

Implementasi Time Series Forecasting dengan Algoritma LSTM untuk Pemantauan dan Prediksi Produktivitas Kelapa Sawit Berdasarkan Hasil Panen

Ardian Pramana Putra*, Aninda Muliani Harahap

Sains dan Teknologi, Sistem Informasi, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

Email: ¹*ardianpramana1802@gmail.com, ²anindamh@gmail.com

Email Penulis Korespondensi: ardianpramana1802@gmail.com

Submitted 05-03-2025; Accepted 26-03-2025; Published 30-04-2025

Abstrak

Produktivitas kelapa sawit merupakan elemen kunci dalam menjaga stabilitas dan keberlanjutan industri agribisnis di Indonesia. Fluktuasi hasil panen di PTPN IV Kebun Bah Birung Ulu, seperti kenaikan dari 43.308 ton pada 2020 menjadi 44.028 ton pada 2022, lalu menurun menjadi 34.643 ton pada 2024, menunjukkan perlunya sistem pemantauan yang lebih akurat. Fluktuasi ini dipengaruhi oleh cuaca, penggunaan pupuk, infeksi tanaman, dan usia tanaman. Pencatatan manual tanpa dukungan sistem digital juga meningkatkan risiko kesalahan dan menyulitkan pemantauan produksi. Penelitian ini bertujuan mengembangkan sistem prediksi produktivitas kelapa sawit berbasis web menggunakan algoritma Long Short-Term Memory (LSTM). Data historis harian selama lima tahun, yang mencakup variabel usia tanaman, penggunaan pupuk, curah hujan, tingkat infeksi tanaman, dan hasil panen per-afdeling, digunakan sebagai input model. Proses penelitian meliputi pengumpulan data, preprocessing dengan normalisasi Min-Max, pembagian data training dan testing dengan proporsi 80%:20%, serta pelatihan model LSTM dengan dua lapisan LSTM, dua lapisan dropout, dan satu lapisan Dense. Evaluasi model menggunakan Root Mean Squared Error (RMSE) menunjukkan bahwa model mampu memprediksi produktivitas dengan tingkat akurasi yang baik, dengan RMSE terbaik untuk masing-masing variabel target diperoleh pada epoch yang berbeda. Hasil prediksi tahun 2025 menunjukkan kecenderungan stabil atau menurun yang dipengaruhi oleh usia tanaman, pemakaian pupuk, curah hujan, dan tingkat infeksi. Sistem berbasis web yang dikembangkan dilengkapi fitur pemantauan real-time dan visualisasi data, memberikan solusi yang lebih efisien dalam pengelolaan produksi dan pengambilan keputusan strategis di perkebunan kelapa sawit.

Kata Kunci: Produktivitas Kelapa Sawit; Time Series; LSTM; Prediksi; Sistem Berbasis Web

Abstract

Palm oil productivity is a key factor in maintaining the stability and sustainability of Indonesia's agribusiness industry. The fluctuation in yield at PTPN IV Kebun Bah Birung Ulu, which increased from 43,308 tons in 2020 to 44,028 tons in 2022 and then decreased to 34,643 tons in 2024, highlights the need for a more accurate monitoring system. These fluctuations are influenced by weather, fertilizer usage, plant infections, and plant age. Manual record-keeping without digital system support also increases the risk of errors and complicates production monitoring. This study aims to develop a web-based palm oil productivity prediction system using the Long Short-Term Memory (LSTM) algorithm. Five years of daily historical data, including plant age, fertilizer usage, rainfall, infection rates, and harvest results per afdeling, were used as model input. The research process includes data collection, preprocessing with Min-Max normalization, data splitting into 80% training and 20% testing, and training the LSTM model with two LSTM layers, two dropout layers, and one Dense layer. Model evaluation using Root Mean Squared Error (RMSE) shows that the model can predict productivity with good accuracy, with the best RMSE for each target variable achieved at different epochs. The 2025 prediction results indicate a stable or declining trend influenced by plant age, fertilizer application, rainfall, and infection rates. The developed web-based system features real-time monitoring and data visualization, providing a more efficient solution for production management and strategic decision-making in palm oil plantations.

Keywords: Palm Oil Productivity; Time Series; LSTM; Prediction; Web-Based System

1. PENDAHULUAN

Indonesia merupakan produsen utama kelapa sawit dunia, menyumbang 60% dari total produksi global pada 2021/2022. Dengan total produksi 51 juta ton (CPO dan PKO), industri ini menjadi sumber devisa besar dan menyerap banyak tenaga kerja, terutama di pedesaan [1]. Permintaan global yang terus meningkat mendorong perlunya sistem pemantauan untuk menjaga efisiensi produksi dan memenuhi target pasar [2]. Namun, pengelolaan produksi di lapangan menghadapi tantangan signifikan, terutama dalam memantau produktivitas tanaman berdasarkan faktor usia tanaman, penggunaan pupuk, curah hujan, serangan hama dan hasil panen per-afdeling. Produktivitas kelapa sawit, yang diukur dalam kilogram atau ton per hektar, membutuhkan pengelolaan yang tepat untuk mencapai hasil optimal [3].

Di PTPN IV Kebun Bah Birung Ulu, produktivitas kelapa sawit berfluktuasi setiap tahun, naik dari 43.308 ton (2020) ke 43.716 ton (2021) lalu naik lagi 44.028 ton (2022), lalu turun menjadi 38.947 ton (2023) dan 34.643 ton (2024). Fluktuasi ini dipengaruhi oleh cuaca, pupuk, infeksi tanaman, dan usia tanaman [4]. Ketidakseimbangan panen dan permintaan pasar mengganggu distribusi dan stabilitas bisnis. Selain itu, pencatatan manual tanpa sistem digital rentan terhadap kesalahan, sementara infrastruktur yang kurang memadai menyulitkan pemantauan [5]. Oleh karena itu, diperlukan solusi prediksi produktivitas berbasis data untuk mendukung pengambilan keputusan [6].

Penelitian terdahulu yang menjadi referensi dalam penelitian ini melibatkan lima studi terkait prediksi menggunakan algoritma kecerdasan buatan, masing-masing dengan metode dan hasil yang berbeda.

Penelitian pertama oleh Marpaung et al. (2020) menggunakan algoritma Backpropagation Neural Network untuk memprediksi produktivitas kelapa sawit di PTPN IV Kebun Dolok Sinumbah, dengan akurasi 92%. Namun, penelitian

ini hanya menggunakan data produksi bulanan tanpa mempertimbangkan faktor multi-aspek seperti usia tanaman atau kondisi kebun, serta tidak mengembangkan sistem berbasis web [7]. Model ini kurang mampu menangani pola kompleks dalam data time series serta tidak mempertimbangkan faktor lingkungan yang dapat mempengaruhi hasil panen.

Penelitian kedua oleh David et al. (2023) menerapkan algoritma Long Short-Term Memory (LSTM) untuk memprediksi harga cabai di Kota Malang berdasarkan data historis harian, dengan nilai MSE terbaik sebesar 0,0155. Namun, penelitian ini hanya berfokus pada data tunggal (harga cabai) tanpa mempertimbangkan faktor eksternal lainnya dan tidak menghasilkan sistem berbasis web [8]. Perbedaan utama dari penelitian ini adalah bahwa studi yang dilakukan saat ini tidak hanya menggunakan LSTM tetapi juga mengintegrasikan multi-faktor dalam analisis prediksi.

Penelitian ketiga oleh Sianturi et al. (2023) menggunakan LSTM berbasis multi fungsi aktivasi untuk memprediksi harga Ethereum dengan nilai MSE terbaik sebesar 0,0121. Meskipun menggunakan pendekatan yang lebih kompleks, penelitian ini tetap terbatas pada data tunggal tanpa integrasi multi-aspek [9]. Dibandingkan dengan penelitian ini, penelitian saat ini mengadopsi LSTM tetapi dengan pendekatan berbasis multi-aspek yang lebih luas, mencakup faktor-faktor yang mempengaruhi produktivitas kelapa sawit.

Penelitian keempat oleh Pratiwi et al. (2023) menggunakan metode *Fuzzy Time Series* (FTS) dengan model *Lee* untuk meramalkan jumlah produksi Tandan Buah Segar (TBS) di PT Kalimantan Sawit Kusuma, dengan nilai *MAPE* sebesar 4,8%. Penelitian ini hanya berfokus pada data produksi tanpa analisis multi-aspek atau pengembangan sistem aplikasi [10]. Perbedaan utama dari penelitian ini adalah bahwa penelitian saat ini menggunakan deep learning (LSTM) dibandingkan dengan pendekatan berbasis FTS yang memiliki keterbatasan dalam menangkap pola kompleks dalam data time series.


Penelitian kelima oleh Widiarni & Mustakim (2023) menggunakan algoritma *Support Vector Regression* (SVR) untuk memprediksi produktivitas kelapa sawit di PTPN V, dengan akurasi tertinggi sebesar 75,4% untuk data produksi. Penelitian ini menganalisis faktor-faktor seperti curah hujan dan kesuburan tanah, tetapi memiliki keterbatasan dalam menangani volume data besar dan hubungan temporal, serta tidak menghasilkan sistem berbasis web [11]. Metode SVR kurang efektif dalam menangani data yang memiliki ketergantungan temporal jangka panjang, sedangkan penelitian saat ini menggunakan LSTM yang lebih unggul dalam time series forecasting.

Berbeda dari penelitian-penelitian tersebut, Penelitian ini menggunakan algoritma *Long Short-Term Memory* (LSTM), salah satu metode *deep learning* untuk memprediksi produktivitas kelapa sawit. Keunggulan penelitian ini dibandingkan dengan studi sebelumnya adalah integrasi multi-aspek dalam prediksi produktivitas kelapa sawit, mencakup usia tanaman, pupuk, curah hujan, infeksi hama, dan hasil panen per-afdeling [12]. LSTM, varian dari *Recurrent Neural Network* (RNN), mampu menangkap pola data jangka panjang dalam *time series forecasting* [13]. Selain itu, penelitian ini mengembangkan sistem berbasis web dengan fitur pemantauan real-time, notifikasi dini, dan visualisasi data guna mendukung pengambilan keputusan berbasis data serta meningkatkan produktivitas. Dengan pendekatan ini, penelitian ini bertujuan meningkatkan akurasi pemantauan hasil panen dan daya saing PTPN IV Kebun Bah Birung Ulu.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini memiliki tahapan-tahapan yang dapat dilihat pada Gambar 1 berikut.



Gambar 1. Tahapan Penelitian

Berikut adalah penjelasan rinci untuk setiap tahapan dalam penelitian ini:

a. Pengumpulan Data

1. Observasi: Melakukan pengamatan langsung di PTPN IV Kebun Bah Birung Ulu untuk memahami proses pencatatan produktivitas dan pengelolaan kebun.
2. Wawancara: Mengumpulkan informasi dari manajer kebun dan petugas lapangan terkait kendala dan kebutuhan sistem.
3. Studi Dokumentasi: Mengakses data historis hasil panen kelapa sawit, termasuk faktor-faktor seperti usia tanaman, penggunaan pupuk, curah hujan, dan serangan hama [14].

b. *Preprocessing* (Normalisasi Data)

Tahap ini mencakup proses pembersihan dan normalisasi data untuk memastikan kualitas serta kelengkapan data [15]. Langkah-langkah yang dilakukan meliputi identifikasi dan penanganan missing value, serta penerapan metode normalisasi min-max untuk mengubah nilai-nilai dataset agar berada dalam rentang tertentu, sehingga memudahkan proses pelatihan model [16].

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan:

x' = Hasil Normalisasi

x_i = Data ke i

x_{min} = Data dengan nilai minimum

x_{max} = Data dengan nilai maksimum

c. Pemisahan Data

Data dipisahkan menjadi data training dan data testing dengan tujuan untuk melatih serta menguji model. Dalam penelitian ini, proporsi data training dan data testing adalah 80%:20%.

d. Model LSTM

Penelitian ini menggunakan model LSTM dengan lima lapisan, terdiri dari dua lapisan LSTM dengan masing-masing 64 *neuron*, dua lapisan *dropout*, dan satu lapisan *dense* dengan 3 *neuron*. Model ini memiliki 154.187 parameter, dengan 51.395 parameter yang dapat dilatih dan 102.792 parameter optimizer. *Learning rate* awal sebesar 0,001 dapat berkurang secara dinamis melalui *ReduceLROnPlateau*. Pelatihan model direncanakan hingga 100 *epoch*, namun dapat berhenti lebih awal jika *validation loss* tidak membaik selama 15 *epoch* (early stopping). Penentuan parameter ini didasarkan pada literatur dan hasil trial and error untuk memperoleh konfigurasi optimal.

e. Evaluasi:

Model yang dihasilkan dari pelatihan menggunakan metode LSTM dievaluasi dengan menggunakan *Root Mean Squared Error* (RMSE) sebagai metrik evaluasi untuk mengetahui tingkat kesalahan prediksi model terhadap data aktual [17].

$$RMSE = \sqrt{\sum (Aktual - Prediksi)^2 / n} \quad (2)$$

Keterangan:

n = Ukuran sampel

f. Prediksi:

Prediksi model LSTM untuk tahun 2025 memperkirakan produktivitas kelapa sawit berdasarkan pola data historis. Hasil ini dapat digunakan sebagai acuan dalam perencanaan produksi dan pengelolaan kebun secara efektif, dengan harapan tingkat akurasi yang baik untuk proyeksi jangka panjang.

g. Denormalisasi Data:

Mengembalikan data prediksi ke nilai asli dengan melakukan proses denormalisasi sehingga dapat dibandingkan dengan data aktual [18].

$$x = x'(x_{max} - x_{min}) + x_{min} \quad (3)$$

Keterangan:

x' = Data yang akan di denormalisasi

x_i = Hasil denormalisasi

x_{min} = Data dengan nilai minimum

x_{max} = Data dengan nilai maksimum


h. Deployment:

Model LSTM yang telah dilatih dan dievaluasi diimplementasikan ke dalam sistem berbasis web. Tujuannya adalah agar hasil prediksi produktivitas kelapa sawit dapat diakses dan dimanfaatkan dengan mudah oleh pengguna dalam pengambilan keputusan.

2.2 Metode Long Short-Term Memory (LSTM)

Metode *Long Short-Term Memory* (LSTM) digunakan dalam penelitian ini untuk memprediksi produktivitas kelapa sawit di PTPN IV Kebun Bah Birung Ulu. LSTM dipilih karena kemampuannya dalam menangani data deret waktu dengan

pola kompleks yang mencakup hubungan temporal jangka panjang [12]. Struktur gerbang pada LSTM terdapat pada Gambar 2.



Gambar 2. Arsitektur LSTM

LSTM terdiri dari rangkaian sel memori unik yang memproses informasi melalui struktur gerbang. Model LSTM memiliki empat jenis gerbang utama, yaitu *forget gate*, *input gate*, *cell gate*, dan *output gate*. Setiap gerbang memiliki persamaan dan fungsi masing-masing.

1. *Input gate*:

$$i_t = \sigma(W_i \times X_i + U_i \times h_{t-1} + b_i) \quad (4)$$

2. *Forget gate*:

$$f_t = \sigma(W_f \times X_t + U_f \times h_{t-1} + b_f) \quad (5)$$

3. *Cell State*:

$$c_t = f_t \odot c_{t-1} + i_t \odot c'_t \quad (6)$$

4. *New Candidate*:

$$c'_t = \tanh(W_c \times X_c + U_c \times h_{t-1} + b_c) \quad (7)$$

5. *Output gate*:

$$o_t = \sigma(W_o \times X_i + U_o \times h_{t-1} + b_o) \quad (8)$$

6. *Hidden State*:

$$h_t = o_t \odot \sigma(c_t) \quad (9)$$

Elemen σ dalam persamaan tersebut adalah fungsi aktivasi *sigmoid*, sedangkan $\tanh$ merupakan fungsi aktivasi *hyperbolic tangent* (TanH) [19].

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari 1.827 data historis harian yang tercatat dari tahun 2020 hingga 2024. Dataset ini mencakup berbagai variabel penting yang berpengaruh terhadap prediksi produktivitas kelapa sawit, seperti hasil panen harian (Hafd) dalam kilogram, penggunaan pupuk (Pup) dalam kilogram, tingkat infeksi hama (Tih) dalam persen, dan curah hujan (Ch) dalam milimeter. Berikut dapat dilihat pada Tabel 1.

Tabel 1. Hasil Pengumpulan Data dari Tahun 2020-2024

No	Tanggal	Hafd1	Hafd2	Hafd3	Pup	Ch	Tih
1	01/01/2020	0	0	0	0	8	1
2	02/01/2020	28.960	30.950	11.810	3.700	6	0
3	03/01/2020	50.380	35.000	18.610	3.500	0	1
4	04/01/2020	53.800	20.710	18.580	3.600	20	0
5	05/01/2020	0	0	0	0	3	0
..	...	...	...	...	...	...	...

1823	27/12/2024	37.110	55.350	37.190	4.460	0	0
1824	28/12/2024	35.790	45.830	41.040	4.470	0	0
1825	29/12/2024	63.660	35.470	40.680	4.470	0	0
1826	30/12/2024	68.770	41.110	48.690	4.460	0	0
1827	31/12/2024	30.380	21.090	27.590	4.470	0	0

Berdasarkan hasil dari tabel di atas, hasil panen afdeling 1 (Hafd1), produktivitas kelapa sawit tercatat sebesar 52,834 ton dengan luas kebun 1.727 ha. Sementara itu, hasil panen afdeling 2 (Hafd2) menunjukkan produktivitas sebesar 273,011 ton dari luas kebun 258 ha, dan hasil panen afdeling 3 (Hafd3) mencatat produktivitas sebesar 15,170 ton dengan luas kebun 435 ha.

3.2 Normalisasi Data

Melakukan normalisasi pada data hasil panen kelapa sawit menggunakan metode *Min-Max*. Normalisasi data adalah proses penyesuaian skala atau rentang nilai data sehingga informasi dapat dianalisis dengan lebih akurat [20]. Hasil dari proses normalisasi tersebut disajikan dalam Tabel 2 berikut.

Tabel 2. Hasil Normalisasi Data

Data ke-	Hafd1	Hafd2	Hafd3	Pup	Ch	Tih
1	0	0	0	0	0,019231	1
2	0,219677	0,313101	0,161781	0,810515	0,014423	0
3	0,382159	0,354072	0,254932	0,766703	0	1
4	0,408101	0,209509	0,254521	0,788609	0,048077	0
5	0	0	0	0	0,007212	0
..	...	...	...	...	...	...
1823	0,281499	0,559939	0,509452	0,976999	0	0
1824	0,271486	0,463632	0,562192	0,979189	0	0
1825	0,482895	0,358827	0,55726	0,979189	0	0
1826	0,521657	0,415883	0,666986	0,976999	0	0
1827	0,230448	0,213354	0,377945	0,979189	0	0

3.3 Pemisahan Data Training dan Data Testing

Pembagian data dalam penelitian ini menggunakan skema 80% untuk data training dan 20% untuk data testing. Data training terdiri dari 1461 data historis harian yang mencakup periode 1 Januari 2020 hingga 31 Desember 2023. Sementara itu, data testing terdiri dari 366 data historis harian yang mencakup periode 1 Januari 2024 hingga 31 Desember 2024. Pembagian ini bertujuan untuk memastikan model LSTM dapat mempelajari pola data dengan baik dan menguji performa model pada data yang belum pernah dilihat sebelumnya. Hasil pemisahan data dapat dilihat pada Tabel 3 berikut.

Tabel 3. Pemisahan Data Training dan Data Testing

Dataset	Persentase	Jumlah	Tanggal Mulai	Tanggal Akhir
Training	80%	1461	2020/01/01	2023/12/31
Testing	20%	366	2024/01/01	2024/12/31

3.4 Arsitektur Model LSTM

Pembuatan arsitektur model LSTM, yang bertujuan untuk membangun jaringan saraf tiruan yang mampu menangkap pola dalam data deret waktu [21]. Pada tahap ini, model LSTM dirancang dengan beberapa lapisan, seperti lapisan input, lapisan LSTM, dan lapisan output. Hasil pemodelannya dapat dilihat pada Tabel 4 berikut.

Tabel 4. Model LSTM

Layer (type)	Output Shape	Param #
lstm_12 (LSTM)	(None, 30, 64)	18,176
dropout_12 (Dropout)	(None, 30, 64)	0
lstm_13 (LSTM)	(None, 64)	33,024
dropout_13 (Dropout)	(None, 64)	0
dense_6 (Dense)	(None, 3)	195

Arsitektur model LSTM dalam penelitian ini dirancang untuk memprediksi produktivitas kelapa sawit berdasarkan data historis dengan lima lapisan model LSTM. Terdiri dari dua lapisan LSTM dengan masing-masing 64 *neuron*, dua lapisan *Dropout*, dan satu lapisan *Dense* dengan 3 *neuron* sebagai *output*. Total parameter model sebanyak 154.187, terdiri dari 51.395 parameter yang dapat dilatih dan 102.792 parameter optimizer. Model menggunakan *Adam optimizer* dengan *learning rate* awal 0,001 yang dapat berkurang dinamis melalui *callback ReduceLROnPlateau*. Pelatihan direncanakan hingga 100 *epoch*, namun dapat berhenti lebih awal jika *validation loss* tidak membaik selama 15 *epoch* melalui mekanisme *early stopping*. *Output Shape* dengan nilai *None* menunjukkan fleksibilitas jumlah sampel input,

angka 30 merepresentasikan panjang urutan data historis, dan 64 adalah dimensi fitur dari setiap lapisan LSTM. *Output Shape* (None, 3) pada layer *Dense* terakhir mengindikasikan prediksi tiga variabel target, yaitu hasil panen afdeling 1, hasil panen afdeling 2, dan hasil panen afdeling 3. Model ini dirancang untuk menangkap pola temporal dalam *data time series* secara efektif, sehingga mampu menghasilkan prediksi produktivitas yang akurat.


3.5 Evaluasi

Evaluasi dilakukan untuk mengukur sejauh mana model mampu mengenali pola data dan menghasilkan prediksi yang akurat. Parameter evaluasi yang digunakan adalah *Root Mean Squared Error* (RMSE) dan visualisasi perbandingan antara data aktual dan hasil prediksi. Dengan evaluasi ini, dapat dinilai efektivitas model dalam mengolah *data time series* dan memprediksi variabel target dengan tingkat kesalahan yang minimal. Hasil evaluasi model LSTM selama pelatihan disajikan dalam bentuk tabel dan grafik, yang menampilkan urutan epoch dan nilai RMSE. Hasil nilai RMSE dapat dilihat pada Tabel 5 dan Gambar 3 berikut ini.

Tabel 5. Rekapitulasi Nilai RMSE per Epoch pada Model LSTM


Epoch	Total RMSE	Hafd1 RMSE	Hafd2 RMSE	Hafd3 RMSE
1	0.136454	0.127123	0.121988	0.157537
2	0.134337	0.126411	0.117299	0.156207
3	0.132719	0.126062	0.116066	0.154568
4	0.130476	0.120637	0.115569	0.162492
5	0.128851	0.121065	0.115042	0.157881
6	0.129015	0.120889	0.115408	0.157211
7	0.129835	0.121098	0.116752	0.154685
8	0.130253	0.120078	0.116590	0.156836
9	0.132329	0.107537	0.118833	0.168868
10	0.134608	0.123751	0.118563	0.145821
11	0.134342	0.123095	0.118623	0.146531
12	0.133336	0.122333	0.117423	0.146792
13	0.131140	0.118698	0.117004	0.145328
14	0.131112	0.119011	0.117063	0.145263
15	0.130672	0.118460	0.116879	0.145409
16	0.130338	0.118755	0.116557	0.145013
17	0.130108	0.117565	0.125295	0.145108
18	0.130374	0.117553	0.116866	0.146093
19	0.130653	0.118153	0.117214	0.146783
20	0.130872	0.118493	0.117286	0.147317
21	0.130512	0.117328	0.117476	0.147107
22	0.130192	0.117125	0.117394	0.146580
23	0.130512	0.117326	0.117475	0.147108
24	0.136867	0.136512	0.138315	0.158870

Berdasarkan tabel RMSE per *epoch*, performa terbaik untuk masing-masing fitur target dicapai pada *epoch* yang berbeda. Fitur Hafd1 mencapai nilai RMSE terbaik sebesar 0.107593 pada *epoch* ke-20, sedangkan fitur Hafd2 memperoleh RMSE terendah sebesar 0.115498 pada *epoch* ke-6. Sementara itu, fitur Hafd3 mencatatkan RMSE terbaik sebesar 0.154885 pada *epoch* ke-8. Variasi dalam *epoch* terbaik untuk masing-masing fitur ini menunjukkan bahwa kecepatan konvergensi model terhadap setiap target berbeda-beda. Kemudian untuk hasil visual dalam bentuk grafik dapat dilihat pada Gambar 3 berikut.



Gambar 3. Grafik Model Loss over Epochs

Grafik Model *Loss over Epochs* menunjukkan penurunan nilai *loss* pada data pelatihan dan validasi seiring bertambahnya *epoch*, yang mengindikasikan bahwa model semakin baik dalam mengenali pola data. Pada awal pelatihan, *loss* menurun dengan cepat, kemudian melambat dan menjadi lebih stabil setelah sekitar *epoch* ke-10. Namun, terdapat sedikit fluktuasi pada *validation loss* di beberapa *epoch* terakhir, yang bisa menjadi indikasi awal terjadinya *overfitting*. Dengan memperhatikan nilai RMSE terbaik pada tabel dan pola *loss* pada grafik, dapat disimpulkan bahwa model cukup efektif dalam mempelajari data historis dan menghasilkan prediksi yang akurat. Untuk melihat perbandingan antara data aktual dan prediksi disajikan pada Gambar 4 berikut.




Gambar 4. Perbandingan Data Aktual dan Prediksi pada Target Hafd1, Hafd2 dan Hafd3

Gambar tersebut menampilkan perbandingan antara data aktual dan hasil prediksi untuk tiga variabel target (Hafd1, Hafd2, dan Hafd3) pada data uji. Garis biru merepresentasikan data aktual, sementara garis merah putus-putus menunjukkan hasil prediksi model LSTM. Ketiga grafik menunjukkan bahwa pola prediksi model cukup mendekati data aktual, meskipun terdapat beberapa deviasi pada titik-titik tertentu. Ini mengindikasikan bahwa model mampu mengenali tren dan fluktuasi pada data historis dengan baik, meskipun masih terdapat sedikit perbedaan pada nilai puncak dan lembah produksi. Secara keseluruhan, visualisasi ini mendukung evaluasi RMSE sebelumnya, yang menunjukkan performa prediksi yang cukup baik pada ketiga variabel.


3.6 Prediksi

Hasil prediksi merupakan gambaran hasil panen kelapa sawit di masa mendatang berdasarkan pola historis data aktual. Prediksi ini bertujuan untuk memberikan estimasi tren produktivitas sehingga dapat digunakan sebagai acuan dalam pengambilan keputusan strategis. Hasil prediksi dapat dilihat pada Gambar 5, 6 dan 7 berikut.



Gambar 5. Prediksi Hasil Panen Afdeling 1


Hasil prediksi untuk Hafd1 menunjukkan kecenderungan stabil atau menurun. Salah satu faktor utama yang memengaruhi hal ini adalah usia tanaman. Produktivitas kelapa sawit biasanya mencapai puncaknya pada usia 14–19 tahun dan mulai menurun setelah memasuki usia tua. Berdasarkan data tahun tanam, Hafd1 memiliki tanaman yang ditanam pada tahun 2004 dan 2005. Ini berarti sebagian besar tanaman telah berusia sekitar 20–21 tahun pada 2025, yang masuk dalam kategori tanaman tua dengan potensi penurunan hasil.



Gambar 6. Prediksi Hasil Panen Afdeling 2

Untuk Hafd2, hasil prediksi cenderung lebih stabil dibandingkan Hafd1. Hal ini disebabkan oleh usia tanaman yang masih dalam fase produktif. Berdasarkan data, tanaman di Hafd2 ditanam pada tahun 2006, 2007, dan 2011,

sehingga usia tanamannya berkisar antara 14–19 tahun pada periode prediksi. Dengan berada dalam fase produktif, produksi Hafd2 masih cukup stabil, meskipun tetap mengalami sedikit fluktuasi yang wajar dalam siklus pertumbuhan dan panen.



Gambar 7. Prediksi Hasil Panen Afdeling 3

Berbeda dengan Hafd1 dan Hafd2, Hafd3 memiliki tanaman dengan tahun tanam 2017 dan 2018, yang pada 2025 baru berusia 7–8 tahun. Tanaman ini masih tergolong muda dan sedang menuju fase produktif. Oleh karena itu, hasil prediksinya cenderung menunjukkan potensi peningkatan atau stabilitas dalam jangka menengah. Tanaman muda ini masih dalam fase pertumbuhan dan memiliki potensi untuk meningkatkan produktivitas seiring berjalannya waktu.

Hasil prediksi hasil panen yang cenderung stabil atau menurun dalam grafik dapat disebabkan oleh beberapa faktor penting yang memengaruhi produktivitas kelapa sawit. Salah satu faktor utama adalah usia tanaman, di mana produktivitas kelapa sawit biasanya mencapai puncaknya pada usia 14–19 tahun (fase produktif) dan mulai menurun setelah memasuki usia tua. Selain faktor usia, penggunaan pupuk yang tidak optimal juga dapat memengaruhi hasil produksi. Jika pemberian pupuk tidak sesuai dengan kebutuhan tanaman pada setiap fase pertumbuhan, produktivitas tanaman bisa terhambat. Curah hujan juga berperan penting, di mana kekurangan atau kelebihan hujan dapat mengganggu proses pembungaan dan pembuahan, yang pada akhirnya berdampak pada hasil panen. Faktor lain yang tak kalah penting adalah tingkat infeksi tanaman. Penyakit atau serangan hama yang tinggi dapat menyebabkan penurunan kesehatan tanaman, sehingga berpengaruh langsung pada kualitas dan kuantitas hasil panen. Pengelolaan kesehatan tanaman yang kurang baik bisa mempercepat penurunan produktivitas, terutama pada tanaman yang sudah berusia tua.

Dengan mempertimbangkan kombinasi faktor usia tanaman, pemupukan, curah hujan, dan tingkat infeksi tanaman, dapat disimpulkan bahwa variasi pola prediksi produksi antar afdeling sangat dipengaruhi oleh kondisi agronomis dan manajemen kebun, yang secara langsung memengaruhi tingkat produktivitas kelapa sawit di masa mendatang.

Sebelum menampilkan tabel hasil prediksi, proses denormalisasi dilakukan untuk mengembalikan data ke skala aslinya [20]. Dengan denormalisasi, hasil prediksi produksi kelapa sawit untuk tahun 2025 dapat diinterpretasikan dengan lebih akurat, sesuai dengan satuan dan rentang data sebenarnya. Proses ini penting karena model LSTM dilatih menggunakan data yang telah dinormalisasi, sehingga output model perlu dikonversi kembali agar dapat dibandingkan dengan data aktual. Hasil total prediksi panen kelapa sawit tahun 2025 untuk masing-masing afdeling akan ditampilkan dalam Tabel 6 berikut.

Tabel 6. Prediksi Tahun 2025

Afdeling	Tahun Tanam	Usia Tanaman (2025)	Prediksi Hasil Panen (Ton)	Produktivitas (Ton/Ha)	Luas Lahan (Ha)
I	2004, 2005	20-21 (Tua)	14.500	8,39	1.727
II	2006, 2008, 2011	14-19 (Produktif)	10.384	40,24	258
III	2016, 2017	6-7 (Muda)	9.251	21,26	435


3.7 Deployment

a. Halaman Login

Gambar 8. Halaman Login

Tampilan awal pada sistem adalah halaman login, di mana pengguna harus memasukkan username dan password yang telah terdaftar. Sistem ini mendukung berbagai peran pengguna (role), seperti admin, manajer, dan petugas lapangan, dengan akses yang disesuaikan berdasarkan hak masing-masing.

b. Halaman Dashboard



Gambar 9. Halaman Dashboard

Setelah berhasil login, pengguna akan diarahkan ke halaman dashboard. Halaman ini menampilkan grafik produktivitas kelapa sawit, yang memberikan visualisasi data hasil panen berdasarkan periode waktu tertentu.

c. Halaman Data Harian


The daily data table is as follows:

No	Tanggal	Afd 1	Afd 2	Afd 3	Pupuk	Curah Hujan	Hama	Aksi
1	2020-01-01	0 kg	0 kg	0 kg	0 kg	8 mm	1%	Edit Hapus
2	2020-01-02	28.960 kg	30.950 kg	11.810 kg	3.700 kg	6 mm	0%	Edit Hapus
3	2020-01-03	50.380 kg	35.000 kg	18.610 kg	3.500 kg	0 mm	1%	Edit Hapus
4	2020-01-04	53.800 kg	20.710 kg	18.580 kg	3.600 kg	20 mm	0%	Edit Hapus
5	2020-01-05	0 kg	0 kg	0 kg	0 kg	3 mm	0%	Edit Hapus
6	2020-01-06	35.590 kg	53.140 kg	21.530 kg	3.620 kg	0 mm	1%	Edit Hapus
7	2020-01-07	38.630 kg	38.690 kg	2.500 kg	3.610 kg	6 mm	1%	Edit Hapus

Gambar 10. Halaman Data Harian

Pada halaman ini, pengguna dapat mengelola data harian, termasuk data hasil panen, penggunaan pupuk, curah hujan, infeksi hama, dan usia tanaman, yang berperan dalam analisis produktivitas kelapa sawit.

d. Halaman Prediksi



Gambar 11. Halaman Prediksi

Pada halaman ini, pengguna dapat memprediksi hasil produktivitas kelapa sawit untuk satu bulan ke depan. Dengan mengklik tombol "Predict", sistem akan memproses data dan menampilkan grafik prediksi hasil panen.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi produktivitas kelapa sawit menggunakan algoritma *Long Short-Term Memory* (LSTM) berbasis data historis harian selama lima tahun. Model ini mempertimbangkan berbagai faktor produksi, seperti usia tanaman, penggunaan pupuk, curah hujan, dan tingkat infeksi tanaman, yang berkontribusi pada fluktuasi hasil panen di PTPN IV Kebun Bah Birung Ulu. Dengan pembagian data 80% untuk *training* dan 20% untuk *testing*, serta penerapan *preprocessing* melalui normalisasi *Min-Max*, model LSTM yang dirancang menggunakan dua lapisan LSTM, dua lapisan *Dropout*, dan satu lapisan *Dense* mampu mengenali pola data dengan baik. Evaluasi menggunakan *Root Mean Squared Error* (RMSE) menunjukkan bahwa model ini mencapai tingkat akurasi yang baik, dengan RMSE terbaik diperoleh pada *epoch* yang berbeda untuk setiap variabel target. Hasil prediksi tahun 2025 menunjukkan kecenderungan produksi yang stabil hingga menurun, yang dipengaruhi oleh usia tanaman yang semakin tua, penggunaan pupuk, curah hujan, dan tingkat infeksi. Meskipun model ini menunjukkan performa yang baik, penelitian ini memiliki beberapa keterbatasan. Model belum sepenuhnya menangkap variasi musiman dan anomali pada data produksi, yang dapat disebabkan oleh keterbatasan fitur *input* yang digunakan. Selain itu, pengaruh faktor eksternal seperti kebijakan pengelolaan perkebunan dan kondisi pasar belum dimasukkan dalam model. Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan variabel pendukung lainnya dan mengeksplorasi algoritma *deep learning* lain untuk meningkatkan akurasi dan generalisasi model. Dengan pengembangan lebih lanjut, sistem ini diharapkan dapat menjadi alat bantu yang lebih efektif dalam pengambilan keputusan strategis terkait produksi kelapa sawit.

REFERENCES

- [1] BPS, Statistik Kelapa Sawit Indonesia 2021. Jakarta: Badan Pusat Statistik/BPS–Statistics Indonesia, 2021.
- [2] R. A. Hadiguna, MANAJEMEN RANTAI PASOK AGROINDUSTRI. Padang: Andalas University Press, 2016.
- [3] T. Ningsih, R. Maharany, and S. Khoirul Fu, "ANALISA PRODUKTIVITAS KELAPA SAWIT DI DATARAN TINGGI KEBUN BAH BIRONG ULU-PT. PERKEBUNAN NUSANTARA IV," *Jurnal Agrium*, vol. 17, no. 1, 2020.
- [4] W. D. U. Parwati, F. H. Nadeak, and V. Kautsar, "Analisis Pertumbuhan dan Produktivitas Kelapa Sawit pada Variasi Kerapatan Tanam," *Jurnal Agro Industri Perkebunan*, pp. 105–116, Jul. 2023, doi: 10.25181/jaip.v12i2.3535.
- [5] A. Gabriel, S. Zaman, and Supijatno, "Pengelolaan Sistem Panen Kelapa Sawit (*Elaeis guineensis* Jacq.) di Kebun Rambutan, Serdang Berdagai, Sumatera Utara," 2023.
- [6] M. Ihsan, Samsudin, and A. M. Harahap, "Sales Forecasting Application Using The Triple Exponential Smoothing Method Based on Android," 2022.

- [7] D. Marpaung, S. Sumarno, and I. Gunawan, "Prediksi Produktivitas Kelapa Sawit di PTPN IV dengan Algoritma Backpropagation," 2020. [Online]. Available: <https://djournals.com/index.php/klik/Page35>
- [8] M. David, I. Cholissodin, and N. Yudistira, "Prediksi Harga Cabai menggunakan Metode Long-Short Term Memory (Case Study : Kota Malang)," 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [9] T. B. Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum," 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [10] R. I. Pratiwi, N. Salam, H. Maisarah, J. A. Yani, K. M. 36, and K. Selatan, "PERAMALAN JUMLAH PRODUKSI TANDAN BUAH SEGAR (TBS) KELAPA SAWIT MENGGUNAKAN METODE FUZZY TIME SERIES (STUDI KASUS: PT KALIMANTAN SAWIT KUSUMA)," 2023. [Online]. Available: <http://ppjp.ulm.ac.id/journals/index.php/epsilon>
- [11] A. Widiarni and M. Mustakim, "Penerapan Algoritma Support Vector Regression dalam Memprediksi Produksi dan Produktivitas Kelapa Sawit," JURNAL MEDIA INFORMATIKA BUDIDARMA, vol. 7, no. 2, p. 864, Apr. 2023, doi: 10.30865/mib.v7i2.6089.
- [12] R. Al Kiramy, I. Permana, A. Marsal, M. R. Munzir, and M. Megawati, "Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad," MALCOM: Indonesian Journal of Machine Learning and Computer Science, vol. 4, no. 4, pp. 1224–1234, Jul. 2024, doi: 10.57152/malcom.v4i4.1373.
- [13] A. Khumaidi, R. Raafi, I. Permana Solihin, and J. Rs Fatmawati, "Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung," Jurnal Telematika, vol. 15, no. 1, 2020.
- [14] G. Daruhadi and P. Sopiati, "Pengumpulan Data Penelitian," in Jurnal Cendekia Ilmiah, 2024.
- [15] B. G. Aji, D. C. A. Sondawa, F. A. Anindika, and D. Januarita, "Analisis Peramalan Obat Menggunakan Metode Simple Moving Average, Weighted Moving Average, Dan Exponential Smoothing," JURIKOM (Jurnal Riset Komputer), vol. 9, no. 4, p. 959, Aug. 2022, doi: 10.30865/jurikom.v9i4.4454.
- [16] I. Permana and F. Nur Salisah, "Pengaruh Normalisasi Data Terhadap Performa Hasil Klasifikasi Algoritma Backpropagation," 2022.
- [17] H. Budiman, "ANALISIS DAN PERBANDINGAN AKURASI MODEL PREDIKSI RENTET WAKTU SUPPORT VECTOR MACHINES DENGAN SUPPORT VECTOR MACHINES PARTICLE SWARM OPTIMIZATION UNTUK ARUS LALU LINTAS JANGKA PENDEK," 2016.
- [18] R. Juniadi Domitri Simamora, "Peramalan Curah Hujan Menggunakan Metode Extreme Learning Machine," 2019. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [19] T. G. Lasijan, R. Santoso, and A. R. Hakim, "PREDIKSI HARGA EMAS DUNIA MENGGUNAKAN METODE LONG-SHORT TERM MEMORY," Jurnal Gaussian, vol. 12, no. 2, pp. 287–295, Jul. 2023, doi: 10.14710/j.gauss.12.2.287-295.
- [20] R. Dina, N. Azizah, D. S. Susanti, and S. Annisa, "PREDIKSI INDEKS HARGA KONSUMEN KELOMPOK BAHAN MAKANAN DI PROVINSI KALIMANTAN SELATAN," 2024. [Online]. Available: <http://ppjp.ulm.ac.id/journals/index.php/epsilon>
- [21] M. Atharsyah, M. A. Romli, J. R. Utara, K. Sleman, and I. Yogyakarta, "IMPLEMENTASI MODEL LSTM, GRU, BILSTM, DAN BIGRU DALAM PREDIKSI HARGA NIKEL," 2024. [Online]. Available: <http://ejournal.stmiklombok.ac.id/index.php/jireISSN.2620-6900>