

PENERAPAN PYTHON UNTUK VISUALISASI DAN PERAMALAN PADA NILAI TUKAR USD/IDR MENGGUNAKAN METODE SARIMA

Ayung Perdana, Anis Zubair

Sistem Informasi, Universitas Merdeka Malang
Jl. Terusan Dieng No.57-59 Malang, Indonesia
anis.zubair@unmer.ac.id

ABSTRAK

Nilai tukar mata uang memiliki peran penting dalam perekonomian suatu negara, karena menghubungkan aktivitas ekonomi domestik dan internasional serta memengaruhi neraca perdagangan, inflasi, dan kestabilan ekonomi. Tren depresiasi Rupiah terhadap Dollar US selama 2016–2022 menimbulkan kekhawatiran terhadap dampaknya terhadap daya saing dan kestabilan ekonomi nasional. Oleh karena itu, diperlukan model peramalan yang akurat dan efisien untuk memprediksi nilai tukar. Penelitian ini bertujuan mengembangkan dan memvalidasi model SARIMA menggunakan Python untuk meramalkan nilai tukar US Dollar terhadap Rupiah periode 2020–Mei 2025, dengan prediksi satu tahun ke depan. Metode SARIMA dipilih karena kemampuannya menangani pola musiman yang relevan pada data nilai tukar. Parameter model diidentifikasi melalui analisis ACF, PACF, dan `auto_arima`, menghasilkan model terbaik SARIMA (0,1,2) (0,1,1)[52] dengan nilai AIC dan BIC terendah. Evaluasi model menggunakan metrik MAE, MSE, RMSE, dan MAPE menunjukkan performa sangat baik dengan MAPE 2,61% pada data uji. Pemodelan menggunakan seluruh data historis menghasilkan prediksi mingguan yang konsisten dengan tren historis. Penggunaan Python dan pustaka seperti `pandas`, `matplotlib`, dan `statsmodels` mempermudah proses analisis dan visualisasi data secara efisien. Hasil ini memberikan gambaran peramalan nilai tukar yang akurat dan dapat mendukung pengambilan keputusan strategis dalam menghadapi ketidakpastian ekonomi global.

Kata kunci : Nilai Tukar, Deret Waktu, Peramalan, SARIMA, Python, MAPE.

1. PENDAHULUAN

Nilai tukar mata uang sangat berperan dalam menentukan arah perekonomian suatu negara karena menghubungkan aktivitas ekonomi domestik dan internasional, serta memengaruhi neraca perdagangan, inflasi, ketenagakerjaan, dan kestabilan ekonomi. Depresiasi nilai tukar dapat meningkatkan daya saing ekspor, namun tren depresiasi Rupiah terhadap Dollar US selama 2016–2022 berpotensi berdampak negatif [1].

Studi sebelumnya menggunakan model ARIMA dan SARIMA dengan pendekatan CRISP-DM untuk meramalkan nilai tukar, dengan SARIMA terbukti lebih akurat [2]. Namun, keterbatasan dari model konvensional tersebut mendorong adanya pengembangan integrasi metode peramalan deret waktu dengan teknologi Python yang menawarkan otomatisasi parameter melalui pustaka `Statsmodels`, sehingga meningkatkan efisiensi dan akurasi peramalan. SARIMA yang mampu menangani pola musiman sangat relevan untuk data nilai tukar yang dipengaruhi faktor musiman [3]. Python menyediakan ekosistem pustaka seperti `Pandas`, `Matplotlib`, dan `Statsmodels` yang mendukung analisis dan visualisasi data secara komprehensif, Python dinilai efektif untuk eksplorasi dan pemodelan data karena fleksibilitas teknis dan kemampuannya dalam visualisasi yang terintegrasi [4].

Penelitian ini fokus pada data nilai tukar US Dollar terhadap Rupiah periode 2020–Mei 2025, bertujuan mengembangkan dan memvalidasi model SARIMA menggunakan Python untuk meramalkan

tren nilai tukar selama satu tahun ke depan. Pendekatan ini diharapkan membantu pengambilan keputusan strategis dalam menghadapi ketidakpastian ekonomi global.

Rumusan masalah penelitian mencakup proses identifikasi parameter dan evaluasi model SARIMA menggunakan Python serta hasil peramalan nilai tukar untuk satu tahun mendatang. Tujuan penelitian adalah mengembangkan model SARIMA yang valid dan menghasilkan prediksi nilai tukar US Dollar terhadap Rupiah menggunakan Python.

Kemudian manfaat pada penelitian ini meliputi penyediaan gambaran peramalan nilai tukar yang akurat, identifikasi pola musiman dan tren historis, serta dukungan dalam perencanaan strategi perdagangan, investasi, dan pengelolaan risiko nilai tukar.

Sedangkan batasan dari penelitian ini meliputi penggunaan data historis dari situs <https://www.wsj.com> periode 2020–Mei 2025, tidak mempertimbangkan faktor eksternal seperti inflasi atau kebijakan moneter, penggunaan metode SARIMA, dan pemanfaatan Google Colab sebagai platform analisis.

2. TINJAUAN PUSTAKA

Dalam penelitian sebelumnya [2], menjelaskan penerapan model ARIMA dan SARIMA dengan pendekatan Cross-Industry Standard Process for Data Mining (CRISP-DM) untuk meramalkan nilai tukar Rupiah terhadap Dollar US. Hasil penelitian menunjukkan bahwa SARIMA dengan parameter

musiman mingguan ($s = 7$) memberikan hasil prediksi yang lebih akurat dibandingkan ARIMA, dengan nilai MAPE sebesar 3,82% dibandingkan 3,95% dari ARIMA, menunjukkan keunggulan SARIMA dalam menangani pola musiman pada data ekonomi.

Namun, pendekatan konvensional tersebut masih menghadapi keterbatasan dalam proses optimasi parameter dan efisiensi pemodelan, terutama saat dihadapkan pada volume data yang besar. Oleh karena itu, penelitian ini menawarkan Integrasi SARIMA dengan teknologi Python yang mampu mendukung otomatisasi parameter sehingga dapat meningkatkan efisiensi proses peramalan sekaligus mengurangi potensi kesalahan dalam penentuan parameter model.

2.1. Nilai Tukar

Nilai tukar adalah nilai mata uang suatu negara yang dinyatakan dalam mata uang negara lain, yang mencerminkan perbandingan harga antara dua mata uang [5]. Secara teori, nilai tukar dapat dijelaskan melalui dua pendekatan utama, yaitu teori fundamental dan teori pasar.

- Teori Fundamental, menyatakan bahwa nilai tukar dipengaruhi variabel makroekonomi seperti inflasi, suku bunga, dan cadangan devisa. Inflasi berpengaruh negatif, sedangkan suku bunga dan cadangan devisa berpengaruh positif [6].
- Teori Pasar, menjelaskan bahwa nilai tukar terbentuk dari keseimbangan penawaran dan permintaan mata uang di pasar valuta asing, tanpa campur tangan pemerintah [7].

2.2. Peramalan (Forecasting)

Peramalan adalah proses memprediksi nilai atau tren masa depan berdasarkan data historis dan pola yang teridentifikasi, bertujuan memberikan estimasi pergerakan nilai tukar untuk mendukung pengambilan keputusan ekonomi dan kebijakan moneter [8]. Metode peramalan terbagi menjadi dua, yaitu kualitatif dan kuantitatif [9].

- Metode Kualitatif, merupakan metode yang menggunakan pendapat ahli tanpa data historis
- Metode Kuantitatif, merupakan metode yang dilakukan dengan mengolah data historis secara statistik sehingga lebih objektif.

Kemudian untuk peramalan kuantitatif sendiri juga terbagi menjadi dua pendekatan yang dapat dilakukan, yaitu deret waktu (time series) dan kausal (sebab-akibat) [10].

Selain itu menurut [11], peramalan dapat dikategorikan berdasarkan jangka waktu:

- Jangka Pendek, peramalan dengan kejadian dalam periode waktu beberapa hari hingga bulan berikutnya.
- Jangka Menengah, peramalan dengan menggunakan data selama periode satu hingga dua tahun ke depan.
- Jangka Panjang, peramalan dengan kejadian lebih dari dua tahun kedepan.

2.3. Data Deret Waktu (Time Series)

Data deret waktu adalah kumpulan data yang diobservasi secara berurutan pada interval waktu yang sama, seperti harian, mingguan, bulanan, atau tahunan. Namun dalam hal ini penting untuk memperhatikan tipe pola data dalam memilih metode runtun waktu yang tepat. Jenis pola data tersebut meliputi:

- Pola H (Horizontal), yaitu kondisi dimana data bergerak naik turun di sekitar rata-rata yang stabil.
- Pola S (Musiman), yaitu kondisi dimana data dipengaruhi oleh faktor musiman.
- Pola C (Siklis), yaitu kondisi data dipengaruhi oleh siklus bisnis jangka panjang
- Pola T (Trend), yaitu kondisi dimana data menunjukkan pergerakan naik atau turun secara sekuler dalam jangka waktu lama

Selain itu, kestasioneran data merupakan aspek penting dalam analisis deret waktu. Banyak metode peramalan, seperti SARIMA, mensyaratkan data stasioner agar hasil prediksi menjadi akurat [2]

2.4. Stasioneritas Data

Data dikatakan stasioner apabila rata-rata dan variansnya tidak berubah sepanjang waktu, sehingga nilai data bergerak di sekitar rata-rata konstan tanpa tren naik atau turun yang tajam [12]. Pengecekan stasioneritas dapat dilakukan dengan mengamati grafik data dan melakukan uji Augmented Dickey Fuller (ADF) menggunakan persamaan berikut:

$$\Delta Y_t = \alpha_0 + \gamma Y_{t-1} + \sum_{i=1}^k \beta_i \Delta Y_{t-i} + e_t \quad (1)$$

Data dinyatakan stasioner jika grafik menunjukkan rata-rata dan varians yang tetap, serta nilai p-value uji ADF lebih kecil dari taraf signifikansi [13].

Jika data tidak stasioner, teknik differencing digunakan untuk mengubah data yang tidak stasioner menjadi data yang stasioner dengan menghitung selisih antara nilai saat ini dan nilai sebelumnya, sesuai persamaan:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2)$$

2.5. Autocorrelation Function (ACF)

ACF berguna untuk mengukur korelasi antara nilai data saat ini dengan nilai data pada periode sebelumnya (lag), dan grafik ACF menunjukkan hubungan data pada berbagai lag [8]. ACF juga dapat membantu dalam identifikasi komponen moving average (MA) dan musiman pada model SARIMA serta dapat digunakan untuk mendeteksi kestasioneran data. Secara matematis, ACF pada lag k , dilambangkan dengan ρ_k , dirumuskan sebagai:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (3)$$

Dimana γ_k adalah kovarians pada lag k dan γ_0 adalah varians data pada lag 0.

2.6. Partial Autocorrelation Function (PACF)

PACF digunakan untuk mengukur korelasi parsial antara nilai data saat ini dengan nilai data pada lag tertentu setelah menghilangkan pengaruh lag-lag di antaranya. Fungsi ini penting untuk mengidentifikasi

komponen autoregressive (AR) dalam model SARIMA [8]. PACF pada lag k , dilambangkan ϕ_{kk} merupakan koefisien regresi dari X_{t+k} terhadap $(X_{t+k-1}, X_{t+k-2}, \dots, X_{t+1})$.

2.7. Metode Seasonal Autoregressive Integrated Moving Average (SARIMA)

Metode SARIMA merupakan pengembangan dari model ARIMA yang dirancang khusus untuk menangani data deret waktu musiman, yang terdiri dari komponen non-musiman dan musiman [14]. Parameter umum SARIMA adalah $(p, d, q) (P, D, Q)[s]$, di mana p, d, q adalah orde dari komponen non-musiman, P, D, Q adalah orde komponen musiman, dan s adalah periode musiman. Persamaan umum dari model SARIMA adalah:

$$\Phi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Y_t = \Theta_Q(B^s)\theta_q(B)\varepsilon_t \quad (4)$$

Model komponen dasar dari SARIMA diambil dari model ARIMA (p, d, q) yang mempunyai tiga komponen utama [15].

a. Autoregressive (AR atau p)

Nilai p atau orde AR menunjukkan bahwa nilai saat ini Y_t bergantung pada nilai-nilai masa lalu sebanyak p periode, dengan persamaan sebagai berikut:

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon \quad (5)$$

b. Integrated (I atau d)

Nilai d atau orde I merupakan sebuah tingkat diferensiasi yang dibutuhkan. Hal ini dapat menggambarkan banyaknya langkah diferensiasi yang dibutuhkan untuk membuat deret waktu menjadi stasioner.

c. Moving Average (MA atau q)

Nilai q atau orde MA menunjukkan hubungan antara observasi yang diamati dengan serangkaian nilai kesalahan (error) berurutan dari waktu t sampai $t-q$. Model MA dengan orde q secara umum dinyatakan sebagai berikut:

$$Y_t = \delta + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (6)$$

2.8. Metrik Kesalahan Perhitungan Error

Metrik kesalahan dalam peramalan digunakan untuk mengukur selisih antara nilai aktual dan nilai hasil peramalan. Oleh karena itu, diperlukan metrik evaluasi seperti MAE, MSE, RMSE dan MAPE yang memberikan ukuran akurasi peramalan yang lebih objektif.

a. Mean Absolute Error (MAE)

MAE merupakan rata-rata nilai absolut dari gap antara nilai konkret dan peramalan, memberikan gambaran kesalahan rata-rata tanpa memperhatikan arah kesalahan. MAE dirumuskan sebagai berikut :

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (7)$$

b. Mean Square Error (MSE)

MSE dihitung dengan mengakumulasi kuadrat dari seluruh kesalahan peramalan pada tiap periode dan membaginya dengan jumlah periode. Sehingga memberikan penalti lebih besar

terhadap kesalahan yang besar. Rumus MSE adalah sebagai berikut:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (8)$$

Kelebihan MSE adalah perhitungannya yang sederhana. Namun, kelemahannya adalah MSE tidak memberikan informasi mengenai arah kesalahan (bias) dalam peramalan karena hanya mengukur besarnya kesalahan tanpa membedakan apakah hasil peramalan terlalu rendah atau terlalu tinggi.

c. Root Mean Square Error (RMSE)

RMSE adalah akar kuadrat dari MSE, yang mengembalikan satuan error ke skala asli data sehingga lebih mudah diinterpretasikan. RMSE digunakan untuk mengukur jarak antara nilai peramalan dan nilai aktual, dimana semakin kecil nilai RMSE menunjukkan akurasi model yang semakin baik [16]. Rumus RMSE adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (9)$$

d. Mean Absolute Percentage Error (MAPE)

MAPE merupakan ukuran kesalahan relatif yang digunakan untuk menghitung keakuratan peramalan dengan menunjukkan persentase tingkat kesalahan pada hasil peramalan selama periode tertentu [17]. Sehingga mudah diinterpretasikan, rumus MAPE adalah sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{Y_t - \hat{Y}_t}{Y_t} \quad (10)$$

Berikut adalah rujukan nilai kisaran MAPE dari sebuah model peramalan [18]:

Tabel 1. Range Nilai MAPE

Range MAPE	Arti Nilai
< 10%	Kinerja model sangat baik
10 - 20%	Kinerja model baik
20 - 50%	Kinerja model layak
> 50%	Kinerja model buruk

Terdapat dua metrik informasi yang umum digunakan untuk mengevaluasi dan memilih model terbaik yaitu :

a. Akaike Information Criterion (AIC)

AIC adalah ukuran kualitas relatif dari sebuah model statistik untuk data yang diberikan. Tujuannya adalah memilih model yang memberikan keseimbangan terbaik antara akurasi dan kesederhanaan, sehingga menghindari overfitting.

b. Bayesian Information Criterion (BIC)

BIC mirip dengan AIC, tetapi memberikan penalti yang lebih berat terhadap jumlah parameter, sehingga cenderung memilih model yang lebih sederhana, terutama pada dataset yang berukuran kecil atau sedang.

Model dengan hasil nilai AIC dan BIC terendah dipilih menjadi model optimal yang digunakan dalam

peramalan. Jika nilai AIC dan BIC yang dihasilkan lebih kecil artinya menunjukkan kecocokan model yang lebih optimal terhadap data tanpa overfitting [19].

2.2. Python

Python adalah bahasa pemrograman tingkat tinggi yang mendukung berbagai paradigma dan memiliki aturan penulisan ketat untuk menghindari kesalahan eksekusi [20]. Dalam analisis deret waktu, Python banyak digunakan untuk peramalan dan visualisasi data berkat pustaka lengkap seperti pandas, matplotlib, dan statsmodels. Studi menunjukkan Python efektif untuk pemodelan SARIMA, mulai dari preprocessing hingga peramalan [21].

2.3. Visualisasi Data

Visualisasi data adalah proses penyajian data dalam bentuk grafik atau gambar yang memudahkan pemahaman pola, tren, dan hubungan antar variabel dalam dataset. Dalam analisis deret waktu, visualisasi penting untuk mengenali pola musiman, tren, dan anomali sebelum pemodelan seperti SARIMA [22]. Python menyediakan berbagai pustaka visualisasi yang mendukung analisis data deret waktu, antara lain:

- Matplotlib: pustaka populer untuk membuat grafik 2D berdasarkan data array.
- Seaborn: dikembangkan dari Matplotlib, memungkinkan pembuatan visualisasi yang variatif dan optimal untuk bekerja dengan Pandas DataFrame.
- Plotly: pustaka berbasis JavaScript yang mampu menampilkan berbagai jenis visualisasi, termasuk grafik statistik, data keuangan, peta geografis, dan visualisasi 3D.


2.4. Google Colab

Google Colab (Google Colaboratory) adalah platform cloud yang disediakan oleh Google untuk menulis dan menjalankan kode Python langsung melalui browser tanpa perlu instalasi atau konfigurasi tambahan [23]. Platform ini memanfaatkan infrastruktur cloud Google dan menyediakan lingkungan pengembangan yang kuat dengan akses gratis ke GPU dan TPU, sehingga cocok untuk keperluan data science, machine learning, dan analisis data.

3. METODE PENELITIAN

3.1. Desain Penelitian

Bagian ini menjelaskan langkah-langkah dan prosedur yang digunakan dalam penelitian ini, yang terdiri dari beberapa tahapan.



Gambar 1. Alur Penelitian

Pada Gambar 1. penelitian ini memiliki tahapan penelitian sebagai berikut:

- Mulai, penelitian dimulai dengan penentuan masalah dan tujuan, yaitu melakukan peramalan nilai tukar menggunakan SARIMA berbasis Python.
- Pengumpulan Data, data historis nilai tukar US Dollar terhadap Rupiah periode 2020 hingga Mei 2025 dikumpulkan dari sumber terbuka dalam format Excel (.xls) dengan frekuensi harian pada hari kerja (business day).
- Persiapan Data, data dibersihkan dari nilai hilang menggunakan fungsi `isnull()` dan `fillna()`, serta dilakukan transformasi waktu menjadi format datetime dan pengaturan indeks deret waktu menggunakan pustaka Python seperti pandas dan numpy.
- Visualisasi Data, data divisualisasikan menggunakan Matplotlib, Seaborn, dan Plotly untuk memahami pola tren, musiman, dan fluktuasi nilai tukar.
- Uji Stasioneritas, pengujian stasioneritas dilakukan dengan uji ADF. Jika data tidak stasioner, dilakukan differencing untuk menghilangkan tren atau musiman.
- Identifikasi Parameter SARIMA, parameter SARIMA ditentukan melalui analisis plot ACF dan PACF, kemudian disempurnakan dengan pustaka pmdarima yang mengotomatisasi pemilihan model terbaik berdasarkan nilai AIC dan BIC.
- Peramalan (Forecasting), model SARIMA yang telah dibangun digunakan untuk meramalkan nilai tukar US Dollar terhadap Rupiah selama satu tahun ke depan.

- h. Evaluasi Model, evaluasi dilakukan menggunakan metrik MAE, MSE, RMSE, dan MAPE untuk menilai akurasi peramalan. Semakin kecil nilai metrik tersebut, terutama MAPE, semakin baik kinerja model.
- i. Interpretasi dan Visualisasi Hasil, hasil peramalan divisualisasikan dan dianalisis untuk memberikan insight yang berguna dalam pengambilan keputusan ekonomi atau keuangan.

3.2. Lokasi Penelitian

Penelitian ini bersifat kuantitatif dengan menggunakan data sekunder yang diperoleh secara daring (online) dari situs resmi The Wall Street Journal. Pemilihan situs The Wall Street Journal didasarkan pada kredibilitasnya sebagai media ekonomi dan keuangan internasional yang konsisten menyediakan data real-time, akurat, dan terverifikasi terkait nilai tukar dan pasar global.

3.3. Populasi dan Sampel

Populasi dalam penelitian ini adalah seluruh data historis nilai tukar US Dollar terhadap Rupiah yang tersedia di situs <https://www.wsj.com>. Sampel penelitian terdiri dari data historis nilai tukar harian periode 1 Januari 2020 hingga 31 Mei 2025. Pemilihan periode lebih dari lima tahun ini didasarkan pada pertimbangan bahwa rentang waktu tersebut cukup untuk menangkap pola tren jangka panjang dan variasi musiman tahunan, sesuai dengan studi sebelumnya yang menyatakan bahwa periode lima tahun memadai untuk analisis nilai tukar menggunakan metode SARIMA [2].

3.4. Teknik Analisa Data

Penelitian ini menggunakan teknik analisis kuantitatif dengan metode SARIMA yang diimplementasikan menggunakan bahasa pemrograman Python. Peramalan dilakukan untuk jangka pendek, yaitu meramalkan nilai tukar selama satu tahun ke depan berdasarkan data historis lima tahun lima bulan sebelumnya. Seluruh proses analisis, mulai dari pengolahan data, pembangunan model, hingga visualisasi hasil, dilakukan menggunakan platform Google Colab yang mendukung integrasi pustaka Python secara fleksibel dan efisien. Proses pemodelan SARIMA mengikuti tahapan sistematis untuk menghasilkan prediksi yang akurat dan dapat diandalkan.

3.5. Persiapan Data

- a. Penanganan Data Hilang, identifikasi nilai hilang dilakukan menggunakan fungsi *isnull()* untuk mengetahui keberadaan dan jumlah data yang hilang pada setiap kolom. Jika ditemukan nilai hilang, akan diisi menggunakan teknik pengisian dengan nilai rata-rata *fillna()*.
- b. Pengaturan Format Waktu, data diubah ke format *datetime* menggunakan fungsi *pd.to_datetime()* dan diatur indeksnya sebagai

deret waktu dengan fungsi *set_index()*. Langkah ini memastikan data tersusun secara kronologis untuk mendukung analisis deret waktu.

- c. Resampling Data, data harian berdasarkan hari kerja (business day) diubah menjadi data mingguan dengan fungsi *resample()* pada pustaka *pandas* menggunakan rata-rata mingguan (mean), untuk mengurangi noise dan menangkap pola yang lebih relevan dalam peramalan jangka pendek.
- d. Visualisasi Data Awal, visualisasi awal dilakukan menggunakan pustaka *Matplotlib*, *Seaborn*, dan *Plotly* untuk memahami pola tren, musiman, dan karakteristik data melalui grafik *seasonal decomposition*, grafik garis, dan histogram frekuensi.

3.6. Pengujian Stasioneritas

- a. Implementasi Uji ADF, pengujian ini dilakukan menggunakan fungsi *adfuller()* dari library *statsmodels.tsa.stattools* untuk menguji stasioneritas data.
- b. Evaluasi Hasil Uji, data dinyatakan stasioner jika nilai *p-value* < 0,05 dan statistik uji lebih kecil dari nilai kritis; jika tidak, data dianggap tidak stasioner dan perlu dilakukan transformasi atau differencing.

3.7. Identifikasi Parameter SARIMA

- a. Analisis ACF dan PACF, plot ACF digunakan untuk mengidentifikasi parameter MA (q, dan Q), sedangkan plot PACF untuk parameter AR (p, dan P). Parameter differencing (d, dan D) ditentukan berdasarkan jumlah differencing yang dibutuhkan agar data stasioner, dan periode musiman (s) diidentifikasi dari pola musiman data.
- b. Pencarian Grid Otomatis, setelah estimasi awal parameter, pustaka *pmdarima* dengan fungsi *auto_arma()* digunakan untuk mencari kombinasi parameter terbaik berdasarkan kriteria AIC dan BIC secara otomatis.

3.8. Peramalan dan Validasi

- a. Pembagian Data, Data historis dibagi menjadi 80% data latih untuk membangun model dan 20% data uji untuk evaluasi performa model.
- b. Model Fitting, model SARIMA dibangun menggunakan data latih dan diuji pada data uji. Setelah performa optimal tercapai, pemodelan ulang dilakukan dengan menggunakan 100% data historis untuk peramalan satu tahun ke depan.
- c. Peramalan, peramalan dilakukan menggunakan fungsi seperti *forecast()* pada pustaka *Python* untuk mengestimasi nilai tukar di masa depan.
- d. Evaluasi Model, model dievaluasi menggunakan metrik MAE, MSE, RMSE, dan MAPE untuk mengukur akurasi prediksi terhadap data uji.

- e. Visualisasi Hasil, hasil peramalan dan data aktual divisualisasikan menggunakan Matplotlib dengan grafik yang menampilkan kedua kurva untuk memudahkan interpretasi performa model.

4. HASIL DAN PEMBAHASAN

4.1. Persiapan Data

Dataset yang digunakan dalam penelitian ini terdiri dari 1413 data runtun waktu nilai tukar US Dollar terhadap Rupiah yang merepresentasikan hari kerja (business day) dari 1 Januari 2020 - 31 Mei 2025. Data ini diperoleh dalam format Excel dan dimuat ke dalam DataFrame untuk analisis lebih lanjut.

Date	Open	High	Low	Close
05/30/25	16300	16386	16264	16369
05/29/25	16293	16362	16260	16300
05/28/25	16285	16326	16266	16293
05/27/25	16257	16303	16225	16285
05/26/25	16246	16278	16148	16257
...	...	...	...	...
2020-07-01T00:00	13940	13940	13875	13875
2020-06-01T00:00	13925	13970	13925	13940
2020-03-01T00:00	13889	13935	13882	13925
2020-02-01T00:00	13883	13906	13873	13889
2020-01-01T00:00	13883	13883	13883	13883

Gambar 2. Preview Data Historis nilai tukar US Dollar terhadap Rupiah

4.2. Penanganan Data Hilang

Berdasarkan pemeriksaan menggunakan fungsi `isnull()` dari pustaka `pandas`, tidak ditemukan nilai hilang pada dataset. Namun, jika nilai hilang ditemukan, penanganannya dilakukan dengan metode pengisian nilai sebelumnya (`forward fill`) menggunakan fungsi `fillna(method='ffill')` untuk menjaga kontinuitas data dan kualitas model SARIMA.

4.3. Pengaturan Format Waktu

Kolom Date dikonversi ke format datetime menggunakan fungsi `pd.to_datetime()`, kemudian dijadikan indeks dengan `set_index()` agar data tersusun secara kronologis, memudahkan proses resampling, visualisasi, dan pemodelan.

4.4. Resampling Data Harian menjadi Mingguan


Data harian berdasarkan hari kerja diubah menjadi data mingguan menggunakan fungsi `resample("W-FRI")` dengan perhitungan rata-rata mingguan (`mean()`). Transformasi ini bertujuan mengurangi noise harian dan memperkuat pola musiman yang relevan untuk peramalan jangka pendek.

4.5. Visualisasi Data Awal

Visualisasi eksploratif dilakukan untuk mengidentifikasi pola tren dan musiman pada data historis nilai tukar USD/IDR sebelum pemodelan peramalan. Kemudian hasil dari visualisasi eksploratif meliputi :



Gambar 3. Grafik Garis USD/IDR – Resampled Mingguan



Gambar 4. Grafik Seasonal Decomposition

Pada Gambar 3, dan 4 diatas, dapat dilihat bahwa pada grafik garis menunjukkan pergerakan nilai tukar dari waktu ke waktu, memperlihatkan tren mingguan yang penting untuk mengamati tren jangka panjang, fluktuasi musiman, serta kenaikan atau penurunan tajam dalam periode tertentu. Selain itu, grafik komponen musiman (seasonal) menampilkan pola berulang secara periodik dengan interval konsisten, yang mencerminkan siklus waktu tertentu seperti mingguan atau bulanan. Pola musiman ini terlihat stabil dari waktu ke waktu, mengindikasikan adanya perilaku pasar yang berulang secara konsisten.

4.6. Pengujian Stasioneritas

Setelah data nilai tukar US Dollar terhadap Rupiah diresample menjadi format mingguan, dilakukan pengujian stasioneritas menggunakan uji ADF.

Tabel 2. Hasil Uji ADF terhadap Data Historis Nilai Tukar


ADF Statistic	p-value	Nilai Kritis 1%	Nilai Kritis 5%	Nilai Kritis 10%
-1.2372	0.6573	-3.4350	-2.8636	-2.5678

Hasil uji menunjukkan nilai p-value sebesar 0,657353 yang lebih besar dari tingkat signifikansi 0,05, dan statistik uji ADF lebih besar dari nilai kritis pada level 1%, 5%, dan 10%. Hal ini mengindikasikan bahwa data masih belum stasioner. Oleh karena itu, diperlukan transformasi differencing untuk menjadikan data stasioner dengan mengurangi nilai saat ini dengan nilai sebelumnya.

4.7. Identifikasi Parameter SARIMA


Setelah tahap persiapan data dan visualisasi awal, langkah berikutnya adalah mengidentifikasi parameter terbaik untuk model SARIMA yang terdiri dari parameter non-musiman (p, d, q) dan musiman (P, D, Q)[s] agar performa prediksi optimal.

4.8. Plot ACF dan PACF




Gambar 5. Grafik ACF sebelum di Transformasi

Pada grafik ACF sebelum transformasi diatas menunjukkan pola *slow decay* dan banyak batang melewati batas signifikan, menandakan data non-stasioner dan perlunya differencing non-musiman dan musiman.




Gambar 6. Grafik ACF Hasil Non-Seasonal Differencing sekali

Setelah differencing non-musiman sekali ($d=1$), plot ACF menunjukkan penurunan drastis pada lag 1, mengindikasikan data menjadi stasioner. Spike signifikan pada lag 1–2 pada grafik ACF non-musiman tersebut mengindikasikan bahwa nilai MA (q) = 1




Gambar 7. Grafik ACF Hasil Seasonal Differencing sekali

Sedangkan pada Gambar 7. diatas grafik ACF musiman menunjukkan spike pada lag musiman (lag 52) tidak signifikan sehingga MA musiman (Q) = 0 dipertimbangkan.




Gambar 8. Grafik PACF sebelum di Transformasi

Grafik PACF sebelum transformasi diatas menunjukkan beberapa lag signifikan pada lag 1–3.



Gambar 9. Grafik PACF Hasil Non-Seasonal Differencing sekali

Setelah differencing non-musiman, dapat dilihat pada grafik diatas spike signifikan hanya pada lag 1 dan 2, sehingga AR (p) = 2 dipilih untuk menghindari overfitting.



Gambar 10. Grafik PACF Hasil Seasonal Differencing sekali

Pada PACF musiman tersebut, terdapat spike signifikan pada lag 52 sehingga mengindikasikan AR musiman (P) = 1.

4.9. Differencing

Setelah differencing non-musiman dan musiman sekali ($d=1$, $D=1$), uji ADF kembali dilakukan untuk mengetahui apakah data telah memenuhi syarat stasioneritas.

Tabel 3. Hasil Uji ADF Setelah Differencing

ADF Statistic	p-value	Nilai Kritis 1%	Nilai Kritis 5%	Nilai Kritis 10%
-10.635	0.0000	-3.4350	-2.8636	-2.5678

Berdasarkan Tabel 3, menunjukkan nilai statistik uji -10.635740 dengan p-value 0.000000, lebih kecil dari nilai kritis pada semua tingkat signifikansi, sehingga data telah memenuhi syarat stasioneritas dan siap untuk pemodelan.

4.10. Penentuan Periode Musiman

Berdasarkan pola musiman yang konsisten setiap tahun dan data yang sudah diresample menjadi mingguan, untuk periode musimannya ditetapkan $s = 52$ karena dalam satu tahun terdapat ± 52 minggu.

4.11. Pencarian Grid Otomatis

Parameter model SARIMA disempurnakan menggunakan fungsi `auto_arima`, pencarian grid otomatis ini berdasarkan kriteria AIC dan BIC. Model terbaik yang diperoleh adalah SARIMA (0,1,2) (0,1,1)[52] dengan waktu pemodelan 550,511 detik, yang lebih optimal dibandingkan model manual SARIMA (2,1,1) (1,1,0)[52].

Tabel 4. Perbandingan hasil performa nilai AIC dan BIC secara manual dan otomatis

Identifikasi Model	Parameter SARIMA	AIC	BIC	Keterangan
Manual	(2,1,1) (1,1,0)[52]	2617.745	2633.511	Dugaan Awal
Otomatis	(0,1,2) (0,1,1)[52]	2615.438	2628.051	auto_arima

Tabel tersebut menunjukkan bahwa model otomatis memberikan performa lebih baik berdasarkan nilai AIC dan BIC dibandingkan model manual.

4.12. Peramalan dan Validasi

Setelah model SARIMA optimal diperoleh, dilakukan proses peramalan dan validasi untuk mengevaluasi kemampuan model dalam memprediksi nilai tukar US Dollar terhadap Rupiah selama satu tahun ke depan.

4.13. Pembagian Data

Data dibagi menjadi 80% sebagai data latih (training set) dan 20% sebagai data uji (testing set) untuk memastikan evaluasi performa model yang objektif terhadap data yang tidak digunakan dalam pelatihan.

4.14. Model Fitting

Model SARIMA (0,1,2) (0,1,1)[52] di-fit menggunakan fungsi SARIMAX dari pustaka statsmodels dengan dua skenario:

- Evaluasi Performa: Model dibangun dengan 80% data latih dan diuji pada 20% data uji. Dari model ini menghasilkan parameter $MA(1) = -0.6334$ dan MA musiman(52) = -0.0968 signifikan secara statistik ($p < 0.05$), dengan nilai AIC 2615.438 dan BIC 2628.051.
- Forecasting: Model di-refit menggunakan 100% data historis untuk menghasilkan peramalan jangka panjang. Sedangkan model ini menghasilkan parameter $MA(1) = -0.2484$ dan MA musiman(52) = -0.4503 tetap signifikan, dengan nilai AIC dan BIC yang lebih tinggi karena ukuran sampel lebih besar, namun refitting tetap diperlukan karena tujuannya bukan lagi evaluasi, melainkan optimalisasi guna menghasilkan peramalan jangka panjang yang lebih akurat.


4.15. Peramalan

Peramalan dilakukan menggunakan metode `forecast()`, sehingga menghasilkan estimasi mingguan nilai tukar selama 52 minggu ke depan. Hasil peramalan disajikan dalam bentuk deret waktu dengan interval kepercayaan 95%. Nilai ramalan mingguan yang dihasilkan berada dalam kisaran antara 16.488 hingga 16.927, sedangkan batas bawah (Lower Bound 95%) berkisar dari 15.313 hingga 15.951, dan batas atas (Upper Bound 95%) mencapai rentang 17.532 hingga 18.023.

4.16. Evaluasi Akurasi Model


Evaluasi performa model pada data uji menggunakan metrik MAE, MSE, RMSE, dan MAPE menghasilkan nilai masing-masing 412.8130, 280524.1243, 529.6453, dan 2.61%. Nilai MAPE di bawah 5% menunjukkan model memiliki tingkat akurasi sangat baik dalam memprediksi nilai tukar.

4.17. Visualisasi Hasil Peramalan



Gambar 11. Grafik Hasil Peramalan dengan Skenario Evaluasi Performa

Gambar 11 tersebut, menampilkan visualisasi hasil peramalan menggunakan Matplotlib dengan kurva data historis (training), data aktual uji, dan hasil prediksi model beserta interval kepercayaan 95%.



Gambar 12. Grafik Hasil Peramalan dengan Skenario Forecasting

Sedangkan pada Gambar 12 tersebut, dapat dilihat grafik menunjukkan model SARIMA mampu mengikuti pola data historis dan memprediksi data uji dengan akurat, serta menghasilkan peramalan mingguan yang informatif untuk satu tahun ke depan.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, model SARIMA terbaik yang diperoleh melalui analisis ACF, PACF, dan fungsi `auto_arima` dari pustaka `pmdarima` adalah SARIMA (0,1,2)(0,1,1), dengan nilai AIC dan BIC terendah dibandingkan model manual. Model ini menunjukkan performa yang sangat baik dengan nilai MAPE 2,61% pada data uji, sehingga efektif untuk peramalan nilai tukar US Dollar terhadap Rupiah dalam jangka pendek satu tahun ke depan. Pemodelan berbasis seluruh data historis menghasilkan peramalan mingguan yang konsisten dengan tren historis, hal ini menunjukkan stabilitas model dalam jangka pendek. Penggunaan bahasa pemrograman Python dan pustaka seperti `pandas`, `matplotlib`, dan `statsmodels` mempermudah seluruh proses analisis secara efisien dan mudah diinterpretasikan. Disarankan metode ini diaplikasikan pada analisis deret waktu ekonomi lain yang memiliki pola musiman, serta dikembangkan dengan memasukkan faktor eksternal makroekonomi dan menggunakan data real-time atau interval waktu yang lebih pendek. Selain itu, pengujian model alternatif selain SARIMA juga dianjurkan untuk meningkatkan keakuratan peramalan.

DAFTAR PUSTAKA

- [1] E. A. Mutiara and D. Puspitasari, "Pengaruh Inflasi, Ekspor dan Impor Terhadap Stabilitas Nilai Tukar Rupiah per Dollar AS Periode 2016-2022," *J. Simki Econ.*, vol. 7, no. 1, pp. 50–62, 2024, doi: 10.29407/jse.v7i1.516.
- [2] W. S. Kesuma, "Prediksi Analisis Time Series Nilai Tukar Rupiah terhadap Dolar Amerika dengan ARIMA dan SARIMA melalui CRISP-DM," vol. 4, pp. 190–203, 2024.
- [3] A. Mustopa, J. D. Santoso, M. S. F. Nauvaldhi, and D. Wulandari, "PEMODELAN VARIABILITAS MUSIMAN DALAM CURAH HUJAN: PENDEKATAN DERET WAKTU Abstraksi Keywords: Pendahuluan," vol. 6, no. 2, 2025.
- [4] F. A. Rezy *et al.*, "Provinsi DKI Jakarta, 2022). Dalam dua dekade terakhir, berbagai faktor seperti urbanisasi, migrasi, wilayah perkotaan. Ketimpangan distribusi penduduk dapat mengakibatkan tekanan pada transportasi ekonomi, seperti meningkatnya pengangguran dan kem," vol. 6, pp. 50–63, 2025.
- [5] L. A. Muzakki, M. N. H. Ryandono, S. Herianingrum, and S. Rusgianto, "Analisis Pengaruh Pertumbuhan Ekonomi, Inflasi, Dan Nilai Tukar Mata Uang Asing Terhadap Profitabilitas Bank Umum Syariah Di Indonesia Periode 2016-2020," *J. Ilm. Ekon. Islam*, vol. 10, no. 1, p. 29, 2024, doi: 10.29040/jiei.v1i1.12314.
- [6] Q. Qarina, "Analisis Determinan Nilai Tukar Di Indonesia," *SIBATIK J. J. Ilm. Bid. Sos. Ekon. Budaya, Teknol. dan Pendidik.*, vol. 2, no. 2, pp. 369–380, 2023, doi: 10.54443/sibatik.v2i2.562.
- [7] A. Ratnasari, H. Rumatiga, and Amany, "Teori Ekonomi Al-Ghazali dan Adam Smith: Analisis Komparatif terhadap Mekanisme Pasar," vol. 3, no. 2, pp. 186–195, 2024, doi: 10.69768/ji.v3i2.63.
- [8] G. Ardesfira, H. F. Zedha, I. Fazana, J. Rahmadhiyanti, S. Rahima, and S. Anwar, "Peramalan Nilai Tukar Rupiah Terhadap Dollar Amerika Dengan Menggunakan Metode Autoregressive Integrated Moving Average (Arima)," *Jambura J. Probab. Stat.*, vol. 3, no. 2, pp. 71–84, 2022, doi: 10.34312/jjps.v3i2.15469.
- [9] R. P. Septianti and N. Dahtiah, "Penerapan Metode Peramalan dalam Menyusun anggaran Penjualan dan Anggaran Produksi Sebagai Dasar Penyusunan Anggaran Biaya Produksi pada LAF Project," *Indones. Account. Lit. J.*, vol. 1, no. 3, pp. 490–503, 2021, doi: 10.35313/ialj.v1i3.3166.
- [10] T. Alda and M. Azalia, "Pendekatan Time Series dan Kausal terhadap penjualan ragum di provinsi Gorontalo," *Talent. Conf. Ser. Energy Eng.*, vol. 5, no. 2, pp. 146–151, 2022, doi: 10.32734/ee.v5i2.1558.
- [11] F. Ahmad, "PENENTUAN METODE PERAMALAN PADA PRODUKSI PART NEW GRANADA BOWL ST Di PT.X," *JISI J. Integr. Sist. Ind.*, vol. 7, no. 1, p. 31, 2020, doi: 10.24853/jisi.7.1.31-39.
- [12] I. Fadliani, I. Purnamasari, and W. Wasono, "PERAMALAN DENGAN METODE SARIMA PADA DATA INFLASI DAN IDENTIFIKASI TIPE OUTLIER (Studi Kasus: Data Inflasi Indonesia Tahun 2008-2014)," *J. Stat. Univ. Muhammadiyah Semarang*, vol. 9, no. 2, p. 109, 2021, doi: 10.26714/jsunimus.9.2.2021.109-116.
- [13] M. I. Hakiqi, A. Firmansyah, and R. Arisanti, "Peramalan Curah Hujan di Kota Bandung dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average)," *Inferensi*, vol. 1, no. 1, p. 23, 2023, doi: 10.12962/j27213862.v1i1.19119.
- [14] G. A. Suwandi, *Model Seasonal Autoregressive Integrated Moving Average (Sarima) Pada Peramalan Metode Fuzzy Time Series Markov*

- Chain (Fts-Mc). 2021.
- [15] N. E. Susanti, R. Saputra, and I. A. Situmorang, "Perbandingan Metode SARIMA, Double Exponential Smoothing dan Holt-Winter Additive dalam Peramalan Retail Sales Mobil Honda," *J. Sains Mat. dan Stat.*, vol. 10, no. 1, p. 58, 2024, doi: 10.24014/jsms.v10i1.26375.
- [16] W. C. Utomo, "Prediksi Pergerakan Saham BBRI ditengah Issue Ancaman Resesi 2023 dengan Pendekatan Machine Learning," *J. Teknol. dan Manaj. Inform.*, vol. 9, no. 1, pp. 20–27, 2023, doi: 10.26905/jtmi.v9i1.9135.
- [17] J. B. Rijanto and A. Zubair, "Evaluasi Akurasi Moving Average dan Single Exponential Smoothing dalam Meramalkan Harga Jual Karkas Ayam Broiler dan Pakan Ayam Broiler (Studi Kasus: Jawa Timur)," *J. Ilm. Univ. Batanghari Jambi*, vol. 24, no. 2, p. 966, 2024, doi: 10.33087/jiubj.v24i2.5305.
- [18] R. Yolanda, D. Rahmi, A. Kurniati, and S. Yuniati, "Penerapan Metode Triple Exponential Smoothing dalam Peramalan Produksi Buah Nenas di Provinsi Riau," *J. Teknol. dan Manaj. Ind. Terap.*, vol. 3, no. 1, pp. 1–10, 2024, doi: 10.55826/tmit.v3i1.285.
- [19] N. W. Aji and H. Retnawati, "Perbandingan Kecocokan Model Analisis Teori Respons Butir Pada Data Politomi," *J. Stat. dan Sains Data*, vol. 1, no. 2, pp. 31–47, 2024, [Online]. Available: <https://www.digitaleduka.com/artikel-ilmu-kunci-toefl/artikel/reading-comprehension/contoh->
- [20] J. Teguh *et al.*, "JURNAL LOCUS : Penelitian & Pengabdian BAHASA PEMROGRAMAN PYTHON," vol. 3, no. 12, pp. 1018–1031, 2024, doi: 10.58344/locus.v3i12.3663.
- [21] B. D. Prasetya, F. S. Pamungkas, and I. Kharisudin, "Pemodelan dan Peramalan Data Saham dengan Analisis Time Series menggunakan Python," *Prism. Pros. Semin. Nas. Mat.*, vol. 3, pp. 714–718, 2020, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/article/view/38116>
- [22] Y. Galahartlambang and T. Khotiah, "Visualisasi Data Dari Dataset COVID-19 Menggunakan Pemrograman Python," vol. 4902, no. x, 2021.
- [23] R. Nazar, "Implementasi Pemrograman Python Menggunakan Google Colab," *J. Inform. dan Komput.*, vol. 15, no. 1, pp. 50–56, 2024.