

IMPLEMENTASI ALGORITMA LONG SHORT-TERM MEMORY (LSTM) PADA SISTEM
PREDIKSI HASIL PANEN SAWITFajar Ramadhan^{1*}, Muhammad Fachrie²^{1,2}Informatika, Universitas Teknologi Yogyakarta
email: fajarrahdan34@gmail.com^{1*}

Abstrak: Tanaman Kelapa Sawit merupakan salah satu jenis perkebunan yang menduduki posisi penting di sektor pertanian atau perkebunan. Penelitian sistem prediksi hasil panen kelapa sawit menggunakan metode *Long Short-Term Memory* (LSTM) untuk membantu petani dalam merencanakan dan mengelola kebun mereka secara lebih efektif. Sebelum sistem ini ada, petani sering menghadapi tantangan besar dalam memperkirakan hasil panen secara akurat, yang mengakibatkan penggunaan sumber daya yang tidak efisien dan kerugian ekonomi. Data yang digunakan dalam penelitian ini dikumpulkan dari wawancara dan catatan petani kelapa sawit selama periode Januari 2023 hingga Januari 2024. Sistem yang diusulkan melibatkan beberapa tahapan, termasuk pengumpulan dan pra-pemrosesan data, pembangunan dan pelatihan model LSTM, serta evaluasi kinerja model. Hasil penelitian ini menunjukkan bahwa model LSTM mampu memberikan prediksi yang lebih akurat dibandingkan metode sebelumnya, dengan nilai *Mean Absolute Error* (MAE) yang rendah. Sementara itu, dalam proses pembuatan model persentase data training dan data testing sebesar 80%:20% dengan nilai sequence data sebanyak 640, Parameter yang digunakan, yaitu hidden unit sebanyak 128, dan jumlah epoch 150 sehingga menghasilkan nilai MSE sebesar 5.3968. Implementasi sistem ini diharapkan dapat membantu petani meningkatkan efisiensi dan efektivitas dalam manajemen kebun serta memanfaatkan peluang pasar secara optimal.

Kata Kunci : Kelapa Sawit, LSTM, Deep Learning, Prediksi, Streamlit

Abstract: Oil palm plantations are a type of plantation that occupies an important position in the agricultural or plantation sector. Research on palm oil yield prediction systems uses the *Long Short-Term Memory* (LSTM) method to help farmers plan and manage their plantations more effectively. Before these systems existed, farmers often faced major challenges in accurately estimating crop yields, resulting in inefficient use of resources and economic losses. The data used in this research were collected from interviews and notes of oil palm farmers during the period January 2023 to January 2024. The proposed system involves several stages, including data collection and pre-processing, LSTM model building and training, and model performance evaluation. The research results show that the LSTM model is able to provide more accurate predictions than previous methods, with a low *Mean Absolute Error* (MAE) value. Meanwhile, in the process of making the model, the percentage of training data and testing data was 80%:20% with a sequence data value of 640. The parameters used were 128 hidden units, and the number of epochs was 150, resulting in an MSE value of 5.3968. It is hoped that the implementation of this system can help farmers increase efficiency and effectiveness in plantation management and make optimal use of market opportunities.

Keywords : Palm oil, LSTM, Deep Learning, Prediction, Streamlit

PENDAHULUAN

Kelapa sawit merupakan komoditas penting dalam perekonomian global, terutama dalam menghasilkan minyak yang digunakan di berbagai industri, seperti makanan, kosmetik, dan biodiesel. Selain itu, kelapa sawit juga memiliki keuntungan yang lebih besar dibandingkan dengan tebu dan karet jika dilihat dari segi biaya produksi. Dengan permintaan yang terus meningkat, Di antara berbagai keuntungan yang diperoleh dari industri ini, salah satu yang paling signifikan adalah kontribusi devisa ekspor Crude Palm Oil (CPO) ke negara-negara ASEAN dan Eropa, yang sangat membutuhkan pasokan CPO dari Indonesia. Hal ini tidak hanya meningkatkan pendapatan nasional, tetapi juga memperkuat posisi Indonesia sebagai salah satu penghasil utama CPO di dunia. Sebagai salah satu produsen minyak sawit terbesar di dunia, Indonesia juga perlu meningkatkan tingkat produksinya. Saat ini, sebagian besar upaya untuk meningkatkan produksi kelapa sawit di Indonesia dilakukan melalui perluasan lahan atau ekstensifikasi, yang bertujuan untuk memaksimalkan potensi produksi tanpa mengorbankan keberlanjutan lingkungan. [1].

Namun, petani kelapa sawit sering kali menghadapi tantangan dalam merencanakan dan mengelola produksi yang efektif. Faktor-faktor seperti perubahan iklim, fluktuasi harga, dan perubahan lingkungan mempersulit perkiraan hasil panen. Akibatnya, petani sering kali mengalami kesulitan dalam mengoptimalkan penggunaan sumber daya manusia, yang menyebabkan biaya produksi tinggi dan hasil panen yang tidak stabil.

Dalam upaya untuk mengatasi tantangan tersebut, peneliti telah mengadopsi pendekatan inovatif dengan menerapkan metode *Deep Learning*. *Deep Learning* mampu menangani permasalahan yang kompleks dan rumit dengan serangkaian transformasi non-linear yang banyak [2]. seperti *Long Short-Term Memory* (LSTM) telah

diterapkan dalam sistem prediksi hasil panen. *Long Short-Term Memory* (LSTM) merupakan sebuah jenis modul dari Jaringan Saraf Rekurens (*Recurrent Neural Network/RNN*) yang berbeda dengan RNN konvensional [3]. LSTM mampu memodelkan hubungan kompleks antara variabel-variabel yang mempengaruhi hasil panen, sehingga menghasilkan perkiraan yang lebih akurat. Prediksi merupakan upaya untuk menebak atau memperkirakan kejadian yang akan datang dengan memanfaatkan informasi relevan yang diperoleh dari data-data sebelumnya (historis) melalui metode ilmiah [4]. Dengan informasi prediksi yang lebih tepat, petani dapat mengoptimalkan penggunaan sumber daya, meningkatkan produktivitas, dan mengurangi dampak lingkungan.

Kemudian, dalam sistem ini memiliki potensi untuk memberikan manfaat yang signifikan bagi petani maupun industri secara keseluruhan. Dengan menggunakan sistem ini, petani dapat mengakses informasi prediksi yang akurat dan terpercaya, yang memungkinkan mereka untuk mengambil tindakan yang tepat guna meningkatkan produktivitas dan efisiensi kebun mereka. Selain itu, hasil akhir sistem ini disajikan dalam bentuk website interaktif menggunakan *Streamlit*, sehingga pengguna dapat dengan mudah memantau dan mengakses data prediksi hasil panen melalui antarmuka yang ramah pengguna dan responsif, yang dapat diakses kapan saja dan di mana saja, hanya dengan menggunakan perangkat yang terhubung ke internet.

Penelitian mengenai prediksi hasil panen sawit telah banyak dilakukan, salah satunya oleh Ananda dkk. dengan judul "Prediksi Jumlah Hasil Panen Sawit Menggunakan Algoritma Naive Bayes." Penelitian ini bertujuan untuk memprediksi jumlah hasil panen sawit dan memberikan rekomendasi kepada pihak PTPN IV Dolok Sinubah. Algoritma Naive Bayes digunakan sebagai metode prediksi, menghasilkan akurasi 100% dengan prediksi peningkatan dan penurunan secara manual. Hasil penelitian ini memberikan wawasan yang berharga bagi industri kelapa sawit dalam meningkatkan efisiensi dan produktivitas pertanian. Namun, penelitian tersebut tidak menggunakan algoritma LSTM, yang diketahui sangat efektif dalam masalah prediksi, terutama dengan data *time series* atau multiatribut. *Long Short-Term Memory* (LSTM) dipilih karena kemampuannya dalam menangani data yang memiliki ketergantungan waktu atau pola berurutan, sehingga dapat memberikan prediksi yang lebih akurat, terutama dalam memproses data yang kompleks dan dinamis seperti hasil panen sawit yang dipengaruhi oleh banyak faktor sepanjang waktu.

TINJAUAN PUSTAKA

Andrianto dan Irawan melakukan penelitian berjudul "Implementasi Metode Regresi Linear Berganda pada Sistem Prediksi Jumlah Tonase Kelapa Sawit di PT. Paluta Inti Sawit," yang berfokus pada penerapan metode regresi linear berganda untuk memprediksi jumlah tonase buah kelapa sawit. Penelitian ini menunjukkan tingkat akurasi prediksi yang sangat tinggi, mencapai 99,99% secara keseluruhan. Meskipun demikian, terdapat tingkat akurasi terendah yang tercatat pada tanggal 3 November 2022 sebesar 88%, sementara akurasi tertinggi mencapai 100% pada tanggal 5 dan 7 November 2022. Temuan dari penelitian ini memiliki implikasi penting bagi para petani kelapa sawit dalam merencanakan strategi pertanian yang lebih efektif [5].

Eki Komariah dkk. melakukan penelitian yang berjudul "Penerapan Jaringan Syaraf Tiruan untuk Memprediksi Hasil Produksi Kelapa Sawit Menggunakan Backpropagation", mereka memanfaatkan data dari PT. Kebun Ganda Prima yang digunakan dalam memprediksi hasil dari produksi kelapa sawit dengan mengimplementasikan algoritma JST backpropagation. Hasil dari penelitian ini menunjukkan tingkat akurasi sebesar 88% dengan tingkat *error Mean Squared Error* (MSE) sebesar 0,11249. Penelitian ini akan memberikan dampak yang signifikan dalam proses pengembangan teknologi prediksi, yang membantu meningkatkan produktivitas pertanian [6].

Adi & Sudianto melakukan penelitian berjudul "Prediksi Harga Komoditas Pangan Menggunakan Algoritma *Long Short-Term Memory* (LSTM)" yang menggunakan teknik *Deep Learning* LSTM dalam memprediksi harga komoditas pangan. Hasilnya menunjukkan bahwa model prediksi dengan menggunakan *epoch* 50 memiliki tingkat *Root Mean Squared Error* (RMSE) yang terendah, yakni 79,19%. Penelitian ini memiliki dampak penting dalam meningkatkan pemahaman tentang aplikasi LSTM dalam memprediksi harga komoditas pangan, yang membantu para pelaku industri dalam pengambilan keputusan yang lebih baik [7].

Aji Santoso dkk. melakukan penelitian berjudul "Prediksi harga beras menggunakan metode *recurrent neural network* dan *long short-term memory*" yang menggunakan data rata-rata harga beras yang dikumpulkan dari Badan Pusat Statistik, meliputi rentang tahun 2013 hingga 2023 dan dilaporkan setiap bulan. Langkah awal penelitian melibatkan pra-pemrosesan data dengan menggunakan teknik KDD untuk menyesuaikan dataset yang akan dipergunakan dalam proses peramalan. Kemudian, metode Data Mining seperti *Recurrent Neural Networks* (RNN) dan *Long Short-Term Memory* diterapkan untuk melakukan peramalan. Hasil penelitian menunjukkan bahwa model RNN memiliki nilai RMSE terendah sebesar 0.73 untuk jenis harga beras menengah, sementara algoritma LSTM memiliki nilai MAE terkecil sebesar 2.31 untuk jenis harga beras dari luar negeri. Dalam penelitian ini akan menambahkan variasi pada masalah peramalan harga beras dengan memperkenalkan metode RNN, sehingga memberikan kontribusi signifikan dalam pemodelan dan prediksi harga beras [9].

Deep Learning


Deep Learning adalah evolusi dari *Machine Learning* dan *Artificial Intelligence* dengan menggabungkan kecerdasan buatan dan pembelajaran dalam. Dalam konteks machine learning, model dirancang untuk mengidentifikasi pola dalam data dan memanfaatkan pola tersebut untuk melakukan prediksi terhadap data yang baru. [15]. *Deep Learning* berfungsi sebagai jaringan syaraf tiruan yang memproses metadata masukan melalui lapisan tersembunyi. Teknik ini mampu mengurangi kebutuhan akan pemrograman secara manual dengan cara mengidentifikasi fitur-fitur yang penting secara otomatis. Dengan demikian, teknik end-to-end seperti *Deep Learning* lebih tepat untuk digunakan karena menerapkan serangkaian operasi perhitungan (tensor math) yang sejalan dengan kemampuan GPU, agar dapat mempersingkat waktu proses komputasi [13]. Setiap lapisan tersembunyi dalam jaringan dilatih untuk mengekstraksi fitur-fitur yang relevan dari keluaran lapisan sebelumnya. Dengan pendekatan ini, *Deep Learning* mampu menangani permasalahan yang kompleks dan rumit dengan serangkaian transformasi *non-linear* yang banyak [2].

Recurrent Neural Network (RNN)

Recurrent Neural Network adalah model jaringan saraf tiruan di mana koneksi antar node membentuk graf berarah sepanjang urutan. Arsitektur ini memungkinkannya untuk menunjukkan perilaku dinamis temporal, dengan menggunakan status internal (memori) untuk memproses urutan input dengan panjang yang bervariasi. RNN sering digunakan dalam bidang seperti pemodelan bahasa, pengenalan suara, dan prediksi deret waktu karena kemampuannya mempertimbangkan data input sebelumnya saat menghasilkan output [9]. Sistem ini dianggap sangat penting karena merupakan satu-satunya sistem dengan memori internal pada saat itu. Selanjutnya, pada tahun 1990-an, sejumlah perubahan dilakukan untuk menyempurnakan RNN, di antaranya adalah *long short-term memory* (LSTM) [14].

Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan sebuah jenis modul dari Jaringan Saraf Rekurens (*Recurrent Neural Network*/RNN) yang berbeda dengan RNN konvensional. Algoritma LSTM ditemukan pada tahun 1997, yang di kemukakan oleh Hochreiter dan Schmidhuber [16]. LSTM akan menyimpan informasi penting pada unit kontrol yang terpisah dari aliran utama RNN. Meskipun strukturnya masih mengikuti pola rantai seperti RNN, akan tetapi ada perbedaan yang terletak pada organisasi modul pengulangannya. Khususnya, LSTM dirancang untuk menangani masalah yang melibatkan ketergantungan jangka panjang, karena mampu secara alami menyimpan informasi jangka panjang. Struktur dasar LSTM melibatkan sebuah blok memori yang terdiri dari tiga gerbang utama: gerbang memori, gerbang penghilangan informasi, dan gerbang keluaran. Selain itu, LSTM juga memiliki unit memori yang mengatur aliran informasi ke tahap berikutnya [3].



Gambar 1. Rangkaian LSTM

Forget gate, input gate, dan output gate adalah tiga komponen utama dalam mekanisme LSTM yang bekerja bersama untuk mengatur aliran informasi di setiap langkah waktu. Forget gate bertanggung jawab untuk memutuskan seberapa banyak informasi dari cell state sebelumnya yang harus dilupakan atau dipertahankan. Informasi ini ditentukan berdasarkan fungsi aktivasi sigmoid, yang menghasilkan nilai antara 0 dan 1, di mana 0 berarti sepenuhnya dilupakan dan 1 berarti sepenuhnya disimpan. Input gate kemudian menentukan seberapa banyak informasi baru dari input saat ini (x_t) yang harus disimpan ke dalam cell state. Seperti forget gate, input gate juga menggunakan fungsi sigmoid untuk mengontrol proporsi informasi baru yang disimpan. Terakhir, output gate menentukan apa yang akan dijadikan output dari cell state saat ini (c_t) dan diubah menjadi hidden state (h_t), yang diteruskan ke langkah berikutnya. Output gate mengombinasikan cell state yang telah diperbarui dengan

fungsi sigmoid dan tanh untuk memastikan hanya informasi penting yang dipertahankan dalam hidden state. Kombinasi dari ketiga gerbang ini memungkinkan LSTM untuk belajar kapan harus menyimpan atau membuang informasi, yang sangat penting dalam memproses data sekuensial jangka panjang. Dibawah ini merupakan cara kerja dari arsitektur LSTM:

Forget Gate

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

Keterangan:

W_f : Bobot matriks

x_t : Data input

h_{t-1} : Output dari blok memori langkah sebelumnya

b_f : Bias pada forget gate

σ : Fungsi sigmoid

Input Gate

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (2)$$

Output Gate

$$o_t = \sigma(W_o \times [h_{t-1}, c_t] + b_o) \quad (3)$$

Seluruh proses transisi dari cell state lama c_{t-1} ke cell state baru yaitu c_t dapat dijelaskan melalui persamaan berikut, di mana fungsi aktivasi yang digunakan adalah tanh:

$$\tilde{c}_t = \tanh(W_c \times [h_{t-1}, c_t] + b_c) \quad (4)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t \quad (5)$$

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

Min-max Normalization

Min-max normalization adalah teknik normalisasi data yang berfungsi untuk mengonversi data asli ke dalam rentang nilai yang baru, dengan tujuan menciptakan keseimbangan antara nilai sebelum dan sesudah proses normalisasi. Metode ini penting untuk memastikan bahwa semua fitur dalam data memiliki skala yang sama, sehingga mencegah dominasi fitur dengan nilai lebih besar terhadap fitur dengan nilai lebih kecil. Proses normalisasi ini membantu meningkatkan kinerja model pembelajaran mesin, terutama ketika data memiliki berbagai rentang nilai yang berbeda [10]. Rumus untuk min-max normalization dapat dilihat pada persamaan berikut:

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (7)$$

Keterangan:

x' = Hasil dari Normalization

x_i = Data ke-i

x_{min} = Nilai minimum data

x_{max} = Nilai maksimum data

Mean Squared Error (MSE)

Mean Squared Error (MSE) merupakan kesalahan kuadrat rata-rata antara nilai asli dan nilai prediksi. Metode MSE biasanya digunakan untuk memeriksa perkiraan nilai kesalahan dalam ramalan. Semakin kecil nilai RMS menunjukakan bahwa hasil prediksi sesuai dengan data aktual sehingga dapat digunakan untuk perhitungan prediksi periode mendatang. Metode Mean Squared Error (MSE) umumnya digunakan untuk menilai akurasi, metode pengukuran yang menggunakan model regresi atau model peramalan dalam analisis. Perhitungan MSE dilakukan dengan cara mengurangkan nilai data asli dari data prediksi dan mengkuadratkan hasil, kemudian menjumlahkan dan membagi hasil selisih kuadrat dengan jumlah data yang ada [11].

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_t - F_t)^2 \quad (8)$$

Keterangan:

A_t = Permintaan aktual ke-t

F_t = Hasil dari peramalan t

n = Ukuran data peramalan

METODE

Data untuk penelitian ini diperoleh melalui dua metode utama, yaitu wawancara dengan petani kelapa sawit dan pencatatan langsung dari kegiatan pertanian. Pertama, data dikumpulkan melalui wawancara dengan petani kelapa sawit di berbagai lokasi. Melalui wawancara ini, data yang relevan seperti informasi tentang penggunaan pupuk, frekuensi penyiraman, pengendalian hama, kondisi tanah, dan faktor-faktor lain yang memengaruhi hasil panen kelapa sawit dapat dikumpulkan. Untuk mengatasi tantangan ini, penelitian ini mengusulkan pengembangan implementasi algoritma *Long Short-Term Memory* (LSTM) pada sistem prediksi hasil panen sawit. LSTM dipilih karena kemampuannya dalam memproses data deret waktu dan mengingat informasi dalam jangka panjang dan pendek. Model data yang digunakan dalam penelitian ini adalah model *time series* adalah sebuah pendekatan yang digunakan untuk menganalisis dan memprediksi data yang terurut dalam suatu rangkaian waktu tertentu [12], dengan rentang waktu dari tahun 2023 hingga 2024.

HASIL DAN PEMBAHASAN

Dalam pembuatan model, penulis mengevaluasi kinerja aplikasi sistem prediksi hasil panen kelapa sawit menggunakan algoritma *Long Short-Term Memory* (LSTM) dalam berbagai kondisi parameter, berikut tabel eksperimen penulis pada tabel 1.

Tabel 1. Tabel eksperimen


activation	optimizer	drop out	learning rate	epochs	batch_size	loss	val_loss
relu	Adam	0.2	0,0001	150	32	6.8734	4.5228
tanh	RMSprop	0.3	0,0001	150	32	5.7854	4.3994
tanh	RMSprop	0.3	0,005	250	32	5.5256	4.4160
tanh	RMSprop	tidak ada dropout	0,0001	300	64	11.3797	10.7531
-	Nadam	0.2	0,0005	300	32	5.6268	4.5632
tanh,linear	RMSprop	0.3	0,0001	150	32	5.3968	4.5722

Tabel eksperimen menunjukkan kinerja model LSTM dengan berbagai kombinasi parameter untuk memprediksi hasil panen sawit. Pada eksperimen pertama, dengan menggunakan aktivasi *Relu*, *optimizer Adam*, *dropout* sebesar 0,2, dan *learning rate* 0,0001, model menunjukkan *loss* sebesar 6.8734 dan *val_loss* 4.5228. Model ini dilakukan uji coba selama 150 *epoch* dengan *batch size* 32. Berdasarkan hasil ini, penggunaan Adam dengan kombinasi parameter yang dipilih memberikan hasil yang relatif stabil, meskipun *val_loss* masih bisa ditingkatkan lebih lanjut.


Selanjutnya, penggunaan aktivasi tanh dengan *optimizer RMSprop* menunjukkan hasil yang lebih baik dalam beberapa eksperimen. Pada eksperimen kedua, dengan *learning rate* yang sama dan *dropout* 0,3, *loss* mencapai 5.7854 dan *val_loss* turun ke 4.3994, menunjukkan bahwa tanh lebih efektif dibandingkan *Relu* pada prediksi ini. Selain itu, peningkatan jumlah *epoch* dari 150 menjadi 250 pada eksperimen ketiga lebih menekan *loss* hingga 5.5256, meskipun *val_loss* tidak mengalami perubahan signifikan (4.4160). Ini menunjukkan bahwa menambah *epoch* dapat meningkatkan kemampuan model, tetapi ada batas pada peningkatan kinerja.

Pada eksperimen terakhir, penggunaan kombinasi aktivasi *tanh* dan linear dengan *optimizer RMSprop* dan *dropout* 0,3 menghasilkan *loss* 5.3968 dan *val_loss* 4.5722. Ini mengindikasikan bahwa penggabungan aktivasi dan konfigurasi *dropout* memberikan hasil yang lebih stabil. Namun, pada eksperimen tanpa *dropout*, *loss* dan *val_loss* meningkat secara signifikan (11.3797 dan 10.7531), menunjukkan bahwa regularisasi melalui *dropout* sangat penting dalam mencegah *overfitting* pada model LSTM untuk tugas ini.

Hasil dari beberapa eksperimen yang telah dilakukan, telah didapatkan hasil model terbaik dengan MSE terendah, yaitu 5.3968 dengan parameter yang digunakan, yaitu *hidden* unit sebanyak 128, dan jumlah *epoch* 150. Untuk gambar *layer* pada model yang digunakan dapat dilihat pada gambar 3. serta terdapat grafik presentasi MSE *loss* dan validasi *loss* yang dapat dilihat pada gambar 4 yang tidak terjadinya *overfitting* dan *underfitting*.



Gambar 3. Layer model



Gambar 4. Grafik presentasi loss dan validasi loss

Pengujian

Tabel 2. Tabel pengujian

Tanggal Panen	Hasil panen	Prediksi
2023-01-28	7.0	7.1500998
2023-01-10	1.5	1.6289786
2023-03-05	7.8	7.9690704
2023-01-29	1.6	1.281618
2023-05-29	4.5	4.330477
2023-08-23	7.5	7.1284018
2023-07-21	6.7	6.620211
2023-09-07	1.1	1.2511736
2023-11-17	9.1	9.0065155

Tabel tersebut menunjukkan hasil pengujian sistem prediksi dibandingkan dengan nilai sebenarnya dalam konteks tertentu. Terdapat dua bagian dari data yang diujikan, masing-masing memuat nilai prediksi dan nilai aktual. Pada bagian pertama, prediksi untuk beberapa data, seperti nilai 7.1500998 dibandingkan dengan nilai sebenarnya 7.0, dan prediksi 1.6289786 dibandingkan dengan nilai 1.5, menunjukkan bahwa prediksi cukup mendekati nilai sebenarnya. Hal serupa terlihat pada bagian kedua, di mana prediksi seperti 7.1284018 dibandingkan dengan nilai aktual 7.5, serta prediksi 9.0065155 mendekati nilai sebenarnya 9.1. Secara keseluruhan, hasil prediksi dari model yang digunakan menunjukkan akurasi yang cukup baik, dengan kesalahan yang kecil di antara nilai prediksi dan nilai sebenarnya. Hasil ini mengindikasikan bahwa sistem mampu menghasilkan prediksi yang cukup akurat untuk kasus yang diujikan.

KESIMPULAN DAN SARAN

Berdasarkan hasil dari berbagai rancangan dan pengujian algoritma LSTM pada penelitian “Implementasi Algoritma *Long Short-Term Memory* (LSTM) Pada Sistem Prediksi Hasil Panen Sawit”, dapat disimpulkan bahwa penelitian ini telah membahas dan mengimplementasikan algoritma Long Short-Term Memory (LSTM) yang digunakan untuk memprediksi hasil panen sawit. Algoritma LSTM digunakan karena kemampuannya yang unggul dalam menangani data deret waktu maupun multi atribut, serta mempertahankan informasi penting dalam jangka waktu yang panjang. Implementasi algoritma ini melalui serangkaian proses, dimulai dari pengumpulan data, pemrosesan data, pelatihan model, pembuatan model, hingga validasi menggunakan data uji. Pengukuran tingkat kesalahan prediksi dilakukan dengan menggunakan *Mean Squared Error* (MSE).

Hasil penelitian ini menunjukkan bahwa algoritma LSTM yang dikembangkan mampu menghasilkan prediksi hasil panen sawit dengan tingkat kesalahan yang rendah. Evaluasi kinerja model menggunakan MSE menunjukkan kesalahan yang minimal, dengan pembagian data *training* dan *testing* sebesar 80%:20%, menggunakan sequence data sebanyak 640. Parameter model menggunakan 128 *hidden unit*, dengan jumlah *epoch* 150, menghasilkan nilai MSE *loss* sebesar 5.3968. Selain itu, aplikasi berbasis *Streamlit* yang dikembangkan memungkinkan pengguna untuk melakukan perencanaan dan pengelolaan kebun dengan lebih efisien, meningkatkan efektivitas penggunaan sumber daya, dan memaksimalkan hasil panen.

Penelitian ini masih memiliki beberapa keterbatasan. Untuk penelitian selanjutnya, perlu dipertimbangkan penambahan faktor lain dalam prediksi hasil panen, seperti kondisi cuaca, jenis pupuk yang digunakan, dan teknik pemeliharaan, selain dari data historis sebelumnya. Selain itu, dalam penentuan nilai bobot, bias, dan *weight*, penelitian ini menggunakan eksperimen parameter yang memungkinkan variasi dalam hasil. Penelitian lebih lanjut disarankan untuk menggunakan teknik optimasi yang lebih canggih agar nilai bobot dan bias yang dihasilkan lebih stabil dan konsisten.

DAFTAR PUSTAKA

- [1] M. Syarovy, A. P. Nugroho, and L. Sutiarso, “PEMANFAATAN MODEL NEURAL NETWORK DALAM GENERASI BARU PERTANIAN PRESISI DI PERKEBUNAN KELAPA SAWIT,” *WARTA Pusat Penelitian Kelapa Sawit*, vol. 28, no. 1, pp. 39–54, Feb. 2023, doi: 10.22302/iopri.war.warta.v28i1.97.
- [2] A. Helsaputra, A. L. Prasasti, and R. R. Septiawan, “Implementasi deep learning untuk prediksi tingkat kematangan dan bobot buah pepaya,” *Dec.*, vol. 01, no. 01, p. 1, Dec. 2021, <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/16971>.
- [3] T. A. F. Muhammad and M. I. Irawan, “Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang),” *Jurnal Sains Dan Seni ITS*, vol. 12, no. 1, May 2023, doi: 10.12962/j23373520.v12i1.106892.

- [4] F. Fadilah, M. Melina, and A. Komarudin, "PREDIKSI PENJUALAN OBAT MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK," *Jurnal Informatika Teknologi Dan Sains (Jinteks)*, vol. 6, no. 3, pp. 521–531, Aug. 2024, doi: 10.51401/jinteks.v6i3.4346.
- [5] R. Andrianto and F. Irawan, "Implementasi Metode Regresi Linear Berganda Pada Sistem Prediksi Jumlah Tonase Kelapa Sawit di PT. Paluta Inti Sawit," *jptam.org*, Mar. 2023, doi: 10.31004/jptam.v7i1.5658.
- [6] E. Komariah, B. C. Octariadi, and A. C. Siregar, "Penerapan Jaringan Syaraf Tiruan untuk Memprediksi Hasil Produksi Kelapa Sawit Menggunakan Backpropagation," *Komariah | Jutisi : Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, Aug. 2023, doi: 10.35889/jutisi.v12i2.1342.
- [7] R. M. S. Adi and S. Sudianto, "Prediksi harga komoditas pangan menggunakan algoritma Long Short-Term Memory (LSTM)," *Building of Informatics Technology and Science (BITS)*, vol. 4, no. 2, Sep. 2022, doi: 10.47065/bits.v4i2.2229.
- [8] W. Ananda, M. Safii, and M. Fauzan, "Prediksi jumlah hasil panen sawit menggunakan algoritma Naive Bayes," Mar. 30, 2021. <https://ejournal.seminar-id.com/index.php/tin/article/view/698>
- [9] A. Santoso, A. I. Purnamasari, and N. I. Ali, "PREDIKSI HARGA BERAS MENGGUNAKAN METODE RECURRENT NEURAL NETWORK DAN LONG SHORT-TERM MEMORY," *PROSISKO Jurnal Pengembangan Riset Dan Observasi Sistem Komputer*, vol. 11, no. 1, pp. 128–136, Mar. 2024, doi: 10.30656/prosisko.v11i1.7921.
- [10] I. M. Shofi and S. U. Masrurroh, "Analisis perbandingan cosine normalization dan min-max normalization pada pengelompokan terjemahan ayat Al Quran menggunakan algoritma k-means clustering," Nov. 19, 2019. <https://repository.uinjkt.ac.id/dspace/handle/123456789/48588>
- [11] M. David, I. Cholissodin, and N. Yudistira, "Prediksi Harga Cabai menggunakan Metode Long-Short Term Memory (Case Study : Kota Malang)," Mar. 10, 2023. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/12406>
- [12] A. M. Hadi, W. Witanti, and M. Melina, "PREDIKSI PERGERAKAN HARGA EMAS MENGGUNAKAN METODE GENETIC SUPPORT VECTOR REGRESSION," *Jurnal Informatika Teknologi Dan Sains (Jinteks)*, vol. 6, no. 3, pp. 486–496, Aug. 2024, doi: 10.51401/jinteks.v6i3.4247.
- [13] S. Rahmadani, N. C. S. Rahayu, N. A. Salim, and N. K. N. Cahyo, "DETEKSI EMOSI BERDASARKAN WICARA MENGGUNAKAN DEEP LEARNING MODEL," *Jurnal Informatika Teknologi Dan Sains (Jinteks)*, vol. 4, no. 3, pp. 220–224, Aug. 2022, doi: 10.51401/jinteks.v4i3.1952.
- [14] D. E. B. Jabat, L. Y. Sipayung, and K. R. S. Dakhi, "PENERAPAN ALGORITMA RECURRENT NEURAL NETWORKS (RNN) UNTUK KLASIFIKASI ULOS BATAK TOBA," Jun. 19, 2024. <https://ejournal.ust.ac.id/index.php/SNISTIK/article/view/3697>
- [15] W. A. Nascier, S. Sarwido, and B. B. Wahono, "GRADIENT BOOSTING OPTIMIZATION WITH PRUNING TECHNIQUE FOR PREDICTION OF BMT AL-HIKMAH PERMATA CUSTOMER DATA," *jurnal.uts.ac.id*, Aug. 2024, doi: 10.51401/jinteks.v6i3.4702.
- [16] R. A. 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.