

Pemodelan Time Series Harga Lump Karet di Provinsi Jambi Menggunakan ARIMA

Afifah Rizka¹, Novrianti^{2*}

¹Teknik Industri, Sekolah Tinggi Teknologi Nasional

²Teknik Mesin, Sekolah Tinggi Teknologi Nasional

*Corresponding author, e-mail: novrianti@stiteknas.ac.id

ABSTRACT

Rubber is one of the leading plantation commodities in Jambi Province and plays an important role in supporting the regional economy. One of the traded rubber products is lump rubber, whose price movements are highly influenced by market dynamics and tend to exhibit significant fluctuations. During the 2023–2025 period, lump rubber prices showed an increasing trend accompanied by growing volatility, indicating the need for an appropriate forecasting method capable of capturing historical price patterns. This study aims to analyze and forecast lump rubber prices using a time series approach based on the Autoregressive Integrated Moving Average (ARIMA) method. The data used consist of weekly lump rubber prices from the Unit Pengolahan dan Pemasaran Bokar (UPPB) with Dry Rubber Content (DRC) of 56 – 60 percent, covering 149 weeks from January 2023 to November 2025. The analysis stages include data pattern identification, variance stabilization using Box–Cox transformation, stationarity testing with the Augmented Dickey–Fuller test, model identification through ACF and PACF, and model evaluation based on parameter significance and residual diagnostics. The results indicate that the ARIMA(1,1,1) model provides the best performance and is applied to forecast lump rubber prices for the next 16 periods. The forecasting results are expected to support decision-making and risk management in the rubber plantation sector.

Keyword: lump rubber, ARIMA, price forecasting

ABSTRAK

Karet merupakan salah satu komoditas perkebunan unggulan di Provinsi Jambi yang memiliki peran penting dalam mendukung perekonomian daerah. Salah satu produk karet yang diperdagangkan adalah lump karet, dimana pergerakan harganya sangat dipengaruhi oleh dinamika pasar dan menunjukkan fluktuasi yang cukup tinggi. Pada periode 2023–2025, harga lump karet mengalami kecenderungan meningkat disertai volatilitas yang semakin besar, sehingga diperlukan suatu metode peramalan yang mampu menangkap pola historis data secara akurat. Penelitian ini bertujuan untuk menganalisis dan meramalkan harga lump karet menggunakan pendekatan *time series* dengan metode *Autoregressive Integrated Moving Average* (ARIMA). Data yang digunakan merupakan data harga lump karet Unit Pengolahan dan Pemasaran Bokar (UPPB) dengan Kadar Karet Kering (KKK) 56 – 60 persen selama 149 minggu dari Januari 2023 hingga November 2025. Tahapan analisis meliputi identifikasi pola data, transformasi Box – Cox untuk menstabilkan varians, uji stasioneritas menggunakan *Augmented Dickey–Fuller*, identifikasi model melalui ACF dan PACF, serta evaluasi model berdasarkan signifikansi parameter dan diagnostik residual. Hasil analisis menunjukkan bahwa model ARIMA(1,1,1) merupakan model terbaik dan digunakan untuk melakukan peramalan harga lump karet selama 16 periode ke depan. Hasil peramalan diharapkan dapat menjadi acuan bagi pelaku usaha dan pengambil kebijakan dalam pengelolaan risiko dan perencanaan sektor perkebunan karet.

Kata kunci: lump karet, ARIMA, peramalan harga

PENDAHULUAN

Karet merupakan salah satu komoditas perkebunan unggulan di Provinsi Jambi yang memiliki peran penting dalam perekonomian daerah. Sebagian besar masyarakat di wilayah perdesaan Jambi menggantungkan pendapatan pada

sektor perkebunan karet, baik sebagai petani maupun pelaku usaha turunannya. Salah satu produk utama yang diperdagangkan adalah lump karet, yaitu bahan olahan karet yang dihasilkan dari lateks alam dan dipasarkan melalui Unit Pengolahan dan Pemasaran Bokar (UPPB). Oleh karena itu,

pergerakan harga lump karet menjadi faktor krusial yang memengaruhi kesejahteraan petani serta stabilitas ekonomi sektor perkebunan.

Dalam beberapa tahun terakhir, khususnya pada periode 2023 – 2025, harga lump karet menunjukkan fluktuasi yang cukup signifikan. Perubahan harga terjadi tidak hanya akibat faktor musiman, tetapi juga dipengaruhi oleh dinamika permintaan dan penawaran global, kondisi pasar internasional, nilai tukar, serta kebijakan perdagangan. Fluktuasi harga yang tinggi menimbulkan ketidakpastian bagi petani dan pelaku usaha, sehingga diperlukan informasi peramalan harga yang akurat untuk mendukung pengambilan keputusan, baik dalam perencanaan produksi, pemasaran, maupun pengelolaan risiko harga.

Data harga *lump* karet bersifat runtun waktu (*time series*), dimana nilai harga pada suatu periode dipengaruhi oleh pola historis pada periode sebelumnya. Karakteristik data tersebut umumnya menunjukkan tren, fluktuasi, serta kemungkinan ketidakstasioneran, sehingga memerlukan metode analisis yang mampu menangkap ketergantungan antarwaktu secara sistematis. Salah satu metode statistik yang banyak digunakan untuk analisis dan peramalan data runtun waktu adalah *Autoregressive Integrated Moving Average (ARIMA)*.

Metode ARIMA mengombinasikan komponen *autoregressive* (AR), *differencing* (I), dan *moving average* (MA) untuk memodelkan struktur ketergantungan jangka pendek pada data runtun waktu. Keunggulan utama ARIMA terletak pada kemampuannya dalam menangani data non – stasioner melalui proses *differencing*, serta kesederhanaannya dalam membangun model yang parsimonious namun efektif [1], [2]. Selain itu, ARIMA tidak memerlukan variabel independen tambahan, sehingga sangat sesuai untuk peramalan harga komoditas yang sangat bergantung pada pola historisnya.

Pemilihan metode ARIMA dalam penelitian ini didasarkan pada beberapa pertimbangan. Pertama, data harga *lump* karet menunjukkan tren dan fluktuasi yang kuat, sehingga memerlukan pendekatan yang mampu mengakomodasi ketidakstasioneran. Kedua, ARIMA telah terbukti secara luas memberikan kinerja yang baik dalam

peramalan jangka pendek pada berbagai komoditas pertanian dan perkebunan. Ketiga, metode ini relatif mudah diinterpretasikan dan banyak direkomendasikan dalam literatur *time series* klasik.

Berbagai penelitian terdahulu telah menunjukkan keberhasilan penggunaan ARIMA dalam memodelkan dan meramalkan harga komoditas dengan karakteristik yang serupa. Misalnya, penelitian oleh Box dan Jenkins [1] serta Brockwell dan Davis [2] menegaskan bahwa ARIMA efektif dalam menangkap pola autokorelasi pada data ekonomi dan keuangan. Penelitian lain oleh Zhang et al. [3] menggunakan ARIMA untuk peramalan harga komoditas pertanian dan menemukan bahwa model ARIMA mampu memberikan hasil yang akurat dalam jangka pendek. Selain itu, studi oleh Suryanto dan Nugroho [4] pada harga komoditas kelapa sawit serta penelitian oleh Putri et al. [5] pada harga kopi menunjukkan bahwa ARIMA dapat menangkap fluktuasi harga komoditas yang bersifat volatil dengan baik, meskipun objek komoditas yang dianalisis berbeda.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis pola pergerakan dan melakukan peramalan harga lump karet di Provinsi Jambi menggunakan pendekatan ARIMA. Hasil penelitian diharapkan dapat memberikan informasi yang bermanfaat bagi petani, pelaku usaha, dan pengambil kebijakan dalam memahami dinamika harga serta mendukung pengambilan keputusan yang lebih tepat di sektor perkebunan karet.

METODE

Pengumpulan Data

Data yang diambil dalam penelitian ini adalah data sekunder yang diperoleh dari *website* Sistem Informasi Pasar Produk Perkebunan Unggulan. Data yang digunakan yaitu data Harga *Lump* Karet Unit Pengolahan dan Pemasaran Bokar (UPPB), dengan Kadar Karet Kering antara 56 hingga 60 persen, selama 149 minggu mulai dari Januari 2023 hingga November 2025. Data tersebut disusun dalam bentuk *time series* (runtun waktu) dan dianalisis menggunakan Metode *Autoregressive Integrated Moving Average* (ARIMA).

Identifikasi Pola Data Awal

Tahap awal dilakukan identifikasi pola data awal melalui *plotting data*, dalam bentuk grafik *time series*. Visualisasi ini bertujuan untuk mengamati bagaimana karakteristik pergerakan data, melihat apakah terdapat adanya kecenderungan (*tren*), fluktuasi, maupun *varians* dari waktu ke waktu.

Transformasi Box-Cox (stabilitas *varians*)

Varians data harga komoditas sering tidak konstan, misalnya adanya fluktuasi harga yang membesar ketika level harga meningkat akibat *demand* dan inflasi. Kondisi ini akan mengganggu pemodelan ARIMA yang menyebabkan heteroskedastisitas. Oleh sebab itu, dilakukan Transformasi Box-Cox untuk menstabilkan *varians* data. Transformasi ini diperkenalkan oleh Box and Cox tahun 1964 sebagai *power transformation*, untuk memperoleh bentuk data yang memenuhi asumsi pemodelan statistik, terutama menstabilkan *varians* dan mendekatkan distribusi data terhadap distribusi normal [6]. Transformasi Box-Cox dirumuskan sebagai berikut:

- Jika $\lambda \neq 0$:

$$y^{(\lambda)} = \frac{y^\lambda - 1}{\lambda} \quad (1)$$

- Jika $\lambda = 0$:

$$y^{(\lambda)} = \ln(y) \quad (2)$$

Nilai λ ditentukan berdasarkan hasil Box-Cox plot, kemudian data ditransformasi sesuai λ terbaik (misalnya mendekati akar kuadrat atau *log*).

Uji Stasioneritas

Salah satu asumsi penting dalam analisis data *time series* adalah data harus bersifat stasioner. Data stasioner tidak menunjukkan keberagaman yang besar dari waktu ke waktu, tidak memiliki *tren* tertentu, dan cenderung berfluktuasi di sekitar nilai rata-ratanya (*mean*) [7], [8], [9]. Sehingga diperlukan uji stasioneritas pada data, dengan menggunakan metode Augmented Dickey Fuller (ADF). ADF merupakan pengembangan dari Dickey Fuller untuk mendeteksi *unit root* pada data *time series*. Keberadaan *unit root* (yang ditunjukkan pada nilai *p-value*) menunjukkan

bahwa data bersifat stasioner atau tidak. Apabila tidak bersifat stasioner perlu ditransformasikan melalui *differencing* agar menjadi stasioner [10].

Secara umum, ADF mengestimasi regresi sebagai berikut:

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^k \delta_i \Delta y_{t-i} + \varepsilon_t \quad (3)$$

Keterangan:

- y_t = nilai deret waktu pada waktu ke- t
- $\Delta y_t = y_t - y_{t-1}$
- t = tren waktu (opsional)
- k = jumlah lag untuk “augmenting” agar residual tidak berautokorelasi

Pengujian berfokus pada parameter γ . Jumlah proses *differencing* hingga data menjadi stasioner menentukan nilai ordo integrasi d , apabila proses dilakukan satu kali maka nilai ordo integrasi d bernilai 1.

Penentuan ordo AR dan MA pada Model

Tahap selanjutnya dilakukan prosedur *Box-Jenkins* untuk identifikasi model. Tahap ini, data *differencing* dianalisis menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) [16]. ACF digunakan untuk mengukur korelasi antara nilai deret waktu pada periode t dengan periode sebelumnya pada berbagai *lag*, sedangkan PACF mengukur korelasi parsial antara X_t dan X_{t-k} dengan mengendalikan pengaruh *lag* yang lebih kecil. Dalam pendekatan *Box-Jenkins*, analisis ACF merupakan alat utama pada tahap identifikasi, dan PACF digunakan sebagai alat pelengkap untuk memperjelas pola ketergantungan *lag*.

Penentuan kandidat ordo komponen *autoregressive* (AR) dan *moving average* (MA) dilakukan berdasarkan sifat teoritis ACF dan PACF pada model stasioner. Secara umum, pada proses AR(p), PACF menunjukkan pola *cut-off* pada lag ke- p , sehingga nilai p dapat ditentukan dari lag terakhir yang signifikan pada plot PACF [12]. Sebaliknya, pada proses MA(q), ACF menunjukkan pola *cut-off* pada lag ke- q , sehingga nilai q ditentukan dari lag terakhir yang

signifikan pada plot ACF [13]. *Lag* yang dianggap signifikan adalah *lag* yang nilai korelasinya melewati batas kepercayaan (*confidence limits*) yang ditetapkan. Nilai p dan q yang diperoleh dari interpretasi ACF dan PACF digunakan sebagai kandidat awal untuk membangun beberapa alternatif model ARIMA (p, d, q).

Model Autoregressive Integrated Moving Average (ARIMA)

ARIMA merupakan model linear stokastik yang mengintegrasikan tiga komponen utama, yaitu *autoregressive* (AR), *integrated* (I), dan *moving average* (MA). Komponen AR merepresentasikan ketergantungan nilai saat ini terhadap nilai masa lalu deret, komponen I merepresentasikan proses *differencing* untuk mengatasi ketidakstasioneran, sedangkan komponen MA merepresentasikan pengaruh gangguan acak masa lalu terhadap nilai saat ini. Kerangka ini banyak digunakan karena bersifat parsimonious namun mampu menangkap struktur autokorelasi yang umum pada data deret waktu [14], [15].

Model ARIMA dinotasikan sebagai p, d, q , dengan p sebagai orde komponen AR, d sebagai orde diferensiasi (*difference*), dan q sebagai orde komponen MA. Sebagai contoh, Y_t menyatakan nilai deret waktu pada waktu t . Apabila deret Y_t tidak stasioner, biasanya karena menunjukkan *tren* atau perubahan level, maka dilakukan diferensiasi non-musiman sebanyak d kali untuk memperoleh deret transformasi $X_t = \nabla^d Y_t$, yang lebih mendekati stasioner. Operator diferensiasi pertama didefinisikan sebagai $\nabla Y_t = Y_t - Y_{t-1}$. Transformasi ini penting karena pemodelan ARIMA mengasumsikan proses yang stasioner setelah diferensiasi, dimana diferensiasi berfungsi menghilangkan komponen non-stasioner pada rata-rata sehingga struktur dependensi temporal dapat diestimasi secara lebih andal [16], [17].

Setelah memperoleh deret transformasi yang telah stasioner X_t , struktur ketergantungan antarwaktu dimodelkan melalui kombinasi struktur AR dan MA. Dengan operator *backshift* B (dengan definisi $BY_t = Y_{t-1}$), model ARIMA dapat dirumuskan sebagai berikut:

$$\phi(B)X_t = c + \theta(B)\varepsilon_t, \quad (4)$$

dengan

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (5)$$

sebagai polinomial autoregresif,

dan

$$\theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q \quad (6)$$

sebagai polinomial *moving average*, c sebagai konstanta (opsional sesuai spesifikasi), dan ε_t sebagai gangguan acak yang diasumsikan *white noise* dengan rata-rata nol dan varians konstan. Formulasi ini menyatakan bahwa nilai X_t dipengaruhi oleh kombinasi linear nilai-nilai masa lalu serta kombinasi linear *shock*/galat masa lalu, sehingga ARIMA secara eksplisit merepresentasikan memori jangka pendek (*short-run dependence*) dari suatu proses deret waktu [14], [15].

Dalam interpretasi statistik, komponen AR (p) menangkap persistensi deret melalui koefisien ϕ_i yang mengukur kontribusi X_{t-i} terhadap X_t . Sementara itu, komponen MA(q) menangkap struktur korelasi residual melalui koefisien θ_j yang mengukur pengaruh *shock* ε_{t-j} terhadap X_t . Pemilihan orde p dan q pada umumnya mempertimbangkan prinsip parsimoni: orde yang terlalu besar dapat meningkatkan kompleksitas dan risiko *overfitting*, sedangkan orde yang terlalu kecil berpotensi menyisakan autokorelasi pada residual yang mengindikasikan spesifikasi model belum memadai [14], [15].


Peramalan Harga Lump Karet

Berdasarkan orde model ARIMA (p, d, q) yang telah ditetapkan, peramalan deret waktu dilakukan dengan menggunakan parameter hasil estimasi model. Proses peramalan memanfaatkan informasi historis yang terkandung dalam deret waktu melalui struktur ketergantungan antarwaktu yang telah dimodelkan oleh komponen autoregresif dan moving average sesuai dengan spesifikasi orde model. Dengan demikian, nilai ramalan yang dihasilkan merepresentasikan kelanjutan pola historis deret waktu berdasarkan dinamika yang teridentifikasi dari data pengamatan sebelumnya.

HASIL DAN PEMBAHASAN

Plot Harga Lump Karet

Fluktuasi dan kenaikan Harga Lump Karet di Provinsi Jambi dapat dilihat pada Gambar 1. Awal periode pengamatan menunjukkan harga berada pada kisaran yang relatif rendah, kemudian mengalami kenaikan secara bertahap hingga mencapai level tertinggi pada akhir periode. Pola ini memperlihatkan adanya kecenderungan peningkatan harga jangka panjang, dengan berbagai faktor fundamental dari pasar.




Gambar 1. Plotting Data Harga Lump Karet

Data ini juga memperlihatkan fluktuasi harga jangka pendek yang semakin volatil pada awal tahun 2024. *Varians* harga yang signifikan mengindikasikan adanya peningkatan ketidakpastian pasar serta memungkinkan adanya perubahan struktur harga. Hal ini menegaskan harga lump dipengaruhi dari tren dan dinamika volatilitas. Besarnya *varians* yang tidak konsisten antar periode menunjukkan adanya heteroskedastisitas, sehingga data belum memenuhi asumsi kestasioneran *varians*. Untuk menstabilkan *varians* data, dilakukan dengan transformasi Box-Cox agar data dapat digunakan pada pemodelan *time series*.


Transformasi Box-Cox

Transformasi Box Cox dilakukan untuk menstabilkan *varians* pada Harga Lump Karet. Sebelum data ditransformasi, dilakukan analisis untuk melihat sejauh mana *varians* belum konstan.



Gambar 2. Box-Cox Plot Harga Lump Karet

Hasil kalkulasi Box-Cox plot pada data awal menghasilkan estimasi parameter sebesar $\lambda = 0,65$ dengan interval kepercayaan 95% (-18;1,37). Estimasi parameter dengan nilai tidak mendekati satu ($\lambda = 1$), mengindikasikan adanya heteroskedastisitas *varians* sehingga perlu dilakukan transformasi untuk menstabilkan *varians* data.



Gambar 3. Box-Cox Plot Transformed Harga Lump Karet

Setelah transformasi dilakukan, menunjukkan adanya peningkatan dalam kestabilan *varians*. Box-cox plot pada data tertansformasi menghasilkan nilai estimasi parameter yang mendekati satu (*rounded value* = 1), dengan estimasi parameter ($\lambda = 1,30$), dengan interval kepercayaan 95% (-0,25;2,88). Kondisi $\lambda \approx 1$ mengindikasikan bahwa data hasil transformasi berada pada skala yang sesuai dan tidak memerlukan transformasi tambahan [18].

Uji Stasioneritas

Uji Stasioneritas dikalkulasikan menggunakan uji Augmented Dickey-Fuller (ADF) pada data yang telah ditransformasikan. Hasil uji ADF disajikan pada Gambar 4.

Augmented Dickey-Fuller Test

Null hypothesis: Data are non-stationary

Alternative hypothesis: Data are stationary

Test

Statistic P-Value Recommendation

-1,48130 0,543 Test statistic > critical value of -2,88127.

Significance level = 0,05

Fail to reject null hypothesis.

Consider differencing to make data stationary.

Gambar 4. Hasil Augmented Dickey-Fuller Test dengan Data Transformed

Hasil ADF menunjukkan nilai statistik uji sebesar -1,48130 dengan nilai p -value 0,534. Nilai p -value > 0,05 mengindikasikan data tidak stasioner [10]. Oleh karena itu, dilakukan *differencing* untuk menghilangkan tren dan menjadikan deret data menjadi stasioner.

Augmented Dickey-Fuller Test

Null hypothesis: Data are non-stationary

Alternative hypothesis: Data are stationary

Test

Statistic P-Value Recommendation

-6,02686 0,000 Test statistic <= critical value of -2,88304.

Significance level = 0,05

Reject null hypothesis.

Data appears to be stationary, not supporting differencing.

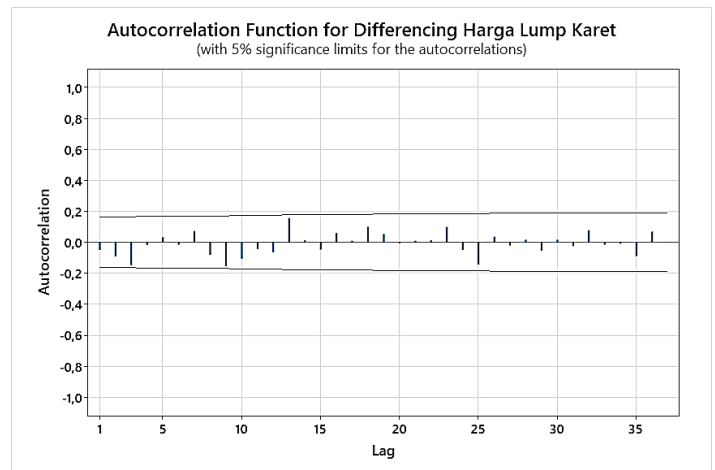
Gambar 5. Augmented Dickey-Fuller Test setelah *differencing* Data

Setelah dilakukan *differencing*, Hasil ADF berubah dengan statistik uji sebesar -6,02686 dan p -value < 0,001, hal ini menunjukkan bahwa data telah stasioner (p -value < 0,05). Tahap ini *differencing* cukup dilakukan sebanyak satu kali, sehingga orde *differencing* ditetapkan sebesar $d = 1$.

Penentuan ordo AR dan MA pada model


Tahap selanjutnya melakukan identifikasi model dengan analisis *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Kedua fungsi ini digunakan untuk menggambarkan pola keterkaitan data

antar periode waktu (*lag*), digunakan sebagai acuan dalam penentuan orde parameter *autoregressive* (p) dan *moving average* (q) pada model ARIMA.



Gambar 6. Hasil *Autocorrelation Function* untuk *Differencing* Harga Lump Karet

Berdasarkan plot ACF pada data hasil *differencing*, sebagian besar batang autokorelasi berada di dalam batas signifikansi 5% dan tidak menunjukkan pola *cut-off* yang tegas pada *lag* awal. Nilai autokorelasi cenderung kecil dan berfluktuasi di sekitar nol, sehingga mengindikasikan bahwa komponen *moving average* (MA) tidak dominan secara kuat dan orde q diperkirakan rendah (sekitar 0–1).



Gambar 7. Hasil *Partial Autocorrelation Function* Untuk *Differencing* Harga Lump Karet

Berdasarkan plot PACF, pola yang serupa juga terlihat, yaitu sebagian besar autokorelasi parsial berada di dalam batas signifikansi 5% dan tidak membentuk *cut-off*

yang jelas pada *lag* kecil. Kondisi ini menunjukkan bahwa komponen *autoregressive* (AR) tidak dominan secara tunggal dan orde p juga cenderung rendah (sekitar 0–1). Secara keseluruhan, kombinasi hasil ACF dan PACF yang sama-sama tidak menunjukkan dominasi AR atau MA mengindikasikan bahwa dinamika deret waktu setelah *differencing* kemungkinan dapat direpresentasikan oleh model ber-orde rendah, termasuk kemungkinan model campuran ARIMA sederhana.

Oleh karena itu, untuk memperoleh model yang paling sesuai, dilakukan pengujian beberapa model pembandingan dengan $d = 1$. Kandidat yang diuji dipilih di sekitar orde rendah yang paling mungkin berdasarkan ACF–PACF, yaitu ARIMA(1,1,0) untuk menangkap kemungkinan pengaruh AR minimal, ARIMA(0,1,1) untuk menangkap kemungkinan pengaruh MA minimal, serta ARIMA(1,1,1) sebagai model campuran yang lebih fleksibel.

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0,0204	0,0830	-0,25	0,806
Constant	33,8	44,5	0,76	0,448

Residual Sums of Squares

DF	SS	MS
146	42724163	292631

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	16,19	25,80	33,56	42,98
DF	10	22	34	46
P-Value	0,094	0,260	0,489	0,599

Gambar 8. Hasil Pengujian ARIMA (1,1,0)

Estimasi model ARIMA(1,1,0) menunjukkan bahwa parameter AR(1) memiliki nilai estimasi parameter sebesar $-0,0204$ dengan p -value sebesar 0,806, sehingga tidak signifikan pada taraf 5%. Konstanta (*drift*) juga tidak signifikan (p -value = 0,448). Hal ini mengindikasikan bahwa setelah *differencing* satu kali, model belum menemukan hubungan yang kuat antara perubahan harga saat ini dengan perubahan pada satu periode sebelumnya. Meskipun demikian, uji Ljung–Box pada *lag* 12, 24, 36, dan 48 memberikan p -value 0,094; 0,260; 0,489; dan 0,599 (seluruhnya $> 0,05$), yang berarti residual tidak

menunjukkan autokorelasi yang signifikan. Dengan kata lain, dari sisi residual model cukup baik, tetapi kontribusi komponen AR dalam menjelaskan pola data masih lemah.

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
MA 1	0,0252	0,0830	0,30	0,762
Constant	33,2	43,3	0,77	0,445

Residual Sums of Squares

DF	SS	MS
146	42720034	292603

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	16,35	25,98	33,71	43,19
DF	10	22	34	46
P-Value	0,090	0,252	0,482	0,591

Gambar 9. Hasil Pengujian ARIMA (0,1,1)

Model ARIMA(0,1,1), parameter MA(1) memiliki nilai estimasi parameter sebesar 0,0252 dengan p -value 0,762 dan konstanta juga tidak signifikan (p -value = 0,445). Hal ini menunjukkan bahwa pengaruh galat satu periode sebelumnya belum terbukti berperan penting dalam menjelaskan perubahan harga pada periode sekarang. Uji Ljung–Box menghasilkan p -value 0,090; 0,252; 0,482; dan 0,591 pada lag 12, 24, 36, dan 48 (seluruhnya $> 0,05$), sehingga residual dapat dianggap acak dan tidak berkorelasi. Namun, karena parameter utama MA(1) tidak signifikan, model ini juga belum optimal untuk menggambarkan struktur ketergantungan jangka pendek pada data.

Final Estimates of Parameters

Type	Coef	SE	Coef	T-Value	P-Value
AR 1	0,8578	0,0465	18,46	0,000	
MA 1	0,97983	0,00805	121,73	0,000	
Constant	6,03	1,39	4,34	0,000	

Residual Sums of Squares

DF	SS	MS
145	40490139	279242

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	9,99	23,38	30,02	39,16
DF	9	21	33	45
P-Value	0,351	0,324	0,616	0,717

Gambar 10. Hasil Pengujian ARIMA (1,1,1)

Model ARIMA(1,1,1) memberikan hasil yang lebih kuat dibanding dua model sebelumnya. Parameter AR(1) memiliki nilai estimasi parameter sebesar 0,8578 dan MA(1) memiliki nilai estimasi parameter sebesar 0,97983 signifikan ($p\text{-value} < 0,001$), dan konstanta (*drift*) = 6,03 juga signifikan ($p\text{-value} < 0,001$). Hal ini berarti perubahan harga saat ini dipengaruhi oleh perubahan pada satu periode sebelumnya (AR) sekaligus oleh *shock*/galat periode sebelumnya (MA). Selain itu, nilai MS residual pada model ini lebih kecil dibandingkan dua model lain, yang menunjukkan galat model lebih rendah. Uji *Ljung-Box* juga memberikan $p\text{-value}$ yang lebih besar pada berbagai lag (0,351; 0,324; 0,616; 0,717), sehingga residual memenuhi asumsi *white noise*. Secara keseluruhan, berdasarkan signifikansi parameter, besarnya galat, dan diagnostik residual, ARIMA(1,1,1) lebih layak dipilih sebagai model yang merepresentasikan data.

Peramalan Harga Lump Karet

Berdasarkan hasil identifikasi dan evaluasi model pada tahap sebelumnya, model ARIMA(1,1,1) dipilih sebagai model yang paling sesuai untuk merepresentasikan dinamika Harga Lump Karet. Model ini selanjutnya digunakan untuk melakukan peramalan harga dalam 16 periode (minggu) ke depan. Peramalan ini bertujuan untuk memberikan gambaran arah pergerakan harga jangka pendek serta menjadi dasar dalam pengambilan keputusan terkait perencanaan dan pengelolaan risiko harga.

Tabel 1. Peramalan 16 Periode Kedepan

Period	Forecast
150	Rp14.954
151	Rp15.080
152	Rp15.195
153	Rp15.299
154	Rp15.394
155	Rp15.482
156	Rp15.564
157	Rp15.640
158	Rp15.711
159	Rp15.778
160	Rp15.841
161	Rp15.902
162	Rp15.960
163	Rp16.016
164	Rp16.070
165	Rp16.122

KESIMPULAN

Penelitian ini bertujuan untuk menganalisis dan memodelkan pergerakan Harga Lump Karet menggunakan pendekatan *time series*. Data yang digunakan merupakan data Harga Lump Karet Unit Pengolahan dan Pemasaran Bokar (UPPB) dengan Kadar Karet Kering (KKK) antara 56 hingga 60 persen, yang diamati selama 149 minggu dari Januari 2023 hingga November 2025. Hasil analisis menunjukkan bahwa data harga memiliki *tren* meningkat disertai fluktuasi yang semakin besar, sehingga *varians* data tidak konstan. Untuk mengatasi kondisi tersebut, dilakukan transformasi Box – Cox yang terbukti efektif dalam menstabilkan *varians*.

Selanjutnya, uji Augmented Dickey–Fuller menunjukkan bahwa data belum stasioner pada level, namun setelah dilakukan *differencing* satu kali, data telah memenuhi asumsi stasioneritas sehingga orde *differencing* ditetapkan sebesar $d = 1$. Berdasarkan analisis ACF dan PACF, beberapa model ARIMA kandidat dibangun dan dievaluasi. Hasil estimasi dan diagnostik model menunjukkan bahwa ARIMA(1,1,1) memberikan kinerja terbaik dibandingkan model alternatif lainnya, ditunjukkan oleh signifikansi parameter, nilai galat yang lebih kecil, serta residual yang bersifat acak. Model ARIMA(1,1,1) kemudian digunakan untuk melakukan peramalan Harga Lump Karet selama 16 periode (minggu) ke depan. Hasil peramalan ini diharapkan

dapat memberikan informasi yang bermanfaat bagi pelaku usaha dan pengambil kebijakan dalam memahami arah pergerakan harga serta mendukung pengambilan keputusan yang lebih tepat.

DAFTAR PUSTAKA

- [1] G. E. P. Box and G. M. Jenkins, *Time Series Analysis: Forecasting and Control*, Holden-Day, 1976.
- [2] P. J. Brockwell and R. A. Davis, *Introduction to Time Series and Forecasting*, Springer, 1997.
- [3] Y. Zhang, S. Wang, and J. Phillips, "Forecasting agricultural commodity prices using ARIMA models," *Journal of Forecasting*, vol. 37, no. 5, pp. 555–567, 2018.
- [4] T. Suryanto and S. Nugroho, "Peramalan harga kelapa sawit menggunakan model ARIMA," *Jurnal Agribisnis Indonesia*, vol. 10, no. 2, pp. 123–134, 2022.
- [5] R. Putri, A. Hidayat, and M. Prasetyo, "Analisis peramalan harga kopi berbasis ARIMA," *Jurnal Statistika dan Aplikasinya*, vol. 7, no. 1, pp. 45–56, 2021.
- [6] G. E. P. Box and D. R. Cox, "An Analysis of Transformations," 1964. doi: 10.1111/j.2517-6161.1964.tb00553.x.
- [7] M. Sivaram, A. Hudaya, and A. Hapzi, "Building a Purchase and Prchase Decision: Analysis of Brand Awareness and Brand Loyalty (Case Study of Private Label Products at Alfamidi Stores In Tangerang City)," *Dijemss*, vol. 1, no. 2, pp. 235–248, 2019, doi: 10.31933/DIJEMSS.
- [8] Y. Xu *et al.*, "Advanced multi-sensor optical remote sensing for urban land use and land cover classification: Outcome of the 2018 ieee grss data fusion contest," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 12, no. 6, pp. 1709–1724, 2019, doi: 10.1109/JSTARS.2019.2911113.
- [9] J. N. van Rijn, G. Holmes, B. Pfahringer, and J. Vanschoren, "The online performance estimation framework: heterogeneous ensemble learning for data streams," *Mach. Learn.*, vol. 107, no. 1, pp. 149–176, 2018, doi: 10.1007/s10994-017-5686-9.
- [10] P. Taylor, D. A. Dickey, W. A. Fuller, D. A. Dickey, and W. A. Fuller, "Journal of the American Statistical Association Distribution of the Estimators for Autoregressive Time Series with a Unit Root Distribution of the Estimators for Autoregressive Time Series With a Unit Root," no. July 2015, pp. 37–41, 2012, doi: 10.1080/01621459.1979.10482531.
- [11] A. G. E. P. Box, G. M. Jenkins, S. Journal, R. Statistical, S. Series, and C. A. Statistics, "Some Recent Advances in Forecasting and Control Published by: Wiley for the Royal Statistical Society Some Recent Advances in Forecasting and Control," *J. R. Stat. Soc.*, vol. 17, no. 2, pp. 91–109, 1968.
- [12] C. H. Weiß, B. Aleksandrov, M. Faymonville, and C. Jentsch, "Partial Autocorrelation Diagnostics for Count Time Series," *Entropy*, vol. 25, no. 1, pp. 1–21, 2023, doi: 10.3390/e25010105.
- [13] M. Royer-Carenzi and H. Hassani, "Deviations from Normality in Autocorrelation Functions and Their Implications for MA(q) Modeling," *Stats*, vol. 8, no. 1, pp. 1–38, 2025, doi: 10.3390/stats8010019.
- [14] L. Seymour, P. J. Brockwell, and R. A. Davis, *Introduction to Time Series and Forecasting.*, vol. 92, no. 440. 1997. doi: 10.2307/2965440.
- [15] G. T. Wilson, "Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1," *J. Time Ser. Anal.*, vol. 37, no. 5, pp. 709–711, 2016, doi: 10.1111/jtsa.12194.
- [16] I. Yanovitzky and A. VanLear, *Time Series Analysis Time Series Analysis*, no. I. 2018. [Online]. Available: https://us.sagepub.com/sites/default/files/upm-assets/23658_book_item_23658.pdf
- [17] P. R. Roberge, *Principles and Practice Principles and Practice Editors*. 2008. [Online]. Available: <https://www.taylorfrancis.com/chapters/edit/10.4324/9781315694108-6/principles-practice-roy-bahl-richard-bird>
- [18] G. E. P. Box and D. R. Cox, "An Analysis of Transformations," *J. R. Stat. Soc. Ser. B Stat. Methodol.*, vol. 26, no. 2, pp. 211–243, 1964, doi: 10.1111/j.2517-6161.1964.tb00553.x.