



KOMPARASI MODEL ARIMA, REGRESI LINEAR, *RANDOM FOREST*, DAN LSTM UNTUK PERAMALAN HARGA BERAS JAWA BARAT

Marsello Ormanda¹, Irfan Ardiansah²

^{1,2}Teknologi Industri Pertanian, Universitas Padjadjaran
Sumedang, Jawa Barat, Indonesia 45363
marsello22001@mail.unpad.ac.id, irfan@unpad.ac.id

Abstract

Rice price fluctuations in West Java significantly impact regional inflation and national food security. The main challenge in forecasting this commodity price is the high volatility of the data, which conventional statistical models often fail to capture. This study aims to compare the accuracy of four forecasting methods: ARIMA, Linear Regression, Random Forest, and Long Short-Term Memory (LSTM), to identify the best-performing model. The data used are daily medium rice prices in West Java from January 2022 to October 2024, obtained from Kaggle. The methodology includes data pre-processing, model parameter optimization, and performance evaluation using RMSE, MAE, and MAPE metrics. The results show that non-linear models significantly outperform linear models. LSTM recorded superior performance with the lowest error rates (MAPE 0.43% and RMSE 91.95), followed by Random Forest (MAPE 0.67%). In contrast, ARIMA and Linear Regression produced errors above 10%. In conclusion, Deep Learning and Machine Learning approaches are more robust at handling volatile food price data than classical econometric methods, making them highly recommended as a basis for policymakers' early warning systems.

Keywords: Forecasting, LSTM, random forest, rice prices, volatility

Abstrak

Fluktuasi harga beras di Jawa Barat memiliki dampak signifikan terhadap inflasi daerah dan ketahanan pangan nasional. Tantangan utama dalam peramalan harga komoditas ini adalah tingginya volatilitas data yang seringkali gagal ditangkap oleh model statistik konvensional. Penelitian ini bertujuan untuk membandingkan akurasi empat metode peramalan, yaitu ARIMA, regresi linear, *random forest*, dan *long short-term memory* (LSTM), guna mengidentifikasi model terbaik. Data yang digunakan adalah harga harian beras medium di Jawa Barat periode Januari 2022 hingga Oktober 2024 yang diperoleh dari Kaggle. Metodologi meliputi pra-pemrosesan data, optimasi parameter model, dan evaluasi kinerja menggunakan metrik RMSE, MAE, dan MAPE. Hasil penelitian menunjukkan bahwa model non-linier mengungguli model linear secara signifikan. LSTM mencatatkan kinerja superior dengan tingkat kesalahan terendah (MAPE 0,43% dan RMSE 91,95), diikuti oleh *random forest* (MAPE 0,67%). Sebaliknya, ARIMA dan regresi linear menghasilkan error di atas 10%. Kesimpulannya, pendekatan *deep learning* dan *machine learning* terbukti lebih *robust* dalam menangani data harga pangan yang volatil dibandingkan metode ekonometrika klasik, sehingga sangat direkomendasikan sebagai landasan sistem peringatan dini bagi pemangku kebijakan.

Kata kunci: Harga beras, LSTM, peramalan, *random forest*, volatilitas

1. PENDAHULUAN

Beras memegang peran yang sentral dan tidak tergantikan dalam struktur ekonomi, sosial, dan politik Indonesia [1], [2]. Sebagai makanan pokok mayoritas masyarakat, posisinya sebagai komoditas strategis menjadikannya pilar utama ketahanan pangan nasional [3], [4]. Stabilitas harga beras memiliki dampak langsung terhadap stabilitas ekonomi makro, mengingat fluktuasi harganya merupakan penyumbang utama inflasi bahan makanan yang dapat melampaui 5 persen pada periode tertentu [5], [6]. Oleh karena itu, peramalan harga yang akurat berfungsi sebagai

sistem peringatan dini atau *early warning system* yang esensial untuk memitigasi risiko inflasi dan mempertahankan daya beli masyarakat [7], [8].

Penelitian ini memfokuskan analisis pada Provinsi Jawa Barat karena perannya yang fundamental dalam menjaga ketersediaan pangan nasional [9]. Sebagai salah satu sentra produksi utama, volatilitas harga di Jawa Barat memiliki potensi untuk menjadi indikator utama pergerakan harga beras di wilayah sekitarnya [9]. Tantangan metodologis utama dalam peramalan harga beras adalah sifat datanya

yang tidak stabil dan sangat volatil akibat faktor musiman serta gangguan eksternal [10]. Karakteristik non-linier yang kompleks ini menyebabkan model ekonometrika tradisional seringkali kurang memadai untuk memberikan akurasi peramalan yang optimal [10].

Upaya pengembangan sistem prediksi harga komoditas pangan yang volatil sebenarnya telah banyak dilakukan. Sebagai referensi, terdapat penelitian yang telah membahas sistem prediksi harga komoditas cabai di Jawa Timur untuk membantu pengambilan keputusan petani dan pedagang akibat fluktuasi harga harian [11]. Namun, penelitian terdahulu [12] yang menerapkan model ARIMA untuk harga beras di Jawa Barat mencatat adanya batasan pada pola data linier. Demikian pula, studi terkait [13] yang telah mengeksplorasi penggunaan *Random Forest* dan Regresi Linier, namun belum mengintegrasikan pendekatan *deep learning* untuk menangani volatilitas pasca-pandemi yang ekstrem.

Oleh karena itu, studi yang membandingkan secara komprehensif spektrum luas metodologi mulai dari ekonometrika tradisional hingga *deep learning* secara spesifik pada dinamika harga beras di Jawa Barat masih sangat terbatas. Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan melakukan analisis komparatif untuk mengidentifikasi model peramalan yang paling akurat dan *robust*. Empat metode dipilih untuk perbandingan ini yaitu ARIMA, regresi linear, *random forest*, dan *long short-term memory* (LSTM). Model ARIMA dipilih sebagai standar emas ekonometrika dan regresi linear sebagai tolok ukur linearitas dasar [14]. Sementara itu, *random forest* dipilih sebagai representasi *machine learning* yang telah terbukti andal dalam menangani data kompleks, dan LSTM sebagai representasi *deep learning* yang diharapkan unggul dalam menangkap dependensi jangka panjang pada data yang bergejolak [15]. Perbandingan ini diharapkan dapat memberikan rekomendasi metode terbaik bagi pemangku kebijakan dalam merencanakan intervensi pasar yang efektif [16].

2. METODE PENELITIAN

Penelitian ini menerapkan desain eksperimental kuantitatif untuk mengevaluasi akurasi peramalan harga beras di Jawa Barat. Mengingat karakteristik data harga pangan yang memiliki volatilitas tinggi dan pola non-linier [10], [17], pendekatan statistik klasik sering kali memiliki keterbatasan dalam menangkap fluktuasi ekstrem [18]. Oleh karena itu, penelitian ini melakukan analisis komparatif antara model linear (*baseline*) yaitu ARIMA dan regresi linear, melawan model non-linear berbasis kecerdasan buatan, yakni *random forest* dan *long short-term memory* (LSTM). Pemilihan model ini didasarkan pada kemampuan *machine learning* dan *deep learning* dalam mempelajari dependensi jangka panjang dan pola kompleks yang tidak dapat dijangkau oleh model ekonometrika tradisional [19], [20]. Hasil evaluasi diukur secara objektif menggunakan metrik RMSE, MAE,

dan MAPE untuk merekomendasikan model yang paling *robust* sebagai landasan kebijakan ketahanan pangan [16].

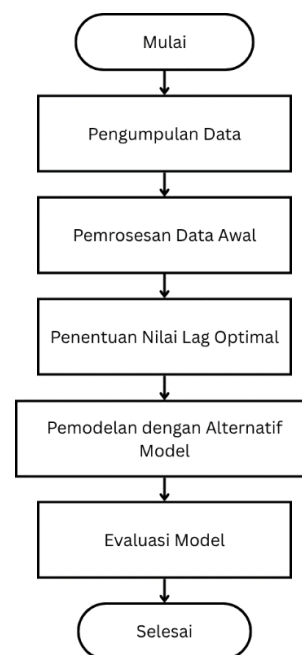
2.1 Metode pengumpulan data, instrumen penelitian, dan metode pengujian

Data yang didayagunakan dalam studi ini merupakan data sekunder berjenis deret waktu (*time series*) univariat, yakni harga harian beras medium di Provinsi Jawa Barat. Rentang waktu pengamatan mencakup periode Januari 2022 hingga Oktober 2024 yang diakuisisi melalui repositori publik Kaggle [21]. Instrumen komputasi yang digunakan mencakup bahasa pemrograman *Python* dengan pustaka *Pandas* untuk manipulasi struktur data, serta pemanfaatan algoritma *Min-Max Scaler* untuk prosedur normalisasi data, khususnya pada pemodelan jaringan saraf tiruan [22].

Untuk memvalidasi keandalan model, evaluasi kinerja dilakukan secara objektif menggunakan tiga metrik statistik standar. *Root Mean Squared Error* (RMSE) digunakan untuk mendeteksi deviasi ekstrem dengan memberikan bobot lebih pada kesalahan besar [23]. *Mean Absolute Error* (MAE) diterapkan untuk mengukur rata-rata kesalahan absolut [23], sedangkan *Mean Absolute Percentage Error* (MAPE) digunakan untuk menginterpretasikan akurasi dalam persentase yang intuitif [24]. Kombinasi ketiga metrik ini bertujuan untuk memastikan validitas kedekatan antara nilai estimasi model dengan data aktual di lapangan.

2.2 Tahapan penelitian

Seluruh rangkaian kegiatan penelitian dilaksanakan melalui fase-fase terstruktur sebagaimana direpresentasikan dalam diagram alur pada Gambar 1. Penjelasan mendalam mengenai setiap tahapan tersebut dipaparkan pada paragraf sebagai berikut.



Gambar 1. Diagram Alur Penelitian

Riset diawali dengan pengumpulan data historis yang kemudian melalui tahap inspeksi integritas. Terdapat 37 entri data yang hilang (*missing values*) yang ditangani secara metodologis menggunakan interpolasi linear guna mempertahankan kontinuitas deret waktu. Selanjutnya, dataset dibagi secara sekuensial menjadi 80% untuk fase pelatihan (*training*) dan 20% untuk fase pengujian (*testing*). Khusus pada model LSTM, dilakukan transformasi nilai ke rentang 0 hingga 1 untuk mengoptimalkan konvergensi saat proses pelatihan [15].

Empat algoritma prediktif kemudian diterapkan dengan melibatkan prosedur *hyperparameter tuning*. Model ARIMA dioptimasi menggunakan mekanisme *grid search* dengan target nilai AIC minimum untuk mendapatkan estimasi parameter terbaik [25]. Pada model regresi linear dan *random forest*, dilakukan ekstraksi fitur berbasis *lagged features*, di mana diterapkan lag 10 untuk regresi linear dan lag 1 untuk *random forest* berdasarkan kriteria galat terkecil. Sementara itu, arsitektur LSTM dikonfigurasi menggunakan urutan waktu (*sequences*) sepanjang 30 hari untuk menangkap dependensi temporal jangka panjang [20].

Kinerja dari setiap model kemudian divalidasi menggunakan data uji yang bersifat independen dari proses latih. Analisis akhir dilakukan untuk mengidentifikasi model dengan tingkat ketahanan tertinggi. Penentuan kualitas model didasarkan pada standar interpretasi nilai MAPE sebagaimana disajikan dalam Tabel 1 [26], di mana model dengan nilai MAPE di bawah 10% diklasifikasikan sebagai kategori akurasi tertinggi. Observasi visual melalui perbandingan grafik tren harga juga dilakukan untuk memastikan model mampu beradaptasi terhadap volatilitas harga harian secara dinamis.

Tabel 1. Tabel Standar Interpretasi nilai MAPE

Nilai MAPE	Interpretasi
Kurang dari 10%	Akurasi peramalan tinggi (<i>highly accurate forecasting</i>)
10-20%	Akurasi peramalan baik (<i>good forecasting</i>)
20-50%	Akurasi peramalan dapat diterima (<i>reasonable forecasting</i>)
Lebih dari 50%	Akurasi peramalan rendah (<i>inaccurate forecasting</i>)

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil uji coba dan analisis komparatif performa model yang diimplementasikan pada dataset penelitian. Analisis dilakukan dengan menggunakan data harga komoditas beras historis sebagai bahan pelatihan dan evaluasi untuk mengidentifikasi model yang paling akurat dalam menangkap tren dan volatilitas harga.

Tabel 2. Rangkuman Metrik Evaluasi Kinerja (Data Uji)

Model	Kategori	RMSE (Rp)	MAE (Rp)	MAPE (Rp)	Interpretasi Kualitas
LSTM	<i>Deep Learning</i>	91,95	55,72	0,43%	Akurat Tinggi
<i>Random Forest</i>	<i>Machine Learning</i>	136,00	88,28	0,67%	Akurat Tinggi
ARIMA	Ekonometrika Klasik	1488,19	1399,37	10,93%	Akurasi Baik
Regresi Linear	<i>Baseline Linear</i>	1544,30	1500,77	11,67%	Akurasi Baik

3.1 Perbandingan Kinerja Model

Analisis kuantitatif dilakukan pada dataset *data testing* untuk membandingkan kinerja dari keempat model peramalan menggunakan metrik RMSE, MAE, dan MAPE. Berdasarkan Tabel 2, model LSTM terbukti menghasilkan kinerja superior dengan nilai MAPE terkecil sebesar 0,43% dan RMSE 91,95 Rupiah. Nilai MAPE ini secara definitive menempatkan LSTM dan *random forest* (MAPE 0,67%) dalam kategori akurasi peramalan tinggi (*highly accurate forecasting*).

Sebaliknya dengan model linear ARIMA dan regresi linear yang menunjukkan tingkat kesalahan lebih tinggi. Regresi linear menghasilkan MAPE 11,67% dan ARIMA sebesar 10,93%, yang mana kedua nilai ini menempatkan model linear hanya dalam kategori akurasi peramalan baik (*good forecasting*). Perbedaan signifikan ini menegaskan bahwa metode berbasis *deep learning* dan *machine learning* jauh lebih efektif dalam menangani volatilitas harga komoditas dibandingkan metode *time series* klasik.

3.2 Karakteristik Dataset dan Implikasi Pemodelan

Dataset harga beras medium Provinsi Jawa Barat menunjukkan property volatilitas tinggi dan non-linieritas yang signifikan, yang secara fundamental memengaruhi kinerja model peramalan. Volatilitas data ini dikuantifikasi melalui koefisien variasi (CV) yang menunjukkan nilai sebesar 11,6452%. Koefisien variasi dihitung sebagai rasio antara standar deviasi (σ) dan rata-rata (μ), serta dinyatakan dalam persentase dengan rumus:

$$CV = \frac{\sigma}{\mu} \times 100\% \quad [27]$$

Tingkat fluktuasi yang tinggi ini secara teoritis membuat model linear tradisional rentan terhadap kesalahan besar [17]. Fluktuasi yang ekstrem ini menjelaskan mengapa model linear seperti ARIMA dan regresi linear menghasilkan error yang tinggi, menempatkan keduanya hanya pada kategori akurasi peramalan baik (*good forecasting*). Nilai MAPE kedua model linear tersebut secara numerik mencerminkan kondisi fluktuasi harga pada dataset. Model-model linear ini dipaksa memproyeksikan pola yang kaku, sehingga gagal beradaptasi dengan

perubahan struktural mendadak yang berpotensi menyebabkan error jauh lebih besar pada data *test* dibandingkan dengan data *training* [28].

Sebaliknya, kinerja superior LSTM dan *random forest* yang masuk ke dalam kategori akurasi peramalan tinggi (*highly accurate forecasting*), memberikan pembenaran metodologis yang kuat untuk memilih model non-linier. Kinerja ini menunjukkan bahwa dataset harga beras memerlukan model yang mampu menangkap dinamika non-linier dan kompleks secara efektif, dibandingkan model yang berbasis pada asumsi linearitas. Hal ini sejalan dengan literatur yang menyimpulkan bahwa metode *deep learning* seperti LSTM lebih *robust* dalam menangani fluktuasi data yang ekstrem dibandingkan model tradisional, karena kemampuannya menangkap hubungan non-linier dan adaptasi terhadap perubahan struktural [29].

3.3 Penentuan Parameter Model Optimal

Proses penentuan parameter optimal dilakukan secara ketat untuk menjamin kinerja terbaik dari setiap model. Untuk model ARIMA, berdasarkan uji stasioneritas ($d = 1$) dan seleksi *Grid Search*, terpilih spesifikasi model ARIMA(5, 1, 6) yang menghasilkan nilai AIC terendah sebesar 8.790,98. Pada pendekatan berbasis regresi, Regresi Linear mencapai performa terbaik menggunakan Lag 10 dengan teknik regularisasi Lasso (L1), mencatatkan nilai RMSE terendah sebesar 74,19 pada data latih. Berbeda dengan itu, model *Random Forest* justru mencapai kinerja optimalnya menggunakan Lag 1 dengan RMSE sebesar 136,00, yang mengindikasikan efektivitas model dalam menangkap korelasi harga harian jangka pendek. Sementara itu, model *Deep Learning LSTM* dikonfigurasi dengan *sequence length* 30 hari, di mana proses pelatihan berhenti secara otomatis pada Epoch 21 dengan capaian RMSE *training* sebesar 89,44 dan *Validation Loss* terendah sekitar $5,28 \times 10^{-4}$.

3.4 Keunggulan Model *Deep Learning* dan *Machine Learning*

Model non-linier LSTM dan *Random Forest* menunjukkan keunggulan adaptif yang signifikan. Kinerja LSTM yang superior (MAPE 0,43%) disebabkan oleh arsitektur *memory cell* yang memungkinkannya mengatasi masalah *vanishing gradient* dan mempertahankan informasi yang relevan dalam jangka panjang [20]. Kemampuan mekanisme *gate* ini memungkinkan LSTM untuk menangkap hubungan non-linier yang kompleks, sehingga model mampu menyesuaikan diri dengan cepat terhadap perubahan struktural harga. Secara visual, perbandingan keunggulan prediksi model *machine learning* dan *deep learning* terhadap harga actual disajikan pada Gambar 2. Prediksi *random forest* (Gambar 2a) memvalidasi efektivitas pendekatan *ensemble* dalam peramalan harga komoditas dengan mengatasi volatilitas data, sehingga menghasilkan garis prediksi yang sangat rapat dengan data actual. Sementara itu, prediksi LSTM (Gambar 2b) menunjukkan

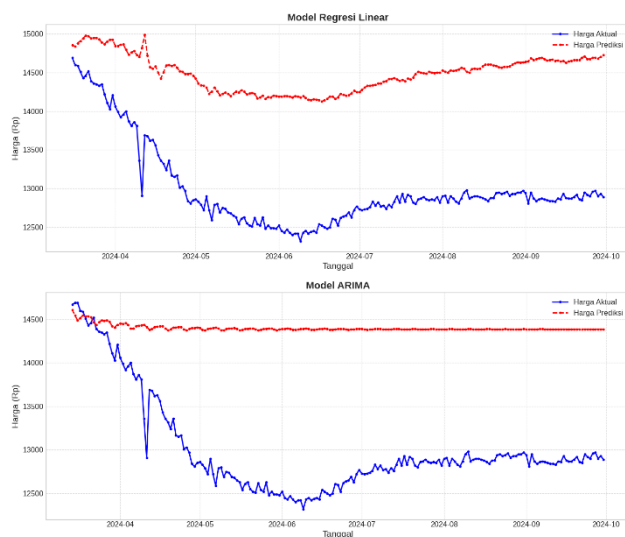
tingkat keakuratan tertinggi dengan kemampuannya mengikuti fluktuasi minor harga secara mulus di sepanjang periode uji. Model *Random Forest* juga menunjukkan akurasi yang sangat tinggi (MAPE 0,67%), memvalidasi efektivitas pendekatan *ensemble* dalam peramalan harga komoditas [30]. Keberhasilan RF didukung oleh penentuan Lag 1 sebagai parameter optimal, yang menunjukkan bahwa korelasi kuat harga hari sebelumnya dapat digunakan secara efektif oleh model non-linier untuk memprediksi harga hari ini. Meskipun RF membangkitkan banyak pohon yang lebih sederhana, model ini secara efektif mengatasi volatilitas data, sehingga menghasilkan prediksi yang sangat rapat dengan data actual pada periode *testing*.



Gambar 2. Grafik Perbandingan Model Non-Linier: (a) *Random Forest*, dan (b) LSTM.

3.5 Kegagalan Model Ekonometrika Klasik

Sebaliknya, model linear seperti ARIMA dan Regresi Linear menunjukkan kelemahan mendasar yang terekam jelas dalam visualisasi pada Gambar 3. Model ARIMA (MAPE 10,93%) cenderung menghasilkan prediksi yang kaku karena hanya mampu menangkap tren linear dasar. Grafik prediksi ARIMA (Gambar 3b) menunjukkan bahwa model ini gagal beradaptasi dengan cepat terhadap penurunan harga tajam yang terjadi di awal periode *testing*, menyebabkan garis prediksi (garis merah) stagnan pada level harga yang tinggi. Kegagalan ini memvalidasi literatur yang menyatakan bahwa model time series klasik seringkali tidak memadai untuk memodelkan karakteristik non-linier dan sifat harga yang sangat volatil [18].



Gambar 3. Grafik Perbandingan Model Linear: (a) Regresi Linear, dan (b) ARIMA.

Demikian pula, Regresi Linear (MAPE 11,67%) juga gagal menangkap dinamika harga secara akurat. Meskipun menggunakan Lag 10, grafik prediksi Regresi Linear (Gambar 3a) menunjukkan keterbatasan yang sama dalam menyesuaikan diri dengan tren penurunan struktural, menghasilkan deviasi prediksi yang signifikan. Kegagalan model linear ini membuktikan bahwa *dataset* harga beras memerlukan model yang secara inheren mampu memproses hubungan non-linier dan volatilitas ekstrem untuk menghasilkan peramalan yang *robust*.

3.6 Implikasi Temuan dan Rekomendasi

Temuan penelitian ini memberikan kontribusi dan implikasi yang signifikan, baik secara teoritis maupun praktis. Secara Implikasi Teoritis, kinerja superior yang ditunjukkan oleh model LSTM secara empiris membuktikan bahwa pendekatan *deep learning* menawarkan alternatif yang andal dan *robust* untuk skenario peramalan harga komoditas yang kompleks. Dominasi LSTM memvalidasi bahwa metode *time series* tradisional, seperti ARIMA dan Regresi Linear, memiliki keterbatasan fundamental dalam menangani data dengan volatilitas tinggi dan pola non-linier [31]. Secara Implikasi Praktis, adopsi model LSTM dengan akurasi MAPE 0.43% dapat menghasilkan manfaat nyata bagi pemangku kepentingan. Akurasi tinggi ini berfungsi sebagai sistem peringatan dini yang esensial dalam memitigasi risiko inflasi dan memungkinkan pemerintah merencanakan intervensi pasar yang tepat waktu [32]. Bagi pelaku bisnis, model ini dapat menghasilkan perbaikan signifikan pada manajemen persediaan, perencanaan anggaran, dan peningkatan efisiensi operasional [33].

4. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, penelitian ini menyimpulkan bahwa pendekatan berbasis *deep learning* dan *machine learning* terbukti secara signifikan lebih unggul dan *robust* dibandingkan dengan metode statistik tradisional dalam melakukan peramalan

harga beras medium di Jawa Barat. Keunggulan utama dari model non-linier tersebut terletak pada kemampuannya untuk menangkap pola dependensi jangka panjang dan beradaptasi secara dinamis terhadap data komoditas pangan yang memiliki tingkat volatilitas ekstrem. Sebaliknya, kegagalan model ekonometrika klasik seperti ARIMA dan regresi linear membuktikan bahwa asumsi linearitas dan stasioneritas yang kaku sangat rentan dan tidak responsif terhadap guncangan pasar (*shocks*) maupun perubahan tren struktural secara tiba-tiba.

Secara praktis, akurasi tinggi yang dicapai oleh model LSTM menjadikannya sangat layak direkomendasikan sebagai instrumen utama dalam sistem peringatan dini (*early warning system*) bagi pemangku kebijakan. Sebagai tindak lanjut dari penelitian ini, disarankan untuk mengembangkan pendekatan model *hybrid* yang menggabungkan keandalan statistik linear dan jaringan saraf tiruan guna mengoptimalkan akurasi prediksi. Selain itu, integrasi teknik *explainable AI* (XAI) sangat esensial pada penelitian masa depan untuk mengurai sifat “*black box*” pada algoritma *deep learning*, sehingga transparansi keputusan komputasional dapat lebih mudah diinterpretasikan dan diadopsi dalam perumusan kebijakan ketahanan pangan.

DAFTAR PUSTAKA

- [1] F. Rafidah, Y. Hariyati, K. Muhtadi, and H. Prayuginingsih, “Determinan dan Dampak Kebijakan Peningkatan Areal Irigasi terhadap Rasio Ketergantungan Impor Beras Indonesia,” *J. Pangan*, vol. 33, no. 2, pp. 97–118, 2024, doi: <https://doi.org/10.33964/jp.v33i2.664>.
- [2] F. A. Nasution, Y. I. Indainanto, and P. D. K. Pardede, “Beras Sebagai Komoditas Politik Dalam Pemilihan Umum di Indonesia,” *J. Kaji. Agrar. dan Kedaulatan Pangan*, vol. 2, no. 1, pp. 37–43, 2023, doi: [10.32734/jkakp.v2i1.13421](https://doi.org/10.32734/jkakp.v2i1.13421).
- [3] N. D. Budiman and L. Santu, “Kajian Strategi dan Kebijakan Pemerintah Indonesia dalam Mencapai Target Swasembada Beras,” *J. Pertan. CEMARA*, vol. 21, no. 2, pp. 125–136, 2024, doi: [10.24929/fp.v21i2.3888](https://doi.org/10.24929/fp.v21i2.3888).
- [4] F. A. Adit Kurniawan, I. Ramadhani, and R. A. Fitri, “Analisis Pengambilan Keputusan Kebijakan Impor Beras dalam Konteks Pemenuhan Pangan Nasional di Indonesia,” *Indones. J. Public Adm. Rev.*, vol. 1, no. 2, p. 15, 2024, doi: [10.47134/par.v1i2.2394](https://doi.org/10.47134/par.v1i2.2394).
- [5] V. Hildayanti, “Pengaruh Fluktuasi Harga Komoditas Beras dan Minyak Goreng Terhadap Pengendalian Inflasi di Kota Cirebon Tahun 2021–2023,” *J. Din. Sos. Dan Sains*, vol. 1, no. 4, pp. 305–313, 2024, doi: <https://doi.org/10.60145/jds.v1i4.85>.
- [6] W. S. Nugroho and Jamilatuzzahro, “Harga Beras

- Lampau HET, Berikut Penjelasan Pengamat Ekonomi FEB UGM,” FEB UGM. Accessed: Nov. 29, 2025. [Online]. Available: <https://feb.ugm.ac.id/id/berita/4509-harga-beras-lampau-het-berikut-penjelasan-pengamat-ekonomi-feb-ugm>
- [7] A. Winata, M. D. Lauro, and T. Handhayani, “Analysis and Prediction of Foodstuffs Prices in Tasikmalaya Using ELM and LSTM,” *Sistemasi*, vol. 12, no. 3, p. 874, 2023, doi: 10.32520/stmsi.v12i3.3145.
- [8] W. Widiyantoro, Y. H. Chrisnanto, and A. I. Hadiana, “Peramalan Produksi Padi di Kabupaten Bandung Menggunakan Metode Double Moving Average,” *J. Sos. Teknol.*, vol. 5, no. 9, pp. 3762–3776, 2025, doi: 10.59188/journalsostech.v5i9.32409.
- [9] V. Virgiani, A. Hadianto, and F. Dewi Raswatie, “Analisis Capaian Program Swasembada Beras di Pulau Jawa,” *Indones. J. Agric. Resour. Environ. Econ.*, vol. 2, no. 2, pp. 1–14, 2023, doi: 10.29244/ijaree.v2i2.51682.
- [10] A. Pala and W. Windasari, “Prediksi Harga Komoditas Pertanian Beras dengan Metode Hybrid ARIMA dan Neural Network di Daerah Istimewa Yogyakarta,” *J. Appl. Sci. Inf. Technol.*, vol. 1, no. 1, pp. 126–145, 2025, doi: <https://doi.org/10.32639/d3m0cb17>.
- [11] B. Al badi, M. A. Bianto, R. N. Rohman, and M. S. Alamsyah, “Sistem Prediksi Harga Komoditas Cabai di Wilayah Jawa Timur Menggunakan Simple Moving Average,” *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3, pp. 2261–2269, 2025, doi: 10.23960/jitet.v13i3.7345.
- [12] R. D. Putra, N. Musyaffa, H. Nurdin, and R. M. Square, “Analisis Komparatif Model Arima dan Lstm untuk Prediksi,” *IJCIT (Indonesian J. Comput. Inf. Technol.)*, vol. 10, no. 1, pp. 1–6, 2025.
- [13] I. R. Muchtar and Afiyati, “Comparison of Linear Regression and Random Forest Algorithms for Premium Rice Price Prediction (Case Study : West Java),” *J. Indones. Sos. Teknol.*, vol. 5, no. 7, pp. 3122–3132, 2024.
- [14] G. Box, “Box and Jenkins: Time Series Analysis, Forecasting and Control,” in *A Very British Affair: Six Britons and the Development of Time Series Analysis During the 20th Century*, London: Palgrave Macmillan UK, 2013, pp. 161–215. doi: 10.1057/9781137291264_6.
- [15] R. Muhammad and I. Nurhaida, “Penerapan LSTM Dalam Deep Learning Untuk Prediksi Harga Kopi Jangka Pendek Dan Jangka Panjang,” *JIPi (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 1, pp. 554–564, 2025, doi: 10.29100/jipi.v10i1.5904.
- [16] Y. Ashari and A. Suhendar, “Implementasi Algoritma Long Short-Term Memory (Lstm) untuk Memprediksi Harga Beras di Jawa Tengah berdasarkan Cuaca,” *Djtechno J. Teknol. Inf.*, vol. 5, no. 3, pp. 624–636, 2024, doi: 10.46576/djtechno.v5i3.5136.
- [17] A. V. Septani, F. M. Afendi, and A. Kurnia, “Perbandingan Metode GARCH, LSTM, GRU, dan CNN pada Peramalan Volatilitas Kurs,” *J. Math. Its Appl.*, vol. 22, no. 1, pp. 149–169, 2025, doi: <http://dx.doi.org/10.12962/limits.v22i1.3384>.
- [18] S. Annisa *et al.*, “Peramalan harga minyak mentah indonesia menggunakan algoritma random forest,” *J. Gaussian*, vol. 13, no. 2, pp. 472–478, 2025, doi: 10.14710/j.gauss.13.2.472-478.
- [19] H. Hewamalage, C. Bergmeir, and K. Bandara, “Recurrent Neural Networks for Time Series Forecasting: Current status and future directions,” *Int. J. Forecast.*, vol. 37, no. 1, pp. 388–427, 2021, doi: <https://doi.org/10.1016/j.ijforecast.2020.06.008>.
- [20] J. Cahyani, S. Mujahidin, and T. P. Fiqar, “Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional,” *J. Sist. dan Teknol. Inf.*, vol. 11, no. 2, p. 346, 2023, doi: 10.26418/justin.v11i2.57395.
- [21] Fathur, “Indonesia Commodity Price.” Accessed: Feb. 09, 2026. [Online]. Available: <https://www.kaggle.com/datasets/dataavidia/indonesia-commodity-price>
- [22] Y. S. Kim, M. K. Kim, N. Fu, J. Liu, J. Wang, and J. Srebric, “Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models,” *Sustain. Cities Soc.*, vol. 118, no. October 2023, p. 105570, 2025, doi: 10.1016/j.scs.2024.105570.
- [23] T. O. Hodson, “Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not,” *Geosci. Model Dev.*, no. 2, pp. 5481–5487, 2022, doi: <https://doi.org/10.5194/gmd-15-5481-2022>.
- [24] B. L. Bowerman, R. T. O’connell, and A. B. Koehler, “Forecasting, time series, and regression : an applied approach,” 2005. [Online]. Available: <https://api.semanticscholar.org/CorpusID:117736686>
- [25] S. Deviana, Nusyirwan, D. Azis, and P. Ferdias, “Analisis Model Autoregressive Integrated Moving Average Data Deret Waktu Dengan Metode Momen Sebagai Estimasi Parameter,” *J. Siger Mat.*, vol. 02, no. 02, pp. 57–67, 2021.
- [26] A. Febiola *et al.*, “Perbandingan Metode ARIMA dan SARIMA Dalam Peramalan Jumlah Penumpang Bandara Provinsi Kepulauan Bangka

- Belitung.” *Jambura J. Math.*, vol. 6, no. 2, pp. 160–168, 2024, doi: 10.37905/jjom.v6i2.25081.
- [27] D. Cramer and D. N. V.-0 Howitt, “Coefficient of variation,” in *The SAGE dictionary of statistics*, 2004, p. 27. doi: <https://doi.org/10.4135/9780857020123.n81>.
- [28] R. A. A. Ananda, A. Nazir, L. Oktavia, E. Haerani, and F. Insani, “Analisa Perbandingan Metode Trend Moment dan Regresi Linear dalam Prediksi Kurs Mata Uang Rupiah terhadap Mata Uang Riyal,” *J. Comput. Syst. Informatics*, vol. 6, no. 3, pp. 563–571, 2025, doi: 10.47065/josyc.v6i3.7400.
- [29] D. K. T. Suwarso *et al.*, “Perbandingan Performa Arimax-Garch Dan Lstm Pada Data Harga Penutupan Saham PT Aneka Tambang Tbk (ANTM.JK),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 3, pp. 695–704, 2025, doi: 10.25126/jtiik.20258756.
- [30] C. A. Bahri and K. D. Tania, “Perbandingan Kinerja LSTM , Random Forest , dan SVR Berbasis Knowledge Discovery untuk Prediksi Harga Beras Sumatera Selatan,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 12, no. 5, pp. 721–732, 2025, doi: 10.30865/jurikom.v12i5.9140.
- [31] N. Sunendar, H. P. Putro, and R. Hesnananda, “Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU,” *J. Sains dan Teknol.*, vol. 4, no. 1, pp. 113–126, 2025, doi: 10.55123/insologi.v4i1.4868.
- [32] I. K. Dewi, “Strategi Kebijakan Badan Pangan Nasional Melalui Pendekatan Berbasis Spasial Dalam Rangka Menjaga Stabilitas Pasokan dan Harga Pangan,” *J. Econ. Bus. Account.*, vol. 8, no. 2, pp. 2782–2802, 2025.
- [33] A. T. Hidayat, D. P. Sari, and P. Andriani, “Forecasting Penjualan Produk Sembako Menggunakan Metode Triple Exponential Smoothing,” *RESOLUSI Rekayasa Tek. Inform. dan Inf.*, vol. 4, no. 4, pp. 436–445, 2024, doi: <https://doi.org/10.30865/resolusi.v4i4.1754>.