

# ANALYSIS OF RICE YIELD PREDICTION WITH MLPREGRESSOR AND LONG SHORT-TERM MEMORY MODELS

## ANALISIS PREDIKSI HASIL PADI DENGAN MODEL MLPREGRESSOR DAN LONG SHORT-TERM MEMORY

Sunoto<sup>1</sup>, Mangapul Siahaan<sup>2</sup>

Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Internasional Batam

Email: 2131077.sunoto@uib.ac.id

**Abstract** - This research aims to analyse and compare the accuracy of rice productivity prediction using Multi-Layer Perceptron Regressor (MLPRegressor) and Long Short-Term Memory (LSTM) models. The data used comes from the Badan Pusat Statistik (BPS) for the period 2018-2023, covering rice productivity from 34 provinces in Indonesia. The study employed six different architectural models for each model, with training data using the 2018-2020 period and testing data for 2021-2023. The results show that the LSTM model with 2-42-42-42-1 architecture achieved the highest accuracy rate of 94.12% with MSE 0.00305660, while the MLPRegressor model with 2-22-1 architecture achieved 91.18% accuracy with MSE 0.00471975. These results indicate that LSTM performs slightly better in predicting rice productivity, which can be used as a reference for agricultural planning and food policy in Indonesia.

**Keywords:** Artificial Neural Network, Artificial Neural, Long Short-Term Memory, Network, Rice Prediction, Rice Productivity.

**Abstrak** – Penelitian ini bertujuan membandingkan akurasi prediksi produktivitas padi menggunakan model Multi-Layer Perceptron Regressor (MLPRegressor) dan Long Short-Term Memory (LSTM). Data dari Badan Pusat Statistik (BPS) periode 2018–2023 mencakup produktivitas padi dari 34 provinsi di Indonesia. Padi sebagai komoditas pangan utama berperan penting dalam ketahanan pangan nasional, sehingga prediksi produktivitasnya menjadi krusial. Penelitian ini menggunakan enam arsitektur model untuk masing-masing algoritma, dengan data pelatihan dari tahun 2018–2020 dan data pengujian dari tahun 2021–2023. Hasil penelitian menunjukkan model LSTM dengan arsitektur 2-42-42-42-1 memiliki akurasi tertinggi sebesar 94,12% dan MSE 0,00305660, sementara model MLPRegressor dengan arsitektur 2-22-1 mencapai akurasi 91,18% dan MSE 0,00471975. LSTM lebih unggul dalam menangkap pola musiman dan temporal dibandingkan MLPRegressor. Temuan ini mendukung perencanaan pertanian dan kebijakan pangan nasional untuk meningkatkan ketahanan pangan dan stabilitas ekonomi. Selain itu, hasilnya dapat membantu memitigasi fluktuasi hasil panen akibat faktor musiman dan iklim, mendukung stabilitas harga pangan, serta meningkatkan kesejahteraan masyarakat.

**Kata Kunci:** Jaringan Syaraf Tiruan, Long Short-Term Memory (LSTM), Mlpregressor, Prediksi Padi, Produktivitas Padi.

## I. PENDAHULUAN

Padi merupakan salah satu komoditas pangan paling penting di Indonesia, memegang peranan yang sangat vital dalam ketahanan pangan nasional [1]. Sebagai makanan pokok bagi sebagian besar penduduk Indonesia, padi menjadi salah satu sumber karbohidrat utama bagi masyarakat [2], padi juga memainkan peran strategis dalam menjaga kestabilan sosial dan ekonomi [3]. Stabilitas produksi padi berpengaruh besar terhadap harga pangan dan kesejahteraan masyarakat [4]. Dalam konteks global, Indonesia menempati peringkat ketiga sebagai produsen beras terbesar di dunia [5]. Dengan demikian, Indonesia memiliki peran yang signifikan dalam pasar beras internasional, meskipun sebagian besar produksinya digunakan untuk memenuhi kebutuhan domestik. Lahan sawah di Indonesia tersebar di berbagai pulau utama seperti Jawa, Sumatra, dan Sulawesi, yang masing-masing memiliki karakteristik agrikultur dan iklim yang berbeda-beda [6]. Pulau Jawa, dikenal sebagai salah satu pusat produksi padi terbesar di Indonesia [7]. Fluktuasi ini disebabkan oleh berbagai faktor eksternal, termasuk perubahan kondisi cuaca yang tidak dapat diprediksi, serangan hama dan penyakit yang dapat menurunkan hasil panen, serta praktik pertanian yang mungkin belum sepenuhnya optimal atau efisien [8]. Mengingat pentingnya padi bagi ketahanan pangan dan ekonomi Indonesia, upaya untuk meningkatkan produktivitas padi menjadi sangat krusial [8]. Salah satu pendekatan yang semakin banyak diterapkan oleh para peneliti dan praktisi di bidang pertanian adalah penggunaan metode prediksi untuk memperkirakan hasil panen padi di masa depan [9], [10].

Prediksi yang akurat membantu petani merencanakan kegiatan pertanian dan memungkinkan pemerintah merumuskan kebijakan pangan yang lebih tepat [11]. Dengan data prediksi, pemerintah dapat mengalokasikan sumber daya seperti pupuk, benih, dan irigasi secara efektif, serta mengantisipasi kebutuhan impor beras dan menjaga stabilitas harga pangan untuk mencegah inflasi dan menjaga daya beli masyarakat. Artificial Neural Network (ANN) adalah pendekatan populer dalam prediksi, termasuk di bidang pertanian. MLP adalah arsitektur ANN yang terdiri dari beberapa lapisan perceptron yang saling terhubung, memungkinkan pemrosesan informasi kompleks dengan fleksibilitas dalam menangani banyak variabel [12]. Dengan menambahkan lebih banyak lapisan dan meningkatkan jumlah neuron per lapisan, model MLPRegressor dapat dilatih dengan lebih baik, sehingga menghasilkan prediksi yang lebih akurat dan spesifik sesuai dengan data yang ada [13].

Di sisi lain LSTM merupakan turunan dari metode Recurrent Neural Network (RNN), yang juga banyak digunakan dalam analisis data sekuensial. LSTM pertama kali dikenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 [14]. LSTM adalah turunan dari RNN yang dikembangkan untuk mengolah data sekuensial dan temporal. Penelitian ini menggunakan dua metode berbasis ANN, yaitu dengan menggunakan MLPRegressor dan LSTM, untuk membandingkan hasil serta performa dalam memprediksi produktivitas padi.

Model LSTM dirancang untuk menangani data deret waktu, namun penerapannya dalam prediksi hasil pertanian, terutama padi, masih sangat terbatas. Hasil penelitian dari [5] menunjukkan efektivitas LSTM dalam menangkap pola musiman pada prediksi harga saham, namun belum ada penelitian yang secara spesifik mengeksplorasi model ini untuk produktivitas padi di Indonesia, yang memiliki pola pertanian musiman yang kompleks. Hal ini menandai kebutuhan untuk mengeksplorasi LSTM lebih lanjut, terutama dalam konteks agrikultur yang memiliki faktor musiman dan jangka panjang.

Selain itu, hanya sedikit studi yang membandingkan langsung performa model MLPRegressor dan LSTM dalam prediksi produktivitas padi. Meskipun ANN telah banyak digunakan dalam aplikasi pertanian, penelitian yang membandingkan model MLPRegressor dengan LSTM dalam konteks data musiman sangat jarang dilakukan. Studi oleh [13], [15], [16] mengindikasikan bahwa LSTM memiliki keunggulan dalam menangkap pola jangka panjang dan musiman, namun belum ada penelitian yang melihat bagaimana performa keduanya secara langsung dalam prediksi produktivitas padi. Berdasarkan permasalahan di atas, maka perlu melakukan penelitian ini yang bertujuan melakukan perbandingan mendalam antara dua metode berbasis ANN, yaitu MLPRegressor dan LSTM dalam prediksi produktivitas padi, khususnya dengan mempertimbangkan data musiman yang bersifat temporal.

## II. SIGNIFIKANSI STUDI

### A. Studi Literatur

Penelitian mengenai prediksi produktivitas padi perlu dilakukan terutama terkait keterbatasan model dalam menangkap pola temporal dan musiman. Metode klasifikasi sederhana seperti Support Vector Machine (SVM) kurang efektif untuk prediksi jangka panjang, sementara metode regresi linier dan Random Forest belum mampu menangani pola musiman dan deret waktu khas data pertanian, yang dipengaruhi oleh cuaca dan periode tanam (Hutahaean et al., 2024). Meskipun Backpropagation Neural Network (BPNN) telah banyak digunakan, model ini masih memiliki keterbatasan dalam memodelkan data deret waktu, terutama untuk data musiman. Penelitian oleh Sugiyarto et al. mengoptimalkan BPNN dengan algoritma genetika, namun belum menguji efektivitasnya untuk menangani data musiman yang dinamis. Dalam penelitian ini, teknik yang umum digunakan untuk mengatasi data yang hilang dan outliers yaitu normalisasi data.

Hasil dari penelitian ini dapat digunakan secara praktis untuk meningkatkan relevansi penelitian dalam beberapa cara berikut:

#### 1. Perencanaan pertanian yang lebih baik

Dengan menggunakan model LSTM yang memiliki akurasi prediksi tinggi, petani dan pemerintah dapat merencanakan penanaman serta panen padi secara lebih efektif. Prediksi yang akurat memungkinkan optimalisasi penggunaan sumber daya seperti pupuk dan irigasi, sehingga mendukung efisiensi produksi pertanian. Selain itu, keputusan berbasis data ini membantu mengurangi risiko kerugian akibat ketidakpastian cuaca atau fluktuasi hasil panen.

#### 2. Pengambilan keputusan kebijakan

Temuan penelitian ini dapat memberikan dasar yang kuat bagi pembuat kebijakan untuk merumuskan kebijakan pangan yang lebih responsif terhadap fluktuasi produktivitas, sehingga meningkatkan ketahanan pangan nasional. Dengan memanfaatkan prediksi yang akurat, pemerintah dapat mengelola cadangan pangan secara lebih efisien dan mencegah kekurangan pasokan yang berpotensi meningkatkan harga. Selain itu, langkah ini juga membantu menjaga stabilitas harga di pasar, melindungi kesejahteraan petani dan konsumen dari dampak ketidakpastian ekonomi.

### 3. Mitigasi risiko

Dengan memahami pola musiman dan temporal dalam produktivitas padi, pemangku kepentingan dapat mengembangkan strategi mitigasi untuk menghadapi risiko yang terkait dengan perubahan iklim dan kondisi cuaca ekstrem. Analisis ini memungkinkan penyesuaian jadwal tanam dan panen yang lebih adaptif, sehingga mengurangi potensi kerugian akibat anomali cuaca. Selain itu, strategi ini juga dapat mendukung implementasi praktik pertanian berkelanjutan yang lebih tahan terhadap perubahan lingkungan jangka panjang.

### 4. Peningkatan efisiensi sumber daya

Hasil penelitian ini dapat membantu dalam mengalokasikan sumber daya secara lebih efisien, sehingga mengurangi pemborosan dan memaksimalkan hasil pertanian. Dengan optimalisasi penggunaan input seperti pupuk, air, dan tenaga kerja berdasarkan data prediksi yang akurat, produktivitas lahan dapat ditingkatkan secara signifikan. Pada gilirannya, langkah ini tidak hanya meningkatkan hasil panen, tetapi juga berkontribusi langsung terhadap peningkatan kesejahteraan petani dan stabilitas sektor pertanian.

### 5. Pendidikan dan pelatihan

Temuan ini dapat digunakan sebagai bahan ajar dalam program pendidikan dan pelatihan bagi petani serta pengelola pertanian, untuk meningkatkan pemahaman mereka tentang pentingnya data dan teknologi dalam pertanian modern. Melalui pelatihan berbasis teknologi, petani dapat belajar mengaplikasikan prediksi data untuk pengambilan keputusan yang lebih efektif, seperti penjadwalan tanam dan panen. Selain itu, program ini juga mendorong adopsi inovasi pertanian digital, yang pada akhirnya mempercepat transformasi sektor pertanian menuju keberlanjutan dan efisiensi yang lebih tinggi.

### 6. Riset lanjutan

Hasil penelitian ini dapat menjadi dasar untuk penelitian lebih lanjut dalam bidang pertanian, mendorong eksplorasi model dan teknik baru untuk meningkatkan prediksi serta pengelolaan produktivitas pertanian. Dengan memperluas aplikasi teknologi seperti pembelajaran mesin dan analisis data, penelitian mendatang dapat menghasilkan solusi yang lebih presisi dalam menghadapi tantangan seperti perubahan iklim dan kebutuhan pangan yang terus meningkat. Selain itu, pengembangan ini juga membuka peluang kolaborasi antara peneliti, pemerintah, dan sektor swasta untuk menciptakan inovasi yang berkelanjutan di sektor pertanian.

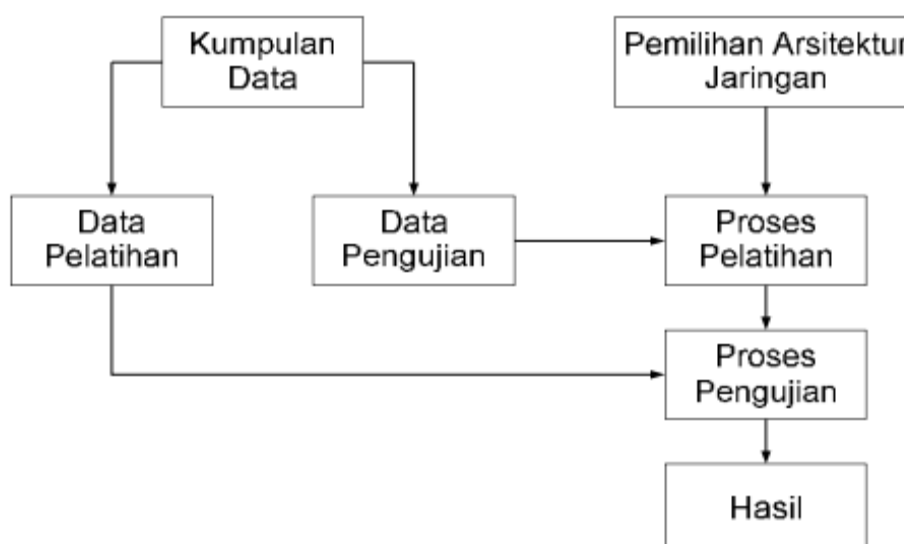
Dengan demikian, hasil penelitian ini tidak hanya memberikan kontribusi akademis tetapi juga memiliki dampak praktis yang signifikan dalam meningkatkan ketahanan pangan dan efisiensi pertanian di Indonesia. Temuan ini dapat langsung diimplementasikan dalam kebijakan dan praktik pertanian untuk menghadapi tantangan seperti fluktuasi produktivitas dan perubahan iklim. Selain itu, penerapan hasil penelitian ini dapat memperkuat sistem pangan nasional, memastikan ketersediaan pasokan yang stabil, dan mendukung kesejahteraan petani serta masyarakat secara keseluruhan.

#### *B. Sumber Data*

Dataset yang digunakan dalam penelitian ini merupakan data produktivitas padi di Indonesia selama beberapa tahun terakhir, yang diperoleh dari sumber resmi pemerintah seperti BPS. Data

ini meliputi periode tahun 2018 hingga 2023, dengan fokus pada prediksi produktivitas padi untuk tahun 2024 dan 2025. Informasi yang dikumpulkan mencakup produktivitas padi (ku/ha).

### C. Tahapan Penelitian



Gambar 1. Tahapan Penelitian

Pada Gambar 1 dapat dijabarkan bahwa hal pertama yang dilakukan dalam penelitian ini yaitu pengumpulan dataset. Dataset yang digunakan pada penelitian ini yaitu data “luas panen, produktivitas, dan produksi padi menurut provinsi” yang berasal dari BPS. Selanjutnya dilakukan tahapan preprocessing data dan membagi data menjadi beberapa bagian, yaitu data yang digunakan untuk pelatihan (*training*) dan data yang akan digunakan untuk pengujian (*testing*). Kemudian akan dilakukan tahapan pemilihan arsitektur jaringan, masing-masing model akan dilakukan proses pelatihan dan proses pengujian menggunakan 5 model arsitektur yang berbeda-beda.

Berdasarkan tabel 1, data akan dibagi menjadi 2 bagian terlebih dahulu, yaitu data pelatihan (*training*) dan data pengujian (*testing*). Data tahun 2018 dan 2019 dengan target 2020 akan digunakan sebagai data pelatihan, sedangkan data tahun 2021 dan 2022 dengan target 2023 akan digunakan sebagai data pengujian. Kemudian setelah pembagian 2 data tersebut, akan dilakukan proses normalisasi terlebih dahulu. Normalisasi data dilakukan agar hasil *ouput* pelatihan sesuai dengan fungsi aktivasi yang akan digunakan [17]. Menggunakan persamaan sebagai berikut:

$$x' = \frac{0.8(x-a)}{b-a} + 0.1 \quad (1)$$

Keterangan:

- $x'$  = Hasil normalisasi
- $x$  = Data yang akan dinormalisasi
- $a$  = Data terkecil dalam dataset
- $b$  = Data terbesar dalam dataset

Normalisasi ini dilakukan untuk mengubah skala data ke dalam rentang [0.1, 0.9], sehingga perbedaan skala antar fitur dapat diminimalisir [18]. Langkah ini penting dalam algoritma yang menggunakan gradien, seperti MLPRegressor dan LSTM, untuk mempercepat konvergensi model dan menghindari fitur tertentu mendominasi proses pembelajaran [12].

### III. HASIL DAN PEMBAHASAN

Tabel 1. Hasil Prediksi Model MLPRegressor

PROVINSI	Produktivitas (ku/ha)					
	2020	2021	2022	2023	2024	2025
Aceh	55.28	55.03	55.55	55.22	58.16	59.43
Sumatera Utara	52.51	52.00	50.76	51.4	50.86	51.03
Sumatera Barat	46.92	48.36	50.52	49.32	49.08	48.06
Riau	37.64	40.98	41.83	39.68	39.48	38.97
Jambi	45.58	46.29	45.88	45.06	43.43	42.16
Sumatera Selatan	49.75	51.44	54.06	56.19	57.18	60.11
Bengkulu	45.66	48.67	49.27	49.53	48.35	47.63
Lampung	48.62	50.77	51.87	52.03	52.30	52.64
Kep. Bangka Belitung	32.13	38.57	40.66	43.49	40.84	40.33
Kep. Riau	28.56	31.65	28.24	28.11	29.38	30.02
DKI Jakarta	49.69	58.03	48.98	49.26	47.97	47.17
Jawa Barat	56.82	56.81	56.75	57.71	61.00	63.38
Jawa Tengah	56.93	56.69	55.41	55.3	58.12	59.52
D.I Yogyakarta	47.35	51.77	50.64	50.53	50.14	49.75
Jawa Timur	56.68	56.02	56.26	57.19	60.20	62.53
Banten	50.88	50.38	53.04	54.19	54.93	56.63
Bali	58.49	58.83	60.59	62.07	67.03	69.11
Nusa Tenggara Barat	48.17	51.39	53.79	53.51	55.19	56.04
Nusa Tenggara Timur	39.9	41.85	41.29	41.52	40.20	39.65
Kalimantan Barat	30.33	31.9	30.28	31.25	32.10	33.03
Kalimantan Tengah	31.96	30.28	31.78	32.56	33.50	34.30
Kalimantan Selatan	39.69	39.97	38.13	40.86	39.18	39.10
Kalimantan Timur	35.67	36.92	36.85	39.76	38.46	38.59
Kalimantan Utara	33.97	33.74	35.49	36.31	36.68	37.06
Sulawesi Utara	40.25	39.35	41.88	43.65	41.31	40.63
Sulawesi Tengah	44.49	47.59	44.05	46.22	43.26	42.37
Sulawesi Selatan	48.23	51.67	51.64	50.39	50.77	50.14
Sulawesi Tenggara	39.85	41.57	40.5	42.08	40.25	39.78
Gorontalo	46.75	48.12	51.29	50.68	50.77	50.35
Sulawesi Barat	53.23	52.05	50.99	49.73	49.75	48.86
Maluku	38.53	41.24	38.6	35.32	37.10	36.98
Maluku Utara	42.11	36.05	38.16	34.59	36.68	36.60
Papua Barat	32.2	41.98	43.89	45.08	42.62	41.69
Papua	31.48	44.05	38.99	44.76	40.71	40.50

Pada tabel 1 di atas menunjukkan bahwa hasil prediksi pada tahun 2024 dan 2025 produktivitas panen provinsi Bali mengalami peningkatan yakni sebesar 67.03 (ku/ha) pada tahun 2024 dan 69.11 (ku/ha) pada tahun 2025. Peningkatan produktivitas ini mencerminkan keberhasilan dalam pengelolaan sektor pertanian di Provinsi Bali, yang mungkin dipengaruhi oleh adopsi teknologi modern, pengelolaan lahan yang lebih efisien, serta dukungan kebijakan pemerintah terhadap

petani. Selain itu, tren ini menunjukkan bahwa Bali memiliki potensi untuk terus meningkatkan hasil panennya, terutama dengan memperhatikan faktor-faktor pendukung seperti akses terhadap irigasi, penggunaan pupuk berkualitas, dan pelatihan bagi petani.

Tabel 2. Hasil Prediksi Model LSTM

PROVINSI	Produktivitas (ku/ha)					
	2020	2021	2022	2023	2024	2025
Aceh	55.28	55.03	55.55	55.22	53.96	53.02
Sumatera Utara	52.51	52.00	50.76	51.4	50.22	49.46
Sumatera Barat	46.92	48.36	50.52	49.32	48.57	47.76
Riau	37.64	40.98	41.83	39.68	39.48	38.72
Jambi	45.58	46.29	45.88	45.06	44.24	43.47
Sumatera Selatan	49.75	51.44	54.06	56.19	54.47	53.53
Bengkulu	45.66	48.67	49.27	49.53	48.44	47.72
Lampung	48.62	50.77	51.87	52.03	50.94	50.14
Kep. Bangka Belitung	32.13	38.57	40.66	43.49	41.60	41.18
Kep. Riau	28.56	31.65	28.24	28.11	30.82	31.63
DKI Jakarta	49.69	58.03	48.98	49.26	48.18	47.46
Jawa Barat	56.82	56.81	56.75	57.71	55.99	54.85
Jawa Tengah	56.93	56.69	55.41	55.3	54.00	53.07
D.I Yogyakarta	47.35	51.77	50.64	50.53	49.54	48.78
Jawa Timur	56.68	56.02	56.26	57.19	55.53	54.47
Banten	50.88	50.38	53.04	54.19	52.81	51.96
Bali	58.49	58.83	60.59	62.07	59.43	57.65
Nusa Tenggara Barat	48.17	51.39	53.79	53.51	52.43	51.54
Nusa Tenggara Timur	39.9	41.85	41.29	41.52	40.46	39.86
Kalimantan Barat	30.33	31.9	30.28	31.25	32.22	32.86
Kalimantan Tengah	31.96	30.28	31.78	32.56	33.07	33.50
Kalimantan Selatan	39.69	39.97	38.13	40.86	39.10	38.84
Kalimantan Timur	35.67	36.92	36.85	39.76	38.04	37.91
Kalimantan Utara	33.97	33.74	35.49	36.31	35.75	35.70
Sulawesi Utara	40.25	39.35	41.88	43.65	42.07	41.56
Sulawesi Tengah	44.49	47.59	44.05	46.22	44.53	43.98
Sulawesi Selatan	48.23	51.67	51.64	50.39	49.63	48.82
Sulawesi Tenggara	39.85	41.57	40.5	42.08	40.59	40.12
Gorontalo	46.75	48.12	51.29	50.68	49.80	48.99
Sulawesi Barat	53.23	52.05	50.99	49.73	48.99	48.18
Maluku	38.53	41.24	38.6	35.32	36.09	35.58
Maluku Utara	42.11	36.05	38.16	34.59	35.58	35.15
Papua Barat	32.2	41.98	43.89	45.08	43.68	43.05
Papua	31.48	44.05	38.99	44.76	41.94	41.77

Berdasarkan tabel 2 di atas, prediksi produktivitas panen yang mengalami peningkatan adalah provinsi Kalimantan Barat dan Kalimantan Tengah dengan masing-masing adalah sebesar 32.22 (ku/ha) pada tahun 2024 dan 32.86 (ku/ha) pada tahun 2025, untuk Kalimantan Tengah sebesar 33.07 (ku/ha) pada tahun 2024 dan 33.50 (ku/ha) pada tahun 2025. Meskipun peningkatan ini terlihat menjanjikan, rata-rata produktivitas di Kalimantan Barat dan Kalimantan Tengah masih

berada di bawah provinsi-provinsi di Pulau Jawa atau Bali, yang mencapai angka di atas 50 ku/ha. Hal ini mengindikasikan bahwa masih ada ruang untuk perbaikan lebih lanjut dalam hal efisiensi penggunaan lahan, pengelolaan sumber daya, serta inovasi dalam teknologi pertanian untuk mengejar ketertinggalan.

Tabel 3. Perbandingan Hasil Akurasi Model MLPRegressor

Model Arsitektur	Data Pelatihan			Data Uji	
	Epoch	Waktu	MSE	MSE	Akurasi
2-12-1	3849	00:01,6	0.00464184	0.02429468	61,76%
2-18-1	2505	00:01,1	0.00471170	0.00710725	73,53%
2-22-1	2894	00:01,2	0.00367936	0.00471975	91.18%
2-24-1	718	00:00,3	0.00272249	0.00567826	76,47%
2-28-1	846	00:00,4	0.00345001	0.00735666	73,53%
2-32-1	1800	00:00,8	0.00350129	0.01320424	67.65%

Tabel 3 di atas menunjukkan performa berbagai model arsitektur dalam sebuah eksperimen pelatihan dan pengujian jaringan saraf buatan (Artificial Neural Network). Setiap model diuji berdasarkan parameter arsitektur, jumlah data pelatihan, waktu pelatihan, Mean Squared Error (MSE) pada data pelatihan dan data uji, serta akurasi model. Berdasarkan tabel 3 di atas menunjukkan bahwa model 2-22-1 memiliki kinerja terbaik dengan akurasi 91,18%, MSE data uji terendah (0.00471975), dan waktu pelatihan relatif cepat (1,2 detik). Model 2-24-1 memiliki MSE data pelatihan paling kecil (0.00272249), namun akurasinya lebih rendah (76,47%). Model dengan MSE data uji lebih rendah cenderung memiliki akurasi yang lebih tinggi.

Tabel 4. Perbandingan Hasil Akurasi Model LSTM

Model Arsitektur	Data Pelatihan			Data Uji	
	Epoch	Waktu	MSE	MSE	Akurasi
2-16-16-16-1	100	00:34,7	0.00362149	0.00547060	73,53%
2-20-20-20-1	100	00:31,8	0.00394267	0.00663962	73,53%
2-22-22-22-1	100	00:31,7	0.00350268	0.00498316	79,41%
2-32-32-32-1	100	00:35,6	0.00323333	0.00444326	79,41%
2-36-36-36-1	100	00:32,0	0.00349112	0.00409728	88.24%
2-42-42-42-1	100	00:35,0	0.00329369	0.00305660	94,12%

Tabel 4 di atas menunjukkan bahwa model dengan arsitektur lebih kompleks, seperti 2-42-42-42-1, memberikan kinerja terbaik dengan akurasi tertinggi dan error terendah. Namun, ini dicapai dengan waktu pelatihan yang sedikit lebih lama. Model dengan konfigurasi lebih sederhana dapat lebih efisien dalam waktu pelatihan, tetapi cenderung memberikan performa yang kurang optimal.

#### IV. KESIMPULAN

Penelitian ini membandingkan performa dua metode berbasis ANN, yaitu MLPRegressor dan LSTM, dalam memprediksi produktivitas padi di Indonesia dari tahun 2024 - 2025 dengan data musiman dan temporal. Dari hasil penelitian, dapat disimpulkan bahwa model LSTM dengan



arsitektur 2-42-42-42-1 menunjukkan performa terbaik dengan tingkat akurasi 94,12% dan Mean Squared Error (MSE) sebesar 0,00305660. LSTM mampu menangkap pola temporal dan musiman dengan lebih baik dibandingkan MLPRegressor, sehingga cocok digunakan untuk data time series seperti produktivitas padi. Sedangkan model MLPRegressor terbaik menggunakan arsitektur 2-22-1 dengan akurasi 91,18% dan MSE 0,00471975. Meskipun memiliki akurasi yang tinggi, MLPRegressor kurang optimal dalam menangani pola musiman dibandingkan LSTM.

## REFERENSI

- [1] H. Tohari, S. Harini, M. A. Yaqin, I. B. Santoso, and C. Crysdiyan, "Penerapan Metode Support Vector Machine (SVM) Dalam Klasifikasi Produktivitas Padi," *J. Comput. Syst. Informatics*, vol. 5, no. 1, pp. 175–183, 2023, doi: 10.47065/josyc.v5i1.4538.
- [2] A. W. Sugiyarto, D. Urwatul Wutsqa, N. Hendiyani, and A. R. I. Rasjava, "Optimization of genetic algorithms on backpropagation neural network to predict national rice production levels," in *Proceedings of ICAITI 2019 - 2nd International Conference on Applied Information Technology and Innovation*, 2019, pp. 77–81. doi: 10.1109/ICAITI48442.2019.8982118.
- [3] J. Hutahean, D. Yusup, and Purwantoro, "Perbandingan Metode Linear Regression, Random Forest & K-Nearest Neighbor untuk Prediksi Produksi Hasil Panen Padi di Provinsi Jawa Barat," *JATI*, vol. 8, no. 3, Jun. 2024.
- [4] A. Wanto, "Prediksi Produktivitas Jagung Di Indonesia Sebagai Upaya Antisipasi Impor Menggunakan Jaringan Saraf Tiruan Backpropagation," *SINTECH (Science Inf. Technol. J.)*, vol. 2, no. 1, pp. 53–62, 2019, doi: 10.31598/sintechjournal.v2i1.355.
- [5] G. Budiprasetyo, M. Hani'ah, and D. Z. Aflah, "Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)," *J. Nas. Teknol. Dan Sist. Inf.*, vol. 8, no. 3, pp. 164–172, 2023, doi: 10.25077/teknosi.v8i3.2022.164-172.
- [6] V. V. Utari, A. Wanto, I. Gunawan, and Z. M. Nasution, "Prediksi Hasil Produksi Kelapa Sawit PTPN IV Bahjambi Menggunakan Algoritma Backpropagation," *J. Comput. Syst. Informatics (JoSYC)*, vol. 2, no. 3, pp. 271–279, 2021.
- [7] S. Rokhmah, A. Susilowati, and M. I. Permatasari, "Klasifikasi Data untuk Prediksi Hasil Panen Tanaman Padi di Wilayah Kabupaten Sukoharjo Menggunakan Algoritma C 45," *J. Rekayasa Teknol. Inf.*, vol. 6, no. 2, p. 134, 2022, doi: 10.30872/jurti.v6i2.8323.
- [8] N. Nafiiyah, "Prediksi Harga Beras Berdasarkan Kualitas Beras dengan Metode LSTM," *INOVTEK Polbeng - Seri Inform.*, vol. 7, no. 2, p. 278, 2022, doi: 10.35314/isi.v7i2.2599.
- [9] T. Jaelani, "Machine Learning untuk Prediksi Produksi Gula Nasional," *JMPM (Jurnal Mater. dan Proses Manufaktur)*, vol. 6, no. 1, pp. 31–36, 2022, doi: 10.18196/jmpm.v6i1.14897.
- [10] I. Firmansyah and B. H. Hayadi, "Komparasi Fungsi Aktivasi Relu Dan Tanh Pada Multilayer Perceptron," *JIKO (Jurnal Inform. Dan Komputer)*, vol. 6, no. 2, p. 200, 2022, doi: 10.26798/jiko.v6i2.600.

- [11] M. Hafizh, F. Hamami, and T. F. Kusumasari, "Prediksi Network Capacity Planning PT XYZ Menggunakan Algoritma Recurrent Neural Network (RNN)," *Unkn. J.*, vol. 10, no. 5, p. 4880, 2023, [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/21336>
- [12] G. Tamami and M. Arifin, "Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens," *Unkn. J.*, vol. 14, no. 2, pp. 301–308, 2024.
- [13] S. Sen, D. Sugiarto, and A. Rochman, "Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras," *ULTIMATICS*, vol. 12, no. 1, Jun. 2020.
- [14] A. Suwandi, "Prediksi Harga Emas Menggunakan Metode Single Moving Average," *JiTEKH*, vol. 8, no. 1, pp. 32–36, 2020, doi: 10.35447/jitekh.v8i1.194.
- [15] P. Alkhairi, A. P. Windarto, and M. M. Efendi, "Optimasi LSTM Mengurangi Overfitting untuk Klasifikasi Teks Menggunakan Kumpulan Data Ulasan Film Kaggle IMDB," *BITS*, vol. 6, no. 2, pp. 1142–1150, 2024, doi: 10.47065/bits.v6i2.5850.
- [16] J. Aprilyanto and Y. Yohannes, "Implementasi Arsitektur VGG-Unet Dalam Melakukan Segmentasi Keretakan pada Citra Bangunan," *MDP Student Conf.*, vol. 2, no. 1, pp. 257–264, 2023, doi: 10.35957/mdp-sc.v2i1.4311.
- [17] A. Fitriadini, T. Pramiyati, and A. B. Pangaribuan, "Penerapan Backpropagation Neural Network Dalam Prediksi Harga Saham," in *Seminar Nasional Mahasiswa Ilmu Komputer Dan Aplikasinya (SENAMIKA)*, 2020, pp. 561–573.
- [18] Y. Li and H. Cao, "Prediction for Tourism Flow based on LSTM Neural Network," *Procedia Comput. Sci.*, vol. 129, pp. 277–283, 2018, doi: 10.1016/j.procs.2018.03.076.