

**PERAMALAN SUHU UDARA DI KABUPATEN MALANG  
MENGGUNAKAN *LONG SHORT-TERM MEMORY* (LSTM)**

**SKRIPSI**

**OLEH:  
ALWI  
NIM. 210601110015**



**PROGRAM STUDI MATEMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG  
2025**

**PERAMALAN SUHU UDARA DI KABUPATEN MALANG  
MENGGUNAKAN *LONG SHORT-TERM MEMORY (LSTM)***

**SKRIPSI**

**Diajukan Kepada  
Fakultas Sains dan Teknologi  
Universitas Islam Negeri Maulana Malik Ibrahim Malang  
untuk Memenuhi Salah Satu Persyaratan dalam  
Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh  
ALWI  
NIM. 210601110015**

**PROGRAM STUDI MATEMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG  
2025**

**PERAMALAN SUHU UDARA DI KABUPATEN MALANG  
MENGGUNAKAN *LONG SHORT-TERM MEMORY* (LSTM)**

**SKRIPSI**

**Oleh  
Alwi  
NIM. 210601110015**

**Telah Disetujui Untuk Diuji**

**Malang, 28 Mei 2025**

**Dosen Pembimbing I**

  
**Prof. Dr. H. Sri Harini, M.Si.  
NIP. 19731014 200112 2 002**

**Dosen Pembimbing II**

  
**Mohammad Nafe Jauhari, M.Si.  
NIPPK. 19870218 202321 1 018**



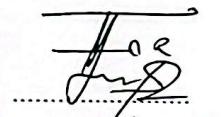
**PERAMALAN SUHU UDARA DI KABUPATEN MALANG  
MENGGUNAKAN *LONG SHORT-TERM MEMORY* (LSTM)**

**SKRIPSI**

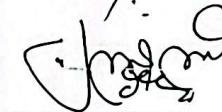
Oleh  
Alwi  
**NIM. 210601110015**

Telah Dipertahankan di Depan Pengaji Skripsi  
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan  
untuk Memperoleh Gelar Sarjan Matematika (S.Mat)  
Tanggal 17 Juni 2025

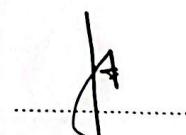
Ketua Pengaji : Dr. Fachrur Rozi, M.Si.



Anggota Pengaji 1 : Ria Dhea Layla Nur Karisma, M.Si.



Anggota Pengaji 2 : Prof. Dr. Hj. Sri Harini, M.Si.



Anggota Pengaji 3 : Mohammad Nafie Jauhari, M.Si.



## PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Alwi  
NIM : 210601110015  
Program Studi : Matematika  
Fakultas : Sains dan Teknologi  
Judul Skripsi : Peramalan Suhu Udara di Kabupaten Malang  
Menggunakan *Long Short-Term Memory* (LSTM)

Menyatakan dengan sebenarnya bahwa skripsi yang saya tulis benar-benar merupakan hasil karya sendiri, bukan merupakan pengambilan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan dan pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka. Apabila di kemudian hari terbukti atau dapat dibuktikan skripsi ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 17 Juni 2025

Yang membuat pernyataan,



Alwi  
NIM. 210601110015

## **MOTO**

“Percayalah, disaat kamu ikhlas dengan keadaanmu, disitulah Allah SWT merencanakan kebahagiaan untukmu. Allah SWT mampu mengubah situasi paling terpuruk menjadi momen terbaik dalam hidupmu.”

- K.H. Maimoen Zubair

## **PERSEMBAHAN**

Segala puji dan syukur kehadirat Allah SWT atas limpahan rahmat, taufik, dan hidayah yang telah diberikan kepada penulis dalam menyelesaikan skripsi ini. Dengan segenap cinta dan ketulusan, penulis persembahkan skripsi ini kepada:

Kedua orang tua, bapak Sugiono dan Ibu Nanik Sri Handayani. Sumber kekuatanku, cahaya dalam setiap langkahku. Terima kasih atas cinta yang tak bersyarat, doa yang tak pernah putus, dan pengorbanan yang tak terhitung. Dalam setiap detak jantungku, ada namamu yang kusebut dalam diam. Skripsi ini hanyalah secuil balasan dari segala yang telah kalian beri, namun semoga menjadi bukti kecil bahwa anakmu terus berjuang, sebagaimana kalian selalu ajarkan.

Untuk diri sendiri, Alwi, yang telah melewati begitu banyak badai dalam diam. Untuk setiap malam yang penuh kegelisahan, untuk pagi-pagi yang dipaksa tetap kuat, untuk langkah-langkah yang sempat goyah namun tak pernah benar-benar menyerah. Terima kasih, karena tak menyerah. Terima kasih, karena tetap percaya bahwa Allah tidak pernah tidur, bahwa setiap tetes keringat dan air mata tak pernah sia-sia di mata-Nya. Teruslah melangkah, dengan rendah hati kepada bumi, dan hati yang selalu menengadah ke langit. Karena selama semesta masih berputar, perjalanan seorang pejuang takkan pernah benar-benar selesai.

## KATA PENGANTAR

*Assalamu'alaikum Warahmatullahi Wabarakatuh*

Segala puji dan syukur penulis panjatkan kepada Allah SWT atas segala rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Peramalan Suhu Udara di Kabupaten Malang Menggunakan *Long Short-Term Memory (LSTM)*”. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Matematika di Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Pada penyusunan skripsi ini, penulis mendapatkan banyak bimbingan, bantuan, dukungan, dan masukan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. H. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Mualana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Elly Susanti, M.Sc., selaku ketua Program Studi Matematika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Prof. Dr. Hj. Sri Harini, M.Si., selaku dosen pembimbing I yang telah memberikan berbagai pengetahuan, pengalaman, nasihat, motivasi, serta arahan selama proses penyusunan srikpsi ini.
5. Mohammad Nafie Jauhari, M.Si., selaku dosen pembimbing II yang telah memberikan arahan dan masukan yang sangat bermanfaat dalam penulisan skripsi ini.
6. Dr. Fachrur Rozi, M.Si., selaku ketua penguji dalam ujian skripsi yang telah memberikan arahan, nasihat, dan saran yang bermanfaat kepada penulis dalam menyelesaikan skripsi ini.
7. Ria Dhea Layla Nur Karisma, M.Si., selaku anggota penguji I dalam ujian skripsi yang telah memberikan bimbingan, nasihat, dan saran yang bermanfaat kepada penulis dalam menyelesaikan skripsi ini.

8. Seluruh dosen Program Studi Matematika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang, yang telah mendidik dan membimbing penulis selama masa perkuliahan.
9. Bapak dan Ibu tercinta, Sugiono dan Nanik Sri Handayani, terima kasih yang sebesar-besarnya atas segala doa, arahan, motivasi, kasih sayang, serta dukungan baik moral maupun material yang telah diberikan. Segala bentuk dukungan tersebut menjadi sumber inspirasi dan kekuatan bagi penulis dalam menyelesaikan skripsi ini.
10. Keluarga kakak penulis yang tersayang, Edi, Puspita Sari, Abi, dan Adel, yang selalu memberikan motivasi, semangat, dan dukungan kepada penulis yang sangat berarti.
11. Teman-teman TEOREMA Program Studi Matematika Angkatan 2021 yang senantiasa memberikan semangat kepada penulis.

Semoga Allah SWT memberikan balasan atas segala bantuan dan kebaikan yang telah diberikan kepada penulis. Penulis menyadari masih terdapat kekurangan dalam penyusunan skripsi ini. Penulis berharap dapat memberikan manfaat bagi pembaca serta menjadi referensi untuk penelitian lanjutan.

Malang, 8 Mei 2025

Penulis

## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>HALAMAN PENGAJUAN .....</b>	<b>ii</b>
<b>HALAMAN PERSETUJUAN .....</b>	<b>iii</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>iv</b>
<b>PERNYATAAN KEASLIAN TULISAN .....</b>	<b>v</b>
<b>MOTO .....</b>	<b>vi</b>
<b>PERSEMBAHAN.....</b>	<b>vii</b>
<b>KATA PENGANTAR.....</b>	<b>viii</b>
<b>DAFTAR ISI .....</b>	<b>x</b>
<b>DAFTAR TABEL .....</b>	<b>xii</b>
<b>DAFTAR GAMBAR .....</b>	<b>xiii</b>
<b>DAFTAR SIMBOL .....</b>	<b>xiv</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xv</b>
<b>ABSTRAK .....</b>	<b>xvi</b>
<b>ABSTRACT .....</b>	<b>xvii</b>
<b>مستخلص البحث.....</b>	<b>xviii</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	6
1.3 Tujuan Penelitian.....	6
1.4 Manfaat Penelitian.....	6
1.5 Batasan Masalah.....	7
1.6 Definisi Istilah .....	8
<b>BAB II KAJIAN TEORI .....</b>	<b>10</b>
2.1 Teori Pendukung .....	10
2.1.1 <i>Time Series</i> .....	10
2.1.2 Peramalan .....	11
2.1.3 <i>Preprocessing Data</i> .....	12
2.1.4 <i>Long Short-Term Memory (LSTM)</i> .....	15
2.1.5 Optimasi RMSProp .....	22
2.1.6 <i>Epoch</i> .....	24
2.1.7 Denormalisasi .....	25
2.1.8 <i>Mean Absolute Percentage Error (MAPE)</i> .....	26
2.1.9 <i>Root Mean Square Error (RMSE)</i> .....	27
2.1.10 Suhu Udara .....	27
2.2 Peramalan Menurut Pandangan Islam.....	28
2.3 Kajian Penelitian dengan Teori Pendukung .....	30
<b>BAB III METODE PENELITIAN .....</b>	<b>32</b>
3.1 Jenis Penelitian.....	32
3.2 Data dan Sumber Data.....	32
3.3 Tahapan Penelitian .....	32
3.4 Diagram Alir Penelitian.....	36
<b>BAB IV HASIL DAN PEMBAHASAN.....</b>	<b>38</b>
4.1 Statistika Deskriptif.....	38
4.2 <i>Pre-Processing</i> .....	40

4.2.1	Data <i>Cleaning</i> .....	40
4.2.2	Normalisasi.....	43
4.2.3	Segmentasi Data .....	45
4.2.4	Partisi Data .....	45
4.3	Konstruksi Model LSTM .....	46
4.4	Perhitungan Manual LSTM.....	48
4.5	Perhitungan Optimasi RMSProp.....	60
4.6	Denormalisasi.....	67
4.7	Analisis Hasil Perbandingan Parameter Model LSTM .....	67
4.8	Peramalan Suhu Udara .....	70
4.9	Integrasi Keislaman.....	76
<b>BAB V</b>	<b>PENUTUP</b> .....	<b>79</b>
5.1	Kesimpulan.....	79
5.2	Saran.....	80
<b>DAFTAR PUSTAKA</b> .....	<b>81</b>	
<b>LAMPIRAN</b> .....	<b>84</b>	
<b>RIWAYAT HIDUP</b> .....	<b>107</b>	

## DAFTAR TABEL

Tabel 2.1 Kategori Nilai MAPE.....	27
Tabel 3.1 Parameter Konstruksi Model LSTM .....	34
Tabel 4.1 Statistika Deskriptif.....	38
Tabel 4.2 <i>Output Cek Missing Value</i> .....	40
Tabel 4.3 <i>Output Normalisasi Data</i> .....	44
Tabel 4.4 Model LSTM yang Terbentuk .....	47
Tabel 4.5 Inisialisasi Acak Bobot dan Bias .....	48
Tabel 4.6 Hasil Perbandingan Parameter Variasi <i>Batch Size</i> dan Variasi <i>Epoch</i> .....	68

## DAFTAR GAMBAR

Gambar 2.1 Arsitektur LSTM .....	15
Gambar 2.2 Arsitektur LSTM <i>Forget Gate</i> .....	16
Gambar 2.3 Arsitektur LSTM <i>Input Gate</i> .....	18
Gambar 2.4 Arsitektur LSTM <i>Cell State</i> .....	20
Gambar 2.5 Arsitektur LSTM <i>Output Gate</i> .....	21
Gambar 2.6 Grafik <i>Overfitting</i> , Optimum, <i>Underfitting</i> dari Jumlah <i>Epoch</i> ..	25
Gambar 3.1 Diagram Alir Penelitian.....	37
Gambar 4.1 Grafik Suhu Udara Harian di Kabupaten Malang.....	39
Gambar 4.2 Ilustrasi Proses Segmentasi .....	45
Gambar 4.3 Grafik Perbandingan Hasil Prediksi Dengan Data Aktual .....	70
Gambar 4.4 Grafik Peramalan Suhu Minimum 59 Hari ke Depan .....	71
Gambar 4.5 Grafik Peramalan Suhu Maksimum 59 Hari ke Depan .....	72
Gambar 4.6 Grafik Peramalan Suhu Rata-rata 59 Hari ke Depan .....	73
Gambar 4.7 Grafik Data Aktual dan Hasil Peramalan Selama 59 Hari ke Depan .....	75

## DAFTAR SIMBOL

$x_t$	: Vektor <i>input</i> pada langkah waktu $t$ berdimensi $d$ ( $\mathbb{R}^d$ )
$h_t$	: Vektor <i>hidden state</i> berdimensi $m$ ( $\mathbb{R}^m$ ) pada waktu ( $t$ )
$f_t$	: Nilai <i>forget gate</i> pada langkah waktu ( $t$ )
$i_t$	: Nilai <i>input gate</i> pada langkah waktu ( $t$ )
$\tilde{c}_t$	: Nilai kandidat baru yang ditambahkan ke <i>cell state</i>
$c_t$	: Nilai <i>cell state</i> pada langkah waktu ( $t$ )
$o_t$	: Nilai <i>output gate</i> pada langkah waktu ( $t$ )
$y_t$	: Nilai <i>output layer</i> pada langkah waktu ( $t$ )
$\sigma$	: Fungsi aktivasi sigmoid
$\tanh$	: Fungsi aktivasi tangen hiperbolik
$W_f, W_i, W_{\tilde{c}}, W_o$	: Matriks bobot untuk <i>forget</i> , <i>input</i> , <i>output gate</i> , dan <i>candidate cell</i> berukuran $\mathbb{R}^{m \times (m+d)}$
$b_f, b_i, b_{\tilde{c}}, b_o$	: Vektor bias untuk <i>forget</i> , <i>input</i> , <i>output gate</i> , dan <i>candidate cell</i> berdimensi $m$ ( $\mathbb{R}^m$ )
$W_y$	: Matriks bobot untuk <i>output layer</i> berukuran $\mathbb{R}^{m \times d}$
$b_y$	: Vektor bias <i>output layer</i> berdimensi $m$ ( $\mathbb{R}^m$ )
$\eta$	: <i>Learning rate</i> (nilai <i>default</i> = 0.001)
$\gamma$	: <i>Decay rate</i> (laju peluruhan dengan nilai <i>default</i> = 0.9)
$\varepsilon$	: <i>Epsilon</i> (nilai <i>default</i> = $10^{-8}$ )
$g_{W,t}$	: Gradien dari bobot terhadap fungsi <i>loss</i> pada waktu ke- $t$
$g_{b,t}$	: Gradien dari bias terhadap fungsi <i>loss</i> pada waktu ke- $t$
$E[g_W^2]_t$	: Rata-rata bergerak ( <i>moving average</i> ) dari kuadrat gradien bobot pada waktu ke- $t$
$E[g_b^2]_t$	: Rata-rata bergerak ( <i>moving average</i> ) dari kuadrat gradien bias pada waktu ke- $t$
$[h_{t-1}, x_t]$	: Konkatenasi vektor $h_{t-1}$ dan $x_t$ menjadi satu vektor <i>input</i> berdimensi $m + d$ ( $\mathbb{R}^{m+d}$ )

## **DAFTAR LAMPIRAN**

Lampiran 1. Dataset Suhu Udara .....	84
Lampiran 2. <i>Syntax Code</i> Python LSTM .....	98
Lampiran 3. Hasil Penanganan <i>Missing Value</i> .....	103
Lampiran 4. Hasil Normalisasi Data.....	104
Lampiran 5. Perhitungan MAPE Suhu Udara.....	105
Lampiran 6. Perhitungan RMSE Suhu Udara.....	106

## ABSTRAK

Alwi. 2025. **Peramalan Suhu Udara di Kabupaten Malang Menggunakan *Long Short-Term Memory* (LSTM).** Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Hj. Sri Harini, M.Si. (II) Mohammad Nafie Jauhari, M.Si.

**Kata Kunci:** Peramalan, Suhu Udara, *Long Short-Term Memory* (LSTM).

Negara Indonesia yang beriklim tropis sering mengalami perubahan cuaca yang tidak menentu, salah satunya adalah suhu udara yang fluktuatif. Perubahan suhu ini berdampak signifikan pada berbagai sektor, terutama pertanian di Kabupaten Malang yang merupakan salah satu lumbung pangan. Untuk mengantisipasi dampak tersebut, diperlukan peramalan suhu udara yang akurat. Penelitian ini bertujuan untuk meramalkan suhu udara di Kabupaten Malang menggunakan metode *Long Short-Term Memory* (LSTM), salah satu algoritma *deep learning* yang unggul dalam analisis data deret waktu. Data yang digunakan adalah data suhu udara harian (minimum, maksimum, dan rata-rata) dari BMKG periode 1 Januari 2021 hingga 31 Desember 2024. Model LSTM dibangun melalui beberapa tahapan, yaitu *preprocessing* data, pelatihan model dengan berbagai parameter, dan evaluasi menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa arsitektur model LSTM terbaik diperoleh dengan konfigurasi empat *layer*, 50 *hidden neuron*, *batch size* 16, dan 200 *epoch*. Model ini menghasilkan tingkat akurasi yang sangat dengan RMSE sebesar 1.04 untuk suhu minimum, 1.00 untuk suhu maksimum, dan 0.69 untuk suhu rata-rata. Adapun nilai MAPE untuk suhu minimum, maksimum, dan rata-rata secara berturut-turut sebesar 4.14%, 2.66%, dan 2.16%. Hasil peramalan untuk 59 hari ke depan menunjukkan adanya tren kenaikan suhu secara bertahap, yang dapat menjadi informasi penting bagi pemerintah dan masyarakat dalam mengambil langkah antisipatif.

## ABSTRACT

Alwi. 2025. **Forecasting Air Temperature in Malang Regency Using Long Short-Term Memory (LSTM)**. Thesis. Mathematics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisors: (I) Prof. Dr. Hj. Sri Harini, M.Si. (II) Mohammad Nafie Jauhari, M.Si.

**Keywords:** Forecasting, Air Temperature, *Long Short-Term Memory* (LSTM).

Indonesia, which has a tropical climate, often experiences erratic weather changes, one of which is fluctuating air temperatures. These temperature changes have a significant impact on various sectors, especially agriculture in Malang Regency, which is one of the food barns. To anticipate this impact, accurate air temperature forecasting is needed. This research aims to forecast the air temperature in Malang Regency using the Long Short-Term Memory (LSTM) method, one of the deep learning algorithms that excel in analyzing time series data. The data used is daily air temperature data (minimum, maximum, and average) from BMKG for the period January 1, 2021 to December 31, 2024. The LSTM model is built through several stages, namely data preprocessing, model training with various parameters, and evaluation using Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). The results showed that the best LSTM model architecture was obtained with a configuration of four layers, 50 hidden neuron, batch size 16, and 200 epochs. This model produces a very high level of accuracy with an RMSE of 1.04 for minimum temperature, 1.00 for maximum temperature, and 0.69 for average temperature. The MAPE values for minimum, maximum, and average temperatures are 4.14%, 2.66%, and 2.16%, respectively. The forecasting results for the next 59 days show a gradual upward trend in temperature, which can be important information for the government and the public.

## مستخلص البحث

علوي. ٢٠٢٥. التنبؤ بدرجة حرارة الهواء في مالانج ريجنسي باستخدام الذاكرة قصيرة المدى الطويلة (*LSTM*). البحث العلمي. قسم الرياضيات ، كلية العلوم والتكنولوجيا ، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف: (١) الأستاذة الدكتور الحاجة سري هاريني، الماجستير في العلوم.(٢) محمد نفع جوهري، الماجستير في العلوم.

**الكلمات الأساسية:** التنبؤ ، درجة حرارة الهواء ، الذاكرة الطويلة قصيرة المدى (*LSTM*).

غالباً ما تشهد إندونيسيا ، التي تتمتع بنمط استوائي ، تغيرات مناخية غير منتظمة ، أحدها تقلب درجة حرارة الهواء. هذا التغير في درجة الحرارة له تأثير كبير على مختلف القطاعات ، وخاصة الزراعة في مالانج ريجنسي التي تعد واحدة من حظائر الطعام. لتوقع هذه التأثيرات ، هناك حاجة إلى تنبؤ دقيق بدرجة حرارة الهواء. هدفت هذه الدراسة إلى التنبؤ بدرجة حرارة الهواء في مالانج ريجنسي باستخدام طريقة الذاكرة الطويلة قصيرة المدى (*LSTM*) ، وهي من واحدي خوارزميات التعلم العميق الرائدة في تحليل بيانات السلسلة الزمنية. البيانات المستخدمة هي بيانات درجة حرارة الهواء اليومية (الحد الأدنى والحد الأقصى والمتوسط) من ٣١ ديسمبر ٢٠٢٤ إلى ١ يناير ٢٠٢١. تم بناء نموذج *LSTM* من خلال عدة مراحل ، وهي المعالجة المناسبة للبيانات ، وتدريب النموذج ببيانات مختلفة ، والتقييم باستخدام جذر متوسط الخطأ التربيعي (*RMSE*) ومتوسط النسبة المئوية المطلقة للخطأ (*MAPE*). أظهرت النتائج أنه تم الحصول على أفضل بنية نموذج *LSTM* بتكونه من ٤ طبقات و ٥٠ خلية عصبية وحجم الدفعه ١٦ و ٢٠٠ حقبة. ينتج هذا النموذج مستوى عال جداً من الدقة مع *RMSE* يبلغ ١,٠٠ لدرجة الحرارة الدنيا ، و ١,٠٠ لدرجة الحرارة القصوى ، و ٠,٦٩ لمتوسط درجة الحرارة. كانت قيم *MAPE* لدرجات الحرارة الدنيا والقصوى والمتوسطة ٤,١٤٪ و ٢,٦٦٪ و ٢,١٦٪ على التوالي. ظهرت نتائج التوقعات للأيام الـ ٥٩ القادمة اتجاهها تدريجياً لزيادة درجة الحرارة ، والتي يمكن أن تكون معلومات مهمة للحكومة والجمهور في اتخاذ خطوات استباقية.

## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Negara Indonesia memiliki iklim tropis karena posisinya berada di sekitar garis khatulistiwa. Ciri khas iklim tropis adalah adanya dua musim, yaitu musim kemarau dan musim penghujan. Setiap wilayah di Indonesia memiliki intensitas iklim yang bervariasi. Perbedaan ini dipengaruhi oleh berbagai faktor, seperti posisi geografis, elevasi, kedekatan dengan sumber air, pola angin, temperatur tanah, serta luas area daratan. Cuaca di Indonesia tidak selalu berjalan sesuai pola musiman, sering kali mengalami perubahan mendadak yang disebabkan oleh faktor-faktor yang mempengaruhi kenaikan atau penurunan suhu (Afida dkk., 2021).

Pada masa sekarang, kondisi cuaca di Indonesia terkadang tidak menentu. Kondisi cuaca ini selalu diinformasikan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Berdasarkan data BMKG, suhu udara rata-rata di Indonesia pada periode 1991-2020 tercatat sebesar  $26.7^{\circ}\text{C}$ . Sementara itu, pada tahun 2024, rata-rata suhu udara mencapai  $27.5^{\circ}\text{C}$ , yang menunjukkan adanya anomali peningkatan suhu sebesar  $0.8^{\circ}\text{C}$  (Wicaksono, 2025). Kondisi cuaca sangat berkaitan erat dengan kegiatan manusia, karena keadaan cuaca dapat mempengaruhi keterbatasan dalam kegiatan yang dilakukan oleh manusia.

Kabupaten Malang memiliki iklim tropis dengan kekayaan sumber daya alam yang berlimpah, terutama di bidang pertanian. Menurut Nurhidayat dkk. (2024), perubahan iklim memengaruhi produktivitas pertanian, khususnya di daerah tropis. Pertanian padi, yang menjadi salah satu aktivitas pertanian utama di banyak negara

tropis, tidak hanya mendukung ketahanan pangan, tetapi juga berperan sebagai penggerak ekonomi serta menjaga kelangsungan hidup masyarakat setempat. Namun, dengan perubahan iklim yang semakin jelas dan terasa, pertanian padi kini menghadapi tantangan yang semakin besar dalam mempertahankan produktivitasnya.

Kenaikan suhu udara global juga memiliki dampak besar terhadap pertumbuhan dan perkembangan tanaman padi. Suhu yang terlalu tinggi dapat mengganggu proses fotosintesis, menurunkan hasil produksi dan kualitas panen, serta meningkatkan risiko kerusakan tanaman akibat kekeringan dan suhu yang ekstrem. Selain itu, perubahan suhu juga dapat memengaruhi interaksi antara tanaman padi dengan organisme lain, termasuk hama dan penyakit, yang berpotensi mengancam keberlanjutan produksi pertanian (Nurhidayat dkk., 2024).

Berdasarkan kebutuhan akan informasi cuaca, peramalan cuaca salah satunya suhu udara menjadi penting untuk dilakukan. Metode peramalan merupakan metode yang memanfaatkan data masa lampau untuk memprediksi kondisi di masa depan. *Deep learning* banyak digunakan dalam meramalkan data *time series* karena kemampuannya yang unggul dalam mengenali pola-pola data. Salah satu metode *deep learning* yang bisa digunakan dalam memprediksi data *time series* yaitu *Long Short-Term Memory* (LSTM).

LSTM adalah salah satu algoritma yang efektif untuk analisis deret waktu. Algoritma ini telah terbukti mampu memprediksi data selama beberapa tahun terakhir. Keunggulan utama LSTM adalah kemampuannya untuk mengingat informasi dari urutan jangka panjang, yang sulit dicapai oleh teknik fitur tradisional (Isnain dkk., 2022). Selain itu, LSTM dapat menangani ukuran data yang lebih

besar dengan memanfaatkan seluruh informasi yang tersedia sebagai *input* (Badriyah dkk., 2022).

LSTM merupakan bagian dari jaringan saraf tiruan yang dirancang untuk meniru cara kerja otak manusia, terutama dalam proses berpikir dan mengingat. Dalam Al-Quran, kemampuan manusia untuk berpikir dan mengingat telah dijelaskan dalam Q.S. Ali Imran ayat 191.

الَّذِينَ يَذْكُرُونَ اللَّهَ قِيَامًا وَقُعُودًا وَعَلَى جُنُوبِهِمْ وَيَتَفَكَّرُونَ فِي حَلْقِ السَّمَاوَاتِ وَالْأَرْضِ رَبَّنَا مَا حَلَقْتَ  
هَذَا بِاطِّلَّا سُبْحَنَكَ فَقَنَا عَذَابَ النَّارِ (١٩١)

(Kementerian Agama, 2019)

“(yaitu) orang-orang yang mengingat Allah sambil berdiri, duduk atau dalam keadaan berbaring, dan mereka memikirkan tentang penciptaan langit dan bumi (seraya berkata), ‘Ya Tuhan kami, tidaklah Engkau menciptakan semua ini sia-sia; Mahasuci Engkau, lindungilah kami dari azab neraka.’”. (Q.S. Al-Imron: 191).

Menurut tafsir Ibnu Katsir, yang dimaksud dengan orang-orang berakal adalah mereka yang senantiasa mengingat Allah dalam segala keadaan, baik saat berdiri, duduk, maupun berbaring, serta memikirkan penciptaan langit dan bumi. Mereka juga berdoa memohon perlindungan dari siksa neraka, menunjukkan bahwa mereka adalah orang-orang yang beriman (Kasir, 2014).

Allah menciptakan otak manusia dengan kemampuan luar biasa dalam menyimpan memori. Memori sendiri merupakan proses yang mencakup pengkodean, penyimpanan, serta pengambilan kembali informasi. Terdiri dari berbagai jenis, seperti informasi faktual, sintetik, pengalaman pribadi, dan keterampilan, memori dapat bertahan dalam jangka pendek maupun panjang. Namun, terkadang manusia juga dapat mengalami lupa. Konsep ini kemudian

diadaptasi ke dalam model LSTM, yang memiliki keunggulan dalam menyimpan data dalam jangka waktu yang lebih lama berkat keberadaan *memory cell*.

LSTM dirancang untuk mengingat informasi penting dalam jangka panjang dan melupakan informasi yang tidak relevan. Konsep ini mirip dengan bagaimana manusia yang berakal merenungkan penciptaan langit dan bumi, memilah informasi, dan mengambil pelajaran dari tanda-tanda kebesaran Allah. LSTM membantu mengenali pola data berdasarkan data historis, sehingga dapat memberikan peramalan yang lebih akurat. Seperti halnya manusia yang menggunakan akal untuk memahami ciptaan Allah dan membuat keputusan yang lebih baik. Dengan demikian, baik dalam pemikiran manusia maupun dalam kecerdasan buatan, pemahaman terhadap pola dan pemanfaatannya menjadi faktor utama dalam menghasilkan peramalan yang lebih akurat dalam menghadapi dinamika perubahan lingkungan.

Terdapat penelitian sebelumnya yang mendukung peneliti untuk melakukan penelitian dengan menggunakan metode yang sama yaitu LSTM. Penelitian yang dilakukan oleh Badriyah dkk. (2022) yaitu prediksi curah hujan di Kota Surabaya menggunakan LSTM. Pada penelitian tersebut menggunakan data curah hujan di dua stasiun BMKG Surabaya yaitu stasiun meteorologi perak I dan stasiun meteorologi perak II dari tahun 2015 sampai tahun 2020. Selain menggunakan algoritma LSTM, penelitian Badriyah dkk. juga menggunakan algoritma *Recurrent Neural Network* (RNN) dan *Gated Recurrent Unit* (GRU) untuk membandingkan hasil pengujian prediksi curah hujan di Kota Surabaya. Setelah dilakukan pengujian, didapatkan hasil algoritma LSTM lebih baik dibandingkan algoritma RNN dan GRU dikarenakan nilai akurasi yang dihasilkan memiliki tingkat *error*

yang paling kecil dibandingkan algoritma lainnya. Kemudian penelitian selanjutnya yang dilakukan Firdaus & Paputungan (2022) berfokus pada peramalan curah hujan di Kota Bandung dengan menggunakan metode LSTM. Penelitian tersebut menggunakan data curah hujan yang diperoleh dari BMKG Kota Bandung dari tahun 2017 sampai tahun 2021. Setelah dilakukan pengujian, Hasil yang diperoleh dari penelitian tersebut yaitu menunjukkan bahwa didapatkan nilai uji RMSE sebesar 8.86. Hal tersebut menunjukkan hasil prediksi dikatakan cukup baik karena semakin rendah nilai uji yang diperoleh maka semakin baik tingkat akurasi dari prediksi.

Meskipun metode LSTM telah banyak digunakan dalam peramalan data *time series*, sebagian besar penelitian sebelumnya berfokus pada peramalan curah hujan di wilayah perkotaan seperti Surabaya dan Bandung. Penelitian yang dilakukan oleh Badriyah dkk. (2022) dan Firdaus & Paputungan (2022) menunjukkan bahwa LSTM memiliki akurasi yang tinggi dibandingkan metode lain seperti RNN dan GRU. Namun, penelitian tersebut masih memiliki keterbatasan, yaitu sebagian besar menggunakan satu jenis fitur curah hujan, sedangkan penelitian ini memanfaatkan tiga parameter suhu sekaligus, yaitu suhu minimum, maksimum, dan rata-rata, sebagai fitur *input* dalam model LSTM.

Berdasarkan uraian beberapa penelitian yang telah dijabarkan, dapat disimpulkan bahwa metode *Long Short-Term Memory* (LSTM) telah banyak diterapkan dalam penelitian peramalan dan mampu menghasilkan model yang baik. Dari topik dan permasalahan yang telah diuraikan, maka peneliti berencana untuk melakukan penelitian terkait peramalan suhu udara di Kabupaten Malang menggunakan LSTM. Hasil penelitian ini diharapkan dapat memberikan manfaat

berupa informasi baik bagi masyarakat maupun pemerintah sebagai bahan pertimbangan dalam mempersiapkan apa yang perlu dilakukan dalam mengantisipasi apa yang akan terjadi berdasarkan hasil peramalan.

## **1.2 Rumusan Masalah**

Adapun rumusan masalah pada penelitian ini adalah:

1. Bagaimana arsitektur jaringan paling optimal yang diperoleh dari penerapan metode LSTM pada data suhu udara?
2. Bagaimana tingkat akurasi peramalan yang dihasilkan oleh LSTM dalam meramalkan suhu udara di Kabupaten Malang?
3. Bagaimana hasil peramalan suhu udara di Kabupaten Malang selama 59 hari ke depan menggunakan LSTM?

## **1.3 Tujuan Penelitian**

Adapun tujuan pada penelitian ini adalah:

1. Menganalisis arsitektur jaringan paling optimal yang diperoleh dari penerapan metode LSTM pada data suhu udara.
2. Menganalisis tingkat akurasi peramalan yang dihasilkan oleh LSTM dalam meramalkan suhu udara di Kabupaten Malang.
3. Menganalisis hasil peramalan suhu udara di Kabupaten Malang selama 59 hari ke depan menggunakan LSTM.

## **1.4 Manfaat Penelitian**

Adapun manfaat pada penelitian ini adalah:

1. Bagi Peneliti

Meningkatkan pengalaman implementasi dalam meramalkan suhu udara menggunakan LSTM.

2. Bagi Mahasiswa

- a. Memberikan wawasan tentang peramalan suhu udara menggunakan LSTM.
- b. Sebagai sumber referensi untuk studi selanjutnya serta mengembangkan hasil penelitian ini lebih lanjut

3. Bagi Program Studi

Sebagai referensi pembelajaran dan pengembangan dalam bidang matematika khususnya mata kuliah matematika statistika pada Program Studi Matematika.

## 1.5 Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Pengukuran tingkat akurasi peramalan menggunakan perhitungan *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).
2. Penelitian ini menggunakan tiga fitur variabel yaitu suhu udara minimum, suhu udara maksimum, dan suhu udara rata-rata dengan satuan derajat *celcius* ( $^{\circ}\text{C}$ ).
3. Penelitian ini menggunakan beberapa parameter yaitu, *epoch*, *batch size*, *hidden layer*, *hidden neuron*, *optimizer*, dan fungsi aktivasi.

## 1.6 Definisi Istilah

Beberapa istilah yang digunakan dalam penelitian ini adalah:

- LSTM : Sebuah jenis arsitektur *Recurrent Neural Network* (RNN) yang mampu memproses data *time series* dan dapat menyimpan informasi dalam jangka waktu yang panjang.
- Peramalan : Proses perkiraan sesuatu di masa mendatang berdasarkan data historis
- Time Series* : Sekumpulan data yang dicatat secara berurutan dalam interval waktu tertentu.
- Epoch* : Jumlah iterasi yang dilakukan untuk menjalankan proses *training* model.
- Batch size* : Jumlah sampel data yang diproses oleh model LSTM dalam satu iterasi sebelum pembaruan bobot dilakukan.
- Dropout* : Teknik regularisasi yang digunakan selama pelatihan model LSTM untuk mencegah *overfitting*.
- Layer* : Komponen dasar dalam arsitektur jaringan saraf, termasuk LSTM. Setiap lapisan terdiri dari sekumpulan neuron yang memproses informasi.
- Bias : Nilai tambahan yang dimasukkan ke dalam perhitungan setiap neuron dalam jaringan LSTM

Bobot : Nilai numerik yang digunakan untuk mengukur seberapa besar pengaruh suatu *input* terhadap *output*

## **BAB II**

### **KAJIAN TEORI**

#### **2.1 Teori Pendukung**

##### **2.1.1 *Time Series***

Pengamatan terhadap satu atau lebih variabel yang dilakukan secara berurutan pada interval tertentu disebut *time series* (deret waktu) (Wei, 2006). Analisis deret waktu pertama kali dikemukakan oleh George Box dan Gwillyn Jenkins pada tahun 1976. Analisis deret waktu adalah teknik statistik yang digunakan untuk meramalkan peristiwa di masa mendatang. Analisis deret waktu menetapkan hubungan antara kejadian saat ini dan masa lalu dengan menggunakan data yang telah dihubungkan antar waktu. Ada kemungkinan adanya hubungan antar berbagai dimensi, seperti wilayah atau dimensi lain yang saling terkait, selain hubungan antar deret waktu.

Langkah penting dalam memilih teknik analisis deret waktu yang tepat adalah mengetahui berbagai jenis pola data deret waktu. Ada empat kategori pola data deret waktu (Makridakis dkk., 1993).

1. Ketika nilai data berfluktuasi di sekitar rata-rata yang tetap atau relatif konstan, disebut pola data horizontal.
2. Ketika data menunjukkan peningkatan atau penurunan selama periode waktu tertentu, disebut pola data tren.
3. Ketika data dipengaruhi oleh pergeseran ekonomi terkait siklus bisnis dalam jangka waktu yang lama, disebut pola data siklus.

4. Ketika data berfluktuasi yang berulang setiap periode tertentu, seperti harian, bulanan, atau tahunan, disebut pola data musiman.

### 2.1.2 Peramalan

Peramalan adalah aktivitas yang bertujuan untuk memprediksi kondisi atau peristiwa di masa depan dengan tingkat akurasi setinggi mungkin. Hal ini dilakukan dengan memanfaatkan seluruh informasi yang tersedia secara optimal, termasuk data historis serta pemahaman tentang peristiwa masa depan yang mungkin memengaruhi hasil peramalan tersebut (Hyndman & Athanasopoulos, 2018). Peramalan merupakan proses yang bersifat terus-menerus karena data baru akan selalu tersedia, sehingga model perlu diperbarui dan dinilai secara rutin. Proses ini melibatkan penggunaan data lampau serta memperkirakannya ke masa mendatang dengan bantuan model matematika. Tujuan dilakukannya peramalan yaitu mengurangi ketidakpastian terkait kejadian atau kondisi yang mungkin terjadi di waktu mendatang.

Menurut Montgomery dkk. (2015), proses peramalan diantaranya:

1. *Problem definition* (definisi masalah): membangun pemahaman yang jelas tentang tujuan peramalan dan bagaimana hasil ramalan akan dimanfaatkan.
2. *Data collection* (pengumpulan data): mengumpulkan data yang relevan terkait variabel-variabel yang akan diprediksi.
3. *Data analysis* (analisis data): mengidentifikasi pola dalam data yang akan digunakan untuk analisis. Hal ini dapat dilakukan dengan membuat

representasi visual dari data dan melakukan analisis visual terhadap pola tersebut.

4. *Model selection and fitting* (pemilihan dan pemasangan model): memilih metode peramalan yang paling sesuai dengan karakteristik dan pola data yang telah dianalisis.
5. *Model evaluation* (evaluasi model): menilai kinerja model peramalan yang telah dibangun untuk memastikan apakah model tersebut mampu memberikan prediksi yang akurat dan andal.
6. Menampilkan hasil peramalan: menggunakan model yang telah terpilih untuk menghasilkan prediksi atau ramalan untuk periode waktu mendatang.
7. *Monitoring forecasting model performance* (pemantauan kinerja model peramalan): melakukan pemantauan secara berkala terhadap kinerja model peramalan untuk memastikan bahwa model tetap efektif dan akurat dalam aplikasi nyata.

### 2.1.3 *Preprocessing* Data

*Preprocessing* data merupakan tahap awal yang dilakukan sebelum merancang sistem peramalan. Sebelum digunakan, data yang diperoleh akan melalui tahap *preprocessing* agar data tersebut dapat bekerja dengan optimal (Aprian dkk., 2020). Data akan melewati beberapa proses yaitu data *cleaning*, normalisasi data, dan partisi data.

## 1. Data *cleaning*

Data *cleaning* merupakan tahap pembersihan data dalam proses ini. Data yang bersih dapat mendukung pemilihan model yang lebih optimal serta mengurangi potensi kesalahan yang disebabkan oleh data yang tidak valid atau tidak terstruktur dengan baik. Tahap ini bertujuan untuk menyeleksi dan menghilangkan data yang berpotensi menurunkan akurasi prediksi, sehingga menghasilkan dataset yang lebih rapi dan konsisten untuk dianalisis. Salah satu masalah umum yang sering terjadi pada dataset adalah *missing value*, yaitu nilai yang hilang dalam data (Muhammad & Nurhaida, 2025). Metode yang umum digunakan dalam menangani *missing value* yaitu interpolasi linier. Metode ini dapat diterapkan untuk mengisi nilai yang hilang dalam data *time series* dengan cara menghubungkan dua titik terdekat menggunakan interpolasi garis lurus. Berikut rumus dari interpolasi linier (Gnauck, 2004).

$$x = \frac{x_{k+1} - x_k}{t_{k+1} - t_k} (t - t_k) + x_k \quad (2.1)$$

Keterangan:

- $x_{k+1}$  : Nilai variabel yang diketahui pada waktu  $t_{k+1}$
- $x_k$  : Nilai variabel yang diketahui pada waktu  $t_k$
- $t_k, t_{k+1}$  : Dua waktu yang diketahui
- $t$  : Waktu di mana nilai akan diestimasi

## 2. Normalisasi data

Normalisasi merupakan tahap penting dalam proses ini, karena mampu menghilangkan ketidakakuratan serta ketidaksesuaian dalam data. Fungsi

dari normalisasi adalah untuk mengurangi skala data tanpa mengubah nilainya. Dalam LSTM, normalisasi diperlukan untuk menyesuaikan skala data dengan fungsi sigmoid yang memiliki rentang [0:1], sehingga dapat meminimalisir *error* dan meningkatkan kinerja model (Lubis & Lubis, 2021). Metode normalisasi yang umum digunakan dalam menangani perbedaan besar antar nilai dalam berbagai dataset yaitu *min-max scaling*. Metode ini mengubah nilai asli dalam data menjadi rentang antara 0 dan 1, tanpa mengurangi informasi yang ada dalam dataset. Berikut rumus *min-max scaling* (Elfaladonna dkk., 2024).

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.2)$$

Keterangan:

- $x'$  : Nilai data setelah normalisasi
- $x$  : Nilai data
- $x_{\min}$  : Nilai terendah dalam data
- $x_{\max}$  : Nilai tertinggi dalam data

### 3. Segmentasi data

Segmentasi merupakan proses pemisahan dan pengelompokan data agar sesuai dengan kebutuhan sistem. Proses ini dilakukan dengan membentuk pola deret waktu pada data yang digunakan (Suyudi dkk., 2019).

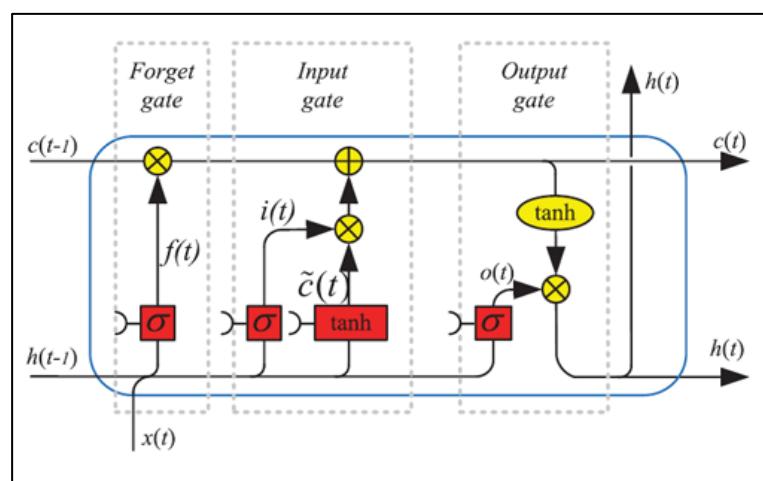
### 4. Partisi data

Partisi data merupakan tahap pembagian dataset menjadi dua bagian yaitu data *training* dan data *testing*. Data *training* merupakan bagian dari dataset

yang digunakan untuk melatih model, sedangkan data *testing* digunakan untuk menguji akurasi atau performa model yang telah dilatih sebelumnya. Pembagian data ini bertujuan untuk memperoleh model dengan akurasi yang optimal (Cahyadi dkk., 2020).

#### 2.1.4 Long Short-Term Memory (LSTM)

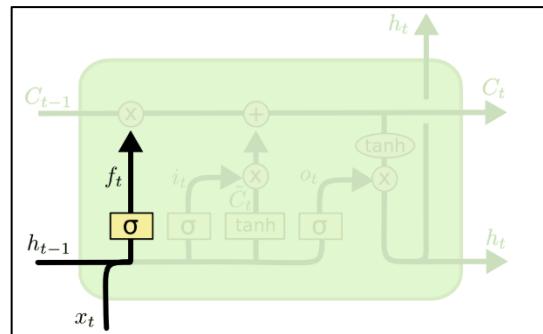
Pada tahun 1997, Hochreiter dan Schmidhuber memperkenalkan konsep LSTM. LSTM, yang sering disebut sebagai jaringan saraf dengan fleksibilitas arsitektur yang tinggi, memungkinkan penyesuaian bentuknya sesuai dengan kebutuhan aplikasinya. Metode ini merupakan pengembangan dari *Recurrent Neural Network* (RNN), yang dirancang khusus untuk mengelola data berurutan, tetapi RNN memiliki kendala seperti hilangnya atau melebarnya gradien. LSTM dikembangkan untuk menangani masalah tersebut dengan mempertahankan informasi jangka panjang dari data sekuensial. Lapisan *input*, lapisan *output*, dan lapisan tersembunyi membentuk arsitektur LSTM, seperti yang terlihat di bawah ini (Wiranda & Sadikin, 2019).



Gambar 2.1 Arsitektur LSTM (Yu dkk., 2019)

Lapisan tersembunyi terdiri dari sel memori, dan setiap sel memiliki tiga gerbang (*gate*) utama, yaitu *input gate*, *forget gate*, dan *output gate*. Fungsi dari *input gate* yaitu mengatur jumlah informasi yang akan disimpan dalam sel memori. Hal ini dilakukan untuk menghindari penyimpanan data yang tidak diperlukan. *Forget gate* berfungsi mengendalikan seberapa banyak informasi yang tetap tersimpan dalam sel memori. Sementara itu, *output gate* menentukan jumlah informasi dari sel memori yang akan digunakan sebagai keluaran (Wiranda & Sadikin, 2019). Berikut penjelasan tentang fungsi gerbang dalam satu sel memori LSTM.

### 1. *Forget Gate*



**Gambar 2.2** Arsitektur LSTM *Forget Gate* (Olah, 2015)

Langkah pertama dalam LSTM yaitu menentukan informasi yang akan dipertahankan atau dibuang dari *memory cell* melalui mekanisme yang disebut *forget gate*. Pada tahap ini, LSTM menerima dua *input* utama, yaitu  $h_{t-1}$  dan  $x_t$ . Kedua vektor tersebut digabungkan menjadi satu vektor melalui operasi konkatensi yang dinotasikan dengan  $[h_{t-1}, x_t]$ . Jika  $h_{t-1} \in \mathbb{R}^m$  dan  $x_t \in \mathbb{R}^d$ , maka hasil konkatensinya adalah vektor berdimensi  $\mathbb{R}^{m+d}$ , di mana  $d$  adalah jumlah fitur *input* dan  $m$  adalah jumlah *hidden neuron*. Vektor hasil konkatenasi ini kemudian dikalikan

dengan bobot, ditambahkan bias, dan dimasukkan ke dalam fungsi aktivasi sigmoid. Hasil dari fungsi *sigmoid* tersebut, yang bernilai antara 0 dan 1, menentukan apakah informasi tersebut akan disimpan (jika mendekati 1) atau dibuang (jika mendekati 0). Berikut rumus perhitungan fungsi *sigmoid* (Buduma & Lacascio, 2017).

$$\text{Sigmoid}(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

Persamaan dari *forget gate* sebagai berikut (Yu dkk., 2019).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.4)$$

Di mana:

$f_t$  : Nilai *forget gate* pada langkah waktu ( $t$ )

$W_f$  : Matriks bobot *forget gate* berukuran  $\mathbb{R}^{m \times (m+d)}$

$\sigma$  : Fungsi aktivasi sigmoid

$h_{t-1}$ : Vektor *hidden state* berdimensi  $m$  ( $\mathbb{R}^m$ ) pada waktu ( $t - 1$ )

$x_t$  : Vektor *input* pada langkah waktu  $t$  berdimensi  $d$  ( $\mathbb{R}^d$ )

$b_f$  : Vektor bias untuk *forget gate* berdimensi  $m$  ( $\mathbb{R}^m$ )

$d$  : Banyaknya fitur *input*

$m$  : Banyaknya *hidden neuron*

Nilai bobot dan bias ditetapkan secara acak oleh sistem pada awal proses, kemudian akan terus disesuaikan selama tahap pelatihan berlangsung. Proses pembaruan nilai bobot dan bias dijelaskan melalui persamaan berikut (Hochreiter & Schmidhuber, 1997).

$$W_{f_{new}} = W_f - \eta \cdot \nabla_{W_f} \quad (2.5)$$

$$b_{f_{new}} = b_f - \eta \cdot \nabla_{b_f} \quad (2.6)$$

Keterangan:

$$\eta : \text{Learning rate}$$

$$\nabla_{W_f} : \sum_{t=1}^{\tau} \delta_{f_t} \cdot ([h_{t-1}, x_t])^T$$

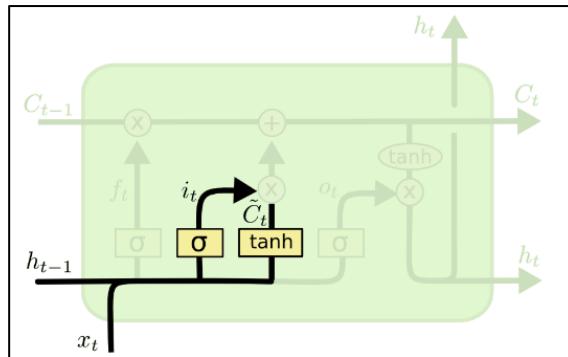
$$\nabla_{b_f} : \sum_{t=1}^{\tau} \delta_{f_t}$$

$$\delta_{f_t} : \delta_{C_t} \odot C_{t-1} \odot f_t \odot (1 - f_t)$$

$$\delta_{C_t} : \delta_{h_t} \odot o_t \odot (1 - \tanh^2(C_t)) + \delta_{C_{t+1}} \odot f_{t+1}$$

$$\delta_{h_t} : W_{fh}^T \delta_{f_{t+1}} + W_{ih}^T \delta_{i_{t+1}} + W_{ch}^T \delta_{c_{t+1}} + W_{oh}^T \delta_{o_{t+1}}$$

## 2. Input Gate



**Gambar 2.3** Arsitektur LSTM *Input Gate* (Olah, 2015)

*Input gate* mengatur seberapa banyak informasi *input* saat ini,  $x_t$ , yang akan disimpan dalam *cell state*,  $C_t$ . Fungsinya adalah untuk menyaring data yang tidak relevan agar tidak masuk ke dalam memori sel. *Input gate* memiliki dua fungsi yaitu menentukan bagian dari keadaan sel yang perlu diperbarui serta memilih nilai yang akan diperbarui melalui lapisan sigmoid. Selanjutnya, sebuah *layer* tanh membuat nilai kandidat baru,  $\tilde{c}_t$ , yang dapat ditambahkan ke *cell state*. Kemudian, *output* dari lapisan *input gate* dan tanh digabungkan untuk memperbarui *cell state*. Persamaan dari *input gate* ( $i_t$ ) dan kandidat nilai baru ( $\tilde{c}_t$ ) sebagai berikut (Yu dkk., 2019).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.7)$$

$$\tilde{c}_t = \tanh(W_{\tilde{c}} \cdot [h_{t-1}, x_t] + b_C) \quad (2.8)$$

Keterangan:

$i_t$  : Nilai *input gate* pada langkah waktu ( $t$ )

$W_i$  : Matriks bobot *input gate* berukuran  $\mathbb{R}^{m \times (m+d)}$

$b_i$  : Vektor bias untuk *input gate* berdimensi  $m$  ( $\mathbb{R}^m$ )

$\tilde{c}_t$  : Nilai kandidat baru yang ditambahkan ke *cell state*

$W_{\tilde{c}}$  : Matriks bobot *candidate cell* berukuran  $\mathbb{R}^{m \times (m+d)}$

$b_C$  : Vektor bias pada *candidate cell* berdimensi  $m$  ( $\mathbb{R}^m$ )

Proses pembaruan nilai bobot dan bias pada *input gate* dan nilai *candidate cell* dijelaskan melalui persamaan yang tercantum pada rumus berikut.

$$W_{i_{new}} = W_i - \eta \cdot \nabla_{W_i} \quad (2.9)$$

$$W_{\tilde{c}_{new}} = W_{\tilde{c}} - \eta \cdot \nabla_{W_{\tilde{c}}} \quad (2.10)$$

$$b_{i_{new}} = W_i - \eta \cdot \nabla_{W_i} \quad (2.11)$$

$$b_{\tilde{c}_{new}} = W_{\tilde{c}} - \eta \cdot \nabla_{W_{\tilde{c}}} \quad (2.12)$$

Keterangan:

$\nabla_{W_i} : \sum_{t=1}^{\tau} \delta_{i_t} \cdot ([h_{t-1}, x_t])^T \cdot$

$\nabla_{W_{\tilde{c}}} : \sum_{t=1}^{\tau} \delta_{\tilde{c}_t} \cdot ([h_{t-1}, x_t])^T$

$\nabla_{b_i} : \sum_{t=1}^{\tau} \delta_{i_t}$

$\nabla_{b_{\tilde{c}}} : \sum_{t=1}^{\tau} \delta_{\tilde{c}_t}$

$\delta_{i_t} : \delta_{C_t} \odot \tilde{c}_t \odot i_t \odot (1 - i_t)$

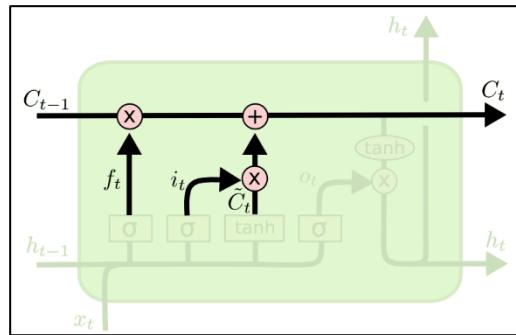
$\delta_{\tilde{c}} : \delta_{C_t} \odot i_t \odot (1 - \tilde{c}_t^2)$

Fungsi tanh, atau tangen hiperbolik memiliki rentang nilai dari  $(-1)$  hingga  $(1)$ .

(1). Fungsi ini dapat dirumuskan dengan persamaan berikut:

$$\tanh(x) = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2.13)$$

### 3. Cell State



**Gambar 2.4** Arsitektur LSTM *Cell State* (Olah, 2015)

Pada langkah ini, terdapat *output* dari *forget gate* ( $f_t$ ) dan *input gate* ( $i_t$ ), yang masing-masing dihasilkan dari fungsi *sigmoid* dan hasil  $\tilde{c}_t$  dari fungsi tanh. *Output* dari *forget gate* dan *input gate* berfungsi sebagai bobot untuk menentukan jumlah informasi baru dan lama yang akan ditambahkan dan dipertahankan. Persamaan dari *cell state* sebagai berikut (Yu dkk., 2019).

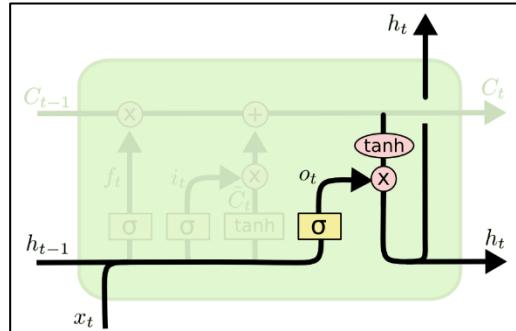
$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{c}_t \quad (2.14)$$

Keterangan:

$C_t$  : Nilai *cell state* pada langkah waktu ( $t$ )

$C_{t-1}$ : Nilai *cell state* pada langkah waktu ( $t - 1$ )

#### 4. Output Gate



**Gambar 2.5** Arsitektur LSTM *Output Gate* (Olah, 2015)

*Output gate* mengatur jumlah informasi yang diteruskan ke *output* dan beroperasi dengan cara yang serupa dengan *gate* lainnya. Langkah terakhir adalah menghasilkan *hidden state* yang baru ( $h_t$ ). Persamaan  $o_t$  dan  $h_t$  sebagai berikut (Yu dkk., 2019).

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.15)$$

$$h_t = o_t \odot \tanh(C_t) \quad (2.16)$$

Keterangan:

$o_t$  : Nilai *output gate* pada langkah waktu ( $t$ )

$W_o$  : Matriks bobot untuk *output gate* berukuran  $\mathbb{R}^{m \times (m+d)}$

$b_o$  : Vektor bias pada *output gate* berdimensi  $m$  ( $\mathbb{R}^m$ )

$\tanh$  : Fungsi aktivasi tanh

Proses pembaruan nilai bobot dan bias pada *output gate* dijelaskan melalui persamaan yang tercantum pada rumus berikut.

$$W_{o_{new}} = W_o - \eta \cdot \nabla_{W_o} \quad (2.17)$$

$$b_{o_{new}} = b_o - \eta \cdot \nabla_{b_o} \quad (2.18)$$

Keterangan:

$\nabla_{W_o} : \sum_{t=1}^{\tau} ([h_{t-1}, x_t])^T \cdot \delta_{o_t}$

$$\nabla_{b_o} : \sum_{t=1}^{\tau} \delta_{o_t}$$

$$\delta_{o_t} : \delta_{h_t} \odot \tanh(C_t) \odot o_t \odot (1 - o_t)$$

Kemudian, *output* pada layer terakhir ( $y_t$ ) akan menggambarkan hasil peramalan akhir dari LSTM pada waktu ( $t$ ) sesuai dengan rumus berikut.

$$y_t = W_y \cdot h_t + b_y \quad (2.19)$$

Keterangan:

$y_t$  : Nilai *output layer* pada langkah waktu ( $t$ )

$W_y$  : Matriks bobot untuk *output layer* berukuran  $\mathbb{R}^{m \times d}$

$h_t$  : Vektor *hidden state* berdimensi  $m$  ( $\mathbb{R}^m$ ) pada *timestep*  $t$

$b_y$  : Vektor bias pada *output layer* berdimensi  $m$  ( $\mathbb{R}^m$ )

Proses pembaruan nilai bobot dan bias pada *output layer* dijelaskan melalui persamaan yang tercantum pada rumus berikut.

$$W_{y_{new}} = W_y - \eta \cdot \nabla_{W_y} \quad (2.20)$$

$$b_{y_{new}} = b_y - \eta \cdot \nabla_{b_y} \quad (2.21)$$

Keterangan:

$$\nabla_{W_y} : \sum_{t=1}^T \delta_{y_t} \cdot (h_{t-1})^T$$

$$\nabla_{b_y} : \sum_{t=1}^T \delta_{y_t}$$

$$\delta_{y_t} : \hat{Y} - Y$$

$$\delta_{h_T} : (W_y)^T \cdot \delta \hat{Y}$$

### 2.1.5 Optimasi RMSProp

RMSProp (*Root Mean Square Propagation*) merupakan algoritma optimasi *learning rate* adaptif yang dirancang untuk meningkatkan kinerja dan

kecepatan pelatihan model *deep learning*. RMSProp diperkenalkan oleh Geoffrey Hinton. Ini merupakan varian dari algoritma *gradient descent* yang menyesuaikan *learning rate* untuk setiap parameter secara individual, dengan memperhitungkan besarnya gradien terbaru dari parameter tersebut. Sifat adaptif ini membantu dalam mengatasi tantangan seperti tujuan pelatihan yang tidak stabil dan gradien yang jarang muncul, yang sering terjadi dalam tugas *deep learning* (Kannan dkk., 2024).

RMSProp memodifikasi aturan pembaruan *gradient descent* standar dengan memasukkan rata-rata bergerak dari kuadrat gradien. Berikut persamaan untuk optimasi RMSProp (Cahyani dkk., 2023).

1. Menghitung gradien  $g_t$  pada waktu  $t$

Bobot:

$$g_{W,t} = \nabla W \quad (2.22)$$

Bias:

$$g_{b,t} = \nabla b \quad (2.23)$$

2. Perbarui rata-rata bergerak dari kuadrat gradien

Bobot:

$$E[g_W^2]_t = \gamma E[g_W^2]_{t-1} + (1 - \gamma) \odot g_{W,t}^2 \quad (2.24)$$

Bias:

$$E[g_b^2]_t = \gamma E[g_b^2]_{t-1} + (1 - \gamma) \odot g_{b,t}^2 \quad (2.25)$$

di mana  $\gamma$  adalah *decay rate* (laju peluruhan) dengan nilai *default* 0.9

3. Perbarui parameter bobot dan bias menggunakan *learning rate* yang disesuaikan

Bobot:

$$W_{baru} = W_{lama} - \frac{\eta}{\sqrt{E[g_W^2]_t + \varepsilon_W}} \odot g_{W,t} \quad (2.26)$$

Bias:

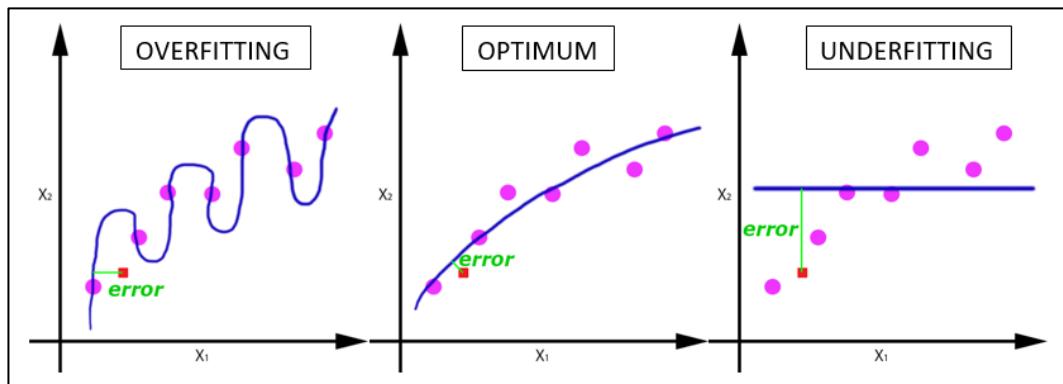
$$b_{baru} = b_{lama} - \frac{\eta}{\sqrt{E[g_b^2]_t + \varepsilon_b}} \odot g_{b,t} \quad (2.27)$$

di mana  $\eta$  merupakan *learning rate* dengan nilai *default* 0.001 dan  $\varepsilon$  merupakan konstanta kecil yang ditambahkan untuk mencegah pembagian dengan nol dan menjaga kestabilan numerik dengan nilai *default*  $10^{-8}$ . Algoritma RMSProp memperbarui parameter bobot dan bias dengan menyesuaikan arah dan besar langkah berdasarkan rata-rata kuadrat gradien. Operasi akar kuadrat dalam rumus dilakukan secara *element-wise*, yaitu pada tiap elemen hasil kuadrat gradien, bukan akar terhadap struktur matriks secara keseluruhan. Hal ini menjaga stabilitas dan adaptivitas langkah pembaruan terhadap skala gradien.

### 2.1.6 Epoch

*Epoch* merupakan satu siklus penuh di mana seluruh dataset telah melewati proses pelatihan pada *Neural Network* dan kembali ke awal untuk mengulang proses tersebut. Penggunaan lebih dari satu *epoch* diperlukan karena melewati seluruh dataset satu kali saja melalui jaringan saraf tidak cukup untuk mengoptimalkan pembelajaran. Hal ini berkaitan dengan keterbatasan data yang digunakan serta metode optimasi seperti *Gradient Descent*, yang bersifat iteratif. Oleh karena itu, pembaruan bobot tidak dapat dilakukan hanya dengan satu *epoch*. Jika hanya menggunakan satu *epoch*, model cenderung mengalami *underfitting*

seperti yang terlihat pada grafik. Dengan menambah jumlah *epoch*, bobot dalam jaringan saraf akan terus diperbarui, sehingga kurva prediksi akan berkembang dari yang awalnya tidak sesuai hingga berpotensi mencapai kondisi *overfitting* (Khumaidi & Nirmala, 2022).



Gambar 2.6 Grafik *Overfitting*, *Optimum*, *Underfitting* dari Jumlah *Epoch*

Penentuan jumlah *epoch* tidak memiliki jawaban pasti karena sangat bergantung pada karakteristik masing-masing dataset. Secara umum, jumlah *epoch* berkaitan dengan keragaman data yang digunakan, sehingga perlu disesuaikan dengan kompleksitas dan kebutuhan dari dataset yang dimiliki.

### 2.1.7 Denormalisasi

Denormalisasi merupakan proses mengembalikan data hasil peramalan yang sebelumnya telah dinormalisasi ke bentuk aslinya. Tujuan dari proses ini adalah untuk membandingkan data peramalan dengan data aktual guna mengevaluasi kinerja model yang telah dibuat. Apabila normalisasi dilakukan dalam rentang [0:1], maka denormalisasi dapat dihitung menggunakan persamaan seperti berikut (Khumaidi & Nirmala, 2022).

$$y = \hat{y}(x_{max} - x_{min}) + x_{min} \quad (2.28)$$

Keterangan:

- $y$  : Nilai data peramalan setelah denormalisasi
- $\hat{y}$  : Nilai data peramalan sebelum denormalisasi
- $x_{max}$  : Nilai maksimum data
- $x_{min}$  : Nilai minimum data

### 2.1.8 Mean Absolute Percentage Error (MAPE)

MAPE adalah metrik evaluasi yang sering dipakai dalam peramalan untuk menilai keakuratan model dalam memprediksi suatu data. MAPE menghitung rata-rata persentase kesalahan antara data sebenarnya dan hasil prediksi pada sebuah dataset. Dengan menggunakan MAPE, dapat diketahui rata-rata tingkat kesalahan prediksi sebagai persentase dari nilai sebenarnya (Yanti dkk., 2024).

Berikut persamaan dalam menghitung nilai MAPE (Montgomery dkk., 2015).

$$MAPE = \frac{1}{n} \left( \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \right) \times 100\% \quad (2.29)$$

Keterangan:

$n$  : Banyaknya sampel data

$Y_t$  : Nilai asli

$\hat{Y}_t$  : Nilai peramalan

Semakin rendah nilai MAPE, semakin baik kualitas peramalannya.

Kriteria untuk nilai MAPE dapat dilihat dalam tabel di bawah ini (Lewis, 1982).

**Tabel 2.1 Kategori Nilai MAPE**

Nilai	Keterangan
$MAPE \leq 10\%$	Sangat Akurat
$10\% < MAPE \leq 20\%$	Akurat
$20\% < MAPE \leq 50\%$	Cukup Akurat
$MAPE > 50\%$	Tidak Akurat

### 2.1.9 Root Mean Square Error (RMSE)

RMSE merupakan akar kuadrat dari *Mean Square Error* (MSE) yang digunakan untuk memberikan ukuran kesalahan yang sebanding dengan skala aslinya. Semakin rendah nilai RMSE, semakin baik akurasi model yang dihasilkan. Rumus RMSE dapat dinyatakan sebagai berikut (Khumaidi & Nirmala, 2022).

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (2.30)$$

Keterangan:

$n$  : Banyaknya sampel data

$Y_t$  : Nilai asli

$\hat{Y}_t$  : Nilai peramalan

### 2.1.10 Suhu Udara

Panas atau dinginnya udara dikenal sebagai suhu udara. Variasi dalam kecepatan pemanasan dan pendinginan di berbagai wilayah, serta interaksi antara udara, lautan, dan permukaan bumi, semuanya berkontribusi terhadap perubahan suhu udara. Penjelasan tentang cara suhu udara memengaruhi iklim sebanding

dengan penjelasan tentang elemen lamanya matahari untuk bersinar. Bentuk dan ketinggian permukaan bumi menentukan seberapa besar variasi suhu udara di berbagai lokasi (Widyatmanti & Natalia, 2008).

Beragam skala digunakan untuk menyatakan suhu udara. Dua skala yang umum digunakan adalah skala Fahrenheit, yang banyak digunakan di Inggris, dan skala Celsius atau *centigrade*, yang diterapkan oleh sebagian besar negara di dunia (Tjasyono, 2004).

## 2.2 Peramalan Menurut Pandangan Islam

Peramalan atau *forecasting* adalah proses memprediksi kejadian di masa mendatang dengan menggunakan data historis dan metode matematis. Islam membedakan peramalan yang dilakukan berdasarkan ilmu pengetahuan yang dapat dipertanggungjawabkan dengan yang berbasis takhayul atau kesyirikan. Pada dasarnya, Islam memperbolehkan peramalan selama dilakukan dengan metode yang ilmiah, bertujuan baik, dan tidak bertentangan dengan akidah Islam. Islam menekankan pentingnya ilmu pengetahuan dalam memahami dan mengelola fenomena alam. Dalam Al-Qur'an, banyak ayat yang mendorong manusia untuk berpikir, meneliti, dan mengambil pelajaran dari tanda-tanda kebesaran Allah. Allah berfirman dalam Q.S. Al-Jatsiyah ayat 13.

وَسَحْرٌ لِكُنْمٌ مَا فِي السَّمَاوَاتِ وَمَا فِي الْأَرْضِ جَمِيعًا مِنْهُ أَنَّ فِي ذَلِكَ لَآيَاتٍ لِقَوْمٍ يَتَعَكَّرُونَ ﴿١٣﴾

(Kementerian Agama, 2019)

*“Dia telah menundukkan (pula) untukmu apa yang ada di langit dan apa yang ada di bumi semuanya (sebagai rahmat) dari-Nya. Sesungguhnya pada yang demikian itu benar-benar terdapat tanda-tanda (kebesaran Allah) bagi kaum yang berpikir.”*  
(Q.S. Al-Jatsiyah: 13)

Dalam Tafsir Wajiz disebutkan bahwa hanya Allah Yang Maha Esa dan Mahakuasa yang mampu menundukkan segala sesuatu demi kemaslahatan manusia. Baik yang ada di langit, seperti bintang dan planet, maupun yang ada di bumi, seperti tanah subur dan air, semuanya diperuntukkan sebagai rahmat dari-Nya. Sesungguhnya, dalam hal tersebut terdapat tanda-tanda kebesaran dan kekuasaan Allah bagi mereka yang mau berpikir dan merenungkan ayat-ayat-Nya. (Kementerian Agama, 2016).

Ayat tersebut menunjukkan bahwa manusia diperintahkan untuk mempelajari dan memanfaatkan ilmu pengetahuan dalam memahami fenomena alam, termasuk dalam proses peramalan untuk memprediksi kejadian tertentu. Hal ini sejalan dengan ajaran Islam yang mendorong penggunaan akal dan pengetahuan untuk mencegah kerugian, mempersiapkan diri terhadap kemungkinan di masa depan, dan mengoptimalkan sumber daya yang telah Allah berikan. Dengan demikian, peramalan berbasis ilmu pengetahuan dapat menjadi bagian dari ikhtiar manusia untuk menjaga keseimbangan kehidupan, selama tetap berada dalam kerangka tauhid dan tidak melibatkan unsur-unsur yang bertentangan dengan syariat.

Ayat tersebut juga menegaskan bahwa segala sesuatu di langit dan di bumi telah ditundukkan oleh Allah untuk kepentingan manusia. Hal tersebut mencerminkan bahwa manusia memiliki tanggung jawab untuk memahami dan memanfaatkan fenomena alam, termasuk cuaca, demi keberlangsungan hidup. Dengan memahami pola suhu udara menggunakan metode ilmiah, manusia dapat mengambil langkah-langkah preventif dalam sektor pertanian, perencanaan kota, dan mitigasi bencana.

### 2.3 Kajian Penelitian dengan Teori Pendukung

Peramalan merupakan ilmu membuat prediksi berdasarkan data historis untuk memperkirakan peristiwa di masa mendatang. Dalam peramalan, data historis dianalisis dan diproyeksikan di masa mendatang menggunakan model matematika. Peramalan dilakukan dengan tujuan untuk mengurangi ketidakpastian terhadap kejadian di masa depan. Dalam konteks peramalan suhu udara, analisis ini menjadi penting bagi ahli meteorologi untuk memprediksi perubahan suhu berdasarkan data historis. Informasi ini berguna untuk memberikan peringatan dini, mendukung perencanaan aktivitas harian, serta mengantisipasi kondisi cuaca ekstrem. Fitur-fitur yang digunakan dalam memprediksi suhu udara meliputi:

1. Tanggal: Data tanggal, bulan, dan tahun saat waktu pengukuran data
2. Suhu udara minimum: suhu terendah yang tercatat dalam satu hari
3. Suhu udara rata-rata: nilai tengah atau rata-rata dari suhu yang tercatat satu hari
4. Suhu udara maksimum: suhu tertinggi yang tercatat dalam satu hari

LSTM adalah salah satu algoritma dalam *deep learning* yang terkenal dengan tingkat akurasinya yang tinggi untuk memprediksi data *time series*. *Memory cell* pada LSTM dirancang untuk menyimpan informasi dari langkah komputasi sebelumnya dalam jangka waktu yang lama, terutama untuk data besar. Hal ini memungkinkan algoritma ini mengenali pola data secara efektif dan menghasilkan prediksi yang lebih akurat. LSTM sering diterapkan dalam peramalan suhu udara, di mana urutan data historis menjadi faktor penting. Algoritma ini mampu menangkap hubungan antara perubahan suhu dari hari-hari sebelumnya dengan pola suhu di masa mendatang. Yan (2016) menjelaskan bahwa fitur gerbang sel (*cell*

*gate*) dalam LSTM adalah elemen utama yang berfungsi untuk mengatur aliran informasi di dalam jaringan. Proses pada *cell gate* dalam model LSTM meliputi:

1. Menghitung nilai *forget gate*.
2. Menghitung nilai *input gate*.
3. Memperbarui status memori dalam *cell*.
4. Menghitung *output gate* serta hasil akhirnya.

Dengan menggunakan LSTM, peramalan suhu udara menjadi lebih akurat karena algoritma ini dapat menangani data yang kompleks dan mengidentifikasi pola jangka panjang dengan lebih baik.

## **BAB III**

### **METODE PENELITIAN**

#### **3.1 Jenis Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif dan studi literatur. Pendekatan kuantitatif dipilih karena melibatkan penggunaan data numerik dan mencakup proses analisis data yang menghasilkan kesimpulan berbasis numerik. Studi literatur dimanfaatkan untuk mengumpulkan referensi dan sumber-sumber relevan dari jurnal dan buku yang menjadi dasar pemahaman lebih mendalam mengenai topik penelitian ini.

#### **3.2 Data dan Sumber Data**

Data yang digunakan pada penelitian ini merupakan data sekunder. Penelitian ini menggunakan data suhu udara wilayah Kabupaten Malang dengan periode waktu mulai 1 Januari 2021-31 Desember 2024 sebanyak 1461 baris data. Sumber data berasal dari situs resmi data *online* BMKG (2025) yang diakses pada 5 Januari 2025. Adapun data tersebut terlampir pada lampiran 1.

#### **3.3 Tahapan Penelitian**

Tahapan penelitian dapat dijalankan dengan langkah-langkah berikut.

##### **1. Persiapan data**

Pada tahap ini mempersiapkan data suhu udara wilayah Kabupaten Malang. Data yang digunakan merupakan data suhu udara harian yang didapatkan melalui situs data *online* BMKG periode waktu 1 Januari 2021-31 Desember

2024 sebanyak 4383 data. Fitur yang digunakan dalam memprediksi pada penelitian ini yaitu suhu udara minimum, suhu udara maksimum, dan suhu udara rata-rata.

## 2. Statistika deskriptif

Pada tahap ini dilakukan statistika deskriptif untuk mengetahui karakteristik dari setiap fitur yang akan digunakan dan menampilkan visualisasi data dalam bentuk grafik *time series* untuk memantau pola aliran data.

## 3. *Preprocessing* data

### a. Pemeriksaan dan penanganan nilai yang hilang (*missing value*)

Pemeriksaan nilai yang hilang dilakukan pada data yang dikumpulkan sehingga tindakan yang tepat dapat diambil jika nilai yang hilang ditemukan. Salah satu cara menangani nilai yang hilang pada penelitian ini menggunakan interpolasi linier dengan rumus (2.1). Setelah itu, data yang tidak memiliki nilai yang hilang dapat diproses lebih lanjut dan digunakan untuk membuat model peramalan.

### b. Normalisasi data

Pada tahap ini yaitu dilakukan normalisasi data dengan tujuan menyamakan skala data yang nilainya besar menggunakan *min-max scaling* dengan rumus (2.2). Data tersebut diubah menjadi skala 0 hingga

1.

### c. Segmentasi data

Pada tahap segmentasi data, peneliti membentuk *data window* dengan panjang rangkaian (*timestep*) selama 30 hari. Kemudian, data tersebut digunakan untuk meramalkan nilai pada hari ke-31.

d. Partisi data

Data sekarang dipisahkan menjadi dua, yaitu data pengujian (*testing*) sebanyak 80% dan data pelatihan (*training*) sebanyak 20%. Model peramalan yang telah dibangun akan dilatih dengan menggunakan data pelatihan. Sementara itu, data pengujian akan digunakan untuk menilai seberapa baik kinerja model yang dikembangkan dalam memprediksi.

4. Membuat konstruksi model LSTM

Pada tahap ini, diperlukan beberapa parameter pendukung. Beberapa parameter yang digunakan sebagai berikut.

**Tabel 3.1** Parameter Konstruksi Model LSTM

No	Jenis	Uraian/Nilai
1	<i>Layer</i>	4
2	<i>Hidden neuron</i>	50
3	<i>Batch size</i>	4, 16, 32, 64
4	<i>Epoch</i> maksimum	50, 100, 150
5	<i>Optimizer</i>	RMSProp
6	Fungsi aktivasi	tanh dan sigmoid

Karena tidak ada batasan yang ditetapkan untuk parameter yang dipilih, maka parameter ini dapat diubah sesuai dengan kebutuhan sistem.

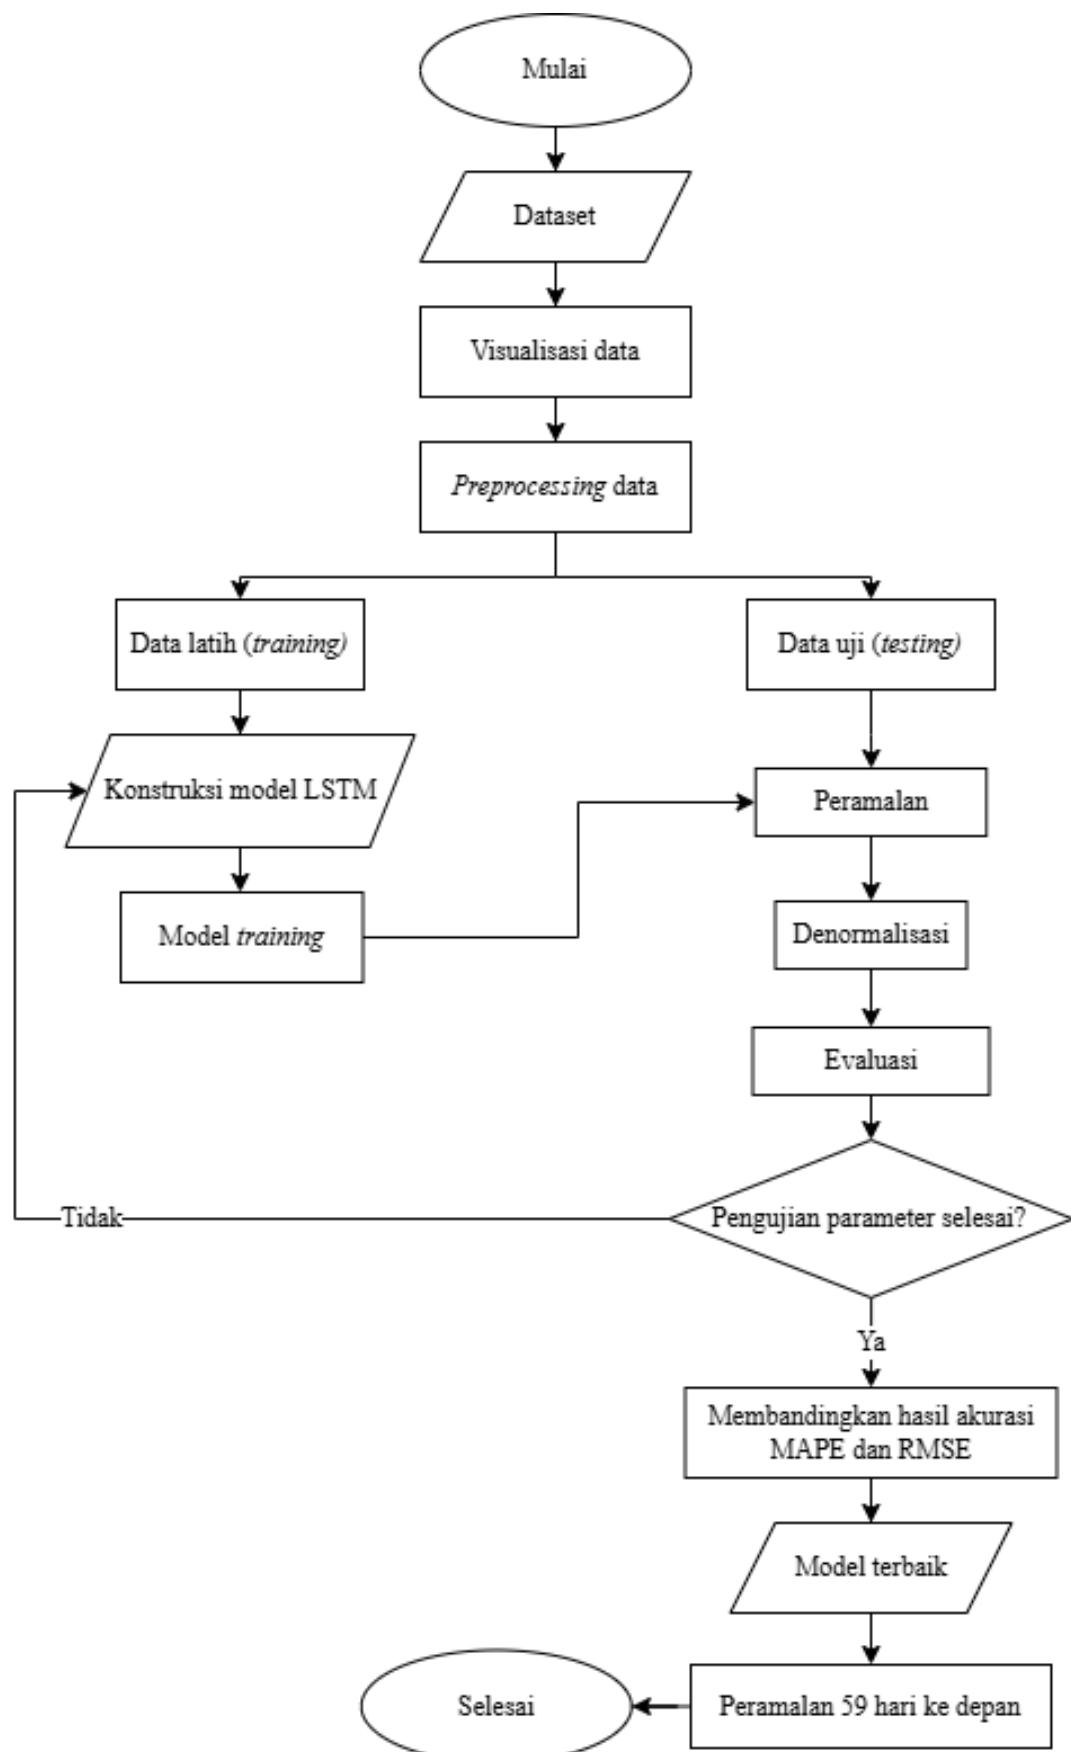
5. *Training* data

- a. Menghitung semua fungsi gerbang *unit* pada setiap *neuron*. Secara berurutan, fungsi gerbang yang akan dihitung adalah *forget gates* menggunakan persamaan (2.4), *input gates* menggunakan persamaan (2.7), nilai *candidate cell* menggunakan persamaan (2.8), *cell state* menggunakan persamaan (2.14), dan terakhir *output gates* menggunakan persamaan (2.15).

- 
- 
- 
- 
- 
- b. Semua hasil perhitungan dari tiap *gates* dihitung untuk setiap *timestep* dan kemudian digunakan sebagai masukan ke *output layer* menggunakan persamaan (2.19).
  - c. Ulangi langkah a-b dan jika perulangan telah mencapai jumlah *epoch* yang ditentukan, maka proses akan berhenti.
6. *Testing* data
  - a. Model yang telah dilatih akan dilakukan peramalan terhadap data *testing*.
  - b. Hasil dari peramalan dilakukan proses denormalisasi terhadap data hasil peramalan untuk mengembalikan skala nilai ke bentuk aslinya.
  - c. Setelah dilakukan denormalisasi akan dilakukan evaluasi terhadap model dengan menggunakan data *testing* untuk memperoleh nilai RMSE dan MAPE sebagai indikator performa prediksi
7. Pengujian parameter
  - a. Jika pengujian parameter belum selesai, proses kembali ke tahap pelatihan dengan konfigurasi parameter berbeda.
  - b. Jika selesai, hasil akurasi MAPE dan RMSE dibandingkan untuk memilih model terbaik.
8. Membandingkan kinerja model yang terbentuk untuk beberapa variasi jumlah *batch size* (4,16, 32, 64) dan jumlah *epoch* (50,100,150,200). Model LSTM dengan nilai MAPE dan RMSE paling kecil dianggap sebagai model LSTM yang memiliki performa terbaik.
9. Model terbaik LSTM akan digunakan untuk meramalkan suhu udara Kabupaten Malang selama 59 hari ke depan.

### 3.4 Diagram Alir Penelitian

Berdasarkan tahap-tahap penelitian yang telah dijelaskan, proses penggerjaan penelitian ini dapat divisualisasikan melalui diagram alir berikut.



Gambar 3.1 Diagram Alir Penelitian

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1 Statistika Deskriptif

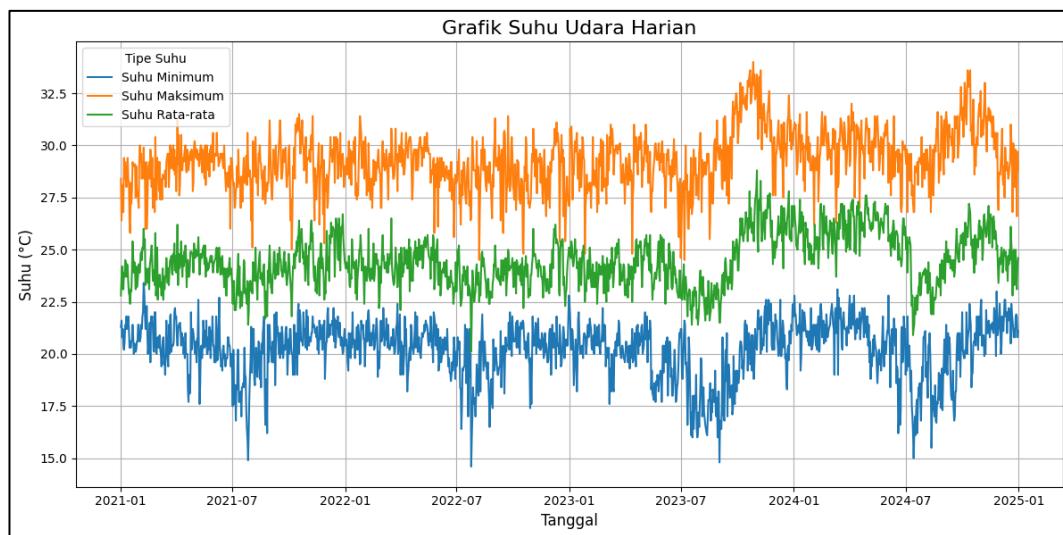
Penelitian ini menggunakan data suhu udara harian Kabupaten Malang yang diperolah dari laman *website data online* BMKG dalam format excel. Data tersebut diambil dari periode 1 Januari 2021 hingga 31 Desember 2024 sebanyak 4375 data. Fitur yang digunakan pada data tersebut yaitu suhu udara minimum, suhu udara maksimum, dan suhu udara rata-rata. Untuk mengetahui karakteristik dari setiap fitur yang digunakan, dilakukan analisis statistika deskriptif data. Tujuan dilakukan analisis statistik deskriptif yaitu untuk melihat kecenderungan umum dari data, termasuk nilai rata-rata, median, nilai minimum dan nilai maksimum yang mencerminkan sebaran dan pola dari masing-masing fitur. Adapun hasil dari statistik deskriptif dari masing-masing fitur dapat dilihat pada tabel berikut.

**Tabel 4.1** Statistika Deskriptif

	Suhu Minimum	Suhu Maksimum	Suhu Rata-rata
<b>Count</b>	1455	1461	1459
<b>Mean</b>	20.19	29.28	24.45
<b>Min</b>	14.6	24.5	20.1
<b>Max</b>	23.4	34	28.8
<b>Std</b>	1.38	1.39	1.24

Berdasarkan tabel 4.1, menggambarkan karakteristik tiga variabel suhu, yaitu suhu minimum, suhu maksimum, dan suhu rata-rata berdasarkan 1.461 data pengamatan, meskipun terdapat beberapa *missing value* pada dua variabel. Rata-rata suhu minimum tercatat sebesar 20.19°C, dengan suhu terendah 14.6°C dan tertinggi 23.4°C, serta standar deviasi 1.38, menunjukkan kestabilan suhu minimum

harian. Sementara itu, suhu maksimum memiliki rata-rata  $29.28^{\circ}\text{C}$ , dengan kisaran antara  $24.5^{\circ}\text{C}$  hingga  $34^{\circ}\text{C}$  dan standar deviasi sebesar 1.39, yang juga menunjukkan fluktuasi suhu maksimum yang relatif konsisten. Suhu rata-rata harian tercatat sebesar  $24.45^{\circ}\text{C}$ , dengan nilai minimum  $20.1^{\circ}\text{C}$  dan maksimum  $28.8^{\circ}\text{C}$  serta standar deviasi 1.24, yang mengindikasikan bahwa suhu harian cenderung stabil dan berada pada kisaran hangat. Untuk mendapatkan pemahaman visual yang lebih jelas mengenai pola dan distribusi suhu, dapat dilihat pada grafik berikut.



**Gambar 4.1** Grafik Suhu Udara Harian di Kabupaten Malang

Berdasarkan gambar 4.1, grafik tersebut menunjukkan variasi suhu udara harian dari Januari 2021 hingga Desember 2024 dengan tiga kategori suhu yaitu minimum (biru), maksimum (oranye), dan rata-rata (hijau). Secara umum, suhu maksimum berkisar antara  $24.5^{\circ}\text{C}$  hingga  $34^{\circ}\text{C}$ , suhu rata-rata sekitar  $20.1^{\circ}\text{C}$  hingga  $28.8^{\circ}\text{C}$ , dan suhu minimum berada dalam rentang  $14.6^{\circ}\text{C}$  hingga  $23.4^{\circ}\text{C}$ . Terdapat pola musiman yang terlihat jelas, dengan fluktuasi tahunan yang menunjukkan kenaikan suhu pada pertengahan tahun dan penurunan suhu pada awal dan akhir tahun. Tren keseluruhan menunjukkan adanya sedikit peningkatan

suhu dari waktu ke waktu, terutama pada suhu maksimum dan rata-rata, yang dapat mengindikasikan perubahan iklim atau fenomena cuaca regional yang berpengaruh terhadap suhu udara dalam jangka waktu tersebut.

## 4.2 Pre-Processing

### 4.2.1 Data Cleaning

Data *cleaning* merupakan langkah awal yang penting dalam analisis data. Data *cleaning* dilakukan untuk memastikan bahwa data yang digunakan bebas nilai yang hilang (*missing value*). Sebelum dilakukan analisis lebih lanjut, data diperiksa untuk melihat apakah terdapat nilai yang hilang (*missing values*). Identifikasi dilakukan dengan mengecek keberadaan nilai NaN atau NULL pada dataset.

**Tabel 4.2 Output Cek Missing Value**

Jumlah <i>missing value</i> per kolom:				
Suhu Minimum	6			
Suhu Maksimum	0			
Suhu Rata-rata	2			
Baris dengan <i>missing value</i> :				
Indeks	Tanggal	Suhu Minimum	Suhu Maksimum	Suhu Rata-rata
145	26-05-2021	NaN	29.8	NaN
438	15-03-2022	NaN	29.4	24.8
656	19-10-2022	NaN	27.7	23.4
915	05-07-2023	NaN	27.3	23.7
1183	29-03-2024	NaN	30.0	25.6
1284	08-07-2024	NaN	28.3	NaN

Berdasarkan tabel 4.2 menunjukkan hasil identifikasi *missing value* dalam dataset suhu udara. Dari hasil tersebut, terdapat 6 nilai yang hilang pada kolom

suhu minimum dan 2 nilai yang hilang pada kolom suhu rata-rata. Dataset tersebut dikonfirmasi memiliki *missing value* pada baris ke-145, 438, 656, 915, 1183, dan 1284. Dalam penelitian ini, penanganan *missing value* dilakukan dengan metode interpolasi linier, yaitu dengan mengisi nilai yang hilang berdasarkan estimasi linier antara dua titik data terdekat yang tersedia. Teknik ini dianggap efektif karena mampu mempertahankan kontinuitas tren data tanpa menimbulkan deviasi yang signifikan. Misalnya, jika nilai suhu minimum hilang pada baris ke-145, maka nilai tersebut akan diestimasi dengan menghitung rata-rata linier antara nilai suhu minimum pada baris ke-144 dan 146. Metode ini sangat sesuai diterapkan pada data *time series* seperti suhu, karena perubahannya cenderung gradual dan kontinu antar waktu. Berikut contoh perhitungan manual interpolasi linier menggunakan rumus (2.1).

### 1. Suhu udara minimum

Baris ke-145:

$$\begin{aligned}
 x &= \frac{x_{k+1} - x_k}{t_{k+1} - t_k} (t - t_k) + x_k \\
 &= \frac{19.8 - 21.3}{146 - 144} (145 - 144) + 21.3 \\
 &= \frac{-1.5}{2} \times 1 + 21.3 \\
 &= 20.55
 \end{aligned}$$

Baris ke-438:

$$\begin{aligned}
 x &= \frac{x_{k+1} - x_k}{t_{k+1} - t_k} (t - t_k) + x_k \\
 &= \frac{20.4 - 20.2}{439 - 437} (438 - 437) + 20.2 \\
 &= \frac{0.2}{2} \times 1 + 20.2 \\
 &= 20.3
 \end{aligned}$$

Baris ke-656:

$$\begin{aligned}
 x &= \frac{x_{k+1} - x_k}{t_{k+1} - t_k} (t - t_k) + x_k \\
 &= \frac{20.2 - 21.5}{657 - 655} (656 - 655) + 21.5 \\
 &= \frac{-1.3}{2} \times 1 + 21.5 \\
 &= 20.85
 \end{aligned}$$

2. Suhu udara rata-rata

Baris ke-145:

$$\begin{aligned}
 x &= \frac{x_{k+1} - x_k}{t_{k+1} - t_k} (t - t_k) + x_k \\
 &= \frac{24.7 - 24.4}{146 - 144} (145 - 144) + 24.4 \\
 &= \frac{0.3}{2} \times 1 + 24.4 \\
 &= 24.55
 \end{aligned}$$

Baris ke-1284:

$$\begin{aligned}
 x &= \frac{x_{k+1} - x_k}{t_{k+1} - t_k} (t - t_k) + x_k \\
 &= \frac{25.2 - 25.6}{1285 - 1283} (1284 - 1283) + 25.6 \\
 &= \frac{-0.4}{2} \times 1 + 25.6 \\
 &= 25.4
 \end{aligned}$$

Hasil dari penanganan *missing value* menggunakan interpolasi linier dapat dilihat pada lampiran 3.

#### 4.2.2 Normalisasi

Pada tahap normalisasi akan dilakukan penyetaraan seluruh nilai variabel dalam skala [0:1]. Rumus yang digunakan yaitu rumus (2.2). Berikut contoh perhitungan manual dari rumus (2.2).

Diketahui:

$$x_1^{max} = 23.4 \quad x_1^{min} = 14.6$$

$$x_2^{max} = 34 \quad x_2^{min} = 24.5$$

$$x_3^{max} = 28.8 \quad x_3^{min} = 20.1$$

1. Suhu udara minimum ( $x_1$ )

Hari ke-1:

$$x' = \frac{21.3 - 14.6}{23.4 - 14.6} \approx 0.7614$$

Hari ke-2:

$$x' = \frac{21.6 - 14.6}{23.4 - 14.6} \approx 0.7954$$

Hari ke-3:

$$x' = \frac{20.8 - 14.6}{23.4 - 14.6} \approx 0.7045$$

2. Suhu udara maksimum ( $x_2$ )

Hari ke-1:

$$x' = \frac{28.4 - 24.5}{34 - 24.5} \approx 0.4105$$

Hari ke-2:

$$x' = \frac{26.4 - 24.5}{34 - 24.5} \approx 0.2$$

Hari ke-3:

$$x' = \frac{28.1 - 24.5}{34 - 24.5} \approx 0.3789$$

3. Suhu udara rata-rata ( $x_3$ )

Hari ke-1:

$$x' = \frac{22.8 - 20.1}{28.8 - 20.1} \approx 0.3103$$

Hari ke-2:

$$x' = \frac{23.7 - 20.1}{28.8 - 20.1} \approx 0.4138$$

Hari ke-3:

$$x' = \frac{24.2 - 20.1}{28.8 - 20.1} \approx 0.4713$$

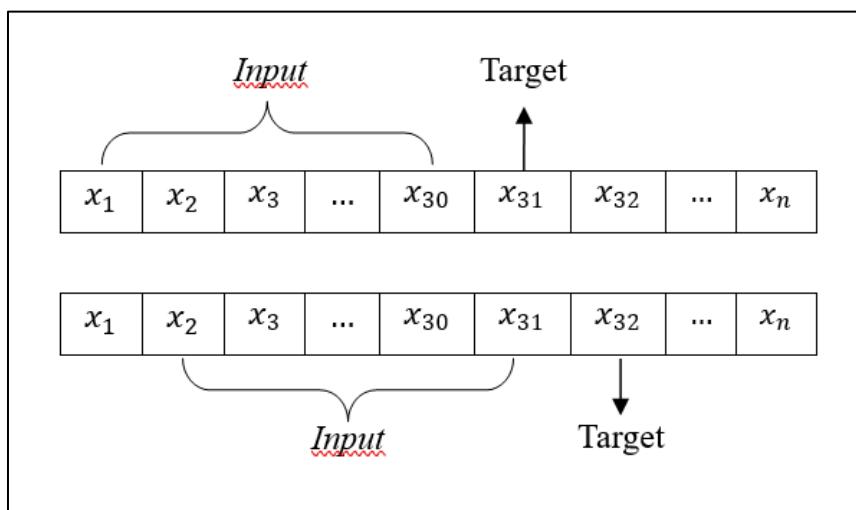
Hasil perhitungan normalisasi dapat dilihat pada tabel 4.3 dan lampiran 4.

**Tabel 4.3 Output Normalisasi Data**

<b>Tanggal</b>	<b>Suhu Minimum</b>	<b>Suhu Maksimum</b>	<b>Suhu Rata-rata</b>
01-01-2021	0.761364	0.410526	0.310345
01-02-2021	0.795455	0.2	0.413793
01-03-2021	0.704545	0.378947	0.471264
01-04-2021	0.75	0.284211	0.344828
01-05-2021	0.659091	0.242105	0.344828
01-06-2021	0.636364	0.515789	0.436782
01-07-2021	0.681818	0.410526	0.413793
:	:	:	:
12-25-2024	0.75	0.452632	0.367816
12-26-2024	0.704545	0.368421	0.448276
12-27-2024	0.818182	0.557895	0.563218
12-28-2024	0.829545	0.452632	0.390805
12-29-2024	0.818182	0.221053	0.344828
12-30-2024	0.704545	0.547368	0.482759
12-31-2024	0.738636	0.452632	0.517241

### 4.2.3 Segmentasi Data

Seperti yang telah dijelaskan sebelumnya, proses segmentasi bertujuan untuk mengelompokkan data guna memprediksi nilai target. Pada setiap kelompok data, akan dibentuk *timestep* 30 hari. Rangkaian ini disusun dari data historis masa lalu untuk meramalkan nilai target pada hari ke-31. Berikut gambar ilustrasi dari proses segmentasi.



**Gambar 4.2** Ilustrasi Proses Segmentasi

Berdasarkan gambar 4.2, jika data dikelompokkan dalam rentang 30 hari, maka data dari hari ke-1 hingga hari ke-30 digunakan sebagai *input*. Sementara itu, data hari ke-31 menjadi target peramalan. Proses ini bergeser terus menerus untuk membentuk pola *input-target* selanjutnya.

### 4.2.4 Partisi Data

Pada tahap ini, data akan dibagi menjadi dua bagian yaitu data *training* dan data *testing*. Pembagian dilakukan secara berurutan berdasarkan waktu (*time series split*) agar struktur temporal data tetap terjaga, dengan proporsi sebagai berikut.

1. Data *training* : 80% dari total data, mencakup periode dari tanggal 1 Januari 2021 hingga 12 April 2024.
2. Data *testing* : 20% dari total data, mencakup periode dari tanggal 13 April 2024 hingga 31 Desember 2024.

Pembagian ini dilakukan menggunakan metode pembagian berurutan tanpa pengacakan (*shuffle=False*) karena data bersifat *time series*. Dengan pendekatan ini, model mampu belajar dari pola historis dan diuji untuk memprediksi kejadian masa depan, yang mencerminkan kondisi nyata saat model diterapkan.

### 4.3 Konstruksi Model LSTM

Model LSTM dibuat dengan mempertimbangkan beberapa parameter yang optimal untuk memodelkan *time series*. Parameter-parameter yang dibutuhkan antara lain:

1. *Layer* : 4
2. *Hidden neuron* : 50
3. *Batch size* : 4, 16, 32, 64
4. *Epoch* : 50, 100, 150, 200
5. *Optimizer* : RMSProp
6. Fungsi aktivasi : tanh dan sigmoid

Tidak ada aturan yang pasti dalam menentukan parameter. Parameter ditentukan melalui serangkaian percobaan dengan data dan model yang akan digunakan. Parameter dari penelitian sebelumnya bisa dijadikan referensi, namun

tetapi perlu diuji lagi untuk memastikan parameter tersebut benar-benar bekerja secara optimal ketika diterapkan pada model yang sedang dikembangkan.

**Tabel 4.4** Model LSTM yang Terbentuk

Model: “sequential”		
<i>Layer (type)</i>	<i>Output Shape</i>	Param#
lstm (LSTM)	(None, 30, 50)	10800
lstm_1 (LSTM)	(None, 50)	20200
dropout (Dropout)	(None, 50)	0
dense (Dense)	(None, 3)	153
Total params: 62,308		
Trainable params: 31,153		
Non-trainable params: 0		

Tabel 4.4 menampilkan arsitektur model LSTM tipe *sequential* yang terdiri dari beberapa lapisan, yaitu dua lapisan LSTM, satu lapisan *Dropout*, dan satu lapisan *Dense*. Lapisan pertama adalah LSTM dengan 50 *hidden neuron* dan menghasilkan *output shape* berbentuk (None, 30, 50) serta memiliki 10,800 parameter. Lapisan kedua adalah LSTM yang juga memiliki 50 unit dan menghasilkan *output shape* berbentuk (None, 50) dengan jumlah parameter sebanyak 20,200. Setelah itu, terdapat lapisan *dropout* yang berfungsi untuk mencegah *overfitting* dan tidak memiliki parameter yang dilatih. Lapisan terakhir adalah *dense* yang menghasilkan *output* sebanyak 3 unit, sesuai dengan jumlah *output* yang diinginkan, dan memiliki 153 parameter. Secara keseluruhan, model ini memiliki total 62,308 parameter, dengan 31,153 parameter yang dapat dilatih (*trainable*), sedangkan sisanya adalah parameter non-*trainable* yang bernilai nol.

#### 4.4 Perhitungan Manual LSTM

Pada tahap ini akan dijelaskan contoh perhitungan matematis dalam proses pelatihan data suhu udara menggunakan LSTM dengan *timestep* sebesar 3 dan *hidden neuron* sebesar 3. Pada contoh perhitungan matematis LSTM ini menggunakan 3 fitur *input* dan menghasilkan 3 *output* fitur sebagai hasil peramalan. Perhitungan dimulai dengan menginisialisasi bobot dan bias secara acak oleh program untuk masing-masing *gate*, yaitu *input*, *forget*, *cell*, dan *output gate*, yang masing-masing memiliki bobot dan bias sendiri. Model ini dilatih dengan *batch size* sebesar 1, artinya satu sampel data diproses dalam satu waktu sehingga urutan data *time series* tetap terjaga, serta *epoch* sebesar 1, sehingga pelatihan dilakukan hanya satu kali putaran data. Tujuan dari konfigurasi ini adalah untuk memberikan ilustrasi perhitungan manual yang sederhana dan transparan terhadap aliran data dalam model LSTM. Inisialisasi bobot dan bias ditampilkan pada tabel

4.5.

**Tabel 4.5** Inisialisasi Acak Bobot dan Bias

$\mathbf{W}_f$	$\begin{bmatrix} 0.1184 & -0.1136 & -0.1760 & -0.0026 & -0.0621 & 0.0559 \\ 0.1162 & 0.0645 & 0.0886 & -0.0074 & -0.0003 & -0.0128 \\ -0.0817 & 0.0048 & -0.1380 & -0.0565 & -0.0109 & 0.0222 \end{bmatrix}$	$\mathbf{b}_f$	$\begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix}$
$\mathbf{W}_i$	$\begin{bmatrix} 0.0024 & -0.0646 & -0.1115 & 0.0309 & 0.0670 & -0.1473 \\ 0.0245 & 0.0242 & 0.0685 & -0.1235 & -0.0038 & 0.0268 \\ -0.2058 & -0.0513 & 0.1487 & -0.1290 & -0.0500 & 0.0012 \end{bmatrix}$	$\mathbf{b}_i$	$\begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix}$
$\mathbf{W}_{\tilde{c}}$	$\begin{bmatrix} 0.2202 & 0.0466 & -0.2110 & -0.2157 & -0.0113 & 0.0410 \\ 0.0991 & 0.0382 & 0.2699 & -0.0833 & 0.0267 & 0.1811 \\ -0.0210 & 0.1539 & -0.0062 & 0.0269 & 0.0704 & -0.1196 \end{bmatrix}$	$\mathbf{b}_{\tilde{c}}$	$\begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix}$
$\mathbf{W}_o$	$\begin{bmatrix} 0.0423 & 0.0027 & -0.1361 & -0.0258 & 0.0776 & 0.1230 \\ 0.3388 & -0.0117 & 0.0497 & 0.0484 & -0.0100 & -0.0498 \\ -0.1624 & 0.1384 & -0.0353 & -0.0478 & 0.0211 & 0.0335 \end{bmatrix}$	$\mathbf{b}_o$	$\begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix}$
$\mathbf{W}_y$	$\begin{bmatrix} 0.1758 & 0.1461 & 0.2959 \\ 0.3312 & 0.2497 & 0.2273 \\ -0.3170 & 0.0744 & -0.0096 \end{bmatrix}$	$\mathbf{b}_y$	$\begin{bmatrix} 0.5923 \\ 0.4600 \\ 0.4439 \end{bmatrix}$

Berdasarkan tabel 4.5, diperoleh inisialisasi acak bobot dan bias dari program. Struktur matriks bobot dan vektor bias pada LSTM merepresentasikan hubungan

antara setiap *input* fitur dan *neuron* pada sebuah *layer*. Dalam contoh perhitungan manual ini, karena terdapat 3 *input* fitur dan 3 *hidden neuron*, maka *input* aktual ke setiap gerbang LSTM merupakan gabungan dari *hidden state* sebelumnya dan *input* saat ini, sehingga menghasilkan vektor berdimensi 6. Oleh karena itu, matriks bobot memiliki ukuran  $3 \times 6$  yang secara umum dapat dinyatakan sebagai  $\mathbb{R}^{m \times (m+d)}$ , di mana  $d$  adalah jumlah fitur *input* dan  $m$  adalah jumlah *hidden neuron*. Setiap baris pada matriks ini mewakili bobot yang terhubung ke satu *neuron*, sementara setiap kolom menunjukkan kontribusi dari satu *input* fitur ke seluruh *neuron*. Selain itu, terdapat pula vektor bias berdimensi 3. Secara umum dapat dinyatakan sebagai  $\mathbb{R}^m$ , di mana  $m$  adalah jumlah *hidden neuron*. Vektor ini mewakili bias yang ditambahkan ke masing-masing *neuron*, satu per baris. Sebagai perbandingan, pada *output layer*, *input* yang digunakan hanya berasal dari *hidden state* sebelumnya. Oleh karena itu, bentuk matriks bobot pada *output layer* adalah  $\mathbb{R}^{m \times d}$  dengan  $d$  sebagai jumlah fitur *input* dan  $m$  sebagai jumlah *neuron*. Vektor bias pada *output layer* juga berukuran  $\mathbb{R}^m$ , satu nilai bias untuk setiap *neuron*. Berikut contoh perhitungan manual LSTM.

Diketahui:

$$\text{Hidden neuron} = 3 \quad \text{Batch size} = 1$$

$$\text{Timestep} = 3 \quad \text{Epoch} = 1$$

$$\text{Input fitur} = 3$$

$$X_t = \begin{bmatrix} \text{suhu\_min} \\ \text{suhu\_max} \\ \text{suhu\_mean} \end{bmatrix}$$

$$X_1 = \begin{bmatrix} 0.761364 \\ 0.410526 \\ 0.310345 \end{bmatrix}, X_2 = \begin{bmatrix} 0.795455 \\ 0.2 \\ 0.413793 \end{bmatrix}, X_3 = \begin{bmatrix} 0.704545 \\ 0.378947 \\ 0.471264 \end{bmatrix}$$

$$Y = \begin{bmatrix} 0.75 \\ 0.284211 \\ 0.344828 \end{bmatrix}$$

- Perhitungan hari ke-1

Diketahui:

$$h_{t-1} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

$$[h_{t-1}, x_1] = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0.761364 \\ 0.410526 \\ 0.310345 \end{bmatrix}$$

$$c_{t-1} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

a. Perhitungan *forget gate*

$$\begin{aligned}
f_1 &= \sigma(W_f \cdot [h_{t-1}, x_1] + b_f) \\
&= \sigma \left( \begin{bmatrix} 0.1184 & -0.1136 & -0.1760 & -0.0026 & -0.0621 & 0.0559 \\ 0.1162 & 0.0645 & 0.0886 & -0.0074 & -0.0003 & -0.0128 \\ -0.0817 & 0.0048 & -0.1380 & -0.0565 & -0.0109 & 0.0222 \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0.761364 \\ 0.410526 \\ 0.310345 \end{bmatrix} + \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} -0.0101 \\ -0.0097 \\ -0.0406 \end{bmatrix} + \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.0311 \\ 0.1537 \\ -0.0749 \end{bmatrix} \right) \\
&\approx \begin{bmatrix} 0.5078 \\ 0.5383 \\ 0.481 \end{bmatrix}
\end{aligned}$$

b. Perhitungan *input gate*

$$\begin{aligned}
 i_1 &= \sigma(W_i \cdot [h_{t-1}, x_1] + b_i) \\
 &= \sigma \left( \begin{bmatrix} 0.0024 & -0.0646 & -0.1115 & 0.0309 & 0.0670 & -0.1473 \\ 0.0245 & 0.0242 & 0.0685 & -0.1235 & -0.0038 & 0.0268 \\ -0.2058 & -0.0513 & 0.1487 & -0.1290 & -0.0500 & 0.0012 \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0.761364 \\ 0.410526 \\ 0.310345 \end{bmatrix} + \begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix} \right) \\
 &= \sigma \left( \begin{bmatrix} 0.0053 \\ -0.0873 \\ -0.1184 \end{bmatrix} + \begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix} \right) \\
 &= \sigma \left( \begin{bmatrix} 0.9683 \\ 0.9198 \\ 0.8250 \end{bmatrix} \right) \\
 &\approx \begin{bmatrix} 0.7248 \\ 0.7150 \\ 0.6953 \end{bmatrix}
 \end{aligned}$$

c. Perhitungan nilai kandidat baru yang ditambahkan ke *cell state*

$$\begin{aligned}
 \tilde{c}_1 &= \tanh(W_{\tilde{c}} \cdot [h_{t-1}, x_1] + b_{\tilde{c}}) \\
 &= \tanh \left( \begin{bmatrix} 0.2202 & 0.0466 & -0.2110 & -0.2157 & -0.0113 & 0.0410 \\ 0.0991 & 0.0382 & 0.2699 & -0.0833 & 0.0267 & 0.1811 \\ -0.0210 & 0.1539 & -0.0062 & 0.0269 & 0.0704 & -0.1196 \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0.761364 \\ 0.410526 \\ 0.310345 \end{bmatrix} + \begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix} \right) \\
 &= \tanh \left( \begin{bmatrix} -0.1561 \\ 0.0037 \\ 0.0123 \end{bmatrix} + \begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix} \right) \\
 &= \tanh \left( \begin{bmatrix} -0.2461 \\ -0.1979 \\ -0.0789 \end{bmatrix} \right) \\
 &\approx \begin{bmatrix} -0.2412 \\ -0.1953 \\ -0.0787 \end{bmatrix}
 \end{aligned}$$

d. Perhitungan *cell state*

$$\begin{aligned}
 C_1 &= f_t \odot C_{t-1} + i_t \odot \tilde{c}_t \\
 &= \left( \begin{bmatrix} 0.5078 \\ 0.5383 \\ 0.481 \end{bmatrix} \odot \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \right) + \left( \begin{bmatrix} 0.7248 \\ 0.7150 \\ 0.6953 \end{bmatrix} \odot \begin{bmatrix} -0.2412 \\ -0.1953 \\ -0.0787 \end{bmatrix} \right) \\
 &= \begin{bmatrix} -0.1748 \\ -0.1396 \\ -0.0547 \end{bmatrix}
 \end{aligned}$$

e. Perhitungan *output gate*

$$\begin{aligned}
 o_1 &= \sigma(W_o \cdot [h_{t-1}, x_1] + b_o) \\
 &= \sigma \left( \begin{bmatrix} 0.0423 & 0.0027 & -0.1361 & -0.0258 & 0.0776 & 0.1230 \\ 0.3388 & -0.0117 & 0.0497 & 0.0484 & -0.0100 & -0.0498 \\ -0.1624 & 0.1384 & -0.0353 & -0.0478 & 0.0211 & 0.0335 \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0.761364 \\ 0.410526 \\ 0.310345 \end{bmatrix} + \begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix} \right) \\
 &= \sigma \left( \begin{bmatrix} -0.0184 \\ 0.0369 \\ -0.0363 \end{bmatrix} + \begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix} \right) \\
 &= \sigma \left( \begin{bmatrix} 0.0227 \\ 0.1843 \\ -0.0718 \end{bmatrix} \right) \\
 &\approx \begin{bmatrix} 0.5057 \\ 0.5459 \\ 0.4821 \end{bmatrix}
 \end{aligned}$$

f. Perhitungan *hidden state*

$$\begin{aligned}
 h_1 &= o_1 \odot \tanh(C_1) \\
 &= \begin{bmatrix} 0.5057 \\ 0.5459 \\ 0.4821 \end{bmatrix} \odot \tanh \left( \begin{bmatrix} -0.1748 \\ -0.1396 \\ -0.0547 \end{bmatrix} \right) \\
 &= \begin{bmatrix} 0.5057 \\ 0.5459 \\ 0.4821 \end{bmatrix} \odot \begin{bmatrix} -0.1730 \\ -0.1387 \\ -0.0546 \end{bmatrix}
 \end{aligned}$$

$$\approx \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \end{bmatrix}$$

- Perhitungan hari ke-2

Diketahui:

$$h_{t-1} = \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \end{bmatrix}$$

$$[h_{t-1}, x_2] = \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \\ 0.795455 \\ 0.2 \\ 0.413793 \end{bmatrix}$$

$$C_1 = \begin{bmatrix} -0.1748 \\ -0.1396 \\ -0.0547 \end{bmatrix}$$

- a. Perhitungan *forget gate*

$$\begin{aligned}
f_2 &= \sigma(W_f \cdot [h_{t-1}, x_2] + b_f) \\
&= \sigma \left( \begin{bmatrix} 0.1184 & -0.1136 & -0.1760 & -0.0026 & -0.0621 & 0.0559 \\ 0.1162 & 0.0645 & 0.0886 & -0.0074 & -0.0003 & -0.0128 \\ -0.0817 & 0.0048 & -0.1380 & -0.0565 & -0.0109 & 0.0222 \end{bmatrix} \cdot \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \\ 0.795455 \\ 0.2 \\ 0.413793 \end{bmatrix} + \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.0322 \\ -0.0083 \\ -0.0418 \end{bmatrix} + \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.0734 \\ 0.1551 \\ -0.0761 \end{bmatrix} \right) \\
&\approx \begin{bmatrix} 0.5183 \\ 0.5387 \\ 0.4810 \end{bmatrix}
\end{aligned}$$

b. Perhitungan *input gate*

$$\begin{aligned}
 i_2 &= \sigma(W_i \cdot [h_{t-1}, x_2] + b_i) \\
 &= \sigma \left( \begin{bmatrix} 0.0024 & -0.0646 & -0.1115 & 0.0309 & 0.0670 & -0.1473 \\ 0.0245 & 0.0242 & 0.0685 & -0.1235 & -0.0038 & 0.0268 \\ -0.2058 & -0.0513 & 0.1487 & -0.1290 & -0.0500 & 0.0012 \end{bmatrix} \cdot \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \\ 0.795455 \\ 0.2 \\ 0.413793 \end{bmatrix} + \begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix} \right) \\
 &= \sigma \left( \begin{bmatrix} -0.0149 \\ -0.0894 \\ -0.1301 \end{bmatrix} + \begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix} \right) \\
 &= \sigma \left( \begin{bmatrix} 0.9481 \\ 0.9177 \\ 0.8133 \end{bmatrix} \right) \\
 &\approx \begin{bmatrix} 0.6743 \\ 0.7146 \\ 0.6928 \end{bmatrix}
 \end{aligned}$$

c. Perhitungan nilai kandidat baru yang ditambahkan ke *cell state*

$$\begin{aligned}
 \tilde{c}_2 &= \tanh(W_{\tilde{c}} \cdot [h_{t-1}, x_2] + b_{\tilde{c}}) \\
 &= \tanh \left( \begin{bmatrix} 0.2202 & 0.0466 & -0.2110 & -0.2157 & -0.0113 & 0.0410 \\ 0.0991 & 0.0382 & 0.2699 & -0.0833 & 0.0267 & 0.1811 \\ -0.0210 & 0.1539 & -0.0062 & 0.0269 & 0.0704 & -0.1196 \end{bmatrix} \cdot \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \\ 0.795455 \\ 0.2 \\ 0.413793 \end{bmatrix} + \begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix} \right) \\
 &= \tanh \left( \begin{bmatrix} -0.1360 \\ -0.0127 \\ -0.0273 \end{bmatrix} + \begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix} \right) \\
 &= \tanh \left( \begin{bmatrix} -0.226 \\ -0.2143 \\ -0.1185 \end{bmatrix} \right)
 \end{aligned}$$

$$\approx \begin{bmatrix} -0.2222 \\ -0.2111 \\ -0.1179 \end{bmatrix}$$

d. Perhitungan *cell state*

$$\begin{aligned} C_2 &= f_2 \odot C_{t-1} + i_2 \odot \tilde{c}_2 \\ &= \begin{bmatrix} 0.5183 \\ 0.5387 \\ 0.4810 \end{bmatrix} \odot \begin{bmatrix} -0.1748 \\ -0.1396 \\ -0.0547 \end{bmatrix} + \begin{bmatrix} 0.6743 \\ 0.7146 \\ 0.6928 \end{bmatrix} \odot \begin{bmatrix} -0.2222 \\ -0.2111 \\ -0.1179 \end{bmatrix} \\ &= \begin{bmatrix} 0.2404 \\ -0.2260 \\ -0.1080 \end{bmatrix} \end{aligned}$$

e. Perhitungan *output gate*

$$\begin{aligned} o_2 &= \sigma(W_o \cdot [h_{t-1}, x_2] + b_o) \\ &= \sigma \left( \begin{bmatrix} 0.0423 & 0.0027 & -0.1361 & -0.0258 & 0.0776 & 0.1230 \\ 0.3388 & -0.0117 & 0.0497 & 0.0484 & -0.0100 & -0.0498 \\ -0.1624 & 0.1384 & -0.0353 & -0.0478 & 0.0211 & 0.0335 \end{bmatrix} \cdot \begin{bmatrix} 0.0875 \\ -0.0757 \\ -0.0263 \\ 0.795455 \\ 0.2 \\ 0.413793 \end{bmatrix} + \begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix} \right) \\ &= \sigma \left( \begin{bmatrix} 0.0530 \\ 0.0451 \\ -0.0437 \end{bmatrix} + \begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix} \right) \\ &= \sigma \left( \begin{bmatrix} 0.0941 \\ 0.1925 \\ -0.0792 \end{bmatrix} \right) \\ &\approx \begin{bmatrix} 0.5235 \\ 0.5480 \\ 0.4802 \end{bmatrix} \end{aligned}$$

f. Perhitungan *hidden state*

$$h_2 = o_2 \odot \tanh(C_2)$$

$$\begin{aligned}
&= \begin{bmatrix} 0.5235 \\ 0.5480 \\ 0.48021 \end{bmatrix} \odot \tanh \left( \begin{bmatrix} 0.2404 \\ -0.2260 \\ -0.1080 \end{bmatrix} \right) \\
&= \begin{bmatrix} 0.5116 \\ 0.4963 \\ 0.4476 \end{bmatrix} \odot \begin{bmatrix} 0.2359 \\ -0.2222 \\ -0.1076 \end{bmatrix} \\
&\approx \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \end{bmatrix}
\end{aligned}$$

- Perhitungan hari ke-3

Diketahui:

$$\begin{aligned}
h_{t-1} &= \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \end{bmatrix} \\
[h_{t-1}, x_3] &= \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \\ 0.704545 \\ 0.378947 \\ 0.471264 \end{bmatrix} \\
C_2 &= \begin{bmatrix} 0.1780 \\ -0.0642 \\ -0.1505 \end{bmatrix}
\end{aligned}$$

- a. Perhitungan *forget gate*

$$\begin{aligned}
f_3 &= \sigma(W_f \cdot [h_{t-1}, x_3] + b_f) \\
&= \sigma \left( \begin{bmatrix} 0.1184 & -0.1136 & -0.1760 & -0.0026 & -0.0621 & 0.0559 \\ 0.1162 & 0.0645 & 0.0886 & -0.0074 & -0.0003 & -0.0128 \\ -0.0817 & 0.0048 & -0.1380 & -0.0565 & -0.0109 & 0.0222 \end{bmatrix} \cdot \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \\ 0.704545 \\ 0.378947 \\ 0.471264 \end{bmatrix} + \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.0363 \\ -0.0087 \\ -0.0372 \end{bmatrix} + \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} \right)
\end{aligned}$$

$$= \sigma \begin{pmatrix} 0.0775 \\ 0.1547 \\ -0.0715 \end{pmatrix}$$

$$\approx \begin{bmatrix} 0.5194 \\ 0.5386 \\ 0.4821 \end{bmatrix}$$

b. Perhitungan *input gate*

$$\begin{aligned}
i_3 &= \sigma(W_i \cdot [h_{t-1}, x_3] + b_i) \\
&= \sigma \left( \begin{bmatrix} 0.0024 & -0.0646 & -0.1115 & 0.0309 & 0.0670 & -0.1473 \\ 0.0245 & 0.0242 & 0.0685 & -0.1235 & -0.0038 & 0.0268 \\ -0.2058 & -0.0513 & 0.1487 & -0.1290 & -0.0500 & 0.0012 \end{bmatrix} \cdot \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \\ 0.704545 \\ 0.378947 \\ 0.471264 \end{bmatrix} + \begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} -0.0095 \\ -0.1041 \\ -0.1356 \end{bmatrix} + \begin{bmatrix} 0.9630 \\ 1.0071 \\ 0.9434 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.9535 \\ 0.903 \\ 0.8078 \end{bmatrix} \right) \\
&\approx \begin{bmatrix} 0.7218 \\ 0.7116 \\ 0.6916 \end{bmatrix}
\end{aligned}$$

c. Perhitungan nilai kandidat baru yang ditambahkan ke *cell state*

$$\begin{aligned}
c_3 &= \tanh(W_c \cdot [h_{t-1}, x_3] + b_c) \\
&= \tanh \left( \begin{bmatrix} 0.2202 & 0.0466 & -0.2110 & -0.2157 & -0.0113 & 0.0410 \\ 0.0991 & 0.0382 & 0.2699 & -0.0833 & 0.0267 & 0.1811 \\ -0.0210 & 0.1539 & -0.0062 & 0.0269 & 0.0704 & -0.1196 \end{bmatrix} \cdot \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \\ 0.704545 \\ 0.378947 \\ 0.471264 \end{bmatrix} + \begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix} \right)
\end{aligned}$$

$$\begin{aligned}
&= \tanh \left( \begin{bmatrix} -0.1054 \\ 0.0315 \\ -0.0299 \end{bmatrix} + \begin{bmatrix} -0.0900 \\ -0.2016 \\ -0.0912 \end{bmatrix} \right) \\
&= \tanh \left( \begin{bmatrix} -0.1954 \\ -0.1701 \\ -0.1211 \end{bmatrix} \right) \\
&\approx \begin{bmatrix} -0.1929 \\ -0.1685 \\ -0.1205 \end{bmatrix}
\end{aligned}$$

d. Perhitungan *cell state*

$$\begin{aligned}
C_3 &= f_3 \odot C_{t-1} + i_3 \odot \tilde{c}_3 \\
&= \begin{bmatrix} 0.5194 \\ 0.5386 \\ 0.4821 \end{bmatrix} \odot \begin{bmatrix} 0.1780 \\ -0.0642 \\ -0.1505 \end{bmatrix} + \begin{bmatrix} 0.7218 \\ 0.7116 \\ 0.6916 \end{bmatrix} \odot \begin{bmatrix} -0.1929 \\ -0.1685 \\ -0.1205 \end{bmatrix} \\
&= \begin{bmatrix} -0.0468 \\ -0.1545 \\ -0.1559 \end{bmatrix}
\end{aligned}$$

e. Perhitungan *output gate*

$$\begin{aligned}
o_3 &= \sigma(W_o \cdot [h_{t-1}, x_3] + b_o) \\
&= \sigma \left( \begin{bmatrix} 0.0423 & 0.0027 & -0.1361 & -0.0258 & 0.0776 & 0.1230 \\ 0.3388 & -0.0117 & 0.0497 & 0.0484 & -0.0100 & -0.0498 \\ -0.1624 & 0.1384 & -0.0353 & -0.0478 & 0.0211 & 0.0335 \end{bmatrix} \cdot \begin{bmatrix} 0.1207 \\ -0.1103 \\ -0.0482 \\ 0.704545 \\ 0.378947 \\ 0.471264 \end{bmatrix} + \begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.0806 \\ 0.0466 \\ -0.0421 \end{bmatrix} + \begin{bmatrix} 0.0411 \\ 0.1474 \\ -0.0355 \end{bmatrix} \right) \\
&= \sigma \left( \begin{bmatrix} 0.1217 \\ 0.194 \\ -0.0776 \end{bmatrix} \right) \\
&\approx \begin{bmatrix} 0.5304 \\ 0.5483 \\ 0.4806 \end{bmatrix}
\end{aligned}$$

f. Perhitungan *hidden state*

$$\begin{aligned}
 h_3 &= o_3 \odot \tanh(C_3) \\
 &= \begin{bmatrix} 0.5304 \\ 0.5483 \\ 0.4806 \end{bmatrix} \odot \tanh \left( \begin{bmatrix} -0.0468 \\ -0.1545 \\ -0.1559 \end{bmatrix} \right) \\
 &= \begin{bmatrix} 0.5304 \\ 0.5483 \\ 0.4806 \end{bmatrix} \odot \begin{bmatrix} -0.0467 \\ -0.1532 \\ -0.1546 \end{bmatrix} \\
 &\approx \begin{bmatrix} -0.0248 \\ -0.0840 \\ -0.0743 \end{bmatrix}
 \end{aligned}$$

- Perhitungan *output* peramalan hari ke-4

Diketahui:

$$h_3 \approx \begin{bmatrix} -0.0248 \\ -0.0840 \\ -0.0743 \end{bmatrix}$$

Perhitungan *output* peramalan

$$\begin{aligned}
 \hat{Y} &= W_y \cdot h_3 + b_y \\
 &= \begin{bmatrix} 0.1758 & 0.1461 & 0.2959 \\ 0.3312 & 0.2497 & 0.2273 \\ -0.3170 & 0.0744 & -0.0096 \end{bmatrix} \cdot \begin{bmatrix} -0.0248 \\ -0.0840 \\ -0.0743 \end{bmatrix} + \begin{bmatrix} 0.5923 \\ 0.4600 \\ 0.4439 \end{bmatrix} \\
 &\approx \begin{bmatrix} 0.5537 \\ 0.4139 \\ 0.4462 \end{bmatrix}
 \end{aligned}$$

Berdasarkan contoh perhitungan matematis LSTM di atas dengan *timestep* sebesar 3 dan *hidden neuron* sebesar 3, didapatkan *output* peramalan pada hari ke-4 sebesar 0.5537 untuk suhu minimum, 0.4139 untuk suhu maksimum, dan 0.4462 untuk suhu rata-rata. Akan tetapi, nilai tersebut masih dalam bentuk normalisasi dan akan dilakukan denormalisasi untuk mengembalikan nilai dari hasil perhitungan ke bentuk aslinya.

## 4.5 Perhitungan Optimasi RMSProp

Pada tahap ini, dijelaskan contoh proses perhitungan pembaruan bobot dan bias pada salah satu *gate* LSTM, yaitu *forget gate* menggunakan algoritma optimasi RMSProp. Proses perhitungan untuk memperbarui bobot dan bias *forget gate* seperti berikut.

Diketahui:

$$\eta = 0.001, \gamma = 0.9$$

$$E[g_w^2]_{t-1} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, E[g_b^2]_{t-1} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$\varepsilon_w = \begin{bmatrix} 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} \\ 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} \\ 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} & 10^{-8} \end{bmatrix}, \varepsilon_b = \begin{bmatrix} 10^{-8} \\ 10^{-8} \\ 10^{-8} \end{bmatrix}$$

### 1. Perhitungan gradien bobot *forget gate*

- Langkah 1 dan 2: menghitung gradien *loss output* ( $\hat{Y}$ ) dan gradien *hidden state* pada *timestep* 3

$$\begin{aligned} \delta\hat{Y} &= \hat{Y} - Y \\ &= \begin{bmatrix} 0.5537 \\ 0.4139 \\ 0.4462 \end{bmatrix} - \begin{bmatrix} 0.75 \\ 0.284211 \\ 0.344828 \end{bmatrix} \\ &= \begin{bmatrix} -0.1963 \\ 0.1297 \\ 0.1014 \end{bmatrix} \\ \delta h_3 &= (W_y)^T \cdot \delta\hat{Y} \\ &= \begin{bmatrix} 0.1758 & 0.3312 & -0.3170 \\ 0.1461 & 0.2497 & 0.0744 \\ 0.2959 & 0.2273 & -0.0096 \end{bmatrix} \cdot \begin{bmatrix} -0.1963 \\ 0.1297 \\ 0.1014 \end{bmatrix} \\ &= \begin{bmatrix} -0.0236 \\ 0.0112 \\ -0.0296 \end{bmatrix} \end{aligned}$$

- Langkah 3: menghitung gradien *forget gate* tiap *timestep* dimulai dari  $t = 3$  ke  $t = 1$

a.  $Timestep = 3$

$$\begin{aligned}
 \delta_{C_3} &= \delta_{h_3} \odot o_3 \odot (1 - \tanh^2(C_3)) + \delta_{C_{t+1}} \odot f_{t+1} \\
 &= \begin{bmatrix} -0.0236 \\ 0.0112 \\ -0.0296 \end{bmatrix} \odot \begin{bmatrix} 0.5304 \\ 0.5483 \\ 0.4806 \end{bmatrix} \odot \left( 1 - \tanh^2 \left( \begin{bmatrix} -0.0468 \\ -0.1545 \\ -0.1559 \end{bmatrix} \right) \right) \\
 &= \begin{bmatrix} -0.0125 \\ 0.0059 \\ -0.0139 \end{bmatrix} \\
 \delta_{f_3} &= (\delta_{C_3} \odot C_2) \odot ((1 - f_3) \odot f_3) \\
 &= \left( \begin{bmatrix} -0.0125 \\ 0.0059 \\ -0.0139 \end{bmatrix} \odot \begin{bmatrix} 0.2404 \\ -0.2260 \\ -0.1080 \end{bmatrix} \right) \odot \left( \left( 1 - \begin{bmatrix} 0.5194 \\ 0.5386 \\ 0.4821 \end{bmatrix} \right) \odot \begin{bmatrix} 0.5194 \\ 0.5386 \\ 0.4821 \end{bmatrix} \right) \\
 &= \begin{bmatrix} -0.0007 \\ -0.0003 \\ 0.0014 \end{bmatrix} \\
 \delta_{i_3} &= \delta_{C_3} \odot \tilde{c}_3 \odot i_3 \odot (1 - i_3) \\
 &= \begin{bmatrix} -0.0125 \\ 0.0059 \\ 0.0139 \end{bmatrix} \odot \begin{bmatrix} -0.1929 \\ -0.1685 \\ -0.1205 \end{bmatrix} \odot \begin{bmatrix} 0.7218 \\ 0.7116 \\ 0.6916 \end{bmatrix} \odot \left( 1 - \begin{bmatrix} 0.7218 \\ 0.7116 \\ 0.6916 \end{bmatrix} \right) \\
 &= \begin{bmatrix} 0.0005 \\ -0.0002 \\ -0.0004 \end{bmatrix} \\
 \delta_{\tilde{c}_3} &= \delta_{C_3} \odot i_3 \odot (1 - \tilde{c}_3^2) \\
 &= \begin{bmatrix} -0.0125 \\ 0.0059 \\ -0.0139 \end{bmatrix} \odot \begin{bmatrix} 0.7218 \\ 0.7116 \\ 0.6916 \end{bmatrix} \odot \left( 1 - \begin{bmatrix} -0.1929 \\ -0.1685 \\ -0.1205 \end{bmatrix}^2 \right) \\
 &= \begin{bmatrix} -0.0087 \\ 0.0041 \\ -0.0095 \end{bmatrix} \\
 \delta_{o_3} &= \delta_{h_3} \odot \tanh(C_3) \odot o_3 \odot (1 - o_3) \\
 &= \left( \begin{bmatrix} -0.0236 \\ 0.0112 \\ -0.0296 \end{bmatrix} \odot \tanh \left( \begin{bmatrix} -0.0468 \\ -0.1545 \\ -0.1559 \end{bmatrix} \right) \right) \odot \left( \begin{bmatrix} 0.5304 \\ 0.5483 \\ 0.4806 \end{bmatrix} \odot \left( 1 - \begin{bmatrix} 0.5304 \\ 0.5483 \\ 0.4806 \end{bmatrix} \right) \right)
 \end{aligned}$$

$$\begin{aligned}
&= \begin{bmatrix} 0.0002 \\ -0.0004 \\ 0.0011 \end{bmatrix} \\
\nabla W_{f_3} &= \delta_{f_3}[h_{t-1}, x_t]^T \\
&= \begin{bmatrix} -0.0007 \\ -0.0003 \\ 0.0014 \end{bmatrix} [0.1207 \quad -0.1103 \quad -0.0482 \quad 0.704545 \quad 0.378947 \quad 0.471264] \\
&= \begin{bmatrix} -0.00084 & 0.000077 & 0.000034 & -0.000493 & -0.000265 & -0.000330 \\ -0.000036 & 0.000033 & 0.000014 & -0.000211 & -0.000114 & -0.000141 \\ 0.000169 & -0.000154 & -0.000067 & 0.000986 & 0.000531 & 0.000660 \end{bmatrix}
\end{aligned}$$

b. *Timestep = 2*

$$\begin{aligned}
\delta_{h_2} &= W_{fh}^T \delta_{f_3} + W_{ih}^T \delta_{i_3} + W_{ch}^T \delta_{c_3} + W_{oh}^T \delta_{o_3} \\
&\quad \begin{bmatrix} 0.1184 & 0.1162 & -0.0817 \\ -0.1136 & 0.0645 & 0.0048 \\ -0.1760 & 0.0886 & -0.1380 \end{bmatrix} \begin{bmatrix} -0.0007 \\ -0.0003 \\ 0.0014 \end{bmatrix} + \\
&= \begin{bmatrix} 0.0024 & 0.0245 & -0.2058 \\ -0.0646 & 0.0242 & 0.0685 \\ -0.1115 & -0.0513 & 0.1487 \end{bmatrix} \begin{bmatrix} 0.0005 \\ -0.0002 \\ -0.0004 \end{bmatrix} + \\
&= \begin{bmatrix} 0.2202 & 0.0991 & -0.0210 \\ 0.0466 & 0.0382 & 0.1539 \\ -0.2110 & 0.2699 & -0.0062 \end{bmatrix} \begin{bmatrix} -0.0087 \\ 0.0041 \\ -0.0095 \end{bmatrix} + \\
&\quad \begin{bmatrix} 0.0423 & 0.3388 & -0.1624 \\ 0.0027 & -0.0117 & 0.1384 \\ -0.1361 & 0.0497 & -0.0353 \end{bmatrix} \begin{bmatrix} 0.0002 \\ -0.0004 \\ 0.0011 \end{bmatrix} \\
&= \begin{bmatrix} -0.0018 \\ -0.0015 \\ 0.0027 \end{bmatrix} \\
\delta_{C_2} &= \delta_{h_2} \odot o_2 \odot (1 - \tanh^2(C_2)) + \delta_{C_{t+1}} \odot f_{t+1} \\
&= \begin{bmatrix} -0.0018 \\ -0.0015 \\ 0.0027 \end{bmatrix} \odot \begin{bmatrix} 0.5235 \\ 0.5480 \\ 0.4802 \end{bmatrix} \odot \left( 1 - \tanh^2 \left( \begin{bmatrix} 0.2404 \\ -0.2260 \\ -0.1080 \end{bmatrix} \right) \right) + \\
&= \left( \begin{bmatrix} -0.0125 \\ 0.0059 \\ -0.0139 \end{bmatrix} \odot \begin{bmatrix} 0.5181 \\ 0.4821 \\ 0.4427 \end{bmatrix} \right) \\
&= \begin{bmatrix} -0.00737 \\ 0.00206 \\ -0.00487 \end{bmatrix} \\
\delta_{f_3} &= (\delta_{C_2} \odot C_1) \odot ((1 - f_2) \odot f_2) \\
&= \left( \begin{bmatrix} -0.00737 \\ 0.00206 \\ -0.00487 \end{bmatrix} \odot \begin{bmatrix} -0.1748 \\ -0.1396 \\ -0.0547 \end{bmatrix} \right) \odot \left( \left( 1 - \begin{bmatrix} 0.5183 \\ 0.5387 \\ 0.4810 \end{bmatrix} \right) \odot \begin{bmatrix} 0.5183 \\ 0.5387 \\ 0.4810 \end{bmatrix} \right) \\
&= \begin{bmatrix} 0.000322 \\ -0.000072 \\ 0.000067 \end{bmatrix}
\end{aligned}$$

$$\begin{aligned}
\delta_{i_2} &= \delta_{c_2} \odot \tilde{c}_2 \odot i_2 \odot (1 - i_2) \\
&= \begin{bmatrix} -0.00737 \\ 0.00206 \\ -0.00487 \end{bmatrix} \odot \begin{bmatrix} -0.2222 \\ -0.2111 \\ -0.1179 \end{bmatrix} \odot \begin{bmatrix} 0.6743 \\ 0.7146 \\ 0.6928 \end{bmatrix} \odot \left( 1 - \begin{bmatrix} 0.6743 \\ 0.7146 \\ 0.6928 \end{bmatrix} \right) \\
&= \begin{bmatrix} 0.000360 \\ -0.000089 \\ 0.000122 \end{bmatrix} \\
\delta_{\tilde{c}_2} &= \delta_{c_2} \odot i_2 \odot (1 - \tilde{c}_2^2) \\
&= \begin{bmatrix} -0.00737 \\ 0.00206 \\ -0.00487 \end{bmatrix} \odot \begin{bmatrix} 0.6743 \\ 0.7146 \\ 0.6928 \end{bmatrix} \odot \left( 1 - \begin{bmatrix} -0.2222 \\ -0.2111 \\ -0.1179 \end{bmatrix}^2 \right) \\
&= \begin{bmatrix} -0.004724 \\ 0.001406 \\ -0.003329 \end{bmatrix} \\
\delta_{o_2} &= \delta_{h_2} \odot \tanh(c_2) \odot o_2 \odot (1 - o_2) \\
&= \begin{bmatrix} -0.0018 \\ -0.0015 \\ 0.0027 \end{bmatrix} \odot \tanh \left( \begin{bmatrix} 0.2404 \\ -0.2260 \\ -0.1080 \end{bmatrix} \right) \odot \begin{bmatrix} 0.5235 \\ 0.5480 \\ 0.4802 \end{bmatrix} \odot \left( 1 - \begin{bmatrix} 0.5235 \\ 0.5480 \\ 0.4802 \end{bmatrix} \right) \\
&= \begin{bmatrix} -0.000106 \\ 0.000083 \\ -0.000072 \end{bmatrix} \\
\nabla W_{f_2} &= \delta_{f_2} [h_{t-1}, x_t]^T \\
&= \begin{bmatrix} 0.000322 \\ -0.000072 \\ 0.000067 \end{bmatrix} [0.0875 \quad -0.0757 \quad -0.0263 \quad 0.795455 \quad 0.2 \quad 0.413793] \\
&= \begin{bmatrix} 0.000028 & -0.000024 & -0.000008 & 0.000256 & 0.000064 & 0.000133 \\ -0.000006 & 0.000005 & 0.000002 & -0.000057 & -0.000014 & -0.000030 \\ 0.000006 & -0.000005 & -0.000002 & 0.000053 & 0.000013 & 0.000028 \end{bmatrix}
\end{aligned}$$

c.  $Timestep = 1$

$$\begin{aligned}
\delta_{h_1} &= W_{fh}^T \delta_{f_2} + W_{ih}^T \delta_{i_2} + W_{ch}^T \delta_{\tilde{c}_2} + W_{oh}^T \delta_{o_2} \\
&= \begin{bmatrix} 0.1184 & 0.1162 & -0.0817 \end{bmatrix} \begin{bmatrix} 0.000322 \\ -0.000072 \\ 0.000067 \end{bmatrix} + \\
&\quad \begin{bmatrix} 0.0024 & 0.0245 & -0.2058 \\ -0.0646 & 0.0242 & 0.0685 \\ -0.1115 & -0.0513 & 0.1487 \end{bmatrix} \begin{bmatrix} 0.000360 \\ -0.000089 \\ 0.000122 \end{bmatrix} +
\end{aligned}$$

$$\begin{aligned}
& \begin{bmatrix} 0.2202 & 0.0991 & -0.0210 \\ 0.0466 & 0.0382 & 0.1539 \\ -0.2110 & 0.2699 & -0.0062 \end{bmatrix} \begin{bmatrix} -0.004724 \\ 0.001406 \\ -0.003329 \end{bmatrix} + \\
& \begin{bmatrix} 0.0423 & 0.3388 & -0.1624 \\ 0.0027 & -0.0117 & 0.1384 \\ -0.1361 & 0.0497 & -0.0353 \end{bmatrix} \begin{bmatrix} -0.000106 \\ 0.000083 \\ -0.000072 \end{bmatrix} \\
& = \begin{bmatrix} -0.000798 \\ -0.000748 \\ 0.001329 \end{bmatrix} \\
\delta_{C_1} & = \delta h_1 \odot o_1 \odot (1 - \tanh^2(C_1)) + \delta C_2 \odot f_2 \\
& = \begin{bmatrix} -0.000798 \\ -0.000748 \\ 0.001329 \end{bmatrix} \odot \begin{bmatrix} 0.5057 \\ 0.5459 \\ 0.4821 \end{bmatrix} \odot \left( 1 - \tanh^2 \left( \begin{bmatrix} -0.1748 \\ -0.1396 \\ -0.0547 \end{bmatrix} \right) \right) + \\
& = \left( \begin{bmatrix} -0.00737 \\ 0.00206 \\ -0.00487 \end{bmatrix} \odot \begin{bmatrix} 0.5183 \\ 0.5387 \\ 0.4810 \end{bmatrix} \right) \\
& = \begin{bmatrix} -0.004211 \\ 0.000710 \\ -0.001703 \end{bmatrix} \\
\delta_{f_1} & = (\delta_{C_1} \odot C_0) \odot ((1 - f_1) \odot f_1) \\
& = \left( \begin{bmatrix} -0.004211 \\ 0.000710 \\ -0.001703 \end{bmatrix} \odot \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \right) \odot \left( \left( 1 - \begin{bmatrix} 0.5078 \\ 0.5383 \\ 0.481 \end{bmatrix} \right) \odot \begin{bmatrix} 0.5078 \\ 0.5383 \\ 0.481 \end{bmatrix} \right) \\
& = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \\
\nabla W_{f_1} & = \delta_{f_1} [h_{t-1}, x_t]^T \\
& = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} [0 \ 0 \ 0 \ 0.761364 \ 0.410526 \ 0.310345] \\
& = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}
\end{aligned}$$

- Akumulasi gradien untuk *forget gate*

a. Bobot

$$\begin{aligned}
g_{W,t} & = \nabla W_f \\
& = \sum_{(t=1)}^3 \delta_f [h_{t-1}, x_t]^T
\end{aligned}$$

$$\begin{aligned}
& \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} + \\
& = \begin{bmatrix} 0.000028 & -0.000024 & -0.000008 & 0.000256 & 0.000064 & 0.000133 \\ -0.000006 & 0.000005 & 0.000002 & -0.000057 & -0.000014 & -0.000030 \\ 0.000006 & -0.000005 & -0.000002 & 0.000053 & 0.000013 & 0.000028 \end{bmatrix} \\
& \quad \begin{bmatrix} -0.00084 & 0.000077 & 0.000034 & -0.000493 & -0.000265 & -0.000330 \\ -0.000036 & 0.000033 & 0.000014 & -0.000211 & -0.000114 & -0.000141 \\ 0.000169 & -0.000154 & -0.000067 & 0.000986 & 0.000531 & 0.000660 \end{bmatrix} \\
& = \begin{bmatrix} -0.000056 & 0.000053 & 0.000026 & -0.000237 & -0.000201 & -0.000197 \\ -0.000042 & 0.000038 & 0.000016 & -0.000268 & -0.000128 & -0.000171 \\ 0.000175 & -0.000159 & -0.000069 & 0.001039 & 0.000544 & 0.000688 \end{bmatrix}
\end{aligned}$$

### b. Bias

$$\begin{aligned}
g_{b,t} &= \nabla b_f \\
&= \sum_{(t=1)}^3 \delta_f \\
&= \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} 0.000322 \\ -0.000072 \\ 0.000067 \end{bmatrix} + \begin{bmatrix} -0.0007 \\ -0.0003 \\ 0.0014 \end{bmatrix} \\
&= \begin{bmatrix} -0.000378 \\ -0.000372 \\ 0.001467 \end{bmatrix}
\end{aligned}$$

## 2. Memperbarui rata-rata bergerak dari kuadrat gradien

Bobot

$$\begin{aligned}
E[g_W^2]_t &= \gamma E[g_W^2]_{t-1} + (1 - \gamma) g_{W,t}^2 \\
&= 0.9 \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} + (1 - 0.9) \\
&\quad \cdot \begin{bmatrix} -0.000056 & 0.000053 & 0.000026 & -0.000237 & -0.000201 & -0.000197 \\ -0.000042 & 0.000038 & 0.000016 & -0.000268 & -0.000128 & -0.000171 \\ 0.000175 & -0.000159 & -0.000069 & 0.001039 & 0.000544 & 0.000688 \end{bmatrix}^2 \\
&= \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} + \\
&\quad \begin{bmatrix} 3.14 \times 10^{-11} & 2.81 \times 10^{-11} & 6.76 \times 10^{-12} & 5.62 \times 10^{-10} & 4.04 \times 10^{-10} & 3.88 \times 10^{-10} \\ 1.76 \times 10^{-11} & 1.44 \times 10^{-11} & 2.56 \times 10^{-12} & 7.18 \times 10^{-10} & 1.64 \times 10^{-10} & 2.92 \times 10^{-10} \\ 3.06 \times 10^{-10} & 2.53 \times 10^{-10} & 4.76 \times 10^{-11} & 1.08 \times 10^{-8} & 2.96 \times 10^{-9} & 4.73 \times 10^{-9} \end{bmatrix} \\
&= \begin{bmatrix} 3.14 \times 10^{-11} & 2.81 \times 10^{-11} & 6.76 \times 10^{-12} & 5.62 \times 10^{-10} & 4.04 \times 10^{-10} & 3.88 \times 10^{-10} \\ 1.76 \times 10^{-11} & 1.44 \times 10^{-11} & 2.56 \times 10^{-12} & 7.18 \times 10^{-10} & 1.64 \times 10^{-10} & 2.92 \times 10^{-10} \\ 3.06 \times 10^{-10} & 2.53 \times 10^{-10} & 4.76 \times 10^{-11} & 1.08 \times 10^{-8} & 2.96 \times 10^{-9} & 4.73 \times 10^{-9} \end{bmatrix}
\end{aligned}$$

Bias

$$E[g_b^2]_t = \gamma E[g_b^2]_{t-1} + (1 - \gamma) g_{b,t}^2$$

$$\begin{aligned}
&= 0.9 \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} + (1 - 0.9) \begin{bmatrix} -0.000378 \\ -0.000372 \\ 0.001467 \end{bmatrix}^2 \\
&= \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} 1.42884 \times 10^{-8} \\ 1.38384 \times 10^{-8} \\ 2.15209 \times 10^{-7} \end{bmatrix} \\
&= \begin{bmatrix} 1.42884 \times 10^{-8} \\ 1.38384 \times 10^{-8} \\ 2.15209 \times 10^{-7} \end{bmatrix}
\end{aligned}$$

### 3. Memperbarui parameter bobot dan bias

$$\begin{aligned}
W_{baru} &= W_{lama} - \frac{\eta}{\sqrt{E[g_W^2]_t + \varepsilon_W}} \cdot g_{W,t} \\
&= \begin{bmatrix} 0.1184 & -0.1136 & -0.1760 & -0.0026 & -0.0621 & 0.0559 \\ 0.1162 & 0.0645 & 0.0886 & -0.0074 & -0.0003 & -0.0128 \\ -0.0817 & 0.0048 & -0.1380 & -0.0565 & -0.0109 & 0.0222 \end{bmatrix} - \\
&\quad \begin{bmatrix} 0.001 \\ \sqrt{[3.14 \times 10^{-11}, 2.81 \times 10^{-11}, \dots, 3.88 \times 10^{-10}] + [10^{-8}, 10^{-8}, \dots, 10^{-8}]} \\ \sqrt{[1.76 \times 10^{-11}, 1.44 \times 10^{-11}, \dots, 2.92 \times 10^{-10}] + [10^{-8}, 10^{-8}, \dots, 10^{-8}]} \\ \sqrt{[1.06 \times 10^{-10}, 2.53 \times 10^{-10}, \dots, 4.73 \times 10^{-9}] + [10^{-8}, 10^{-8}, \dots, 10^{-8}]} \end{bmatrix} \\
&\quad \odot \begin{bmatrix} -0.000056 & 0.000053 & 0.000026 & -0.000237 & -0.000201 & -0.000197 \\ -0.000042 & 0.000038 & 0.000016 & -0.000268 & -0.000128 & -0.000171 \\ 0.000175 & -0.000159 & -0.000069 & 0.001039 & 0.000544 & 0.000688 \end{bmatrix} \\
&= \begin{bmatrix} 0.1184 & -0.1136 & -0.1760 & -0.0026 & -0.0621 & 0.0559 \\ 0.1162 & 0.0645 & 0.0886 & -0.0074 & -0.0003 & -0.0128 \\ -0.0817 & 0.0048 & -0.1380 & -0.0565 & -0.0109 & 0.0222 \end{bmatrix} - \\
&\quad \begin{bmatrix} -5.6 \times 10^{-8} & 5.3 \times 10^{-8} & 2.6 \times 10^{-8} & -2.37 \times 10^{-7} & -2.01 \times 10^{-7} & -1.97 \times 10^{-7} \\ -4.2 \times 10^{-8} & 3.8 \times 10^{-8} & 1.6 \times 10^{-8} & -2.68 \times 10^{-7} & -1.28 \times 10^{-7} & -1.71 \times 10^{-7} \\ 1.75 \times 10^{-7} & -1.59 \times 10^{-7} & -6.9 \times 10^{-8} & 1.039 \times 10^{-6} & 5.44 \times 10^{-7} & 6.88 \times 10^{-7} \end{bmatrix} \div \\
&\quad \begin{bmatrix} 1.0016 \times 10^{-4} & 1.0014 \times 10^{-4} & 1.0003 \times 10^{-4} & 1.0028 \times 10^{-4} & 1.0020 \times 10^{-4} & 1.0019 \times 10^{-4} \\ 1.0012 \times 10^{-4} & 1.0011 \times 10^{-4} & 1.0001 \times 10^{-4} & 1.0036 \times 10^{-4} & 1.0008 \times 10^{-4} & 1.0015 \times 10^{-4} \\ 1.0015 \times 10^{-4} & 1.0013 \times 10^{-4} & 1.0002 \times 10^{-4} & 1.0392 \times 10^{-4} & 1.0149 \times 10^{-4} & 1.0222 \times 10^{-4} \end{bmatrix} \\
&= \begin{bmatrix} 0.1190 & -0.1141 & -0.1763 & -0.0007 & -0.0604 & 0.0576 \\ 0.1166 & 0.0641 & 0.0884 & -0.0047 & 0.0008 & -0.0111 \\ -0.0815 & 0.0063 & -0.1381 & -0.0555 & -0.0098 & 0.0239 \end{bmatrix} \\
b_{baru} &= b_{lama} - \frac{\eta}{\sqrt{E[g_b^2]_t + \varepsilon_b}} \odot g_{b,t} \\
&= \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} - \frac{0.001}{\sqrt{[1.42884 \times 10^{-8}, 1.38384 \times 10^{-8}, 2.15209 \times 10^{-7}] + [10^{-8}, 10^{-8}, 10^{-8}]}} \odot \begin{bmatrix} -0.000378 \\ -0.000372 \\ 0.001467 \end{bmatrix} \\
&= \begin{bmatrix} 0.0412 \\ 0.1634 \\ -0.0343 \end{bmatrix} - \frac{0.001}{\sqrt{[4.9283 \times 10^{-5}, 4.8824 \times 10^{-5}, 1.5007 \times 10^{-4}]}} \odot \begin{bmatrix} -0.000378 \\ -0.000372 \\ 0.001467 \end{bmatrix} \\
&= \begin{bmatrix} 0.0489 \\ 0.1710 \\ -0.0441 \end{bmatrix}
\end{aligned}$$

Berdasarkan perhitungan pembaruan bobot dan bias untuk *forget gate*, didapatkan hasil pembaruan untuk matriks bobot ( $W_f$ ) dan vektor bias ( $b_f$ ). Proses pembaruan bobot dan bias yang sama juga diterapkan secara independen pada setiap *gate* lainnya, yaitu *input gate*, *output gate*, dan *candidate cell gate*.

#### 4.6 Denormalisasi

Pada tahap ini dilakukan proses denormalisasi dengan tujuan untuk mengembalikan nilai hasil perhitungan dari tahap sebelumnya ke skala atau bentuk aslinya. Langkah-langkah perhitungan denormalisasi dengan menggunakan persamaan (2.28) ditunjukkan sebagai berikut.

1. Perhitungan denormalisasi suhu minimum

$$\begin{aligned} y &= \hat{y}(x_{max} - x_{min}) + x_{min} \\ &= 0.5537(23.4 - 14.6) + 14.6 \\ &= 19.47 \end{aligned}$$

2. Perhitungan denormalisasi suhu maksimum

$$\begin{aligned} y &= \hat{y}(x_{max} - x_{min}) + x_{min} \\ &= 0.4139(34 - 24.5) + 24.5 \\ &= 28.43 \end{aligned}$$

3. Perhitungan denormalisasi suhu rata-rata

$$\begin{aligned} y &= \hat{y}(x_{max} - x_{min}) + x_{min} \\ &= 0.4462(28.8 - 20.1) + 20.1 \\ &= 23.98 \end{aligned}$$

#### 4.7 Analisis Hasil Perbandingan Parameter Model LSTM

Pada tahap ini, akan dilakukan perbandingan hasil dari beberapa parameter model LSTM yang sudah ditetapkan pada bab 4.3. Parameter yang sudah ditetapkan

sebelumnya akan digunakan untuk mencari model yang optimal dalam meramalkan suhu udara. Parameter *batch size* yang digunakan pada penelitian ini sebesar 4, 16, 32, dan 64. Pemilihan *batch size* tidak harus merupakan kelipatan 4. Nilai apa pun dapat digunakan agar model tetap berfungsi. Namun, penggunaan *batch size* yang merupakan kelipatan dari pangkat 2 (seperti 4, 16, 32, 64) telah menjadi konvensi dan praktik terbaik karena alasan optimasi performa. Arsitektur perangkat keras modern, khususnya GPU, dirancang untuk memproses data secara paralel dalam blok-blok berukuran pangkat 2, sehingga penggunaan *batch size* semacam itu memungkinkan komputasi berjalan lebih efisien dan secara signifikan mempercepat waktu pelatihan per *epoch* (Goodfellow & Bengio, 2016). Selain parameter *batch size*, penelitian ini juga menggunakan variasi parameter *epoch*, yaitu 50, 100, 150, dan 200. Berikut ini ditampilkan hasil perbandingan performa model terhadap variasi *batch size* dan variasi *epoch*, sebagaimana tercantum pada tabel 4.6.

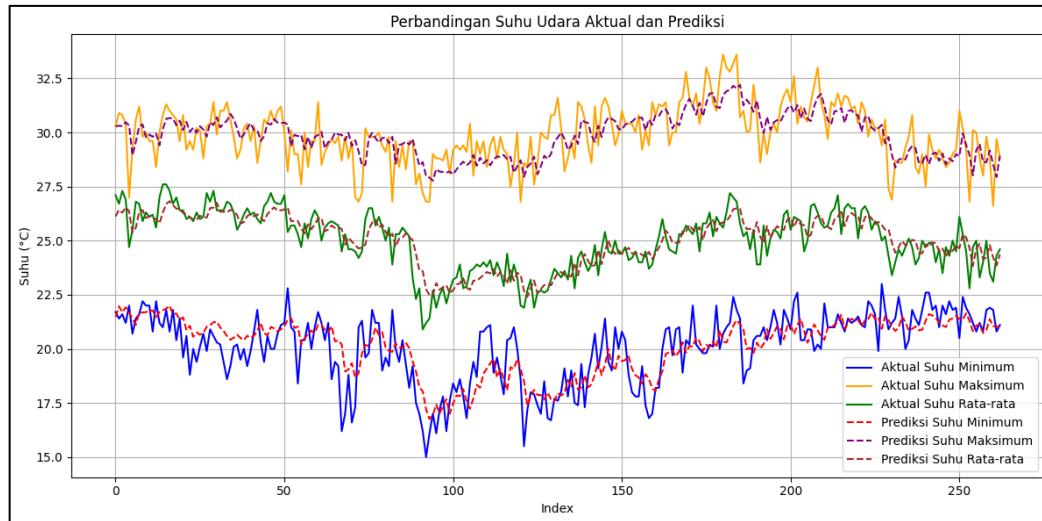
**Tabel 4.6** Hasil Perbandingan Parameter Variasi *Batch Size* dan Variasi *Epoch*

<i>Batch Size</i>	<i>Epoch</i>	RMSE			MAPE		
		Suhu Minimum	Suhu Maksimum	Suhu Rata-rata	Suhu Minimum	Suhu Maksimum	Suhu Rata-rata
4	50	1.04	1.03	0.72	4.15%	2.75%	2.26%
	100	1.04	1.04	0.70	4.14%	2.81%	2.17%
	150	1.07	1.00	0.71	4.33%	2.71%	2.24%
	200	1.13	1.02	0.73	4.51%	2.75%	2.24%
16	50	1.06	1.03	0.72	4.20%	2.67%	2.23%
	100	1.04	1.02	0.71	4.14%	2.68%	2.17%
	150	1.02	1.07	0.71	4.08%	2.82%	2.18%
	200	1.04	1.00	0.69	4.14%	2.66%	2.16%
32	50	1.11	1.05	0.77	4.37%	2.76%	2.32%

	100	1.07	1.01	0.72	4.27%	2.64%	2.22%
	150	1.04	1.03	0.71	4.15%	2.69%	2.19%
	200	1.03	1.02	0.70	4.13%	2.71%	2.19%
64	50	1.15	1.11	0.86	4.59%	2.98%	2.74%
	100	1.09	1.05	0.76	4.30%	2.79%	2.39%
	150	1.06	1.03	0.73	4.19%	2.73%	2.29%
	200	1.06	1.05	0.72	4.22%	2.79%	2.30%

Berdasarkan Tabel 4.6, diperoleh nilai akurasi RMSE dan MAPE dari berbagai variasi *batch size* dan *epoch*. Kombinasi *batch size* 16 dan *epoch* 200 menunjukkan performa paling optimal, dengan nilai RMSE dan MAPE yang lebih rendah dibandingkan kombinasi parameter lainnya. Selain itu, nilai RMSE dan MAPE pada kombinasi tersebut tidak berbeda jauh dari nilai pada variasi lain, yang menunjukkan bahwa model tetap stabil meskipun terjadi perubahan pada *batch size* dan *epoch*. Berdasarkan keseluruhan hasil tersebut, *batch size* 16 dan *epoch* 200 dipilih sebagai parameter terbaik untuk model ini.

Berdasarkan seluruh pengujian parameter yang telah dilakukan, diperoleh model terbaik dengan kombinasi *batch size* sebesar 16, *epoch* sebanyak 200, serta proporsi data pelatihan sebesar 80% dan data pengujian sebesar 20%. Model ini menghasilkan akurasi terbaik dengan nilai MAPE sebesar 4.14% untuk suhu minimum, 2.66% untuk suhu maksimum, dan 2.16% untuk suhu rata-rata. Sementara itu, nilai RMSE yang diperoleh adalah 1.04 untuk suhu minimum, 1.00 untuk suhu maksimum, dan 0.69 untuk suhu rata-rata. Hasil ini menunjukkan bahwa metode yang digunakan cukup efektif dalam meramalkan suhu pada dataset ini. Efektivitas tersebut juga terlihat dari kesesuaian pola antara hasil peramalan dan data aktual, sebagaimana ditunjukkan pada gambar 4.3.



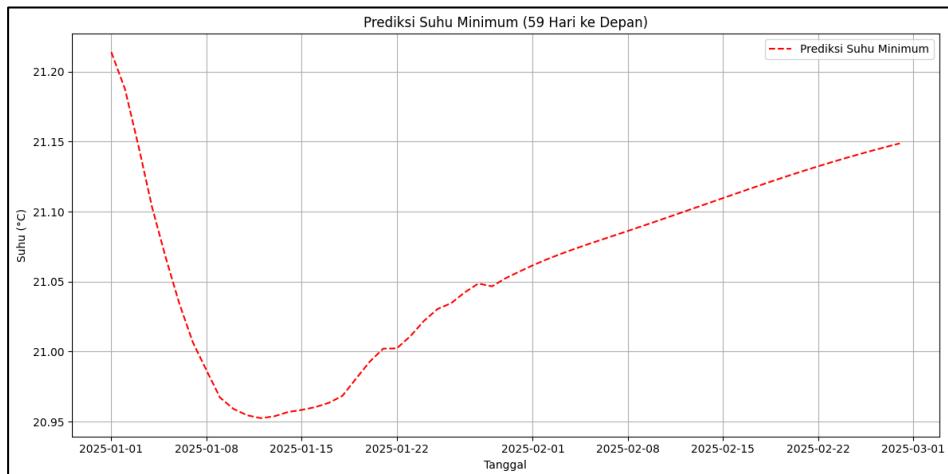
**Gambar 4.3** Grafik Perbandingan Hasil Prediksi Dengan Data Aktual

Berdasarkan gambar 4.3, dapat diketahui bahwa pola garis prediksi mengikuti pola garis aktual dengan cukup baik di ketiga kategori suhu. Hal tersebut terlihat dari bentuk tren, fluktuasi naik-turun, serta pergerakan musiman yang mirip antara data aktual dan hasil prediksi. Secara keseluruhan, model mampu menangkap pola umum suhu udara dengan akurasi cukup baik, yang mendukung hasil evaluasi nilai RMSE dan MAPE yang relatif kecil.

#### 4.8 Peramalan Suhu Udara

Setelah didapatkan model terbaik LSTM dari beberapa uji coba, kemudian akan dilakukan peramalan suhu udara selama 59 hari ke depan. Hasil peramalan suhu udara selama 59 hari ke depan akan ditampilkan pada grafik berikut.

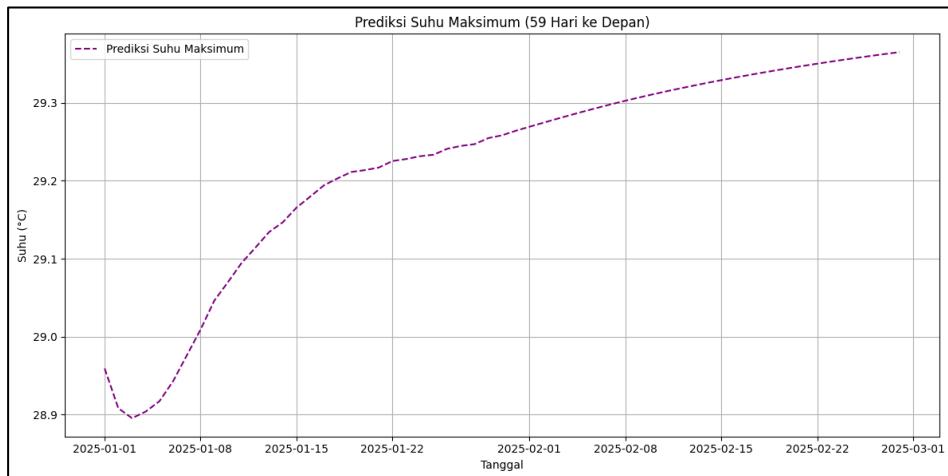
### 1. Peramalan suhu minimum selama 59 hari ke depan



**Gambar 4.4** Grafik Peramalan Suhu Minimum 59 Hari ke Depan

Berdasarkan gambar 4.4, menunjukkan hasil peramalan suhu minimum selama 59 hari ke depan, dari 1 Januari hingga 28 Februari 2025. Pola suhu minimum terlihat mengalami penurunan pada awal Januari 2025, dari sekitar  $21.21^{\circ}\text{C}$  hingga mencapai titik terendah sekitar  $20.95^{\circ}\text{C}$  pada pertengahan bulan. Setelah itu, suhu mulai mengalami peningkatan perlahan dan stabil hingga akhir Februari, mencapai sekitar  $21.21^{\circ}\text{C}$ . Fluktuasi kecil terlihat pada paruh kedua Januari, yang menunjukkan adanya variabilitas suhu harian. Namun, tren umum tetap menunjukkan pola penurunan di awal, kemudian meningkat secara bertahap, kemungkinan disebabkan oleh pergeseran musim atau pengaruh cuaca regional.

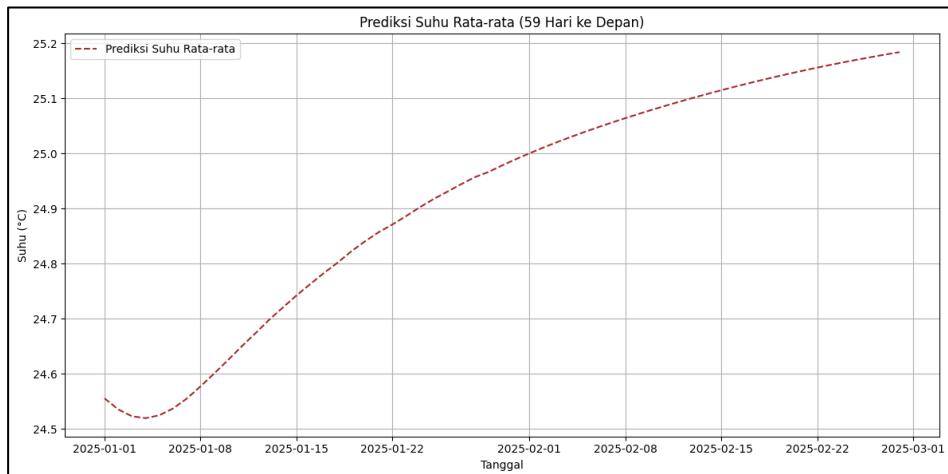
## 2. Peramalan suhu maksimum selama 59 hari ke depan



**Gambar 4.5** Grafik Peramalan Suhu Maksimum 59 Hari ke Depan

Berdasarkan gambar 4.5, menunjukkan hasil peramalan suhu maksimum selama 59 hari ke depan, dari 1 Januari hingga 28 Februari 2025. Pola pergerakan suhu maksimum terlihat mengalami sedikit penurunan pada awal Januari, turun dari sekitar  $29.86^{\circ}\text{C}$  ke titik terendah  $28.89^{\circ}\text{C}$ . Namun, penurunan ini bersifat sementara karena setelah itu suhu kembali naik secara perlahan namun konsisten. Tren kenaikan berlanjut hampir tanpa gangguan hingga mencapai sekitar  $29.36^{\circ}\text{C}$  di akhir Februari 2025. Secara keseluruhan, grafik ini menunjukkan pola pemanasan bertahap dalam suhu maksimum harian. Ini dapat dikaitkan dengan pergeseran musim dari musim hujan ke musim kemarau atau pengaruh dari peningkatan radiasi matahari seiring waktu.

### 3. Peramalan suhu rata-rata selama 59 hari ke depan



**Gambar 4.6** Grafik Peramalan Suhu Rata-rata 59 Hari ke Depan

Berdasarkan gambar 4.6, menunjukkan hasil peramalan suhu rata-rata selama 59 hari ke depan. Pola pergerakan suhu rata-rata terlihat bahwa suhu rata-rata mengalami tren kenaikan secara perlahan namun konsisten sepanjang periode peramalan. Pada awalnya, suhu berada di sekitar  $24.55^{\circ}\text{C}$ , kemudian sedikit menurun dalam beberapa hari pertama, mencapai titik terendah sekitar  $24.52^{\circ}\text{C}$ . Setelah itu, suhu mulai naik secara bertahap dan stabil, hingga mencapai sekitar  $25.18^{\circ}\text{C}$  di akhir Februari 2025. Pola grafik tersebut menunjukkan bahwa model peramalan memperkirakan adanya pola musiman atau peningkatan bertahap suhu yang mungkin berkaitan dengan transisi musim atau tren iklim lokal.

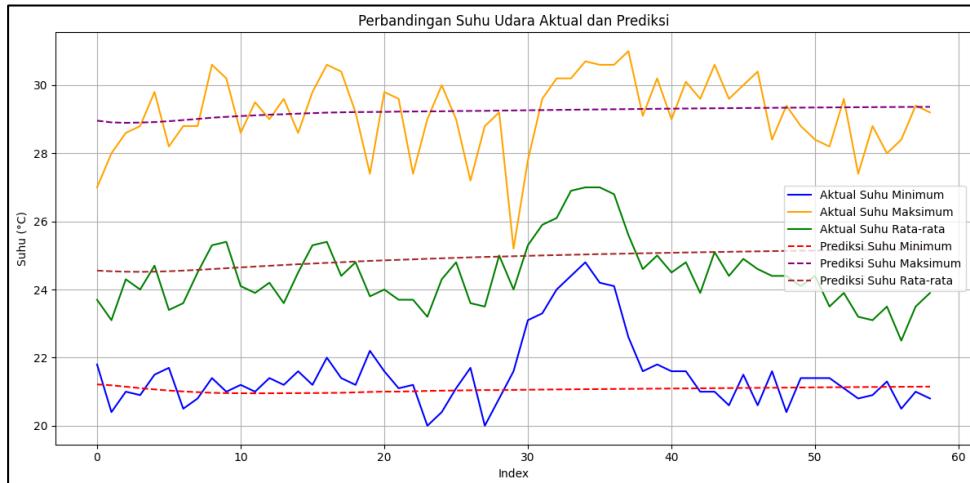
Berdasarkan hasil peramalan tiap kategori suhu selama 59 hari ke depan, dapat dikaitkan dengan kondisi terkini di wilayah Malang. Periode Januari-Februari 2025 dalam grafik terlihat adanya tren kenaikan suhu di wilayah Kabupaten Malang. Suhu minimum sempat menurun di awal Januari, namun kemudian naik secara bertahap. Suhu maksimum dan rata-rata menunjukkan kenaikan yang

konsisten, menandakan transisi dari kondisi puncak musim hujan menuju awal musim kemarau.

Dalam konteks iklim wilayah Jawa Timur, terutama Malang, grafik ini selaras dengan pola cuaca musiman. Pada Januari–Februari, meskipun wilayah ini secara umum berada dalam fase musim hujan, data menunjukkan bahwa suhu tidak mengalami penurunan tajam, melainkan justru mulai meningkat perlahan. Hal ini bisa dikaitkan dengan berkurangnya intensitas hujan sejak akhir Januari, serta adanya anomali iklim regional akibat pengaruh fenomena global seperti El Niño lemah, yang menyebabkan musim hujan 2024–2025 berakhir lebih cepat di sebagian wilayah Jawa Timur.

Fenomena ini berbanding terbalik dengan kondisi Juni 2025, di mana masyarakat Malang mulai merasakan suhu dingin yang khas di pagi dan malam hari. Kondisi ini dikenal dengan fenomena “bediding”, yaitu suhu minimum yang turun signifikan pada musim kemarau. Menurut BMKG, fenomena *bediding* terjadi akibat berhembusnya Angin Monsun Australia yang kering, serta langit malam yang cerah tanpa awan, yang menyebabkan radiasi panas dari permukaan bumi lepas ke atmosfer tanpa hambatan. Di sisi lain, suhu maksimum tetap hangat di siang hari karena paparan matahari penuh, sehingga menghasilkan rentang suhu harian yang sangat besar.

#### 4. Grafik data aktual dan hasil peramalan selama 59 hari ke depan



**Gambar 4.7** Grafik Data Aktual dan Hasil Peramalan Selama 59 Hari ke Depan

Berdasarkan gambar 4.7, dapat disimpulkan bahwa model peramalan yang digunakan menunjukkan performa yang kurang memadai dalam meramalkan kondisi suhu udara harian. Terlihat adanya perbedaan yang mencolok di mana data suhu aktual, yang diwakili oleh garis solid, menampilkan pola yang sangat dinamis dan berfluktuasi secara signifikan dari hari ke hari, yang mencerminkan variasi cuaca alami. Sebaliknya, hasil peramalan yang digambarkan dengan garis putus-putus menampilkan tren yang hampir sepenuhnya datar dan statis untuk ketiga kategori suhu minimum, maksimum, dan rata-rata. Kegagalan model untuk menangkap fluktuasi suhu harian ini kemungkinan besar disebabkan oleh kurangnya fitur yang informatif pada data yang digunakan untuk pelatihan. Suhu udara tidak hanya bergantung pada nilainya di hari sebelumnya. Suhu sangat dipengaruhi oleh banyak faktor lain seperti kelembapan, kecepatan angin, tekanan udara, dan pola musiman. Tanpa adanya konteks dari fitur-fitur penting ini, model tidak memiliki informasi yang cukup untuk memahami mengapa suhu seharusnya naik atau turun. Model ini terbukti kurang akurat dalam menangkap puncak suhu

tertinggi maupun penurunan suhu terendah, dan pada dasarnya hanya menghasilkan sebuah nilai rata-rata yang konstan selama periode 59 hari.

#### 4.9 Integrasi Keislaman

Hasil peramalan yang dihasilkan pada penelitian ini menunjukkan bahwa dalam rentang tanggal 1 Januari hingga 28 Februari 2025, di wilayah Kabupaten Malang diperkirakan terjadi fluktuasi suhu dengan kecenderungan kenaikan bertahap pada suhu minimum, maksimum, dan rata-rata harian. Berdasarkan hasil grafik peramalan, suhu minimum sempat mengalami penurunan pada awal Januari namun meningkat kembali secara konsisten hingga akhir Februari. Sementara itu, suhu maksimum dan rata-rata menunjukkan tren kenaikan yang cukup signifikan, yang mengindikasikan pemanasan lokal secara perlahan namun pasti. Hal tersebut mengindikasikan adanya pergeseran pola cuaca yang berpotensi mempengaruhi sektor pertanian, kesehatan, dan kehidupan sosial ekonomi masyarakat Kabupaten Malang. Sebagaimana tujuan sebuah peramalan tentang fenomena alam, hasil ini sangat bermanfaat terutama bagi peneliti, pemerintah daerah, dan masyarakat dalam upaya mitigasi risiko perubahan iklim lokal. Sebagai warga negara yang baik, kita semestinya mendukung kebijakan pemerintah dalam menjaga keseimbangan lingkungan dan mengurangi risiko dampak perubahan iklim, khususnya yang berkaitan dengan suhu ekstrem dan cuaca tak menentu. Sebagaimana firman Allah SWT dalam Q.S. Al-A'raf ayat 56 berikut.

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَادْعُوهُ خَوْفًا وَطَمْعًا إِنَّ رَحْمَةَ اللَّهِ قَرِيبٌ مِّنَ الْمُحْسِنِينَ ﴿٥٦﴾

(Kementerian Agama, 2019)

*“Janganlah kamu berbuat kerusakan di bumi setelah diatur dengan baik. Berdoalah kepada-Nya dengan rasa takut dan penuh harap. Sesungguhnya rahmat Allah sangat dekat dengan orang-orang yang berbuat baik.” (Q.S. Al-A’raf: 56)*

Pada ayat di atas dijelaskan bahwa kerusakan lingkungan, termasuk ketidakseimbangan iklim dan degradasi alam, harus dicegah dan tidak boleh dibiarkan. Maka selama kebijakan pemerintah bertujuan untuk melestarikan dan menyeimbangkan ekosistem, wajib bagi kita untuk mendukung dan menjalankannya. Sebagaimana pula diterangkan dalam hadis Nabi SAW.

إِنَّ الدُّنْيَا حُلْوَةٌ حَضِيرَةٌ، وَإِنَّ اللَّهَ مُسْتَحْلِفُكُمْ فِيهَا، فَيَنْظُرُ كَيْفَ تَعْمَلُونَ

(Baqi, 2017)

*“Sesungguhnya dunia itu manis nan hijau dan sesungguhnya Allah menjadikan kalian sebagai khalifah padanya lalu mengawasi bagaimana kalian berbuat.” (HR. Muslim No. 2742)*

Hadis di atas menguatkan bahwa amanah menjaga bumi, termasuk mengelola suhu dan iklim dengan bijaksana, adalah tanggung jawab setiap umat muslim. Kesalahan dalam pengelolaan sumber daya alam dan pengabaian terhadap mitigasi perubahan iklim bisa berdampak besar pada sektor lain seperti produktivitas pertanian, ketersediaan air, dan kesehatan masyarakat. Sebagai contoh, saat perlindungan kawasan hijau mulai dilonggarkan atau terjadi konversi lahan pertanian, hal ini memperparah kenaikan suhu lokal dan mempercepat pemanasan mikroklimat.

الْأَصْرَرُ مُرَبَّلٌ

(Ibrahim, 2019)

*“Kemudaran itu hendaklah dihilangkan.”*

Kaidah fikih di atas menegaskan bahwa potensi kemudaratan lingkungan akibat ketidakseimbangan suhu dan iklim harus diatasi terlebih dahulu walaupun suatu aktivitas secara asal dibolehkan. Oleh karena itu, semestinya umat Islam, harus menerapkan kaidah ini yaitu mematuhi semua kebijakan pemerintah terkait pelestarian lingkungan, agar perubahan iklim dan fluktuasi suhu bisa dikendalikan, serta bumi tetap lestari.

Hasil peramalan suhu ini diharapkan menjadi *insight* penting bagi pemerintah daerah dalam merumuskan kebijakan adaptasi dan mitigasi risiko iklim. Sebab, fluktuasi suhu ini dapat berdampak pada sektor pertanian (masa tanam), kesehatan (risiko penyakit), dan sosial ekonomi masyarakat.

## BAB V

### PENUTUP

#### 5.1 Kesimpulan

Berdasarkan hasil pembahasan pada bab sebelumnya, didapatkan beberapa kesimpulan diantaranya:

1. Desain sistem model LSTM ini memanfaatkan data suhu udara Kabupaten Malang yang dikumpulkan dari Januari 2021 hingga Desember 2024, dengan 3 fitur utama. Setiap fitur diantaranya yaitu suhu minimum, suhu maksimum, dan suhu rata-rata. Data dibagi menjadi 80% untuk data *training* dan 20% untuk data *testing*. Model telah dibangun menggunakan konfigurasi parameter terbaik yang dihasilkan dari beberapa uji coba, yaitu 4 *layer*, 50 *hidden neuron*, *batch size* sebesar 16, dan maksimum *epoch* sebanyak 200.
2. Hasil evaluasi menunjukkan bahwa model prediksi memiliki tingkat akurasi yang baik untuk ketiga kategori suhu berdasarkan nilai RMSE dan MAPE. Untuk suhu minimum, nilai RMSE sebesar 1.04 dan MAPE sebesar 4.14% menunjukkan bahwa model mampu melakukan peramalan dengan tingkat kesalahan yang rendah dan akurasi yang baik. Sementara itu, suhu maksimum memiliki nilai RMSE sebesar 1.00 dan MAPE sebesar 2.66%, yang mengindikasikan tingkat akurasi yang lebih baik dengan kesalahan prediksi yang relatif rendah. Adapun suhu rata-rata menunjukkan performa terbaik dengan nilai RMSE hanya 0.66 dan MAPE sebesar 2.16%, yang mencerminkan bahwa prediksi model sangat mendekati nilai aktual.

3. Peramalan suhu selama 59 hari ke depan menunjukkan tren peningkatan bertahap pada suhu minimum, maksimum, dan rata-rata, dengan fluktuasi ringan di awal periode, mencerminkan transisi musiman yang stabil. Suhu minimum tertinggi diperkirakan mencapai  $21.15^{\circ}\text{C}$ , dengan suhu minimum terendah sekitar  $20.95^{\circ}\text{C}$ . Suhu maksimum tertinggi sebesar  $29.35^{\circ}\text{C}$ , dengan suhu maksimum terendah  $28.89^{\circ}\text{C}$ . Sementara itu, suhu rata-rata harian tertinggi mencapai  $25.18^{\circ}\text{C}$ , dengan suhu rata-rata terendah  $24.52^{\circ}\text{C}$ .

## 5.2 Saran

Setelah memperoleh hasil akhir dari penelitian ini yang memanfaatkan metode LSTM untuk meramalkan suhu udara, Penulis bermaksud memberikan beberapa masukan untuk pengembangan dan penyempurnaan penelitian ini di masa yang akan datang diantaranya.

1. Menambahkan metode peramalan lain yang dapat dikombinasikan dengan metode LSTM. Metode tersebut bisa berupa ARIMA atau pendekatan *deep learning* lainnya seperti *Recurrent Neural Network* (RNN) guna meningkatkan kinerja model dalam melakukan peramalan.
2. Menggunakan variabel lain yang berpotensi memengaruhi suhu, seperti kelembapan, curah hujan, kecepatan angin, dll. Model multivariat dapat membantu LSTM menangkap dinamika hubungan antar variabel, sehingga peramalan bisa lebih adaptif terhadap pola data aktual.

## DAFTAR PUSTAKA

- Afida, L. N. I., Putra, I., Azizah, I., Nabawi, S., & Alifia, A. (2021). Pembelajaran Mesin Lanjut Forecasting Temperature Menggunakan LSTM. *Teknik Informatika, Fakultas Ilmu Komputer*, 1–6. www.wunderground.com.
- Aprian, B. A., Azhar, Y., & Nastiti, V. R. S. (2020). Prediksi Pendapatan Kargo Menggunakan Arsitektur Long Short Term Memory. *Jurnal Komputer Terapan*, 6(2), 148–157. <https://doi.org/10.35143/jkt.v6i2.3621>
- Badriyah, J., Fariza, A., & Harsono, T. (2022). Prediksi Curah Hujan Menggunakan Long Short Term Memory. *Jurnal Media Informatika Budidarma*, 6(3), 1297. <https://doi.org/10.30865/mib.v6i3.4008>
- Baqi, M. F. A. (2017). *Shahih Bukhari Muslim*. Jakarta: PT Elex Media Komputindo. <http://pustaka-indo.blogspot.com>
- BMKG. (2025). *Data Suhu Harian*. <https://dataonline.bmkg.go.id/data-harian>
- Buduma, N., & Lacascio, N. (2017). *Fundamentals of Deep Learning*. USA: O'Reilly Media.
- Cahyadi, R., Damayanti, A., & Aryadani, D. (2020). Recurrent Neural Network (Rnn) Dengan Long Short Term Memory (Lstm) Untuk Analisis Sentimen Data Instagram. *Jurnal Informatika dan Komputer*, 5(1), 1–9.
- Cahyani, J., Mujahidin, S., & Fiqar, T. P. (2023). Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem dan Teknologi Informasi (JustIN)*, 11(2), 346. <https://doi.org/10.26418/justin.v11i2.57395>
- Elfaladonna, F., Isa, I. G. T., Sartika, D., Yusniarti, & Putra, A. M. (2024). *Buku Ajar Dasar Exploratory Data Analysis (EDA)*. Pekalongan: PT Nasya Expanding Management.
- Firdaus, R. F., & Paputungan, I. V. (2022). Prediksi Curah Hujan di Kota Bandung Menggunakan Metode Long Short Term Memory. *Jurnal Penelitian Inovatif*, 2(3), 453–460. <https://doi.org/10.54082/jupin.99>
- Gnauck, A. (2004). Interpolation and Approximation of Water Quality Time Series and Process Identification. *Analytical and Bioanalytical Chemistry*, 380(3 SPEC.ISS.), 484–492. <https://doi.org/10.1007/s00216-004-2799-3>
- Goodfellow, I., & Bengio, Y. (2016). *Deep Learning*. Cambridge: MIT Press.
- Hochreiter, S., & Schmidhuber, J. (1997). *Long Short-Term Memory*.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice* (2 ed.). Melbourne: OTexts.

- Ibrahim, D. (2019). *Al-Qawa'Id Al-Fiqhiyah (Kaidah-Kaidah Fiqih)*. Palembang: Noer Fikri.
- Isnain, A. R., Sulistiani, H., Hurohman, B. M., Nurkholis, A., & Styawati, S. (2022). Analisis Perbandingan Algoritma LSTM dan Naive Bayes untuk Analisis Sentimen. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 8(2), 299. <https://doi.org/10.26418/jp.v8i2.54704>
- Kannan, M., Jayakrishnan, T. S., Jayasree, S., & Priyanandhini, V. (2024). *Neural Networks and Deep Learning*. Tamil Nadu: Leilani Katie Publication and Press.
- Kasir, I. (2014). *Tafsir Ibnu Kasir Juz 4*. Bandung: Sinar Baru Algensindo.
- Kementerian Agama, R. (2016). *Tafsir Wajiz Jilid 2*. Jakarta: Lajnah Pentashihan Mushaf Al-Qur'an.
- Kementerian Agama, R. (2019). *Al-Qur'an dan Terjemahannya*. Jakarta: Lajnah Pentashihan Mushaf Al-Qur'an.
- Khumaidi, A., & Nirmala, I. A. (2022). *Algoritma Long Short Term Memory dengan Hyperparameter Tuning: Prediksi Penjualan Produk*. Sleman: Deepublish.
- Lewis, C. D. (1982). *Industrial and Business Forecasting Methods*. Southampton: Butterworth & Co.
- Lubis, N. H., & Lubis, Y. F. A. (2021). Implementasi Model Recurrent Neural Network Dalam Melakukan Prediksi Harga Kartu Perdana Internet Dengan Menggunakan Algoritma Long Short Term Memory. *Prosiding SNASTIKOM: Seminar Nasional Teknologi Informasi & Komunikasi*, 463–469.
- Montgomery, D. C., Jennings, C. L., & Kulahci, Murat. (2015). *Introduction Time Series Analysis and Forecasting* (2 ed.). USA: John Wiley & Sons, Inc.
- Muhammad, R., & Nurhaida, I. (2025). Penerapan LSTM Dalam Deep Learning Untuk Prediksi Harga Kopi Jangka Pendek Dan Jangka Panjang. *JPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 10(1), 554–564. <https://doi.org/https://doi.org/10.29100/jipi.v10i1.5758>
- Nurhidayat, A., Difa, A. K. T., Nasrullah, F., Anwar, F. H., & Radianto, D. O. (2024). Pengaruh Perubahan Iklim Terhadap Produktivitas Pertanian Padi di Daerah Tropis. *Sains Student Research*, 2(2), 111–117. <https://doi.org/https://doi.org/10.61722/jssr.v2i2.1181>
- Olah, C. (2015, Agustus 27). *Understanding LSTM Networks*. Colah's Blog. Diakses pada 20 Januari 2025, dari <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- Suyudi, M. A. D., Djamal, E. C., & Maspupah, A. (2019). Prediksi Harga Saham menggunakan Metode Recurrent Neural Network. *Seminar Nasional Aplikasi Teknologi Informasi (SNATi)*, 33–38.
- Tjasyono, B. (2004). *Klimatologi*. Bandung: ITB Press.
- Wicaksono, A. (2025, Januari 3). *Anomali Suhu Udara Rata-Rata Tahun 2024*. Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Diakses pada 20 Januari 2025, dari <https://www.bmkg.go.id/iklim/anomali-suhu-udara-rata-rata-tahun-2024>
- Widyatmanti, W., & Natalia, D. (2008). *Geografi SMP/MTs Kls VII (KTSP)*. Jakarta: Grasindo.
- 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.
- Yanti, F., Nurina Sari, B., & Defiyanti, S. (2024). Implementasi Algoritma Lstm Pada Peramalan Stok Obat (Studi Kasus: Puskesmas Beber). *Jurnal Mahasiswa Teknik Informatika*, 8(4), 6082–6089.
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, 31(7), 1235–1270. [https://doi.org/10.1162/neco\\_a\\_01199](https://doi.org/10.1162/neco_a_01199)

## LAMPIRAN

**Lampiran 1.** Dataset Suhu Udara

Tanggal	Suhu Minimum	Suhu Maksimum	Suhu Rata-rata
01-01-2021	21.3	28.4	22.8
01-02-2021	21.6	26.4	23.7
01-03-2021	20.8	28.1	24.2
01-04-2021	21.2	27.2	23.1
01-05-2021	20.4	26.8	23.1
01-06-2021	20.2	29.4	23.9
01-07-2021	20.6	28.4	23.7
01-08-2021	21.4	29.2	24.5
01-09-2021	21.2	28.4	24.4
01-10-2021	21.8	28.0	23.7
:	:	:	:
02-01-2021	20.6	30.0	23.9
02-02-2021	20.8	29.2	24.8
02-03-2021	21.4	29.6	24.9
02-04-2021	21.2	28.4	24.5
02-05-2021	21.8	29.2	25.1
02-06-2021	22.0	28.6	25.0
02-07-2021	23.4	29.9	26.0
02-08-2021	23.0	28.4	25.1
02-09-2021	22.0	29.0	25.5

Tanggal	Suhu Minimum	Suhu Maksimum	Suhu Rata-rata
02-10-2021	21.2	26.0	23.3
02-11-2021	21.2	29.2	24.1
02-12-2021	22.3	26.0	23.5
02-13-2021	21.0	26.9	23.7
02-14-2021	20.0	28.4	23.4
02-15-2021	20.5	29.0	24.1
02-16-2021	20.7	29.2	23.1
02-17-2021	21.5	28.4	24.2
02-18-2021	19.6	29.8	24.5
02-19-2021	21.8	29.4	24.8
:	:	:	:
03-06-2021	20.2	27.4	23.2
03-07-2021	20.0	28.4	23.4
03-08-2021	19.4	28.3	22.8
03-09-2021	20.2	27.4	23.5
03-10-2021	20.6	28.6	24.1
03-11-2021	20.8	28.4	22.6
03-12-2021	19.5	28.4	23.7
03-13-2021	19.8	28.4	23.1
03-14-2021	19.0	28.8	23.6

03-15-2021	20.2	28.0	23.8
03-16-2021	21.6	29.2	24.6
03-17-2021	20.3	29.4	24.1
03-18-2021	19.8	29.6	23.4
03-19-2021	19.4	29.6	24.1
03-20-2021	21.4	28.0	23.3
03-21-2021	20.0	28.8	24.1
03-22-2021	21.8	30.0	24.5
03-23-2021	21.9	29.8	24.5
03-24-2021	20.1	28.9	24.7
03-25-2021	20.4	29.8	23.9
03-26-2021	20.4	29.4	23.8
:	:	:	:
04-09-2021	20.4	30.5	25.4
04-10-2021	21.0	29.0	24.4
04-11-2021	20.8	28.8	23.7
04-12-2021	20.8	29.4	24.7
04-13-2021	20.0	29.2	24.2
04-14-2021	20.5	29.5	24.9
04-15-2021	19.8	29.8	24.4
04-16-2021	21.0	30.0	25.2
04-17-2021	20.0	28.8	24.6
04-18-2021	20.0	28.7	23.2
04-19-2021	20.0	29.8	24.5

04-20-2021	18.3	29.6	24.5
04-21-2021	17.7	28.8	23.7
04-22-2021	19.0	29.1	23.7
04-23-2021	18.1	29.4	24.0
04-24-2021	18.8	29.7	24.9
04-25-2021	22.0	29.3	24.9
04-26-2021	20.2	29.8	24.9
04-27-2021	20.9	29.6	24.8
04-28-2021	21.2	27.8	24.6
04-29-2021	21.0	28.2	23.9
04-30-2021	20.6	30.0	25.3
05-01-2021	20.2	30.2	24.7
:	:	:	:
05-17-2021	20.3	28.4	24.3
05-18-2021	21.1	30.0	25.2
05-19-2021	20.4	28.1	23.7
05-20-2021	21.6	29.5	24.6
05-21-2021	20.0	30.0	24.4
05-22-2021	20.0	29.2	24.0
05-23-2021	20.8	28.8	24.3
05-24-2021	20.2	29.6	24.1
05-25-2021	21.3	28.5	24.4
05-26-2021		29.8	
05-27-2021	19.8	29.2	24.7

05-28-2021	21.1	30.0	24.4
05-29-2021	20.6	29.2	24.7
05-30-2021	21.8	29.4	24.3
05-31-2021	20.4	30.6	23.9
06-01-2021	20.4	28.8	24.3
06-02-2021	19.6	29.4	24.4
06-03-2021	19.9	29.6	24.5
06-04-2021	19.6	29.6	24.6
06-05-2021	21.8	29.5	25.0
06-06-2021	21.0	30.6	25.1
06-07-2021	19.7	29.6	23.9
06-08-2021	19.8	29.6	24.7
:	:	:	:
06-23-2021	19.8	28.7	24.1
06-24-2021	20.8	28.3	23.7
06-25-2021	20.8	28.0	23.7
06-26-2021	20.4	29.0	24.3
06-27-2021	20.4	29.0	24.6
06-28-2021	20.0	26.0	23.8
06-29-2021	19.4	29.4	24.1
06-30-2021	20.0	29.3	23.8
07-01-2021	19.0	29.1	23.4
07-02-2021	17.5	28.4	22.4
07-03-2021	20.2	28.1	23.5

07-04-2021	18.4	28.2	23.5
07-05-2021	17.6	27.0	22.1
07-06-2021	18.5	27.1	22.2
07-07-2021	16.8	27.8	22.1
07-08-2021	18.5	28.0	22.6
07-09-2021	18.3	29.0	23.6
07-10-2021	20.2	28.0	24.1
07-11-2021	20.2	29.8	24.8
07-12-2021	17.7	28.6	22.8
07-13-2021	17.7	28.2	24.2
07-14-2021	18.0	28.2	22.2
07-15-2021	18.2	27.0	23.0
:	:	:	:
08-06-2021	18.8	29.6	23.7
08-07-2021	18.5	28.5	23.5
08-08-2021	19.4	30.4	25.1
08-09-2021	20.3	29.2	23.7
08-10-2021	19.4	28.2	23.5
08-11-2021	18.9	28.8	22.6
08-12-2021	19.8	27.6	23.8
08-13-2021	20.6	29.6	24.1
08-14-2021	20.5	29.6	24.6
08-15-2021	18.8	30.0	24.9
08-16-2021	20.1	29.2	23.6

08-17-2021	18.4	29.1	23.9
08-18-2021	20.5	28.4	23.6
08-19-2021	20.0	28.5	23.4
08-20-2021	21.0	27.4	23.3
08-21-2021	21.4	28.8	24.2
08-22-2021	21.8	28.6	24.3
08-23-2021	18.4	29.0	22.8
08-24-2021	16.6	27.2	21.7
08-25-2021	17.8	27.8	23.0
08-26-2021	18.8	28.2	22.5
08-27-2021	16.2	27.8	21.8
08-28-2021	21.4	28.2	24.0
:	:	:	:
09-11-2021	22.0	28.4	24.3
09-12-2021	21.2	28.3	23.8
09-13-2021	21.3	28.6	24.8
09-14-2021	20.7	29.3	23.8
09-15-2021	20.0	30.0	24.6
09-16-2021	21.0	30.4	25.1
09-17-2021	19.8	31.2	24.6
09-18-2021	21.0	30.2	24.5
09-19-2021	20.0	28.4	24.0
09-20-2021	21.3	28.4	23.9
09-21-2021	20.9	28.8	23.7

09-22-2021	19.8	29.8	24.0
09-23-2021	20.2	29.8	24.6
09-24-2021	20.4	29.2	24.9
09-25-2021	20.2	29.2	23.9
09-26-2021	21.1	29.9	24.4
09-27-2021	21.3	28.6	23.7
09-28-2021	20.7	28.0	23.3
09-29-2021	19.0	28.6	23.6
09-30-2021	20.0	28.6	24.1
10-01-2021	20.7	29.8	24.8
10-02-2021	20.0	30.0	24.4
10-03-2021	21.2	28.0	23.8
:	:	:	:
10-24-2021	20.4	30.0	24.6
10-25-2021	22.0	30.0	24.9
10-26-2021	21.2	28.8	24.3
10-27-2021	21.2	29.0	24.5
10-28-2021	20.4	29.6	23.5
10-29-2021	20.3	30.4	25.3
10-30-2021	22.1	28.2	24.2
10-31-2021	20.2	29.4	24.7
11-01-2021	21.8	29.3	23.7
11-02-2021	20.6	29.4	23.3
11-03-2021	20.4	29.4	25.1

11-04-2021	20.8	29.8	25.2
11-05-2021	20.6	29.2	25.0
11-06-2021	20.6	30.3	26.1
11-07-2021	21.0	30.5	26.4
11-08-2021	21.0	29.8	25.4
11-09-2021	21.8	31.4	25.8
11-10-2021	21.3	29.0	24.5
11-11-2021	21.4	28.1	23.7
11-12-2021	21.3	26.4	23.5
11-13-2021	21.0	28.9	24.2
11-14-2021	21.2	28.0	23.0
11-15-2021	20.8	27.4	23.5
:	:	:	:
12-19-2021	21.4	30.3	26.2
12-20-2021	21.8	28.4	24.6
12-21-2021	21.0	28.6	24.5
12-22-2021	20.8	29.4	26.5
12-23-2021	21.5	29.8	24.6
12-24-2021	20.8	30.6	24.0
12-25-2021	20.4	28.5	25.5
12-26-2021	20.8	29.4	26.1
12-27-2021	20.4	29.4	25.8
12-28-2021	20.0	29.6	26.7
12-29-2021	20.1	28.9	25.5

12-30-2021	20.8	28.0	25.0
12-31-2021	21.2	28.5	24.5
01-01-2022	20.4	29.0	24.3
01-02-2022	20.4	28.6	24.1
01-03-2022	20.7	29.4	24.4
01-04-2022	20.2	28.6	24.1
01-05-2022	19.6	28.8	24.3
01-06-2022	19.2	29.3	23.9
01-07-2022	21.0	30.2	24.7
01-08-2022	20.1	28.4	23.3
01-09-2022	20.0	29.8	23.2
01-10-2022	19.8	28.8	23.8
:	:	:	:
03-01-2022	20.6	27.0	24.2
03-02-2022	20.7	29.7	25.0
03-03-2022	21.0	30.2	25.7
03-04-2022	22.2	29.0	24.5
03-05-2022	21.3	29.6	24.7
03-06-2022	20.4	28.8	24.1
03-07-2022	21.0	28.9	24.1
03-08-2022	20.7	29.0	24.1
03-09-2022	21.7	29.8	24.4
03-10-2022	20.8	28.8	23.9
03-11-2022	20.3	28.6	24.8

03-12-2022	21.4	27.4	23.9
03-13-2022	20.4	29.4	24.6
03-14-2022	20.2	29.6	24.3
03-15-2022		29.4	24.8
03-16-2022	20.4	29.0	24.6
03-17-2022	20.8	30.8	26.5
03-18-2022	20.8	30.3	24.3
03-19-2022	20.4	29.2	23.8
03-20-2022	21.2	28.4	23.5
03-21-2022	20.6	28.4	23.3
03-22-2022	20.0	28.6	23.4
03-23-2022	20.1	29.4	24.1
:	:	:	:
04-15-2022	20.0	30.3	25.5
04-16-2022	20.3	30.4	23.0
04-17-2022	19.7	30.4	25.1
04-18-2022	21.4	30.1	24.7
04-19-2022	21.2	28.8	23.5
04-20-2022	20.3	27.4	23.7
04-21-2022	20.2	28.0	23.5
04-22-2022	20.0	29.6	24.5
04-23-2022	20.4	29.8	24.9
04-24-2022	21.0	29.7	24.6
04-25-2022	22.0	29.8	25.4

04-26-2022	20.3	28.8	24.7
04-27-2022	20.8	29.0	24.3
04-28-2022	21.8	29.8	25.1
04-29-2022	20.1	28.8	24.2
04-30-2022	20.2	29.0	24.6
05-01-2022	20.8	30.0	25.5
05-02-2022	20.1	30.2	25.0
05-03-2022	20.0	30.4	24.5
05-04-2022	19.8	29.9	25.0
05-05-2022	20.5	29.8	25.2
05-06-2022	21.0	29.0	25.2
05-07-2022	20.8	29.9	24.1
:	:	:	:
06-05-2022	20.8	28.3	22.8
06-06-2022	19.6	28.4	23.1
06-07-2022	19.8	29.4	24.0
06-08-2022	20.0	28.6	23.9
06-09-2022	20.7	28.5	24.1
06-10-2022	20.0	29.2	23.9
06-11-2022	20.2	29.0	24.4
06-12-2022	20.8	28.3	24.0
06-13-2022	20.3	28.6	23.7
06-14-2022	20.2	28.8	24.3
06-15-2022	20.2	29.0	24.5

06-16-2022	21.2	28.6	23.3
06-17-2022	20.0	28.4	23.1
06-18-2022	19.4	28.6	23.7
06-19-2022	19.8	28.8	23.4
06-20-2022	19.1	27.8	23.2
06-21-2022	19.1	28.6	23.5
06-22-2022	18.7	29.2	24.0
06-23-2022	19.0	29.2	23.5
06-24-2022	19.6	27.4	23.4
06-25-2022	19.2	28.4	23.4
06-26-2022	19.8	27.8	22.4
06-27-2022	20.8	25.6	22.8
:	:	:	:
08-10-2022	20.0	29.0	23.9
08-11-2022	21.0	29.8	24.8
08-12-2022	21.9	29.2	24.9
08-13-2022	20.6	30.4	24.2
08-14-2022	19.2	28.8	24.6
08-15-2022	19.9	29.8	24.3
08-16-2022	20.6	29.8	24.0
08-17-2022	19.9	28.4	23.6
08-18-2022	19.4	28.0	23.4
08-19-2022	19.4	27.8	22.7
08-20-2022	18.8	29.0	23.2

08-21-2022	19.6	28.8	23.6
08-22-2022	18.7	28.9	23.6
08-23-2022	17.9	28.2	22.4
08-24-2022	16.5	29.2	22.4
08-25-2022	17.6	28.5	23.0
08-26-2022	18.7	28.0	22.7
08-27-2022	18.8	27.2	22.9
08-28-2022	17.7	26.5	22.7
08-29-2022	17.4	28.6	23.4
08-30-2022	20.7	28.0	23.6
08-31-2022	19.6	29.8	24.3
09-01-2022	19.2	30.2	24.2
:	:	:	:
10-21-2022	20.6	28.3	24.0
10-22-2022	19.8	30.4	24.7
10-23-2022	19.8	30.0	23.7
10-24-2022	20.2	27.8	24.3
10-25-2022	20.8	28.6	24.0
10-26-2022	21.0	27.2	22.7
10-27-2022	19.7	27.3	23.1
10-28-2022	19.5	27.0	22.8
10-29-2022	17.4	27.2	22.8
10-30-2022	19.8	27.4	23.8
10-31-2022	17.6	28.5	23.8

11-01-2022	19.6	29.6	24.3
11-02-2022	21.8	29.2	24.6
11-03-2022	20.4	30.8	26.0
11-04-2022	20.5	29.9	24.7
11-05-2022	20.4	29.8	24.8
11-06-2022	21.2	28.5	24.8
11-07-2022	21.5	29.8	24.6
11-08-2022	20.0	29.8	24.3
11-09-2022	21.4	27.7	24.1
11-10-2022	20.4	29.4	24.3
11-11-2022	21.7	29.2	23.7
11-12-2022	20.3	29.2	24.5
:	:	:	:
12-23-2022	21.0	29.4	23.7
12-24-2022	19.8	27.8	23.0
12-25-2022	20.4	25.4	22.3
12-26-2022	20.7	26.6	22.9
12-27-2022	20.4	27.6	23.1
12-28-2022	20.4	28.5	23.9
12-29-2022	20.4	27.6	24.4
12-30-2022	21.6	27.4	24.7
12-31-2022	22.8	27.1	25.1
01-01-2023	22.4	27.2	25.1
01-02-2023	21.8	30.8	24.7

01-03-2023	20.3	30.0	24.6
01-04-2023	20.2	30.9	25.4
01-05-2023	21.2	30.0	25.2
01-06-2023	21.1	27.4	24.5
01-07-2023	20.3	28.7	24.2
01-08-2023	18.5	28.6	24.4
01-09-2023	19.2	29.8	24.8
01-10-2023	19.9	30.2	25.5
01-11-2023	20.7	29.7	24.8
01-12-2023	19.8	30.2	25.0
01-13-2023	18.2	30.6	24.1
01-14-2023	19.5	29.0	24.2
:	:	:	:
02-15-2023	21.3	26.8	22.4
02-16-2023	20.7	28.2	23.3
02-17-2023	20.4	27.2	23.6
02-18-2023	21.4	29.3	24.3
02-19-2023	20.3	29.6	24.0
02-20-2023	20.0	29.0	23.8
02-21-2023	20.6	30.3	24.2
02-22-2023	20.6	29.4	23.8
02-23-2023	21.0	27.8	24.1
02-24-2023	22.2	30.2	24.7
02-25-2023	20.6	30.0	24.1

02-26-2023	20.8	28.0	22.9
02-27-2023	21.4	28.4	24.3
02-28-2023	21.3	28.4	24.0
03-01-2023	19.4	28.4	23.2
03-02-2023	20.0	27.2	22.5
03-03-2023	20.3	30.5	24.6
03-04-2023	20.2	28.1	23.9
03-05-2023	19.8	29.4	23.0
03-06-2023	20.3	28.8	24.3
03-07-2023	17.6	30.4	23.6
03-08-2023	19.3	29.6	23.7
03-09-2023	19.2	31.0	24.5
:	:	:	:
04-13-2023	21.2	24.8	22.5
04-14-2023	19.6	27.5	23.6
04-15-2023	19.7	28.1	23.6
04-16-2023	20.0	31.0	24.6
04-17-2023	21.0	29.6	24.4
04-18-2023	20.2	29.2	23.9
04-19-2023	19.4	30.4	25.4
04-20-2023	21.3	30.0	25.5
04-21-2023	21.1	29.4	24.8
04-22-2023	21.4	28.6	24.2
04-23-2023	20.0	29.9	25.2

04-24-2023	21.0	30.4	25.2
04-25-2023	20.4	29.8	25.1
04-26-2023	20.6	30.2	25.4
04-27-2023	20.6	30.6	25.4
04-28-2023	21.3	30.0	24.4
04-29-2023	21.4	28.0	23.2
04-30-2023	20.0	29.4	24.1
05-01-2023	20.2	28.8	24.7
05-02-2023	20.4	29.0	24.5
05-03-2023	21.4	30.2	25.2
05-04-2023	22.0	29.6	25.5
05-05-2023	20.7	31.0	25.2
:	:	:	:
06-15-2023	18.9	27.8	24.3
06-16-2023	19.3	28.6	23.2
06-17-2023	18.0	29.3	23.1
06-18-2023	18.0	28.5	23.2
06-19-2023	18.6	29.6	24.9
06-20-2023	19.3	30.3	23.8
06-21-2023	20.2	28.6	24.2
06-22-2023	19.3	29.4	24.0
06-23-2023	17.7	29.6	23.4
06-24-2023	17.8	29.7	23.6
06-25-2023	18.4	28.5	23.0

06-26-2023	18.6	28.0	22.9
06-27-2023	19.2	26.4	22.7
06-28-2023	20.4	25.6	22.7
06-29-2023	21.0	28.2	24.0
06-30-2023	20.8	28.4	24.0
07-01-2023	21.2	24.6	22.7
07-02-2023	21.2	25.7	22.7
07-03-2023	19.0	27.2	22.6
07-04-2023	18.8	28.2	23.1
07-05-2023		27.3	23.7
07-06-2023	20.6	28.3	24.3
07-07-2023	21.6	24.5	22.6
:	:	:	:
08-11-2023	16.4	28.6	22.7
08-12-2023	16.2	29.0	22.3
08-13-2023	16.1	29.6	21.9
08-14-2023	16.9	29.2	22.7
08-15-2023	17.8	29.6	23.5
08-16-2023	17.8	29.0	22.8
08-17-2023	17.8	25.5	21.6
08-18-2023	18.6	26.5	21.9
08-19-2023	16.8	28.6	22.1
08-20-2023	17.6	28.7	23.4
08-21-2023	17.2	28.5	22.5

08-22-2023	18.3	27.2	22.8
08-23-2023	18.1	27.8	22.2
08-24-2023	17.7	29.9	23.0
08-25-2023	17.7	30.2	23.3
08-26-2023	19.2	30.3	23.2
08-27-2023	17.2	28.8	22.7
08-28-2023	17.0	29.6	22.6
08-29-2023	17.9	31.2	23.4
08-30-2023	16.0	29.8	22.9
08-31-2023	18.2	29.9	23.1
09-01-2023	18.2	29.4	22.5
09-02-2023	14.8	29.3	21.5
:	:	:	:
10-10-2023	19.7	32.8	25.6
10-11-2023	18.8	32.0	25.4
10-12-2023	19.6	32.2	25.8
10-13-2023	21.4	32.0	25.8
10-14-2023	21.6	31.8	26.3
10-15-2023	20.2	32.4	26.8
10-16-2023	21.4	31.7	26.4
10-17-2023	21.0	32.3	26.5
10-18-2023	19.2	33.1	25.4
10-19-2023	20.4	32.8	26.5
10-20-2023	21.0	33.2	26.0

10-21-2023	20.2	33.4	27.8
10-22-2023	19.5	33.6	26.1
10-23-2023	19.6	32	27
10-24-2023	20.9	32.2	26.2
10-25-2023	19.2	32.6	25.8
10-26-2023	20.9	33.4	26.3
10-27-2023	19.7	34.0	25.7
10-28-2023	18.8	32.9	25.4
10-29-2023	19.7	33.4	26.6
10-30-2023	21.2	32.2	27.4
10-31-2023	20.3	32.4	27.5
11-01-2023	20.4	32.6	27.9
:	:	:	:
12-16-2023	20.3	31.1	27.0
12-17-2023	20.9	29.8	26.2
12-18-2023	19.8	30.1	26.3
12-19-2023	20.0	29.8	25.8
12-20-2023	18.5	29.0	25.7
12-21-2023	18.3	30.1	26.4
12-22-2023	20.2	31.2	26.7
12-23-2023	20.4	31.4	27.2
12-24-2023	19.7	32.4	27.8
12-25-2023	21.1	31.4	25.6
12-26-2023	20.6	30.2	25.5

12-27-2023	20.5	31.2	25.9
12-28-2023	21.4	29.8	25.4
12-29-2023	21.1	30.6	27.1
12-30-2023	22.3	30.0	26.1
12-31-2023	22.4	30.5	26.6
01-01-2024	21.8	30.8	27.1
01-02-2024	22.8	31.1	27.1
01-03-2024	21.9	30.8	26.4
01-04-2024	21.9	31.0	26.1
01-05-2024	21.4	29.8	25.2
01-06-2024	20.9	28.6	25.1
01-07-2024	21.3	29.0	25.0
:	:	:	:
02-19-2024	20.5	30.0	27.1
02-20-2024	20.8	31.0	25.8
02-21-2024	21.4	31.4	26.2
02-22-2024	20.6	31.1	25.8
02-23-2024	21.9	30.2	26.6
02-24-2024	21.4	30.0	25.7
02-25-2024	20.8	29.3	25.8
02-26-2024	21.0	30.6	24.6
02-27-2024	21.2	30.0	25.3
02-28-2024	21.3	29.4	25.7
02-29-2024	21.4	29.8	26.4

03-01-2024	21.9	29.7	25.9
03-02-2024	22.1	28.6	26.3
03-03-2024	22.4	29.8	25.2
03-04-2024	21.9	30.0	24.8
03-05-2024	21.4	30.8	25.7
03-06-2024	21.2	30.2	26.5
03-07-2024	19.0	29.8	26.3
03-08-2024	22.0	30.7	25.4
03-09-2024	22.2	28.0	24.8
03-10-2024	21.0	26.3	23.7
03-11-2024	21.4	28.4	25.8
03-12-2024	23.1	30.1	26.3
:	:	:	:
04-07-2024	21.4	30.9	26.6
04-08-2024	22.8	31.1	26.6
04-09-2024	21.3	27.5	24.9
04-10-2024	20.7	29.0	25.7
04-11-2024	21.6	29.6	24.8
04-12-2024	21.0	31.0	26.5
04-13-2024	21.7	30.3	27.1
04-14-2024	21.4	30.9	26.7
04-15-2024	21.6	30.8	27.3
04-16-2024	21.2	30.4	26.9
04-17-2024	22.0	27.0	24.7

04-18-2024	20.7	29.2	25.5
04-19-2024	21.4	30.6	26.8
04-20-2024	21.6	31.2	26.7
04-21-2024	22.2	29.8	25.9
04-22-2024	22.0	30.0	26.3
04-23-2024	22.0	29.6	26.1
04-24-2024	20.8	29.6	26.2
04-25-2024	22.2	28.4	25.6
04-26-2024	21.2	30.0	27.0
04-27-2024	21.0	30.8	27.6
04-28-2024	21.8	31.3	27.6
04-29-2024	20.8	31.0	27.3
:	:	:	:
05-25-2024	21.8	28.6	26.0
05-26-2024	20.3	29.6	25.8
05-27-2024	19.4	30.6	26.6
05-28-2024	20.6	30.4	26.8
05-29-2024	20.0	31.0	27.2
05-30-2024	20.0	30.5	26.8
05-31-2024	20.7	31.0	26.7
06-01-2024	21.1	31.2	26.7
06-02-2024	21.2	30.0	27.1
06-03-2024	22.8	28.2	25.4
06-04-2024	21.0	30.1	25.7

06-05-2024	20.8	29.0	25.7
06-06-2024	18.4	29.0	25.3
06-07-2024	20.4	27.6	24.7
06-08-2024	20.4	30.0	25.8
06-09-2024	21.2	28.4	25.1
06-10-2024	20.0	29.6	26.0
06-11-2024	21.0	29.6	26.4
06-12-2024	21.7	31.4	26.1
06-13-2024	21.2	28.5	25.0
06-14-2024	20.4	29.1	25.6
06-15-2024	21.2	29.4	25.8
06-16-2024	18.6	29.7	25.9
:	:	:	:
07-12-2024	17.0	28.1	22.8
07-13-2024	16.2	27.2	20.9
07-14-2024	15.0	26.8	21.2
07-15-2024	16.1	26.8	21.4
07-16-2024	17.0	29.0	22.7
07-17-2024	16.1	28.8	21.9
07-18-2024	17.2	28.8	22.5
07-19-2024	17.8	28.7	22.8
07-20-2024	16.2	29.2	22.1
07-21-2024	17.6	28.1	22.7
07-22-2024	18.4	29.2	23.2

07-23-2024	18.0	29.4	23.3
07-24-2024	18.6	29.2	23.9
07-25-2024	17.8	29.4	22.8
07-26-2024	16.8	29.1	22.9
07-27-2024	18.4	30.4	23.6
07-28-2024	19.4	28.0	23.7
07-29-2024	18.7	29.6	23.9
07-30-2024	20.8	29.0	23.8
07-31-2024	20.8	29.6	24.0
08-01-2024	21.0	28.4	23.8
08-02-2024	21.1	29.4	24.1
08-03-2024	18.9	29.8	23.4
:	:	:	:
09-19-2024	17.0	31.4	23.9
09-20-2024	18.2	30.8	24.6
09-21-2024	18.2	31.3	25.2
09-22-2024	20.0	31.2	26.0
09-23-2024	20.9	31.4	25.2
09-24-2024	21.0	29.4	24.6
09-25-2024	19.7	30.0	24.5
09-26-2024	20.9	30.0	24.4
09-27-2024	21.0	31.4	25.3
09-28-2024	18.9	31.6	25.3
09-29-2024	20.4	32.8	25.7

09-30-2024	20.2	31.6	25.5
10-01-2024	22.0	31.2	25.3
10-02-2024	20.2	31.8	25.8
10-03-2024	20.0	30.4	24.5
10-04-2024	19.8	31.4	25.8
10-05-2024	19.8	33.0	25.8
10-06-2024	20.2	32.5	26.3
10-07-2024	20.1	31.4	25.2
10-08-2024	22.0	31.0	26.1
10-09-2024	20.0	32.6	25.8
10-10-2024	20.7	33.6	25.6
10-11-2024	21.0	33.0	26.3
:	:	:	:
11-05-2024	20.9	31.4	26.6
11-06-2024	19.9	32.2	26.7
11-07-2024	20.2	33.0	26.3
11-08-2024	20.0	31.4	25.8
11-09-2024	22.1	30.8	25.6
11-10-2024	21.0	29.7	25.7
11-11-2024	21.0	31.4	26.3
11-12-2024	21.0	31.2	26.5
11-13-2024	21.6	31.8	27.1
11-14-2024	21.2	31.2	25.3
11-15-2024	20.8	31.7	26.5

11-16-2024	21.4	31.6	26.7
11-17-2024	21.2	31.1	26.5
11-18-2024	21.3	31.2	26.5
11-19-2024	21.5	30.4	25.1
11-20-2024	21.1	31.4	26.4
11-21-2024	21.0	31.0	26.6
11-22-2024	22.2	29.8	26.3
11-23-2024	22.0	30.6	25.5
11-24-2024	21.6	30.2	25.9
11-25-2024	19.9	30.2	25.7
11-26-2024	23.0	29.4	25.0
11-27-2024	21.8	30.6	25.2
:	:	:	:
12-21-2024	21.9	29.2	24.5
12-22-2024	21.6	26.8	22.8
12-23-2024	21.2	30.1	24.7
12-24-2024	20.8	30.0	25.0
12-25-2024	21.2	28.8	23.3
12-26-2024	20.8	28.0	24.0
12-27-2024	21.8	29.8	25.0
12-28-2024	21.9	28.8	23.5
12-29-2024	21.8	26.6	23.1
12-30-2024	20.8	29.7	24.3
12-31-2024	21.1	28.8	24.6

Lampiran 2. Syntax Code Python LSTM

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
import matplotlib.pyplot as plt
import seaborn as sns
import os
import random
import tensorflow as tf

# Membaca Excel
excel_file = pd.read_excel("Dataset Suhu.xlsx")
df = pd.DataFrame(excel_file)

print(df)
df.info()

# Mengecek apakah ada missing value
print("Jumlah missing value per kolom:")
print(df.isnull().sum())

# Mengecek apakah ada missing value secara keseluruhan
print("\nApakah ada missing value di dataset?")
print(df.isnull().values.any())

# Menampilkan baris yang mengandung missing value
print("\nBaris dengan missing value:")
print(df[df.isnull().any(axis=1)])

# Preprocessing (Handling Missing value)
df_interpolate = df.interpolate()
print(df_interpolate)
df_interpolate.to_excel("Dataset_fix.xlsx", index=False)

# Membaca dataset baru
excel1 = pd.read_excel("Dataset_fix.xlsx")
df1 = pd.DataFrame(excel1)

print(df1)

# Deskriptif data
deskriptif = df1.describe()
print(deskriptif)

# Mengubah dataset menjadi format long untuk seaborn
dataset_long = df1.melt(
    id_vars="Tanggal",
    value_vars=["Suhu Minimum", "Suhu Maksimum", "Suhu Rata-rata"],
    var_name="Tipe Suhu",
    value_name="Suhu",
)
)

# Membuat plot menggunakan seaborn
plt.figure(figsize=(12, 6))
sns.lineplot(data=dataset_long, x="Tanggal", y="Suhu",
hue="Tipe Suhu")
```

```

# Menambahkan judul dan label
plt.title("Grafik Suhu Udara Harian", fontsize=16)
plt.xlabel("Tanggal", fontsize=12)
plt.ylabel("Suhu (°C)", fontsize=12)
plt.legend(title="Tipe Suhu")
plt.grid(True)
plt.tight_layout()

# Menampilkan grafik
plt.show()

# memisahkan fitur input dan output
input_features = ["Suhu Minimum", "Suhu Maksimum", "Suhu Rata-rata"]
output_features = ["Suhu Minimum", "Suhu Maksimum", "Suhu Rata-rata"]

x = df1[input_features].values
y = df1[output_features].values

# Normalisasi
scaler = MinMaxScaler()
x_scaled = scaler.fit_transform(x)
y_scaled = scaler.fit_transform(y)
print(x_scaled)
print(y_scaled)
pd.DataFrame(x_scaled).to_excel("X_scaled.xlsx",
index=False)

# Partisi data
X_train, X_test, y_train, y_test = train_test_split(
    x_scaled, y_scaled, test_size=0.2, shuffle=False
)

# Segmentasi data
timesteps = 30 # menggunakan 30 hari sebelumnya menjadi
input_lstm
n_features_input = len(input_features)
n_features_output = len(output_features)

# Membangun model
def create_sequences(x, y, time_steps):
    X_seq, y_seq = [], []
    for i in range(len(x) - time_steps):
        X_seq.append(x[i : i + time_steps])
        y_seq.append(y[i + timesteps])
    return np.array(X_seq), np.array(y_seq)

X_train_seq, y_train_seq = create_sequences(X_train,
y_train, timesteps)
X_test_seq, y_test_seq = create_sequences(X_test, y_test,
timesteps)

model = Sequential()
model.add(
    LSTM(

```

```

        50,
        input_shape=(timesteps, n_features_input),
        return_sequences=True,
        recurrent_activation="sigmoid",
        activation="tanh",
    )
)
model.add(LSTM(50))
model.add(Dropout(0.2))
model.add(Dense(n_features_output))

model.compile(optimizer="rmsprop", loss="mse")

hist = model.fit(x_train_seq, y_train_seq, batch_size=16,
epochs=200)

model.summary()

predictions = model.predict(x_test_seq)
predictions = scaler.inverse_transform(predictions)
y_test_asli = scaler.inverse_transform(y_test_seq)

# Evaluasi
for i, feature in enumerate(["Suhu Minimum", "Suhu Maksimum", "Suhu Rata-rata"]):
    MAPE = (
        np.mean(np.abs((y_test_asli[:, i] - predictions[:, i]) / y_test_asli[:, i])) * 100
    )
    print(f"MAPE untuk {feature}: {MAPE:.2f}%")

for i, feature in enumerate(["Suhu Minimum", "Suhu Maksimum", "Suhu Rata-rata"]):
    RMSE = np.sqrt(np.mean((y_test_asli[:, i] - predictions[:, i]) ** 2))
    print(f"RMSE untuk {feature}: {RMSE:.2f}")

# Grafik perbandingan data aktual dan data peramalan
plt.figure(figsize=(12, 6)) # Mengatur ukuran figure

# Plot data aktual untuk setiap kategori suhu
plt.plot(y_test_asli[:, 0], label='Aktual Suhu Minimum', color='blue')
plt.plot(y_test_asli[:, 1], label='Aktual Suhu Maksimum', color='yellow')
plt.plot(y_test_asli[:, 2], label='Aktual Suhu Rata-rata', color='green')

# Plot data peramalan untuk setiap kategori suhu
plt.plot(predictions[:, 0], label='Prediksi Suhu Minimum', color='red', linestyle='--')
plt.plot(predictions[:, 1], label='Prediksi Suhu Maksimum', color='purple', linestyle='--')
plt.plot(predictions[:, 2], label='Prediksi Suhu Rata-rata', color='brown', linestyle='--')

plt.xlabel('Index')
plt.ylabel('Suhu (°C)')

```

```

plt.title('Perbandingan Suhu Udara Aktual dan Prediksi')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()

# Fungsi peramalan masa depan untuk semua fitur
def predict_future(model, last_sequence, n_future,
scaler):
    preds_scaled = []
    current_seq = last_sequence.copy()

    for _ in range(n_future):
        pred_scaled = model.predict(
            current_seq.reshape(1, timesteps,
n_features_input), verbose=0
        )[0]
        preds_scaled.append(pred_scaled)

        # Geser window, tambahkan prediksi
        current_seq = np.vstack([current_seq[1:], pred_scaled])

    preds_scaled = np.array(preds_scaled)
    preds = scaler.inverse_transform(preds_scaled)
    return preds

# Ambil 30 hari terakhir dari keseluruhan data (X_scaled)
last_30_days = X_scaled[-timesteps:]

# Tentukan jumlah hari ke depan
n_future_days = 59 # Prediksi 59 hari ke depan

# Peramalan masa depan
future_predictions = predict_future(model, last_30_days,
n_future_days, scaler)

# Buat DataFrame hasil peramalan dengan tanggal
future_dates = pd.date_range(
    start=df1["Tanggal"].max() + pd.Timedelta(days=1),
    periods=n_future_days
)
df_future = pd.DataFrame(
    future_predictions, columns=["Suhu Minimum", "Suhu Maksimum",
    "Suhu Rata-rata"]
)
df_future["Tanggal"] = future_dates

# Simpan ke Excel
df_future.to_excel("Prediksi_Masa_Depan.xlsx",
index=False)

# Tampilkan hasil peramalan
print(df_future)

# Plot Gabungan Peramalan Suhu udara 59 Hari ke Depan
plt.figure(figsize=(12, 6))

```

```
plt.plot(df_future['Tanggal'], df_future['Suhu Minimum'],
         label='Peramalan Suhu Minimum', color='red', linestyle='--')
plt.plot(df_future['Tanggal'], df_future['Suhu Maksimum'],
         label='Peramalan Suhu Maksimum', color='purple',
         linestyle='--')
plt.plot(df_future['Tanggal'], df_future['Suhu Rata-
rata'], label='Peramalan Suhu Rata-rata', color='brown',
         linestyle='--')

plt.xlabel('Tanggal')
plt.ylabel('Suhu (°C)')
plt.title(f'Peramalan Suhu Maksimum ({n_future_days} Hari
ke Depan)')
plt.legend()
plt.grid()
plt.tight_layout()
plt.show()

# Menampilkan bobot dan bias
lstm_layer = model.layers[0]
weights = lstm_layer.get_weights()
w, b = weights

print("Bobot input ke LSTM (w):\n", w)
print("\nBias (b):\n", b)
```

**Lampiran 3.** Hasil Penanganan *Missing Value*

<b>Baris Ke-</b>	<b>Tanggal</b>	<b>Suhu Minimum</b>	<b>Suhu Maksimum</b>	<b>Suhu Rata-rata</b>
145	26-05-2021	20.55	29.8	24.55
438	15-03-2022	20.3	29.4	24.8
656	19-10-2022	20.85	27.7	23.4
915	05-07-2023	19.7	27.3	23.7
1183	29-03-2024	21.15	30.3	25.6
1284	08-07-2024	19.3	28.3	25.4

**Lampiran 4.** Hasil Normalisasi Data

<b>Tanggal</b>	<b>Suhu Minimum</b>	<b>Suhu Maksimum</b>	<b>Suhu Rata-rata</b>
01-01-2021	0.761364	0.410526	0.310345
01-02-2021	0.795455	0.2	0.413793
01-03-2021	0.704545	0.378947	0.471264
01-04-2021	0.75	0.284211	0.344828
01-05-2021	0.659091	0.242105	0.344828
01-06-2021	0.636364	0.515789	0.436782
01-07-2021	0.681818	0.410526	0.413793
01-08-2021	0.772727	0.494737	0.505747
01-09-2021	0.75	0.410526	0.494253
01-10-2021	0.818182	0.368421	0.413793
01-11-2021	0.75	0.452632	0.482759
01-12-2021	0.772727	0.515789	0.471264
01-13-2021	0.818182	0.410526	0.37931
01-14-2021	0.75	0.389474	0.321839
01-15-2021	0.647727	0.189474	0.310345
01-16-2021	0.681818	0.136842	0.264368
:	:	:	:
12-17-2024	0.818182	0.473684	0.563218
12-18-2024	0.829545	0.494737	0.505747
12-19-2024	0.670455	0.684211	0.689655
12-20-2024	0.886364	0.6	0.597701
12-21-2024	0.829545	0.494737	0.505747
12-22-2024	0.795455	0.242105	0.310345
12-23-2024	0.75	0.589474	0.528736
12-24-2024	0.704545	0.578947	0.563218
12-25-2024	0.75	0.452632	0.367816
12-26-2024	0.704545	0.368421	0.448276
12-27-2024	0.818182	0.557895	0.563218
12-28-2024	0.829545	0.452632	0.390805
12-29-2024	0.818182	0.221053	0.344828
12-30-2024	0.704545	0.547368	0.482759
12-31-2024	0.738636	0.452632	0.517241

**Lampiran 5.** Perhitungan MAPE Suhu Udara

Tanggal	Data aktual	Data Peramalan	$\left  \frac{Y_t - \hat{Y}_t}{Y_t} \right $
2024-04-13	21.7	21.46733856	0.010721725
2024-04-14	21.4	21.90192986	0.023454666
2024-04-15	21.6	21.59074974	0.000428253
2024-04-16	21.2	21.98017311	0.036800618
2024-04-17	22	21.66381836	0.015280984
2024-04-18	20.7	21.49545097	0.038427583
2024-04-19	21.4	21.10372925	0.013844428
2024-04-20	21.6	21.60129356	5.98872E – 05
2024-04-21	22.2	21.50225258	0.031430064
2024-04-22	22	21.6594677	0.015478741
2024-04-23	22	21.72538948	0.012482296
:	:	:	:
2024-12-21	21.9	22.00848961	0.004953863
2024-12-22	21.6	21.58542061	0.000674972
2024-12-23	21.2	21.22041702	0.000963067
2024-12-24	20.8	21.3428688	0.026099462
2024-12-25	21.2	21.37620163	0.008311398
2024-12-26	20.8	21.02986908	0.011051398
2024-12-27	21.8	21.17889214	0.028491186
2024-12-28	21.9	21.59041214	0.014136432
2024-12-29	21.8	21.23897171	0.025735243
2024-12-30	20.8	21.33323669	0.02563638
2024-12-31	21.1	21.11501503	0.000711613
$Total = \sum_{t=1}^n \left  \frac{Y_t - \hat{Y}_t}{Y_t} \right $			11.34251823
$MAPE = \frac{1}{n} \left( \sum_{t=1}^n \left  \frac{Y_t - \hat{Y}_t}{Y_t} \right  \right) \times 100\%$			4.312744576

Link: <https://bit.ly/3ZlW69a>



**Lampiran 6.** Perhitungan RMSE Suhu Udara

Tanggal	Data aktual	Data Peramalan	$(Y_t - \hat{Y}_t)^2$
2024-04-13	21.7	21.46733856	0.054131345
2024-04-14	21.4	21.90192986	0.25193358
2024-04-15	21.6	21.59074974	8.55673E – 05
2024-04-16	21.2	21.98017311	0.608670083
2024-04-17	22	21.66381836	0.113018095
2024-04-18	20.7	21.49545097	0.632742251
2024-04-19	21.4	21.10372925	0.087776358
2024-04-20	21.6	21.60129356	1.67331E – 06
2024-04-21	22.2	21.50225258	0.486851464
2024-04-22	22	21.6594677	0.115962249
2024-04-23	22	21.72538948	0.075410937
:	:	:	:
2024-12-21	21.9	22.00848961	0.011769995
2024-12-22	21.6	21.58542061	0.000212559
2024-12-23	21.2	21.22041702	0.000416855
2024-12-24	20.8	21.3428688	0.294706539
2024-12-25	21.2	21.37620163	0.031047014
2024-12-26	20.8	21.02986908	0.052839794
2024-12-27	21.8	21.17889214	0.385774979
2024-12-28	21.9	21.59041214	0.095844643
2024-12-29	21.8	21.23897171	0.314752742
2024-12-30	20.8	21.33323669	0.284341372
2024-12-31	21.1	21.11501503	0.000225451
$Total = \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$			308.6111999
$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}}$			1.083248178

Link: <https://bit.ly/3ZlW69a>



## **RIWAYAT HIDUP**



Alwi, lahir di Lumajang pada 19 April 2003. Penulis merupakan anak kedua dari dua bersaudara, putra dari pasangan Sugiono dan Nanik Sri Handayani, serta adik dari Puspita Sari. Penulis memulai jenjang pendidikan di TK Pembangunan I dan dilanjutkan di SDN Kaliboto Lor 01 hingga lulus pada tahun 2015. Setelah itu, penulis menempuh pendidikan di SMPN 1 Jatiroto dan lulus pada tahun 2018, kemudian melanjutkan pendidikan ke SMAN 1 Lumajang dan lulus pada tahun 2021. Pada tahun yang sama, penulis diterima sebagai mahasiswa Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang melalui jalur SNMPTN. Selama masa perkuliahan, penulis aktif dalam berbagai kegiatan akademik dan organisasi kemahasiswaan, seperti menjadi asisten praktikum mata kuliah Pemrograman Komputer I, tergabung dalam HMPS “Integral” Matematika divisi *External Public Relation* (EPR), serta mengikuti sejumlah kegiatan organisasi lainnya yang mendukung pengembangan diri. Penulis juga melaksanakan Kuliah Kerja Mahasiswa (KKM) sebagai ketua kelompok pada tahun 2024 di Desa Ngadas, Kecamatan Poncokusumo, Kabupaten Malang. Selain itu, penulis aktif mengikuti program Praktik Kerja Lapangan (PKL) selama satu bulan di Badan Meteorologi, Klimatologi dan Geofisika (BMKG) Maritim Tanjung Perak II Surabaya. Berbagai pengalaman tersebut menjadi bekal penting bagi penulis dalam membentuk karakter, memperluas wawasan, serta mempersiapkan diri untuk berkontribusi secara profesional maupun sosial.



### BUKTI KONSULTASI SKRIPSI

Nama : Alwi  
NIM : 210601110015  
Fakultas / Jurusan : Sains dan Teknologi / Matematika  
Judul Skripsi : Peramalan Suhu Udara di Kabupaten Malang Menggunakan *Long Short-Term Memory* (LSTM)  
Pembimbing I : Prof. Dr. Hj. Sri Harini, M.Si.  
Pembimbing II : Mohammad Nafie Jauhari, M.Si.

No	Tanggal	Hal	Tanda Tangan
1.	27 Agustus 2024	Konsultasi Topik dan Data	1. ✓
2.	21 Oktober 2024	Konsultasi Topik dan Data	2. ✓
3.	24 Oktober 2024	Konsultasi Topik dan Data	3. ✓
4.	10 Januari 2025	Konsultasi Bab I, II, dan III	4. ✓
5.	17 Januari 2025	Konsultasi Bab I, II, dan III	5. ✓
6.	22 Januari 2025	ACC Bab I, II, dan III	6. ✓
7.	4 Februari 2025	Konsultasi Kajian Agama Bab I dan II	<del>✓</del>
8.	10 Februari 2025	ACC Kajian Agama Bab I dan II	<del>✓</del>
9.	12 Februari 2025	ACC Seminar Proposal	9. ✓
10.	29 April 2025	Konsultasi Revisi Seminar Proposal	10. ✓
11.	8 Mei 2025	Konsultasi Bab IV dan V	11. ✓
12.	14 Mei 2025	Konsultasi Kajian Agama Bab IV	12. <del>✓</del>
13.	14 Mei 2025	ACC Kajian Agama Bab IV	<del>✓</del>
14.	21 Mei 2025	ACC Seminar Hasil	14. ✓
15.	6 Juni 2025	Konsultasi Revisi Seminar Hasil	15. ✓



KEMENTERIAN AGAMA RI  
UNIVERSITAS ISLAM NEGERI  
MAULANA MALIK IBRAHIM MALANG  
FAKULTAS SAINS DAN TEKNOLOGI  
Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558913

16.	8 Juni 2025	Konsultasi Revisi Seminar Hasil	16. ✓
17.	10 Juni 2025	Konsultasi Kajian Agama Bab I, II, dan IV	17. ✗
18.	10 Juni 2025	ACC Kajian Agama Bab I, II, dan IV	18. ✗
19.	11 Juni 2025	ACC Revisi Seminar Hasil	19. ✓
18.	12 Juni 2025	ACC Sidang Skripsi	20. ✓
19.	17 Juni 2025	ACC Akhir Keseluruhan	21. ✓

Malang, 17 Juni 2025

Mengetahui,

Ketua Program Studi Matematika-

Dt. Elly Susanti, M.Sc.

NIP. 19741129 200012 2 005

