



# Prediksi *Multivariate Time Series* Parameter Cuaca Menggunakan *Long Short - Term Memory (LSTM)*

Romadona Tanjung<sup>1</sup>, Amalia Listiani<sup>2</sup>, Fuji Lestari<sup>3</sup>

<sup>1, 3</sup>Sains Aktuaria, Institut Teknologi Sumatera

<sup>1</sup>romadona.120410092@student.itera.ac.id

<sup>3</sup>fuji.lestari@at.itera.ac.id

<sup>2</sup>Sains Aktuaria, Institut Teknologi Sumatera

Corresponding author email: [amalia.listiani@at.itera.ac.id](mailto:amalia.listiani@at.itera.ac.id)

**Abstract:** *Unstable weather can affect crop production, including banana production, which is a major commodity in Lampung Province. Leaf diseases in banana plants caused by weather conditions reduce fruit yield and quality, making weather prediction crucial for maintaining productivity. This study uses data from a station at PT. Great Giant Pineapple, one of the largest banana producers in Indonesia. Based on this data, a Long Short-Term Memory (LSTM) model will be developed to predict weather parameters such as rainfall, soil moisture, soil temperature, soil electrical conductivity, leaf bud temperature, wind speed, air pressure, air temperature, air humidity, and solar radiation collectively. Various techniques for filling missing data (median, mean, constant "0") and hyperparameter tuning (number of neurons, activation function, number of epochs, learning rate) were applied to obtain the best model. The optimal model, using 100 neurons, hyperbolic tangent activation function, 100 epochs, a learning rate of 0.005, and filling missing data with the mean, resulted in an RMSE of 0.0224. The LSTM model demonstrated good capability in predicting climate factors but was less accurate for extreme values. Banana plants face major challenges for optimal growth. Implementing drip irrigation systems, soil nutrient management, and other adaptive measures are important to ensure banana plants remain healthy and productive.*

**Keywords:** *Weather, Hyperparameter Tuning, LSTM Model*

**Abstrak:** Cuaca yang tidak stabil dapat mempengaruhi produksi tanaman, salah satunya adalah produksi tanaman pisang yang menjadi komoditas utama di Provinsi Lampung. Penyakit daun pada tanaman pisang akibat cuaca mengurangi produksi dan kualitas buah, sehingga prediksi cuaca penting untuk menjaga produktivitas. Penelitian ini menggunakan data dari stasiun di PT. Great Giant Pineapple yang merupakan salah satu perusahaan besar produksi pisang di Indonesia. Berdasarkan data tersebut akan dibangun model *Long Short Term Memory (LSTM)* untuk memprediksi parameter cuaca seperti Curah Hujan, Kelembapan Tanah, Suhu Tanah, Konduktivitas Elektrik Tanah, Suhu Tunas Daun, Kecepatan Angin, Tekanan Udara, Suhu Udara, Kelembaban Udara, dan Penyinaran Sinar Matahari secara bersama - sama. Variasi teknik pengisian data kosong (nilai tengah, rata - rata, tetap "0") dan tuning *hyperparameter* (jumlah *neuron*, fungsi aktivasi, jumlah *epoch*, *learning rate*) dilakukan untuk mendapatkan model terbaik. Model optimal menggunakan 100 *neuron*, fungsi aktivasi tangen hiperbolik, 100 *epoch*, *learning rate* 0,005, dan pengisian data kosong dengan nilai rata - rata menghasilkan RMSE 0,0224. Model LSTM menunjukkan kemampuan baik dalam memprediksi faktor-faktor iklim, namun kurang baik untuk nilai ekstrim. Tanaman pisang menghadapi tantangan utama untuk pertumbuhan optimal. Penerapan sistem irigasi tetes, pengelolaan nutrisi tanah, dan langkah adaptasi lainnya penting untuk memastikan tanaman pisang tetap sehat dan produktif.

**Kata kunci:** Cuaca, Tuning *Hyperparameter*, Model LSTM.

## I. PENDAHULUAN

Kondisi cuaca di Indonesia saat ini cenderung tidak stabil. Daerah yang awalnya terlihat cerah dapat berubah menjadi hujan atau bahkan mengalami badai dalam waktu singkat [1]. Menurut buku prakiraan musim hujan 2022/2023 yang dirilis BMKG pada Agustus 2022, sebagian besar wilayah Indonesia diperkirakan akan mengalami awal musim hujan antara September hingga November 2022, dengan puncak hujan terjadi pada Desember 2022 dan Januari 2023. Namun, cuaca di Indonesia tidak selalu mengikuti pola musiman yang diperkirakan karena beberapa faktor yang dapat mempengaruhi curah hujan, sehingga seringkali terjadi perubahan yang cepat dan tiba - tiba [2]. Kondisi cuaca yang tidak menentu ini memiliki dampak besar terhadap sektor pertanian dan perkebunan, karena faktor cuaca mempengaruhi jumlah hujan dan menjadi pertimbangan utama dalam menentukan kesesuaian jenis



tanaman yang akan ditanam [3]. Kejadian cuaca ekstrem sering kali menjadi penyebab utama kegagalan panen di Indonesia dan berdampak pada hasil pertanian.

Salah satu perusahaan yang terdampak oleh faktor cuaca adalah PT Great Giant Pineapple (PT GGP), sebuah perusahaan besar di Lampung yang bergerak di sektor perkebunan dan memproduksi pisang dan nanas dalam skala besar. Perusahaan ini menghasilkan produk olahan nanas yang sebagian besar diekspor ke pasar internasional [4]. Selain nanas, perusahaan ini juga mengeksport pisang ke berbagai negara. Namun, pada tahun 2001, perusahaan mengalami penurunan hasil produksi pisang yang menyebabkan putusnya hubungan kerja sama dengan perusahaan dunia Del Monte. Penurunan produksi ini sebagian besar disebabkan oleh penyakit pada tanaman pisang, terutama pada bagian daun yang dapat mempengaruhi kualitas daun yang berperan penting dalam proses fotosintesis. Ketika kemampuan tanaman untuk melakukan fotosintesis terhambat, pertumbuhan dan perkembangan tanaman tidak lagi optimal, yang akhirnya mengakibatkan penurunan produksi dan kualitas buah pisang itu sendiri. Oleh karena itu, sangat penting untuk menjaga produktivitas dan keberlanjutan produksi tanaman pisang dengan mengelola penyakit daun secara efektif. Penyebaran penyakit daun pada tanaman pisang dipengaruhi oleh berbagai faktor cuaca seperti peningkatan kelembaban udara, suhu tinggi, curah hujan berlebih, angin kuat dan kurangnya cahaya matahari langsung yang mendukung pertumbuhan jamur penyebab penyakit daun. Kombinasi faktor - faktor cuaca ini mempengaruhi tingkat keparahan penyakit daun pada tanaman pisang [5]. Pengelolaan penyakit daun pada tanaman pisang melibatkan berbagai strategi, salah satunya adalah melakukan monitoring cuaca dan kondisi lingkungan. Oleh karena itu, mengetahui perkiraan cuaca di masa yang akan datang sangat penting untuk pengelolaan yang efektif.

Cuaca tidak dapat dipastikan secara tepat, tetapi dapat diprediksi atau diperkirakan menggunakan data historis dari periode sebelumnya. Berdasarkan catatan cuaca masa lalu, kita dapat memproyeksikan atau memperkirakan kondisi cuaca yang mungkin terjadi di masa mendatang. Terdapat berbagai metode untuk meramalkan cuaca, masing - masing dengan kelebihan dan kekurangannya. Beberapa teknik yang dapat digunakan untuk memprediksi cuaca diantaranya metode *Simple Exponential Smoothing* (SES), *Autoregressive Integrated Moving Average* (ARIMA) beserta variasinya, dan saat ini, prediksi juga dapat dilakukan menggunakan algoritma pembelajaran mesin *deep learning* [6]. Salah satu algoritma yang sering dipakai dalam prediksi adalah model *Long Short - Term Memory* (LSTM) yang memandang data deret waktu seperti data cuaca sebagai data sekuensial. Model LSTM adalah algoritma *time series* yang efektif untuk memproses data seperti cuaca dan terbukti handal dalam memprediksi kondisi cuaca beberapa tahun terakhir [7]. Keunggulan utama LSTM adalah kemampuannya mengingat informasi dari sekuens jangka panjang dan mengakomodasi ukuran data besar dengan memanfaatkan semua informasi sebagai input [8].

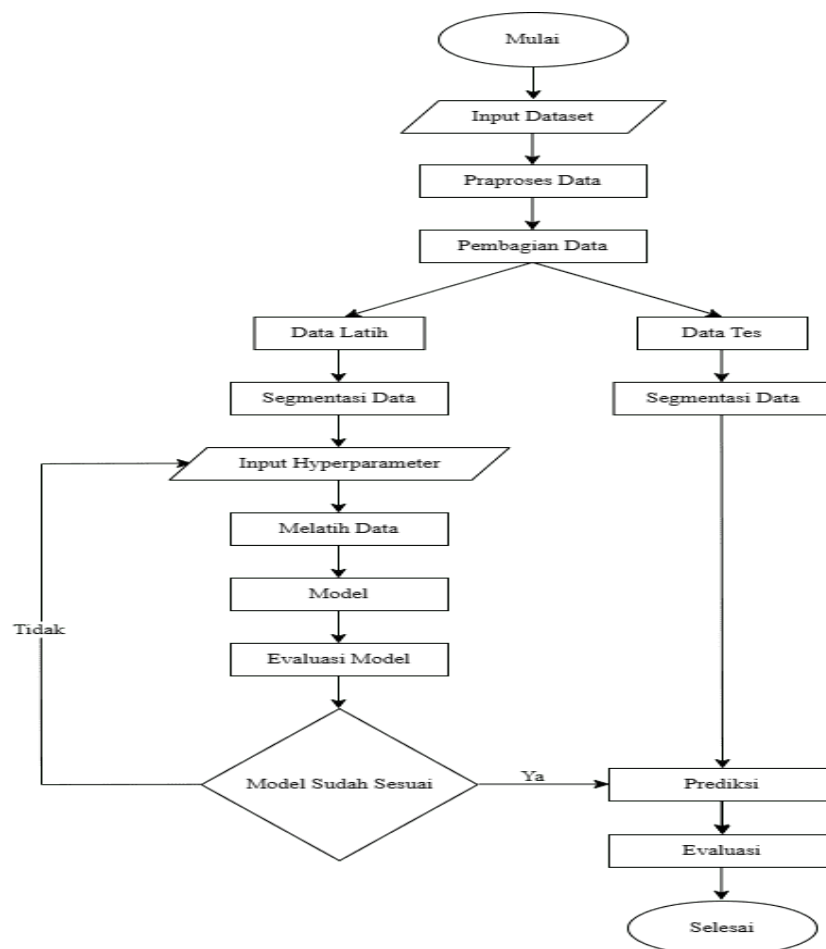
Penelitian tentang penggunaan model LSTM untuk memprediksi cuaca telah banyak dilakukan. Thoriq, Mohammad (2020) menemukan bahwa model LSTM memberikan kinerja optimal dengan RMSE sebesar 0,98162 dan MAE sebesar 0,68847, menunjukkan akurasi tinggi dalam prediksi [1]. Penelitian lain oleh Jamilatul Badriyah dkk (2022) juga menunjukkan performa LSTM yang unggul dalam memprediksi curah hujan di Surabaya dibandingkan model RNN dan GRU, dengan MSE sebesar 0,489, MAE sebesar 0,537, dan koefisien determinasi ( $R^2$ ) sebesar 0,497 [3]. Penelitian ini akan membahas lebih lanjut mengenai prediksi cuaca menggunakan model LSTM.

Penelitian ini akan memperluas penggunaan model LSTM dalam prediksi cuaca dengan fokus yang lebih spesifik daripada penelitian sebelumnya. Berbeda dengan penelitian sebelumnya yang hanya menggunakan beberapa parameter cuaca umum, penelitian ini akan melibatkan 10 parameter cuaca

yang berbeda untuk memberikan prediksi cuaca yang lebih detail dan akurat. Selain itu, penelitian ini akan dilakukan dengan studi kasus di PT GGP PG 4, sebuah perusahaan agribisnis dengan kebutuhan spesifik dalam prediksi cuaca untuk mendukung operasinya.

## II. METODE PENELITIAN

Tahapan dalam penelitian ini ditunjukkan pada Gambar 1 dan melibatkan tiga bagian, yaitu pengumpulan data, pra proses data, hingga akhirnya memprediksi cuaca menggunakan model LSTM untuk beberapa waktu kedepan. Data yang telah dikumpulkan selanjutnya dilakukan pra proses data yang terdiri dari dua aktivitas: *cleaning* dan normalisasi.



Gambar 1. Tahapan Penelitian

Proses *cleaning* bertujuan untuk mengisi nilai yang kosong dan melihat korelasi antar variabel. Dalam hal ini, peneliti menggunakan tiga skenario dalam mengisi nilai yang kosong yaitu menggunakan nilai rata - rata (*mean*), nilai tengah (*median*), atau nilai tetap nol. Berdasarkan ketiga skenario tersebut maka akan dipilih skenario yang paling minimum errornya. Normalisasi digunakan untuk menyamakan jangkauan data setiap variabel yang berbeda - beda, dengan tujuan memudahkan algoritma model memperlakukan semua variabel dengan sama dan memudahkan proses pembelajaran yang terjadi. Setelah data dibersihkan dan dinormalisasi, data dibagi menjadi data latih dan data uji yang kemudian data tersebut akan disegmentasi dengan bentuk rangkaian vektor 24 data histori untuk satu prediksi ke



depan. Kemudian data tersebut diolah menggunakan pemodelan LSTM untuk menghasilkan nilai prediksi. Keakuratan algoritma diukur menggunakan *Root Mean Square Error* (RMSE).

### 2.1 Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang bersumber dari PT GGP dengan populasi histori per jam data cuaca yang meliputi Curah Hujan (CH), Kelembaban Tanah (KT), Suhu Tanah (ST), Konduktivitas Elektrik Tanah (KET), Suhu Tunas Daun (STD), Kecepatan Angin (KA), Suhu Udara (SU), Kelembaban Udara (KU), Tekanan Udara (TU), dan Penyinaran Sinar Matahari (PSM) di PT GGP yang merupakan sampel data diambil pada periode 01 Desember 2022 sampai dengan 31 Juli 2023 sebanyak 5832 data. Data tersebut akan digunakan pada proses pelatihan data (*data training*) dan pengujian data (*data testing*), untuk pembagian data *training* sebanyak 80% dan 20% sisanya untuk data *testing*.

### 2.2 Pra Proses Data

Pada pra proses data terdiri dari dua aktivitas yaitu *cleaning* dan normalisasi. Proses *cleaning* terdiri dari 2 yaitu mengisi nilai data yang kosong dan melihat korelasi antar variabel. Pada proses normalisasi, setiap nilai pada sebuah fitur dikurangi dengan nilai minimum fitur tersebut kemudian dibagi dengan selisih nilai maksimum dan nilai minimum fitur tersebut. Implementasi rumus normalisasi yang telah dijelaskan sebelumnya dapat direpresentasikan melalui (1) berikut.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

dengan:

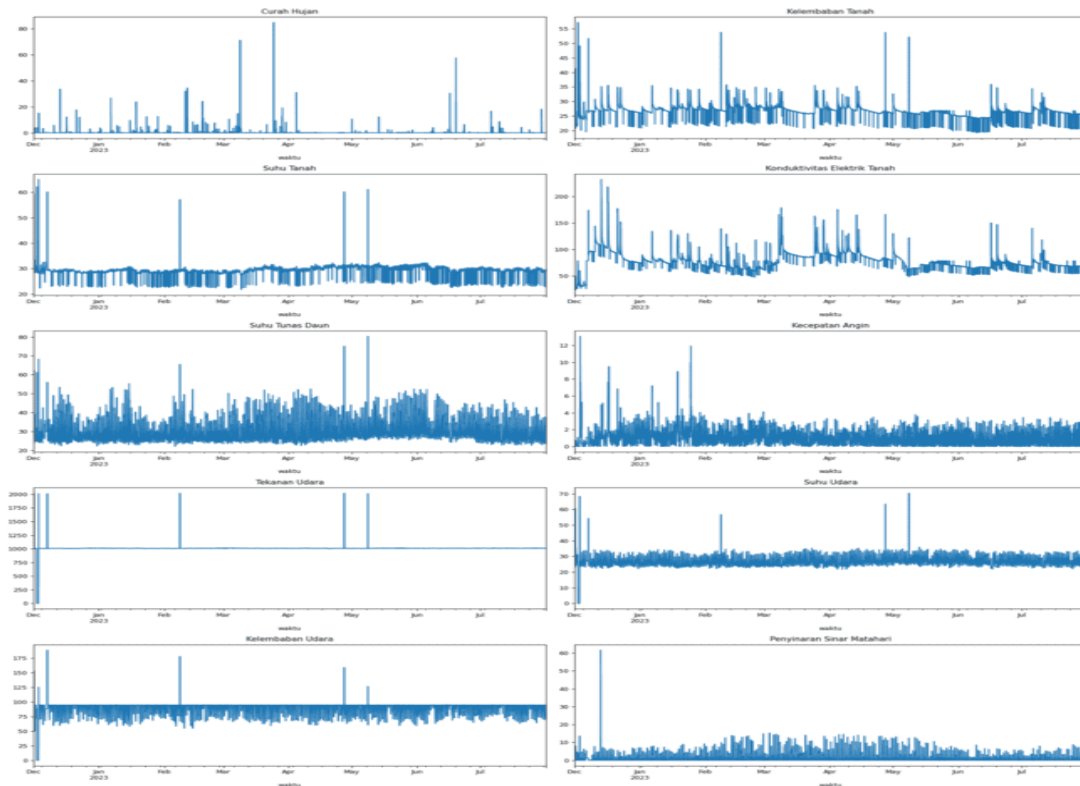
$X'$  : Data setelah normalisasi;

$X_{min}$ : Nilai minimum keseluruhan data;

$X$  : Data yang akan dinormalisasi;


$X_{max}$ : Nilai maksimum keseluruhan data.

Normalisasi digunakan untuk menyamakan jangkauan data setiap variabel yang berbeda - beda, dengan tujuan memudahkan algoritma model memperlakukan semua variabel dengan sama dan memudahkan proses pembelajaran yang terjadi. Selain itu tentu juga akan memudahkan proses interpretasi pada data. Berikut visualisasi data setelah dilakukan pengisian nilai yang kosong menggunakan nilai rata - rata dan matriks korelasi antar variabel data seperti pada Gambar 2 dan 3.



Gambar 2. Visualisasi Data

Berdasarkan Gambar 2, terlihat bahwa beberapa parameter menunjukkan variabilitas yang tinggi dengan distribusi yang luas (seperti CH dan STD), sementara yang lain lebih stabil dengan sedikit variabilitas (seperti SU dan TU). Secara keseluruhan, variasi dan fluktuasi dari berbagai parameter cuaca dapat memberikan wawasan penting tentang kondisi cuaca dan lingkungan di lokasi tersebut selama periode waktu yang ditentukan. Memahami sebaran data ini penting untuk analisis lebih lanjut seperti dalam model prediksi cuaca pada penelitian ini, di mana variabilitas tinggi mungkin memerlukan model yang lebih kompleks untuk akurasi yang lebih baik. Selanjutnya, berdasarkan Gambar 3 terlihat bahwa setiap variabel memiliki korelasi antar variabel yang beragam. Secara keseluruhan, dapat diidentifikasi beberapa hubungan yang signifikan antara variabel – variabel yang berbeda. Misalnya, suhu udara memiliki hubungan yang sangat kuat dengan suhu daun, sedangkan kelembaban udara menunjukkan hubungan negatif yang kuat dengan suhu udara. Memahami korelasi ini dapat membantu dalam mengidentifikasi parameter mana yang mungkin saling mempengaruhi.



Gambar 3. Korelasi Antar Variabel Data



Salah satu hasil dari tahap normalisasi ini dapat dilihat pada Tabel 1, yang menunjukkan normalisasi variabel suhu tanah. Sebagai contoh, suhu tanah yang diukur pada 01/12/2022 pukul 00:00 adalah 28,7°C. Setelah dinormalisasi menggunakan (1) dengan nilai minimum 21,69°C dan nilai maksimum 65,06°C, hasilnya menjadi 0,1616. Normalisasi ini memastikan bahwa setiap nilai suhu tanah dapat dibandingkan secara langsung, memudahkan analisis lebih lanjut, dan meningkatkan performa model pembelajaran mesin. Pada akhirnya akan dilakukan pengembalian rentang data menjadi seperti semula pada tahap denormalisasi data.

**Tabel 1.** Contoh Data Suhu Tanah Sebelum dan Sesudah Normalisasi

Waktu	Suhu Tanah (ST)	Suhu Tanah (ST) sesudah Normalisasi
01/12/2022 00:00	28,7	0,1616
01/12/2022 01:00	28,5	0,1570
01/12/2022 02:00	28,38	0,1542
01/12/2022 03:00	28,23	0,1507
01/12/2022 04:00	28,26	0,1491

### 2.3 Prediksi menggunakan Model LSTM

Prediksi adalah suatu proses sistematis dalam melakukan perkiraan mengenai peristiwa yang kemungkinan besar akan terjadi di masa depan, berdasarkan informasi yang diperoleh dari masa lalu dan situasi saat ini dengan tujuan untuk mengurangi kesalahan antara apa yang diprediksi dengan apa yang benar – benar terjadi. Penting untuk dicatat bahwa prediksi tidak selalu memberikan jawaban yang pasti mengenai peristiwa yang akan terjadi, tetapi bertujuan untuk mencari perkiraan yang seakurat mungkin [9]. Terdapat berbagai metode untuk memprediksi data deret waktu yang memiliki kelemahan dan keunggulannya masing – masing. Salah satunya adalah menggunakan algoritma pembelajaran mesin *deep learning* seperti model *Long Short – Term Memory* (LSTM) yang memandang data deret waktu sebagai data sekuensial [6].

LSTM merupakan salah satu modifikasi *Recurrent Neural Network* (RNN) yang pertama kali diperkenalkan pada tahun 1997 oleh Hochreiter dan Schmidhuber. LSTM terbukti mampu mengatasi kelemahan yang dimiliki oleh RNN terkait dengan kemampuannya dalam memprediksi kata – kata yang tersimpan dalam memori jangka panjang [10]. Proses prediksi dilakukan setelah pra proses data dengan menggunakan algoritma perhitungan model LSTM yang terdiri dari 3 *gate* yaitu *forget gate*, *input gate*, dan *output gate* seperti pada rumus berikut.

$$f_t = \sigma(W_f x_t + W_f h_{t-1} + b_f) \quad (2)$$

dengan  $f_t$  adalah nilai dari *forget gate*,  $x_t$  adalah nilai *input* pada waktu ke  $t$ ,  $h_{t-1}$  adalah nilai *hidden state* yang merupakan *output* dari *cell* LSTM sebelumnya,  $W_f$  dan  $b_f$  berturut – turut merupakan parameter bobot dan bias dari *forget gate*, serta  $\sigma$  adalah fungsi aktivasi sigmoid.

$$i_t = \sigma(W_i x_t + W_i h_{t-1} + b_i) \quad (3)$$

dengan  $i_t$  adalah nilai dari *input gate*,  $W_i$  dan  $b_i$  berturut – turut adalah parameter bobot dan bias dari *input gate*. Kemudian *cell state* (*memory cell*), dalam tahap ini fungsi Tanh digunakan untuk menciptakan vektor nilai baru yang dikenal sebagai *candidate memory cell* yang akan disimpan dalam *memory cell*.

$$c_t = f_t c_{t-1} + i_t \{ \tanh(W_c x_t + W_c h_{t-1} + b_c) \} \quad (4)$$

dengan  $c_{t-1}$  adalah nilai *cell state* yang merupakan *output* dari *cell* LSTM sebelumnya,  $W_c$  dan  $b_c$  berturut – turut adalah parameter bobot dan parameter bias dari *cell state*.

$$o_t = \sigma(W_o x_t + W_o h_{t-1} + b_o) \quad (5)$$





dengan  $W_o$  dan  $b_o$  berturut – turut adalah parameter bobot dan bias dari *output gate*. Berikut adalah persamaan dari *hidden state* yang merupakan keluaran bersamaan dengan *output gate* [11].

$$h_t = \tanh(c_t) \cdot o_t \quad (6)$$

Pada penelitian ini, proses prediksi menggunakan model LSTM mencakup pemilihan berbagai *hyperparameter* seperti *hidden layer*, *hidden neuron*, fungsi aktivasi, *epoch* dan *learning rate* dengan rancangan seperti pada Tabel 2. Setelah mendapatkan hasil dari perhitungan prediksi menggunakan model LSTM dan dilakukan proses denormalisasi untuk mengembalikan nilai data yang sebelumnya telah diubah ke dalam rentang 0 – 1 selama proses normalisasi maka dilakukan pengujian akurasi menggunakan rumus RMSE seperti pada (7), dimana semakin kecil (mendekati nol) nilai RMSE maka semakin akurat prediksinya [12]. Sementara itu, nilai *loss* merupakan fungsi tujuan yang digunakan untuk mengevaluasi data pelatihan dengan menggunakan persamaan *Mean Square Error* (MSE) seperti yang dijelaskan dalam (8) [13].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{pred,i} - y_{obs,i})^2} \quad (7)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{pred,i} - y_{obs,i})^2 \quad (8)$$

dengan:

- $n$  : Jumlah data;
- $y_{pred,i}$  : Nilai hasil prediksi ke  $i$ ;
- $y_{obs,i}$  : Nilai aktual ke  $i$ .

**Tabel 2.** Variasi Hyperparameter dari Model LSTM

<b>Hyperparameter</b>	<b>Ruang Pencarian</b>
Jumlah <i>nueron</i> tiap layer	[50,75,100]
Fungsi aktivasi pada layer LSTM	[sigmoid, tanh, relu]
Besar <i>epoch</i>	[25, 50,100]
Banyak <i>learning rate</i>	[0,001, 0,002, 0,003, 0,004, 0,005]

### III. HASIL DAN PEMBAHASAN

Pada bagian ini penulis melakukan percobaan dan analisa pada model LSTM yang telah dibuat. Percobaan tersebut yang akan menjelaskan hasil dari *training* dan *testing* yang sudah di uji coba sesuai rancangan variasi *hyperparameter* agar berjalan dengan baik sesuai dengan tujuan dari penelitian ini. Pengujian prediksi dilakukan berkali kali untuk mendapatkan hasil yang optimal. Berikut penjelasan masing – masing variasi pada *tuning hyperparameter*.

#### 3.1 Variasi *hyperparameter hidden neuron*

Variasi *hyperparameter* pada model LSTM dimulai dengan menggunakan empat *hidden layer* dengan jumlah *hidden neuron* yang sama untuk dua lapisan/layer LSTM yaitu 50, 75 dan 100. Namun, dengan fungsi aktivasi dimulai dari fungsi aktivasi Tangen Hiperbolik (ketetapan bawaan LSTM), *epoch* 100, dan teknik pengisian data kosong menggunakan *mean* serta *learning rate* sebesar 0,005. Hasilnya, diperoleh bahwa 100 *hidden neuron* menghasilkan RMSE terbaik. Hasil RMSE variasi *hidden neuron* dapat dilihat pada Tabel 3.

**Tabel 3.** Hasil Variasi *Hyperparameter Hidden Neuron*

<b>Hidden Neuron</b>	<b>RMSE</b>
50	0,0286
75	0,0301
100	0,0224



### 3.2 Variasi Hyperparameter Fungsi Aktivasi

Setelah menerapkan tiga variasi fungsi aktivasi pada model yaitu tanh, relu, dan sigmoid dengan pengujian menggunakan 100 *hidden neuron* pada dua lapisan LSTM, 100 *epoch*, teknik pengisian data kosong menggunakan *mean*, dan *learning rate* sebesar 0,005. Hasilnya menunjukkan bahwa fungsi aktivasi tanh (tangen hiperbolik) menghasilkan RMSE terkecil dengan nilai 0,0224.

### 3.3 Variasi Hyperparameter Epoch

Pengujian dengan variasi *epoch* 25, 50, dan 100 menggunakan 100 *hidden neuron* pada dua lapisan LSTM, fungsi aktivasi tanh, teknik pengisian data kosong menggunakan *mean*, dan *learning rate* 0,005 menunjukkan bahwa *epoch* 100 menghasilkan RMSE terkecil. Tabel 4 menunjukkan RMSE untuk tiap variasi *epoch*, dengan *epoch* 100 memberikan hasil prediksi terbaik dibandingkan *epoch* 25 dan 50.

**Tabel 4.** Hasil Variasi *Hyperparameter Epoch*

<i>Epoch</i>	RMSE
25	0,0346
50	0,0332
100	0,0224

### 3.4 Variasi Hyperparameter Learning Rate

Variasi *learning rate* sebesar 0,001, 0,002, 0,003, 0,004 dan 0,005 dapat dilihat pada Tabel 5 untuk pengujian menggunakan 100 *hidden neuron* pada 2 lapisan LSTM, fungsi aktivasi tanh, dan *epoch* 100 serta teknik pengisian data kosong menggunakan *mean*. RMSE terkecil diperoleh dengan menggunakan *learning rate* sebesar 0,005.


**Tabel 5.** Hasil Variasi *Hyperparameter Learning Rate*

<i>Learning Rate</i>	RMSE
0,001	0,0308
0,002	0,0296
0,003	0,0291
0,004	0,0294
0,005	0,0224

Berdasarkan variasi *hyperparameter* yang sudah dijelaskan di atas diperoleh hasil bahwa variasi *hyperparameter* yang dipilih yaitu 100 *hidden neuron*, jenis fungsi aktivasi tanh, 100 *epoch* dan 0,005 untuk nilai *learning rate* yang digunakan. Setelah dilakukan variasi *hyperparameter* kemudian yang terakhir yaitu variasi pengisian data kosong. Hasil terbaik dari variasi pengisian data kosong yaitu menggunakan nilai rata – rata (*mean*) dengan nilai RMSE mencapai 0,0224, dibandingkan dengan skenario nilai tengah RMSE sebesar 0,0284 dan nilai tetap nol RMSE sebesar 0,0469.


Pemodelan LSTM dilakukan dengan variasi *hyperparameter* dan teknik pengisian data kosong untuk mencapai kinerja optimal. *Hyperparameter* terbaik yang digunakan adalah 100 *hidden neuron*, fungsi aktivasi tanh, 100 *epoch*, *learning rate* 0,005, dan pengisian data kosong dengan nilai rata - rata. Hasil pemodelan ini menunjukkan *training loss* dan *validation loss* seperti yang ditunjukkan pada Gambar 4.






Gambar 4. Grafik *Training Loss* dan *Validation Loss*


Berdasarkan Gambar 4, terlihat grafik *loss* yang semakin optimal selama proses pelatihan berlangsung. Proses *training* yang dilakukan dengan 100 *epoch* menunjukkan nilai *loss* awal sebesar 0,0047 dan seiring dengan berlangsungnya proses pelatihan pada tiap *epoch* menjadikan nilai *loss* menurun hingga sebesar 0,00074. Hal ini menunjukkan model telah berhasil mempelajari pola di dalam data dengan sangat baik ditunjukkan dengan nilai *loss* yang rendah. Namun tentu saja masih diperlukan evaluasi kinerja model pada data testing untuk mengukur kualitas prediksi model yang telah dibangun. Berikut merupakan gambaran hasil prediksi pada data tes yang dihasilkan.




Gambar 5a.




Gambar 5b.




Gambar 5c.




Gambar 5d.




Gambar 5e.




Gambar 5f.




Gambar 5g.



Gambar 5h.



Gambar 5i.



Gambar 5j.

**Gambar 5.** Prediksi pada Data Tes

Secara keseluruhan, model LSTM menunjukkan kemampuan yang baik dalam memprediksi berbagai parameter cuaca. Model ini berhasil menangkap tren umum dan fluktuasi data aktual meskipun kurang responsif terhadap perubahan mendadak atau lonjakan tajam. Prediksi model cenderung lebih halus dibandingkan data aktual, namun tingkat akurasi yang tinggi pada pola umum menunjukkan efektivitas model ini untuk analisis dan peramalan jangka panjang. Meskipun lonjakan signifikan dan fluktuasi besar menantang, model LSTM tetap mampu memberikan gambaran yang mendekati kenyataan.

Evaluasi hasil prediksi menggunakan RMSE yang terlihat pada Tabel 6 menunjukkan performa model dalam memprediksi variabel cuaca, dimana nilai RMSE yang lebih rendah mengindikasikan performa yang lebih baik. Pada curah hujan, nilai RMSE sebesar 2,36 menunjukkan rata-rata kesalahan prediksi sebesar 2,36 mm. Hal ini menunjukkan model cukup akurat dalam memprediksi curah hujan meskipun ada beberapa perbedaan antara nilai prediksi dan data aktual. Secara keseluruhan, model



memiliki performa baik untuk sebagian besar parameter, meskipun beberapa variabel memerlukan peningkatan untuk mencapai akurasi prediksi yang lebih baik.

**Tabel 6.** Evaluasi Hasil Akurasi Prediksi Parameter Cuaca

Parameter	RMSE
Curah Hujan (CH)	2,36
Kelembaban Tanah (KT)	1,51
Suhu Tanah (ST)	1,53
Konduktivitas Elektrik Tanah (KET)	6,94
Suhu Tunas Daun (STD)	2,04
Kecepatan Angin (KA)	0,42
Suhu Udara (SU)	1,09
Kelembaban Udara (KU)	3,46
Tekanan Udara (TU)	6,29
Penyinaran Sinar Matahari (PSM)	1,08

Berdasarkan hasil prediksi pada Tabel 7, tanaman pisang menghadapi beberapa tantangan utama untuk pertumbuhan optimal. Tidak adanya curah hujan memerlukan irigasi tambahan seperti sistem irigasi tetes untuk menjaga kelembaban tanah yang diperlukan. Suhu tanah yang berkisar antara 23 hingga 38 derajat Celcius, dengan sebagian besar waktu melebihi suhu optimal, dapat menurunkan fotosintesis dan memperlambat pertumbuhan. Tingkat kelembaban tanah yang rendah, rata – rata 29,1% jauh dibawah kebutuhan ideal 60 hingga 80% memerlukan irigasi teratur. Konduktivitas listrik tanah yang rendah mengindikasikan ketersediaan nutrisi yang kurang, sehingga pemberian pupuk yang tepat dan pengelolaan air sangat penting. Meskipun kecepatan angin rendah tidak menyebabkan kerusakan signifikan, tekanan udara yang bervariasi dari 951 hingga 1.046 hPa dapat mengganggu proses metabolisme dan fotosintesis. Sementara, suhu udara 21 hingga 33 derajat Celcius dan kelembaban udara 88,29% mendukung pertumbuhan, penyinaran matahari yang rendah dapat membatasi fotosintesis, sehingga diperlukan pengaturan pola tanam dan penggunaan mulsa untuk memaksimalkan sinar matahari yang tersedia.

**Tabel 7.** Hasil Prediksi Parameter Cuaca

waktu	CH	KT	ST	KET	STD	KA	TU	SU	KU	PSM
2023-06-13 13:00:00	0	24,34	30,10	66,40	32,98	0,72	1011,92	28,32	90,65	1,60
2023-06-13 14:00:00	0	24,35	30,05	64,60	39,05	1,46	1007,89	30,43	83,07	2,64
2023-06-13 15:00:00	0	23,93	29,68	64,79	46,72	1,58	1009,52	31,92	75,90	2,89
2023-06-13 16:00:00	0	24,83	30,07	64,66	43,15	1,39	1002,16	32,97	74,62	5,53
...	...	...	...	...	...	...	...	...	...	...
2023-07-31 01:00:00	0	26,74	29,41	77,22	25,94	0,37	1010,79	25,44	94,74	0
2023-07-31 02:00:00	0	26,69	29,31	77,94	25,51	0,36	1009,22	24,94	94,62	0
2023-07-31 03:00:00	0	26,57	29,00	78,17	24,98	0,33	1009,03	24,57	94,59	0

#### IV. KESIMPULAN

Model LSTM telah di tuning *hyperparameter* dengan variasi pengisian data kosong untuk mencapai kinerja optimal, yaitu menggunakan *hyperparameter* 100 *hidden neuron*, jenis fungsi aktivasi tanh, 100 *epoch*, *learning rate* sebesar 0,005, dan teknik pengisian data kosong menggunakan nilai rata – rata menghasilkan prediksi cuaca pada data tes yang mendekati data asli dengan RMSE 0,0274 dan evaluasi parameter yang baik. Berdasarkan hasil prediksi, tanaman pisang menghadapi tantangan utama seperti kekurangan curah hujan, suhu tanah tinggi, kelembaban tanah rendah, dan konduktivitas tanah yang kurang, yang semuanya dapat menghambat pertumbuhan dan produktivitas. Irigasi tambahan, terutama sistem irigasi tetes, sangat diperlukan untuk menjaga kelembaban dan suhu tanah yang optimal.



Pemberian pupuk yang tepat juga diperlukan untuk meningkatkan ketersediaan nutrisi. Tekanan udara yang bervariasi dan penyinaran matahari yang rendah juga memerlukan perhatian khusus untuk memastikan kondisi optimal bagi pertumbuhan tanaman pisang.

## REFERENSI

1. M. I. I. Thoriq Afa Faisal Muhammad, “Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang),” *JURNAL SAINS DAN SENI ITS*, vol. 12, no. 1, pp. A34–A39, 2023.
2. R. Farikhul Firdaus and I. V. Papatungan, “Prediksi Curah Hujan di Kota Bandung Menggunakan Metode Long Short Term Memory,” *Jurnal Penelitian Inovatif*, vol. 2, no. 3, pp. 453–460, Nov. 2022, doi: 10.54082/jupin.99.
3. J. Badriyah, A. Fariza, and T. Harsono, “Prediksi Curah Hujan Menggunakan Long Short Term Memory,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 3, p. 1297, Jul. 2022, doi: 10.30865/mib.v6i3.4008.
4. A. Prayogi, E. Santoso, and Sutrisno, “Sistem Pendukung Keputusan Untuk Penentuan Jumlah Produksi Nanas Menggunakan Metode Fuzzy Tsukamoto (Studi kasus PT.Great Giant Pineapple),” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 6, pp. 2032–2037, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>
5. D. P. Bebber, “Climate change effects on Black Sigatoka disease of banana,” *Philosophical Transactions of the Royal Society B: Biological Sciences*, vol. 374, no. 1775, 2019, doi: 10.1098/rstb.2018.0269.
6. S. Siami-Namini, N. Tavakoli, and A. Siami Namin, “A Comparison of ARIMA and LSTM in Forecasting Time Series,” in *Proceedings - 17th IEEE International Conference on Machine Learning and Applications, ICMLA 2018*, Institute of Electrical and Electronics Engineers Inc., Jul. 2018, pp. 1394–1401. doi: 10.1109/ICMLA.2018.00227.
7. D. Desmonda, Tursina, and M. Azhar Irwansyah, “Prediksi Besaran Curah Hujan Menggunakan Metode Fuzzy Time Series,” *Jurnal Sistem dan Teknologi Informasi*, vol. 6, no. 4, pp. 145–149, Oct. 2018.
8. S. J. and S. A., “A COMPARATIVE ANALYSIS OF WEB INFORMATION EXTRACTION TECHNIQUES DEEP LEARNING vs. NAÏVE BAYES vs. BACK PROPAGATION NEURAL NETWORKS IN WEB DOCUMENT EXTRACTION,” *ICTACT Journal on Soft Computing*, vol. 06, no. 02, pp. 1123–1129, Jan. 2016, doi: 10.21917/ijsc.2016.0156.
9. M. Arifin, “Implementasi Data Mining Pada Prediksi Pemesanan Menggunakan Algoritma Apriori (Studi Kasus : Kimia Farma),” *Jurnal Pelita Informatika*, vol. 8, no. 3, 2020.
10. S. Hochreiter, “LSTM CAN SOLVE HARD LOG TIME LAG PROBLEMS.”
11. A. G. Barnston, “Correspondence among the correlation, RMSE, and Heidke forecast verification measures; refinement of the Heidke score,” *Weather Forecast*, vol. 7, no. 4, pp. 699–709, 1992.
12. F. H. Hamdanah and D. Fitriana, “Analisis Performansi Algoritma Linear Regression dengan Generalized Linear Model untuk Prediksi Penjualan pada Usaha Mikro, Kecil, dan Menengah,” *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 10, no. 1, p. 23, Apr. 2021, doi: 10.23887/janapati.v10i1.31035.
13. O. Theobald, “Machine learning for absolute beginners: a plain English introduction ,” *London, UK: Scatterplot press*, vol. 157, 2017.