prediksi dan grafik data sebenarnya sangat rapat, bahkan di beberapa titik samapi bersinggungan, hal ini terjadi karena pada *epoch* 50 model LSTM yang dibuat memiliki angka RMSE sebesar 0.13 yang merupakan angka paling kecil dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi paling tinggi dalam penelitian ini.



Gambar 10. Plot hasil prediksi suhu *epoch* 100

Berdasarkan Gambar 10 dapat dilihat bahwa grafik prediksi dan grafik data sebenarnya sangat rapat, bahkan di beberapa titik samapi bersinggungan, hal ini terjadi karena pada *epoch* 100 model LSTM yang dibuat memiliki angka RMSE sebesar 0.13 yang merupakan angka paling kecil dari semua *epoch* yang digunakan. Artinya prediksi yang dihasilkan memiliki tingkat akurasi paling tinggi dalam penelitian ini.

4. KESIMPULAN

Penelitian ini mengembangkan model prediksi suhu menggunakan algoritma Long Short-Term Memory (LSTM) yang melalui beberapa tahap penting, mulai dari pengumpulan dan normalisasi data hingga evaluasi model. Data yang diperoleh diolah dengan cara normalisasi dan dibagi menjadi dua bagian, yaitu data latih dan data uji. Model LSTM kemudian dibangun dengan menetapkan parameter seperti jumlah epoch, layer, dan batch size yang optimal untuk prediksi suhu. Penelitian ini mengevaluasi model menggunakan metode Root Mean Square Error (RMSE) untuk mengukur tingkat keakuratan. Hasil penelitian menunjukkan bahwa dua parameter utama, yaitu epoch dan batch size, memiliki pengaruh signifikan terhadap performa model. Pengujian dilakukan dengan variasi epoch sebesar 5, 10, 20, 30, 40, 50, dan 100, sementara batch size ditetapkan pada 32. Algoritma LSTM yang digunakan memanfaatkan optimizer RMSProps, yang memberikan akurasi prediksi terbaik ketika batch size bernilai 32 dan epoch diatur pada 20, 30, 40, 50, atau 100. Pada konfigurasi ini, model berhasil mencapai nilai RMSE sebesar 0.13 dengan tingkat akurasi sebesar 99.96% dalam memprediksi suhu di Kota Mataram untuk tahun 2023, serta error persentase yang sangat rendah, hanya 0.04%. Dengan demikian, model prediksi suhu berbasis LSTM ini terbukti sangat akurat dan dapat diandalkan dalam mendukung analisis data cuaca di masa depan.

REFERENCES

- [1] T. Lattifa, "Model Prediksi Cuaca Menggunakan Metode LSTM," *JITTER - J. Ilm. Teknol. dan Komput.*, vol. 3, 2022.
- [2] S. Hidayatullah and A. Cherid, "Prediksi Temperatur Cuaca di Negara Norwegia Menggunakan Metode LSTM," *Simkom*, vol. 8, no. 2, pp. 187–198, 2023, doi: 10.51717/simkom.v8i2.192.
- [3] N. K. Manaswi, *Deep Learning with Application Using Python*. CA: Apress, 2018.
- [4] F. M. Madjid, "Perbandingan prediksi visibility menggunakan LSTM dan MLP di Bandara Sultan Mahmud Badaruddin II Palembang," *JSI J. Sist. Inf.*, vol. 14, no. 1, pp. 2497–2507, 2022, doi: 10.18495/jsi.v14i1.16798.
- [5] A. Wahyu, D. Adytia, D. Saepudin, and S. Husrin, "Forecasting of Sea Level Time Series using RNN and LSTM Case Study in Sunda Strait," vol. 12, 2021.
- [6] R. Tanjung, A. Listiani, and F. Lestari, "Prediksi Multivariate Time Series Parameter Cuaca Menggunakan Long Short - Term Memory (LSTM)," vol. 2024, no. November 2022, pp. 445–456, 2024.
- [7] A. Hanifa, S. A. Fauzan, and M. Hikal, "Perbandingan Metode LSTM dan GRU (RNN) untuk Klasifikasi Berita Palsu Berbahasa Indonesia," *Din. Rekayasa*, vol. 17, 2021, [Online]. Available: <http://dinarek.unsoed.ac.id/jurnal/index.php/dinarek/article/view/436>
- [8] A. Khumaidi, R. Raafi'udin, and I. P. Solihin, "Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung," *J. Telemat.*, vol. 15, no. 1, pp. 13–18, Dec. 2020, doi: 10.61769/telematika.v15i1.340.
- [9] E. Supriyadi, "Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (LSTM) Weather Parameters Prediction Using Deep Learning Long-Short Term Memory (LSTM)," *J. Meteorol. Dan Geofis.*, vol. 21, no. 21, pp. 56–59, 2019, [Online]. Available: <http://bmgksoft.database.bmkg.go.id>.
- [10] Y. E. N. Nugraha, I. Ariawan, and W. A. Arifin, "Weather Forecast From Time Series Data Using Lstm Algorithm," *J. Teknol. Inf. Dan Komun.*, vol. 14, no. 1, pp. 144–152, 2023, doi: 10.51903/jtikp.v14i1.531.
- [11] D. Lestari and A. Irawan, "Long Short-Term Memory Neural Network for Rainfall Prediction in Jakarta," 2019.
- [12] H. Andre and T. Handhayani, "Implementasi Algoritma LSTM untuk Memprediksi Temperatur di Wilayah Ternate Maluku Utara," *J. Esensi Infokom J. Esensi Sist. Inf. dan Sist. Komput.*, 2024.
- [13] T. L. Nguyen and C. Liu, "LSTM-Based Model for Temperature Prediction in Agricultural Smart Farms," *IEEE Trans. Comput. Soc. Syst.*, vol. 8, 2021, doi: <https://doi.org/10.1109/TCSS.2021.3068257>.
- [14] X. Yin and G. Leng, "Modelling global impacts of climate variability and trend on maize yield during 1980–2010," *Int. J. Climatol.*, vol. 41, no. S1, Jan. 2021, doi: 10.1002/joc.6792.
- [15] W. Winata, "Prakira Suhu Udara Rata-Rata Kota-Kota Besar Dunia Menggunakan Metode Long Short-Term Memory," 2018, [Online]. Available: [repository.usu.ac.id/bitstream/123456789/30230/4/Chapter II.pdf](https://repository.usu.ac.id/bitstream/123456789/30230/4/Chapter%20II.pdf)
- [16] A. Jain and R. Singh, "A Comparative Study of Machine Learning Algorithms for Air Pollution Prediction Using LSTM and GRU," *Environ. Sci. Pollut. Res.*, vol. 30, 2024, doi: <https://doi.org/10.1007/s11356-022-22340-6>.
- [17] L. N. I. Afida, I. Putra, I. Azizah, S. Nabawi, and A. Alifia, "Forecasting Temperature Menggunakan LSTM," *Pembelajaran Mesin Lanjut*, 2022, [Online]. Available: www.wunderground.com.