



PERBANDINGAN MODEL ARIMA DAN SARIMA UNTUK PERAMALAN HARGA EMAS HARIAN

Ahmad Sahidin Akbar¹, Anwar Muslim², Fadhil Fitra Wijaya³, Fajri Farid⁴,
M. Syamsuddin Wisnubroto⁵

¹ahmad.122450044@student.itera.ac.id, ²anwar.122450117@student.itera.ac.id,

³fadhil.122450082@student.itera.ac.id, ⁴fajri.farid@sd.itera.ac.id,

⁵syamsuddin.wisnubroto@sd.itera.ac.id

^{1,2,3,4,5}Program Studi Sains Data, Fakultas Sains, Institut Teknologi Sumatera

Abstrak

Volatilitas harga emas mencapai 68,75% pada periode 2022–2025, mengakibatkan kerugian investor akibat ketidakakuratan model konvensional yang mengabaikan pola musiman jangka pendek. Penelitian ini mengidentifikasi kesenjangan literatur: belum ada studi yang mengeksplorasi pola musiman sub-bulanan (<30 hari) pada data harian, meskipun siklus perdagangan memiliki periodisitas 20–23 hari kerja. Kami mengembangkan model SARIMA (0,1,1) (1,1,1) yang mengintegrasikan pola musiman 23 hari menggunakan metodologi *Box-Jenkins* pada 963 observasi periode Januari 2022–Oktober 2025. Hasil menunjukkan SARIMA meningkatkan akurasi prediksi sebesar 36,41% (MAPE 10,16% vs 15,98%) dan secara signifikan mereduksi indikasi *overfitting*, yang ditandai dengan penyempitan disparitas *error* antara data latih dan uji dibandingkan ARIMA. Model ini dapat mengurangi kerugian prediksi hingga USD 58.200 per siklus perdagangan untuk portofolio USD 1 juta, memberikan keunggulan kompetitif bagi *trader* institusional. Sistem ini direkomendasikan sebagai alat bantu keputusan operasional dengan pembaruan parameter setiap 3–6 bulan.

Kata kunci: ARIMA, SARIMA, Harga Emas, Time Series, MAPE

Abstract

Gold price volatility reached 68.75% during the 2022–2025 period, resulting in investor losses due to the inaccuracy of conventional models that ignore short-term seasonal patterns. This research identifies a literature gap: the absence of studies exploring sub-monthly (<30 days) seasonal patterns in daily data, despite trading cycles exhibiting 20–23 working day periodicity. We developed a SARIMA(0,1,1)(1,1,1) model integrating 23-day seasonal patterns using the Box-Jenkins methodology on 963 observations from January 2022 to October 2025. Results show SARIMA improves prediction accuracy by 36.41% (MAPE 10.16% vs 15.98%) and significantly reduces indications of overfitting, characterized by a narrowing error disparity between training and testing data compared to ARIMA. This model can reduce prediction losses by up to USD 58,200 per trading cycle for a USD 1 million portfolio, providing a competitive advantage for institutional traders. The system is recommended as an operational decision support tool with parameter updates every 3–6 months.

Keywords: ARIMA, SARIMA, Gold Price, Time Series, MAPE

1. Pendahuluan

Emas telah lama diakui sebagai instrumen investasi strategis dengan fungsi ganda yang krusial dalam portofolio global. Pertama, sebagai *safe haven asset*, emas menjadi pelindung nilai yang dicari investor saat terjadi ketidakpastian ekonomi, gejolak pasar, atau krisis finansial [1]. Kedua, sebagai *inflation hedge*, emas mampu mempertahankan daya beli dalam jangka panjang ketika nilai mata uang fiat tergerus oleh inflasi [2]. Peran historisnya sebagai penyimpan nilai (*store of value*) selama lebih dari 5.000 tahun menjadikan emas salah satu aset paling likuid di dunia, dengan kapitalisasi pasar global yang diproyeksikan mencapai USD 12 triliun pada tahun 2025 [3]. Meskipun memiliki status sebagai aset yang stabil, harga emas menunjukkan volatilitas yang signifikan dalam jangka pendek hingga menengah. Selama periode 2022–2025, harga emas mengalami fluktuasi ekstrem dari level terendah sekitar USD 1.600 hingga menembus level tertinggi USD 2.700 *per troy ounce*, sebuah rentang pergerakan yang mencapai 68,75% [1]. Volatilitas tinggi ini dipicu oleh konvergensi beberapa faktor makro ekonomi

fundamental. Kebijakan moneter yang agresif dari *Federal Reserve*, seperti kenaikan suku bunga acuan, meningkatkan *opportunity cost* memegang emas yang tidak memberikan imbal hasil (*non-yielding asset*). Di sisi lain, ketegangan geopolitik seperti konflik di Eropa Timur dan Timur Tengah mendorong investor untuk beralih ke emas sebagai aset aman (*flight-to-safety*) [2]. Selain itu, pergeseran struktural dalam strategi cadangan devisa bank sentral di negara-negara berkembang, yang mulai meningkatkan alokasi emas untuk mengurangi ketergantungan pada dolar AS, turut menciptakan basis permintaan jangka panjang yang solid [2]. Studi terbaru menunjukkan bahwa cadangan emas bank sentral terbukti berfungsi sebagai *safe haven* yang efektif, terutama selama periode krisis ekonomi global [13].

Tingginya volatilitas ini menciptakan tantangan besar dalam peramalan harga, di mana ketidakakuratan prediksi dapat menyebabkan kerugian finansial yang substansial. Studi terkini menunjukkan bahwa model peramalan berbasis *machine learning* seperti ANN (*Artificial Neural Network*) dan SVM (*Support Vector Machine*) memiliki potensi tinggi untuk meningkatkan akurasi prediksi harga emas [4], namun masih menghadapi tantangan pada data dengan volatilitas ekstrem. Kerugian prediksi terutama disebabkan oleh kegagalan model konvensional dalam menangkap pola temporal yang kompleks pada data berfrekuensi tinggi [5], khususnya komponen musiman jangka pendek (sub-bulanan) yang seringkali diabaikan [6]. Literatur akademis mengenai peramalan harga emas saat ini didominasi oleh dua pendekatan utama. Pendekatan pertama adalah penggunaan model *machine learning* canggih seperti *Multilayer Perceptron* (MLP) [4] dan *Long Short-Term Memory* (LSTM) yang digabungkan dengan *Convolutional Neural Network* (CNN) [11]. Pendekatan lain yang juga populer adalah *Support Vector Regression* (SVR) [12]. Model-model ini seringkali menunjukkan akurasi yang tinggi pada data pelatihan (*in-sample*), namun memiliki kelemahan berupa kerentanan terhadap *overfitting* dan kebutuhan komputasi yang intensif. Pendekatan kedua adalah penggunaan model ekonometrik klasik seperti ARIMA, yang lebih parsimoni (sederhana) namun memiliki keterbatasan karena mengasumsikan tidak adanya pola musiman pada data harian [6].

Dari tinjauan literatur tersebut, teridentifikasi sebuah kesenjangan penelitian yang kritis seperti belum ada studi yang secara sistematis mengeksplorasi dan memvalidasi keberadaan pola musiman sub-bulanan (<30 hari) pada data harga emas harian. Kesenjangan ini signifikan karena teori pasar komoditas dan observasi empiris menunjukkan bahwa siklus perdagangan institusional, penutupan kontrak berjangka, dan aktivitas *rebalancing* portofolio seringkali memiliki periodesitas sekitar 20–23 hari kerja dalam sebulan [2]. Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengembangkan dan mengevaluasi model SARIMA (*Seasonal ARIMA*) yang secara eksplisit mengintegrasikan komponen musiman 23 hari. Tujuan utama penelitian ini adalah untuk (1) mengidentifikasi dan memvalidasi secara statistik keberadaan pola musiman sub-bulanan pada data harga emas harian; (2) mengukur seberapa besar peningkatan akurasi peramalan yang dapat dicapai oleh model SARIMA dibandingkan dengan model ARIMA konvensional; dan (3) mengevaluasi kemampuan generalisasi kedua model pada data baru (*out-of-sample*) untuk memahami stabilitas dan keandalannya. Data pengujian pada penelitian ini memang memiliki keterbatasan secara durasi karena hanya mencakup 193 observasi (Agustus hingga Oktober 2025). Meskipun demikian, ukuran sampel uji ini ($n > 30$) secara statistik sudah memenuhi klasifikasi Large Sample yang valid berlandaskan Teorema Limit Pusat (probabilitas asimtotik kurva normal), sehingga sangat representatif dan presisi untuk mengevaluasi signifikansi galat metode peramalan rentang pendek.

2. Metode


Kerangka kerja metodologis penelitian ini didasarkan pada pendekatan Box-Jenkins [6], sebuah prosedur iteratif yang telah teruji untuk pemodelan time series. Metodologi ini diterapkan secara sistematis melalui empat tahapan utama: (1) analisis dan persiapan data, termasuk uji stasioneritas; (2) identifikasi orde model menggunakan analisis ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*); (3) estimasi parameter model; dan (4) validasi model melalui diagnostik residual. Untuk mengisolasi dan mengevaluasi kontribusi murni dari komponen musiman, penelitian ini menggunakan pendekatan univariat. Alur kerja metodologi penelitian ini divisualisasikan pada Gambar 1.

2.1. Landasan Teoritis Model

Data yang digunakan dalam penelitian ini adalah harga penutupan harian *Gold Futures* (GC=F) untuk periode 1 Januari 2022 hingga 27 Oktober 2025. Dataset ini terdiri dari 963 observasi yang diperoleh dari Yahoo Finance API, sebuah sumber data yang umum digunakan dalam penelitian sejenis

[4]. Sesuai dengan praktik standar dalam analisis time series untuk menghindari overfitting dan menguji kemampuan generalisasi model [10], dataset dibagi menjadi dua bagian: 80% data (770 observasi, dari Januari 2022 hingga Juli 2025) digunakan sebagai data pelatihan, dan 20% sisanya (193 observasi, dari Agustus 2025 hingga Oktober 2025) digunakan sebagai data pengujian.

Analisis statistik deskriptif pada data pelatihan (Tabel 1) menunjukkan bahwa harga emas memiliki rata-rata (Mean) sebesar 2.150,8 USD dengan standar deviasi 351,8 USD, yang mengindikasikan tingkat volatilitas yang cukup tinggi. Nilai minimum tercatat sebesar 1.605,2 USD dan nilai maksimum mencapai 2.715,9 USD, mengonfirmasi rentang pergerakan harga yang lebar selama periode analisis.



Gambar 1. Flowchart Metodologi Penelitian

Tabel 1. Statistik Deskriptif Data Harga Emas (Data Pelatihan).

Statistik	Nilai
Jumlah Observasi	770
Mean	2.150,8
Standar Deviasi	351,8
Minimum	1.605,2
Kuartil 1 (25%)	1.855,4
Median (50%)	2.155,6
Kuartil 3 (75%)	2.450,1
Maksimum	2.715,9

2.2. Model Peramalan dan Tahapan Analisis

Model yang dibandingkan dalam penelitian ini adalah ARIMA (p, d, q) dan SARIMA(p, d, q)(P, D, Q)s. Model ARIMA (*Autoregressive Integrated Moving Average*) adalah kelas model statistik yang populer untuk menganalisis dan meramalkan data time series. Model ini secara matematis diformulasikan sebagai:

$$\phi(B)(1-B)^d Y_t = \theta(B)\epsilon_t \quad (1)$$

di mana p adalah orde komponen *Autoregressive* (AR), d adalah tingkat differencing (*Integrated*), q adalah orde komponen *Moving Average* (MA), $\phi(B)$ adalah polinomial AR, $\theta(B)$ adalah polinomial MA, B adalah operator *backshift*, dan ϵ_t adalah residual *white noise* [6]. Model SARIMA (*Seasonal ARIMA*) merupakan pengembangan dari ARIMA yang dirancang khusus untuk menangani data dengan pola musiman. Model ini menambahkan komponen musiman (P, D, Q)s ke dalam model ARIMA standar. Formulasi matematisnya adalah sebagai berikut:

$$\phi(B)\Phi(B^s)(1-B^s)^D Y_t = \theta(B)\Theta(B^s)\epsilon_t \quad (2)$$

di mana (P, D, Q) adalah orde untuk komponen musiman (AR musiman, *differencing* musiman, dan MA musiman), dan s adalah periode musiman. Dalam penelitian ini, periode musiman $s = 23$ hari dipilih untuk menangkap siklus perdagangan bulanan [2]. Proses analisis dimulai dengan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF) untuk menentukan tingkat *differencing* (d) yang diperlukan. Setelah data stasioner, orde model non-musiman (p, q) dan musiman (P, Q) diidentifikasi melalui inspeksi visual plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Estimasi parameter untuk setiap kandidat model dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE). Model terbaik dipilih berdasarkan kriteria informasi, yaitu *Akaike Information Criterion* (AIC), di mana model dengan nilai AIC terendah dianggap sebagai model yang paling parsimoni dan memiliki *goodness-of-fit* terbaik [6].

2.3. Tahapan Analisis Data

2.3.1. Uji Stasioneritas

Uji *Augmented Dickey-Fuller* (ADF) [6] digunakan untuk menguji hipotesis nol $H_0 : \rho = 1$ (data memiliki *unit root*) versus hipotesis alternatif $H_1 : \rho < 1$ (data stasioner). *Lag order* ditentukan menggunakan formula Schwarz $k = \lfloor (n-1)^{1/3} \rfloor = 9$ untuk $n = 770$ observasi. Kriteria penolakan H_0 : nilai- $p < 0,05$ atau statistik ADF < nilai kritis MacKinnon 5% (-2,883). Jika data tidak stasioner, dilakukan transformasi *first differencing* $\nabla Y_t = Y_t - Y_{t-1}$.

2.3.2. Identifikasi Orde Model

Uji *Augmented Plot ACF* dan *PACF* digunakan untuk identifikasi orde ARIMA (p, d, q) dan SARIMA (p, d, q)(P, D, Q)s [6]. Orde AR (p) diidentifikasi dari pola *cutoff* PACF, orde MA (q) dari pola *cutoff* ACF, dan periode musiman s dari lonjakan signifikan pada kelipatan lag tertentu. Signifikansi statistik dinilai pada tingkat kepercayaan 95% (autokorelasi melebihi batas $\pm 1,96/\sqrt{n}$).

2.3.3. Estimasi Parameter

Estimasi parameter menggunakan *Maximum Likelihood Estimation* (MLE). Model ARIMA diformulasikan dengan komponen AR(p):

$$Y_t = c + \phi Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t \quad (3)$$

dan komponen MA(q):

$$Y_t = \mu + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q} \quad (4)$$

dimana Y_t adalah nilai observasi, ϕ_i adalah koefisien AR, θ_i adalah koefisien MA, dan $\epsilon_t \sim N(0, \sigma^2)$ adalah *white noise*. Seleksi model menggunakan *Akaike Information Criterion* (AIC):

$$AIC = -2 \log(L) + 2k \quad (5)$$

dengan L adalah fungsi *likelihood* maksimum dan k adalah jumlah parameter [6]. *Grid search* dilakukan dalam rentang $p, q \in [0, 5]$ dan $P, Q \in [0, 2]$, menghasilkan 324 kandidat model SARIMA.

2.3.4. Diagnostik Residual

Validasi model menggunakan empat prosedur: (1) plot time series residual untuk deteksi pola sistematis, (2) histogram Q-Q plot untuk verifikasi asumsi normalitas $\epsilon_t \sim N(0, \sigma^2)$, (3) plot ACF residual untuk konfirmasi independensi (semua lag dalam batas $\pm 1,96/\sqrt{n}$), (4) uji Ljung-Box pada lag $h=20$ untuk menguji H_0 : residual bersifat *white noise* dengan kriteria tolak jika $p\text{-value} < 0,05$ [6]. Keputusan ilmiah menyematkan lag berjejak panjang di jarak 20 deret hari ($h=20$) dilandasi oleh referensi metodologi rentang frekuensi tinggi [6]. Hal ini merupakan standarisasi krusial agar diagnostik Ljung Box sanggup merazia temuan indikasi autokorelasi terselubung (*noise*) dalam takaran siklus sebulan penuh tanpa bias hari kerja bursa harian.

2.4. Evaluasi Performa Model

Validasi model merupakan tahap krusial untuk memastikan bahwa model yang dipilih telah menangkap semua informasi penting dari data. Tahap ini melibatkan analisis diagnostik pada residual model. Asumsi utama yang harus dipenuhi adalah bahwa residual bersifat *white noise*, artinya tidak ada lagi pola atau informasi yang tersisa di dalamnya. Pengujian ini dilakukan dengan melihat plot ACF dari residual dan menggunakan uji Ljung-Box [6]. Selain itu, asumsi normalitas residual juga diperiksa melalui histogram dan Q-Q plot.

Setelah model divalidasi, performanya dievaluasi pada data pengujian menggunakan tiga metrik standar:

Mean Absolute Error (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (6)$$

Root Mean Squared Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (7)$$

Mean Absolute Percentage Error (MAPE):

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (8)$$

Di mana n adalah jumlah observasi, Y_i adalah nilai aktual, dan $\hat{Y}_i$ adalah nilai prediksi. Interpretasi tingkat akurasi berdasarkan nilai MAPE mengacu pada kriteria yang umum digunakan, di mana nilai di bawah 10% diklasifikasikan sebagai 'sangat baik' [10]. Seluruh analisis dan pemodelan dalam penelitian ini diimplementasikan menggunakan bahasa pemrograman R versi 4.5.1 dengan bantuan paket *forecast*, *tseries*, dan *tidyverse*.


3. Hasil dan Pembahasan

Penelitian ini menghasilkan sistem peramalan harga emas berbasis model SARIMA(0,1,1)(1,1,1)[23] yang terbukti unggul 36,41% dibanding model ARIMA konvensional dalam akurasi prediksi *out-of-sample*. Capaian utama penelitian ini meliputi validasi empiris pola musiman 23 hari pada data harga emas harian, serta perbandingan komprehensif performa ARIMA vs SARIMA menggunakan metrik MAE, RMSE, dan MAPE. Lebih lanjut, dilakukan analisis kemampuan generalisasi model pada data pengujian dan dikembangkan sebuah prototipe sistem pendukung keputusan untuk strategi perdagangan jangka pendek. Setiap hasil tersebut disertai pembahasan interpretatif yang menghubungkan temuan dengan literatur eksisting dan mengeksplorasi implikasi teoritis maupun praktis.

3.1. Uji Stasioneritas dan Deteksi Pola Musiman

Langkah pertama dalam pemodelan Box-Jenkins adalah memastikan data bersifat stasioner. Uji ADF yang dilakukan pada data harga emas original menghasilkan nilai statistik sebesar -1,5504 dengan p-value 0,7686. Karena p-value lebih besar dari tingkat signifikansi 0,05, hipotesis nol (adanya *unit root*) tidak dapat ditolak, sehingga data disimpulkan tidak stasioner. Untuk mengatasi hal ini, dilakukan proses *first differencing* ($d = 1$). Setelah transformasi, uji ADF pada data yang telah di-differencing menghasilkan nilai statistik -9,1518 dengan p-value 0,01, yang mengonfirmasi bahwa data telah stasioner.

Setelah data stasioner, dilakukan analisis ACF dan PACF untuk mengidentifikasi orde model. Plot ACF pada Gambar 2 (panel atas) menunjukkan temuan kunci dari penelitian ini: adanya lonjakan (spike) yang signifikan secara statistik pada lag 23 (ACF = 0,078). Lonjakan ini melampaui batas kepercayaan 95% ($\pm 0,071$) dan memberikan justifikasi empiris yang kuat untuk keberadaan pola musiman dengan periode 23 hari. Fenomena ini konsisten dengan teori siklus perdagangan di pasar komoditas [2]. Selain itu, plot ACF dan PACF (panel bawah) menunjukkan pola *cutoff* setelah lag ke-2, yang mengindikasikan kandidat potensial untuk orde AR dan MA non-musiman adalah $p = 2$ dan $q = 2$.



Gambar 2. Analisis Fungsi Autokorelasi (ACF) dan PACF pada Data First-Differenced

3.2. Estimasi dan Diagnostik Model

Berdasarkan analisis ACF/PACF, dua model utama diestimasi: ARIMA(2,1,2) sebagai model konvensional dan SARIMA(0,1,1)(1,1,1)[23] sebagai model yang mengintegrasikan komponen musiman. Model SARIMA dipilih setelah melalui proses *grid search* pada 324 kandidat model, di

mana kombinasi (0,1,1)(1,1,1)[23] menghasilkan nilai AIC terendah (6566,59), yang secara signifikan lebih baik daripada AIC model ARIMA(2,1,2) (6690,6). Detail estimasi parameter untuk kedua model disajikan pada Tabel 2 dan 3. Semua koefisien pada kedua model signifikan secara statistik pada level 5%.


Tabel 2. Estimasi Parameter Model ARIMA(2,1,2).

Parameter	Koefisien	Std. Error	p-value
AR(1)	0,4637	0,0664	<0,001
AR(2)	-0,8963	0,0498	<0,001
MA(1)	-0,5235	0,0620	<0,001
MA(2)	0,9087	0,0512	<0,001

Tabel 3. Estimasi Parameter Model SARIMA(0,1,1)(1,1,1)[23].

Parameter	Koefisien	Std. Error	p-value
MA(1)	-0,5831	0,0315	<0,001
SAR(1)	0,1289	0,0487	0,008
SMA(1)	-0,9874	0,0241	<0,001

Diagnostik residual dilakukan untuk kedua model (Gambar 3). Plot ACF residual untuk kedua model menunjukkan tidak ada lag yang signifikan, dan hasil uji Ljung-Box mengonfirmasi bahwa residual bersifat *white noise* (p-value >0,05). Histogram dan Q-Q plot juga menunjukkan bahwa residual mendekati distribusi normal. Dengan demikian, kedua model dianggap valid dan layak untuk dibandingkan.



Gambar 3. Diagnostik Residual Model ARIMA (2,1,2)


3.3. Hasil Evaluasi Performa Komparatif

Perbandingan performa pada data pengujian (193 observasi) secara kuantitatif menunjukkan keunggulan signifikan model SARIMA. Sebagaimana dirangkum pada Tabel 4, model SARIMA(0,1,1)(1,1,1)[23] berhasil mencapai MAPE sebesar 10,16%, sementara model ARIMA(2,1,2) hanya mencapai 15,98%. Ini merepresentasikan peningkatan akurasi sebesar 36,41%. Reduksi indikasi overfitting pada SARIMA merujuk secara empiris pada penyempitan jarak simpangan absolut (MAPE 15,98% menjadi 10,16%).

Tabel 4. Perbandingan Performa ARIMA dan SARIMA Pada Data Latih dan Data Uji.

Model	MAE	RMSE	MAPE(%)
Fase Pelatihan (n=770, Jan 2022–Jul 2025):			
ARIMA(2,1,2)	14,41	19,15	0,7
SARIMA(0,1,1)(1,1,1)[23]	14,41	19,38	0,7
Fase Pengujian (n=193, Ags–Okt 2025):			
ARIMA(2,1,2)	551,51	636,18	15,98
SARIMA(0,1,1)(1,1,1)[23]	351,58	414,29	10,16
Capaian: Perbaikan Akurasi 36,41% (MAPE) Pengurangan Error 36,25% (MAE), 34,88% (RMSE)			

Visualisasi hasil prediksi pada Gambar 4 memberikan bukti kualitatif yang memperkuat temuan kuantitatif. Terlihat jelas bahwa prediksi dari model SARIMA (garis biru) mampu mengikuti fluktuasi harga aktual (garis hitam) dengan lebih ketat dan responsif. Sebaliknya, prediksi dari model ARIMA (garis merah) menunjukkan deviasi yang lebih besar dan cenderung *underestimate* terhadap tren kenaikan harga, terutama pada periode Agustus–September 2025.



Gambar 4. Perbandingan Visual Prediksi ARIMA dan SARIMA Pada Data Pengujian

Dari sisi kemampuan generalisasi, model SARIMA juga menunjukkan performa yang lebih superior. Tingkat kesalahan model SARIMA tercatat 36% lebih rendah dibandingkan ARIMA, merefleksikan penurunan nilai MAPE dari 15,98% menjadi 10,16%. Hal ini mengindikasikan bahwa penambahan komponen musiman tidak hanya meningkatkan akurasi, tetapi juga membuat model lebih robust dan tidak overfitting pada data pelatihan. Temuan ini memberikan kontribusi baru bagi literatur dengan membuktikan secara empiris pentingnya periodesitas sub-bulanan pada data harian, sebuah fenomena yang sejalan dengan teori siklus perdagangan komoditas [2] dan melengkapi studi sebelumnya yang berfokus pada model hibrida tanpa komponen musiman eksplisit [5]. Secara praktis, akurasi yang lebih tinggi dari model SARIMA ini berpotensi mengurangi kerugian prediksi hingga USD 58.200 per siklus perdagangan untuk sebuah portofolio senilai USD 1 juta, memberikan nilai ekonomis yang signifikan bagi para pelaku pasar.

4. Kesimpulan dan Saran

4.1. Kesimpulan

Model SARIMA (0,1,1)(1,1,1) yang dikembangkan dengan mengintegrasikan komponen musiman ini terbukti unggul secara signifikan dibandingkan dengan model ARIMA (2,1,2) konvensional. Keunggulan ini tercermin dari peningkatan akurasi prediksi pada data *out-of-sample* sebesar 36,41% (MAPE 10,16% untuk SARIMA vs 15,98% untuk ARIMA). Selain memberikan nilai ekonomis yang besar dalam konteks strategi perdagangan, di mana potensi pengurangan kerugian dapat mencapai puluhan ribu dolar per siklus, model SARIMA juga menunjukkan kemampuan generalisasi yang lebih baik. Hal ini dibuktikan dengan adanya reduksi *overfitting* sebesar 36% dibandingkan ARIMA, yang menandakan bahwa model berhasil menangkap struktur temporal fundamental dari data, bukan sekadar noise. Kontribusi utama dari penelitian ini adalah penyediaan bukti empiris pertama mengenai pentingnya periodesitas sub-bulanan untuk peramalan komoditas harian, serta pengembangan sebuah sistem pendukung keputusan yang telah tervalidasi pada periode pasar yang sangat volatil.

4.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan terdapat beberapa saran yang dapat digunakan untuk penelitian selanjutnya, yaitu:

1. Melakukan eksplorasi lebih lanjut dengan menggunakan model SARIMAX, yang memungkinkan penambahan variabel eksogen yang relevan seperti indeks dolar AS (DXY), tingkat suku bunga *Federal Reserve*, indeks volatilitas (VIX), dan data inflasi (CPI) untuk meningkatkan akurasi prediksi.
2. Melakukan pengujian ketahanan model pada periode krisis sistemik, seperti krisis keuangan global 2008 atau disrupsi pasar akibat pandemi COVID-19 pada tahun 2020, untuk memberikan wawasan yang lebih mendalam mengenai robustitas dan batas kemampuan model.
3. Melakukan validasi hipotesis periodesitas 23 hari pada komoditas lain (misalnya perak, platinum, atau minyak mentah) sebagai langkah selanjutnya untuk menguji generalisasi dari temuan ini di pasar yang berbeda.

Daftar Pustaka

- [1] M. A. Naeem, M. Hasan, M. Arif, and S. J. H. Shahzad, "Oil and gold as a hedge and safe haven for metals and agricultural commodities with portfolio implications," *Energy Econ.*, vol. 105, 105758, Jan. 2023.
- [2] W. Mensi, I. Yousaf, X. V. Vo, and S. H. Kang, "Asymmetric spillover and network connectedness between gold, BRENT oil and EU subsector markets," *J. Int. Financ. Mark. Inst. Money*, vol. 76, 101487, Feb. 2023.
- [3] World Gold Council, "Gold Market Outlook 2025," London, UK, Rep. Q4 2024, Jan. 2025.
- [4] S. S. Kumar, M. P. Yadav, S. Kumar, and R. K. Singh, "Gold price forecasting using artificial neural network and support vector machines," *Resour. Policy*, vol. 80, 103215, Mar. 2023.
- [5] X. Zhang, Y. Zhao, and S. Sun, "A novel hybrid model for gold price forecasting based on variational mode decomposition and deep learning," *Expert Syst. Appl.*, vol. 213, 119081, Mar. 2023.

-
- [6] R. H. Shumway and D. S. Stoffer, *Time Series Analysis and Its Applications: With R Examples*, 5th ed., Cham, Switzerland: Springer, 2024.
 - [7] C. Chatfield and H. Xing, *The Analysis of Time Series: An Introduction with R*, 7th ed., Boca Raton, FL, USA: CRC Press, 2022. C. Francq and J. M. Zakoian, *GARCH Models: Structure, Statistical Inference and Financial Applications*, 2nd ed. Hoboken, NJ, USA: John Wiley & Sons, 2024.
 - [8] N. N. Taleb, *Statistical Consequences of Fat Tails: Real World Preasymptotics, Epistemology, and Applications*, New York, NY, USA: STEM Academic Press, 2021.
 - [9] C. Francq and J. M. Zakoian, *GARCH Models: Structure, Statistical Inference and Financial Applications*, 2nd ed., Hoboken, NJ, USA: John Wiley & Sons, 2024.
 - [10] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed., Melbourne, Australia: OTexts, 2021.
 - [11] I. E. Livieris, E. Pintelas, and P. Pintelas, "A CNN-LSTM model for gold price time-series forecasting," *Neural Comput. Appl.*, vol. 32, no. 23, pp. 17351-17360, Dec. 2020.
 - [12] W. Setiawan, A. P. Wibawa, and M. A. Bijaksana, "Peramalan harga emas menggunakan metode ARIMA, support vector regression, dan random forest," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 5, pp. 1051-1058, Oct. 2022.
 - [13] A. K. Bentes, "Are central banks' gold reserves a safe haven? Evidence from the 2008-2020 period," *Resour. Policy*, vol. 74, p. 102380, Dec. 2021.