



Tersedia Online : <http://e-journals.unmul.ac.id/>

ADOPSI TEKNOLOGI DAN SISTEM INFORMASI (ATASI)

Alamat Jurnal : <http://e-journals2.unmul.ac.id/index.php/atasi/index>



Perbandingan Akurasi LSTM, ARIMA dan Random Forest untuk Prediksi Harga Beras Medium Indonesia

Oktaria Indi Cahyani ¹⁾, Tua Delima Sitompul ^{2)*}, Faizul Anwar Wandu ³⁾, Cella Auzia Nugraha ⁴⁾, Nur Fadhilah ⁵⁾, Havaluddin ⁶⁾, Novianti Puspitasari ⁷⁾

Informatika, Fakultas Teknik, Universitas Mulawarman

E-Mail : oktariaindi@gmail.com ¹⁾; delimasitompul514@gmail.com ²⁾; faizulanwarwandi@gmail.com ³⁾; celliaauzianugraha@gmail.com ⁴⁾; fadhilnur246@gmail.com ⁵⁾; havaluddin@unmul.ac.id ⁶⁾; novipuspitasari@unmul.ac.id ⁷⁾;

ARTICLE INFO

Article history:

Received : 03-12-2025

Revised : 08-12-2025

Accepted : 24-04-2026

Available online : 29-04-2026

Keywords:

Rice Price

Arima

Random Forest

LSTM

Time Series Forecasting

Kata Kunci :

Harga Beras

Arima

Random Forest

LSTM

Peramalan Deret Waktu

ABSTRACT

This study investigated the effectiveness of forecasting the national average price of Grade II rice using weekly data (January 2022–December 2024) by comparing three methods: ARIMA, Random Forest (RF), and Long Short-Term Memory (LSTM). The study process includes data preprocessing, model development, and evaluation using RMSE, MAE, and MAPE metrics. Although ARIMA is suitable for linear patterns and LSTM is effective for long-term dependencies, Random Forest exhibits superior performance in handling nonlinear patterns and price fluctuations. The results of the evaluation showed that RF achieved the highest accuracy with RMSE 0.08, MAE 0.06, and MAPE 0.38%, outperforming LSTM (MAPE 0.51%) and ARIMA (MAPE 0.73%). Based on this advantage, RF is used to predict prices in the next twelve weeks, resulting in a stable estimate between Rp15,322 to Rp15,326. This finding highlights the effectiveness of the ensemble learning method (Random Forest) in food price forecasting and is intended as the basis for policy recommendations for stabilizing national rice prices.

ABSTRAK

Penelitian ini menyelidiki efektivitas peramalan harga rata-rata nasional beras medium II menggunakan data mingguan (Januari 2022–Desember 2024) dengan membandingkan tiga metode: ARIMA, Random Forest (RF), dan Long Short-Term Memory (LSTM). Proses studi meliputi prapemrosesan data, pengembangan model, dan evaluasi menggunakan metrik RMSE, MAE, dan MAPE. Meskipun ARIMA cocok untuk pola linear dan LSTM efektif untuk ketergantungan jangka panjang, Random Forest menunjukkan kinerja superior dalam menangani pola nonlinier dan fluktuasi harga. Hasil evaluasi menunjukkan RF mencapai akurasi tertinggi dengan RMSE 0,08, MAE 0,06, dan MAPE 0,38%, mengungguli LSTM (MAPE 0,51%) dan ARIMA (MAPE 0,73%). Berdasarkan keunggulan ini, RF digunakan untuk memprediksi harga dalam dua belas minggu mendatang, menghasilkan estimasi yang stabil antara Rp15.322 hingga Rp15.326. Penemuan ini menyoroti efektivitas metode *ensemble learning* (Random Forest) dalam peramalan harga pangan dan ditujukan sebagai dasar rekomendasi kebijakan stabilisasi harga beras nasional.

2026 Adopsi Teknologi dan Sistem Informasi (ATASI) with CC BY SA license.

1. PENDAHULUAN

Dalam beberapa tahun terakhir, dinamika perubahan iklim dan ketidakstabilan cuaca semakin menunjukkan dampak nyata terhadap sektor pertanian. Kondisi ini berpengaruh langsung terhadap proses produksi dan distribusi berbagai komoditas pangan, terutama padi dan beras untuk Prediksi Harga Beras di Indonesia. (Ericko et al., n.d.). Harga beras sangat sensitif terhadap variabilitas cuaca seperti perubahan temperatur, kelembapan, dan curah hujan karena elemen-elemen ini dapat memengaruhi hasil panen dan ketersediaan pasokan di pasar. Ketidakpastian pola

*) Corresponding Author

<https://doi.org/10.30872/atasi.v5i1.4300>

2026 Adopsi Teknologi dan Sistem Informasi (ATASI) with CC BY SA license.

iklim juga dapat mengganggu jadwal tanam dan panen, sehingga berdampak terhadap stabilitas harga dan pasokan pangan nasional (Hidayat & Wibisonya, 2024).

Seiring kemajuan teknologi dan ketersediaan data historis yang semakin banyak, kini data historis tersebut dapat digunakan untuk prediksi harga beras menggunakan pendekatan berbasis data (Santoso et al., n.d.) (Theofilou et al., 2025). Prediksi yang akurat dan efektif menjadi sangat penting untuk mengantisipasi fluktuasi harga beras (Azizah Muzakir & Yahya, 2025). Berbagai metode peramalan telah diterapkan, mulai dari model statistik klasik hingga algoritma kecerdasan buatan.

Penelitian sebelumnya menunjukkan bahwa berbagai metode telah diterapkan untuk memprediksi harga beras di Indonesia, namun masing-masing masih memiliki keterbatasan. Studi menggunakan LSTM dan ELM (Winata et al., 2023) mampu mencapai kesalahan prediksi di bawah 3% dan menunjukkan kemampuan model dalam menangkap pola jangka panjang, tetapi penelitian ini hanya dilakukan di satu wilayah, yakni Tasikmalaya, serta tidak membandingkan metode tersebut dengan pendekatan non-neural seperti ARIMA atau Random Forest. Pada sisi lain, studi ARIMA membuktikan efektivitas model statistik ini dalam menggambarkan tren dan fluktuasi harga beras di DKI Jakarta berdasarkan MAPE dan RMSE, namun tetap terbatas karena hanya mencakup satu wilayah dan kurang mampu menangani hubungan nonlinier dalam data harga pangan.

Di samping itu, pendekatan machine learning seperti Random Forest banyak digunakan dalam penelitian terbaru. Studi di Jawa Barat (Rasyid Muchtar, 2024) menunjukkan bahwa Random Forest memiliki akurasi prediksi jauh lebih baik dibanding regresi linier, meskipun penelitian tersebut juga hanya berfokus pada satu wilayah. Penelitian lainnya (Saputra et al., n.d.-a) membandingkan Random Forest, Linear Regression, dan Support Vector Machine untuk memprediksi harga beras premium di Indonesia dan menemukan bahwa Random Forest menjadi metode paling akurat untuk horizon jangka pendek, tetapi tidak menguji performa deep learning seperti LSTM. Selain itu, studi lintas-komoditas menegaskan keunggulan LSTM dalam memprediksi berbagai komoditas ekspor seperti kopi dan batubara, meskipun penelitian ini tidak secara spesifik membahas harga beras.

Berdasarkan telaah terhadap kelima penelitian terdahulu, masing-masing metode LSTM, ARIMA, dan Random Forest memiliki keunggulan dan keterbatasan tersendiri. Sebagian besar studi sebelumnya hanya menguji satu atau dua algoritma dalam ruang lingkup yang terbatas, baik dari sisi wilayah maupun periode waktu. Oleh karena itu, penelitian ini dilakukan untuk mengisi kesenjangan tersebut dengan membandingkan akurasi ketiga metode dalam memprediksi harga beras medium di Indonesia. Fokus penelitian ini adalah mengevaluasi kinerja dan kemampuan model dalam menangkap pola tren, musiman, serta fluktuasi harga dari waktu ke waktu (Santoso et al., n.d.), sehingga hasilnya diharapkan dapat memberikan rekomendasi metode prediksi yang paling efektif berbasis data historis untuk mendukung kebijakan stabilisasi harga beras di masa mendatang.

2. TINJAUAN PUSTAKA

Prediksi harga komoditas pangan pokok seperti beras medium II memegang peranan penting dalam kestabilan ekonomi, dan studi ini akan meninjau penelitian sebelumnya mengenai efektivitas model dan pendekatan machine learning yang akan digunakan dalam konteks peramalan harga komoditas.

A. Beras Medium

Beras medium merupakan salah satu kategori utama dalam klasifikasi mutu beras di Indonesia berdasarkan Standar Nasional Indonesia (SNI 6128:2020), yang membedakannya melalui parameter seperti derajat sosoh, kadar patah, butir menir, dan tingkat kebersihan fisik. Beras kategori ini diproduksi secara luas oleh penggilingan padi rakyat dan menjadi tipe beras yang paling banyak beredar di pasar untuk kebutuhan konsumsi rumah tangga sehari-hari (Amelia et al., 2023). Karakteristik mutu beras medium biasanya berada pada tingkat menengah, di mana kualitasnya lebih tinggi dibanding beras rendah namun masih berada di bawah mutu premium (Jumali & Liyanan, 2022). Keberadaan kategori ini penting dalam sistem pangan nasional karena proporsinya mendominasi peredaran komoditas beras di berbagai provinsi (Nurmeryteni, 2025).

Secara fisik, beras medium memiliki ciri khas berupa persentase butir patah yang lebih tinggi serta tingkat keseragaman warna yang lebih rendah dibandingkan beras premium, sebagaimana dijelaskan dalam penelitian (Supriyadi 2021, n.d.) yang melakukan klasifikasi mutu berdasarkan persentase butir pecah dan distribusi warna citra. Analisis mutu yang dilakukan oleh (Kobarsih & Dewi Indrasari, n.d.) menunjukkan bahwa kadar kapur dan pecahan beras berkontribusi besar terhadap penentuan kategori medium dalam sistem grading nasional. Sementara itu, penelitian agronomi oleh (Yuriyah et al., 2024) menyebutkan bahwa kualitas beras medium juga dipengaruhi varietas padi yang digunakan serta proses pascapanen seperti pengeringan dan penggilingan. Faktor-faktor tersebut menjadikan beras medium sebagai kategori yang memiliki variabilitas mutu cukup besar antarwilayah.

Dalam konteks konsumsi masyarakat, beras medium memainkan peran penting karena menjadi jenis yang paling banyak dipilih oleh rumah tangga Indonesia berkat ketersediaan yang luas dan kualitasnya yang dianggap memadai untuk kebutuhan harian Puji Lestari et al. 2023. Studi konsumsi pangan menunjukkan bahwa preferensi terhadap beras medium berkaitan dengan kebiasaan kuliner serta persepsi rumah tangga terhadap tekstur nasi yang dihasilkan (Pane et al., 2023). Selain itu, laporan Kementerian Pertanian dan berbagai kajian akademik mencatat bahwa distribusi beras medium melibatkan rantai pasok yang kompleks, mulai dari petani, penggilingan, pedagang besar, hingga pasar tradisional, sehingga kategori ini menjadi fokus dalam berbagai studi logistik beras di Indonesia. Dengan karakteristik mutu yang stabil dan ketersediaan yang luas, beras medium menjadi salah satu komoditas pangan paling strategis dalam mendukung kebutuhan konsumsi nasional.

B. Harga Beras

Harga beras di Indonesia merupakan salah satu indikator penting yang menentukan stabilitas pangan nasional mengingat beras menjadi komoditas utama konsumsi rumah tangga (Hafizah et al., 2020). Pergerakan harga beras dipengaruhi oleh berbagai faktor seperti produksi, distribusi, kondisi cuaca, biaya logistik, dan kebijakan pemerintah (Ugi Sugiharto, 2024). Berdasarkan data dari Pusat Informasi Harga Pangan Strategis (PIHPS), harga beras antarprovinsi menunjukkan disparitas yang cukup signifikan. Sebagai contoh, harga beras medium di Papua dapat mencapai Rp15.000 hingga Rp16.000 per kilogram, sementara di Jawa Tengah dan Jawa Timur yang merupakan sentra produksi padi, harga berada pada kisaran Rp11.000 hingga Rp12.000 per kilogram. Ketimpangan harga ini tidak hanya mencerminkan perbedaan kapasitas produksi dan efisiensi distribusi antardaerah, tetapi juga menimbulkan tantangan dalam upaya pemerataan akses pangan serta efektivitas implementasi kebijakan stabilisasi harga di tingkat nasional (Mahdi & Rianzani, 2025).

Selain ketimpangan spasial, harga beras juga menunjukkan kecenderungan berfluktuasi sepanjang tahun (Wibowo et al., 2025). Pada periode musim paceklik, harga cenderung meningkat karena pasokan menurun, sedangkan pada musim panen raya harga umumnya mengalami penurunan. Tren ini diperkuat oleh temuan beberapa studi yang menyoroti adanya pengaruh cuaca, pola tanam, dan dinamika pasokan terhadap perubahan harga beras di pasar domestik. Kondisi tersebut menjadikan peramalan harga beras sangat penting untuk mendukung strategi pemerintah dalam menjaga stabilitas pasokan dan meminimalkan potensi guncangan harga yang dapat berdampak pada kesejahteraan masyarakat, terutama kelompok berpendapatan rendah.

C. Random Forest

Random forest adalah algoritma machine learning yang mengikuti konsep supervised dalam pembentukan kelas pengklasifikasi. Algoritma ini menggabungkan hasil prediksi dari beberapa pohon keputusan. Random Forest terbentuk dari sekumpulan pohon keputusan. Secara keseluruhan, Random Forest menggabungkan hasil dari seluruh pohon Keputusan yang terbentuk selama proses pelatihan, menghasilkan keluaran kelas untuk tugas klasifikasi dan prediksi nilai rata-rata untuk model regresi (Saputra et al., n.d.-b)

Setiap pohon dalam Random Forest dibangun menggunakan subset acak dari fitur-fitur dalam dataset dan juga menggunakan teknik bootstrapping untuk menghasilkan variasi yang lebih besar. Proses penggabungan prediksi dari pohon-pohon ini dilakukan melalui voting atau averaging, sehingga menghasilkan prediksi akhir yang lebih stabil dan akurat (Fauzi et al., 2025). Keunggulannya terletak pada kemampuannya menangani data dengan jumlah variabel yang besar, mengolah hubungan non-linear, serta meminimalkan risiko overfitting (Muhtajuddin Danny et al. 2025).

D. LSTM

Long Short-Term Memory atau LSTM ini merupakan bentuk model dari Recurrent Neural Network atau RNN, LSTM muncul untuk menghindari permasalahan dari RNN yaitu masalah ketergantungan informasi jangka panjang. LSTM juga dikenal sebagai jaringan syaraf dengan arsitektur yang fleksibel, sehingga strukturnya dapat disesuaikan sesuai dengan kebutuhan aplikasi tertentu (Hadrianto et al., 2025). LSTM menggunakan mekanisme gating yang terdiri dari tiga komponen utama yaitu input gate, forget gate, dan output gate. Input gate menyaring informasi baru yang akan disimpan, forget gate membuang informasi yang tidak relevan, dan output gate mengontrol informasi yang akan diteruskan ke hidden state berikutnya. Pendekatan ini memungkinkan LSTM untuk menyimpan informasi jangka panjang dan melupakan informasi yang tidak berguna (Lim et al. 2025).

E. ARIMA

Autoregressive Integrated Moving Average (ARIMA) merupakan salah satu metode dalam runtun waktu yang digunakan untuk memodelkan data yang bersifat non-stasioner (Azizah Muzakir et al. 2025). Metode ARIMA telah terbukti efektif dalam menganalisis data deret waktu (time series) untuk memprediksi nilai masa depan berdasarkan data historis. Keunggulan metode ARIMA terletak pada kemampuannya menangani data yang tidak stasioner melalui proses differencing serta menggabungkan komponen autoregressive (AR) dan moving average (MA) untuk menghasilkan prediksi yang akurat (Izati Nisa et al., 2024).

Dasar pemikiran dari model ARIMA adalah pengamatan sekarang tergantung pada satu atau beberapa pengamatan sebelumnya. Dengan kata lain, model ini dibuat karena secara statis ada korelasi (dependen) antar deret pengamatan. Untuk melihat adanya dependensi antar pengamatan, dapat melakukan uji korelasi antar pengamatan yang biasa dikenal dengan fungsi autokorelasi (autocorrelation function/ACF). Model ARIMA terdiri dari tiga proses yaitu autoregressive, integrated, Moving Average dengan orde (p, d, q) dinotasikan sebagai ARIMA (p, d, q) (Mokosolang et al., n.d.).

F. Time Series Forecasting

Time series forecasting merupakan pendekatan analisis yang digunakan untuk memprediksi nilai di masa mendatang berdasarkan pola historis yang tersusun secara berurutan dalam dimensi waktu. Metode ini memanfaatkan informasi dari tren, musiman, siklus, serta fluktuasi acak untuk menghasilkan estimasi yang lebih akurat pada berbagai fenomena yang berubah dari waktu ke waktu. Dalam konteks komoditas pangan, Teknik peramalan deret waktu sangat penting karena harga biasanya dipengaruhi oleh kondisi eksternal seperti musim tanam, pola konsumsi, cuaca, dan dinamika pasar (Sihombing et al., 2024).

Model-model peramalan umumnya bekerja dengan mengidentifikasi hubungan matematis atau pola berulang dari data historis, baik melalui pendekatan statistik tradisional maupun metode berbasis pembelajaran mesin

(Andreas, n.d.). Pendekatan statistik biasanya fokus pada pola linear dan stasioner, sedangkan metode modern seperti machine learning dan deep learning mampu menangkap hubungan yang lebih kompleks dan nonlinear. Dengan kemampuan tersebut, analisis deret waktu menjadi salah satu teknik yang paling banyak digunakan dalam studi prediksi harga komoditas karena mampu memberikan gambaran mengenai potensi perubahan harga di masa depan.

G. RMSE

Nilai Root Mean Square Error (RMSE) adalah jumlah dari kesalahan kuadrat atau selisih antara nilai sebenarnya dengan nilai prediksi yang telah ditentukan (Tukiyat, 2022). RMSE sering digunakan dalam evaluasi performa model prediksi karena memberikan gambaran yang intuitif, ukuran yang menunjukkan besarnya kesalahan dalam hasil prediksi. Tujuan RMSE adalah untuk memperhatikan kesalahan besar (outlier), sehingga cocok untuk digunakan pada situasi tersebut, mengetahui kestabilan performa prediksi dalam jangka panjang (Rahmad firdiansyah & Asmunin, n.d.). RMSE dihitung menggunakan persamaan (1):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \dots\dots\dots(1)$$

Di mana:
Y = nilai hasil observasi
Ŷ = nilai hasil prediksi
i = urutan data pada database
n = jumlah data

H. MAE

Mean Absolute Error (MAE) adalah rata-rata selisih mutlak nilai sebenarnya (aktual) dengan nilai perkiraan (prediksi) (Nurani et al., 2023). MAE sendiri secara umum digunakan untuk pengukuran prediksi error pada analisis time series (Tukiyat, T., 2022). Tujuan MAE menunjukkan seberapa besar rata rata kesalahan absolut yang terjadi dalam unit yang sama dengan data, dengan memberikan bobot yang sama pada setiap kesalahan (Rahmad, F., & Asmunin., 2025). MAE dihitung menggunakan persamaan (2):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_j| \dots\dots\dots(2)$$

Di mana:
Ŷ = Nilai hasil Prediksi
Y = Nilai hasil Observasi

I. MAPE


Mean Absolute Percentage Error (MAPE) adalah rata – rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual (Prabowo et al., 2025). MAPE digunakan untuk menilai persentase kesalahan rata-rata dari hasil prediksi dibandingkan nilai yang sebenarnya (Tukiyat, 2022). Tujuan MAPE digunakan untuk menunjukkan rata-rata kesalahan dalam bentuk persentase, sehingga memudahkan interpretasi secara umum. Nilai MAPE yang semakin kecil menandakan akurasi model yang meningkat (Rahmad firdiansyah & Asmunin, n.d.). MAPE dihitung menggunakan Persamaan (3):

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_j}{y_i} \right| \dots\dots\dots(3)$$

Di mana:
Y1 = nilai aktual pada periode ke-i
Ŷt = nilai hasil prediksi pada periode ke-t
n = jumlah total data pengamatan

3. METODE PENELITIAN

Penelitian ini menerapkan pendekatan sistematis untuk memprediksi harga Beras Medium II menggunakan data deret waktu. Proses penelitian ini dimulai dari pengumpulan data, dilanjutkan dengan pra-pemrosesan data, pembangunan tiga model prediksi yang berbeda (ARIMA, Random Forest, dan LSTM), evaluasi komparatif performa model, hingga visualisasi dan penarikan kesimpulan seperti pada Gambar 1.



Gambar. 1 Diagram metode penelitian

A. Pengumpulan Data

Data yang digunakan merupakan data sekunder harga mingguan Beras Medium II yang diperoleh dari Pusat Informasi Harga Pangan Strategis Nasional (PIHPSN–BAPANAS). Periode data mencakup 3 Januari 2022 hingga 30 Desember 2024. Data mentah tersedia dalam format *wide*, di mana setiap kolom merepresentasikan satu provinsi (34 provinsi) sebagaimana ditampilkan pada Tabel 1.

Tabel. 1 Sampel Data Mentah

No	Provinsi (Rp)	03/ 01/ 2022	10/ 01/ 2022	17/ 01/ 2022	...	16/ 12/ 2024	23/ 12/ 2024	30/ 12/ 2024
1	Semua Provinsi	11,550	11,500	11,600	...	15,150	15,150	15,150
2	Aceh	10,050	10,150	10,050	...	13,600	13,650	13,700
3	Sumatera Utara	11,450	11,450	11,450	...	14,050	14,050	14,050
4	Sumatera Barat	13,450	13,450	13,400	...	17,500	17,500	17,500
5	Riau	12,200	12,200	12,200	...	16,100	16,100	16,100
...
30	Sulawesi Barat	9,800	9,800	9,850	...	13,150	13,150	13,150
31	Maluku	13,000	13,000	13,000	...	15,650	15,650	15,650
32	Maluku Utara	12,400	12,400	12,400	...	16,250	16,250	16,250
33	Papua	12,150	12,150	12,150	...	16,600	16,600	16,600
34	Papua Barat	10,250	10,250	10,250	...	16,150	16,150	16,150

B. Pra-Pemrosesan Data

Tahap pra-pemrosesan data Adalah proses untuk mengubah data mentah agar siap dianalisis dan berkualitas, proses ini terdiri dari beberapa langkah berikut:

1. Transformasi dan Agregasi Data

Data awal yang berbentuk *wide* (antar-provinsi) ditransformasi menjadi format *long* berdasarkan dimensi waktu. Selanjutnya, nilai harga nasional pada waktu ke-*t* (\bar{x}_t) dihitung sebagai rata-rata aritmatika dari seluruh provinsi $N = 34$ menggunakan Persamaan (4). Langkah ini menghasilkan satu seri data tunggal yang merepresentasikan fluktuasi harga nasional mingguan.

$$\bar{x}_t = \frac{1}{n} \sum_{i=1}^n x_t \dots\dots\dots(4)$$

2. Pemisahan Data

Data deret waktu dibagi secara kronologis menjadi data latih dan data uji menggunakan proporsi 80:20, Rincian periode waktu dan jumlah sampel untuk masing-masing kategori. Pada penelitian ini, diperoleh 125 sampel data latih sebagaimana yang tersaji di tabel 2 dan 32 sampel data uji yang tersaji di tabel 3.

Tabel 2. Data Latih

No	Provinsi (Rp)	03/ 01/ 2022	10/ 01/ 2022	17/ 01/ 2022	...	06/ 05/ 2024	13/ 05/ 2024	20/ 05/ 2024
1	Semua Provinsi	11,550	11,500	11,600	...	15,300	15,250	15,250
2	Aceh	10,050	10,150	10,050	...	13,650	13,650	13,650
3	Sumatera Utara	11,450	11,450	11,450	...	14,050	14,100	14,100
4	Sumatera Barat	13,450	13,450	13,400	...	17,650	17,400	17,600
5	Riau	12,200	12,200	12,200	...	15,750	15,900	15,950
...

No	Provinsi (Rp)	03/ 01/ 2022	10/ 01/ 2022	17/ 01/ 2022	...	06/ 05/ 2024	13/ 05/ 2024	20/ 05/ 2024
30	Sulawesi Barat	9,800	9,800	9,850	...	14,000	13,900	13,750
31	Maluku	13,000	13,000	13,000	...	16,000	16,000	15,900
32	Maluku Utara	12,400	12,400	12,400	...	16,250	16,250	16,250
33	Papua	12,150	12,150	12,150	...	17,350	17,350	17,350
34	Papua Barat	10,250	10,250	10,250	...	13,050	13,350	13,350

Tabel 3. Data Uji

No	Provinsi (Rp)	27/ 05/ 2024	03/ 06/ 2024	10/ 06/ 2024	...	16/ 12/ 2024	23/ 12/ 2024	30/ 12/ 2024
1	Semua Provinsi	15,200	15,200	15,300	...	15,150	15,150	15,150
2	Aceh	13,600	13,900	13,600	...	13,600	13,650	13,700
3	Sumatera Utara	14,100	14,100	14,250	...	14,050	14,050	14,050
4	Sumatera Barat	17,650	17,650	17,700	...	17,500	17,500	17,500
5	Riau	15,950	15,950	15,900	...	16,100	16,100	16,100
...
30	Sulawesi Barat	13,750	13,750	13,950	...	13,150	13,150	13,150
31	Maluku	16,000	16,200	16,100	...	15,650	15,650	15,650
32	Maluku Utara	16,250	16,250	15,000	...	16,250	16,250	16,250
33	Papua	17,350	17,350	17,350	...	16,600	16,600	16,600
34	Papua Barat	13,350	13,350	17,200	...	16,150	16,150	16,150

3. Normalisasi dan Segmentasi Data

Normalisasi diterapkan khusus untuk model LSTM menggunakan metode Min–Max sebagaimana Persamaan (5):

$$x^1 = \frac{x - x_{min}}{x_{max} - x_{min}} \dots\dots\dots(5)$$

Selanjutnya, data dibentuk menjadi sekuens dengan *time step* 12 sehingga setiap sampel pelatihan menggunakan 12 minggu data sebelumnya sebagai masukan. Tahapan ini tidak diterapkan pada ARIMA dan Random Forest.

C. Pembangunan Model

Tiga model prediksi dikembangkan dan dilatih menggunakan data latih untuk membandingkan kinerjanya dalam memproyeksikan harga Beras Medium II.

1. ARIMA (Autoregressive Integrated Moving Average)

Model ARIMA memodelkan komponen autoregressive, differencing, dan moving average. Berdasarkan evaluasi parameter, konfigurasi ARIMA (2,1,0) terpilih sebagai model yang paling sesuai untuk data. Model direalisasikan menggunakan pustaka statsmodels, dan pemilihan orde dilakukan berdasarkan nilai BIC. Konfigurasi terbaik diperoleh pada ARIMA(2, 1, 0).

2. Random Forest (RF)

Algoritma *Random Forest* memerlukan rekayasa fitur (*feature engineering*) agar dapat memproses data deret waktu. Pembentukan variabel input dilakukan melalui dua pendekatan:

- a) Fitur *Lag*: Variabel *lag* sebanyak 12 periode (*t-1* s.d *t-12*) dibuat untuk menangkap informasi harga dari 3 bulan (1 triwulan) sebelumnya.
- b) Fitur Kalender: Variabel waktu diekstraksi menjadi fitur numerik (Tahun, Bulan, Minggu ke-n) untuk menangkap pola musiman.

3. LSTM (Long Short-Term Memory)

Model *Deep Learning LSTM* dirancang untuk menangkap ketergantungan jangka panjang. Normalisasi data menggunakan teknik *MinMax Scaler* ke rentang [0, 1] dilakukan sebelum pelatihan untuk mempercepat konvergensi. Arsitektur jaringan terdiri dari dua lapisan LSTM bertumpuk (masing-masing 64 neuron), diikuti oleh lapisan *Dropout* sebesar 20% untuk regularisasi, dan diakhiri dengan satu lapisan *Dense* sebagai output. Algoritma optimasi Adam digunakan selama proses pelatihan sebanyak 100 *epoch*.

D. Evaluasi Model

Evaluasi dilakukan untuk mengukur kemampuan setiap model dalam memprediksi harga beras pada data uji. Tiga metrik digunakan dalam penelitian ini, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik ini dipilih karena mampu merepresentasikan tingkat kesalahan baik dalam satuan asli maupun persentase.


Nilai prediksi pada data uji dengan nilai aktual pada minggu yang bersesuaian. Perhitungan RMSE, MAE, dan MAPE dilakukan secara komputasional melalui fungsi evaluasi pada kode penelitian. Hasil ketiga metrik tersebut digunakan untuk menentukan model dengan performa terbaik, di mana model yang memiliki nilai kesalahan paling rendah dinyatakan sebagai model paling akurat.

4. HASIL DAN PEMBAHASAN

Data yang telah melalui tahapan pra-pemrosesan kemudian digunakan dalam proses pelatihan dan pengujian tiga model prediksi, yaitu ARIMA, Random Forest, dan LSTM. Masing-masing model dibangun dengan konfigurasi dan pendekatan yang berbeda untuk memprediksi harga Beras Medium II berdasarkan data historis mingguan. Tahap ini bertujuan untuk mengevaluasi sejauh mana setiap model mampu mempelajari pola fluktuasi harga dan menghasilkan prediksi yang mendekati nilai aktual. Oleh karena itu, dilakukan proses pengujian dan evaluasi performa dengan menggunakan beberapa metrik kesalahan, seperti Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE), guna menentukan model yang memiliki tingkat akurasi paling optimal.

A. Analisis Data Awal

Analisis data awal dimulai dengan memvisualisasikan data deret waktu yang akan digunakan dalam penelitian. Data ini merupakan harga rata-rata nasional Beras Medium II, yang diperoleh dari hasil agregasi (rata-rata) data 34 provinsi dari 03-01-2022 hingga 30-12-2024.



Gambar 2. Rata-rata Harga Beras Nasional

Berdasarkan plot tersebut, dapat diidentifikasi beberapa karakteristik kunci. Data secara jelas menunjukkan adanya tren kenaikan jangka panjang (upward trend), di mana harga konsisten meningkat dari sekitar Rp 10.500 pada awal 2022 menjadi di atas Rp 13.500 pada akhir 2024. Selain tren, terdapat pula indikasi kuat adanya pola musiman, yang ditandai dengan lonjakan harga signifikan pada kuartal pertama tahun 2023 dan 2024. Karakteristik lainnya adalah volatilitas (fluktuasi harga) yang tidak konstan; data tampak relatif stabil pada tahun 2022, namun menunjukkan fluktuasi yang jauh lebih tajam pada tahun 2023 dan 2024.

B. Hasil Preprocessing

Setiap model akan melewati pembagian data (*data splitting*), di mana 80% data sebagai data latih (*train_data*) dan 20% data lainnya sebagai data uji (*test_data*) yang akan dilanjutkan dengan pembuatan asitektur untuk tiap model. Data pada Tabel 2 akan digunakan sebagai data latih untuk membangun model dan data pada Tabel 3 digunakan sebagai data uji untuk mengukur kemampuan model terhadap data baru.

1. Hasil Preprocessing Model ARIMA

Model ARIMA menggunakan pendekatan *SARIMAX* yang menangani stasioneritas secara internal sehingga kebutuhan preprocessing relatif minimal. Data *train_data* [*'Harga'*] digunakan secara langsung sebagai input model. Tabel berikut menyajikan beberapa kombinasi parameter ARIMA beserta nilai BIC yang dihasilkan.

Tabel 2. Parameter Arima

Arima Order	BIC
ARIMA(0, 1, 0)	-306.694
ARIMA(0, 1, 1)	-343.019
ARIMA(0, 1, 2)	-360.304
ARIMA(1, 1, 0)	-380.728
ARIMA(1, 1, 1)	-387.142
ARIMA(1, 1, 2)	-387.582
ARIMA(2, 1, 0)*	-389.976
ARIMA(2, 1, 1)	-385.231
ARIMA(2, 1, 2)	-385.771

Berdasarkan nilai BIC, model terbaik dipilih dengan parameter order = (2,1,0). Selain itu, proses differencing orde pertama (d=1) diterapkan secara otomatis oleh model selama pelatihan untuk membuat data menjadi stasioner.

2. Hasil Preprocessing Model Random Forest

Model Random Forest memerlukan proses *feature engineering* untuk mengubah data waktu menjadi format supervised learning. Data latih diekstraksi fitur berbasis kalender (Tahun, Bulan, Minggu dalam Tahun, Hari dalam Minggu) dan fitur historis berupa *12 lags* (Harga lag1 hingga Harga lag12). Penambahan 12 lag memungkinkan model mempelajari pola harga hingga 12 periode ke belakang. Setelah semua fitur dibentuk, baris yang mengandung nilai kosong (akibat pergeseran lag) dihapus sehingga diperoleh matriks fitur X_{train_rf} dan target y_{train_rf} yang akan digunakan untuk pelatihan Random Forest.

3. Hasil Preprocessing Model LSTM

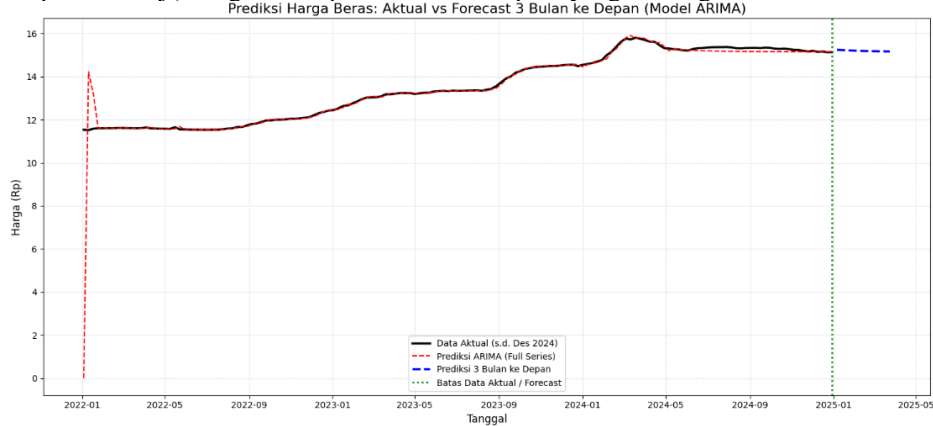
Model LSTM data melalui tranformasi multistahap. Differencing orde pertama akan diterapkan untuk memuat data bersifat stasioner yang selanjutnya hasil dari pada differencing dinormalisasikan menggunakan MinMaxScaler ke rentang [0,1] sebagai stabilitas pelatihan. Kemudian, data diubah menjadi sekuens menggunakan metode *sliding window* dengan $n_steps=12$. Hasilnya adalah data *latih* X_{train} (data 12 timesteps sebelumnya) dan y_{train} (data timestep saat ini). Terakhir, X_{train} di-reshape menjadi format tensor 3D [sampel, 12, 1] sesuai kebutuhan input pada model LSTM.

C. Hasil Pemodelan dan Evaluasi

Bagian ini menjelaskan hasil pelatihan dan pengujian model yang digunakan dalam penelitian, yaitu ARIMA, Random Forest, dan LSTM. Setiap model dievaluasi menggunakan metrik RMSE, MAE, dan MAPE.

1. Hasil dan Evaluasi Model Arima

Model ARIMA (2,1,0) diterapkan sebagai metode tradisional dalam analisis deret waktu untuk memprediksi harga Beras Medium II. Model ini dilatih menggunakan 80% data *training* dan diuji pada 20% data *testing*. Untuk melihat seberapa baik model ARIMA mampu mempelajari pola data, dilakukan perbandingan visual antara data aktual (harga asli pada data uji) dengan hasil prediksi model seperti yang ada di gambar 3.



Gambar 3. Hasil Pemodelan Arima

Pada Gambar 1 menampilkan perbandingan antara data aktual yang ditunjukkan oleh garis berwarna hitam dan hasil prediksi model ARIMA (2,1,0) yang direpresentasikan melalui garis merah putus-putus. Secara visual, terlihat bahwa garis prediksi berada sangat dekat dan hampir sepenuhnya berimpit dengan garis data aktual. Tingkat kedekatan ini menunjukkan bahwa model ARIMA (2,1,0) memiliki kemampuan pemodelan yang sangat baik, dengan selisih prediksi terhadap nilai aktual yang relatif kecil. Untuk menguatkan temuan visual tersebut dan memperoleh gambaran performa model secara kuantitatif, dilakukan evaluasi menggunakan metrik RMSE, MAE, dan MAPE. Ringkasan hasil evaluasi pada data uji disajikan pada Tabel 3.

Tabel 3. Evaluasi Performa Model Arima

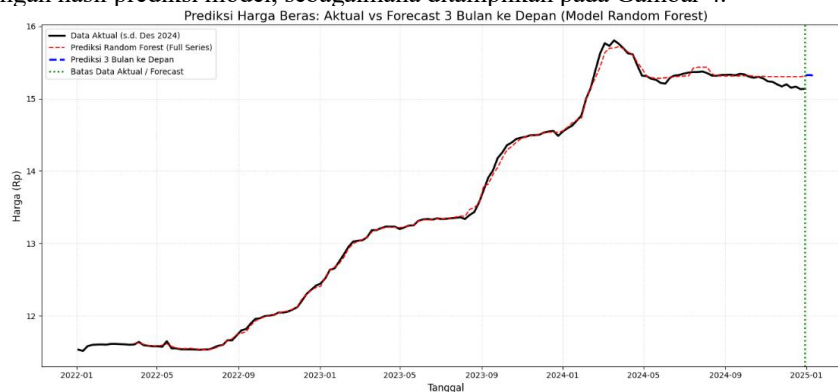
Matrix	Nilai
RMSE	0,13
MAE	0,11
MAPE	0,73

Tabel 2 mengonfirmasi secara kuantitatif apa yang telah ditunjukkan oleh Gambar 1. Nilai RMSE sebesar 0,13 dan MAE sebesar 0,11 tercatat sangat rendah. Nilai ini membuktikan bahwa rata-rata kesalahan prediksi model memang sangat kecil, sejalan dengan tampilan plot yang nyaris berimpitan. Lebih lanjut, nilai MAPE sebesar 0,73% (diasumsikan dari nilai 0,73 pada tabel) menegaskan performa model yang sangat baik. Nilai MAPE ini setara dengan tingkat akurasi prediksi sebesar 99,27% pada data uji.

2. Hasil dan Evaluasi Model Random Forest

Model Random Forest diterapkan sebagai metode berbasis ensemble learning untuk memprediksi harga Beras Medium II. Model ini dilatih menggunakan 80% data training dan diuji pada 20% data testing. Untuk melihat sejauh

mana Random Forest mampu mempelajari pola data, dilakukan perbandingan visual antara data aktual (nilai asli pada data uji) dengan hasil prediksi model, sebagaimana ditampilkan pada Gambar 4.



Gambar 4. Hasil Pemodelan Random Forest

Gambar 4 menampilkan perbandingan antara hasil prediksi model Random Forest (garis merah putus-putus) dan data aktual (garis hitam) pada data uji. Secara visual, model Random Forest menunjukkan tingkat kesesuaian (goodness-of-fit) yang sangat tinggi. Garis prediksi tampak hampir sepenuhnya berimpit dengan garis data aktual, menandakan bahwa model ini mampu mempelajari pola data dengan sangat baik. Random Forest dikenal memiliki kemampuan unggul dalam menangkap pola nonlinier serta fluktuasi halus pada data. Hal ini terlihat jelas pada grafik, di mana garis prediksi dapat mengikuti hampir seluruh puncak dan lembah kecil pada data aktual dengan tingkat presisi yang tinggi.

Kesesuaian visual yang sangat dekat ini mengindikasikan bahwa error prediksi yang dihasilkan oleh model Random Forest relatif kecil. Untuk mengonfirmasi temuan tersebut secara kuantitatif, hasil evaluasi menggunakan metrik RMSE, MAE, dan MAPE disajikan pada Tabel 4.

Tabel 4. Evaluasi Performa Model Random Forest

Matrix	Nilai
RMSE	0,08
MAE	0,06
MAPE	0,38

Tabel 3 memberikan gambaran lebih jelas mengenai kualitas prediksi model Random Forest. Nilai RMSE yang hanya mencapai 0,08 menunjukkan bahwa penyimpangan rata-rata antara nilai prediksi dan nilai aktual berada pada tingkat yang sangat rendah. Hal ini diperkuat oleh nilai MAE sebesar 0,06, yang menandakan konsistensi model dalam menghasilkan prediksi yang dekat dengan data sebenarnya. Sementara itu, MAPE sebesar 0,38% mengindikasikan bahwa persentase kesalahan relatif model sangat kecil, sehingga tingkat akurasi prediksi dapat dikatakan sangat tinggi pada data uji.

3. Hasil dan Evaluasi Model LSTM

Model Long Short-Term Memory (LSTM) digunakan karena mampu mempelajari pola berurutan serta menangkap ketergantungan jangka panjang pada data deret waktu. Pendekatan ini sangat sesuai untuk data harga beras yang menunjukkan adanya tren dan fluktuasi mingguan. Pada proses pemodelan, data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian, kemudian dinormalisasi menggunakan MinMaxScaler sebelum dimasukkan ke dalam model. Untuk melihat bagaimana model LSTM merepresentasikan pola data pada tahap pengujian, visualisasi hasil prediksi dan data aktual disajikan pada Gambar 5. Gambar tersebut menampilkan hasil prediksi model LSTM pada data uji. Garis prediksi berwarna hijau putus-putus menunjukkan bahwa LSTM berhasil menangkap pola utama dari data harga, termasuk tren dan titik balik, sehingga prediksi tidak lagi hanya menggeser nilai sebelumnya. Prediksi terlihat lebih halus dibanding data aktual, tetapi hal ini menunjukkan kemampuan model melakukan generalisasi terhadap pola data tanpa terjebak pada fluktuasi acak.


Hasil visual ini mengindikasikan bahwa LSTM mampu memprediksi arah pergerakan harga dengan baik, yang akan dikonfirmasi melalui metrik evaluasi pada Tabel 4.

Tabel 4 menyajikan evaluasi performa model LSTM pada data uji menggunakan tiga metrik utama: RMSE, MAE, dan MAPE. Nilai RMSE sebesar 0,09 dan MAE sebesar 0,08 menunjukkan bahwa rata-rata kesalahan prediksi model sangat kecil, sejalan dengan hasil visual pada Gambar 3. Selain itu, menegaskan bahwa model LSTM mampu memprediksi harga dengan tingkat akurasi yang sangat tinggi, yaitu sekitar 99,49%.

Tabel 5. Evaluasi Performa LSTM

Matrix	Nilai
RMSE	0,09
MAE	0,08
MAPE	0,51

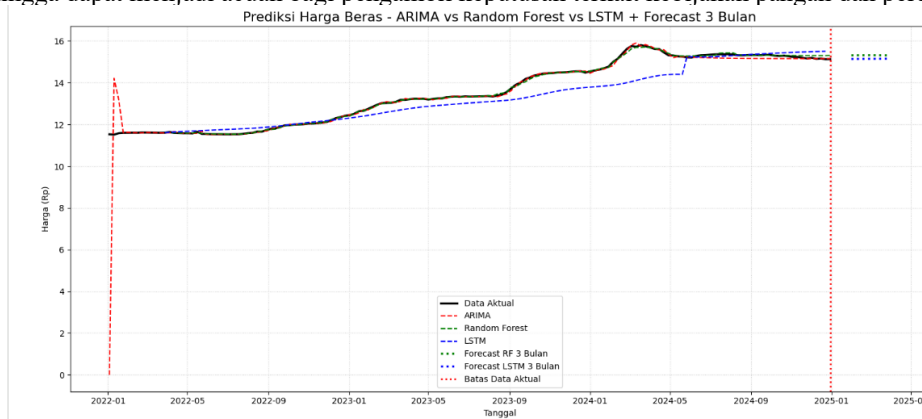
Hasil ini membuktikan bahwa model tidak hanya menangkap arah pergerakan harga, tetapi juga memberikan prediksi yang dekat dengan nilai aktual. Dengan kata lain, evaluasi kuantitatif pada Tabel 5 memperkuat temuan visual sebelumnya bahwa LSTM mampu mempelajari pola data dengan baik dan menghasilkan prediksi yang akurat.



Gambar 5. Hasil Pemodelan LSTM

D. Hasil Prediksi

Setelah melalui evaluasi komprehensif, model Random Forest teridentifikasi sebagai model dengan kinerja terbaik karena menunjukkan akurasi tertinggi serta nilai error (RMSE, MAE, MAPE) terendah pada data uji. Berdasarkan hal ini, model Random Forest dipilih sebagai model final untuk melakukan prediksi harga beras rata-rata nasional selama 12 periode ke depan, setara dengan 12 minggu atau 3 bulan, dimulai dari titik data historis terakhir pada akhir Desember 2024. Prediksi ini bertujuan untuk memberikan estimasi pergerakan harga di masa depan sehingga dapat menjadi acuan bagi pengambilan keputusan terkait kebijakan pangan dan perdagangan.



Gambar 6. Hasil Prediksi Selama 3 Bulan

Gambar 6 menyajikan visualisasi hasil prediksi, di mana garis hitam solid merepresentasikan data aktual harga beras hingga akhir Desember 2024, dan garis merah putus-putus menunjukkan prediksi untuk tiga bulan berikutnya, yaitu Januari, Februari, dan Maret 2025. Dari plot ini terlihat bahwa tren kenaikan harga yang telah diamati pada data historis diperkirakan akan berlanjut, menunjukkan pola yang konsisten dengan dinamika data tiga tahun terakhir. Untuk memudahkan interpretasi dan memberikan informasi numerik yang lebih jelas, nilai-nilai prediksi untuk masing-masing bulan disajikan secara rinci dalam Tabel 6.

Tabel 6. Harga Prediksi

Tanggal	Harga Prediksi (Rp)
12/1/2025	15.3136
19/1/2025	15.3228
26/1/2025	15.3244
02/02/2025	15.3241
09/02/2025	15.3244
16/02/2025	15.3260
23/02/2025	15.3258
02/03/2025	15.3238
09/03/2025	15.3247
16/03/2025	15.3220

Tanggal	Harga Prediksi (Rp)
23/03/2025	15.3220
30/03/2025	15.3220

Tabel 5 menyajikan rincian nilai-nilai prediksi harga beras rata-rata nasional mingguan untuk periode Januari hingga Maret 2025. Berdasarkan data numerik tersebut, harga yang diprediksi oleh model Random Forest cenderung sangat stabil, bergerak di kisaran ketat antara Rp 15.316 hingga Rp 15.326. Stabilitas harga yang terproyeksi ini, didukung oleh visualisasi tren keseluruhan pada Gambar 4, mengindikasikan bahwa meskipun data historis menunjukkan tren kenaikan beberapa tahun terakhir, harga diperkirakan akan terkonsentrasi pada kisaran tersebut tanpa adanya lonjakan tajam dalam tiga bulan pertama tahun 2025.

5. KESIMPULAN

Penelitian ini melakukan evaluasi komprehensif terhadap kinerja ARIMA, Random Forest, dan LSTM dalam memprediksi harga rata-rata nasional Beras Medium II. Berdasarkan analisis data mingguan periode Januari 2022–Desember 2024, *Random Forest* terlihat menghasilkan performa lebih unggul dibandingkan dua metode lainnya.

Secara kuantitatif, *Random Forest* menunjukkan tingkat kesalahan paling rendah dengan nilai RMSE 0,08, MAE 0,06, dan MAPE 0,38%. Ketiga indikator tersebut berada pada kategori sangat baik sesuai literatur. Nilai RMSE dan MAE yang mendekati nol menandakan prediksi yang lebih presisi, sementara MAPE di bawah 10% menunjukkan kemampuan peramalan yang sangat baik. Dibandingkan LSTM (MAPE 0,51%) dan ARIMA (MAPE 0,73%), hasil ini menegaskan bahwa *Random Forest* mampu menangkap pola non linier secara lebih efektif dalam dinamika harga beras.

6. DAFTAR PUSTAKA

- Andreas, C. (n.d.). *Perbandingan Pendekatan Statistika dan Machine Learning dalam Peramalan Data Time Series*. <https://ojs.trigunadharma.ac.id/index.php/jsi>
- Azizah Muzakir, N., & Yahya, Z. (2025). Analisis Perbandingan Model Double Exponential Smoothing dan ARIMA untuk Prediksi Harga Beras di Indonesia. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 7(1), 7–20. <https://doi.org/10.35580/variansiunm349>
- Muhtajuddin Danny, & Asep Muhidin. (2025). BULLETIN OF COMPUTER SCIENCE RESEARCH Optimasi Algoritma Random Forest untuk Prediksi Eksport Kelapa Sawit Global. *Media Online*, 5(5), 1129–1138. <https://doi.org/10.47065/bulletincsr.v5i5.744>
- Ericko, T., Dolok Lauro, M., & Handhayani, T. (n.d.). *Jurnal Ilmu Komputer dan Sistem Informasi PREDIKSI HARGA PANGAN DI PASAR TRADISIONAL KOTA SURABAYA DENGAN METODE LSTM*. <https://www.bi.go.id/hargapangan>
- Fauzi, A., Yunial, A. H., Saputro, D. E., & Saputra, R. (2025). *Optimalisasi Random Forest untuk Sentimen Bahasa Indonesia dengan GridSearch dan SMOTE Random Forest Optimization for Indonesian Sentiment with GridSearch and SMOTE* (Vol. 2025, Issue 2). <https://jurnal.unity-academy.sch.id/index.php/jirsi/index202>
- Hadrianto, M., Nur, A., Rahman, I., Haris, A. S., Juzril, A., & Rahmadani, N. (2025). *Prediksi Harga Emas Menggunakan Algoritma Long-Short Term Memory dengan Optimasi Adaptive Momen Estimation*. 18(2), 1979–276. <https://doi.org/10.30998/faktorexacta.v18i2.26841>
- Hafizah, D., Hakim, D. B., Harianto, H., & Nurmalina, R. (2020). The Role of Rice's Price in the Household Consumption in Indonesia. *AGRIEKONOMIKA*, 9(1), 38–47. <https://doi.org/10.21107/agriekonomika.v9i1.6962>
- Hidayat, R., & Wibisonya, I. (2024). Rice Price Prediction with Long Short-Term Memory (LSTM) Neural Network. *Jurnal RESTI*, 8(5), 658–664. <https://doi.org/10.29207/resti.v8i5.6041>
- Izati Nisa, N., Hatta, M., & Fahrudin, R. (2024). ANALISA AKURASI PREDIKSI HARGA BERAS DI KOTA CIREBON MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE. In *Jurnal Jaringan Sistem Informasi Robotik (JSR)* (Vol. 8, Issue 2). <http://ojsamik.amikmitragama.ac.id>
- Jumali, & Liyanan. (2022). *KARAKTERISTIK MUTU BEBERAPA JENIS BERAS DI TINGKAT PASAR (Studi Kasus di Kota Yogyakarta)*.
- Kobarsih, M., & Dewi Indrasari, S. (n.d.). *Physical and Milling Quality of Milled Rice in Indonesia*.
- Lim, M., & Handhayani, T. (2025). PENERAPAN LSTM DAN GRU UNTUK PREDIKSI HARGA CABAI MERAH DI KOTA JAWA TIMUR. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(2). <https://doi.org/10.23960/jitet.v13i2.6467>
- Mahdi, N. N., & Rianzani, C. (2025). Disparitas Harga Beras Medium terhadap Harga Eceran Tertinggi (HET) dan Implikasinya terhadap Inflasi Pangan di Indonesia. *AGRIFITIA : Journal of Agribusiness Plantation*, 5(2), 132–143. <https://doi.org/10.55180/aft.v5i2.2066>
- Mokosolang, G., Langi, Y. A. R., Mananohas, M. L., Kunci, K., & Farma, S. K. (n.d.). *Prediksi Harga Saham Kimia Farma dan Saham Netflix di Era New Normal Menggunakan Model Autoregressive Integrated Moving Average*. <https://ejournal.unsrat.ac.id/index.php/decartesian>

- Nurani, A. T., Setiawan, A., & Susanto, B. (2023). Perbandingan Kinerja Regresi Decision Tree dan Regresi Linear Berganda untuk Prediksi BMI pada Dataset Asthma. *Jurnal Sains Dan Edukasi Sains*, 6(1), 34–43. <https://doi.org/10.24246/juses.v6i1p34-43>
- Nurmeryteni, I. (2025). STRATEGI PEMERINTAH UNTUK MENGENDALIKAN HARGA BERAS MEDIUM DALAM MENGHADAPI HARI RAYA IDUL FITRI TAHUN 2025. In *Universitas Terbuka* (Vol. 2, Issue 2).
- Pane, P. S. M., Prasmatiwi, F. E., & Situmorang, S. (2023). ANALISIS PREFERENSI, POLA KONSUMSI, DAN PERMINTAAN BERAS TINGKAT RUMAH TANGGA DI KOTA BANDAR LAMPUNG. *Jurnal Ilmu-Ilmu Agribisnis*, 11(1), 70. <https://doi.org/10.23960/jiia.v11i1.7210>
- Pemikiran, J., Ilmiah, M., Agribisnis, B., Eviani, C., Lastinawati, E., Ogari, P. A., Ratu, J. K., Karang, P., Baturaja, S., Oku, K., & Selatan, S. (2023). *Mimbar Agribisnis*.
- Prabowo, T., Charis Fauzan, A., & Yuelisa Mafula, V. (2025). Analisis Deret Waktu untuk Forecasting Populasi Ternak di Indonesia dengan Model LSTM 1. *JSAI: Journal Scientific and Applied Informatics*, 8(1). <https://doi.org/10.36085>
- Puji Lestari, A., Zumi Saidah, dan, Raya Bandung-Sumedang, J. K., Jawa Barat, J., & Artikel, I. (2023). Analisis Preferensi Konsumen terhadap Atribut Beras di Kecamatan Cibeunying Kidul, Kota Bandung Analysis of Consumer Preferences for Rice Attributes in Cibeunying Kidul District, Bandung City. *Jurnal Agrikultura*, 2023(1), 28–36.
- Rahmad firdiansyah, & Asmunin. (n.d.). *RANCANG BANGUN SISTEM PREDIKSI HARGA BERAS TINGKAT GROSIR DI INDONESIA BERBASIS WEB MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)*. www.bps.go.id.
- Rasyid Muchtar, I. (2024). Comparison of Linear Regression and Random Forest Algorithms for Premium Rice Price Prediction (Case Study: West Java). *Jurnal Indonesia Sosial Teknologi*, 5(7), 3122. <http://jst.publikasiindonesia.id/>
- Santoso, A., Purnamasari, A. I., & Ali, I. (n.d.). *PREDIKSI HARGA BERAS MENGGUNAKAN METODE RECURRENT NEURAL NETWORK DAN LONG SHORT-TERM MEMORY*.
- Saputra, D., Raihan Trinadi, D., Agustina, D., & Teknik dan Komputer Prodi Informatika, F. (n.d.-a). Perbandingan Metode Random Forest, Linier Regression, SVM Untuk Memprediksi Harga Beras Premium. *Seminar Nasional Teknologi Informasi Dan Bisnis (SENATIB)*, 2025.
- Saputra, D., Raihan Trinadi, D., Agustina, D., & Teknik dan Komputer Prodi Informatika, F. (n.d.-b). Perbandingan Metode Random Forest, Linier Regression, SVM Untuk Memprediksi Harga Beras Premium. *Seminar Nasional Teknologi Informasi Dan Bisnis (SENATIB)*, 2025.
- Sihombing, E. I., Suhendra, C. D., & Marini, L. F. (2024). KLIK: Kajian Ilmiah Informatika dan Komputer Analisis Data Time Series Untuk Prediksi Harga Komoditas Pangan Menggunakan Autoregressive Integrated Moving Average. *Media Online*, 4(6). <https://doi.org/10.30865/klik.v4i6.1863>
- Supriyadi 2021. (n.d.).
- Theofilou, A., Nastis, S. A., Michailidis, A., Bournaris, T., & Mattas, K. (2025). Predicting Prices of Staple Crops Using Machine Learning: A Systematic Review of Studies on Wheat, Corn, and Rice. In *Sustainability (Switzerland)* (Vol. 17, Issue 12). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/su17125456>
- Tukiyat. (2022). *Pemodelan Prakiraan Tingkat Inflasi di Indonesia dengan ARIMA*. 7(2), 390–398. <https://doi.org/10.32493/informatika.v7i2.17676>
- Ugi Sugiharto. (2024). Factors Affecting Rice Prices in Indonesia (Production, Consumption, Imports, International Prices, Crop Damage). *International Journal of Economics and Management Sciences*, 1(3), 329–337. <https://doi.org/10.61132/ijems.v1i3.183>
- Wibowo, R. P., Pebriyani, D., & Indriyanti, T. (2025). Analysis of Rice Price Volatility in Medan City, Indonesia. *Agro Bali : Agricultural Journal*, 8(1), 291–302. <https://doi.org/10.37637/ab.v8i1.2216>
- Winata, A., Lauro, M. D., & Handhayani, T. (2023). *SISTEMASI: Jurnal Sistem Informasi Analysis and Prediction of Foodstuffs Prices in Tasikmalaya Using ELM and LSTM* (Vol. 12, Issue 3). <http://sistemasi.ftik.unisi.ac.id>
- Yuriyah, S., Purwanto, O. D., Afza, H., Dadang, A., Masyuri, A., Galurina, R. S., & Utami, D. W. (2024). Evaluasi Mutu Fisikokimia Beras Hasil Persilangan antara Empat Padi Varietas Unggul dan Padi Liar (*Oryza glaberrima* dan *O. rufipogon*). *Jurnal Ilmu Pertanian Indonesia*, 29(3), 397–407. <https://doi.org/10.18343/jipi.29.3.397>