

Analisis Komparatif Akurasi dan Stabilitas Model Peramalan Harga Beras Harian Nasional

Restu Puji Hidayat

Pusat Sosial Ekonomi dan Kebijakan Pertanian, Kementerian Pertanian, Bogor, Indonesia

e-mail : restupuji@pertanian.go.id.

Artikel ini diajukan 2 Maret 2026, direvisi 5 Agustus 2026, diterima 5 Agustus 2026, dan dipublikasikan 25 September 2026.

Abstract

Daily forecasting of national rice prices is important for supporting data-driven food price monitoring systems. This study evaluates statistical, machine learning, and deep learning approaches for forecasting Indonesia's national rice prices over the 2017–2025 period. Missing values in the daily data were handled using the Last Observation Carried Forward (LOCF) method, limited to gaps of up to seven days, which successfully filled all missing observations. The completed time series was then transformed into a supervised learning format using a seven-day sliding window selected through temporal analysis and validation-based sensitivity testing. The dataset was divided chronologically, with the final 90 days reserved as the test set. The evaluated models included Seasonal Naive, XGBoost, Support Vector Regression optimized using Particle Swarm Optimization (SVR-PSO), and Temporal Convolutional Network (TCN). Model performance was evaluated using MAE, RMSE, MAPE, and MSE, while SVR-PSO and TCN were each run 10 times to assess performance stability. SVR-PSO achieved the best performance, with an MAE of 16.830 ± 2.722 , an RMSE of 22.189 ± 2.216 , a MAPE of $0.1068\% \pm 0.0173$, and an MSE of 497.270 ± 107.992 . These findings indicate that SVR-PSO produces relatively accurate and stable short-term forecasts and has the potential to support the development of data-driven national food price monitoring and forecasting systems.

Keywords: Rice Price, Time Series Forecasting, Model Comparison, Model Stability

Abstrak

Peramalan harga beras harian pada tingkat nasional penting untuk mendukung sistem pemantauan harga pangan berbasis data. Penelitian ini mengevaluasi pendekatan statistik, machine learning, dan deep learning dalam meramalkan harga beras nasional Indonesia periode 2017–2025. Nilai kosong pada data harian ditangani menggunakan metode *Last Observation Carried Forward* (LOCF) yang dibatasi pada celah maksimum tujuh hari dan berhasil mengisi seluruh nilai kosong. Deret waktu yang telah lengkap kemudian ditransformasikan ke dalam format supervised learning menggunakan *sliding window* tujuh hari yang dipilih melalui analisis temporal dan pengujian sensitivitas berbasis data validasi. Dataset dibagi secara kronologis dengan 90 hari terakhir sebagai data uji. Model yang dievaluasi meliputi *Seasonal Naive*, *XGBoost*, *Support Vector Regression* yang dioptimasi menggunakan *Particle Swarm Optimization* (SVR-PSO), dan *Temporal Convolutional Network* (TCN). Kinerja model dievaluasi menggunakan MAE, RMSE, MAPE, dan MSE, sedangkan SVR-PSO dan TCN masing-masing dijalankan sebanyak 10 kali untuk menilai stabilitas performa. SVR-PSO menghasilkan kinerja terbaik dengan MAE sebesar $16,830 \pm 2,722$, RMSE sebesar $22,189 \pm 2,216$, MAPE sebesar $0,1068\% \pm 0,0173$, dan MSE sebesar $497,270 \pm 107,992$. Temuan ini menunjukkan bahwa SVR-PSO menghasilkan peramalan jangka pendek yang relatif akurat dan stabil serta berpotensi mendukung pengembangan sistem pemantauan dan peramalan harga pangan nasional berbasis data.

Kata Kunci: Harga Beras, Peramalan Deret Waktu, Perbandingan Model, Stabilitas Model

1. PENDAHULUAN

Beras merupakan komoditas pangan strategis di Indonesia yang berperan terhadap stabilitas ekonomi dan ketahanan pangan nasional. Fluktuasi harga beras memengaruhi inflasi, daya beli masyarakat, serta efektivitas kebijakan stabilisasi pangan, sehingga peramalan harga yang



Artikel ini didistribusikan mengikuti lisensi Atribusi-NonKomersial CC BY-NC sebagaimana tercantum pada <https://creativecommons.org/licenses/by-nc/4.0/>.

akurat khususnya pada skala nasional dan resolusi harian menjadi kebutuhan penting dalam pengambilan keputusan berbasis data. Karakteristik harga beras menunjukkan pola deret waktu yang kompleks dengan tren, persistensi yang kuat, fluktuasi jangka pendek, serta potensi perubahan level dan *missing values* yang dapat memengaruhi reliabilitas model.

Urgensi peramalan harga beras juga terlihat dari peningkatan harga yang cukup tinggi. Badan Pusat Statistik (BPS) mencatat bahwa pada September 2023, rata-rata harga beras kualitas premium dan medium di tingkat penggilingan masing-masing mencapai Rp12.900 dan Rp12.685 per kilogram, meningkat sebesar 9,75% dan 10,55% dibandingkan bulan sebelumnya. Secara tahunan, harga beras premium dan medium meningkat masing-masing sebesar 25,83% dan 29,64% dibandingkan September 2022 (Badan Pusat Statistik, 2023). Kondisi tersebut menunjukkan perlunya metode peramalan harian yang akurat untuk mendukung pemantauan harga pangan.

Berbagai pendekatan statistik telah digunakan dalam peramalan harga beras pada konteks regional, seperti *Holt-Winters Exponential Smoothing* (Fitri et al., 2025), *AutoRegressive Integrated Moving Average* (ARIMA) di Kota Kupang (Toy, 2025), ARIMA dan *AutoRegressive Integrated Moving Average with Exogenous Variables* (ARIMAX) di Jawa Timur (Priyanto & Indrasetianingsih, 2025), serta ARIMA pada tingkat penggilingan nasional (Saputra et al., 2025). Pendekatan adaptif seperti *Bayesian Dynamic Linear Models* juga menunjukkan performa tinggi dalam menangkap tren dan musiman (Ramdani & Komara Rifai, 2025), sementara *Exponential Smoothing* di Surakarta (Febryanti & Budihartanti, 2025) dan jaringan saraf tiruan berbasis *backpropagation* di Padang (Nisa et al., 2025) mengindikasikan bahwa metode statistik maupun *machine learning* efektif pada skala lokal.

Pada tingkat internasional, model ARIMA juga digunakan untuk memproyeksikan konsumsi komoditas pangan strategis seperti beras dan jagung guna mendukung kebijakan pangan jangka panjang (Maganga, 2025). Di Indonesia, perkembangan terkini dalam literatur menunjukkan pergeseran menuju pemodelan *spasio-temporal* yang lebih kompleks, seperti *Geographically and Temporally Weighted Spline Regression* (GTWSR) yang mampu menangkap dinamika nonlinier antarwilayah dengan akurasi tinggi (Sifriyani et al., 2025). Selain itu, pendekatan *machine learning* seperti *Support Vector Regression* (SVR) yang efektif dalam memodelkan fenomena pertanian nonlinier (Hidayat et al., 2024), serta didukung analisis *spasio-temporal* berbasis klaster untuk memahami stabilitas produksi wilayah (Hidayat, 2025).

Meskipun berbagai pendekatan telah digunakan dalam peramalan harga beras, sebagian besar penelitian masih berfokus pada data bulanan atau cakupan wilayah terbatas, sementara kajian berbasis deret waktu harian nasional jangka panjang relatif masih terbatas. Studi komparatif lintas pendekatan statistik, *machine learning*, dan *deep learning* juga belum banyak disertai evaluasi stabilitas model melalui *repeated runs* pada periode uji yang konsisten. Selain itu, optimasi *hyperparameter* berbasis metaheuristik seperti *Particle Swarm Optimization* (PSO) untuk meningkatkan performa SVR pada data harga beras harian nasional belum dievaluasi secara sistematis. Oleh karena itu, penelitian ini difokuskan pada evaluasi komparatif peramalan harga beras harian nasional melalui pendekatan multi-metode dan analisis stabilitas model.

Penelitian ini bertujuan membangun dan mengevaluasi model peramalan harga beras harian nasional Indonesia menggunakan *Seasonal Naive* sebagai *baseline* statistik, XGBoost dan SVR yang dioptimasi dengan PSO (SVR-PSO) sebagai pendekatan *machine learning*. *Temporal Convolutional Network* (TCN) digunakan sebagai pembanding berbasis *deep learning*. Evaluasi dilakukan pada 90 hari terakhir menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). SVR-PSO dan TCN masing-masing dijalankan sebanyak 10 kali untuk menilai stabilitas performa, sedangkan *Seasonal Naive* dan XGBoost dievaluasi menggunakan konfigurasi tetap.



2. METODE PENELITIAN

2.1 Dataset dan Prapemrosesan

Data yang digunakan merupakan data harga beras pasar tradisional dengan frekuensi harian pada periode tahun 2017 hingga 2025 yang bersumber dari Pusat Informasi Harga Pangan Strategis Nasional (PIHPS). Dataset memuat informasi tanggal pengamatan, wilayah, serta harga beras. Penelitian ini difokuskan pada deret waktu harga beras nasional yang tersedia secara eksplisit pada dataset dengan label wilayah “INDONESIA”, sehingga analisis dilakukan pada tingkat nasional. Data harga beras harian dipilih pada tingkat nasional untuk menggambarkan dinamika agregat harga pangan strategis yang relevan bagi pengambil keputusan untuk stabilisasi harga (Matondang et al., 2024).

Data deret waktu harian mengandung sejumlah nilai kosong (*missing values*). Untuk menjaga kontinuitas data, dilakukan pra-pemrosesan menggunakan strategi bertingkat. Pada tahap pertama diterapkan metode *Last Observation Carried Forward* (LOCF) untuk mengisi gap pendek dengan memanfaatkan observasi terakhir yang tersedia. Penerapannya dibatasi pada gap maksimum tujuh hari untuk mengurangi distorsi terhadap dinamika temporal (Niako et al., 2024). Secara matematis, metode LOCF dinyatakan pada Pers. (1).

$$\hat{y}_t = y_{t-k}, k = \min\{j \mid y_{t-j} \text{ teramati}\} \quad (1)$$

Nilai taksiran pada waktu t diisi menggunakan observasi terakhir sebelum t yang tersedia. Apabila setelah tahap LOCF masih terdapat nilai kosong, dilakukan tahap kedua berupa interpolasi berbasis waktu (*time-based interpolation*) untuk mengisi gap menengah, mengingat pendekatan interpolasi linier banyak digunakan dalam imputasi deret waktu (Flores et al., 2024). Untuk dua titik waktu teramati t_1 dan t_2 dengan $t_1 < t < t_2$, nilai pada waktu t dihitung menggunakan interpolasi linier pada Pers. (2).

$$\hat{y}_t = y_{t_1} + \frac{y_{t_2} - y_{t_1}}{t_2 - t_1}(t - t_1) \quad (2)$$

Panjang gap yang dapat diisi menggunakan interpolasi dibatasi maksimum 60 hari. Pembatasan panjang celah pada metode LOCF dan interpolasi bertujuan untuk mencegah propagasi nilai historis secara berlebihan yang berpotensi mengaburkan variasi harga harian. Dengan pembatasan tersebut, kedua metode digunakan sesuai dengan panjang gap yang terdapat pada deret waktu.

Sebagai langkah terakhir, apabila masih terdapat nilai kosong yang tidak dapat diisi oleh dua tahap sebelumnya, dilakukan pengisian menggunakan nilai median deret waktu harga beras nasional sebagai bentuk imputasi deterministik sederhana (Alwateer et al., 2024). Secara matematis, nilai median didefinisikan pada Pers. (3), sedangkan nilai kosong diisi menggunakan Pers. (4). Penggunaan median pada tahap terakhir bertujuan untuk memastikan bahwa seluruh nilai kosong yang tersisa telah terisi sebelum data digunakan pada tahap pemodelan.

$$m = \text{median}(\{y_1, y_2, \dots, y_T\}) \quad (3)$$

$$\hat{y}_t = m \quad (4)$$

Strategi imputasi bertingkat ini dipilih untuk menjaga kontinuitas data sekaligus mempertahankan dinamika alami deret waktu. Melalui strategi tersebut, diperoleh deret waktu harga beras nasional yang lengkap dan tanpa nilai hilang. Data hasil pra-pemrosesan selanjutnya digunakan dalam pembentukan dataset untuk pemodelan *supervised learning*.

Karakteristik perubahan harga dianalisis berdasarkan selisih harga harian. Karena sebagian besar perubahan bernilai nol, batas potensi perubahan ekstrem dihitung menggunakan metode



Interquartile Range (IQR) hanya pada perubahan harga yang tidak bernilai nol. Suatu perubahan dikategorikan sebagai potensi nilai ekstrem apabila berada di bawah $Q1 - 1,5IQR$ dan $Q3 + 1,5IQR$. Namun, observasi tersebut tetap dipertahankan karena nilai ekstrem belum tentu menunjukkan kesalahan pencatatan dan dapat mencerminkan perubahan harga yang benar-benar terjadi.

2.2 Analisis Karakteristik Temporal dan Pemilihan *Sliding Window*

Karakteristik temporal deret waktu dianalisis menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), baik pada seri harga asli maupun pada *first difference*, dengan maksimum 30 lag. Analisis pada seri harga asli bertujuan mengidentifikasi persistensi tingkat harga, sedangkan analisis pada *first difference* digunakan untuk mengidentifikasi dependensi temporal pada perubahan harga setelah pengaruh tren dikurangi. Analisis ACF dan PACF dilakukan menggunakan data sebelum periode pengujian 90 hari agar informasi dari data uji tidak digunakan dalam pengambilan keputusan pemodelan. Hasil analisis tersebut digunakan sebagai dasar untuk mengidentifikasi rentang lag yang relevan dan menentukan kandidat ukuran *sliding window*. Selanjutnya, kandidat ukuran jendela dibandingkan berdasarkan nilai RMSE pada data validasi. Ukuran jendela yang menghasilkan nilai RMSE terendah dipilih sebagai ukuran *sliding window* yang selanjutnya diterapkan secara konsisten pada seluruh model agar perbandingan kinerja dilakukan menggunakan struktur input yang sama.

2.3 Pembentukan Data *Supervised*

Deret waktu harga beras harian ditransformasikan ke dalam format *supervised learning* menggunakan pendekatan *sliding window* (Leites et al., 2024). Pemilihan ukuran jendela merupakan tahap penting karena jendela yang terlalu pendek dapat menghilangkan informasi temporal yang relevan, sedangkan jendela yang terlalu panjang dapat meningkatkan kompleksitas model dan risiko *overfitting*. Dalam proses transformasi, sejumlah w observasi terdahulu digunakan sebagai variabel prediktor untuk memperkirakan harga pada periode berikutnya. Dengan demikian, fungsi peramalan dirumuskan dalam Pers. (5).

$$\hat{y}_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-w}) \quad (5)$$

Pada Pers. (5), $\hat{y}_t$ merupakan peramalan harga pada waktu t , sedangkan $y_{t-1}, y_{t-2}, \dots, y_{t-w}$ merupakan harga pada w periode sebelumnya. Sementara itu, $f(\cdot)$ merupakan fungsi peramalan yang dipelajari oleh model. Formulasi tersebut memungkinkan informasi dari sejumlah periode sebelumnya digunakan untuk memprediksi harga pada satu periode berikutnya.

Dataset hasil transformasi kemudian dibagi secara kronologis tanpa pengacakan menjadi data latih, data validasi, dan data uji. Data latih digunakan untuk membangun model, data validasi digunakan untuk memilih ukuran *sliding window* dan mengoptimalkan *hyperparameter*, sedangkan data uji hanya digunakan untuk mengevaluasi kinerja akhir model. Pembagian secara kronologis dilakukan untuk mempertahankan struktur temporal data serta mencegah masuknya informasi dari periode mendatang ke dalam proses pelatihan atau *data leakage* (Albelali & Ahmed, 2025).

Evaluasi model dilakukan menggunakan skema *rolling one-step-ahead*. Pada skema ini, harga pada setiap hari diramal berdasarkan observasi aktual yang tersedia hingga hari sebelumnya. Setelah peramalan untuk suatu hari dihasilkan, nilai aktual pada hari tersebut dapat digunakan sebagai bagian dari input untuk meramal harga pada hari berikutnya.

2.4 Seasonal Naive

Model *Seasonal Naive* digunakan sebagai *baseline* statistik sederhana karena pendekatan *naive* merupakan tolok ukur fundamental dalam evaluasi model peramalan dan sering kali sulit dikalahkan pada deret waktu dengan volatilitas tinggi (Beck et al., 2025). Dalam penelitian ini digunakan variasi *seasonal naive*, di mana peramalan pada waktu t diperoleh dari nilai harga



pada periode musiman sebelumnya dengan periode musiman $s = 7$ hari, sebagaimana dirumuskan pada Pers. (6). Seasonal Naive menggunakan harga tujuh hari sebelumnya sebagai peramalan dan berfungsi sebagai baseline untuk menilai apakah informasi pada lag mingguan masih memiliki kemampuan prediktif.

$$\hat{y}_t = y_{t-s} \quad (6)$$

2.5 XGBoost

XGBoost merupakan model *ensemble* berbasis *gradient boosting* yang membangun prediktor sebagai penjumlahan dari sejumlah pohon keputusan. Secara umum, peramalan untuk suatu observasi i dengan K pohon dapat dirumuskan pada Pers. (7). Pada Pers. (7), f_k merupakan fungsi pohon keputusan, sedangkan $\mathcal{F}$ menyatakan ruang seluruh pohon regresi yang mungkin. Proses pelatihan model dilakukan dengan meminimalkan fungsi objektif yang terdiri dari komponen kerugian (*loss*) dan regularisasi, sebagaimana dirumuskan pada Pers. (8). Pada Pers. (8), l adalah fungsi kerugian yang mengukur kesalahan peramalan, sedangkan Ω merupakan fungsi regularisasi untuk mengendalikan kompleksitas model dan menghindari *overfitting*. Pendekatan ini efektif dalam menangkap hubungan nonlinier yang kompleks serta meningkatkan akurasi peramalan pada data deret waktu (Aisy et al., 2025).

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in \mathcal{F} \quad (7)$$

$$\mathcal{L} = \sum_i l(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (8)$$

2.6 Support Vector Regression-Particle Swarm Optimization (SVR-PSO)

SVR bertujuan untuk mencari suatu fungsi regresi yang memaksimalkan margin dengan toleransi kesalahan tertentu. Fungsi regresi SVR dapat dirumuskan pada Pers. (9). Pada Pers. (9), $\phi(x)$ merupakan fungsi pemetaan input ke ruang fitur berdimensi tinggi. Proses optimasi SVR dilakukan dengan meminimalkan fungsi objektif pada Pers. (10) dengan kendala pada Pers. (11). Pada penelitian ini digunakan kernel *Radial Basis Function* (RBF) sebagaimana dirumuskan pada Pers. (12). SVR efektif dalam peramalan jangka pendek pada data dengan karakteristik nonlinier dan tidak pasti, serta mampu memberikan kinerja yang kompetitif dibandingkan model pembelajaran mesin lainnya (Duan et al., 2025).

$$f(x) = w^T \phi(x) + b \quad (9)$$

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} |w|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (10)$$

$$\begin{aligned} y_i - f(x_i) &\leq \epsilon + \xi_i \\ f(x_i) - y_i &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (11)$$

$$K(x_i, x_j) = \exp(-\gamma |x_i - x_j|^2) \quad (12)$$

Parameter C , γ , dan ϵ dioptimasi menggunakan metode PSO, di mana setiap partikel merepresentasikan kandidat kombinasi parameter. Pembaruan kecepatan dan posisi partikel masing-masing dirumuskan pada Pers. (13) dan Pers. (14). Pendekatan hibrid SVR-PSO ini bertujuan meningkatkan akurasi dan stabilitas model melalui optimasi global *hyperparameter*, serta menunjukkan potensi peningkatan performa prediktif (Alnaqbi et al., 2025).



$$v_i^{(t+1)} = wv_i^{(t)} + c_1r_1(p_i - x_i^{(t)}) + c_2r_2(g - x_i^{(t)}) \quad (13)$$

$$x_i^{(t+1)} = x_i^{(t)} + v_i^{(t+1)} \quad (14)$$

2.7 Temporal Convolutional Network (TCN)

TCN merupakan model *deep learning* berbasis *dilated causal convolution* yang dirancang untuk menangkap dependensi temporal dalam deret waktu (Hewage et al., 2020). Berbeda dengan model berbasis *recurrent*, TCN menggunakan konvolusi kausal sehingga peramalan pada waktu t hanya bergantung pada informasi masa lalu. Operasi konvolusi kausal dengan faktor dilasi d didefinisikan pada Pers. (15).

$$y(t) = \sum_{k=0}^{K-1} w_k x(t - d \cdot k) \quad (15)$$

Penggunaan dilasi memungkinkan model memanfaatkan informasi dari rentang waktu yang lebih panjang secara efisien. Selain itu, arsitektur TCN dirancang untuk menjaga stabilitas proses pelatihan sehingga model tetap mampu belajar dari data historis tanpa mengalami penurunan performa. TCN juga menunjukkan kinerja yang kompetitif dibandingkan dengan model lainnya (Hewage et al., 2020).

2.8 Konfigurasi dan Hyperparameter Model

Hyperparameter setiap model disajikan pada Tabel 1. Parameter SVR, yaitu C , γ , dan ϵ , dioptimasi menggunakan PSO berdasarkan MSE data validasi. SVR-PSO dan TCN dijalankan sebanyak 10 kali untuk menilai stabilitas, sedangkan Seasonal Naive dan XGBoost menggunakan konfigurasi tetap.

Tabel 1 Konfigurasi dan Hyperparameter Model

Model	Konfigurasi
Seasonal Naive	Lag musiman 7 hari
XGBoost	n_estimators=300, max_depth=4, learning_rate=0,03, subsample=0,9, colsample_bytree=0,9, reg_lambda=1, objective=reg:squarederror, dan random_state=42
SVR-PSO	Menggunakan kernel RBF; $C=1-1.000$, $\gamma=0,001-1$, $\epsilon=0,01-0,50$; Optimasi PSO menggunakan 6 partikel dan 8 iterasi dengan $c_1=1,2$; $c_2=1,2$; dan $w=0,7$
TCN	Menggunakan 24 filter, ukuran kernel 3, dilation rate 1–2–4–8, dense layer 48 unit, optimizer Adam dengan learning rate 0,001, batch size 64, maksimum 80 epoch, dan patience 7
Repeated runs	Model SVR-PSO dan TCN masing-masing dijalankan sebanyak 10 kali

2.9 Evaluasi Kinerja Model

Evaluasi kinerja model tidak hanya bertujuan untuk mengukur tingkat akurasi peramalan, tetapi juga untuk menilai reliabilitas dan konsistensi performa model dalam penerapan empiris. Dalam studi peramalan modern, praktik evaluasi yang sistematis dan pelaporan hasil yang transparan menjadi aspek penting untuk memastikan interpretasi yang tepat terhadap kinerja model (Hewamalage et al., 2021).

Untuk mengukur tingkat kesalahan peramalan, penelitian ini menggunakan empat metrik evaluasi yang umum digunakan dalam literatur peramalan, yaitu MAE, MSE, RMSE, dan MAPE. Penggunaan lebih dari satu metrik memungkinkan evaluasi yang lebih komprehensif terhadap



karakteristik kesalahan peramalan (Strøm & Gundersen, 2024). Seluruh metrik dihitung pada periode pengujian yang mencakup 90 hari terakhir data observasi guna merepresentasikan performa model dalam kondisi peramalan *out-of-sample* yang realistis. Periode tersebut dipilih untuk mengevaluasi performa peramalan jangka pendek pada fase terbaru deret waktu.

MAE mengukur rata-rata selisih absolut antara nilai aktual dan nilai peramalan, sebagaimana dirumuskan pada Pers. (16). MSE menghitung rata-rata kuadrat kesalahan peramalan dan dirumuskan pada Pers. (17). RMSE memberikan penalti lebih besar terhadap kesalahan berukuran besar dan didefinisikan pada Pers. (18). Sementara itu, MAPE mengukur kesalahan peramalan dalam bentuk persentase dan dirumuskan pada Pers. (19).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (19)$$

Selain pemilihan metrik evaluasi, prosedur pengujian juga disesuaikan dengan karakteristik masing-masing algoritma. Model yang melibatkan komponen optimasi atau inisialisasi acak, seperti SVR-PSO dan TCN, berpotensi menghasilkan variasi performa antar eksekusi. Oleh karena itu, hasil evaluasi untuk model tersebut dilaporkan dalam bentuk nilai rata-rata dan standar deviasi dari 10 kali percobaan. Pendekatan ini digunakan untuk mengakomodasi variasi akibat komponen stokastik serta memastikan estimasi performa yang lebih reliabel (Noori et al., 2026).

Seasonal Naive merupakan model deterministik dan dievaluasi satu kali. XGBoost menggunakan mekanisme subsampling, tetapi dijalankan dengan konfigurasi dan random seed tetap sehingga hasilnya dapat direproduksi pada data dan lingkungan komputasi yang sama. Kemampuan generalisasi dan potensi *overfitting* dianalisis pada XGBoost, SVR-PSO, dan TCN melalui perbandingan RMSE pada data latih, validasi, dan uji. Pada TCN dilakukan analisis kurva *training loss*, *validation loss*, dan *early stopping* yang digunakan untuk mengembalikan bobot model pada *validation loss* terendah. *Seasonal Naive* tidak disertakan dalam diagnosis *overfitting* karena tidak melalui proses pelatihan dan tidak memiliki parameter yang dipelajari dari data.

3. HASIL DAN PEMBAHASAN


3.1 Prapemrosesan dan Karakteristik Deret Waktu

Deret waktu harga beras harian yang digunakan dalam penelitian ini memiliki total 3.041 observasi. Pada tahap awal, teridentifikasi sebanyak 885 *missing value*, yang mencerminkan adanya ketidaklengkapan pencatatan harga pada beberapa periode observasi. Untuk menjaga kontinuitas data, dilakukan pra-pemrosesan menggunakan strategi imputasi bertingkat. Hasil menunjukkan bahwa setelah penerapan metode LOCF terbatas dengan maksimum *gap* 7 hari, seluruh nilai kosong berhasil diisi sehingga jumlah *missing value* menjadi 0. Dengan demikian, tahap interpolasi berbasis waktu maupun pengisian median tidak lagi diperlukan. Deret waktu telah menjadi lengkap, memiliki frekuensi harian yang konsisten, dan layak digunakan untuk




pembentukan dataset *supervised learning*, dengan tetap menjaga urutan temporal guna mencegah terjadinya kebocoran informasi.

Pada Gambar 1 merupakan deret waktu harga beras harian nasional periode 2017–2025 yang menunjukkan bahwa pada rentang 2017 hingga akhir 2022 harga relatif stabil di kisaran Rp11.500–Rp12.000 per kilogram, meskipun sempat mengalami kenaikan moderat pada 2017–2018. Selama periode 2017 hingga pertengahan 2022, pergerakan harga cenderung datar dengan fluktuasi yang terbatas, mencerminkan kondisi harga yang cukup terkendali. Terdapat beberapa peningkatan atau penurunan yang bersifat sesaat (*spike*) yang mencerminkan fluktuasi jangka pendek dalam dinamika harga, namun juga tidak menutup kemungkinan merupakan *outlier* atau gangguan dalam pencatatan data harian, karena tidak berkembang menjadi tren peningkatan maupun penurunan yang berkelanjutan.



Gambar 1 Deret Waktu Harga Beras Harian Nasional Periode 2017–2025

Perubahan signifikan terjadi mulai pertengahan tahun 2022 ketika harga beras meningkat secara konsisten, menandai adanya pergeseran struktur harga. Kenaikan berlanjut sepanjang 2023 dan mencapai puncaknya pada 2024 hingga mendekati Rp16.000 per kilogram, level tertinggi dalam periode pengamatan. Memasuki 2025, harga sempat terkoreksi ringan namun tetap bertahan pada kisaran tinggi sekitar Rp15.200–Rp15.800, tidak kembali ke level sebelum 2023. Hal ini mengindikasikan terbentuknya level harga baru yang berpotensi memengaruhi dinamika stabilitas harga.



Gambar 2 Perubahan Harga Beras Harian dan Batas Potensi Perubahan Ekstrem Berdasarkan IQR Perubahan *Nonzero*

Gambar 2 menunjukkan perubahan harga beras harian dan batas potensi perubahan ekstrem. Dari 3.040 perubahan harian, sebanyak 2.475 observasi atau 81,41% tidak mengalami perubahan harga, sedangkan 565 observasi atau 18,59% menunjukkan perubahan. Analisis IQR pada perubahan *nonzero* menghasilkan kuartil pertama sebesar –Rp50, kuartil ketiga sebesar Rp50, dan IQR sebesar Rp100. Dengan demikian, perubahan yang lebih rendah dari –Rp200 atau lebih tinggi dari Rp200 per hari dikategorikan sebagai potensi perubahan ekstrem. Berdasarkan batas tersebut, terdapat 107 observasi ekstrem, setara dengan 18,94% dari




perubahan *nonzero* atau 3,52% dari seluruh perubahan harian. Perubahan minimum dan maksimum masing-masing mencapai –Rp2.500 dan Rp2.500 per hari.

Observasi tersebut tetap dipertahankan karena dapat menggambarkan dinamika pasar yang nyata, penyesuaian pencatatan, maupun variasi jangka pendek pada data. Proporsi perubahan bernilai nol mencerminkan stabilitas harga harian yang relatif tinggi, sekaligus menunjukkan kontribusi LOCF dalam menjaga kontinuitas deret waktu pada periode yang sebelumnya memiliki nilai kosong.

3.2 Analisis ACF/PACF dan Pemilihan Sliding Window

Gambar 3 menunjukkan ACF dan PACF harga beras harian nasional pada seri asli dan *first difference*. Pada seri asli, nilai ACF sangat tinggi dan menurun secara lambat, yaitu sebesar 0,992 pada lag pertama, 0,981 pada lag ke-7, 0,975 pada lag ke-14, dan masih mencapai 0,956 pada lag ke-30. Pola tersebut menunjukkan persistensi harga yang sangat kuat serta mengindikasikan adanya tren atau perubahan level dalam deret waktu.



Gambar 3 ACF dan PACF Harga Beras Harian Nasional: (A) ACF Seri Asli; (B) PACF Seri Asli; (C) ACF First Difference; dan (D) PACF First Difference.


PACF seri asli menunjukkan nilai dominan pada lag pertama sebesar 0,992, kemudian menurun menjadi 0,294 pada lag kedua, 0,130 pada lag ketiga, dan 0,156 pada lag keempat. Nilai PACF pada lag berikutnya relatif kecil. Hasil ini menunjukkan bahwa pengaruh langsung harga masa lalu terutama terkonsentrasi pada satu hari sebelumnya, sedangkan korelasi pada lag yang lebih panjang sebagian besar merupakan pengaruh tidak langsung dari persistensi harga.

Setelah dilakukan *first difference*, korelasi temporal menurun secara substansial. ACF pada lag pertama bernilai –0,332, sedangkan pada lag ke-3 sebesar –0,100. Nilai ACF pada lag ke-7 dan ke-14 masing-masing hanya sebesar –0,023 dan 0,004. PACF *first difference* juga menunjukkan korelasi negatif pada lag pertama, kedua, dan ketiga, yaitu masing-masing sebesar –0,332, –0,166, dan –0,196, kemudian secara bertahap mendekati nol. Hal ini menunjukkan bahwa perubahan harga memiliki dependensi jangka pendek dan tidak memperlihatkan lonjakan korelasi yang kuat pada lag ke-7 maupun ke-14.

Berdasarkan karakteristik tersebut, dilakukan sensitivity analysis menggunakan *sliding window* 7, 14, 21, dan 28 hari (Gambar 4). *Window* tujuh hari menghasilkan validation RMSE terendah sebesar 87,231, diikuti *window* 28 hari sebesar 88,006, *window* 21 hari sebesar 88,624, dan



window 14 hari sebesar 88,738. Oleh karena itu, *sliding window* tujuh hari dipilih sebagai input model peramalan.



Gambar 4 Perbandingan Validation RMSE pada *Sliding Window* 7, 14, 21, dan 28 Hari

3.3 Pembagian Data dan Periode Evaluasi

Dataset dibentuk menggunakan *sliding window* tujuh hari. Penggunaan jendela tersebut menyebabkan tujuh observasi awal tidak dapat digunakan sebagai target peramalan karena belum memiliki lag yang lengkap untuk membentuk pasangan input–output. Dengan demikian, jumlah observasi pada dataset berkurang dari 3.041 menjadi 3.034 observasi.

Dataset kemudian dibagi secara kronologis tanpa pengacakan menjadi data latih sebanyak 2.642 observasi (87,08%), data validasi sebanyak 302 observasi (9,95%), dan data uji sebanyak 90 observasi (2,97%). Data latih mencakup periode 11 September 2017 hingga 4 Desember 2024, data validasi mencakup periode 5 Desember 2024 hingga 2 Oktober 2025, sedangkan data uji mencakup 90 hari terakhir, yaitu 3 Oktober hingga 31 Desember 2025.

Pembagian secara kronologis dilakukan untuk menjaga urutan temporal dan mencegah informasi masa depan digunakan dalam proses pelatihan. Data validasi digunakan untuk pemilihan ukuran *sliding window* dan optimasi *hyperparameter*, sedangkan data uji hanya digunakan untuk evaluasi akhir. Pengujian dilakukan menggunakan skema *rolling one-step-ahead*, yaitu harga pada setiap hari diramal dengan memanfaatkan observasi aktual yang tersedia hingga hari sebelumnya.

3.4 Perbandingan Kinerja Model Peramalan

Tabel 2 menyajikan perbandingan kinerja model berdasarkan MAE, RMSE, MAPE, dan MSE. Nilai *error* yang lebih kecil menunjukkan akurasi peramalan yang lebih baik. Standar deviasi digunakan untuk menilai variasi performa SVR-PSO dan TCN pada 10 kali pengujian. Standar deviasi tidak dilaporkan untuk *Seasonal Naive* dan XGBoost karena kedua model hanya dievaluasi satu kali menggunakan konfigurasi tetap.

SVR-PSO menunjukkan kinerja yang baik pada seluruh metrik, dengan MAE sebesar $16,830 \pm 2,722$, RMSE sebesar $22,189 \pm 2,216$, MAPE sebesar $0,1068\% \pm 0,0173$, dan MSE sebesar $497,270 \pm 107,992$. Nilai *error* yang paling rendah dan variasi antar-*run* yang relatif kecil menunjukkan bahwa SVR-PSO menghasilkan peramalan yang lebih akurat dan konsisten dibandingkan model lainnya.

TCN menghasilkan MAE sebesar $24,259 \pm 9,618$, RMSE sebesar $30,077 \pm 9,319$, MAPE sebesar $0,1539\% \pm 0,0610$, dan MSE sebesar $991,469 \pm 651,708$. Secara rata-rata, TCN menempati posisi kedua berdasarkan RMSE dan MSE. Namun, standar deviasi yang relatif besar menunjukkan bahwa performanya cukup sensitif terhadap inisialisasi bobot dan proses pelatihan.



XGBoost menghasilkan MAE sebesar 27,244, RMSE sebesar 32,420, MAPE sebesar 0,1730%, dan MSE sebesar 1.051,066. Dibandingkan *Seasonal Naive*, XGBoost memiliki RMSE dan MSE yang lebih rendah, tetapi MAE dan MAPE yang lebih tinggi. Hal ini menunjukkan bahwa XGBoost mampu mengurangi kesalahan berukuran besar, tetapi secara rata-rata menghasilkan deviasi absolut dan persentase kesalahan yang lebih tinggi.

Tabel 2 Perbandingan Kinerja Model Peramalan Harga Beras Nasional pada Data Uji


Model	SVR-PSO	TCN	XGBoost_fixed_seed	SeasonalNaive(t-7)
Runs	10	10	1	1
MAE_mean	16,8297	24,2588	27,2442	22,2222
MAE_std	2,7218	9,6177	—	—
RMSE_mean	22,1891	30,0769	32,4201	34,1565
RMSE_std	2,2159	9,3192	—	—
MAPE_mean	0,1068	0,1539	0,1730	0,1409
MAPE_std	0,0172	0,0610	—	—
MSE_mean	497,2704	991,4691	1.051,0655	1.166,6667
MSE_std	107,9918	651,7081	—	—

Seasonal Naive (t-7) menghasilkan MAE sebesar 22,222, RMSE sebesar 34,157, MAPE sebesar 0,1409%, dan MSE sebesar 1.166,667. Kinerja MAE dan MAPE yang cukup kompetitif menunjukkan bahwa harga tujuh hari sebelumnya masih mengandung informasi prediktif yang relevan. Namun, hasil tersebut tidak secara langsung membuktikan adanya pola musiman mingguan yang kuat, melainkan dapat berkaitan dengan persistensi harga dan tingginya proporsi perubahan harga harian yang relatif terbatas.

Secara keseluruhan, SVR-PSO memberikan kombinasi akurasi dan stabilitas terbaik. TCN menunjukkan kemampuan prediktif yang cukup baik tetapi memiliki variasi antar-run yang lebih tinggi, sedangkan XGBoost dan Seasonal Naive menunjukkan keunggulan yang berbeda bergantung pada metrik evaluasi yang digunakan.

3.5 Visualisasi Peramalan pada Periode Uji

Gambar 5 menampilkan perbandingan antara harga aktual dan hasil peramalan keempat model pada periode uji 90 hari terakhir. Garis aktual menunjukkan tren penurunan bertahap sejak awal Oktober hingga awal Desember 2025, kemudian diikuti kenaikan kembali menjelang akhir periode. Pola ini menunjukkan dinamika harga yang relatif stabil dengan fluktuasi jangka pendek pada beberapa titik.



Gambar 5 Perbandingan Harga Aktual dan Hasil Peramalan Model pada Data Uji


Model SVR-PSO memperlihatkan kedekatan yang lebih konsisten terhadap harga aktual. Hal ini dapat dikaitkan dengan kemampuan kernel RBF dalam memodelkan hubungan nonlinear antar-lag, sedangkan optimasi parameter C , γ , dan ϵ menggunakan PSO membantu menyeimbangkan kompleksitas model dan toleransi kesalahan. TCN mampu mengikuti tren umum, tetapi



menunjukkan respons yang lebih bervariasi karena sensitivitas terhadap inialisasi bobot dan proses pelatihan, yang tercermin dari RMSE sebesar $30,077 \pm 9,319$. *Seasonal Naive* cenderung terlambat merespons titik balik karena ramalannya menggunakan harga tujuh hari sebelumnya. Sementara itu, XGBoost dapat mengikuti sebagian pola harga, tetapi struktur yang bersifat bertahap dapat membatasi respons terhadap perubahan yang belum banyak terwakili dalam data pelatihan.

3.6 Stabilitas Model Stokastik Berdasarkan *Repeated Runs*

Gambar 6 memperlihatkan distribusi nilai RMSE dari 10 kali pengujian pada model SVR-PSO dan TCN. SVR-PSO menunjukkan rentang variasi yang relatif sempit dengan median lebih rendah, sehingga mencerminkan konsistensi performa antar-*run*. TCN memiliki penyebaran yang lebih lebar dengan median lebih tinggi, yang menunjukkan adanya fluktuasi performa yang lebih besar. Rentang nilai yang lebih luas pada TCN mengindikasikan sensitivitas yang lebih tinggi terhadap proses pelatihan dan inialisasi parameter.



Gambar 6 Sebaran RMSE pada 10 *Repeated Runs* untuk SVR-PSO dan TCN

3.7 Analisis Generalisasi dan Potensi *Overfitting*

Tabel 3 menunjukkan bahwa seluruh model mampu mempertahankan kinerja yang baik pada data validasi dan uji. Nilai RMSE pada kedua subset tersebut lebih rendah dibandingkan data latih, yang mengindikasikan bahwa model tetap mampu melakukan generalisasi pada periode terbaru. Pola ini tidak menunjukkan *overfitting* klasik, yang umumnya ditandai oleh error pelatihan rendah tetapi error validasi dan pengujian tinggi. Perbedaan nilai RMSE tersebut lebih mencerminkan karakteristik data latih yang mencakup periode lebih panjang dengan variasi harga dan perubahan ekstrem yang lebih beragam. Dengan demikian, ketiga model menunjukkan kemampuan adaptasi yang baik terhadap dinamika temporal pada periode validasi dan pengujian.


Tabel 3 Diagnosis Generalisasi Model Berdasarkan RMSE Data Latih, Validasi, dan Uji

Model	RMSE Train	RMSE Validasi	RMSE Uji
XGBoost	127,816	35,014	32,420
SVR-PSO	178,456	37,323	22,189
TCN	184,280	43,669	30,077

Gambar 7 menyajikan kurva pembelajaran TCN pada *run* terbaik. *Training loss* menurun secara konsisten, sedangkan *validation loss* tetap rendah dan stabil hingga mencapai nilai terbaik sekitar epoch ke-27. Pola tersebut menunjukkan bahwa proses pembelajaran berlangsung secara konvergen tanpa peningkatan *validation loss* yang berkelanjutan. Penerapan *early stopping* juga




membantu memilih bobot model pada kondisi validasi terbaik sehingga mendukung kemampuan generalisasi TCN pada data yang belum digunakan dalam pelatihan.



Gambar 7 Kurva Training Loss dan Validation Loss TCN pada Run Terbaik

3.8 Analisis Distribusi Error dan Kesalahan Harian

Gambar 8 menampilkan distribusi *error* (*Actual–Predicted*) seluruh model pada data uji. Nilai *error* yang mendekati nol menunjukkan bahwa hasil peramalan semakin dekat dengan harga aktual, sedangkan *error* negatif menunjukkan kecenderungan model menghasilkan peramalan lebih tinggi dari nilai aktual dan *error* positif menunjukkan kecenderungan peramalan lebih rendah dari nilai aktual.



Gambar 8 Distribusi Error (*Actual – Predicted*) pada Data Uji


Distribusi SVR-PSO terkonsentrasi pada rentang yang relatif dekat dengan nol, terutama pada sisi negatif kecil, dengan penyebaran yang lebih terkendali dibandingkan model lainnya. Pola ini menunjukkan bahwa SVR-PSO mampu menghasilkan kesalahan peramalan yang relatif konsisten, meskipun terdapat sedikit kecenderungan *overprediction*. TCN juga menunjukkan konsentrasi *error* di sekitar nol tetapi memiliki penyebaran yang lebih lebar, konsisten dengan variasi performanya pada *repeated runs*.

Seasonal Naive memiliki frekuensi *error* yang tinggi di sekitar nol, tetapi masih menunjukkan beberapa kelompok *error* pada rentang yang lebih jauh, terutama ketika terjadi perubahan harga yang tidak dapat segera diikuti oleh nilai tujuh hari sebelumnya. XGBoost memperlihatkan distribusi *error* yang lebih menyebar pada sisi negatif maupun positif, yang menunjukkan bahwa deviasi peramalan lebih bervariasi pada beberapa periode pengujian.

Gambar 9 memperlihatkan dinamika nilai absolut *error* harian (*Actual–Predicted*) selama periode uji 90 hari. SVR-PSO umumnya menghasilkan *error* yang relatif rendah dan stabil pada sebagian besar periode, meskipun masih terdapat beberapa lonjakan ketika harga mengalami perubahan



yang lebih tajam. Pola tersebut menunjukkan bahwa model cukup responsif terhadap pergerakan harga harian, tetapi tetap menghadapi tantangan pada titik-titik perubahan mendadak.



Gambar 9 Perbandingan Nilai Error Harian Selama 90 Hari Uji

Seasonal Naive membentuk pola *error* yang cenderung bertingkat/datar karena peramalan didasarkan pada nilai tujuh hari sebelumnya. Model ini memberikan *error* mendekati nol ketika pola harga konstan, tetapi *error* melonjak dan bertahan tinggi saat terjadi pergeseran level harga. XGBoost menunjukkan variasi *error* yang lebar dengan beberapa lonjakan ekstrem, sedangkan TCN mampu mempertahankan *error* yang relatif rendah pada beberapa interval, namun tetap menunjukkan perubahan yang tajam saat terjadi penyesuaian *error*. Peningkatan *error* yang terjadi secara bersamaan pada beberapa model, terutama sekitar awal hingga pertengahan Desember 2025, menunjukkan adanya perubahan harga yang relatif tajam dan belum sepenuhnya tercermin dalam pola historis.

3.9 Implikasi Praktis

Model SVR-PSO menunjukkan kemampuan peramalan harga beras harian dengan tingkat kesalahan yang relatif rendah dan variasi performa antar-*run* yang kecil. Temuan ini mengindikasikan bahwa integrasi SVR dengan optimasi PSO mampu meningkatkan akurasi sekaligus menjaga konsistensi hasil peramalan deret waktu. Stabilitas tersebut menjadi nilai tambah bagi penerapan sistem peramalan yang membutuhkan hasil yang andal dan dapat direproduksi.

Secara praktis, model ini berpotensi diintegrasikan ke dalam sistem pemantauan harga pangan berbasis data untuk mendukung identifikasi dini perubahan harga. Informasi prediktif jangka pendek yang dihasilkan dapat menjadi masukan tambahan bagi pengambil keputusan dalam merespons dinamika harga secara lebih cepat, terukur, dan tepat sasaran, khususnya pada komoditas strategis seperti beras.

4. KESIMPULAN

Hasil evaluasi pada periode uji 90 hari menunjukkan bahwa SVR-PSO menghasilkan kinerja terbaik dengan MAE sebesar $16,830 \pm 2,722$, RMSE sebesar $22,189 \pm 2,216$, MAPE sebesar $0,1068\% \pm 0,0173$, dan MSE sebesar $497,270 \pm 107,992$. Distribusi *error* yang lebih terkonsentrasi di sekitar nol dan variasi antar-*run* yang relatif kecil menunjukkan bahwa SVR-PSO mampu menghasilkan peramalan yang lebih akurat dan konsisten. TCN menunjukkan variabilitas antar-*run* yang lebih besar, sedangkan XGBoost dan *Seasonal Naive* menghasilkan *error* yang lebih tinggi pada beberapa perubahan harga.

Temuan ini menunjukkan bahwa integrasi SVR dengan optimasi PSO merupakan pendekatan yang layak untuk peramalan harga beras harian nasional menggunakan skema *rolling one-step-ahead*. Kinerja *Seasonal Naive* yang cukup kompetitif menunjukkan bahwa harga tujuh hari sebelumnya masih mengandung informasi prediktif, tetapi hasil ACF/PACF belum menunjukkan bukti kuat adanya pola musiman mingguan. Secara praktis, SVR-PSO berpotensi dimanfaatkan



dalam sistem pemantauan harga pangan berbasis data untuk menyediakan informasi prediktif jangka pendek sebagai pendukung pengambilan keputusan yang lebih responsif.

DAFTAR PUSTAKA

- Aisy, R. R., Zulfa, L., Rahim, Y., & Ahsan, M. (2025). Residual XGBoost Regression—Based Individual Moving Range Control Chart for Gross Domestic Product Growth Monitoring. *PLOS One*, 20(5), Article ID: e0321660. <https://doi.org/10.1371/journal.pone.0321660>
- Albelali, S., & Ahmed, M. (2025). *Hidden Leaks in Time Series Forecasting: How Data Leakage Affects LSTM Evaluation Across Configurations and Validation Strategies*. <http://arxiv.org/abs/2512.06932>
- Alnaqbi, A., Zeiada, W., & Al-Khateeb, G. (2025). A Hybrid Machine Learning Method of Support Vector Regression with Particle Swarm Optimization for Predicting IRI in Continuously Reinforced Concrete Pavement. *Journal of Engineering and Applied Science*, 72(1), Article ID: 128. <https://doi.org/10.1186/s44147-025-00706-9>
- Alwateer, M., Atlam, E.-S., El-Raouf, M. M. A., Ghoneim, O. A., & Gad, I. (2024). Missing Data Imputation: A Comprehensive Review. *Journal of Computer and Communications*, 12(11), 53–75. <https://doi.org/10.4236/jcc.2024.1211004>
- Badan Pusat Statistik. (2023, October 2). *Perkembangan Nilai Tukar Petani September 2023*. Badan Pusat Statistik. <https://www.bps.go.id/id/pressrelease/2023/10/02/1994>
- Beck, N., Dovern, J., & Vogl, S. (2025). Mind the Naive Forecast! A Rigorous Evaluation of Forecasting Models for Time Series with Low Predictability. *Applied Intelligence*, 55(6), Article ID: 395. <https://doi.org/10.1007/s10489-025-06268-w>
- Duan, G., Du, Y., Shang, Y., Xue, H., & Zhang, R. (2025). Research on Support Vector Regression Short-Time Traffic Flow Prediction Model for Secondary Roads Based on Associated Road Analysis. *Applied Sciences*, 15(4), Article ID: 1779. <https://doi.org/10.3390/app15041779>
- Febryanti, S. N., & Budihartanti, C. (2025). Peramalan Harga Eceran Beras C4 Biasa di Kota Surakarta Tahun 2025 Menggunakan Exponential Smoothing. *Integrative Perspectives of Social and Science Journal*, 2(06), 8819–8827. <https://ipssj.com/index.php/ojs/article/view/1031>
- Fitri, A., Masa, A. P. A., & Kamila, V. Z. (2025). Penerapan Metode Holt Winters Exponential Smoothing untuk Peramalan Harga Beras di Kota Samarinda. *Explore: Jurnal Sistem Informasi dan Telematika*, 16(2), 259–265. <https://doi.org/10.36448/jsit.v16i2.4578>
- Flores, A., Tito-Chura, H., Cuentas-Toledo, O., Yana-Mamani, V., & Centty-Villafuerte, D. (2024). PM2.5 Time Series Imputation with Moving Averages, Smoothing, and Linear Interpolation. *Computers*, 13(12), Article ID: 312. <https://doi.org/10.3390/computers13120312>
- Hewage, P., Behera, A., Trovati, M., Pereira, E., Ghahremani, M., Palmieri, F., & Liu, Y. (2020). Temporal Convolutional Neural (TCN) Network for an Effective Weather Forecasting Using Time-Series Data from the Local Weather Station. *Soft Computing*, 24(21), 16453–16482. <https://doi.org/10.1007/s00500-020-04954-0>
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current Status and Future Directions. *International Journal of Forecasting*, 37(1), 388–427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>
- Hidayat, R. P. (2025). Regional Stability and Dynamics of Rice Production in West Java through Spatiotemporal Clustering. *Jurnal Masyarakat Informatika*, 16(2), 229–246. <https://doi.org/10.14710/jmasif.16.2.76056>
- Hidayat, R. P., Tosida, E. T., Maesya, A., & Solihin, I. P. (2024). Support Vector Regression Algorithm for Predicting Rice Production in West Java Province. *2024 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 978–983. <https://doi.org/10.1109/ICIMCIS63449.2024.10957446>
- Leites, J., Cerqueira, V., & Soares, C. (2024). *Lag Selection for Univariate Time Series Forecasting Using Deep Learning: An Empirical Study*. <http://arxiv.org/abs/2405.11237>
- Maganga, J. M. (2025). ARIMA Consumption Forecasting Models and ATDC Technological Optimizations: The Case of Rice, Maize and Vegetable Production in Mozambique. *Scientific African*, 28, Article ID: e02762. <https://doi.org/10.1016/j.sciaf.2025.e02762>



- Matondang, M. R., Krisnamurthi, B., & Herawati, H. (2024). Price Fluctuations and Volatility of National Strategic Food Commodities in Indonesia. *Agrisociconomics: Jurnal Sosial Ekonomi Pertanian*, 8(1), 134–146. <https://doi.org/10.14710/agrisociconomics.v8i1.17753>
- Niako, N., Melgarejo, J. D., Maestre, G. E., & Vatcheva, K. P. (2024). Effects of Missing Data Imputation Methods on Univariate Blood Pressure Time Series Data Analysis and Forecasting with ARIMA and LSTM. *BMC Medical Research Methodology*, 24(1), Article ID: 320. <https://doi.org/10.1186/s12874-024-02448-3>
- Nisa, F. L., Dony Permana, & Denny Armelia. (2025). Peramalan Harga Beras di Kota Padang untuk Tahun 2025 Menggunakan Jaringan Syaraf Tiruan dengan Metode Backpropagation. *UNP Journal of Statistics and Data Science*, 3(4), 391–397. <https://doi.org/10.24036/ujsds/vol3-iss4/381>
- Noori, M., Valiante, E., Rozada, I., Van Vaerenbergh, T., & Mohseni, M. (2026). Statistical Analysis for Per-Instance Evaluation of Stochastic Optimizers: Avoiding Unreliable Conclusions. *Physical Review Applied*, 25(3), Article ID: 034081. <https://doi.org/10.1103/2fjp-t663>
- Priyanto, H. D., & Indrasetyaningsih, A. (2025). Pemodelan ARIMA dan ARIMAX untuk Peramalan Rata-Rata Harga Beras Premium di Provinsi Jawa Timur. *Prosiding Seminar Nasional Hasil Riset dan Pengabdian*, 7, 483–498. <https://snhrp.unipasby.ac.id/prosiding/index.php/snhrp/article/view/1226/1152>
- Ramdani, M. G., & Komara Rifai, N. A. (2025). Penerapan Bayesian Dynamic Linear Models untuk Peramalan Harga Komoditas Beras Medium. *Jurnal Riset Statistika*, 5(2), 161–170. <https://doi.org/10.29313/jrs.v5i2.8346>
- Saputra, R. A., Fuadiyah, T., Aini, D. P. A. N., Margaretha, D. N., & Susetyo, A. B. (2025). Peramalan Dinamika Harga Beras Premium di Tingkat Penggilingan dengan Model ARIMA. *Jurnal Ilmiah Intech: Information Technology Journal of UMUS*, 7(2), 9–18. <https://jurnal.umus.ac.id/index.php/intech/article/view/1822>
- Sifriyani, Budiantara, I. N., Candra, K. P., Syaripuddin, Jalaluddin, S., Rasjid, M., & Ruslan. (2025). Advanced Spatio Temporal Modeling with Geographically and Temporally Weighted Spline Regression (GTWSR) for Strategic Food Price Forecasting in Indonesia. *MethodsX*, 15, Article ID: 103727. <https://doi.org/10.1016/j.mex.2025.103727>
- Strøm, E., & Gundersen, O. E. (2024). Performance Metrics for Multi-Step Forecasting Measuring Win-Loss, Seasonal Variance and Forecast Stability: An Empirical Study. *Applied Intelligence*, 54(21), 10490–10515. <https://doi.org/10.1007/s10489-024-05715-4>
- Toy, A. L. (2025). Peramalan Harga Beras di Kota Kupang dengan Menggunakan Model Autoregressive Integrated Moving Average (ARIMA). *MATHunesa: Jurnal Ilmiah Matematika*, 13(3), 127–137. <https://doi.org/10.26740/mathunesa.v13n3.p127-137>

