

Penerapan *Modified Jackknife Kibria-Lukman Regression* dengan Koreksi Autokorelasi Prais-Winsten pada Nilai Tukar Rupiah terhadap Dolar Amerika Serikat

Chrisadna Patricia Kabangnga, A. Muthiah Nur Angriany, dan Raupong



Volume 14, Issue 2, Pages 377–399, August 2026

Diterima 25 April 2026, Direvisi 17 Juni 2026, Disetujui 23 Juni 2026, Diterbitkan 15 Juli 2026

To Cite this Article : C. P. Kabangnga, A. M. N. Angriany, dan R. Raupong, “Penerapan *Modified Jackknife Kibria-Lukman Regression* dengan Koreksi Autokorelasi Prais-Winsten pada Nilai Tukar Rupiah terhadap Dolar Amerika Serikat”, *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 14, no. 2, pp. 377–399, 2026, <https://doi.org/10.37905/euler.v14i2.38482>

© 2026 by author(s)

JOURNAL INFO • EULER : JURNAL ILMIAH MATEMATIKA, SAINS DAN TEKNOLOGI




Homepage	:	http://ejurnal.ung.ac.id/index.php/euler/index
Journal Abbreviation	:	Euler J. Ilm. Mat. Sains dan Teknol.
Frequency	:	Three times a year
Publication Language	:	English (preferable), Indonesia
DOI	:	https://doi.org/10.37905/euler
Online ISSN	:	2776-3706
License	:	Creative Commons Attribution-NonCommercial 4.0 International License
Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
Country	:	Indonesia
OAI Address	:	http://ejurnal.ung.ac.id/index.php/euler/oai
Google Scholar ID	:	QF_r_gAAAAJ
Email	:	euler@ung.ac.id


JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



Jambura Journal of Biomathematics



Jambura Journal of Mathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics

Penerapan *Modified Jackknife Kibria-Lukman Regression* dengan Koreksi Autokorelasi Prais-Winsten pada Nilai Tukar Rupiah terhadap Dolar Amerika Serikat

Chrisadna Patricia Kabangnga¹, A. Muthiah Nur Angriany^{1,*}, dan Raupong¹

¹Program Studi Statistika, Universitas Hasanuddin, Makassar 90245, Indonesia

ARTICLE HISTORY

Diterima 25 April 2026

Direvisi 17 Juni 2026

Disetujui 23 Juni 2026

Diterbitkan 15 Juli 2026

KATA KUNCI

Autokorelasi
Modified Jackknife Kibria-Lukman
Regression
Multikolinieritas
Nilai Tukar Rupiah terhadap Dolar
Amerika Serikat
Prais-Winsten

KEYWORDS

Autocorrelation
Modified Jackknife Kibria-Lukman
Regression
Multicollinearity
Rupiah Exchange Rate Against the
United States Dollar
Prais-Winsten

ABSTRAK. Pergerakan nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD) mengalami volatilitas pada periode 2021 hingga 2024, sehingga membutuhkan analisis yang tepat untuk mengidentifikasi faktor-faktor yang memengaruhinya. Pemodelan ini dapat dilakukan melalui analisis regresi linier berganda, tetapi pendugaan parameter menggunakan Ordinary Least Squares (OLS) sering kali tidak efisien dan rentan menghasilkan variansi yang besar akibat pelanggaran asumsi berupa multikolinieritas dan autokorelasi. Oleh karena itu, penelitian ini bertujuan untuk memodelkan nilai tukar Rupiah terhadap USD tahun 2021-2024 serta mengidentifikasi faktor-faktor yang memengaruhinya secara signifikan menggunakan metode Modified Jackknife Kibria-Lukman Regression (MJKLK) dengan koreksi autokorelasi Prais-Winsten (PW). Penanganan autokorelasi dilakukan melalui koreksi PW, dilanjutkan dengan pemodelan MJKLK pada data hasil transformasi PW untuk mengurangi dampak multikolinieritas. Hasil penelitian menunjukkan bahwa penduga MJKLK-PW memberikan kinerja yang lebih efisien dibandingkan OLS-PW dan KLR-PW, dengan nilai MSE penduga sebesar 0,1877, RMSE sebesar 326,1730, dan nilai adjusted R^2 sebesar 72,54%. Variabel jumlah uang beredar, suku bunga acuan, total ekspor, dan total impor berpengaruh signifikan terhadap nilai tukar Rupiah pada taraf signifikansi 5%. Kesimpulannya, kombinasi MJKLK dan PW efektif dalam memodelkan nilai tukar Rupiah terhadap USD yang memiliki masalah autokorelasi dan multikolinieritas. Secara empiris, penelitian ini menunjukkan bahwa stabilitas nilai tukar Rupiah sangat bergantung pada fundamental makroekonomi, terutama kebijakan moneter dan neraca perdagangan.

ABSTRACT. The movement of the Indonesian Rupiah exchange rate against the United States Dollar (USD) experienced volatility during the 2021-2024 period, thus requiring precise analysis to identify the factors influencing it. This modeling can be conducted through multiple linear regression analysis; however, parameter estimation using Ordinary Least Squares (OLS) is often inefficient and prone to producing large variances due to the violation of assumptions in the form of multicollinearity and autocorrelation. Therefore, this study aims to model the Rupiah exchange rate against the USD for the 2021–2024 period and identify the significantly influencing factors using the Modified Jackknife Kibria-Lukman Regression (MJKLK) method with Prais-Winsten (PW) autocorrelation correction. Autocorrelation handling was performed through the PW correction, followed by MJKLK modeling on the PW-transformed data to reduce the impact of multicollinearity. The results showed that the MJKLK-PW estimator provided a more efficient performance compared to OLS-PW and KLR-PW, with an estimator MSE of 0.1877, RMSE of 326.1730, and an adjusted R^2 value of 72.54%. The variables of money supply, interest rate, total exports, and total imports had a significant effect on the Rupiah exchange rate at a 5% significance level. In conclusion, the combination of MJKLK and PW is effective in modeling the Rupiah exchange rate against the USD that has autocorrelation and multicollinearity problems. Empirically, this study indicates that the stability of the Rupiah exchange rate relies heavily on macroeconomic fundamentals, particularly monetary policy and the trade balance.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. **Editorial of EULER:** Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

*Penulis Korespondensi.

1. Pendahuluan

Analisis regresi linier berganda merupakan metode statistika yang digunakan untuk menganalisis hubungan sebab-akibat antara dua atau lebih variabel prediktor dengan satu variabel respon. Metode yang paling umum digunakan untuk menduga parameter regresi adalah *Ordinary Least Squares* (OLS), yang didasarkan pada pemenuhan asumsi klasik berupa normalitas, homoskedastisitas, nonautokorelasi, dan nonmultikolinieritas [1]. Apabila asumsi klasik terpenuhi, metode OLS akan menghasilkan penduga parameter yang bersifat tak bias dan efisien, sehingga hasil pengujian hipotesis statistik menjadi valid dan dapat diandalkan. Sebaliknya, pelanggaran terhadap asumsi klasik dapat mengakibatkan ketidakakuratan pada nilai galat baku yang dapat meningkatkan risiko kesalahan pengujian hipotesis [2]. Pelanggaran asumsi klasik, khususnya autokorelasi, umumnya berkaitan erat dengan karakteristik data yang digunakan.

Data runtun waktu merupakan salah satu jenis data yang dapat digunakan untuk analisis empiris [3]. Namun, data runtun waktu rentan terhadap pelanggaran asumsi nonautokorelasi karena adanya ketergantungan temporal [4]. Autokorelasi menyebabkan penduga OLS tidak lagi memiliki variansi minimum, meskipun masih tetap bersifat linier dan tak bias [5]. Selain itu, karena OLS tidak memperhitungkan struktur korelasi antargalat, penduga galat baku yang dihasilkan menjadi tidak akurat, sehingga mengakibatkan pengujian hipotesis menjadi tidak valid. Untuk mengatasi autokorelasi, *Feasible Generalized Least Squares* (FGLS) digunakan sebagai pengembangan dari *Generalized Least Squares*. FGLS diterapkan ketika struktur matriks variansi-kovariansi galat tidak diketahui, sehingga harus diduga terlebih dahulu [4]. Prais-Winsten (PW) sebagai salah satu prosedur FGLS menawarkan perbaikan terhadap metode Cochrane-Orcutt (CO) dalam menangani galat dengan pola *Autoregressive* orde satu atau AR(1), terutama pada data dengan jumlah sampel terbatas [6]. Keunggulan PW terletak pada kemampuannya untuk mempertahankan observasi pertama melalui transformasi khusus, sehingga ukuran sampel yang digunakan tidak berkurang.

Selain nonautokorelasi, analisis regresi linier berganda yang melibatkan lebih dari satu variabel prediktor juga rentan terhadap pelanggaran asumsi nonmultikolinieritas. Kondisi ketika terdapat korelasi yang tinggi antarvariabel prediktor pada suatu model regresi disebut multikolinieritas. Adanya multikolinieritas mengakibatkan penduga parameter menjadi tidak stabil dan tidak akurat. Penduga parameter menjadi sangat sensitif terhadap perubahan kecil pada data akibat galat baku yang sangat besar. Secara matematis, galat baku yang besar akan menyebabkan nilai statistik uji t mengecil, sehingga variabel prediktor cenderung menjadi tidak signifikan. Akibatnya, sulit untuk membedakan pengaruh dari masing-masing variabel prediktor, sehingga keputusan mengenai signifikansi prediktor menjadi tidak andal [3].

Kibria dan Lukman memperkenalkan Kibria-Lukman Regression (KLR) sebagai penduga berbias dalam kelas *Ridge Regression* (RR) dan *Liu Regression* (LR) untuk menangani multikolinieritas pada model regresi linier [7]. KLR menggunakan satu parameter bias seperti RR, tetapi dengan struktur penduga yang dimodifikasi agar lebih efektif dalam menangani multikolinieritas. Tujuan KLR adalah menyeimbangkan bias dan variansi penduga parameter regresi. Sebagai pengembangan lebih lanjut, *Jackknife Kibria-Lukman Regression* (JKLR) diperkenalkan dengan menerapkan prosedur *jackknife* untuk mengurangi bias yang dihasilkan oleh penduga KLR [8]. Selanjutnya, dikembangkan *Modified Jackknife Kibria-Lukman Regression* (MJKLR) sebagai modifikasi lanjutan dari penduga JKLR. Metode MJKLR memodifikasi penduga JKLR dengan menyubstitusi komponen penduga dasar menjadi penduga KLR dengan tujuan untuk meminimumkan *Mean Squared Error* (MSE) dengan cara mereduksi bias secara optimal, sambil tetap mempertahankan stabilitas variansi yang rendah.

Pengembangan metode regresi untuk menangani masalah autokorelasi dan multikolinieritas telah dibahas dalam beberapa penelitian sebelumnya. Prosedur PW terbukti lebih efisien dibandingkan CO dalam menangani autokorelasi, terutama pada data yang memiliki tren [9]. Dalam penerapannya pada data empiris, kombinasi RR dengan PW berhasil menangani autokorelasi dan multikolinieritas pada data nilai tukar Rupiah terhadap USD [10]. Selanjutnya, sebuah studi simulasi [11] membuktikan bahwa metode KLR dan PW menghasilkan MSE yang lebih kecil dibanding penduga OLS, PW, CO, *Maximum Likelihood Estimation* (MLE), *Restricted MLE*, *Ridge-Prais* terutama pada tingkat autokorelasi dan multikolinieritas sedang hingga kuat. Penelitian yang dilakukan oleh Ugwuowo dkk. [8] menunjukkan bahwa ketika terdapat multikolinieritas pada data, MJKLR menghasilkan MSE yang lebih minimum dibandingkan dengan OLS, RR, *Jackknife* RR, LR, *Jackknife* LR, dan KLR. Namun, MJKLR berpotensi menghasilkan penduga yang tidak efisien dan galat baku yang bias jika diaplikasikan langsung pada data runtun waktu memiliki masalah autokorelasi galat. Integrasi metode PW menjadi solusi melalui transformasi data untuk menghilangkan autokorelasi tanpa membuang pengamatan awal. Langkah transformasi PW menghasilkan landasan data yang bersih bagi MJKLR untuk mengatasi multikolinieritas secara optimal. Kombinasi metode ini diperlukan untuk memodelkan indikator ekonomi makro yang fluktuatif dan rentan terhadap pelanggaran asumsi, seperti pergerakan nilai tukar mata uang.

Stabilitas nilai tukar mata uang suatu negara terhadap mata uang asing merupakan salah satu indikator untuk memastikan bahwa perekonomian suatu negara berada dalam keadaan yang baik [12]. Bagi Indonesia, fluktuasi nilai tukar Rupiah terhadap USD tidak sekadar mencerminkan kondisi ekonomi domestik, tetapi juga merepresentasikan tingkat kepercayaan pasar terhadap stabilitas nasional. Memasuki akhir tahun 2024, Rupiah terus menghadapi tekanan depresiasi hingga menyentuh Rp16.162 per USD berdasarkan Laporan Ekonomi dan Keuangan Mingguan pada bulan Desember. Depresiasi Rupiah dapat berdampak bagi banyak hal, mulai dari lonjakan biaya impor hingga perubahan dinamika investasi dan kondisi pasar saham di Indonesia. Depresiasi Rupiah juga memicu efek domino berupa penurunan daya beli masyarakat yang dapat menghambat konsumsi domestik, padahal konsumsi merupakan pendorong utama bagi pertumbuhan ekonomi Indonesia [13]. Oleh karena itu, analisis mengenai faktor-faktor yang memengaruhi pergerakan nilai tukar Rupiah menjadi penting untuk dilakukan.

Penelitian ini menggunakan data bulanan nilai tukar Rupiah terhadap USD beserta variabel-variabel yang diduga memengaruhinya selama periode 2021-2024. Namun, karakteristik data runtun waktu sangat rentan memicu tingginya korelasi antarvariabel prediktor (multikolinieritas) serta keterkaitan nilai observasi antara satu periode dengan periode sebelumnya (autokorelasi). Guna mengatasi pelanggaran kedua asumsi tersebut secara simultan, diterapkan pemodelan MJKLR yang diintegrasikan dengan koreksi autokorelasi PW. Oleh karena itu, penelitian ini bertujuan memodelkan nilai tukar Rupiah terhadap USD periode 2021–2024 menggunakan metode MJKLR-PW sekaligus mengidentifikasi faktor-faktor yang memengaruhinya secara signifikan.

2. Metode


Data yang digunakan dalam penelitian ini merupakan data sekunder nilai tukar Rupiah terhadap USD dan faktor-faktor yang diduga memengaruhinya. Data yang digunakan merupakan data periode bulanan dari Januari 2021 hingga Desember 2024 yang berjumlah 48 observasi. Data yang digunakan bersumber dari situs resmi Badan Pusat Statistik (BPS), Bank Indonesia, Satu Data Perdagangan Kementerian Perdagangan Indonesia, dan [investing.com](https://www.investing.com).

Berdasarkan beberapa penelitian sebelumnya [10, 13–15], variabel-variabel yang diduga memengaruhi nilai tukar Rupiah terhadap USD disajikan pada Tabel 1.

Tabel 1. Variabel penelitian.

Variabel	Keterangan	Definisi Operasional	Satuan
y	Nilai Tukar Rupiah terhadap USD	Jumlah Rupiah yang dibutuhkan untuk memperoleh satu USD	Rupiah
X_1	Inflasi	Situasi ketika terjadi peningkatan harga barang dan jasa secara umum dan terus-menerus dalam jangka waktu tertentu	Persen
X_2	Jumlah Uang Beredar (M2)	Keseluruhan nilai mata uang yang beredar dalam perekonomian suatu negara pada periode tertentu, yang mencakup uang tunai (kartal) dan simpanan yang mudah dicairkan (giral)	Miliar Rupiah
X_3	Suku Bunga Acuan	Tingkat suku bunga yang ditetapkan oleh Bank Indonesia (BI) sebagai patokan bagi lembaga keuangan di seluruh Indonesia dalam menentukan besarnya suku bunga yang akan ditawarkan kepada nasabah, termasuk suku bunga pinjaman dan tabungan	Persen
X_4	Total Ekspor	Akumulasi nilai ekspor Indonesia yang mencakup dua sektor utama, yaitu sektor migas (gas dan minyak bumi) dan sektor non migas (pertanian, industri pengolahan, pertambangan, dan lainnya)	Juta USD
X_5	Total Impor	Keseluruhan nilai impor yang masuk ke Indonesia	Juta USD
X_6	Harga Minyak Mentah Dunia (Brent)	Harga minyak global yang diperdagangkan di pasar internasional. Indonesia umumnya menggunakan pergerakan harga Brent Crude Oil sebagai patokan dalam memantau dan menentukan harga minyak mentah	USD

Penelitian ini menggunakan metode *Modified Jackknife* Kibria-Lukman Regression dengan koreksi autokorelasi Prais-Winsten. Analisis data dilakukan menggunakan bantuan *software* R-Studio dan pengujian hipotesis dilakukan pada taraf signifikansi 5%. Alur kerja penelitian dimulai dari pengumpulan data, pra-pemrosesan, pemodelan OLS, pengujian asumsi klasik, penanganan autokorelasi dan multikolinieritas, hingga diperoleh model akhir yang dievaluasi dan diinterpretasikan, sebagaimana yang diilustrasikan pada Gambar 1.



Gambar 1. Diagram alir tahapan penelitian.

Secara rinci, tahapan analisis yang dilakukan dalam penelitian ini berdasarkan diagram alir pada **Gambar 1** dijelaskan sebagai berikut:

1. Melakukan pengumpulan data dan analisis statistik deskriptif untuk memberikan gambaran terkait variabel-variabel yang digunakan dalam penelitian.
2. Melakukan pra-pemrosesan data dengan menerapkan transformasi logaritma natural (ln) pada variabel X_2, X_4, X_5 , dan X_6 hingga diperoleh variabel hasil transformasi $\tilde{X}_2, \tilde{X}_4, \tilde{X}_5$ dan $\tilde{X}_6$.
3. Melakukan pengujian asumsi klasik regresi, seperti uji normalitas galat, homoskedastisitas, multikolinieritas, dan autokorelasi pada model regresi linier berganda OLS. Analisis regresi linier berganda merupakan metode statistika yang sering digunakan untuk memodelkan satu variabel respon terhadap beberapa variabel prediktor [16]. Bentuk umum persamaan regresi linier berganda ditulis pada **pers. (1)** [17].

$$y_i = \beta_0 + \beta_1 X_{i,1} + \beta_2 X_{i,2} + \cdots + \beta_p X_{i,p} + \varepsilon_i, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, p \quad (1)$$

dengan

- y_i : variabel respon pada observasi ke- i ,
 $X_{i,j}$: observasi ke- i pada variabel prediktor ke- j ,
 β_0 : konstanta parameter regresi (intersep),
 $\beta_1, \beta_2, \dots, \beta_p$: koefisien regresi untuk variabel prediktor ke- j ,
 ε_i : galat pada observasi ke- i .

Pers. (1) dapat dituliskan dalam notasi matriks seperti pada **pers. (2)**.

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (2)$$

dengan

- $\mathbf{y}$: vektor variabel respon berukuran $n \times 1$,
 $\mathbf{X}$: matriks variabel prediktor berukuran $n \times (p + 1)$,
 $\boldsymbol{\beta}$: vektor parameter berukuran $(p + 1) \times 1$,
 $\boldsymbol{\varepsilon}$: vektor galat berukuran $n \times 1$.

Model regresi linier berganda yang baik dan ideal harus memenuhi kriteria asumsi klasik regresi. Pemenuhan asumsi ini krusial untuk menjamin bahwa model yang diestimasi dapat memberikan hasil prediksi yang akurat. Beberapa uji asumsi klasik yang harus dilakukan, yaitu:

a. Uji Normalitas

Uji normalitas dilakukan untuk mengetahui apakah galat data berdistribusi normal. Suatu model regresi dianggap tepat atau layak digunakan apabila galatnya memenuhi asumsi normalitas [1]. Uji Shapiro-Wilk lebih direkomendasikan untuk menguji normalitas pada sampel kecil ($n \leq 50$) karena memiliki kekuatan statistik yang tinggi dalam mendeteksi penyimpangan distribusi [18]. Hipotesis uji Shapiro-Wilk adalah sebagai berikut:

$H_0 : \varepsilon \sim N(\mu, \sigma^2)$ (galat berdistribusi normal)

$H_1 : \varepsilon \not\sim N(\mu, \sigma^2)$ (galat tidak berdistribusi normal)

Statistik uji normalitas menggunakan uji Shapiro-Wilk ditunjukkan pada **pers. (3)**.

$$W_{hitung} = \frac{(\sum_{i=1}^n a_i (\varepsilon_{n+1-i} - \varepsilon_i))^2}{\sum_{i=1}^n (\varepsilon_i - \bar{\varepsilon})^2}, \quad (3)$$

dengan a_i adalah koefisien uji Shapiro-Wilk [19].

Kriteria pengujian yaitu gagal tolak H_0 jika nilai uji $W_{hitung} \geq W_{(\alpha;n)}$ atau p -value $> 0,05$ yang artinya galat berdistribusi normal. Sebaliknya, jika nilai uji $W_{hitung} < W_{(\alpha;n)}$ atau p -value $< 0,05$ maka tolak H_0 yang artinya galat tidak berdistribusi normal.

b. Uji Homoskedastisitas

Homoskedastisitas artinya variansi dari galat bernilai konstan pada setiap tingkat variabel prediktor, yang menunjukkan bahwa sebaran data di sekitar garis regresi bersifat seragam. Uji homoskedastisitas dapat dilakukan dengan menggunakan uji Breusch-Pagan dengan hipotesis sebagai berikut:

H_0 : $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2$ (variansi galat bersifat konstan atau homoskedastisitas)

H_1 : Ada $\sigma_i^2 \neq \sigma_{i^*}^2$, untuk $i \neq i^* = 1, 2, \dots, n$ (variansi galat tidak bersifat konstan atau terjadi heteroskedastisitas)

Statistik uji homoskedastisitas menggunakan uji Breusch-Pagan ditunjukkan pers. (4).

$$BP = \frac{1}{2}JKR_{asy} \sim \chi_{\alpha,p}^2, \quad (4)$$

dengan JKR_{asy} merupakan jumlah kuadrat regresi yang diperoleh dari persamaan regresi bantuan (*auxiliary regression*), di mana variabel $p_i = \varepsilon_i^2 / \sigma^2$ diregresikan terhadap variabel-variabel prediktor [3]. Kriteria pengujian yaitu jika nilai $BP < \chi_{(\alpha;p)}^2$ atau p -value $> \alpha(0,05)$ maka gagal menolak H_0 dan disimpulkan bahwa variansi galat bersifat konstan atau homoskedastisitas. Sebaliknya, jika $BP \geq \chi_{(\alpha;p)}^2$ atau p -value $< \alpha(0,05)$ maka tolak H_0 dan disimpulkan bahwa variansi galat tidak bersifat konstan atau terjadi heteroskedastisitas.

c. Uji Autokorelasi

Autokorelasi merupakan kondisi ketika galat dari periode ke- i berkorelasi dengan galat periode lainnya ($i-1, i-2, \dots$). Derajat hubungan autokorelasi dapat diukur menggunakan koefisien autokorelasi (ρ) yang berada pada rentang interval $-1 \leq \rho \leq 1$. Model regresi yang baik adalah model yang terbebas dari masalah autokorelasi. Pendeteksian ada tidaknya autokorelasi dapat dilakukan menggunakan uji Durbin-Watson (DW) dengan rumusan hipotesis sebagai berikut:

H_0 : $\rho = 0$ (tidak terdapat autokorelasi pada galat)

H_1 : $\rho \neq 0$ (terdapat autokorelasi pada galat)

Statistik uji autokorelasi menggunakan uji Durbin-Watson ditunjukkan pada pers. (5).

$$DW = \frac{\sum_{i=2}^n (\hat{\varepsilon}_i - \hat{\varepsilon}_{i-1})^2}{\sum_{i=1}^n \hat{\varepsilon}_i^2}, \quad (5)$$

Kriteria pengujian yaitu jika $d_U < DW < 4 - d_U$ atau p -value $> 0,05$ artinya tidak terdapat autokorelasi. Jika $DW < d_L$ artinya terdapat autokorelasi positif, jika $4 - d_L < DW < 4$ artinya terdapat autokorelasi negatif. Jika nilai $4 - d_U < DW < 4 - d_L$ atau $d_L < DW < d_U$, maka tidak dapat ditarik kesimpulan.

d. Uji Multikolinieritas

Multikolinieritas adalah kondisi ketika terjadi korelasi kuat antara variabel prediktor dalam model regresi. Multikolinieritas mengakibatkan koefisien regresi menjadi tidak stabil (sensitif terhadap perubahan data kecil) dan menyebabkan interpretasi yang keliru terhadap variabel prediktor karena jika galat baku meningkat dapat mengakibatkan nilai statistik uji t menjadi rendah sehingga variabel prediktor tampak tidak signifikan meskipun sebenarnya berpengaruh. Korelasi antara variabel

prediktor dapat dilihat dari nilai *Variance Inflation Factor* (VIF). Nilai VIF akan meningkat ketika terdapat korelasi tinggi antar variabel prediktor. Nilai VIF dapat dihitung dengan pers. (6).

$$VIF_j = \frac{1}{1 - R_j^2}, \quad (6)$$

dengan $R_j^2 = \frac{JKR}{JKT} = \frac{\sum_{i=1}^n (\hat{x}_{ij} - \bar{x}_j)^2}{\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2}$

R_j^2 adalah koefisien determinasi antar variabel prediktor. Jika $VIF \leq 10$, maka tidak terdapat multikolinieritas pada model regresi. Sebaliknya, jika nilai $VIF \geq 10$, maka terdapat multikolinieritas [1]. Matriks korelasi juga dapat digunakan sebagai indikator awal multikolinieritas. Nilai korelasi di atas 0,8 menunjukkan adanya multikolinieritas [3].

4. Mengidentifikasi pola autokorelasi galat menggunakan plot ACF dan PACF.

Analisis pola autokorelasi pada data runtun waktu dapat dilakukan melalui visualisasi plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Fungsi ACF merepresentasikan koefisien korelasi total antara observasi pada periode ke- i dengan observasi pada periode ke- i atau lag k . Sementara PACF mengukur korelasi murni antara kedua observasi tersebut setelah mengeliminasi pengaruh linier dari observasi pada lag perantara. Penentuan orde p dan q didasarkan pada pola plot ACF dan PACF [20] sebagaimana dijelaskan pada Tabel 2.

Tabel 2. Identifikasi pola autokorelasi berdasarkan plot ACF dan PACF.

Model	ACF	PACF
AR(p)	Menurun secara eksponensial atau sinusoidal	Cut off setelah lag ke- p
MA(q)	Cut off setelah lag ke- q	Menurun secara eksponensial atau sinusoidal
ARMA(p, q)	Menurun secara cepat setelah lag ($q-p$)	Menurun secara cepat setelah lag ($q-p$)

5. Melakukan koreksi autokorelasi menggunakan prosedur Prais-Winsten (PW).

Metode Prais-Winsten (PW) diperkenalkan Sigbert John Prais dan Christopher Blake Winsten tahun 1954 sebagai salah satu variasi metode FGLS untuk mengatasi masalah autokorelasi pada galat [3]. Secara spesifik, galat dalam model PW diasumsikan mengikuti pola *Autoregressive* orde satu atau AR(1) yang artinya galat pada periode saat ini (ε_i) dipengaruhi oleh galat pada satu periode sebelumnya (ε_{i-1}). Metode PW melibatkan pendugaan koefisien autokorelasi galat ($\hat{\rho}$). Nilai $\hat{\rho}$ tersebut kemudian digunakan untuk mentransformasi data, sehingga masalah autokorelasi dapat dihilangkan saat model regresi diaplikasikan [21]. Keunggulan utama prosedur PW dibandingkan CO terletak pada kemampuannya untuk mempertahankan observasi pertama melalui transformasi khusus, sehingga ukuran sampel tetap utuh.

Metode PW mengasumsikan galat model mengikuti proses AR(1) seperti pers. (7).

$$\varepsilon_i = \rho \varepsilon_{i-1} + u_i, \quad (7)$$

dengan

ρ : koefisien autokorelasi galat; $|\rho| < 1$,

u_i : galat acak; $u_i \sim IID(0, \sigma^2)$.

Keberadaan struktur AR(1) pada pers. (7) mengindikasikan pelanggaran asumsi nonautokorelasi. Untuk memperoleh penduga parameter yang efisien, dilakukan transformasi linier terhadap komponen galat agar memiliki sifat *white noise*. Proses transformasi ini

diawali dengan membentuk model regresi pada periode sebelumnya ($i - 1$) dengan mensubstitusikan *lag* waktu ke dalam pers. (1), diperoleh pers. (8).

$$y_{i-1} = \beta_0 + \beta_1 X_{i-1,1} + \cdots + \beta_p X_{i-1,p} + \varepsilon_{i-1}. \quad (8)$$

Selanjutnya, pers. (8) dikalikan dengan koefisien autokorelasi $\hat{\rho}$, lalu hasilnya dikurangkan dari pers. (1) untuk menghasilkan persamaan *generalized difference* untuk observasi ke- i (dengan $i = 2, 3, \dots, n$). Karena $\varepsilon_i - \hat{\rho}\varepsilon_{i-1} = u_i$, maka komponen galat telah memenuhi asumsi *white noise* (bebas dari autokorelasi). Persamaan hasil transformasi atau *generalized difference* untuk observasi ke-2 hingga ke- n ($i = 2, 3, \dots, n$) dapat disederhanakan penulisannya seperti pada pers. (9).

$$y_i^* = \beta_0^* + \beta_1 X_{i,1}^* + \cdots + \beta_p X_{i,p}^* + u_i, \quad (9)$$

dengan $y_i^* = y_i - \hat{\rho}y_{i-1}$; $X_{i,j}^* = X_{i,j} - \hat{\rho}X_{i-1,j}$; dan $\beta_0^* = \beta_0(1 - \hat{\rho})$.

Prosedur transformasi *generalized difference* pada pers. (9) mengakibatkan hilangnya observasi pertama ($i = 1$) karena tidak tersedianya data pada periode $i = 0$. Untuk mengatasi hal tersebut, metode PW mempertahankan observasi pertama dengan melakukan transformasi khusus guna menyamakan variansi galatnya dengan variansi galat *white noise* (u_i). Variansi dari galat ε_i dapat didefinisikan seperti pada pers. (10).

$$\text{Var}(\varepsilon_i) = \frac{\sigma_u^2}{1 - \rho^2}, \quad (10)$$

agar variansi pada observasi pertama $\text{Var}(\varepsilon_1)$ setara dengan $\text{Var}(u_i) = \sigma_u^2$, maka pers. (1) untuk $i = 1$ dikalikan dengan faktor pembobot $\sqrt{1 - \rho^2}$. Sehingga, transformasi PW untuk observasi pertama dituliskan pada pers. (11).

$$y_1^* = \beta_0^* + \beta_1 X_{1,1}^* + \cdots + \beta_p X_{1,p}^* + u_1, \quad (11)$$

dengan $y_1^* = \sqrt{1 - \rho^2}y_1$ dan $X_{1,j}^* = \sqrt{1 - \rho^2}X_{1,j}$.

Dengan demikian, seluruh prosedur transformasi PW, baik untuk observasi pertama maupun observasi selanjutnya dapat diringkas dalam notasi matriks. Struktur matriks transformasi G yang diperlukan untuk menduga parameter regresi dapat ditulis seperti pada pers. (12).

$$G = \begin{bmatrix} \sqrt{(1 - \rho^2)} & 0 & 0 & \cdots & 0 & 0 \\ -\hat{\rho} & 1 & 0 & \cdots & 0 & 0 \\ 0 & -\hat{\rho} & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & -\hat{\rho} & 1 \end{bmatrix}. \quad (12)$$

Berdasarkan penjelasan transformasi di atas, prosedur pendugaan parameter regresi menggunakan metode Prais-Winsten dapat ditulis sebagai berikut:

- a. Menduga nilai koefisien autokorelasi ($\hat{\rho}$) awal dengan meregresikan galat $\hat{\varepsilon}_i$ terhadap $\hat{\varepsilon}_{i-1}$ sesuai pers. (13), galat $\hat{\varepsilon}_i$ diperoleh dari hasil regresi OLS.

$$\hat{\rho} = \frac{\sum_{i=2}^n \hat{\varepsilon}_i \hat{\varepsilon}_{i-1}}{\sum_{i=2}^n \hat{\varepsilon}_{i-1}^2} = \frac{\sum_{i=2}^n \hat{\varepsilon}_i \hat{\varepsilon}_{i-1}}{\sum_{i=1}^{n-1} \hat{\varepsilon}_i^2}. \quad (13)$$

- b. Melakukan transformasi Prais-Winsten pada data hasil transformasi ln menggunakan nilai $\hat{\rho}$ awal sesuai pers. (14) and (15).

- Transformasi untuk data observasi pertama ($i = 1$) menggunakan pers. (14)

$$\begin{aligned} y_1^* &= y_1 \left(\sqrt{1 - \hat{\rho}^2} \right), \\ X_{1,j}^* &= X_{1,j} \left(\sqrt{1 - \hat{\rho}^2} \right). \end{aligned} \quad (14)$$

- Transformasi untuk observasi lainnya ($i = 2, 3, \dots, n$) menggunakan pers. (15)

$$\begin{aligned} y_i^* &= y_i - \hat{\rho} y_{i-1} \\ X_{i,j}^* &= X_{i,j} - \hat{\rho} X_{i-1,j}. \end{aligned} \quad (15)$$

- c. Melakukan iterasi hingga memperoleh nilai $\hat{\rho}$ konvergen dengan menggunakan kriteria konvergensi $|\hat{\rho}_{m+1} - \hat{\rho}_m| \leq 0,000001$.
 - d. Melakukan transformasi akhir terhadap data hasil transformasi ln menerapkan nilai $\hat{\rho}$ konvergen ke dalam pers. (14) and (15). Langkah ini menghasilkan $\tilde{X}_{i,j}^*$ dan y_i^* yang akan digunakan sebagai input untuk tahapan selanjutnya.
6. Melakukan pemodelan *Modified Jackknife Kibria-Lukman Regression* (MJKLR) pada data hasil transformasi PW.

a. *Kibria-Lukman Regression* (KLR)

Kibria dan Lukman pada tahun 2020 mengusulkan penduga parameter *Kibria-Lukman Regression* (KLR) yang bertujuan untuk menangani adanya multikolinieritas dengan cara menyeimbangkan bias dan variansi [22]. Secara konstruksi, KLR dibentuk dengan mengombinasikan karakteristik dari *Ridge Regression* (RR) dan *Liu Regression* (LR), yaitu menggunakan parameter bias k dengan $k > 0$ untuk mereduksi tingginya variansi akibat multikolinieritas. Penduga parameter KLR model kanonik dirumuskan seperti pers. (16).

$$\hat{\gamma}_{KL} = (\mathbf{\Lambda} + k\mathbf{I})^{-1}(\mathbf{\Lambda} - k\mathbf{I})\hat{\gamma}_{OLS}, \quad (16)$$

dengan

- $\hat{\gamma}_{KL}$: Vektor penduga parameter KLR dalam bentuk kanonik (ruang ortogonal),
 $\mathbf{\Lambda}$: matriks diagonal yang berisi nilai eigen dari $\mathbf{X}'\mathbf{X}$, dimana $\mathbf{\Lambda} = \mathbf{Z}'\mathbf{Z}$,
 $\mathbf{Z}$: matriks komponen kanonik terstandarisasi berukuran $n \times p$ yang kolom-kolomnya saling ortogonal, dimana $\mathbf{Z} = \mathbf{XP}$ (dengan $\mathbf{P}$ sebagai matriks vektor eigen),
 k : parameter bias, $k > 0$,
 $\mathbf{I}$: matriks identitas persegi berukuran $p \times p$,
 $\hat{\gamma}_{OLS}$: vektor penduga parameter OLS dalam bentuk kanonik (ruang ortogonal).
 Pers. (16) juga dapat direpresentasikan dalam bentuk alternatif seperti pers. (17).

$$\hat{\gamma}_{KL} = [\mathbf{I} - 2k(\mathbf{Z}'\mathbf{Z} + k\mathbf{I})^{-1}]\hat{\gamma}_{OLS}. \quad (17)$$

b. *Modified Jackknife Kibria-Lukman Regression* (MJKLR)

Meskipun penduga KLR mampu mengatasi masalah multikolinieritas, penduga ini masih memiliki bias yang relatif besar [23]. Oleh karena itu, prosedur *jackknife* yang pertama kali diperkenalkan Quenouille diterapkan pada metode KLR untuk mereduksi bias. Dengan menggunakan pendekatan *weighted pseudo-value* yang didefinisikan oleh Hinkley [24], penduga parameter *Jackknife Kibria-Lukman Regression* (JKLR) model kanonik dapat dirumuskan seperti pers. (18).

$$\hat{\gamma}_{JKL} = [\mathbf{I} - (2k(\mathbf{\Lambda} + k\mathbf{I})^{-1})^2]\hat{\gamma}_{OLS}. \quad (18)$$

Selanjutnya, mengacu pada pendekatan Duran & Akdeniz [25], pers. (18) dimodifikasi lebih lanjut untuk membentuk penduga *Modified Jackknife Kibria-Lukman Regression* [8]. Modifikasi ini dilakukan dengan mengganti $\hat{\gamma}_{OLS}$ menjadi $\hat{\gamma}_{KL}$ dengan tujuan meminimumkan *Mean Squared Error* (MSE) melalui reduksi bias secara optimal sembari mempertahankan variansi yang rendah. Penduga parameter MJKL dirumuskan seperti pada pers. (19).

$$\hat{\gamma}_{MJKL} = [\mathbf{I} - 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}]^2 [\mathbf{I} + 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}] \hat{\gamma}_{OLS}. \quad (19)$$

Pada tahap akhir, penduga parameter pada model kanonik tersebut $\hat{\gamma}_{MJKL}$ ditransformasikan kembali menjadi penduga parameter regresi awal $\hat{\beta}_{MJKL}$ melalui perkalian dengan matriks ortogonal $\mathbf{P}$, sebagaimana dinyatakan pada pers. (20).

$$\hat{\beta}_{MJKL} = \mathbf{P} \hat{\gamma}_{MJKL}. \quad (20)$$

Untuk mengevaluasi ketepatan penduga $\hat{\gamma}_{MJKL}$, perlu ditinjau sifat bias, variansi, dan matriks *Mean Squared Error* (MSEM). Berdasarkan nilai harapannya, MJKL merupakan penduga yang bias dengan vektor bias yang dirumuskan seperti pada pers. (21).

$$\text{Bias}(\hat{\gamma}_{MJKL}) = ([\mathbf{I} - 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}]^2 [\mathbf{I} + 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}] - \mathbf{I}) \gamma. \quad (21)$$

Selanjutnya, matriks variansi dari penduga $\hat{\gamma}_{MJKL}$ dapat dinyatakan melalui pers. (22).

$$\text{Var}(\hat{\gamma}_{MJKL}) = \sigma^2 [\mathbf{I} - (2k(\mathbf{\Lambda} + k\mathbf{I})^{-1})^2] \mathbf{\Lambda}^{-1} [\mathbf{I} - 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}]^2. \quad (22)$$

Kinerja keseluruhan dari penduga yang bias dievaluasi menggunakan MSEM, yang merupakan hasil penjumlahan dari variansi dan perkalian vektor biasnya (MSEM = Var + Bias $\times$ Bias'). Dengan demikian, matriks MSEM dari penduga MJKL didefinisikan pada pers. (23).

$$\begin{aligned} \text{MSEM}(\hat{\gamma}_{MJKL}) = & \sigma^2 [\mathbf{I} - (2k(\mathbf{\Lambda} + k\mathbf{I})^{-1})^2] \mathbf{\Lambda}^{-1} [\mathbf{I} - 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}]^2 + \\ & [[\mathbf{I} - 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}]^2 (\mathbf{I} + 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}) - \mathbf{I}] \gamma_{OLS} \gamma'_{OLS} \\ & [[\mathbf{I} - 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}]^2 (\mathbf{I} + 2k(\mathbf{\Lambda} + k\mathbf{I})^{-1}) - \mathbf{I}]'. \end{aligned} \quad (23)$$

Adapun langkah-langkah pemodelan MJKL adalah sebagai berikut:

- 1) Melakukan standardisasi pada data hasil transformasi PW dengan menggunakan pers. (24) sehingga diperoleh $\tilde{X}_{i,j}^{**}$ dan y_i^{**} .

$$X_{i,j}^* = \frac{1}{\sqrt{n-1}} \left(\frac{x_{i,j} - \bar{x}_j}{S_{X_j}} \right) \text{ dan } y_i^* = \frac{1}{\sqrt{n-1}} \left(\frac{y_i - \bar{y}}{S_y} \right), \quad (24)$$

dengan $S_{X_j} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_{i,j} - \bar{X}_j)^2}$ dan $S_{y^*} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2}$.

- 2) Menghitung nilai eigen dan vektor eigen dari matriks $\tilde{\mathbf{X}}^{**'} \tilde{\mathbf{X}}^{**}$, membentuk matriks $\mathbf{P}$ (matriks vektor eigen), dan membentuk $\mathbf{Z} = \tilde{\mathbf{X}}^{**'} \mathbf{P}$. Sehingga model regresi menjadi $\mathbf{y}^{**} = \mathbf{Z} \gamma + \varepsilon$. Menghitung nilai penduga $\hat{\gamma}_{OLS}^{**}$ dengan menggunakan pers. (25).

$$\hat{\gamma}_{OLS}^{**} = (\mathbf{Z}' \mathbf{Z})^{-1} \mathbf{Z}' \mathbf{y}^{**}. \quad (25)$$

- 4) Menentukan nilai optimal parameter bias (k) MJKL menggunakan pendekatan rata-rata harmonik (*harmonic mean*) berdasarkan metode Kibria & Lukman [7], sesuai dengan pers. (27).

$$\hat{k}_{HMN} = \frac{p\hat{\sigma}^2}{\sum_{j=1}^p \left(2\hat{\gamma}_{jOLS}^2 + \frac{\hat{\sigma}^2}{\lambda_j} \right)}, \quad (26)$$

dengan $\hat{\sigma}^2 = \left(\frac{(y - Z\hat{\gamma}_{OLS})'(y - Z\hat{\gamma}_{OLS})}{(n-p)} \right)$.

- 5) Menghitung nilai penduga parameter MJKLR bentuk kanonik ($\hat{\gamma}_{MJKL}$) dengan menggunakan pers. (27).

$$\hat{\gamma}_{MJKL}^{**} = [\mathbf{I} - (2k(\Lambda + k\mathbf{I})^{-1})^2][\mathbf{I} - 2k(\Lambda + k\mathbf{I})^{-1}]\hat{\gamma}_{OLS}^{**}. \quad (27)$$

- 6) Mengonversi penduga dari ruang ortogonal ($\hat{\gamma}_{MJKL}^{**}$) kembali ke ruang variabel asli terstandarisasi ($\hat{\beta}_{MJKL}^{**}$) dengan menggunakan pers. (28).

$$\hat{\beta}_{MJKL}^{**} = \mathbf{P}\hat{\gamma}_{MJKL}^{**}. \quad (28)$$

- 7) Melakukan transformasi balik (*unstandardisasi*) penduga parameter model ke parameter sebelum standarisasi menggunakan pers. (29).

$$\hat{\beta}_{j(MJKL)}^* = \left(\frac{S_{y^*}}{S_{\tilde{X}_j^*}} \right) \hat{\beta}_{j(MJKL)}^{**} \text{ dan } \hat{\beta}_{0(MJKL)}^* = \bar{y}^* - \sum_{j=1}^6 \hat{\beta}_{j(MJKL)}^* \bar{\tilde{X}}_j^*. \quad (29)$$

- 8) Melakukan transformasi balik penduga parameter dari poin (g) sesuai pers. (30) untuk Prais-Winsten dan pembentukan model MJKLR akhir.

$$\beta_0 = \frac{\beta_0^*}{(1 - \hat{\rho})}. \quad (30)$$

7. Melakukan pengujian signifikansi parameter secara simultan dengan menggunakan uji F sesuai pers. (31) dan pengujian secara parsial menggunakan uji t sesuai pers. (32).

$$F_{hitung} = \frac{\frac{JKR}{p}}{\frac{JKG}{n-p-1}} = \frac{KTR}{KTG}, \quad (31)$$

$$t_{hitung} = \frac{\hat{\beta}_j}{SE(\hat{\beta}_j)}. \quad (32)$$

8. Melakukan pemilihan model terbaik dengan membandingkan nilai MSE penduga, RMSE, dan *Adjusted R*².

a. *Mean Square Error Penduga*

Nilai MSE penduga digunakan untuk mengukur rata-rata kuadrat selisih antara penduga dan parameter sebenarnya. Suatu penduga dikatakan sebagai penduga yang baik apabila memiliki kombinasi variansi dan bias yang kecil [26]. Jika parameter yang diduga adalah γ dengan penduga $\hat{\gamma}$, maka MSE dalam bentuk skalar dapat dituliskan seperti pada pers. (33).

$$MSE(\hat{\gamma}) = \text{tr}(\text{Cov}(\hat{\gamma}) + \text{Bias}(\hat{\gamma})\text{Bias}(\hat{\gamma})'). \quad (33)$$

b. *Root Mean Square Error*

Root Mean Square Error (RMSE) merupakan salah satu ukuran ketepatan (akurasi) model regresi dalam memprediksi nilai variabel respon. Semakin kecil nilai RMSE, maka semakin baik kinerja model regresi dalam memprediksi nilai yang mendekati data sebenarnya. Namun, interpretasi besarnya RMSE juga perlu mempertimbangkan skala

data dari variabel respon agar dapat dinilai secara proporsional. Nilai RMSE dapat diperoleh melalui pers. (34) [27].

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (34)$$

c. *Adjusted R²*

Adjusted R² merupakan ukuran kebaikan model regresi yang telah disesuaikan dengan mempertimbangkan jumlah variabel prediktor dan jumlah sampel. *Adjusted R²* mengoreksi nilai *R²* dengan memperhitungkan rasio antara jumlah observasi dan jumlah parameter yang diestimasi. Dengan demikian, penambahan variabel yang tidak memberikan kontribusi berarti dapat menyebabkan nilai *adjusted R²* menurun. Nilai *adjusted R²* berkisar antara 0 hingga 1. Nilai yang semakin mendekati 1 mengindikasikan model semakin baik dalam menjelaskan keragaman variabel respon. *Adjusted R²* dapat dihitung menggunakan pers. (35) [28].

$$\text{Adjusted } R^2 = 1 - \frac{\frac{JKG}{n-p-1}}{\frac{JKT}{n-1}}, \quad (35)$$

dengan *JKG* merupakan jumlah kuadrat galat dan *JKT* adalah jumlah kuadrat total.

9. Melakukan interpretasi hasil pendugaan model MJCLR dengan koreksi autokorelasi PW pada data nilai tukar Rupiah.

3. Hasil dan Pembahasan

3.1. Statistik Deskriptif

Analisis statistika deskriptif dilakukan untuk mengetahui gambaran umum mengenai karakteristik distribusi data dari variabel-variabel yang digunakan dalam penelitian ini selama periode observasi tahun 2021 hingga 2024. Ringkasan statistik yang mencakup nilai minimum, maksimum, rata-rata, dan simpangan baku disajikan pada Tabel 3.

Tabel 3. Statistik deskriptif variabel penelitian.

Variabel	Minimum	Maksimum	Rata-Rata	Simpangan Baku
Nilai Tukar Rupiah terhadap USD (<i>y</i>)	14.084	16.421	15.096,56	673,43
Inflasi (<i>X₁</i>)	1,33	5,95	2,94	1,40
Jumlah Uang Beredar (<i>X₂</i>)	6.767.408	9.210.816	8.134.935	702.300,6
Suku Bunga (BI Rate) (<i>X₃</i>)	3,50	6,25	4,86	1,19
Total Ekspor (<i>X₄</i>)	15.255,40	27.928,70	21.866,06	2.758,048
Total Impor (<i>X₅</i>)	13.264,97	22.150,55	18.582,17	2.272,41
Harga Minyak Mentah Dunia (<i>X₆</i>)	55,04	115,60	82,47	12,30

Berdasarkan hasil analisis statistik deskriptif pada Tabel 3, rata-rata nilai tukar Rupiah terhadap USD tercatat sebesar Rp15.096,56 dengan simpangan baku 673,43. Hal ini menunjukkan bahwa nilai tukar Rupiah terhadap USD cukup berfluktuasi, dari nilai minimum sebesar Rp14.084 hingga nilai maksimum sebesar Rp16.421. Tingkat inflasi bergerak pada rentang 1,33% hingga 5,95% dengan nilai rata-rata sebesar 2,94%, sementara suku bunga acuan memiliki rata-rata 4,86% dengan rentang pergerakan antara 3,50% hingga 6,25%. Adapun jumlah uang beredar menunjukkan tren peningkatan dari titik terendah Rp6.767.408 miliar di awal

periode hingga mencapai titik tertinggi Rp9.210.816 miliar di akhir periode observasi. Pada aktivitas perdagangan luar negeri, rata-rata total ekspor tercatat sebesar \$21.866,06 juta, lebih tinggi dibandingkan rata-rata total impor yang sebesar \$18.582,17 juta. Selain itu, harga minyak mentah dunia berfluktuasi dari level terendah \$55,04 hingga tertinggi \$115,60 per barel, dengan rata-rata \$82,47 per barel.

3.2. Transformasi Logaritma

Penelitian ini menggunakan model regresi *lin-log*. Transformasi logaritma natural ($\ln$) diterapkan pada variabel yang memiliki satuan dan variansi besar seperti X_2 , X_4 , X_5 , dan X_6 , yang dinotasikan sebagai $\tilde{X}_j = \ln(X_j)$. Transformasi ini dilakukan karena variabel-variabel tersebut memiliki satuan yang relatif besar dan variansi yang tinggi. Transformasi logaritma natural bertujuan untuk menyetarakan skala data, menstabilkan variansi galat, dan untuk menghasilkan interpretasi ekonomi yang lebih relevan terhadap analisis ekonomi yang sering kali berfokus pada perubahan relatif. Sedangkan, variabel inflasi (X_1) dan suku bunga acuan (X_3) tidak ditransformasi karena telah dinyatakan dalam satuan persentase sehingga tidak memerlukan penyesuaian skala. Model akhir dirumuskan sebagai berikut:

$$y_i = \beta_0 + \beta_1 X_{i,1} + \beta_2 \tilde{X}_{i,2} + \beta_3 X_{i,3} + \beta_4 \tilde{X}_{i,4} + \beta_5 \tilde{X}_{i,5} + \beta_6 \tilde{X}_{i,6} + \varepsilon_i,$$

dengan $\tilde{X}_{i,j} = \ln(X_{i,j})$, untuk $i = 1, 2, \dots, 48$ dan $j = 2, 4, 5, 6$.

Penggunaan model *lin-log* memungkinkan koefisien regresi diinterpretasikan sebagai perubahan absolut variabel respon yang diakibatkan oleh perubahan persentase pada variabel prediktor.

3.3. Pengujian Asumsi Klasik Regresi Linier Berganda

Berdasarkan pendugaan parameter menggunakan metode OLS, diperoleh persamaan model regresi linier berganda sebagai berikut:

$$\hat{y}_i = -42.426,7711 + 8,2599X_{i,1} + 3.547,8510\tilde{X}_{i,2} + 247,1233X_{i,3} - 196,1633\tilde{X}_{i,4} + 120,9094\tilde{X}_{i,5} + 143,1796\tilde{X}_{i,6}.$$

Selanjutnya, dilakukan pengujian asumsi klasik regresi linier berganda terhadap model yang telah melalui proses transformasi logaritma. Pengujian asumsi klasik meliputi uji normalitas, homoskedastisitas, autokorelasi, dan multikolinieritas.

3.3.1. Uji Normalitas

Uji normalitas dilakukan untuk menguji apakah galat pada data berdistribusi normal. Uji normalitas dilakukan dengan menggunakan uji Shapiro-Wilk. Hasil uji normalitas pada data nilai tukar Rupiah terhadap USD tahun 2021-2024 dengan menggunakan uji Shapiro-Wilk berdasarkan **pers. (3)** dapat dilihat pada **Tabel 4** dengan hipotesis sebagai berikut:

H_0 : Galat nilai tukar Rupiah terhadap USD periode 2021-2024 berdistribusi normal

H_1 : Galat nilai tukar Rupiah terhadap USD periode 2021-2024 tidak berdistribusi normal.

Tabel 4. Uji normalitas.

Statistik Uji (W)	p - value	Keputusan
0,9740	0,3598	Terima H_0

Tabel 4 menunjukkan nilai $W_{hitung}(0,9740) > W_{(0,05;48)}(0,9470)$ dan p - value $(0,36) >$

0,05. Dengan demikian, terima H_0 yang artinya galat nilai tukar Rupiah terhadap USD periode 2021-2024 berdistribusi normal.

3.3.2. Uji Homoskedastisitas

Uji homoskedastisitas dilakukan dengan menggunakan uji Breusch-Pagan (BP). Hasil uji homoskedastisitas pada data nilai tukar Rupiah terhadap USD tahun 2021-2024 dengan uji BP berdasarkan pers. (4) dapat dilihat pada Tabel 5 dengan hipotesis sebagai berikut:

$H_0: \sigma_1^2 = \dots = \sigma_{48}^2$ (variansi galat data nilai tukar rupiah terhadap USD bersifat konstan atau homoskedastisitas)

$H_1: \text{Ada } \sigma_i^2 \neq \sigma_{i^*}^2, i \neq i^* = 1, 2, \dots, 48$ (variansi galat data nilai tukar rupiah terhadap USD tidak konstan atau terjadi heteroskedastisitas)

Tabel 5. Uji homoskedastisitas.

Statistik Uji (BP)	$p - value$	Keputusan
10,7485	0,0965	Terima H_0

Berdasarkan Tabel 5, diketahui nilai $BP(10,7485) < \chi_{(0,05;6)}^2(12,5916)$ dan $p-value(0,10) > 0,05$. Dengan demikian, terima H_0 yang berarti variansi galat pada data bersifat konstan atau homoskedastisitas.

3.3.3. Uji Autokorelasi

Uji autokorelasi bertujuan untuk menguji apakah dalam model regresi linier terdapat korelasi antara galat pada suatu periode dengan periode sebelumnya. Pengujian autokorelasi galat dilakukan menggunakan uji Durbin-Watson (DW) berdasarkan pers. (5) dengan hipotesis sebagai berikut:

$H_0: \rho = 0$ (Galat nilai tukar Rupiah terhadap USD tahun 2021-2024 tidak mengalami autokorelasi)

$H_1: \rho \neq 0$ (Galat nilai tukar Rupiah terhadap USD 2021-2024 mengalami autokorelasi)

Tabel 6. Uji autokorelasi.

Statistik Uji (DW)	$p - value$	Keputusan
0,7244	$4,2 \times 10^{-9}$	Tolak H_0

Berdasarkan hasil pengujian autokorelasi galat yang disajikan pada Tabel 6, diperoleh nilai statistik uji $DW(0,7244) < d_L(1,2709)$ dan $p - value(4,2 \times 10^{-9}) < 0,05$. Dengan demikian, H_0 ditolak yang berarti galat pada data mengalami autokorelasi positif. Atas dasar pelanggaran asumsi ini, analisis selanjutnya akan menerapkan transformasi Prais-Winsten untuk memperoleh model yang bebas dari masalah autokorelasi.

3.3.4. Uji Multikolinieritas

Uji multikolinieritas dilakukan untuk menguji apakah terjadi korelasi yang kuat antar variabel prediktor. Hasil uji multikolinieritas pada data nilai tukar Rupiah terhadap USD tahun 2021-2024 dengan nilai VIF berdasarkan pers. (6) dapat dilihat pada Tabel 7.


Berdasarkan Tabel 7, variabel jumlah uang beredar (X_2) dan suku bunga acuan (X_3) memiliki nilai $VIF > 10$ yang mengindikasikan adanya masalah multikolinieritas.

Tabel 7. Uji multikolinieritas.

Variabel	VIF	Keterangan
X_1	2,1940	Tidak terjadi multikolinieritas
$\tilde{X}_2$	19,6212	Terjadi multikolinieritas
X_3	15,8132	Terjadi multikolinieritas
$\tilde{X}_4$	6,1738	Tidak terjadi multikolinieritas
$\tilde{X}_5$	4,4326	Tidak terjadi multikolinieritas
$\tilde{X}_6$	2,7834	Tidak terjadi multikolinieritas

3.4. Identifikasi Pola Autokorelasi

Visualisasi plot ACF dan PACF pada bertujuan untuk mengidentifikasi apakah galat mengikuti proses AR(1), yang merupakan syarat optimalisasi metode Prais-Winsten.

**Gambar 2.** Plot ACF dan PACF galat data hasil transformasi logaritma natural.

Berdasarkan **Gambar 2**, terlihat bahwa plot ACF menunjukkan adanya pola penurunan yang melambat membentuk sinusoidal, sementara plot PACF mengalami *cut-off* setelah lag pertama. Hal ini mengindikasikan bahwa galat pada data nilai tukar Rupiah terhadap Dolar Amerika Serikat tahun 2021-2024 mengikuti proses AR(1), sesuai dengan kriteria identifikasi pada **Tabel 1**. Teridentifikasinya struktur AR(1) ini menjadi dasar untuk menggunakan koreksi autokorelasi Prais-Winsten dalam penelitian ini

3.5. Transformasi Prais-Winsten

Penanganan masalah autokorelasi pada model dilakukan menggunakan metode transformasi Prais-Winsten (PW). Proses ini diawali dengan menduga koefisien autokorelasi ($\hat{\rho}$) awal dari galat model OLS menggunakan **pers. (13)**, yang kemudian dihitung secara iteratif menggunakan **pers. (14)** dan **(15)** hingga mencapai kriteria konvergensi yang ditentukan berdasarkan selisih absolut antariterasi yaitu $|\hat{\rho}_{m+1} - \hat{\rho}_m| \leq 0,000001$. Berdasarkan hasil komputasi, proses iterasi mencapai konvergensi pada iterasi keenam dengan nilai koefisien akhir $\hat{\rho} = 0,663768$. Nilai $\hat{\rho}$ selanjutnya digunakan untuk mentransformasi seluruh observasi pada variabel respon maupun prediktor menggunakan **pers. (14)** dan **(15)**, sehingga menghasilkan sekumpulan variabel baru (y^* dan $\tilde{X}^*$).

Pengujian asumsi dilakukan kembali terhadap model OLS data hasil transformasi PW. Hasil pengujian asumsi menunjukkan bahwa masalah autokorelasi telah berhasil diatasi menggunakan koreksi autokorelasi PW. Hal ini dibuktikan dengan nilai statistik Durbin-Watson sebe-

sar 1,7249 dan $p - value = 0,11 > \alpha = 0,05$, sehingga H_0 diterima dan disimpulkan bahwa tidak terdapat autokorelasi. Meskipun demikian, pengujian multikolinieritas menunjukkan bahwa masalah multikolinieritas masih ada. Hal ini ditunjukkan oleh nilai VIF yang masih lebih besar dari 10 pada beberapa variabel prediktor, yakni $\tilde{X}_2$ (VIF = 72, 11), $\tilde{X}_4$ (VIF = 92, 93), $\tilde{X}_5$ (VIF = 53, 14), dan $\tilde{X}_6$ (VIF = 12, 78). Keberadaan multikolinieritas yang tinggi ini menyebabkan variansi penduga parameter tetap besar. Oleh karena itu, guna menghasilkan model dengan penduga yang efisien, analisis dilanjutkan dengan menerapkan metode *Modified Jackknife Kibria-Lukman Regression*.

3.6. Pemodelan Modified Jackknife Kibria-Lukman Regression

3.6.1. Standardisasi Menggunakan Metode Pemusatan dan Penskalaan

Pemodelan MJKLR diawali dengan standardisasi (pemusatan dan penskalaan) menggunakan pers. (24) pada variabel yang telah dikoreksi PW (y^* dan $\tilde{X}^*$). Standardisasi dilakukan agar penambahan parameter bias pada tahapan MJKLR dapat mengendalikan tingkat penyusutan koefisien regresi secara proporsional. Dengan skala data yang telah setara, pendugaan parameter tidak lagi terpengaruh oleh perbedaan besaran nilai nominal dan satuan antarvariabel prediktor.

3.6.2. Membentuk Matriks Ortogonal pada Variabel Prediktor

Tahap selanjutnya adalah melakukan dekomposisi spektral pada matriks $\tilde{X}^{**'} \tilde{X}^{**}$ untuk memperoleh nilai eigen (λ) dan matriks ortogonal P . Langkah ini bertujuan mengubah ruang prediktor menjadi sistem koordinat ortogonal untuk mengevaluasi multikolinieritas dan menjadi dasar penentuan parameter bias pada metode MJKLR. Hasil dekomposisi menghasilkan enam nilai eigen, yaitu $\lambda_1 = 4,0524$; $\lambda_2 = 1,0306$; $\lambda_3 = 0,8101$; $\lambda_4 = 0,0865$; $\lambda_5 = 0,0135$; $\lambda_6 = 0,0069$. Nilai eigen yang mendekati nol (λ_5 dan λ_6) secara matematis mengonfirmasi adanya multikolinieritas yang memicu besarnya variansi pada penduga OLS. Vektor-vektor eigen kemudian disusun untuk membentuk matriks ortogonal P .

$$P = \begin{bmatrix} -0,0468 & 0,9145 & 0,3991 & -0,0367 & -0,0116 & 0,0253 \\ -0,4929 & -0,0692 & 0,0445 & -0,0526 & -0,7174 & 0,4825 \\ -0,2251 & 0,3821 & -0,8912 & 0,0823 & 0,0358 & -0,0308 \\ -0,4908 & -0,0577 & 0,0902 & -0,3244 & -0,1565 & -0,7861 \\ -0,4885 & -0,0730 & 0,0627 & -0,4541 & 0,6345 & 0,3786 \\ -0,4739 & -0,0648 & 0,1798 & 0,8233 & 0,2384 & -0,0659 \end{bmatrix}.$$

Matriks P selanjutnya digunakan untuk membentuk matriks komponen kanonik melalui transformasi $Z = \tilde{X}^{**'} P$. Matriks Z ini berisi variabel-variabel baru yang sepenuhnya saling ortogonal (korelasi antarkolom bernilai nol) dan memenuhi sifat $Z'Z = \Lambda$.

3.6.3. Pendugaan Parameter Ordinary Least Squares Bentuk Kanonik

Langkah selanjutnya adalah menghitung penduga parameter OLS dalam bentuk kanonik (γ_{OLS}^{**}). Pendugaan OLS pada ruang ortogonal diperlukan dalam proses penentuan parameter bias (k). Hasil perhitungan menggunakan pers. (25) disajikan pada Tabel 8.

Koefisien regresi bentuk kanonik γ_{OLS}^{**} yang diperoleh pada Tabel 8, selanjutnya digunakan dalam penentuan nilai parameter bias (k) MJKLR.

Tabel 8. Nilai penduga parameter OLS dalam bentuk kanonik.

Parameter	Nilai Penduga Parameter
$\gamma_{1(OLS)}^{**}$	-0,4696
$\gamma_{2(OLS)}^{**}$	0,0342
$\gamma_{3(OLS)}^{**}$	-0,1494
$\gamma_{4(OLS)}^{**}$	-0,0095
$\gamma_{5(OLS)}^{**}$	-0,0733
$\gamma_{6(OLS)}^{**}$	0,4220

3.6.4. Pendugaan Parameter Bias Modified Jackknife Kibria-Lukman Regression

Penentuan parameter bias k merupakan tahap penting dalam penerapan metode MJKLR, karena nilai k berperan dalam mengendalikan tingkat penyusutan terhadap penduga OLS. Proses ini diawali dengan menduga variansi galat ($\hat{\sigma}^2$) dari model OLS bentuk kanonik. Hasil pendugaan nilai $\hat{\sigma}^2$ menggunakan pers. (26) adalah sebagai berikut:

$$\hat{\sigma}^2 = \left(\frac{(\mathbf{y}^{**} - \mathbf{Z}\hat{\gamma}_{OLS}^{**})'(\mathbf{y}^{**} - \mathbf{Z}\hat{\gamma}_{OLS}^{**})}{(n - p)} \right) = 0,0020.$$

Setelah nilai $\hat{\sigma}^2$ diperoleh, parameter bias k dihitung menggunakan pendekatan rata-rata harmonik (*harmonic mean*) sebagaimana dirumuskan dalam pers. (26). Hasil perhitungan nilai k adalah sebagai berikut:

$$k = \frac{(6)(0,0020)}{\left(2(-0,4696)^2 + \frac{0,0020}{4,0524}\right) + \dots + \left(2(0,4220)^2 + \frac{0,0020}{0,0069}\right)} = 0,009183.$$

Nilai parameter bias $k = 0,009183$ yang diperoleh dari perhitungan tersebut selanjutnya digunakan dalam pemodelan MJKLR pada data nilai tukar Rupiah terhadap USD.

3.6.5. Pendugaan Parameter Modified Jackknife Kibria-Lukman Regression

Pendugaan parameter MJKLR dilakukan secara bertahap. Tahap pertama adalah menduga parameter dalam bentuk kanonik (γ_{MJKLR}^{**}) menggunakan pers. (27). Hasil pendugaan parameter dalam bentuk kanonik tersebut disajikan pada Tabel 9. Berdasarkan Tabel 9, diperoleh enam nilai penduga parameter kanonik yang selanjutnya digunakan sebagai dasar untuk memperoleh koefisien regresi pada bentuk terstandardisasi.

Tabel 9. Nilai penduga parameter MJKLR bentuk kanonik.

Parameter	Nilai Penduga Parameter
$\gamma_{1(MJKL)}^{**}$	-0,4675
$\gamma_{2(MJKL)}^{**}$	0,0335
$\gamma_{3(MJKL)}^{**}$	-0,1460
$\gamma_{4(MJKL)}^{**}$	-0,0074
$\gamma_{5(MJKL)}^{**}$	-0,0048
$\gamma_{6(MJKL)}^{**}$	0,0186

Tahap berikutnya adalah mengonversi parameter kanonik menjadi parameter regresi terstandardisasi ($\hat{\beta}_{MJKLR}^{**}$) melalui perkalian dengan matriks ortogonal $\mathbf{P}$ sesuai pers. (28). Hasil konversi tersebut disajikan pada Tabel 10.

Berdasarkan Tabel 10, diperoleh koefisien regresi dalam bentuk terstandardisasi yang merepresentasikan pengaruh masing-masing peubah penjelas setelah transformasi ke ruang

Tabel 10. Hasil konversi penduga parameter MJCLR terstandarisasi.

Parameter	Nilai Penduga Parameter
$\beta_{1(MJKL)}^{**}$	-0,0049
$\beta_{2(MJKL)}^{**}$	0,2344
$\beta_{3(MJKL)}^{**}$	0,2469
$\beta_{4(MJKL)}^{**}$	0,2029
$\beta_{5(MJKL)}^{**}$	0,2242
$\beta_{6(MJKL)}^{**}$	0,1847

ortogonal. Karena parameter pada **Tabel 10** masih berada dalam skala terstandarisasi, tahap selanjutnya adalah melakukan proses *unstandardisasi* untuk mengembalikan koefisien regresi ke skala data hasil transformasi Prais–Winsten menggunakan rasio simpangan baku sebagaimana dinyatakan pada **pers. (29)**. Hasil proses *unstandardisasi* disajikan pada **Tabel 11**.

Tabel 11. Hasil unstandardisasi penduga parameter MJCLR.

Parameter	Nilai Penduga Parameter
$\beta_{0(MJKL)}^*$	26,6909
$\beta_{1(MJKL)}^*$	-7,3876
$\beta_{2(MJKL)}^*$	214,0636
$\beta_{3(MJKL)}^*$	467,4864
$\beta_{4(MJKL)}^*$	305,4800
$\beta_{5(MJKL)}^*$	339,1261
$\beta_{6(MJKL)}^*$	681,9226

Berdasarkan **Tabel 11**, diperoleh koefisien regresi akhir MJCLR yang terdiri atas satu intersep dan enam koefisien regresi untuk masing-masing variabel prediktor. Dengan demikian, model regresi pada skala transformasi PW dapat dituliskan sebagai berikut:

$$\hat{y}_i^* = 26,6909 - 7,3876X_1 + 214,0636\tilde{X}_2 + 467,4864X_3 + 305,4800\tilde{X}_4 + 339,1261\tilde{X}_5 + 681,9226\tilde{X}_6.$$

Model di atas merepresentasikan hubungan regresi pada data hasil transformasi PW. Karena parameter intersep diperoleh melalui proses pemusatan pada data transformasi PW, nilai intersep yang dihasilkan masih berada pada skala transformasi PW. Oleh karena itu, untuk memperoleh parameter intersep pada skala model asli, perlu dilakukan transformasi balik menggunakan **pers. (30)** dengan $\hat{\rho} = 0,663768$ diperoleh:

$$\hat{\beta}_{0(MJKL)} = \frac{26,6909}{1 - 0,663768} = 79,3822.$$

Koefisien regresi lainnya ($j = 1, 2, \dots, 6$) tidak mengalami perubahan ($\hat{\beta}_{j(MJKL)} = \hat{\beta}_{j(MJKL)}^*$), sehingga model akhir MJCLR dengan koreksi autokorelasi PW dituliskan sebagai berikut:

$$\hat{y}_i = 79,3822 - 7,3876X_1 + 214,0636\tilde{X}_2 + 467,4864X_3 + 305,4800\tilde{X}_4 + 339,1261\tilde{X}_5 + 681,9226\tilde{X}_6$$

Model tersebut merupakan model penduga akhir yang lebih stabil dan efisien dibandingkan estimasi OLS standar setelah melakukan penanganan pelanggaran asumsi nonautokorelasi dengan menggunakan koreksi autokorelasi PW dan pelanggaran asumsi nonmultikolinieritas dengan menggunakan MJCLR.

3.7. Pengujian Signifikansi Parameter

3.7.1. Pengujian Signifikansi Simultan

Pengujian parameter model MJKLR secara simultan dilakukan untuk menguji hipotesis berikut:

$H_0: \beta_1 = \beta_2 = \dots = \beta_6 = 0$ (semua variabel prediktor dalam model tidak berpengaruh signifikan terhadap nilai tukar Rupiah terhadap USD),

$H_1: \text{Ada } \beta_j \neq 0 \text{ dengan } j = 1, 2, \dots, 6$ (Ada variabel prediktor dalam model yang berpengaruh signifikan terhadap nilai tukar Rupiah terhadap USD).

Berdasarkan perhitungan menggunakan pers. (31), diperoleh nilai $F_{hitung}(21, 6888) > F_{(0,05;6;41)}(2, 3298)$ dan $p - value (2, 73 \times 10^{-11}) < 0, 05$. Dengan demikian, H_0 ditolak dan disimpulkan bahwa pada taraf signifikansi 5%, seluruh variabel prediktor secara bersama-sama (simultan) memberikan pengaruh yang signifikan terhadap pergerakan nilai tukar Rupiah terhadap USD periode 2021–2024.

3.7.2. Pengujian Signifikansi Parsial Satu-Satu

Pengujian parameter model MJKLR secara parsial dilakukan untuk menguji hipotesis berikut:

$H_0: \beta_j = 0, j = 1, 2, 3, 4, 5, 6$ (variabel prediktor ke- j tidak berpengaruh signifikan terhadap variabel nilai tukar Rupiah terhadap USD tahun 2021-2024),

$H_1: \beta_j \neq 0, j = 1, 2, 3, 4, 5, 6$ (variabel prediktor ke- j berpengaruh signifikan terhadap variabel nilai tukar Rupiah terhadap USD tahun 2021-2024).

Pengujian ini dilakukan dengan membagi nilai setiap penduga parameter MJKLR yang diperoleh dengan nilai galat bakunya masing-masing sesuai dengan pers. (32). Hasil pengujian signifikansi parameter secara parsial menggunakan uji t dapat dilihat pada Tabel 12.

Tabel 12. Hasil uji signifikansi parsial satu-satu.

Variabel	Galat Baku	Statistik Uji t_{hitung}	$p - value$	Keputusan
X_1	66,7556	-0,1107	$9,1242 \times 10^{-1}$	Terima H_0
$\tilde{X}_2$	23,0708	9,2785	$1,2604 \times 10^{-11}$	Tolak H_0
X_3	90,9844	5,1381	$7,1853 \times 10^{-6}$	Tolak H_0
$\tilde{X}_4$	67,6426	4,5161	$5,2374 \times 10^{-5}$	Tolak H_0
$\tilde{X}_5$	88,4696	3,8332	$4,2707 \times 10^{-4}$	Tolak H_0
$\tilde{X}_6$	367,4748	1,8557	$7,0695 \times 10^{-2}$	Terima H_0

Berdasarkan hasil uji parsial Tabel 12, diketahui bahwa variabel $\tilde{X}_2, X_3, \tilde{X}_4$, dan $\tilde{X}_5$ memiliki nilai $|t_{hitung}| > t_{(0,05/2;41)} = 2,0195$ serta $p - value < 0, 05$. Dengan demikian, diputuskan untuk menolak H_0 dan disimpulkan bahwa variabel jumlah uang beredar ($\tilde{X}_2$), suku bunga acuan (X_3), total ekspor ($\tilde{X}_4$), dan total impor ($\tilde{X}_5$) masing-masing berpengaruh signifikan terhadap nilai tukar Rupiah terhadap USD tahun 2021-2024. Sedangkan variabel inflasi (X_1) dan harga minyak mentah dunia (X_6) tidak berpengaruh signifikan terhadap nilai tukar Rupiah terhadap USD.

3.8. Pemilihan Model Terbaik

Pemilihan model terbaik dilakukan dengan mengevaluasi tingkat akurasi dan efisiensi model. Nilai MSE penduga dihitung menggunakan pers. (33), RMSE dihitung menggunakan pers. (34), dan $Adjusted R^2$ dihitung menggunakan pers. (35). Hasil penerapan ketiga persamaan tersebut pada data nilai tukar Rupiah disajikan pada Tabel 13.

Tabel 13. Perbandingan ukuran kebaikan model.

Model	MSE Penduga	RMSE	Adjusted R^2
OLS-PW	0,4758	326,2288	72,53
KLR-PW	0,2681	326,5354	72,47
MJKLR-PW	0,1877	326,1730	72,54

Berdasarkan **Tabel 13**, model MJKLR-PW menunjukkan nilai *Adjusted R^2* lebih besar dibandingkan dengan OLS-PW dan KLR-PW, yaitu berturut-turut sebesar 72,54; 72,53; dan 72,47. Pada nilai MSE Penduga, model MJKLR-PW lebih kecil dibandingkan model OLS-PW and KLR-PW dengan masing-masing nilai 0,1877; 0,4758; dan 0,2681. Sementara itu, nilai RMSE pada model MJKLR-PW tercatat sebesar 326,1730, lebih rendah dibandingkan nilai 326,2288 pada model OLS-PW dan 326,5354 pada model KLR-PW. Dengan demikian, dapat disimpulkan bahwa model MJKLR-PW memiliki kinerja yang lebih unggul daripada model OLS-PW dan KLR-PW dalam menangani masalah autokorelasi dan multikolinieritas pada data.

3.9. Interpretasi Model

Berdasarkan hasil uji MJKLR-PW, interpretasi koefisien model dibagi menjadi dua, yakni perubahan absolut untuk variabel satuan asli (X_1 dan X_2) dan elastisitas persentase untuk variabel logaritma natural (X_2 , X_4 , X_5 , dan X_6). Secara parsial, variabel inflasi (X_1) dan harga minyak mentah dunia (X_6) tidak memberikan pengaruh yang signifikan terhadap depresiasi Rupiah. Hal ini terjadi karena tingkat inflasi di Indonesia selama periode 2021-2024 relatif sangat stabil. Tekanan inflasi yang sesekali muncul mampu direspon secara cepat oleh Bank Indonesia melalui penyesuaian suku bunga acuan. Akibatnya, dampak langsung dari inflasi terhadap depresiasi Rupiah berhasil diredam secara efektif. Di sisi lain, ketidaksignifikanan pengaruh harga minyak mentah dunia terhadap nilai tukar Rupiah dikarenakan beban tingginya biaya impor minyak masih mampu dikompensasi dengan baik oleh surplus pendapatan dari ekspor komoditas unggulan nasional, serta adanya intervensi stabilisasi melalui subsidi APBN.

Jumlah uang beredar (X_2) berpengaruh positif signifikan di mana setiap kenaikan 1% jumlah uang beredar akan melemahkan Rupiah sebesar Rp2,140. Hal ini sejalan dengan hasil penelitian Permatasari [14] yang menyatakan bahwa kelebihan jumlah uang beredar dapat memicu ketidakseimbangan neraca pembayaran, yang kemudian mendorong permintaan terhadap mata uang asing, sehingga mengakibatkan Rupiah terdepresiasi. Suku bunga acuan (X_3) juga berpengaruh positif yang artinya suku bunga melemahkan Rupiah sebesar Rp467,4864 per kenaikan 1 satuan suku bunga acuan, yang mengonfirmasi adanya anomali pelarian modal karena pasar menganggap kenaikan suku bunga sebagai sinyal kepanikan domestik terhadap kebijakan *The Fed* [15]. Pada sektor perdagangan, hasil penelitian menunjukkan bahwa variabel total ekspor (X_4) dan total impor (X_5) secara parsial berpengaruh positif dan signifikan terhadap pelemahan nilai tukar Rupiah. Kenaikan 1% pada ekspor dan impor masing-masing menyebabkan nilai tukar Rupiah meningkat sebesar Rp3,0548 dan Rp3,3913. Secara teoretis, tingginya impor dapat melemahkan Rupiah akibat melonjaknya permintaan USD untuk pembayaran barang luar negeri. Di sisi lain, peningkatan ekspor juga turut menekan Rupiah. Hal ini dipicu oleh masalah struktural di mana eksportir kerap menahan Devisa Hasil Ekspor (DHE) di luar negeri, serta tingginya ketergantungan industri domestik pada bahan baku impor. Akibatnya, kinerja ekspor yang tinggi selalu diiringi oleh lonjakan kebutuhan impor dan permintaan USD, yang pada akhirnya memicu depresiasi Rupiah.

4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *Modified Jackknife Kibria-Lukman Regression* (MJKLR) yang dikombinasikan dengan koreksi autokorelasi Prais-Winsten (PW) terbukti efektif dalam menangani pelanggaran asumsi multikolinieritas dan autokorelasi pada pemodelan nilai tukar Rupiah terhadap Dolar Amerika Serikat periode 2021-2024. Model penduga yang diperoleh, yaitu $\hat{y}_i = 79,3822 - 7,3876X_1 + 214,0636\tilde{X}_2 + 467,4864X_3 + 305,4800\tilde{X}_4 + 339,1261\tilde{X}_5 + 681,9226\tilde{X}_6$. Model MJKLR-PW secara empiris menunjukkan kinerja yang lebih optimal, stabil, dan efisien dibandingkan metode OLS-PW maupun KLR-PW. Keunggulan ini dibuktikan dengan perolehan nilai *Mean Squared Error* (MSE) terkecil yaitu sebesar 0,1877 dan *Root Mean Squared Error* (RMSE) sebesar Rp326,1730, serta nilai *Adjusted R²* sebesar 72,54% yang merepresentasikan kemampuan model dalam menjelaskan keragaman data. Hasil pemodelan menunjukkan bahwa terdapat empat variabel prediktor yang berpengaruh signifikan terhadap variabel respon pada taraf signifikansi 5%, yaitu variabel jumlah uang beredar (X_2), suku bunga acuan (X_3), total ekspor (X_4), dan total impor (X_5).

Penelitian ini memiliki beberapa keterbatasan yang dapat menjadi arah pengembangan bagi penelitian selanjutnya. Asumsi pemodelan yang digunakan masih bersifat linier parametrik dan terbatas pada enam variabel makroekonomi, sehingga penelitian selanjutnya disarankan untuk mengeksplorasi regresi nonlinier atau nonparametrik serta menambahkan variabel prediktor baru. Selain itu, karena model MJKLR-PW yang digunakan belum kebal (*robust*) terhadap pencilan akibat guncangan eksternal, maka implementasi *Robust* MJKLR menggunakan estimator GM, MM, GMM, dan lainnya sangat direkomendasikan. Dari sisi evaluasi, komparasi kinerja MJKLR dalam studi ini hanya berfokus pada OLS dan KLR. Oleh sebab itu, penelitian berikutnya perlu memperluas perbandingan menggunakan metode regularisasi lain seperti *Elastic Net* atau *LASSO Regression* dengan tetap mempertahankan prosedur penanganan autokorelasi.

Kontribusi Penulis. Chrisadna Patricia Kabangnga: Konseptualisasi, metodologi, perangkat lunak, kurasi data, analisis formal, penulisan—persiapan draf asli, visualisasi. A. Muthiah Nur Angriany: Metodologi, kurasi data, supervisi, validasi, penulisan—tinjauan dan penyuntingan. Raupong: Konseptualisasi, metodologi, supervisi, validasi, penulisan—tinjauan dan penyuntingan. Semua penulis mendiskusikan hasil dan berkontribusi pada manuskrip akhir.

Ucapan Terima Kasih. Para penulis mengucapkan terima kasih kepada semua pihak yang telah berkontribusi dalam penelitian ini dan dalam penyusunan manuskrip. Kami sangat menghargai editor dan reviewer atas masukan serta dukungannya dalam menyempurnakan karya ini.

Pembiayaan. Penelitian ini tidak menerima pendanaan eksternal.

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Ketersediaan Data. Tidak tersedia.

Referensi

- [1] G. Mardiatmoko, "Pentingnya uji asumsi klasik pada analisis regresi linier berganda (studi kasus penyusunan persamaan allometrik kenari muda [*canarium indicum* l.])," *BAREKENG: Jurnal Ilmu Matematika*

- dan Terapan, vol. 14, no. 3, pp. 333–342, September 2020, doi:[10.30598/barekengvol14iss3pp333-342](https://doi.org/10.30598/barekengvol14iss3pp333-342).
- [2] N. U. Martaningtyas, E. A. Septiyaningrum, and Z. Maulana, “Dampak pelanggaran asumsi klasik terhadap kesalahan inferensi dalam analisis ekonometrika,” *Synergy: Jurnal Ilmiah Multidisiplin*, vol. 1, no. 04, pp. 255–265, Dec. 2023.
 - [3] D. N. Gujarati and D. C. Porter, *Basic Econometrics*, 5th ed. New York: McGraw-Hill/Irwin, 2009.
 - [4] W. H. Greene, *Econometric Analysis*, 7th ed. New York: Pearson Education, 2012.
 - [5] A. D. A. S. Budi, L. Septiana, and B. E. P. Mahendra, “Memahami asumsi klasik dalam analisis statistik: Sebuah kajian mendalam tentang multikolinearitas, heterokedastisitas, dan autokorelasi dalam penelitian,” *Jurnal Multidisiplin West Science*, vol. 03, no. 01, pp. 1–11, 2024, doi:[10.58812/jmws.v3i01.878](https://doi.org/10.58812/jmws.v3i01.878).
 - [6] J. M. Wooldridge, *Introductory Econometrics: A Modern Approach*, 5th ed. Mason, Ohio: South-Western Cengage Learning, 2013.
 - [7] B. M. G. Kibria and A. F. Lukman, “A new ridge-type estimator for the linear regression model: Simulations and applications,” *Scientifica*, vol. 2020, no. 1, p. 9758378, 2020, doi:[10.1155/2020/9758378](https://doi.org/10.1155/2020/9758378).
 - [8] F. I. Ugwuowo, H. E. Oranye, and K. C. Arum, “On the jackknife kibria-lukman estimator for the linear regression model,” *Communications in Statistics - Simulation and Computation*, vol. 52, no. 12, pp. 6116–6128, 2023, doi:[10.1080/03610918.2021.2007401](https://doi.org/10.1080/03610918.2021.2007401).
 - [9] R. E. Park and B. M. Mitchell, “Estimating the autocorrelated error model with trended data,” *Journal of Econometrics*, vol. 13, no. 2, pp. 185–201, 1980, doi:[10.1016/0304-4076\(80\)90014-7](https://doi.org/10.1016/0304-4076(80)90014-7).
 - [10] A. I. Parapa, “Pemodelan ridge regression pada data time series dengan koreksi autokorelasi prais winsten (studi kasus: Nilai tukar rupiah terhadap dolar amerika serikat),” Skripsi, Universitas Hasanuddin, Makassar, 2025, fakultas Matematika dan Ilmu Pengetahuan Alam, Program Studi Statistika.
 - [11] M. A. Zubair and M. O. Adenomon, “Comparison of estimators efficiency for linear regressions with joint presence of autocorrelation and multicollinearity,” *Science World Journal*, vol. 16, no. 2, pp. 103–109, 2021.
 - [12] A. Putri, R. Santoso, and S. Sugito, “Analisis regresi nonparametrik kernel menggunakan metode jackknife sampel terhapus-1 dan sampel terhapus-2 (studi kasus: Pemodelan tingkat inflasi terhadap nilai tukar rupiah di indonesia periode 2004-2016),” *Jurnal Gaussian*, vol. 6, no. 1, pp. 1–10, 2017.
 - [13] R. Cahyadi, R. A. Yunanda, R. S. Putra, S. I. Jaya, S. P. Bayu, and N. Rizki, “Analisis faktor-faktor melemahnya kurs rupiah pada era digital,” *Jurnal Ilmu Ekonomi Manajemen dan Akuntansi MH Thamrin*, vol. 5, no. 2, pp. 412–427, 2024, doi:[10.37012/ileka.v5i2.2341](https://doi.org/10.37012/ileka.v5i2.2341).
 - [14] D. Permatasari, “Analisis pengaruh suku bunga, jumlah uang beredar, inflasi, neraca transaksi berjalan, cadangan devisa, indeks produksi terhadap kurs valuta asing periode 2010-2024,” Skripsi, Universitas Islam Indonesia, Yogyakarta, 2025.
 - [15] Y. R. Hakim and T. S. Aji, “Factors affecting the exchange rate of the indonesian rupiah against the united states dollar: January 2013 - december 2023,” *Formosa Journal of Multidisciplinary Research*, vol. 4, no. 5, pp. 2043–2062, 2025, doi:[10.55927/fjmr.v4i5.175](https://doi.org/10.55927/fjmr.v4i5.175).
 - [16] A. Prahutama and R. Rahmawati, “Analisis regresi linier berganda pada data survey untuk pemodelan total pengeluaran di jawa tengah, indonesia,” *Jurnal Gaussian*, vol. 13, no. 2, pp. 394–404, 2024, doi:[10.14710/j.gauss.13.2.394-404](https://doi.org/10.14710/j.gauss.13.2.394-404).
 - [17] D. C. Montgomery, E. A. Peck, and G. G. Vining, *Introduction to Linear Regression Analysis*, 5th ed. Hoboken, New Jersey: John Wiley & Sons, Inc., 2012.
 - [18] P. Mishra, C. M. Pandey, U. Singh, A. Gupta, C. Sahu, and A. Keshri, “Descriptive statistics and normality tests for statistical data,” *Annals of Cardiac Anaesthesia*, vol. 22, no. 1, pp. 67–72, 2019, doi:[10.4103/aca.ACA_157_18](https://doi.org/10.4103/aca.ACA_157_18).
 - [19] S. S. SHAPIRO and M. B. WILK, “An analysis of variance test for normality (complete samples),” *Biometrika*, vol. 52, no. 3-4, pp. 591–611, 12 1965, doi:[10.1093/biomet/52.3-4.591](https://doi.org/10.1093/biomet/52.3-4.591).
 - [20] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, 2nd ed. New York: Pearson Education, 2006.
 - [21] C. Bottomley, M. Ooko, A. Gasparrini, and R. Keogh, “In praise of prais-winsten: An evaluation of methods used to account for autocorrelation in interrupted time series,” *Statistics in Medicine*, vol. 42, no. 8, pp. 1277–1288, 2023, doi:[10.1002/sim.9669](https://doi.org/10.1002/sim.9669).
 - [22] W. F. Syafni, “Kibria-lukman estimator untuk menangani multikolinearitas dalam analisis regresi logistik pada dataset audio akord mayor dan minor,” Skripsi, Universitas Gadjah Mada, Yogyakarta, 2024, fakultas Matematika dan Ilmu Pengetahuan Alam, Program Studi Statistika.
 - [23] H. E. Oranye *et al.*, “Selection of a new biasing parameter for the jackknife kibria-lukman estimator for the negative binomial regression model,” *NIPES-Journal of Science and Technology Research*, vol. 7, no. 1, pp. 257–266, 2025, doi:[10.37933/nipes/7.1.2025.SI30](https://doi.org/10.37933/nipes/7.1.2025.SI30).
 - [24] A. E. Hoerl and R. W. Kennard, “Ridge regression by automated selection of k ,” *Technometrics*, vol. 19,

- no. 1, pp. 35–40, 1977, doi:[10.1080/00401706.1977.10489550](https://doi.org/10.1080/00401706.1977.10489550).
- [25] E. Ä. Duran and F. Akdeniz, “Efficiency of the modified jackknifed liu-type estimator,” *Statistical Papers*, vol. 53, no. 2, pp. 265–280, 2012, doi:[10.1007/s00362-010-0334-5](https://doi.org/10.1007/s00362-010-0334-5).
- [26] G. Casella and R. L. Berger, *Statistical Inference*, 2nd ed. Pacific Grove, California: Brooks/Cole Thomson Learning, 2002.
- [27] A. Biriukov, S. Rasp, L. Grundner, and V. Eyring, “Root-mean-square error (rmse) or mean absolute error (mae): when to use them or not,” *Geoscientific Model Development*, vol. 15, no. 14, pp. 5481–5488, 2022, doi:[10.5194/gmd-15-5481-2022](https://doi.org/10.5194/gmd-15-5481-2022).
- [28] M. H. Kutner, C. J. Nachtsheim, J. Neter, and W. Li, *Applied Linear Statistical Models*, 5th ed. Boston, Massachusetts: McGraw-Hill/Irwin, 2005.