

FORECASTING RED CHILLI PLANT GROWTH USING TIME SERIES METHOD WITH LONG SHORT-TERM MEMORY MODEL

FORECASTING PERTUMBUHAN TANAMAN CABAI MERAH MENGGUNAKAN METODE TIME SERIES DENGAN MODEL LONG SHORT-TERM MEMORY

Lastiur Aritonang¹, Brita Aryowindo², Ridho Syarif³, Ertina Sabarita Barus⁴
^{1,2,3,4} Universitas Prima Indonesia, Jl. Sampul No.3, Kota Medan, Sumatera Utara, Indonesia
Email: aritonanglastiur@gmail.com¹, britasilalahi@gmail.com², ridho.rgt16@gmail.com³,
ertinasabaritabarus@unpri.ac.id⁴

Abstract - The growth of red chilli plants is a horticultural commodity whose growth is highly determined by environmental elements, as a result, it is very crucial to make predictions to help more effective agricultural planning. This study aims to examine the ability of the Long Short-Term Memory (LSTM) model in predicting the growth of red chilli plants (*Capsicum annum L.*) according to 4 main parameters, namely stems, branches, leaves, and grains. The data used are red chilli plant growth data obtained from plantations located in Deli Serdang Regency, precisely in Namorambe District, namely Jatikusuma Village, over a period of 63 days and analyzed using the time collection method. The example provides high prediction accuracy for stem parameters ($R^2 = 0.9796$), branches ($R^2 = 0.9618$), and leaves ($R^2 = 0.9489$), but slightly low in fruit ($R^2 = 0.8807$) due to hyperbolic fluctuations. The consequences show the potential of LSTM in helping red chilli cultivation through better planning, green aid control, and early detection of growth anomalies. This study also demonstrates an integrative approach to four plant growth parameters using a single LSTM instance.

Keywords - forecasting, LSTM, plant growth, red chillies, time series.

Abstrak - Pertumbuhan tumbuhan cabai merah merupakan komoditas hortikultura yang pertumbuhannya sangat ditentukan oleh unsur lingkungan sebagai akibatnya sangat krusial buat melakukan prediksi guna membantu perencanaan pertanian yang lebih efektif. Penelitian ini bertujuan buat mengkaji kemampuan contoh *Long Short-Term Memory* (LSTM) pada meramalkan pertumbuhan tanaman cabe merah (*Capsicum annum L.*) sesuai 4 parameter utama yaitu batang, cabang, daun, dan butir. Data yang digunakan ialah data pertumbuhan tanaman cabai merah yang diperoleh berasal perkebunan yang berlokasi pada Kabupaten Deli Serdang tepatnya di Kecamatan Namorambe yaitu Desa Jatikusuma pada rentang saat 63 hari dan dianalisis memakai metode time collection. Contoh tadi memberikan akurasi prediksi yang tinggi pada parameter batang ($R^2 = 0,9796$), cabang ($R^2 = 0,9618$), serta daun ($R^2 = 0,9489$), tetapi sedikit rendah di buah ($R^2 = 0,8807$) karena fluktuasi yang hiperbola. Konsekuensi tadi menunjukkan potensi LSTM dalam membantu budidaya cabe merah melalui perencanaan yang lebih baik, pengendalian bantuan hijau, serta deteksi dini anomali pertumbuhan. Studi ini pula menunjukkan pendekatan integratif terhadap empat parameter pertumbuhan tumbuhan dengan memakai satu contoh LSTM.

Kata Kunci - forecasting, LSTM, pertumbuhan tanaman, cabai merah, time series.

I. PENDAHULUAN

Cabai merah (*Capsicum annum L.*) merupakan tanaman hortikultura yang bernilai ekonomi tinggi serta permintaannya tinggi pada Indonesia. Selain dipergunakan sebagai bumbu masak, cabai merah semakin poly digunakan menjadi yang akan terjadi dari upaya masyarakat dalam diversifikasi sumber pangan[1]. tetapi, panen serta harga cabai merah berfluktuasi secara tidak teratur yang ditimbulkan oleh banyak sekali faktor, termasuk variasi cuaca, agresi hama, serta praktik pertanian yang dipergunakan oleh petani[2]. Fluktuasi tersebut berpotensi merusak stabilitas pendapatan petani serta ketersediaan cabai pada pasaran. Menurut data Badan sentra Statistik Sumatera Utara tahun 2023, harga cabai merah di Sumatera Utara mengalami fluktuasi hingga 25% per bulan selama ekspresi dominan tanam, menggunakan rentang harga antara Rp18.000 hingga Rp45.000 per kilogram. Data ini membagikan pentingnya pengembangan model prediksi buat mendukung pengambilan keputusan pada budidaya cabai[3]. Tetapi, sampai waktu ini masih sedikit penelitian yang memodelkan keempat parameter pertumbuhan tanaman cabai merah (batang, cabang, daun, butir) secara bersamaan menggunakan menggunakan contoh LSTM, walaupun hal ini krusial buat memahami keseluruhan dinamika pertumbuhan tanaman. Buat membantu petani dan pemangku kepentingan lainnya dalam menghasilkan keputusan yang lebih tepat berdasarkan data, sistem prediksi produksi cabai merah sangat penting[4].

Namun, teknik pengelolaan lahan yang digunakan oleh petani yang masih menggunakan metode tradisional sering kali menjadi kendala. Perencanaan strategi penanaman dan distribusi menjadi tantangan karena kemampuan prediksi dampak tanaman yang buruk, yang dapat menyebabkan kerugian panen[5]. Teknologi modern, seperti kecerdasan buatan, sangat penting untuk mengatasi tantangan ini. Menggunakan algoritma peramalan berdasarkan data historis merupakan salah satu cara untuk memproyeksikan produksi cabai merah. Yang akan terjadi produksi di masa mendatang dapat diprediksi menggunakan menggunakan analisis deret saat buat menemukan pola dan tren dalam data produksi[6].

Dalam bidang pertanian, kemajuan pesat teknologi kecerdasan buatan telah membuka banyak kemungkinan, termasuk kemampuan untuk meramalkan pertumbuhan tanaman cabai merah. Salah satu metode populer untuk meramalkan data deret waktu atau data sekuensial adalah *Long Short-Term Memory* (LSTM) [7]. Karena LSTM merupakan model penyimpanan jangka panjang dari *Recurrent Neural Network* (RNN) asli [8], maka LSTM sangat cocok untuk memodelkan data deret waktu [9]. Dengan terciptanya sistem ini, manusia harus menemukan solusi untuk permasalahan saat ini dan meningkatkan hasil produksi.

II. SIGNIFIKASI STUDI

A. Studi Literature

Banyak sekali studi sebelumnya telah mengkonfirmasi efektivitas contoh LSTM di memprediksi contoh *Long Short-Term Memory* (LSTM) merupakan galat satu arsitektur *deep learning* yang dirancang buat menangani data deret waktu menggunakan pola kompleks. Berbagai penelitian telah menandakan efektivitas LSTM pada bidang pertanian, energi, serta prediksi harga komoditas. Dalam sektor pertanian, Arya et al. (2025) menerapkan LSTM untuk memprediksi produksi beras internasional, dengan RMSE sebesar 0,02, yang menandakan model mampu mengenali fluktuasi musiman dengan presisi [10]. Joshi et al. (2024) menerapkan model Bi-LSTM untuk prediksi hasil panen gandum musim dingin. Penelitian ini memperoleh nilai R^2 sebesar 0,957, menandakan bahwa arsitektur bidirectional mampu menangkap pola musiman dan tren fluktuatif lebih akurat[11].

Kontogiannis et al. (2025) mengembangkan model LSTM multistrand untuk klasifikasi dan prediksi pengukuran sensorik. Hasilnya, model mampu mencapai akurasi sangat tinggi dengan koefisien determinasi (R^2) sebesar 0,973, menunjukkan kemampuan dalam mengolah data kompleks dan multivariat [12].

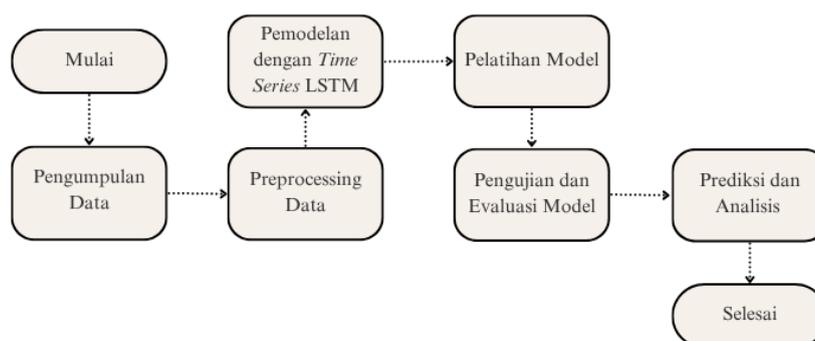
Dalam bidang energi, Manandhar et al. (2024) membandingkan performa model LSTM dengan Prophet dan Random Forest untuk prediksi beban listrik jangka pendek. Hasil evaluasi menunjukkan LSTM memiliki *Mean Absolute Percentage Error* (MAPE) paling rendah, menandakan keunggulan dalam menangkap pola beban yang tidak linier [13]. Hal serupa juga dibuktikan oleh Nguyen et al. (2024) yang mengaplikasikan LSTM untuk peramalan beban listrik rumah tangga dan mencatatkan akurasi yang tinggi [14]. Hu et al. (2023) menyempurnakan model LSTM dan memperoleh R^2 sebesar 0,96 dalam prediksi beban daya jangka pendek [15].

Sebagai perbandingan, Sahputra et al. (2024) menggunakan metode regresi linier berganda untuk memprediksi hasil produksi tanaman cabai, namun hanya mencapai nilai R^2 sebesar 0,76. Kelemahan regresi linear terletak pada ketidakmampuannya mengenali pola non-linier dan ketergantungan temporal antar variabel. Sebaliknya, LSTM unggul karena mampu menangkap dinamika data historis secara berurutan dan menghasilkan prediksi yang lebih tepat [16]

Penelitian ini menggunakan arsitektur LSTM dua lapis (*two-layer LSTM*) yang masing-masing terdiri dari 50 unit. *Input* data diformat dalam bentuk *time window* sebanyak 3 langkah ke belakang (*look-back window* = 3), sehingga model dapat belajar dari dinamika perubahan antar waktu. *Output* dari LSTM terakhir disambungkan ke *Dense layer* untuk memprediksi empat parameter pertumbuhan tanaman sekaligus: batang, cabang, daun, dan buah. Model ini dirancang untuk menangkap korelasi temporal dan spasial antar parameter secara bersamaan, yang sulit dilakukan oleh model prediksi konvensional. Akibat penilaian membagikan bahwa contoh bisa mencapai nilai R^2 sebesar 0,9796 buat batang, 0,9618 buat cabang, 0,9489 buat daun, serta 0,8807 untuk buah. Nilai-nilai tersebut lebih tinggi asal yang akan terjadi regresi linear dan membagikan bahwa LSTM lebih efektif terutama untuk data pertanian yang mempunyai pola musiman, tren, serta fluktuasi tajam. Dari studi literatur dan perbandingan tersebut, dapat disimpulkan bahwa LSTM memiliki performa lebih unggul dibandingkan regresi linear dalam memodelkan dan memprediksi data pertumbuhan tanaman dan produksi hasil pertanian. Hal ini membuahkan LSTM menjadi metode yg sangat direkomendasikan buat pengembangan sistem prediksi agrikultur presisi pada masa depan.

B. Metode Penelitian

Metode penelitian yang dipergunakan ialah LSTM sebab mampu memproses data sekuensial dan menyimpan berita jangka panjang. Berikut artinya alur metode penelitian yang ditunjukkan gambar 1.



Gambar 1. Alur Penelitian.

1. Pengumpulan Data

Pertumbuhan tanaman cabai merah diukur untuk penelitian ini menggunakan sejumlah kriteria utama, seperti tinggi batang, jumlah cabang, daun, dan jumlah buah, mirip yang ditunjukkan di Gambar 2.

Gambar 2. Batang, Cabang, Daun dan Buah

2. Praprocessing Data

Tahapan praproses dilakukan untuk memastikan kualitas data sebelum pelatihan model. Proses ini meliputi penghapusan data ganda, penanganan nilai kosong, serta normalisasi menggunakan metode *Min-Max* [17]. Rumus untuk metode *Min-Max* disediakan di bawah ini.

(1)

Rumus :

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

dimana :

- X adalah nilai asli (data yang dinormalisasi).
- X_{min} dan X_{max} merupakan nilai minimum dan maksimum dari dataset.
- X' adalah nilai hasil setelah normalisasi.

3. Pemodelan dengan Time Series LSTM

Pada taraf ini, versi *Long Short-Term Memory* (LSTM) dirancang secara khusus buat ciri kabar pengumpulan saat. 20% dari dataset digunakan untuk evaluasi, dan 80% sisanya digunakan untuk pelatihan. Metode pengukuran geser membuat pasangan input (X) dan output (Y) dari catatan historis dan mengubah masalah deret waktu harian menjadi format sekuensial. Selanjutnya, satu atau lebih lapisan LSTM dan lapisan output yang memanfaatkan fitur aktivasi yang sesuai digunakan untuk membangun desain jaringan LSTM [18].

4. Pelatihan Model

Model tersebut dilatih di dataset yang dinormalisasi, dengan parameter seperti jumlah *epoch*, berukuran *batch*, serta laju pembelajaran yang dioptimalkan buat menaikkan kemampuan model pada mengenali pola perkembangan tumbuhan. Bobot serta bias ditentukan selama konstruksi contoh menggunakan *Adam optimizer*, dan kesalahan prediksi diukur menggunakan Mean Squared Error (MSE) menjadi fungsi kerugian [19].

5. Pengujian dan Evaluasi Model

Setelah mempelajari versi LSTM, versi tersebut kemudian dibandingkan dengan berita investigasi, yang berisi bagian asli dari kumpulan data yang tidak digunakan untuk pembelajaran. Pengukuran seperti MAE, MSE, dan RMSE kemudian digunakan untuk menilai kinerja model secara keseluruhan [20].

Rumus Mean Absolute Error (MAE) :

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Rumus Mean Squared Error (MSE) :

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

Rumus Root Mean Squared Error (RMSE) :

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Keterangan :

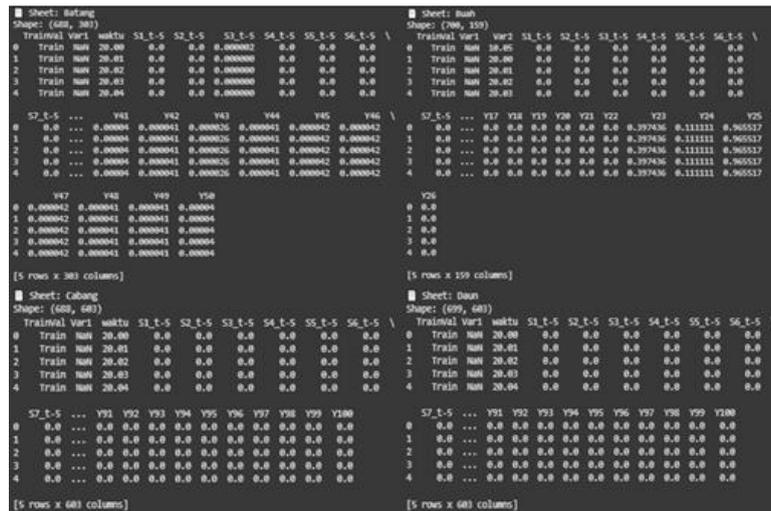
- n : Jumlah total sampel atau data pengamatan.
- y_i : Nilai actual pada pengamatan.
- \hat{y}_i : Nilai prediksi pada pengamatan.

6. Prediksi dan Analisis

Penilaian sebuah contoh dilakukan dengan membandingkan hasil prakiraan dengan pengamatan aktual. Kinerja contoh dianggap baik jika prediksi sangat cocok dengan data aktual. Sebaliknya, perbedaan yang besar menunjukkan bahwa diperlukan penyempurnaan, seperti penyesuaian parameter model, penilaian kualitas data, atau tinjauan prosedur pra-pengolahan data sebelum dilakukan pembinaan.

III. HASIL DAN PEMBAHASAN

Gambar berikut menyajikan hasil penerapan model Long Short-Term Memory (LSTM) dalam memprediksi pertumbuhan tanaman cabai merah berdasarkan empat parameter utama: batang, cabang, daun, dan buah. Penelitian ini memanfaatkan pendekatan deret waktu untuk mengidentifikasi pola pertumbuhan dengan menganalisis data historis yang telah diproses menggunakan perangkat lunak MATLAB, sebagaimana ditampilkan pada Gambar 3.



Gambar 3. Dataset Batang, Cabang, Daun dan Buah

Model LSTM diimplementasikan menggunakan platform Google Colaboratory dengan bahasa pemrograman Python, serta didukung oleh framework TensorFlow dan Keras. Struktur jaringan terdiri atas lapisan input yang menyesuaikan dimensi dengan jendela *look-back* (sebanyak 3 langkah waktu), diikuti oleh dua lapisan LSTM masing-masing berisi 50 unit, di mana lapisan pertama menggunakan parameter `return_sequences=True`. Selanjutnya, hasil keluaran diproses oleh satu lapisan *dense* sebagai output dengan satu unit.

```

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Input

def build_lstm_model(input_shape):
    model = Sequential([
        Input(shape=input_shape),
        LSTM(50, return_sequences=True),
        LSTM(50),
        Dense(1)
    ])
    model.compile(optimizer='adam', loss='mse')
    return model
    
```

Gambar 4. Model LSTM

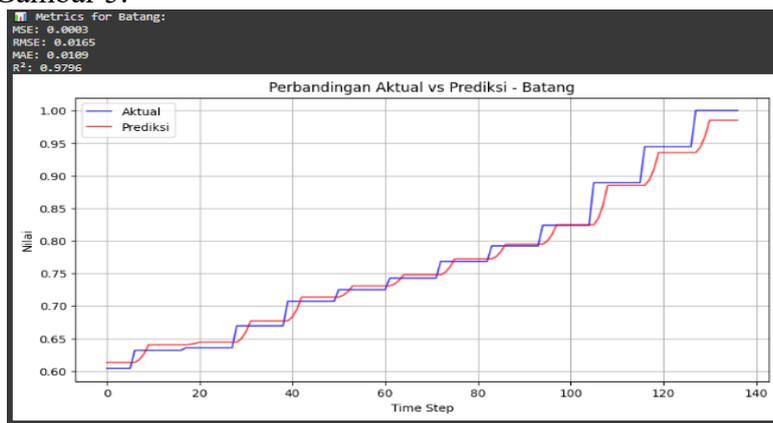
Pelatihan model dilakukan dengan menggunakan *optimizer* Adam dan fungsi kerugian Mean Squared Error (MSE). Pemilihan metode ini didasarkan pada keunggulan LSTM dalam mengidentifikasi pola temporal serta hubungan jangka panjang dalam data deret waktu. Kemampuan tersebut menjadikan LSTM cocok digunakan untuk memprediksi pertumbuhan tanaman yang umumnya memiliki karakteristik kompleks dan dipengaruhi oleh kondisi historis. Data pertumbuhan tumbuhan cabe merah yang berisi atribut batang, cabang, daun, serta butir sudah melalui berbagai tahap pemrosesan, termasuk normalisasi data dan konstruksi dataset. Pertukaran data serta konstruksi contoh. Semua data dinormalisasi menggunakan *MinMaxScaler* supaya mempunyai rentang nilai 0 sampai 1. Langkah ini menaikkan kinerja serta stabilitas contoh LSTM. Data disusun pada bentuk *look-back window* serta dibagi sebagai 3 langkah, yang memungkinkan model buat menganalisis pola sesuai 3 pengamatan sebelumnya. Dataset dipisahkan menjadi dua bagian: 80% data pelatihan dan 20% data pengujian buat mengevaluasi kinerja contoh. Model tadi dilatih selama 50 *epoch*, memakai ukuran *batch* 16 buat setiap parameter pertumbuhan tanaman. Penelitian ini diimplementasikan menggunakan Google Colaboratory dengan bahasa pemrograman Python. Adapun hasil yang diperoleh dari proses pemodelan dan pelatihan ditampilkan sebagai berikut:

Hasil Analisis Per Parameter

Pemodelan berbasis deret waktu dengan algoritma LSTM telah berhasil diterapkan pada empat parameter pertumbuhan tanaman cabai merah. Setiap parameter dianalisis menggunakan arsitektur model yang seragam, sehingga memungkinkan evaluasi dan perbandingan performa prediksi secara terukur antar parameter.

Hasil Analisis Parameter Batang

Hasil pemodelan LSTM pada parameter batang menunjukkan kinerja prediksi yang sangat tinggi. Hal ini tercermin dari nilai evaluasi model, yaitu MSE sebesar 0,0003, RMSE sebesar 0,0165, MAE sebesar 0,0109, serta koefisien determinasi (R^2) sebesar 0,9796. Visualisasi hasil tersebut ditampilkan pada Gambar 5.

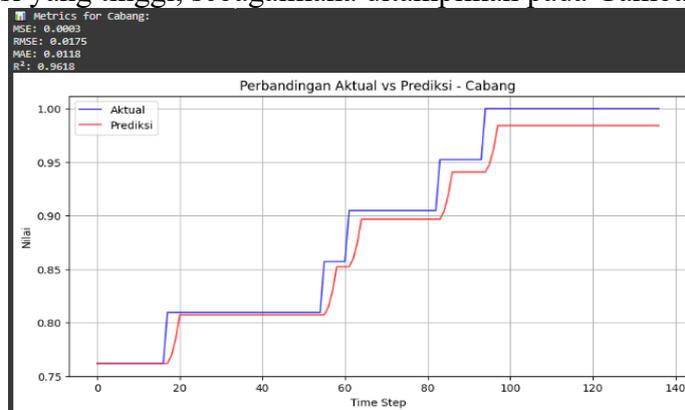


Gambar 5. Perbandingan Aktual vs Prediksi – Batang

Visualisasi perbandingan antara data aktual dan hasil prediksi menunjukkan bahwa model mampu merekonstruksi tren pertumbuhan batang secara akurat. Grafik memperlihatkan pola kenaikan bertahap dengan beberapa lonjakan signifikan yang berhasil diantisipasi oleh model, meskipun terdapat sedikit deviasi pada titik-titik perubahan yang tajam. Nilai koefisien determinasi (R^2) sebesar 0,9796 menunjukkan bahwa model dapat menjelaskan 97,96% variabilitas data, sementara nilai MAE yang rendah (0,0109) mengindikasikan tingkat kesalahan prediksi rata-rata yang sangat kecil.

Hasil Analisis Parameter Cabang

Pemodelan LSTM pada parameter cabang menghasilkan performa yang sangat baik. Hal ini ditunjukkan oleh nilai evaluasi model, yaitu MSE sebesar 0,0003, RMSE sebesar 0,0175, MAE sebesar 0,0118, serta koefisien determinasi (R^2) sebesar 0,9618. Nilai-nilai ini mengindikasikan tingkat akurasi prediksi yang tinggi, sebagaimana ditampilkan pada Gambar 6.

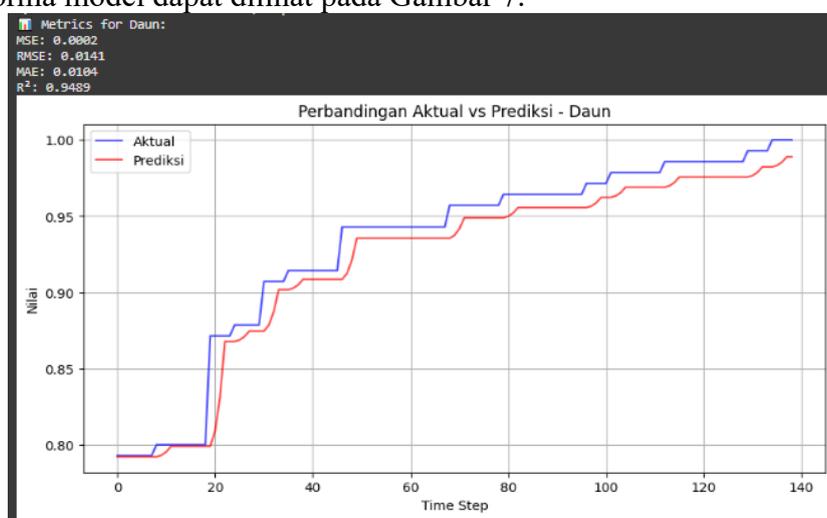


Gambar 6. Perbandingan Aktual vs Prediksi – Cabang

Visualisasi hasil prediksi menunjukkan bahwa model mampu mengenali pola pertumbuhan cabang secara cukup akurat, dengan kecenderungan stabil yang diselingi lonjakan pada periode tertentu. Model berhasil mengikuti dinamika tersebut dengan baik. Nilai R^2 sebesar 0,9618 mengindikasikan bahwa 96,18% variasi dalam data pertumbuhan cabang dapat dijelaskan oleh model. Meskipun sedikit di bawah performa pada parameter batang, tingkat akurasi yang dicapai tetap tergolong sangat tinggi.

Hasil Analisis Parameter Daun

Model LSTM yang digunakan untuk memprediksi parameter daun menunjukkan performa yang sangat baik berdasarkan hasil evaluasi. Nilai-nilai metrik yang diperoleh antara lain MSE sebesar 0,0002, RMSE sebesar 0,0141, MAE sebesar 0,0104, serta koefisien determinasi (R^2) sebesar 0,9489. Hasil ini mengindikasikan bahwa model mampu mempelajari dan merepresentasikan pola pertumbuhan daun dengan tingkat akurasi yang tinggi dan kesalahan prediksi yang relatif kecil. Visualisasi performa model dapat dilihat pada Gambar 7.

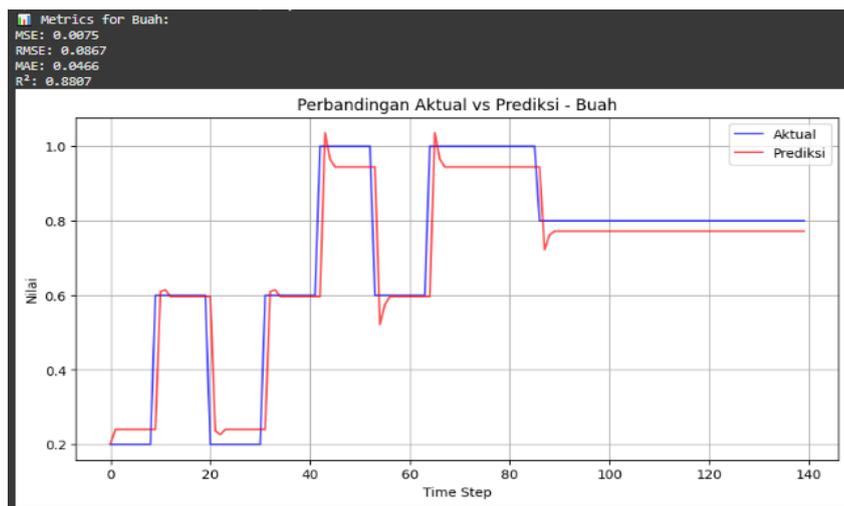


Gambar 7. Perbandingan Aktual vs Prediksi – Daun

Visualisasi hasil prediksi menunjukkan bahwa model LSTM mampu merepresentasikan tren pertumbuhan daun secara lebih halus dan berkesinambungan, dengan fluktuasi yang lebih minim dibandingkan parameter lainnya. Pola pertumbuhan daun yang dihasilkan tampak stabil dan bertahap, meskipun terdapat beberapa fase percepatan pertumbuhan. Nilai koefisien determinasi (R^2) sebesar 0,9489 menunjukkan bahwa model dapat menjelaskan sekitar 94,89% variasi yang terdapat dalam data pertumbuhan daun. Walaupun angka ini sedikit lebih rendah dibandingkan nilai R^2 pada parameter batang dan cabang, model tetap menunjukkan performa prediktif yang sangat baik, tercermin dari nilai Mean Squared Error (MSE) terendah di antara semua parameter, yakni sebesar 0,0002.

Hasil Analisis Parameter Buah

Evaluasi model LSTM terhadap parameter buah menghasilkan metrik performa sebagai berikut: MSE sebesar 0,0075, RMSE sebesar 0,0867, MAE sebesar 0,0466, dan koefisien determinasi (R^2) sebesar 0,8807. Nilai-nilai ini mengindikasikan bahwa model memiliki kemampuan prediktif yang cukup baik, meskipun akurasinya sedikit lebih rendah dibandingkan dengan parameter pertumbuhan tanaman lainnya. Hal ini dapat diamati pada Gambar 8, di mana prediksi menunjukkan ketepatan yang masih layak namun dengan variabilitas yang lebih tinggi dibandingkan parameter daun, batang, atau cabang.



Gambar 8. Perbandingan Aktual vs Prediksi – Buah

Meskipun menyediakan parameter, visualisasi perbandingan menghasilkan pola pertumbuhan yang paling tidak terduga dari semua parameter dengan memanfaatkan beberapa putaran dan penurunan tiba-tiba. Meskipun ada beberapa tantangan dalam memprediksi perubahan nilai yang sangat tiba-tiba secara tepat, model tersebut cukup baik dalam melacak tren umum. Nilai R^2 sebanyak 0,8807 membagikan bahwa sampel dapat mengungkapkan 88,07% variasi dalam data pertumbuhan butir. Skor ini memberikan kemampuan yang wajar buat memprediksi mengingat kompleksitas dan ketebalan data yang lebih besar, meskipun artinya yang terendah dari semua metrik.

Pelatihan Model

Metode pelatihan model memanfaatkan 80% dari seluruh kumpulan data yang dibuat untuk setiap parameter. Model dilatih selama 50 *epoch* menggunakan berukuran *batch* 16, yang mencapai keseimbangan antara panjang pelatihan dan kinerja model. Ketika pemrosesan per langkah tidak memadai buat setiap parameter: 122 milidetik buat batang, 84 milidetik buat cabang, 82 milidetik buat daun, dan 90 milidetik untuk buah.

Pengujian dan Evaluasi Model

Untuk mengevaluasi kinerja contoh secara objektif, pengujian dilakukan pada 20% *dataset* yang tidak termasuk dalam fase pelatihan. penilaian ini mengandalkan empat metrik utama: *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan Koefisien Determinasi (R^2). di model MSE, parameter daun membuktikan nilai terendah yaitu 0.0002 serta nilai tertinggi di parameter buah yaitu 0.0075. Tren yang sama pula terjadi pada RMSE, dimana parameter daun membagikan nilai terendah yaitu 0,0141, dan parameter buah tertinggi yaitu 0,0867. buat MAE, parameter daun pulang mencatatkan performa terbaik menggunakan nilai 0.0104, sedangkan parameter buah memberikan akibat yang paling buruk dengan nilai 0.0466. ad interim itu, buat R^2 , yang mengukur kemampuan model dalam menyebutkan varians data, parameter batang mencapai nilai tertinggi yaitu 0.9796, serta parameter buah terendah yaitu 0.8807.

Tabel di bawah ini memperlihatkan perbandingan kinerja model terhadap empat parameter utama pertumbuhan tanaman.

TABEL I
Perbandingan Matriks Evaluasi

Parameter	MSE	RMSE	MAE	R^2
Batang	0.0003	0.0165	0.0109	0.9796
Cabang	0.0003	0.0175	0.0118	0.9618
Daun	0.0002	0.0141	0.0104	0.9489
Buah	0.0075	0.0867	0.0466	0.8807

Prediksi dan Analisis

Menganalisis yang akan terjadi prediksi terhadap data aktual mengatakan beberapa wawasan utama perihal pola pertumbuhan tanaman cabai merah. Contoh LSTM berhasil diterapkan buat memprediksi 4 parameter pertumbuhan tumbuhan cabai merah, yaitu batang, cabang, daun, serta butir. Secara awam, hasil penilaian memberikan performa prediktif yang sangat tinggi buat parameter batang ($R^2 = 0,9796$), cabang ($R^2 = 0,9618$), dan daun ($R^2 = 0,9489$), namun sedikit lebih rendah pada parameter buah ($R^2 = 0,8807$). Performa ini sejalan dengan karakteristik pola data: batang, cabang, dan daun menunjukkan pertumbuhan yang relatif stabil dan konsisten dari hari ke hari, sedangkan jumlah buah cenderung mengalami fluktuasi tajam akibat faktor lingkungan dan fisiologis tanaman seperti pembungaan dan kerontokan buah. Tingkat fluktuasi harian pada data buah yang tinggi, tanpa adanya pola musiman eksplisit yang cukup panjang (hanya 63 hari), menyebabkan model kesulitan dalam mengenali tren jangka panjang. Hal ini ditunjukkan oleh nilai MSE tertinggi pada buah (0,0075) dibanding parameter lainnya. Sebaliknya, daun memiliki MSE terendah (0,0002), yang menunjukkan prediksi paling stabil.

Gambar 5 hingga Gambar 8 menampilkan grafik perbandingan antara data aktual dan hasil prediksi per parameter. Pada Gambar 5, tren pertumbuhan jangka panjang berhasil diikuti secara akurat, dengan kesalahan prediksi hanya terlihat pada puncak-puncak kecil di sekitar hari ke-20 dan 50, kemungkinan karena pertumbuhan akseleratif yang mendadak. Gambar 6 (cabang) memperlihatkan kecenderungan model underfit saat terjadi pertumbuhan cabang yang tiba-tiba pada hari ke-30, namun prediksi segera menyesuaikan kembali. Gambar 7 (daun) menunjukkan bahwa model memiliki ketepatan sangat baik, dengan garis prediksi hampir identik dengan data aktual. Adapun pada Gambar 8 (buah), tampak bahwa prediksi model cukup akurat dalam menangkap tren umum, tetapi gagal mengikuti lonjakan tajam pada hari ke-35 dan penurunan drastis di sekitar hari ke-50. Hal ini memperkuat kesimpulan bahwa parameter buah memiliki pola acak yang lebih sulit dipelajari oleh model. Selain itu, hasil penelitian ini dibandingkan dengan pendekatan konvensional, yaitu regresi linier berganda yang digunakan oleh Sahputra et al. (2024). Metode regresi tersebut hanya mampu mencapai R^2 sebesar 0,76 untuk prediksi produksi cabai merah. Jika dibandingkan, peningkatan performa yang dicapai oleh LSTM mencapai hingga 21% pada parameter batang (dengan $R^2 = 0,9796$), dan minimal 12% lebih tinggi pada parameter buah ($R^2 = 0,8807$). Ini membuktikan bahwa LSTM jauh lebih efektif dalam mengenali hubungan non-linear dan pola temporal kompleks dalam data pertumbuhan tanaman. Namun, karena data dikumpulkan hanya selama satu musim tanam (63 hari), generalisasi model terhadap musim hujan atau kemarau belum dapat dipastikan. Penelitian lanjutan perlu menambahkan data musiman dan variabel lingkungan (suhu, kelembapan, intensitas cahaya) untuk meningkatkan robustnes model. Kesimpulannya, LSTM efektif pada memprediksi pertumbuhan cabai merah, terutama pada parameter menggunakan pola stabil. Akurasi tertinggi dicapai pada batang, serta terendah pada buah. Perbandingan dengan regresi linear menunjukkan bahwa pendekatan *deep learning* memperlihatkan peningkatan akurasi yang signifikan buat prediksi pertanian berbasis deret saat.

IV. KESIMPULAN

Temuan penelitian ini mengindikasikan bahwa pendekatan *Time Series* menggunakan model Long Short-Term Memory (LSTM) sangat efektif dalam memprediksi pertumbuhan tanaman cabai merah. Model menunjukkan performa yang sangat baik pada parameter batang, cabang, dan daun, dengan nilai koefisien determinasi (R^2) masing-masing di atas 0,94. Sementara itu, untuk parameter buah, model tetap menunjukkan akurasi yang layak dengan nilai R^2 sebesar 0,8807. Perbedaan tingkat akurasi prediksi antar parameter mencerminkan kompleksitas dan karakteristik unik dari masing-masing aspek pertumbuhan tanaman. Parameter yang memiliki pola pertumbuhan yang lebih konsisten dan bertahap, seperti batang dan daun, cenderung memberikan hasil prediksi yang lebih akurat. Sebaliknya, parameter buah yang mengalami fluktuasi signifikan akibat pengaruh faktor fisiologis dan lingkungan memerlukan pendekatan prediktif yang lebih kompleks. Implementasi model prediksi ini berpotensi besar dalam mendukung efisiensi budidaya cabai merah, khususnya dalam hal perencanaan produksi, optimalisasi pemanfaatan sumber daya, serta deteksi dini terhadap anomali pertumbuhan. Untuk meningkatkan akurasi, khususnya pada parameter dengan variabilitas tinggi seperti buah, penelitian selanjutnya disarankan untuk mengintegrasikan variabel lingkungan seperti kelembapan udara, intensitas cahaya, dan kandungan nutrisi tanah ke dalam model LSTM. Selain itu, pemanfaatan teknologi *Internet of Things* (IoT) untuk pengumpulan data secara real-time juga direkomendasikan guna memungkinkan pemantauan pertumbuhan tanaman yang lebih adaptif serta penyesuaian model secara dinamis terhadap kondisi lapangan.

REFERENSI

- [1] A. G. R. Pradana, P. Harsono, and A. T. Sakya, "The effect of mycorrhizal inoculation and liquid organic fertilizer on growth and yield of red chili," *E3S Web Conf.*, vol. 306, pp. 1–6, 2021, doi: 10.1051/e3sconf/202130601049.
- [2] R. J. Lutfi, M. Roviq, and T. Islami, "Konsentrasi Nutrisi dan Media Tanam pada Pertumbuhan dan Hasil Tanaman Cabai Besar (*Capsicum annum L.*) Sistem Hidroponik Substrat," *J. Produksi Tanam.*, vol. 9, no. 9, pp. 559–566, 2021.
- [3] BPS SUMUT, "STATISTIK HARGA PRODUSEN SEKTOR PERTANIAN DI PROVINSI SUMATERA UTARA 2023," *Sustain.*, vol. 11, no. 1, pp. 1–14, 2019, [Online]. Available: http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI
- [4] H. Khatimah, W. G. Abdullah, D. Abdi, and U. H. Oleo, "Analisis Peramalan Produksi dan Harga Cabai Merah (*Capsicum annum L.*) di Provinsi Sulawesi Tenggara Forecasting Analysis of Production and Price of Red Chili (*Capsicum annum L.*) in Southeast Sulawesi Province," *J. Food Syst. Agribus.*, vol. 7, no. 2, pp. 113–122, 2023, doi: 10.25181/jofsa.v7i2.2959.
- [5] R. W. Lestari, K. Kusumiyati, S. Mubarak, and Y. E. Maulana, "Growth and yield response of Tanjung II and Unpad CB2 red chili varieties grown in the medium land," *Kultivasi*, vol. 23, no. 1, pp. 84–90, 2024, doi: 10.24198/kultivasi.v23i1.42551.
- [6] F. N. Fikri, "Performance Evaluation of Long Short-Term Memory for Chili Price Prediction," vol. 10, no. 1, pp. 33–47, 2025, doi: 10.14421/jiska.2025.10.1.33-47.
- [7] R. A. Falah and M. Rachmaniah, "Price Prediction Model for Red and Curly Red Chilies using Long Short Term Memory Method," *Indones. J. Stat. Its Appl.*, vol. 6, no. 1, pp. 143–160, 2022, doi:

- 10.29244/ijsa.v6i1p143-160.
- [8] L. Bui Duy *et al.*, “Refining Long Short-Term Memory Neural Network Input Parameters for Enhanced Solar Power Forecasting,” *Energies*, vol. 17, no. 16, 2024, doi: 10.3390/en17164174.
- [9] C. Sun, M. Pei, B. Cao, S. Chang, and H. Si, “A Study on Agricultural Commodity Price Prediction Model Based on Secondary Decomposition and Long Short-Term Memory Network,” *Agric.*, vol. 14, no. 1, 2024, doi: 10.3390/agriculture14010060.
- [10] S. Arya, Anju, and N. A. Ramli, “Prediction of international rice production using long short-term memory and machine learning models,” *Int. J. Informatics Commun. Technol.*, vol. 14, no. 1, pp. 164–173, 2025, doi: 10.11591/ijict.v14i1.pp164-173.
- [11] A. Joshi *et al.*, “An explainable Bi-LSTM model for winter wheat yield prediction,” *Front. Plant Sci.*, vol. 15, no. January, pp. 1–17, 2024, doi: 10.3389/fpls.2024.1491493.
- [12] S. Kontogiannis, G. Kokkonis, and C. Pikridas, “Proposed Long Short-Term Memory Model Utilizing Multiple Strands for Enhanced Forecasting and Classification of Sensory Measurements,” *Mathematics*, vol. 13, no. 8, pp. 1–22, 2025, doi: 10.3390/math13081263.
- [13] P. Manandhar, H. Rafiq, E. Rodriguez-Ubinas, and T. Palpanas, “New Forecasting Metrics Evaluated in Prophet, Random Forest, and Long Short-Term Memory Models for Load Forecasting,” *Energies*, vol. 17, no. 23, pp. 1–30, 2024, doi: 10.3390/en17236131.
- [14] B. Nguyen, M. Panwar, R. Hovsopian, and Y. Agalgaonkar, “Short-Term Forecasting of Thermostatic and Residential Loads Using Long Short-Term Memory Recurrent Neural Networks,” *2024 IEEE 3rd Ind. Electron. Soc. Annu. On-Line Conf. ONCON 2024*, pp. 5–9, 2024, doi: 10.1109/ONCON62778.2024.10931323.
- [15] S. Hu, W. Cai, J. Liu, H. Shi, and J. Yu, “Refining Short-Term Power Load Forecasting: An Optimized Model with Long Short-Term Memory Network,” *J. Comput. Inf. Technol.*, vol. 31, no. 3, pp. 151–166, 2023, doi: 10.20532/cit.2023.1005730.
- [16] E. B. Sahputra, Delima Christmas Sembiring, Ivan Hasadaon Sipayung, “Analisis prediksi hasil produksi tanaman cabai menggunakan metode multi linier regresi,” *TEKINKOM*, vol. 7, pp. 619–627, 2024, doi: 10.37600/tekinkom.v7i2.1512.
- [17] D. R. Sanjaya and B. Surarso, “International Journal of Current Science Research and Review Stock Price Forecasting on Time Series Data Using the Long Short-Term Memory (LSTM) Model,” vol. 07, no. 12, pp. 8866–8875, 2024, doi: 10.47191/ijcsrr/V7-i12-26.
- [18] S. Wan, “A Denoising Time Window Algorithm for Optimizing LSTM Prediction,” *IEEE Access*, vol. 12, no. May, pp. 74268–74290, 2024, doi: 10.1109/ACCESS.2024.3404456.
- [19] S. Pantopoulou, A. Cilliers, L. H. Tsoukalas, and A. Heifetz, “Transformers and Long Short-Term Memory Transfer Learning for GenIV Reactor Temperature Time Series Forecasting,” *Energies*, vol. 18, pp. 1–18, 2025, doi: 10.3390/en18092286.
- [20] A. Pranolo, F. Usha, and A. Khansa, “Enhanced Multivariate Time Series Analysis Using LSTM : A Comparative Study of Min-Max and Z-Score Normalization Techniques,” *Ilk. J. Ilm.*, vol. 16, no. 2, pp. 210–220, 2024, doi: 10.33096/ilkom.v16i2.2333.210-220.