

Prediksi Padi Menggunakan Algoritma Long Short Term Memory

Putri Cheria Adhany*, Cindi Wulandari, Bunga Intan, Budi Santoso

¹ Ilmu Teknik, Informatika, Universitas Bina Insan, Lubuklinggau, Indonesia

Email: ^{1,*}putricheria03@gmail.com, ²cindi_wulandari@univbinainsan.ac.id, ³bungaintan@univbinainsan.ac.id,

⁴budisantoso@univbinainsan.ac.id

Email Penulis Korespondensi: putricheria03@gmail.com

Abstrak—Padi merupakan salah satu komoditas pertanian utama di Indonesia, termasuk di Kota Lubuklinggau, yang menjadi daerah penghasil padi di Provinsi Sumatera Selatan. Namun, produksi padi setiap bulannya mengalami fluktuasi akibat berbagai faktor seperti musim tanam, alih fungsi lahan, cuaca, dan serangan hama. Ketidakstabilan ini dapat mempengaruhi ketersediaan pangan dan kesejahteraan petani. Oleh karena itu, peramalan produksi padi menjadi penting dalam mendukung pengambilan keputusan yang lebih baik di sektor pertanian. Penelitian ini menggunakan data produksi padi bulanan dari Januari 2019 hingga November 2024 yang diperoleh dari Dinas Pertanian Kota Lubuklinggau. Metode yang digunakan adalah Long Short-Term Memory (LSTM), yang merupakan salah satu teknik jaringan saraf tiruan berbasis data time series. Parameter optimal yang digunakan dalam model adalah jumlah neuron pada hidden layer sebesar 35, batch size sebesar 12, dan maksimal epoch sebanyak 50. Hasil penelitian menunjukkan bahwa model dengan parameter optimal menghasilkan nilai Mean Absolute Percentage Error (MAPE) sebesar 4.44%, yang termasuk dalam kategori sangat baik. Hasil ini menunjukkan bahwa metode LSTM dapat digunakan secara efektif untuk memprediksi produksi padi di Kota Lubuklinggau dengan tingkat akurasi yang tinggi.

Kata Kunci: Prediksi; Padi; Mean Absolute Percentage Error; Long Short Term Memory; Time Series

Abstract—Rice is one of the main agricultural commodities in Indonesia, including in Lubuklinggau City, which is a rice-producing area in South Sumatra Province. However, rice production fluctuates every month due to various factors such as planting seasons, land conversion, weather, and pest attacks. This instability can affect food availability and farmer welfare. Therefore, rice production forecasting is important in supporting better decision-making in the agricultural sector. This study uses monthly rice production data from January 2019 to November 2024 obtained from the Lubuklinggau City Agriculture Service. The method used is Long Short-Term Memory (LSTM), which is one of the artificial neural network techniques based on time series data. The optimal parameters used in the model are the number of neurons in the hidden layer of 35, a batch size of 12, and a maximum of 50 epochs. The results showed that the model with optimal parameters produced a Mean Absolute Percentage Error (MAPE) value of 4.44%, which is included in the very good category. These results indicate that the LSTM method can be used effectively to predict rice production in Lubuklinggau City with a high level of accuracy.

Keywords: Forecasting; Rice; Long Short Term Memory; Mean Absolute Percentage Error; Time Series

1. PENDAHULUAN

Indonesia merupakan negara agraris yang memiliki kekayaan sumber daya alam yang melimpah dan menghasilkan berbagai komoditas pertanian. Pertanian menjadi salah satu sektor yang memegang peranan penting dalam perekonomian nasional. Hal ini terlihat dari besarnya jumlah masyarakat yang bergantung pada sektor ini sebagai mata pencaharian utama mereka, baik sebagai petani, buruh tani, maupun pelaku usaha pertanian lainnya[1]. Kontribusi sektor pertanian terhadap pembangunan nasional juga tidak dapat dipandang sebelah mata karena menyangkut ketersediaan bahan pangan yang menjadi kebutuhan dasar penduduk [2].

Di antara berbagai komoditas pertanian, padi menempati posisi yang sangat strategis. Padi merupakan tanaman pangan utama yang menghasilkan beras, makanan pokok mayoritas masyarakat Indonesia[3]. Oleh karena itu, keberlangsungan produksi padi sangat penting guna menjamin ketahanan pangan nasional. Beras sebagai hasil utama dari padi tidak hanya menjadi sumber utama karbohidrat bagi masyarakat, tetapi juga menjadi komoditas strategis yang berpengaruh terhadap stabilitas sosial dan ekonomi [4].

Namun demikian, dalam beberapa tahun terakhir, produksi padi di Indonesia mengalami tantangan serius. Seiring dengan pertumbuhan jumlah penduduk, produksi padi justru menunjukkan tren penurunan akibat berbagai faktor seperti perubahan iklim, alih fungsi lahan, kurangnya penerapan teknologi pertanian modern, serta gangguan hama dan penyakit tanaman. Penurunan luas lahan panen dan produksi padi secara nasional dari tahun 2010 hingga 2021 menjadi bukti nyata perlunya penanganan strategis dan menyeluruh.

Permasalahan ini tidak hanya terjadi di tingkat nasional, tetapi juga tercermin di daerah-daerah, salah satunya Kota Lubuklinggau di Provinsi Sumatera Selatan. Kota ini merupakan salah satu daerah penghasil padi di wilayah tersebut. Namun, data dari Badan Pusat Statistik (BPS) menunjukkan adanya fluktuasi yang cukup signifikan dalam produksi padi dari tahun ke tahun. Sebagai contoh, pada tahun 2017, produksi padi tercatat sebesar 10.235 ton, tetapi menurun drastis menjadi 6.483 ton pada tahun 2018, sebelum kembali meningkat menjadi 9.001,03 ton di tahun 2019. Pola fluktuatif ini menandakan bahwa sektor pertanian padi di Lubuklinggau masih menghadapi berbagai kendala yang menyebabkan hasil panen belum stabil.

Ketidakstabilan produksi ini tentu berdampak pada ketersediaan beras di masyarakat. Saat produksi berlimpah melebihi konsumsi, diperlukan pengelolaan hasil panen yang tepat agar tidak terjadi pemborosan dan kerugian petani. Sebaliknya, ketika produksi menurun hingga tidak mencukupi kebutuhan konsumsi, hal ini dapat menyebabkan kelangkaan beras yang berdampak pada lonjakan harga dan keresahan masyarakat. Oleh karena itu, pengelolaan produksi yang seimbang menjadi hal yang krusial.

Untuk mengatasi ketidakseimbangan antara pasokan dan permintaan tersebut, diperlukan suatu strategi prediktif yang akurat. Salah satu solusi yang dapat diterapkan adalah penggunaan teknologi prediksi atau peramalan hasil produksi padi. Dengan melakukan peramalan yang tepat, pemerintah daerah dan stakeholder terkait dapat merencanakan kebijakan pangan dengan lebih matang, termasuk pengaturan distribusi, penyimpanan cadangan, dan stabilisasi harga [4].

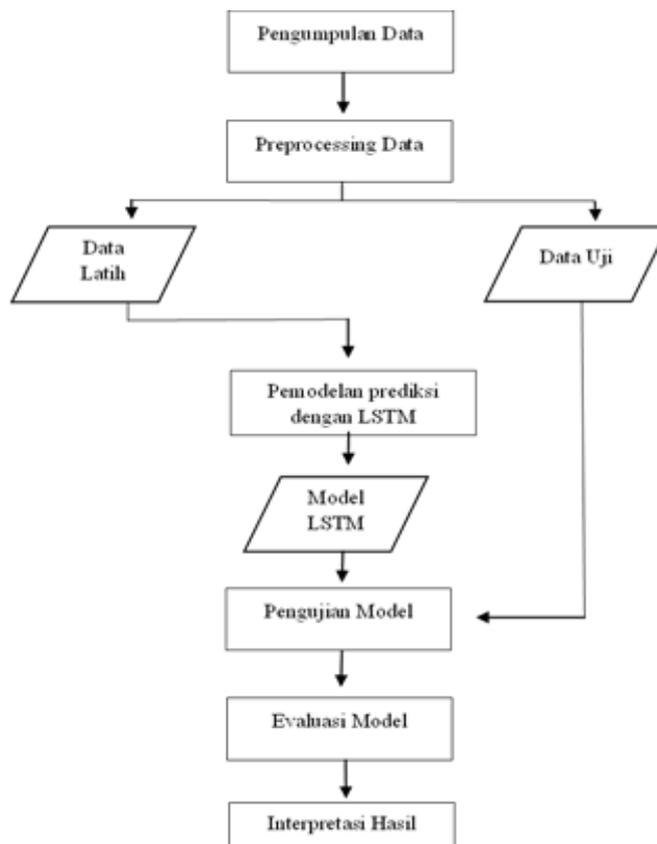
Seiring dengan perkembangan teknologi informasi, pendekatan prediksi di sektor pertanian kini dapat dilakukan lebih canggih melalui penerapan *machine learning*. *Machine learning* memungkinkan pemrosesan data dalam jumlah besar dengan hasil yang lebih akurat, termasuk dalam peramalan data deret waktu (time series) seperti produksi pertanian. Salah satu metode *machine learning* yang terbukti efektif dalam melakukan peramalan data deret waktu adalah Long Short Term Memory (LSTM), yang merupakan pengembangan dari algoritma Recurrent Neural Network (RNN). LSTM memiliki keunggulan dalam mengatasi kelemahan RNN, terutama dalam hal mengingat informasi jangka panjang dan menghindari masalah *vanishing gradient* [5].

Penggunaan LSTM dalam berbagai studi telah menunjukkan hasil yang menjanjikan. Sebagai contoh, LSTM telah berhasil digunakan dalam prediksi harga bitcoin [6], suhu cuaca di Norwegia [7], harga produsen pertanian karet [7], produksi kelapa sawit [5], hingga penjualan produk di sektor retail [8]. Dalam berbagai studi tersebut, LSTM mampu menghasilkan model prediksi dengan tingkat akurasi tinggi dan nilai error yang rendah. Hal ini menunjukkan bahwa LSTM merupakan metode yang sangat potensial untuk diterapkan dalam kasus prediksi produksi padi.

Berdasarkan kondisi produksi padi yang fluktuatif di Kota Lubuklinggau serta pentingnya menjaga ketersediaan beras, maka diperlukan penerapan teknologi prediksi yang akurat untuk membantu perencanaan dan pengambilan keputusan yang lebih baik di bidang pertanian. Berdasarkan uraian tersebut, penelitian ini bertujuan untuk merancang sistem prediksi produksi padi di Kota Lubuklinggau menggunakan algoritma Long Short Term Memory (LSTM), yang mampu memberikan estimasi ketersediaan padi secara lebih akurat berdasarkan data historis produksi. Dengan mengadopsi teknologi ini, diharapkan dapat mendukung pengambilan keputusan yang lebih baik dalam pengelolaan hasil pertanian, menjaga ketahanan pangan daerah, serta meningkatkan kesejahteraan petani melalui perencanaan distribusi dan cadangan pangan yang lebih optimal.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode prediktif. Pendekatan ini dipilih karena tujuan dari penelitian adalah untuk memprediksi produksi padi di Kota Lubuklinggau menggunakan algoritma *Long Short Term Memory* (LSTM). Dataset yang digunakan dalam penelitian ini adalah data historis periode januari tahun 2019 hingga november tahun 2024 meliputi luas panen, tanam, dan produksi padi digunakan sebagai input dalam model. Gambar 1 merupakan langkah-langkah penelitian meliputi:



Gambar 1. Alur Penelitian

2.1 Pengumpulan data

Mengumpulkan data historis yang mencakup luas tanam, luas panen, dan produksi padi selama periode Januari 2019 hingga November 2024. Data diperoleh dari Dinas Pertanian Kota Lubuklinggau.

2.2 Preprocessing data

Tahapan pre-processing adalah serangkaian langkah yang dilakukan untuk mempersiapkan data sebelum diolah atau dianalisis lebih lanjut. Tujuan utama dari pre-processing adalah meningkatkan kualitas data, menghilangkan noise, serta membuat data lebih siap dan sesuai untuk digunakan dalam model atau analisis tertentu. Proses ini sangat penting dalam pengembangan model dan analisis data karena berpengaruh signifikan terhadap kualitas hasil akhir[9]. Langkah-langkahnya meliputi:

2.2.1 Seleksi data

Proses untuk memilih data dari database yang sesuai dengan tujuan analisis [10].

2.2.2 Pembentukan data time series

Pembentukan data time series dilakukan menggunakan data luas panen, tanam, dan produksi padi di Kota Lubuklinggau selama periode Januari 2019 hingga November 2024. Data ini digunakan sebagai variabel input, yang terdiri dari data historis 12 bulan sebelumnya, sedangkan targetnya adalah nilai produksi padi untuk bulan selanjutnya. Sebagai contoh, untuk memprediksi stok padi pada bulan Januari 2023, variabel input yang digunakan adalah data luas panen, tanam, dan produksi padi dari bulan Januari hingga Desember 2022.

2.2.3 Cleaning data

Proses membersihkan data dari data noise dan tidak konsisten[11].

2.2.4 Normalisasi data

Normalisasi berfungsi untuk menghindari terjadinya berbagai anomali data dan tidak konsistensinya data. Normalisasi ini juga bertujuan untuk merubah ukuran data menjadi lebih kecil tanpa harus merubah data asli. Teknik normalisasi yang digunakan adalah Min-Max Normalization. Min-Max Normalization merupakan proses pengolahan data secara linear menjadi nilai baru lainnya[12]. Berikut ini merupakan rumus Min-Max Normalization:

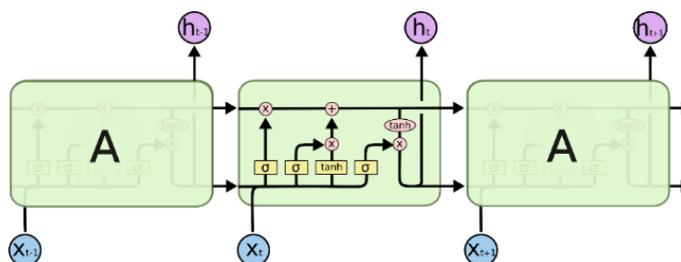
$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

2.2.5 Pembagian dataset

Dataset pada penelitian ini dialokasikan kedalam data pelatihan sebanyak 70% dan data pengujian sebanyak 30%.

2.3 Pemodelan dan validasi

Penelitian ini menggunakan arsitektur model *Long Short Term Memory* (LSTM) yang merupakan salah satu jenis arsitektur jaringan syaraf tiruan yang merupakan pengembangan dari metode *Recurrent Neural Network* (RNN) [13]. *Recurrent Neural Network* (RNN) adalah jaringan saraf yang dirancang khusus untuk menangani data berurutan (sequence data) [14]. Namun, RNN menghadapi masalah vanishing dan exploding gradient yang terjadi ketika perubahan nilai pada satu lapisan memengaruhi lapisan berikutnya[15]. Dalam struktur RNN, lapisan tersembunyi terdiri dari sel memori yang memiliki tiga gerbang, yaitu *input gate*, *forget gate*, dan *output gate* [16]. Gerbang input berfungsi untuk memungkinkan masuknya informasi ke dalam sel memori, sementara gerbang lupa secara selektif menghapus informasi yang dianggap tidak relevan dari sel memori dan menyimpannya untuk proses selanjutnya. Terakhir, gerbang output mengatur informasi apa saja yang akan dikeluarkan oleh sel memori [17]. Gambaran umum arsitektur long short term memory dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur Long Short Term Memory

Berikut persamaan dari algoritma LSTM

$$f_t = \sigma(W_t \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (4)$$

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$

Model LSTM yang telah dibangun kemudian dilatih menggunakan data latih. Proses pelatihan ini melibatkan pemberian data urutan waktu ke dalam model dan melakukan penyesuaian bobot melalui serangkaian iterasi atau *epochs* agar model dapat mengenali pola yang terdapat dalam data. Setelah pelatihan selesai, dilakukan validasi terhadap model dengan menggunakan data test. Hasil prediksi dari model kemudian dibandingkan dengan data aktual untuk menilai sejauh mana akurasi model dalam melakukan prediksi stok padi.

2.4 Evaluasi

Evaluasi terhadap hasil prediksi dilakukan menggunakan metrik evaluasi kuantitatif, yaitu *Mean Absolute Percentage Error (MAPE)*. *Mean Absolute Percentage Error (MAPE)* adalah metode yang digunakan untuk mengukur rata-rata perbedaan absolut antara nilai peramalan dan nilai aktual, yang kemudian dinyatakan sebagai persentase[18]. Keunggulan MAPE dibandingkan metode evaluasi akurasi lainnya adalah kemampuannya dalam menghitung tingkat kesalahan relatif yang lebih konsisten dalam mengukur perbedaan antara hasil peramalan dan nilai data aktual (data sesungguhnya)[19]. MAPE menjadi salah satu metrik yang sering digunakan karena memberikan interpretasi yang sederhana dan dapat menunjukkan seberapa akurat suatu model dalam konteks persentase kesalahan relatif terhadap nilai aktual. Semakin kecil nilai MAPE, semakin baik performa model yang digunakan. Perhitungan MAPE menggunakan persamaan [20]. Namun demikian, kelemahan dari MAPE adalah bahwa metrik ini bersifat ukuran kesalahan relatif, yang dapat menjadi tidak stabil ketika nilai aktual mendekati nol [21]. Dalam kasus tersebut, MAPE bisa menghasilkan nilai yang sangat besar atau bahkan tidak terdefinisi, sehingga kurang cocok untuk data dengan nilai aktual yang kecil atau memiliki banyak nilai nol.

Rumus yang digunakan untuk perhitungan MAPE dapat dilihat pada persamaan berikut:

$$MAPE = \frac{\sum \frac{|y-y'|}{y} \times 100\%}{n} \quad (7)$$

Interpretasi nilai MAPE dapat dilihat dari interval lainnya seperti pada Tabel 1.

Tabel 1. Nilai MAPE

Nilai MAPE	Interpretasi
≤ 10%	Sangat Baik
10% - 20%	Baik
20% - 50%	Cukup
> 50%	Buruk

3. HASIL DAN PEMBAHASAN

Eksperimen yang dilakukan dalam penelitian ini didasarkan pada komposisi data training selama 50 bulan dan data testing sebanyak 21 bulan dari total 71 dataset. Skenario pengujian dilakukan untuk memprediksi produksi padi untuk satu bulan ke depan dengan menggunakan metode *Long Short Term Memory (LSTM)*. Dalam penelitian ini, variabel X terdiri dari data luas tanam, luas panen, dan produksi padi selama 12 bulan sebelumnya, sedangkan variabel y adalah nilai produksi padi pada bulan selanjutnya. Hasil dapat dilihat pada Gambar 3.

```
#Memilih Fitur input dan output
input_features = ["Panen (ha)", "Tanam", "produksi (Ton/Ha)"]
output_features = ["produksi (Ton/Ha)"]

X = data[input_features].values #Mengonversi data menjadi array numpy
y = data[output_features].values
```

Gambar 3. Pembentukan variabel X dan y

Data yang digunakan kemudian dinormalisasi menggunakan metode min-max normalization untuk menghindari dominasi fitur dengan nilai besar, sehingga seluruh fitur berada dalam skala yang seimbang dan mendukung proses

pelatihan model secara optimal. Hasil dari proses normalisasi ini digunakan sebagai input dalam pelatihan model LSTM. Hasil normalisasi data menggunakan *min-max normalization* dapat dilihat pada Gambar 3 dan Gambar 4.

Data X setelah normalisasi:

[0.63204748	0.52748414	0.63588982]	[0.22551929	0.30021142	0.20179054]
[0.3214639	0.47463002	0.3285495]	[0.23442136	0.26109937	0.2097998]
[0.45994065	0.53276956	0.46558022]	[0.22947577	0.26004228	0.20535021]
[0.38278932	0.34989429	0.38923453]	[0.24332344	0.25052854	0.21780907]
[1.	1.	1.]	[0.21958457	0.28646934	0.19645102]
[0.21760633	0.4217759	0.22577647]	[0.1909001	0.22410148	0.17064339]
[0.43521266	0.4217759	0.44111044]	[0.18793274	0.2410148	0.16797363]
[0.33234421	0.31395349	0.3393162]	[0.1810089	0.23361522	0.1617442]
[0.45499505	0.30021142	0.46068626]	[0.1810089	0.21458774	0.1617442]
[0.27002967	0.42917548	0.27765238]	[0.19386746	0.21987315	0.17331314]
[0.18694362	0.25792812	0.19543395]	[0.20573689	0.19767442	0.18399216]
[0.34718101	0.397463	0.35399806]	[0.22749753	0.28541226	0.20664672]
[0.35113749	0.4397463	0.310417]	[0.23837784	0.28541226	0.21652982]
[0.29475767	0.54545455	0.26020796]	[0.23343225	0.2832981	0.2120375]
[0.3214639	0.53488372	0.28399119]	[0.22650841	0.27167019	0.20574826]
[0.36102868	0.41437632	0.31922561]	[0.21562809	0.25052854	0.19586515]
[0.42532146	0.52748414	0.37648154]	[0.20969337	0.26215645	0.19047437]
[0.51434224	0.52959831	0.45575898]	[0.21167161	0.26004228	0.1922713]
[0.38575668	0.3435518	0.34124712]	[0.20672601	0.24630021	0.18777898]
[0.36399604	0.40169133	0.32186819]	[0.	0.	0.]
[0.34718101	0.40803383	0.30689356]	[0.0504451	0.07188161	0.04582166]
[0.33926805	0.4217759	0.29984668]	[0.03758655	0.08245243	0.03414163]
[0.35410485	0.31712474	0.31305959]	[0.06330366	0.10042283	0.0575017]
[0.33333333	0.36469345	0.29456152]	[0.06132542	0.0845666	0.05770644]
[0.47972305	0.35940803	0.43964405]	[0.13748764	0.14376321	0.12525429]
[0.22947577	0.33932347	0.21073279]	[0.11177052	0.17653277	0.10185868]
[0.21958457	0.27906977	0.20168491]	[0.12462908	0.18393235	0.11355648]
[0.21661721	0.25792812	0.19897055]	[0.13649852	0.21564482	0.12435446]
[0.19287834	0.23044397	0.17725565]	[0.12759644	0.21987315	0.11625598]
[0.19980218	0.22938689	0.18358916]	[0.140455	0.19450317	0.12795378]
[0.19683482	0.2346723	0.1808748]	[0.15034619	0.19450317	0.1369521]
[0.21562809	0.17019027	0.19806576]	[0.14638971	0.1807611	0.13335277]
[0.16419387	0.28118393	0.15101681]	[0.10979228	0.18710359	0.10005901]
[0.20178042	0.18604651	0.18539874]	[0.15232443	0.22938689	0.13875176]
[0.19485658	0.15750529	0.17906522]			
[0.23145401	0.33932347	0.21254237]			
[0.24826904	0.2769556	0.22225866]			

Gambar 4. Data X setelah di normalisasi

Data y setelah normalisasi:

[0.63588982]	[0.20179054]
[0.3285495]	[0.2097998]
[0.46558022]	[0.20535021]
[0.38923453]	[0.21780907]
[1.]	[0.19645102]
[0.22577647]	[0.17064339]
[0.44111044]	[0.16797363]
[0.3393162]	[0.1617442]
[0.46068626]	[0.1617442]
[0.27765238]	[0.1617442]
[0.19543395]	[0.17331314]
[0.35399806]	[0.18399216]
[0.310417]	[0.20664672]
[0.26020796]	[0.21652982]
[0.28399119]	[0.2120375]
[0.31922561]	[0.20574826]
[0.37648154]	[0.19586515]
[0.45575898]	[0.19047437]
[0.34124712]	[0.1922713]
[0.32186819]	[0.18777898]
[0.30689356]	[0.]
[0.29984668]	[0.04582166]
[0.31305959]	[0.03414163]
[0.29456152]	[0.0575017]
[0.43964405]	[0.05770644]
[0.21073279]	[0.12525429]
[0.20168491]	[0.10185868]
[0.19897055]	[0.11355648]
[0.17725565]	[0.12435446]
[0.18358916]	[0.11625598]
[0.1808748]	[0.12795378]
[0.19806576]	[0.1369521]
[0.15101681]	[0.13335277]
[0.18539874]	[0.10005901]
[0.17906522]	[0.13875176]
[0.21254237]	

Gambar 5. Data y setelah di normalisasi

Model diuji dengan berbagai kombinasi parameter termasuk jumlah *neuron*, *batch size* dan *max epoch* untuk mendapatkan kinerja terbaik. Pengujian ini bertujuan untuk mengevaluasi dampak parameter terhadap kinerja model yang diukur menggunakan metrik *Mean Absolute Percentage Error* (MAPE). Parameter *neuron hidden* yang digunakan dalam penelitian ini yakni sebesar 20, 25, 30, 35, 40, 45 dan 50. Kombinasi parameter *neuron hidden* juga didapatkan melalui beberapa percobaan. Perpaduan parameter neuron hidden dapat dilihat pada Tabel 2.

Tabel 2. Perpaduan parameter neuron hidden

Neuron	Batch Size	Max Epoch	MAPE
20	12	50	8.71%
25	12	50	12.80%
30	12	50	4.70%
35	12	50	4.44%
40	12	50	11.51%
45	12	50	4.47%
50	12	50	7.87%

Jumlah *neuron hidden* berperan dalam memproses data input yang kemudian terhubung dengan *neuron output*, yang memengaruhi hasil yang dihasilkan oleh jaringan LSTM. Berdasarkan tabel hasil pengujian di atas, *neuron hidden* dengan nilai 35 memberikan hasil terbaik dengan nilai MAPE sebesar 4.44%. Hal ini menunjukkan bahwa jumlah *neuron hidden* yang lebih besar tidak selalu memberikan hasil prediksi yang lebih baik. Sebagai contoh, ketika jumlah *neuron hidden* ditingkatkan menjadi 40 dan 50, nilai MAPE justru meningkat menjadi 11.51% dan 7.87%, yang menunjukkan penurunan akurasi dibandingkan ketika jumlah neuron hidden sebanyak 35. Demikian pula, jumlah neuron yang terlalu kecil seperti 20 dan 25 juga menghasilkan nilai MAPE yang relatif tinggi, yaitu masing-masing sebesar 8.71% dan 12.80%. Dalam menentukan jumlah neuron hidden, diperlukan percobaan berulang untuk mendapatkan konfigurasi yang optimal. Tidak ada aturan pasti dalam menentukan parameter ini, sehingga eksperimen sangat penting untuk menemukan kombinasi terbaik yang dapat menghasilkan prediksi yang akurat sesuai kebutuhan penelitian.

Tabel 3. Perpaduan parameter max epoch

Neuron	Batch Size	Max Epoch	MAPE
35	12	50	4.44%
35	12	100	12.64%
35	12	150	15.41%

Berdasarkan Tabel 3 diketahui bahwa parameter *max epoch* yang optimal adalah 50 dengan nilai MAPE sebesar 4.44%. Untuk menentukan nilai *max epoch* yang optimal, perlu dilakukan percobaan secara berulang. Namun, nilai *max epoch* yang terlalu besar tidak menjamin hasil yang lebih baik. Hal ini disebabkan oleh potensi terjadinya *overfitting*. *Overfitting* adalah kondisi di mana model terlalu fokus pada data latih, sehingga sulit mengenali pola baru pada data uji. Akibatnya, akurasi model terhadap data uji menjadi rendah. Dalam tabel ini, terlihat bahwa peningkatan *max epoch* hingga 100 dan 150 justru menyebabkan nilai MAPE meningkat menjadi 12,64% dan 15,41%, yang menunjukkan penurunan performa model.

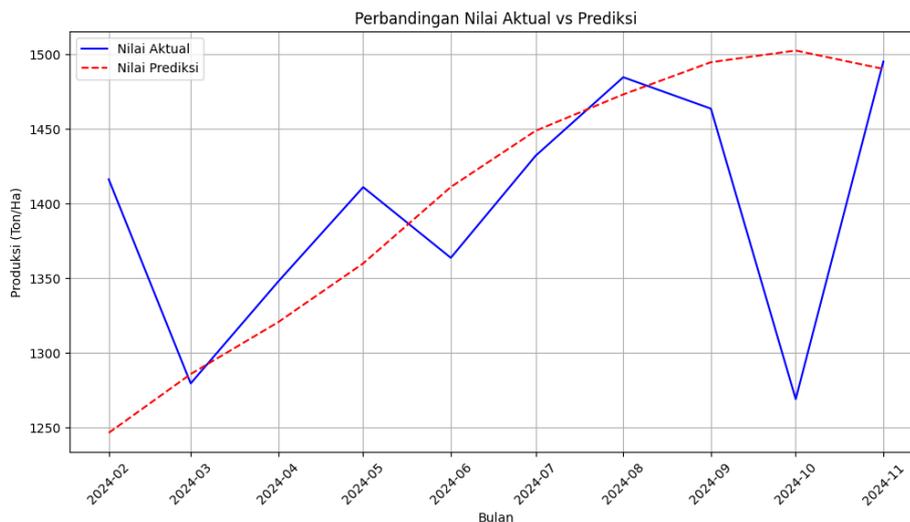
Tabel 4. Perpaduan parameter batch size

Neuron	Batch Size	Max Epoch	MAPE
35	4	50	7.27%
35	8	50	11.03%
35	12	50	4.44%
35	32	50	4.57%
35	64	50	4.71%

Berdasarkan Tabel 4 parameter *batch size* yang optimal adalah 12 dengan nilai MAPE sebesar 4.44%. Jika dilihat dari nilai MAPE <10% dapat disimpulkan bahwa hasil peramalan termasuk kategori sangat baik. Setelah mengetahui parameter optimal dan tingkat akurasi model, langkah selanjutnya adalah mengevaluasi kinerja model secara lebih detail. Untuk menguji performa model yang telah dibangun, dilakukan perbandingan antara data asli dan hasil prediksi. Berikut adalah hasil perbandingan antara data asli dengan hasil prediksi untuk beberapa bulan.

Tabel 5. Perbandingan data asli dan hasil prediksi

Bulan	Data Asli	Hasil Prediksi
1/2/2024	1416.285	1246.239868
1/3/2024	1279.395	1285.685425
1/4/2024	1347.84	1320.561035
1/5/2024	1411.02	1359.895630
1/6/2024	1363.635	1411.115356
1/7/2024	1432.08	1448.845825
1/8/2024	1484.73	1473.199829
1/9/2024	1463.67	1494.815918
1/10/2024	1268.865	1502.623779
1/11/2024	1495.26	1490.298340



Gambar 6. Grafik perbandingan nilai aktual dan prediksi

4. KESIMPULAN

Penelitian ini mengimplementasikan metode *Long Short Term Memory* untuk meramalkan produksi padi di Kota Lubuklinggau menggunakan data Januari 2019 sampai November 2024 sebanyak 71 bulan, dengan pembagian 70% data latih dan 30% data uji. Model terbaik dihasilkan dengan neuron hidden layer sebanyak 35, batch size 12, dan 50 epoch, menghasilkan nilai MAPE sebesar 4.44%, yang termasuk kategori sangat baik. Hasil prediksi menunjukkan model mampu mempelajari pola musiman dengan baik, di mana nilai prediksi mendekati data asli dengan selisih kecil. Dengan tingkat kesalahan rendah, metode LSTM ini dapat diandalkan untuk mendukung pengambilan keputusan dalam pengelolaan produksi padi di Kota Lubuklinggau. Keterbatasan penelitian ini terletak pada jumlah data yang relatif sedikit, sementara LSTM bekerja lebih optimal dengan data yang besar. Untuk penelitian selanjutnya, disarankan menggunakan data yang lebih banyak dan mempertimbangkan variabel tambahan lainnya seperti curah hujan, suhu dan kelembaban udara guna meningkatkan akurasi prediksi.

REFERENCES

- [1] J. H. Galitan, F. Duko, and F. Hatim, "Analisis Produksi Padi Di Indonesia: Indonesia," *Innovative: Journal Of Social Science Research*, vol. 4, no. 2, pp. 7281–7301, 2024.
- [2] N. Meidiana and A. Marhaeni, "Pengaruh kepemilikan aset, ketersediaan infrastruktur, dan pendidikan terhadap pendapatan dan kesejahteraan rumah tangga miskin," *Buletin Studi Ekonomi*, vol. 24, no. 1, 2019.
- [3] R. Rahim *et al.*, "Dinamika Ketahanan Pangan: Analisis Pengaruh Luas Panen Padi, Konsumsi Beras, Harga Beras, dan Jumlah Penduduk Terhadap Produksi Padi di Wilayah Sentra Padi di Indonesia Tahun 2017-2021," *Innovative: Journal Of Social Science Research*, vol. 4, no. 3, pp. 17083–17093, 2024.
- [4] P. D. Wijayanti, Harianto, and A. Suryana, "Permintaan Pangan Sumber Karbohidrat di Indonesia. Analisis Kebijakan Pertanian," *Analisa Kebijakan Pertanian*, vol. 17, pp. 13–26, 2019.
- [5] F. Husaini, I. Permana, M. Afdal, and F. N. Salisah, "Penerapan Algoritma Long Short-Term Memory untuk Prediksi Produksi Kelapa Sawit," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp. 366–374, Feb. 2024, doi: 10.57152/malcom.v4i2.1187.
- [6] F. Febriansyah, A. Sujjada, and F. Sembiring, "Prediksi Harga Bitcoin Menggunakan Algoritma Long Short Term Memory (LSTM)," *INOVTEK Polbeng - Seri Informatika*, vol. 9, no. 1, Jun. 2024, doi: 10.35314/isi.v9i1.4247.
- [7] S. Hidayatullah and A. Cherid, "Prediksi Temperatur Cuaca di Negara Norwegia Menggunakan Metode LSTM," *SIMKOM*, vol. 8, no. 2, pp. 187–198, Aug. 2023, doi: 10.51717/simkom.v8i2.192.
- [8] L. Wiranda and M. Sadikin, "Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk Pt. Metiska Farma." 2019
- [9] S. P. Simanjuntak, S. S. Berutu, and G. C. Setyawan, "Implementasi Metode CNN Pada Klasifikasi Sentimen Terhadap Pelaksanaan Piala Dunia U-17," *Journal of Engineering and Emerging Technology*, vol. 2, no. 1, pp. 23–32, 2024.
- [10] H. Sulastri and A. I. Gufroni, "Penerapan data mining dalam pengelompokan penderita thalassaemia," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 3, no. 2, pp. 299–305, 2017.
- [11] A. Dahlan, E. Utami, and E. T. Luthfi, "Perancangan Data Warehouse Perpustakaan Perguruan Tinggi XYZ Menggunakan Metode Snowflake Schema," *Respati*, vol. 8, no. 24, 2013.
- [12] D. A. Nasution, H. H. Khotimah, and N. Chamidah, "Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN," *Computer Engineering, Science and System Journal*, vol. 4, no. 1, p. 78, Jan. 2019, doi: 10.24114/cess.v4i1.11458.
- [13] T. B. Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbotot dalam Prediksi Harga Ethereum," 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>

- [14] S. J. Pipin, R. Purba, and H. Kurniawan, "Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation," *J. Comput. Syst. Informatics*, vol. 4, no. 4, pp. 806–815, 2023.
- [15] D. Heksaputra, "Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory," *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 7, no. 2, pp. 163–174, 2020.
- [16] R. Vinayakumar, K. P. Soman, and P. Poornachandran, "Long short-term memory based operation log anomaly detection," in *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2017, pp. 236–242. doi: 10.1109/ICACCI.2017.8125846.
- [17] F. A. Nugraha, N. H. Harani, and R. Habibi, *Analisis Sentimen Terhadap Pembatasan Sosial Menggunakan Deep Learning*. Kreatif, 2020.
- [18] A. Krisma, M. Azhari, and P. P. Widagdo, "Perbandingan metode double exponential smoothing dan triple exponential smoothing dalam parameter tingkat error mean absolute percentage error (mape) dan means absolute deviation (mad)," in *Prosiding Seminar Nasional Ilmu Komputer dan Teknologi Informasi*, 2019.
- [19] I. Nabillah and I. Ranggadara, "Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut," *JOINS (Journal of Information System)*, vol. 5, no. 2, pp. 250–255, Nov. 2020. doi: 10.33633/joins.v5i2.3900.
- [20] S. Wardah and I. Iskandar, "Analisis Peramalan Penjualan Produk Keripik Pisang Kemasan Bungkus (Studi Kasus : Home Industry Arwana Food Tembilahan)," *J@ti Undip: Jurnal Teknik Industri*, vol. 11, no. 3, p. 135, Jan. 2017, doi: 10.14710/jati.11.3.135-142.
- [21] A. B. Wibowo and D. Rukmayadi, "Requirement Planning (Mrp) Method For Cake Products In 'Q' Company" 2020