

IMPLEMENTASI ALGORITMA *LONG SHORT-TERM MEMORY*  
(LSTM) UNTUK MEMPREDIKSI HARGA BERAS DI JAWA  
TENGAH BERDASARKAN CUACA

Yusuf Ashari<sup>1</sup>, Agus Suhendar<sup>2</sup>

1, 2) Prodi Informatika, Fakultas Sains & Teknologi, Universitas Teknologi Yogyakarta, Indonesia

Article Info

Article history:

Received: 04 November 2024  
Revised: 15 November 2024  
Accepted: 15 November 2024

ABSTRACT

Abstrak

Harga beras yang tidak stabil seringkali menjadi masalah bagi pemerintah dalam menjaga ketahanan pangan dan bagi petani untuk mendapatkan pendapatan yang stabil. Tujuan Penelitian untuk mengembangkan sistem prediksi harga beras di Jawa Tengah menggunakan metode *Long Short-Term Memory* (LSTM). LSTM dipilih karena kemampuannya dalam menangkap pola *non-linear* dan dependensi jangka Panjang yang terdapat dalam data *time series* seperti harga beras. Sistem dibangun dengan menggunakan data harga beras harian yang didapatkan dari website Pusat Informasi Harga Pangan Strategis Nasional (PIHPS Nasional) dan data cuaca harian yang diperoleh dari website BMKG di Jawa Tengah dari tahun 2017 - 2024. Arsitektur model LSTM yang digunakan terdiri dari tiga lapisan LSTM dengan *dropout* disetiap lapisannya dan satu lapisan *Dense*. Evaluasi performa model dilakukan dengan menggunakan tiga metrik evaluasi yaitu MAE, RMSE, dan MAPE. Hasil dari penelitian menunjukkan bahwa model prediksi harga beras menggunakan LSTM memiliki performa yang cukup baik berdasarkan dengan nilai metrik evaluasi, yaitu MAE sebesar 0.141, MAPE sebesar 1.256%, dan RMSE sebesar 0.205.

**Kata Kunci:** *Machine Learning*, Kecerdasan Buatan, *Long Short-Term Memory* (LSTM), Prediksi Harga

Abstract

Unstable rice prices often become a problem for the government in maintaining food security and for farmers to obtain stable income. This research aims to develop a rice price prediction system in Central Java using the *Long Short-Term Memory* (LSTM) method. LSTM was chosen for its ability to capture *non-linear* patterns and long-term dependencies found in time series data such as rice prices. The system was built using daily rice price data obtained from the National Strategic Food Price Information Center (PIHPS National) website and daily weather data obtained from BMKG website in Central Java from 2017 - 2024. The LSTM model architecture used consists of three LSTM layers with *dropout* in each layer and one *Dense* layer. Model performance evaluation was conducted using three evaluation metrics: MAE, RMSE, and MAPE. The research results show that the rice price prediction model using LSTM has fairly good performance based on evaluation metrics, with MAE of 0.141, MAPE of 1.256%, and RMSE of 0.205.

**Keywords:** *Machine Learning*, Artificial Intelligence, *Long Short-Term Memory* (LSTM), Price Prediction

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



**Corresponding Author:**

E-mail : [ashariy61@gmail.com](mailto:ashariy61@gmail.com)

## 1. PENDAHULUAN

Pada saat ini negara Indonesia sedang dihadapkan pada suatu permasalahan yang cukup sulit yang berimbas pada kesejahteraan warganya yaitu masalah kebutuhan pangan. Terpenuhinya kebutuhan pangan merupakan salah satu hal yang penting dalam kesejahteraan hidup Masyarakat. Ketidakstabilan harga dan kebijakan pemerintah membuat kebutuhan ini terkadang menjagi sulit terpenuhi (Sanjaya & Heksaputra, 2020). Masyarakat Indonesia sebagian besar bermata pencaharian sebagai petani. Kesuburan lahan pertanian di Indonesia dikarenakan Lokasi negara berada di zona iklim tropis, sehingga memungkinkan terjadinya pelapukan batuan secara sempurna dan menghasilkan tanah yang bernutirsi (Ayun et al., 2020). Zona pertanian Indonesia berfungsi untuk meningkatkan perekonomian serta pemenuhan kebutuhan pokok pangan manusia (Sarbaini et al., 2023).

Beras adalah makanan pokok bagi masyarakat Indonesia. Kenaikan harga beras yang terjadi di perdagangan besar di Indonesia menjadi masalah yang penting dalam konteks ekonomi, karena berpotensi mempengaruhi kemampuan masyarakat untuk membeli dan daya produksi petani (Natasya et al., 2021). Dalam penelitian yang dilakukan (Angraini et al., 2022) faktor-faktor yang memberikan pengaruh terhadap permintaan beras di Indonesia adalah harga beras, dan rata-rata pengeluaran, hal ini dibuktikan dengan hasil f-statistik sebesar 10.18965 menunjukkan bahwa dalam kurun waktu 2010-2020, penyebab utama permintaan beras di Indonesia mencakup harga dan rata-rata pengeluaran pangan.


Fluktuasi harga beras dapat mempengaruhi kesejahteraan masyarakat seiring bertumbuhnya jumlah penduduk Indonesia. Perubahan harga beras dapat dipengaruhi berbagai faktor seperti populasi, tingkat inflasi, tingkat produksi, tingkat konsumsi, dan luas panen (Khairuddin et al., 2022). Perubahan cuaca yang tidak pasti

juga dapat berpengaruh pada produksi beras. Berdasarkan (Harvian & Yuhan, 2021) semakin buruk perubahan iklim yang terjadi akan mengakibatkan ketahanan pangan disuatu wilayah menurun.

Prediksi harga beras sangat penting, namun sulit dilakukan dengan metode konvensional karena dinamika data yang kompleks. *Long Short-Term Memory* (LSTM) merupakan solusi yang menjanjikan berkat kemampuannya menangkap pola *non-linear* dan dependensi jangka panjang dalam data *time series* seperti harga beras. Data *time series* merupakan serangkaian kejadian yang tercatat dalam interval waktu tertentu, mulai dari hari hingga tahun, dan dapat dimanfaatkan untuk keperluan penelitian (Setiawan et al., 2023). Berdasarkan penelitian oleh (Selle et al., 2022) yang membandingkan algoritma RNN dan LSTM, berkesimpulan bahwa LSTM memiliki kemampuan yang lebih unggul dalam meminimalkan *error*, khususnya untuk melakukan prediksi pada periode yang lebih panjang di data *time series*. Begitu juga pada penelitian oleh (Jaelani, 2022) dimana hasil *forecasting* produk gula menggunakan dua algoritma yang berbeda yaitu LSTM dan regresi linier memperlihatkan bahwa tingkat error pada LSTM lebih. Pada penelitian yang dilakukan (Meriani & Rahmatulloh, 2024) menunjukkan bahwa model LSTM memiliki performa yang lebih baik dibandingkan model GRU untuk melakukan prediksi pada data harga emas. Penelitian oleh (Arfan & ETP, 2020) menunjukkan bahwa performa algoritma LSTM lebih baik dibandingkan algoritma SVR dalam memprediksi harga saham, dimana algoritma LSTM memiliki tingkat kesalahan yang lebih kecil. Dengan hanya menggunakan data historis harga beras dan cuaca harian, LSTM diharapkan dapat menghasilkan prediksi harga beras dengan baik.

## 2. METODE PENELITIAN

Metode yang digunakan pada penelitian ini berdasarkan beberapa proses yang meliputi, pengumpulan data yang mencakup data harga beras dan data cuaca harian dari tahun 2017 – 2024, *preprocessing data*, pembuatan model LSTM, melakukan training terhadap model, testing dan evaluasi model. Detail alur penelitian yang digunakan dapat dilihat pada Gambar 1. Berikut.



Gambar 1. Alur Penelitian

## 2.1. Pengumpulan Data

Data yang dipakai untuk penelitian ini merupakan data harga beras dan data cuaca harian di Jawa Tengah pada rentang tahun 2017 – 2024. Data harga beras diperoleh dari *website* PIHPS Nasional (Pusat Informasi Harga Pangan Strategis Nasional) dan untuk data cuaca berasal dari *website* BMKG. Data cuaca berdasarkan hasil pengamatan yang dilakukan oleh Stasiun Meteorologi Ahmad Yani. Terdapat 2682 baris data yang berhasil didapatkan. Data sebelum dilakukan *Preprocessing* seperti dapat dilihat pada Gambar 2. Berikut.

|      | Tanggal    | Tavg | RH_avg | RR     | ss  | Harga |
|------|------------|------|--------|--------|-----|-------|
| 0    | 22-06-2017 | 28.3 | 79.0   | 9.5    | 4.7 | 9.95  |
| 1    | 23-06-2017 | 29.2 | 69.0   | 0.0    | 8.0 | 9.95  |
| 2    | 24-06-2017 | 27.7 | 74.0   | 0.0    | 8.4 | 9.95  |
| 3    | 25-06-2017 | 27.3 | 77.0   | 5.2    | 4.0 | 9.95  |
| 4    | 26-06-2017 | 28.4 | 75.0   | 8888.0 | 6.8 | 9.95  |
| ...  | ...        | ...  | ...    | ...    | ... | ...   |
| 2677 | 20-10-2024 | 26.8 | 83.0   | 25.0   | 8.0 | 13.60 |
| 2678 | 21-10-2024 | 29.0 | 69.0   | 1.3    | 3.9 | 13.60 |
| 2679 | 22-10-2024 | 29.7 | 69.0   | 0.2    | 8.0 | 13.60 |
| 2680 | 23-10-2024 | 29.8 | 66.0   | 0.2    | 8.0 | 13.60 |
| 2681 | 24-10-2024 | 29.9 | 66.0   | 0.0    | 6.6 | 13.60 |

2682 rows x 6 columns

Gambar 2. Data Harga Beras dan Cuaca

Terdapat 6 atribut yang digunakan, yaitu Tanggal, Tavg (Temperatur rata-rata (°C)), RH\_avg (Kelembapan rata-rata), RR (Curah hujan (mm)), ss (Lamanya penyinaran matahari (jam)), dan Harga.

## 2.2. Preprocessing Data

Tahap *preprocessing data* dilakukan untuk memastikan data bersih. Pemrosesan data untuk mengatur waktu dan menghapus data yang tidak relevan, data harus disiapkan dalam format yang dapat digunakan oleh model LSTM (Utama, 2023). Adapun proses *preprocessing data* yang dilakukan antara lain, mengisi *NaN value* pada setiap kolom dan nilai 8888 pada setiap baris dengan interpolasi. Seperti pada penelitian oleh (Faisal Muhammad & Irawan, 2023) dimana interpolasi dilakukan untuk mengatasi data yang kosong, dengan cara menghitung nilai tengah dari dua data terdekat yang terdeteksi dan tidak bernilai 0, sehingga dapat menghasilkan estimasi nilai yang digunakan untuk mengisi nilai kosong tersebut. Rumus interpolasi data dapat dilihat pada persamaan (1) berikut:

$$y = y_1 + \frac{y_2 - y_1}{x_2 - x_1} (x - x_1) \quad (1)$$

Keterangan:

y = hasil interpolasi

x = variable bebas

x<sub>1</sub>, y<sub>1</sub> = nilai titik tertentu

x<sub>2</sub>, y<sub>2</sub> = nilai titik lainnya

Setelah itu dilakukan proses ekstraksi fitur tanggal menjadi beberapa fitur, yaitu harian, mingguan, bulanan, dan tahunan. Tujuan dari ekstraksi fitur tanggal ini agar model dapat menangkap pola waktu yang lebih dalam dari data. Proses selanjutnya adalah melakukan normalisasi data. Normalisasi dilakukan untuk menghindari perbedaan nilai yang besar antar data yang dapat mempengaruhi model dalam bekerja dengan optimal. Normalisasi pada penelitian ini dilakukan dengan mengubah nilai data dengan batas antara nilai 0 – 1 menggunakan *Min-Max Scaler*. Berdasarkan penelitian oleh (Yusuf, 2022) Rumus normalisasi data dapat dilihat pada persamaan berikut:

$$y = \frac{(x - x_{min})}{x_{max} - x_{min}} \quad (2)$$

Keterangan:

y = hasil normalisasi

$x$  = data yang di normalisasi


$x_{\min}$  = nilai minimum

$x_{\max}$  = nilai maksimum

Setelah normalisasi, data kemudian dibagi 2 set, yaitu data pelatihan (*data training*) sebanyak 80% dan data pengujian (*data testing*) sebanyak 20%.

### 2.3 Model LSTM

LSTM (*Long Short-Term Memory*) merupakan salah satu bagian dari arsitektur RNN (*Recurrent Neural Network*) yang dikembangkan untuk menangani masalah pada RNN, yaitu *exploding gradient* dan *vanishing gradient* saat mempelajari data dalam jangka rentetan waktu yang panjang. oleh karena itu, LSTM sesuai untuk diterapkan pada kasus prediksi maupun klasifikasi yang melibatkan data *time series* (Tholib et al., 2023). LSTM memperkenalkan unit memori serta mekanisme gerbang untuk menangkap ketergantungan jangka panjang dalam urutan data. Nama "*long short-term memory*" berasal dari jaringan RNN sederhana yang memiliki memori jangka panjang berupa bobot (*weights*), yang berubah secara bertahap selama proses pelatihan, menyimpan informasi umum mengenai data pelatihan. Selain itu, RNN juga memiliki memori jangka pendek dalam bentuk aktivasi sementara, yang mengalir dari satu *node* ke *node* berikutnya (Okut, 2021). Arsitektur LSTM seperti pada Gambar 3. Berikut.



Sumber: (Fang & Shao, 2022)

Gambar 3. Arsitektur LSTM

Seperti yang ditunjukkan dalam arsitektur LSTM (Gambar 3), bahwa arsitektur jaringan saraf untuk blok LSTM mendemonstrasikan bahwa jaringan LSTM

memperluas memori RNN dan dapat secara selektif mengingat atau melupakan informasi melalui struktur yang disebut *cell states* dan tiga gerbang. Dengan demikian, selain memiliki *hidden state* seperti pada RNN, blok LSTM biasanya memiliki empat lapisan tambahan. Lapisan-lapisan ini disebut *cell state* ( $C_t$ ), *input gate* ( $i_t$ ), *output gate* ( $o_t$ ), dan *forget gate* ( $f_t$ ). setiap lapisan memiliki cara untuk berinteraksi satu sama lain dengan cara sangat khusus untuk menghasilkan informasi dari data pelatihan (Okut, 2021). Berikut langkah-langkah pada LSTM dalam memproses masukannya dalam penelitian (Kholifatullah & Prihanto, 2023).

Langkah pertama yang dilakukan adalah menentukan informasi mana yang akan disimpan atau dihapus dalam sel memori dengan memanfaatkan fungsi *sigmoid*, yang disebut *forget gate*  $f_t$ .

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

Langkah kedua adalah menentukan informasi yang akan disimpan dalam *cell state*. *Input gate* terdiri dari dua bagian, yaitu *input gate* dan *tanh layer*. *Input gate layer*  $i_t$  berfungsi untuk menentukan nilai yang akan diperbarui menggunakan fungsi aktivasi *sigmoid*, sedangkan *tanh layer*  $\tilde{C}_t$  menghasilkan kandidat nilai baru dengan fungsi aktivasi *tanh*.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

Langkah selanjutnya adalah memperbarui *cell state* lama menjadi *cell state* baru. Pembaruan ini dilakukan dengan mengalikan *cell state* sebelumnya dengan persamaan (3), kemudian menambahkan hasil dari langkah kedua, yaitu persamaan (4) dan persamaan (5).

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (6)$$

Langkah terakhir adalah menentukan *output* akhir. Pertama, lapisan *sigmoid* menetapkan bagian dari *cell state* yang akan dijadikan *output*. Selanjutnya, *cell state* tersebut diproses melalui *tanh layer* dan hasilnya dikalikan dengan *output* dari lapisan *sigmoid*.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

$$h_t = o_t * \tanh(C_t) \quad (8)$$

Pada penelitian ini untuk mendapatkan model yang optimal dilakukan *training* dengan menggunakan *hyperparameter tuning* dari *Keras Tuner*. Referensi untuk eksperimen *hyperparameter* didasarkan pada penelitian (Sher et al., 2023) untuk meminimalkan komputasi yang dilakukan, batasan dari *hyperparameter* yang berbeda dipertimbangkan selama optimasi *grid search* pada arsitektur LSTM, antara lain *Optimizer*, jumlah *LSTM layers*, *Batch size*, dan *activation function*. Hingga didapatkan model dengan nilai loss terkecil seperti pada Gambar 4. berikut.

| Layer (type)        | Output Shape    | Param # |
|---------------------|-----------------|---------|
| lstm (LSTM)         | (None, 10, 110) | 52,360  |
| dropout (Dropout)   | (None, 10, 110) | 0       |
| lstm_1 (LSTM)       | (None, 10, 45)  | 28,080  |
| dropout_1 (Dropout) | (None, 10, 45)  | 0       |
| lstm_2 (LSTM)       | (None, 35)      | 11,340  |
| dropout_2 (Dropout) | (None, 35)      | 0       |
| dense (Dense)       | (None, 1)       | 36      |


Gambar 4. Model LSTM yang digunakan

Pada model tersebut terdapat 3 layer LSTM dimana tiap layer memiliki unit secara berurutan 110, 45 dan 35 unit. Diikuti layer *Dropout* pada setiap layer LSTM dan terakhir layer *Dense* yang digunakan untuk membuat output terakhir dari LSTM menjadi satu nilai akhir yang diprediksi.

## 2.4 Training

Setelah model LSTM selesai dibuat selanjutnya adalah proses *training* menggunakan data yang sudah dilakukan *preprocessing* sebelumnya. Proses *training* ini menghasilkan nilai berupa dan diagram nilai *Training Loss* dan *Validation Loss*. Diagram hasil *training* terdapat pada Gambar 5. Berikut.





Gambar 5. Hasil Training Model

## 2.5 Testing dan Evaluasi

Pengujian ini dilakukan dengan menggunakan metrik evaluasi. Metrik evaluasi dipergunakan untuk mengukur kinerja prediksi dari sebuah model. Dalam model deret waktu (*time series*), evaluasi dilakukan dengan cara menghitung *error* yang dihasilkan model. Metrik yang umum digunakan untuk evaluasi model deret waktu (*time series*) antara lain *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) (Tholib et al., 2023).

Cara kerja MAE dengan mengambil nilai absolut dari setiap nilai, sehingga nilai negative hilang.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i|$$

Cara kerja RMSE dengan mengukur tingkat kesalahan pada hasil prediksi. Apabila nilai RMSE (mendekati 0), prediksi yang dihasilkan akan semakin akurat.

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


Cara kerja MAPE adalah dengan melakukan perhitungan pada nilai rata-rata absolut *error* dan mengalikan dengan 100%. Fungsi MAPE untuk mengukur kesalahan prediksi dalam bentuk persentase.

$$MAPE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n \cdot y_i} \times 100\%$$

### 3. HASIL DAN PEMBAHASAN

Berdasarkan Gambar 5. model LSTM yang telah dilatih dan diuji menunjukkan bahwa nilai *Loss* yang dihasilkan cukup baik, pada data latih terjadi penurunan yang signifikan dari 0.0554 pada epoch pertama hingga mencapai nilai terendah sebesar 0.0021 pada epoch ke 50. Nilai *loss* pada data validasi juga menurun dari 0.0293 pada epoch pertama menurun hingga 0.0014 pada epoch ke 50, hal ini menunjukkan bahwa model mampu mempelajari pola data latih dengan baik tanpa *overfitting*, berkat pemanfaatan *Dropout* dan *Early Stopping*.

Hasil evaluasi model menggunakan metrik evaluasi pada data pengujian menunjukkan hasil yang cukup baik. Metrik ini memperlihatkan bahwa model yang dibuat mampu melakukan prediksi dengan cukup baik berdasarkan nilai *Mean Absolute Error* (MAE): 0.141 dan *Mean Absolute Percentage Error* (MAPE): 1.256%, dimana nilai tersebut tergolong relatif rendah. *Root Mean Squared Error* (RMSE) sebesar 0.205 juga menunjukkan bahwa variasi prediksi model cenderung kecil, menandakan prediksi yang baik pada nilai target. Hasil perbandingan harga prediksi dan harga sebenarnya terdapat pada Gambar 6. Berikut.



Gambar 6. Hasil prediksi model dengan harga sebenarnya

Berdasarkan Gambar 6. model yang dikembangkan mampu melakukan prediksi yang cukup baik, dimana grafik harga sebenarnya dengan harga prediksi memiliki pola yang hampir serupa. Hasil dari pelatihan ini menunjukkan bahwa kombinasi model LSTM dengan *dropout* dan *hyperparameter tuning* pada lapisan LSTM, *dropout*, dan *learning rate* berhasil meminimalkan nilai *error* pada data validasi.

Selama pelatihan, nilai *loss* menurun secara konsisten, menandakan bahwa model berhasil mempelajari pola data yang ada dengan baik tanpa mengalami *overfitting*, terlihat dari nilai *val\_loss* yang terus menurun meskipun setelah beberapa *epoch* nilai *loss* pada data latih mencapai titik yang stabil.

Setelah pembuatan model, pelatihan, dan pengujian dilakukan, selanjutnya dilakukan eksperimen dengan menguji model dengan memprediksi dan membandingkan harga beras 7 hari setelah tanggal terakhir pada dataset. Hasil eksperimen terdapat pada Tabel 1. berikut.

Tabel 1. Tabel hasil eksperimen

| Tanggal    | Harga Prediksi | Harga Asli |
|------------|----------------|------------|
| 25-10-2024 | 12.433         | 13.600     |
| 26-10-2024 | 12.431         | 13.600     |
| 27-10-2024 | 12.429         | 13.600     |
| 28-10-2024 | 12.428         | 13.600     |
| 29-10-2024 | 12.433         | 13.600     |
| 30-10-2024 | 12.431         | 13.600     |
| 31-10-2024 | 12.429         | 13.550     |

Berdasarkan hasil eksperimen, prediksi harga beras yang dilakukan model memiliki kemiripan dengan harga asli, dimana harga cenderung stabil selama 7 hari.

#### 4. KESIMPULAN

Penelitian ini menghasilkan model prediksi berbasis *Long Short-Term Memory* (LSTM) yang cukup baik dalam mengolah data *time series*, hal ini dibuktikan dengan hasil kinerja yang cukup baik berdasarkan nilai *Mean Absolute Error* (MAE) sebesar 0.141, *Mean Absolute Percentage Error* (MAPE) sebesar 1.256%, dan *Root Mean Squared Error* (RMSE) sebesar 0.205. Melalui teknik *hyperparameter tuning* yang mengoptimalkan arsitektur model, *dropout*, dan *learning rate*, serta penambahan *early stopping* untuk mencegah *overfitting*, model ini mampu menghasilkan prediksi yang cukup baik dan stabil.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing Universitas Teknologi Yogyakarta yang telah memberi dukungan terhadap penelitian ini.

## PUSTAKA

- Angraini, R., Ima Amaliah, & Meidy Haviz. (2022). Pengaruh Harga Beras, Pendapatan Perkapita, Jumlah Penduduk dan Impor Beras terhadap Permintaan Beras di Indonesia Tahun 2010-2020. *Bandung Conference Series: Economics Studies*, 2(1). <https://doi.org/10.29313/bcses.v2i1.1087>
- Arfan, A., & ETP, L. (2020). Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia. *PETIR*, 13(1). <https://doi.org/10.33322/petir.v13i1.858>
- Ayun, Q., Kurniawan, S., & Saputro, W. A. (2020). Perkembangan Konversi Lahan Pertanian Di Bagian Negara Agraris. *Vigor: Jurnal Ilmu Pertanian Tropika Dan Subtropika*, 5(2). <https://doi.org/10.31002/vigor.v5i2.3040>
- Faisal Muhammad, T. A., & Irawan, M. I. (2023). Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang). *Jurnal Sains Dan Seni ITS*, 12(1). <https://doi.org/10.12962/j23373520.v12i1.106892>
- Fang, L., & Shao, D. (2022). Application of Long Short-Term Memory (LSTM) on the Prediction of Rainfall-Runoff in Karst Area. *Frontiers in Physics*, 9. <https://doi.org/10.3389/fphy.2021.790687>
- Harvian, K. A., & Yuhan, R. J. (2021). Kajian Perubahan Iklim Terhadap Ketahanan Pangan. *Seminar Nasional Official Statistics*, 2020(1), 1052–1061. <https://doi.org/10.34123/semnasoffstat.v2020i1.593>
- Jaelani, T. (2022). Machine Learning untuk Prediksi Produksi Gula Nasional. *JMPM (Jurnal Material Dan Proses Manufaktur)*, 6(1). <https://doi.org/10.18196/jmpm.v6i1.14897>
- Khairuddin, K., Machfudz, M., & Syakir, F. (2022). Faktor-Faktor Yang Mempengaruhi Fluktuasi Harga Beras Di Kota Malang. *Jurnal Sosial Ekonomi Pertanian Dan Agribisnis*, 10(4).
- Kholifatullah, B. A. H., & Prihanto, A. (2023). Penerapan Metode Long Short Term Memory Untuk Klasifikasi Pada Hate Speech. *Journal of Informatics and Computer Science (JINACS)*. <https://doi.org/10.26740/jinacs.v4n03.p292-297>
- Meriani, A. P., & Rahmatulloh, A. (2024). Perbandingan Gated Recurrent Unit (Gru) Dan Algoritma Long Short Term Memory (Lstm) Linear Refression Dalam Prediksi Harga Emas Menggunakan Model Time Series. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(1). <https://doi.org/10.23960/jitet.v12i1.3808>
- Natasya, Musdalifah, S., & Andri. (2021). Prediksi Harga Beras Di Tingkat Perdagangan Besar Indonesia Menggunakan Algoritma Backpropagation. *Jurnal Ilmiah Matematika Dan Terapan*, 18(2). <https://doi.org/10.22487/2540766x.2021.v18.i2.15688>
- Okut, H. (2021). Deep Learning for Subtyping and Prediction of Diseases: Long-Short Term Memory. In *Deep Learning Applications*. <https://doi.org/10.5772/intechopen.96180>
- Sanjaya, F. I., & Heksaputra, D. (2020). Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 7(2). <https://doi.org/10.35957/jatisi.v7i2.388>
- Sarbaini, S., Yanti, D., & Nazaruddin. (2023). Prediksi Harga Beras Belida Di Kota Pekanbaru Menggunakan Fuzzy Time Series Cheng. *Jurnal Teknologi Dan Manajemen Industri Terapan*, 2(3). <https://doi.org/10.55826/tmit.v2i3.183>
- Selle, N., Yudistira, N., & Dewi, C. (2022). Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 9(1). <https://doi.org/10.25126/jtiik.2022915585>
- Setiawan, D., Stefani, K., Shandy, Y. J., & Patra, C. A. F. (2023). Sistem Analisa Harga Saham Menggunakan Algoritma Long Short Term Memory (LSTM). *Media Informatika*, 21(3). <https://doi.org/10.37595/mediainfo.v21i3.159>
- Sher, M., Minallah, N., Ahmad, T., & Khan, W. (2023). Hyperparameters analysis of long short-term memory architecture for crop classification. *International Journal of Electrical and Computer Engineering*, 13(4). <https://doi.org/10.11591/ijece.v13i4.pp4661-4670>

- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). Prediksi Harga Emas Menggunakan Metode Lstm Dan Gru. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3).  
<https://doi.org/10.23960/jitet.v11i3.3250>
- Utama, H. (2023). Pendekatan Deep Learning Menggunakan Metode Lstm Untuk Prediksi Harga Bitcoin. *The Indonesian Journal of Computer Science Research*, 2(2).  
<https://doi.org/10.59095/ijcsr.v2i2.77>
- Yusuf, A. (2022). Prediksi Indeks Harga Saham Gabungan (Ihsg) Menggunakan Long Short-Term Memory. *Epsilon: Jurnal Matematika Murni Dan Terapan*, 15(2).  
<https://doi.org/10.20527/epsilon.v15i2.5026>