



Pemodelan Laju Perubahan Nilai Tukar Rupiah (IDR) terhadap Dolar Amerika (USD) dengan Metode Markov Switching Autoregressive (MSAR)

Sherli Yurinanda¹, Darvi Mailisa Putri^{✉ 2}

Matematika, Universitas Jambi, Indonesia¹

Matematika, Universitas Islam Negeri Imam Bonjol Padang, Indonesia²

email: sherliyurinanda@unja.ac.id¹, darvimailisaputri@gmail.com²

Received 31 January 2021, Accepted 19 March 2021, Published 31 March 2021

Abstrak

Penelitian ini bertujuan untuk menentukan pemodelan laju perubahan nilai tukar Rupiah (IDR) terhadap dolar Amerika (USD) menggunakan metode *Markov Switching Autoregressive* (MSAR). Data penelitian bersumber dari data sekunder melalui website investing untuk melihat nilai tukar Rupiah terhadap dolar Amerika dengan rentang waktu Januari sampai dengan Desember 2020. Hasil penelitian menunjukkan model terbaik yang diperoleh adalah MS(2)AR(3) dengan parameter $\sim_1 = 0.031119$ dan $\sim_2 = -0.000504$, dimana saat $state=1$ maka rata-rata laju perubahan nilai tukar rupiah terhadap dolar Amerika adalah 0.031119 per hari, sedangkan saat $state=2$ rata-rata laju perubahan nilai tukar rupiah terhadap dolar Amerika sebesar -0.000504 per hari.

Kata Kunci: Nilai tukar rupiah, dolar Amerika, Markov Switching Autoregressive.

Abstract

This study aims to determine the modeling of the exchange rate change rate of the Rupiah (IDR) against the US dollar (USD) using the Markov Switching Autoregressive (MSAR) method. The research data is sourced from secondary data through website investing to see the Rupiah exchange rate against the US dollar with a time span from January to December 2020. The results show that the best model obtained is MS(2)AR(3) with parameters $\sim_1 = 0.031119$ and $\sim_2 = -0.000504$, where when $state = 1$, the average rate of change in the rupiah exchange rate against the US dollar is 0.031119 per day, while when $state = 2$ the average rate of change in the rupiah exchange rate against the US dollar is -0.000504 per day.

Keywords: Rupiah exchange rate, US dollars, Markov Switching Autoregressive.

✉ Corresponding author

PENDAHULUAN

Time series atau deret waktu merupakan barisan suatu nilai pengamatan yang diukur dalam rentang waktu tertentu dalam interval waktu yang sama [1]. Analisis data deret waktu sangat aplikatif dalam dunia bisnis guna meramalkan nilai suatu perolehan data di masa yang akan datang berdasarkan data-data masa lampau. Suatu peramalan data deret waktu diperoleh dari analisis deret waktu dalam bentuk pemodelan data.

Pemodelan data deret waktu biasanya menggunakan model klasik salah satunya *Autoregressive* (AR). Model ini merupakan model linier dalam runtun waktu yang umumnya dapat diaplikasikan pada sebagian besar data-data statistik dan ekonomi, seperti data nilai tukar mata uang. Data tersebut berfluktuasi di sekitar suatu nilai pada waktu tertentu. Kondisi data yang berfluktuasi pada nilai tukar mata uang ini mengindikasikan suatu perubahan struktur dimana terjadi perubahan kondisi yang berbeda pada waktu-waktu tertentu.

Model deret waktu klasik seperti *Autoregressive* (AR) tidak mampu menjelaskan perubahan struktur yang sering terjadi pada data deret waktu. Karena pada model tersebut perubahan struktur yang terjadi pada data diabaikan. Sedangkan perubahan struktur merupakan suatu kondisi yang sering terjadi pada data ekonomi yang dapat disebabkan oleh krisis keuangan, pandemi, bencana alam, kebijakan pemerintah, dan lain sebagainya.

Perilaku perubahan struktur tersebut dapat dianggap dipengaruhi oleh suatu variabel acak tak teramati yang disebut *state* atau *regime*. Oleh karena itu, untuk mengatasi masalah perubahan struktur, [2] mengenalkan suatu model *Markov Switching Autoregressive* (MSAR) yang merupakan suatu metode pemodelan pada data deret waktu yang mengalami perubahan struktur. Model *Markov Switching Autoregressive* (MSAR) merupakan penggabungan dari suatu model rantai Markov dengan model deret waktu klasik *Autoregressive*. Model ini mampu menghitung peluang suatu data untuk bertahan atau berpindah pada suatu struktur atau kondisi, serta memprediksi durasi dari keberlanjutan suatu data pada kondisi tertentu. Misalnya pada krisis keuangan yang dapat terulang kembali pada suatu waktu yang tidak diketahui pasti kapan terjadinya.

Berdasarkan data masa lalu, dengan menggunakan model *Markov Switching Autoregressive* (MSAR) dapat diketahui berapa peluang data akan bertahan pada suatu kondisi, atau dapat berubah mengikuti kondisi sebaliknya. Hal ini sangat berguna untuk memprediksi pergerakan data pada situasi di masa yang akan datang serta sebagai peringatan dini akan situasi yang akan terjadi. Besarnya laju perubahan merupakan suatu nilai yang diperoleh dari penghitungan return suatu data ekonomi. Penghitungan return selain untuk membentuk suatu data yang tidak stasioner menjadi stasioner, sering juga digunakan untuk meramalkan suatu kondisi laju perubahan data ekonomi seperti nilai tukar mata uang. Meramalkan suatu laju perubahan nilai tukar mata uang dapat bermanfaat guna memprediksi laju perubahan nilai di masa yang akan datang. Memprediksi suatu laju perubahan nilai di masa yang akan datang dapat memberikan gambaran kepada pelaku ekonomi seperti investor ataupun pemerintah dalam membentuk kebijakan dalam menghadapi suatu kondisi ekonomi.

Penelitian mengenai *Markov Switching Autoregressive* ini pernah dilakukan oleh [3] yang berjudul *Pemodelan Markov Switching Autoregressive*. Model terbaik yang diperoleh

adalah MS(2)AR(1) pada data nilai tukar rupiah terhadap US Dolar. Dalam model MSAR dihitung rata-rata durasi lama state apresiasi bertahan sekitar 2 hari dan rata-rata durasi state depresiasi bertahan sebesar 19 hari. Penelitian selanjutnya pernah dilakukan oleh [4] yang berjudul Pemodelan *Markov Switching Autoregressive* (MSAR) Pada Data Time Series. Model terbaik yang diperoleh adalah MS(2)AR(2) dengan peluang perpindahan state disajikan dalam matriks transisi. Dalam model MSAR dihitung rata-rata durasi lama state apresiasi bertahan sebesar 15 hari dan rata-rata durasi state depresiasi bertahan sebesar 22 hari.

METODOLOGI

Penelitian ini menggunakan data nilai tukar Rupiah terhadap dolar Amerika dengan rentang waktu Januari sampai dengan Desember 2020. Langkah-langkah analisis data dalam penelitian ini adalah:

1. Membuat plot data. Hal ini untuk melihat sebaran data apakah sudah sesuai dengan kriteria yang diharapkan.
2. Mentransformasikan data nilai tukar mata uang rupiah (IDR) terhadap dolar Amerika (USD) ke dalam nilai laju perubahan nilai tukar mata uang dengan menggunakan rumus

$$R = \ln \left(\frac{z_t}{z_{t-1}} \right)$$

3. Uji stasioneritas. Data laju perubahan nilai tukar mata uang IDR terhadap USD yang akan dimodelkan dengan MSAR, diuji apakah sudah memenuhi asumsi stasioneritas. Kestasioneran data diuji dengan menggunakan uji *Augmented Dickey-Fuller* (ADF).

H_0 : nilai *return* tidak stasioner

H_1 : nilai *return* stasioner

4. Mengidentifikasi model. Pada metode *Markov Switching Autoregressive* (MSAR) perlu diidentifikasi orde n untuk *Markov Switching* (MS) dan orde p untuk *Autoregressive* (AR).
5. Melakukan estimasi parameter. Estimasi parameter untuk memperoleh nilai koefisien dari masing-masing parameter model.
6. Dilakukan pemilihan model terbaik dengan mengambil nilai AIC, HQC dan SC terkecil dari masing-masing model.
7. Dari model terbaik yang diperoleh selanjutnya dilakukan peramalan peluang perubahan *state* pada periode (waktu) selanjutnya. Dengan persamaan durasi *state*:

$$D = \frac{1}{1 - p_{ij}}$$

8. Merumuskan kesimpulan.

1. Model *Autoregressive* (AR)

Model *Autoregressive* (AR) adalah salah satu model stasioner dari data deret waktu. Model ini merupakan model hasil regresi dengan dirinya sendiri pada waktu-waktu

sebelumnya. Model AR dengan orde p dinotasikan dengan $AR(p)$ (Box,1994). Misalkan $\{X_t\}$ adalah deret waktu stasioner, maka bentuk umum model $AR(p)$ adalah

$$X_t = w_1 X_{t-1} + w_2 X_{t-2} + \dots + w_p X_{t-p} + e_t \quad (1)$$

w_p = parameter *autoregressive* ke p

e_t = nilai residual pada waktu t , dengan $e_t \sim WN(0, \sigma^2)$

Persamaan (1) dapat ditulis dalam operator *backward shift* ($BX_t = X_{t-1}$) seperti berikut

$$\begin{aligned} X_t &= w_1 X_{t-1} + w_2 X_{t-2} + \dots + w_p X_{t-p} + e_t \\ X_t &= w_1 BX_t + w_2 BX_{t-1} + \dots + w_p BX_{t-p} + e_t \\ X_t &= w_1 BX_t + w_2 B^2 X_t + \dots + w_p B^p X_t + e_t \\ X_t - w_1 BX_t - w_2 B^2 X_t - \dots - w_p B^p X_t &= e_t \\ (1 - w_1 B - w_2 B^2 - \dots - w_p B^p) X_t &= e_t \end{aligned}$$

Misalkan $w_p(B) = (1 - w_1 B - w_2 B^2 - \dots - w_p B^p)$, diperoleh

$$w_p(B) X_t = e_t \quad (2)$$

2. Rantai Markov

Rantai Markov (Markov Chains) adalah suatu teknik matematika yang biasa digunakan untuk melakukan pemodelan bermacam-macam sistem dan proses bisnis. Teknik ini dapat digunakan untuk memperkirakan perubahan-perubahan di waktu yang akan datang dalam variabel-variabel dinamis atas dasar perubahan-perubahan dari variabel-variabel dinamis tersebut di waktu yang lalu.

Rantai Markov dapat digambarkan sebagai discrete-time stochastic process yang memiliki jumlah state yang terbatas dan pada suatu saat rantai Markov berada di salah satu state tersebut [5]. Keadaan ini dapat dituliskan pada persamaan berikut ini :


$$P(X_{t+1} = i_{t+1} | X_t = i_t, X_{t-1} = i_{t-1}, \dots, X_1 = i_1, X_0 = i_0) \quad (3)$$

Dengan :

X_t : variabel discrete time stochastic process pada waktu t .

i_t : State dari discrete time stochastic process pada waktu t .

Teknik ini dapat digunakan juga untuk menganalisis kejadian-kejadian di waktu mendatang secara matematis. Dapat digambarkan pola rantai markov sebagai berikut.



Gambar 1. Probabilitas Transisional

Gambar 1 menjelaskan setiap waktu t , ketika kejadian adalah K_t dan seluruh kejadian sebelumnya adalah $K_t(j), \dots, K_t(j-n)$ yang terjadi dari proses yang diketahui, probabilitas seluruh kejadian yang datang $K_t(j)$ hanya bergantung pada kejadian $K_t(j-1)$ dan tidak bergantung pada kejadian-kejadian sebelumnya yaitu $K_t(j-2), K_t(j-3), \dots, K_t(j-n)$. Asumsi-asumsi dalam rantai Markov adalah sebagai berikut:

1. Jumlah probabilitas transisi keadaan adalah 1.
2. Probabilitas transisi tidak berubah selamanya.
3. Probabilitas transisi hanya tergantung pada status sekarang, bukan pada periode sebelumnya.

Peluang transisi p_{ij} tidak bergantung pada waktu n . Peluang ini dikatakan peluang transisi stasioner.

Rantai markov merupakan suatu teknik yang dapat digunakan untuk memperkirakan perubahan di waktu yang akan datang atas dasar perubahan dari masa yang lalu. Perubahan yang terjadi pada proses rantai markov disebabkan oleh suatu peluang transisi yang dilambangkan dengan $\{p_{ij}\}_{i,j=1,2,\dots,N}$. Peluang transisi p_{ij} menyatakan peluang bahwa *state* i diikuti oleh *state* j . *State* menyatakan suatu kondisi atau perubahan dari kejadian yang diasumsikan sebagai suatu bilangan bulat. Peluang transisi memenuhi

$$p_{i1} + p_{i2} + \dots + p_{iN} = 1 \quad (4)$$

Peluang transisi dari suatu rantai markov dibentuk dalam suatu matriks $P_{N \times N}$ yang disebut matriks peluang transisi

$$P = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1N} \\ p_{21} & p_{22} & \dots & p_{2N} \\ \dots & \dots & \dots & \dots \\ p_{N1} & p_{N2} & \dots & p_{NN} \end{bmatrix}$$

Elemen pada baris ke- j kolom ke- i dari matriks P merupakan peluang transisi p_{ij} . Sebagai contoh elemen pada baris ke-2 kolom ke-1 (p_{21}) merupakan peluang dari terjadinya *state* 1 setelah kejadian *state* 2.

Menurut [5] jika sebuah sistem pada saat t berada pada *state* i , maka sistem ini pada saat $t+1$ ada pada *state* lain. Hal ini berarti bahwa:

$$\sum_{j=1}^{j=N} P(X_{t+1} = j | P(X_t = i)) = \sum_{j=1}^{j=N} P_i = 1$$

3. Markov Switching Autoregressive (MSAR)

Model *Markov Switching* oleh Hamilton (1989) [6] atau dikenal juga sebagai *Regime Switching Model*, adalah salah satu model deret waktu nonlinier yang paling banyak digunakan. Model ini mampu memodelkan data deret waktu yang mengalami perubahan struktur. Pada model *Markov Switching* perubahan struktur dikontrol dengan suatu peubah *state* yang tidak teramati yang memenuhi orde pertama rantai markov. Sifat *Markov* mengatur nilai peubah *state* bergantung pada nilai sebelumnya. Suatu struktur yang

berubah pada periode waktu digantikan dengan struktur yang lain dengan proses *switching* (penggantian). Model *Markov Switching* cocok untuk menjelaskan data yang berkorelasi yang menunjukkan dengan jelas pola dinamik selama periode perubahan waktu.

Misalkan untuk suatu data dengan perubahan struktur dari dua kondisi, data tersebut secara klasik dapat dipecah menjadi dua kondisi berdasarkan periode waktunya. Periode waktu pertama dengan kondisi pertama dan periode waktu kedua dengan kondisi kedua. Kedua kondisi ini dapat dimodelkan dengan model *autoregressive*. Misalkan terdapat model *autoregressive* orde pertama dengan model pertama yang bersesuaian dengan deret waktu pada $t_i, t_{i+1}, \dots, t_{i+m}$ berikut.

$$z_t - \sim_1 = W(z_{t-1} - \sim_1) + V_t \quad (5)$$

Sementara model kedua

$$z_t - \sim_2 = W(z_{t-1} - \sim_2) + V_t \quad (6)$$

bersesuaian dengan deret waktu pada $t_j, t_{j+1}, \dots, t_{j+m}$. Kasus ini menggambarkan adanya pergeseran model antara model pertama dan model kedua yang terjadi pada deret waktu yang samapada waktu yang berbeda. Nilai s_t yang satu bersesuaian dengan model pada periode $t_i, t_{i+1}, \dots, t_{i+m}$ dan nilai s_t yang dua bersesuaian dengan model pada periode $t_j, t_{j+1}, \dots, t_{j+m}$.

Model *Markov Switching Autoregressive* (MSAR) merupakan penggabungan model rantai Markov dengan model deret waktu klasik *autoregressive*. Bentuk umum model *Markov Switching Autoregressive*: Hamilton

$$(z_t - \sim_{s_t}) = \sum W_p (z_{t-p} - \sim_{s_{t-p}}) + V_t \quad (7)$$

dimana $\{z_t\}$ adalah data pengamatan, W_p adalah koefisien *autoregressive*, s_t adalah *state* pada waktu t , \sim_{s_t} konstanta yang bergantung pada *state* s_t dan V_t residual pada waktu t .

Kriteria data yang diharapkan pada model *Markov Switching Autoregressive* (MSAR) adalah data yang terdapat perubahan struktur (kondisi).

4. Dugaan Durasi State

Menggunakan *Markov Switching Autoregressive* (MSAR) pada pemodelan data runtun waktu dapat diduga durasi dari masing-masing *state* berdasarkan perolehan peluang masing-masing *state* berdasarkan perolehan peluang masing-masing *state* yang didapatkan dari model. Misalkan $D = t$ adalah durasi dari *state* j pada waktu t setelah waktu pengamatan, maka:

$$\text{Untuk } D = 1 \text{ jika } s_t = j \text{ dan } s_{t+1} \neq j; P(D=1) = (1 - p_{jj})$$

$$\text{Untuk } D = 2 \text{ jika } s_t = s_{t+1} = j \text{ dan } s_{t+2} \neq j; P(D=2) = p_{jj}(1 - p_{jj})$$

$$\text{Untuk } D = 3 \text{ jika } s_t = s_{t+1} = s_{t+2} = j \text{ dan } s_{t+3} \neq j; P(D=3) = p_{jj}^2(1 - p_{jj})$$

dan seterusnya.

Maka dugaan dari durasi masing-masing *state* j dapat dihitung dengan

$$\begin{aligned}
 E(D) &= \sum_{i=1}^{\infty} i P(D=i) \\
 &= 1(1-p_{jj}) + 2p_{jj}(1-p_{jj}) + 3p_{jj}^2(1-p_{jj}) + \dots \\
 &= (1-p_{jj})(1 + 2p_{jj} + 3p_{jj}^2 + \dots) \\
 &\approx \frac{1}{1-p_{jj}}
 \end{aligned} \tag{8}$$

5. Uji Augmented Dickey-Fuller

Uji *Augmented Dickey-Fuller* atau sering juga dikenal dengan *unit root test* (uji akar unit) merupakan uji formalitas untuk kestasioneran suatu data. Uji ini dikenalkan oleh David Dickey dan Wayne Fuller. Formulasi yang digunakan menggunakan model *differenced-lag* yang diregresikan.

$$\nabla z_t = \alpha + \beta z_{t-1} + \sum_{i=1}^k \gamma_i \nabla z_{t-i} + e_t \tag{9}$$

dengan $\nabla z_t = z_t - z_{t-1}$ dan k adalah jumlah lag. Hipotesis yang digunakan dalam uji ini yaitu

$$H_0 : \alpha = 0 \text{ (data tidak stasioner)}$$

$$H_1 : \alpha \neq 0 \text{ (data stasioner)}$$

Statistik uji *Augmented Dickey-Fuller* sebagai berikut

$$ADF = \frac{\hat{\alpha}}{SE(\hat{\alpha})} \tag{10}$$

dimana $SE(\hat{\alpha})$ adalah *standard error* untuk $\hat{\alpha}$. Kriteria pengambilan keputusannya yaitu jika nilai mutlak statistik-t ADF > nilai mutlak statistik-t kritis (t-tabel) maka tolak H_0 , dengan kata lain data stasioner. Sedangkan jika nilai mutlak statistik-t ADF < nilai mutlak statistik-t kritis (t-tabel) maka tidak tolak H_0 , dengan kata lain data tidak stasioner [7].

6. Pemilihan Model Terbaik

Dalam membuat model dari suatu data, terkadang terdapat beberapa model yang signifikan. Tentunya dari beberapa model yang signifikan, hanya satu model yang harus ditetapkan sebagai model yang paling baik menjelaskan data yang dimodelkan. Beberapa kriteria yang dapat menjadi acuan pemilihan model terbaik adalah :

a. Akaike's Information Criteria (AIC)

Kriteria ini dikenalkan oleh Akaike untuk mengidentifikasi model dari suatu kumpulan data. Persamaan AIC dalam pemilihan model adalah

$$AIC = -2 \log \hat{f}^2 + 2k \tag{11}$$

Dimana $\log \hat{f}^2$ = ukuran *likelihood*

k = banyak parameter

n = banyak pengamatan

Suatu model terbaik adalah model yang memiliki nilai AIC paling kecil.

b. Bayesian Information Criterion (BIC) atau Schwarz Criterion (SC)

Bayesian Information Criterion (BIC) pertama kali dikenalkan oleh Schwartz. Pendekatan ini dikenal juga sebagai Schwartz Criterion (SC).

Persamaan BIC dalam pemilihan model adalah.

$$BIC = \log \hat{f}^2 + \frac{k \log(n)}{n} \quad (12)$$

Dimana $\log \hat{f}^2 =$ ukuran *likelihood*

$k =$ banyak parameter

$n =$ banyak pengamatan

Suatu model terbaik adalah model yang memiliki nilai BIC paling kecil.

c. Hannan and Quinn Criterion (HQC)

Kriteria ini dikenalkan oleh Kriteria ini dikenalkan oleh Hannan dan Quinn.

Penerapan ini digunakan meluas pada model autoregressive dan model regresi linier.

Persamaan HQ dapat dituliskan sebagai berikut.

$$HQ = -2 \log \hat{f}^2 + 2k \log(\log(n)) \quad (13)$$

Dimana $\log \hat{f}^2 =$ ukuran *likelihood*

$k =$ banyak parameter

$n =$ banyak pengamatan

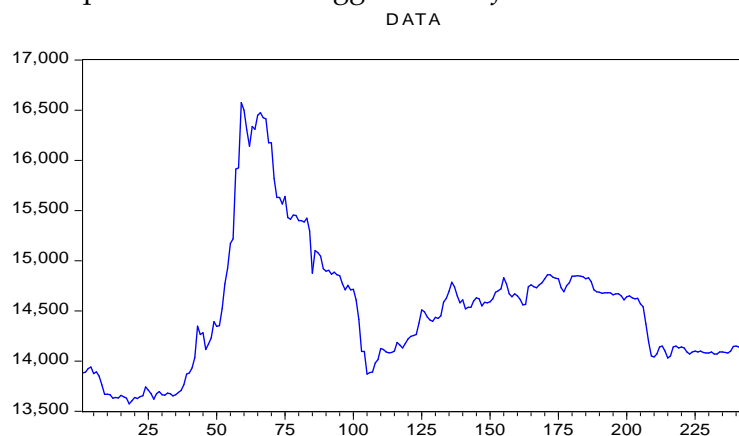
Suatu model terbaik adalah model yang memiliki nilai HQ paling kecil.

HASIL DAN PEMBAHASAN

Pada penelitian ini digunakan data nilai tukar rupiah terhadap dolar Amerika. Data yang dipakai adalah data per hari dari tanggal 01 Januari sampai 30 Desember 2020 dengan jumlah 243 data. Pada data akan diaplikasikan metode *Markov Switching Autoregressive* menggunakan *software statistic E-Views* untuk mencari model terbaik dari laju perubahan yang ada pada nilai tukar rupiah terhadap dolar Amerika. Adapun langkah-langkah yang dilakukan adalah sebagai berikut.

Plot Data

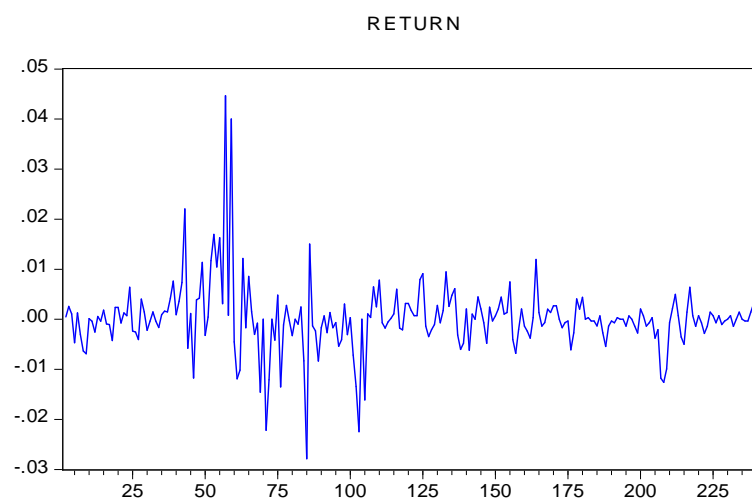
Plot data dilakukan untuk melihat secara kasat mata apakah data sudah stasioner terhadap mean dan varians. Saat data belum stasioner maka dilakukan *differencing* atau transformasi. Berikut hasil plot data awal menggunakan *software statistic E-Views*.



Gambar 2. Plot Data Nilai Tukar Rupiah Terhadap Dolar Amerika Tahun 2020

Pada Gambar 2, sumbu- x menyatakan waktu (dalam hari) dan sumbu- y menyatakan besar nilai tukar rupiah terhadap dolar Amerika (dalam rupiah). Berdasarkan grafik tersebut dapat dilihat bahwa data tidak stabil di sekitar nilai tengah atau mean. Pada hari ke-50 sampai hari ke-60 terjadi pelonjakan nilai dan di periode selanjutnya terjadi penurunan yang begitu signifikan. Dari analisa tersebut dapat disimpulkan bahwa data tidak stasioner terhadap mean dan varians.

Selanjutnya data nilai tukar rupiah terhadap dolar Amerika dilakukan transformasi logaritma dan differencing satu kali. Ini dilakukan agar data stasioner terhadap nilai tengah (mean) dan varians. Berikut hasil plot data setelah dilakukan transformasi logaritma dan differencing satu kali.



Gambar 3. Plot Data Nilai Tukar Rupiah Terhadap Dolar Amerika Tahun 2020 Setelah Dilakukan Transformasi Logaritma dan Differencing

Berdasarkan hasil plot pada Gambar 3 bahwa laju perubahan nilai tukar mata uang rupiah terhadap dolar Amerika terjadi perubahan struktur atau kondisi. Data mengalami lonjakan nilai yang sangat besar sehingga menunjukkan bahwa pada laju perubahan nilai tukar mata uang rupiah terhadap dolar Amerika terdapat suatu perubahan dan pergantian kondisi atau state. Terjadinya perubahan dari satu kondisi ke kondisi lain pada data ini mengindikasikan terdapat dua state pada data sehingga data ini dapat dimodelkan dengan metode *Markov Switching Autoregressive* (MSAR). Adapun asumsi yang digunakan adalah pada state pertama sebagai kondisi apresiasi atau kondisi tidak krisis pada pergerakan nilai tukar mata uang, dan state kedua adalah kondisi depresiasi atau kondisi krisis pada pergerakan nilai tukar mata uang.

Uji Stasioneritas Data

Kestasioneran suatu data selain dapat dilihat dari hasil plot data atau grafik, juga perlu diperiksa dengan uji kestasioneran yaitu dengan uji akar unit atau disebut dengan uji *Augmented Dickey-Fuller* (ADF). Berikut hasil uji akar unit (ADF) pada data nilai tukar rupiah terhadap dolar Amerika.

Tabel 1. Hasil Uji Akar Unit (ADF) Data Nilai Tukar Rupiah Terhadap Dolar Amerika Tahun 2020 Setelah Dilakukan Transformasi Logaritma dan Differencing

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.412699	0.0000
Test critical values: 1% level	-3.457515	
5% level	-2.873390	
10% level	-2.573160	

Berdasarkan hasil uji ADF pada Tabel 1 diperoleh nilai statistik sebesar -7.412699 . Nilai kritis atau t_{tabel} sebesar -3.457515 dengan nilai $\alpha = 0.01$, -2.873390 dengan nilai $\alpha = 0.05$ dan -2.573160 dengan nilai $\alpha = 0.1$. Kestasioneran data diputuskan dengan membandingkan nilai t_{stat} dengan t_{tabel} .

Pada penelitian ini digunakan taraf uji sebesar 5%. Sehingga jika nilai t_{stat} dibandingkan dengan nilai t_{tabel} didapatkan bahwa $|t_{stat-ADF}|$ sebesar 7.412699 jauh lebih besar dari $|nilai\ kritis|$ sebesar 2.873390 . Ini berarti data laju perubahan nilai tukar mata uang rupiah terhadap dolar Amerika sudah stasioner terhadap rata-rata. Sehingga dapat dikatakan bahwa data laju perubahan nilai tukar mata uang rupiah terhadap dolar Amerika sudah stasioner terhadap rata-rata pada taraf kepercayaan 95%. Selanjutnya dilakukan analisis data runtun waktu dengan model MSAR.

Identifikasi Model dan Dugaan Parameter Model

Identifikasi model MSAR dilakukan dengan melihat nilai n dan p pada data. Untuk nilai n sudah ditentukan sama dengan 2, sementara untuk nilai p dapat dilihat dari plot PACF (Partial Autocorrelation Function). Berikut hasil plot PACF setelah dilakukan transformasi logaritma dan differencing.

Tabel 2. Hasil Correlogram PACF Setelah dilakukan Transformasi Logaritma dan Differencing

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.163	0.163	6.4996	0.011
		2	0.304	0.285	29.237	0.000
		3	0.010	-0.08...	29.262	0.000
		4	0.187	0.123	37.931	0.000
		5	0.073	0.059	39.250	0.000
		6	0.115	0.014	42.556	0.000
		7	-0.00...	-0.04...	42.559	0.000
		8	0.062	0.023	43.529	0.000
		9	0.070	0.073	44.754	0.000
		1...	0.085	0.026	46.584	0.000
		1...	0.059	0.016	47.475	0.000
		1...	-0.04...	-0.09...	47.928	0.000
		1...	-0.06...	-0.08...	48.973	0.000
		1...	0.072	0.127	50.334	0.000
		1...	-0.02...	-0.04...	50.532	0.000
		1...	0.158	0.143	57.035	0.000
		1...	-0.10...	-0.10...	59.645	0.000
		1...	0.082	0.025	61.399	0.000
		1...	-0.10...	-0.06...	64.177	0.000
		2...	0.069	0.005	65.455	0.000
		2...	0.009	0.097	65.475	0.000
		2...	-0.08...	-0.17...	67.379	0.000
		2...	0.001	0.098	67.379	0.000
		2...	-0.00...	0.008	67.398	0.000
		2...	-0.01...	-0.09...	67.468	0.000
		2...	-0.09...	-0.06...	70.053	0.000
		2...	0.019	0.073	70.149	0.000
		2...	-0.14...	-0.09...	76.113	0.000
		2...	0.007	0.009	76.124	0.000
		3...	-0.09...	-0.01...	78.423	0.000
		3...	-0.05...	-0.04...	79.170	0.000
		3...	-0.07...	-0.04...	80.650	0.000
		3...	-0.03...	0.087	81.080	0.000
		3...	0.041	0.045	81.554	0.000
		3...	0.018	0.029	81.649	0.000
		3...	-0.03...	-0.04...	81.961	0.000

Dari hasil plot correlogram PACF yang dihasilkan, maka model signifikan pada lag ke-3 sehingga diperoleh nilai $p = 3$. Namun pada kasus ini peneliti akan tetap melakukan estimasi model AR(1), AR(2) dan AR(3). Ini dilakukan untuk melakukan perbandingan model yang didapat. Langkah selanjutnya adalah mengestimasi parameter masing-masing model MS(2)AR(p) dengan $p = 1, 2, 3$.

Tabel 3. Estimasi Parameter Masing-Masing Model MS(2)AR(p)

	MS(2)AR(1)	MS(2)AR(2)	MS(2)AR(3)
$\tilde{\alpha}_1$	0.001140 (0.0892)	-0.018556 (0.0077)	0.031119 (0.0000)
$\tilde{\alpha}_2$	-0.001084 (0.1086)	0.000501 (0.5503)	-0.000504 (0.3889)
w_1	0.195012 (0.0026)	0.072669 (0.2852)	0.314591 (0.0000)
w_2		0.416062 (0.0000)	0.136174 (0.0536)
w_3			-0.040981 (0.5425)

Pemilihan Model Terbaik

Pemilihan model terbaik dilakukan dengan membandingkan nilai AIC, HQC, dan SC masing-masing model, dimana model dengan nilai AIC, HQC, dan SC terkecil adalah model yang paling baik. Tabel berikut adalah perbandingan nilai dari beberapa model yang telah dipilih.

Tabel 4. Nilai AIC, HQC, dan SC dari Masing-Masing Model MS(2)AR(p)

Model	AIC	HQC	SC
MS(2)AR(1)	-7.128653	-7.093699	-7.041894
MS(2)AR(2)	-7.283666	-7.242762	-7.182148
MS(2)AR(3)	-7.449778	-7.402885	-7.333411

Pada Tabel 4 diperoleh nilai AIC, HQC, dan SC yang paling kecil adalah model MS(2)AR(3). Sehingga diperoleh model terbaik adalah MS(2)AR(3) yang memiliki parameter $\tilde{\alpha}_1 = 0.031119$ dan $\tilde{\alpha}_2 = -0.000504$, yaitu rata-rata untuk masing-masing state pada model *Markov Switching*. Pada saat state=1 maka rata-rata laju perubahan nilai tukar rupiah terhadap dolar Amerika adalah 0.031119 per hari, sedangkan pada state=2 rata-rata laju perubahan nilai tukar rupiah terhadap dolar Amerika sebesar -0.000504 per hari. Parameter untuk Autoregressive $w_1 = 0.314591$, $w_2 = 0.136174$, dan $w_3 = -0.040981$. sehingga diperoleh model sebagai berikut.

$$(z_t - \tilde{\alpha}_{s_t}) = 0.314591(z_{t-1} - \tilde{\alpha}_{s_{t-1}}) + 0.136174(z_{t-2} - \tilde{\alpha}_{s_{t-2}}) - 0.040981(z_{t-3} - \tilde{\alpha}_{s_{t-3}}) + v_t$$

SIMPULAN

Pengolahan data yang dilakukan pada data nilai tukar rupiah terhadap dolar Amerika dari tanggal 01 Januari sampai dengan 30 Desember 2020 dengan menggunakan metode *Markov Switching Autoregressive* (MSAR) diperoleh model terbaik MR(2)AR(3). Model ini terpilih karena didukung dengan nilai AIC, SIC, dan HQC yang minimum serta nilai signifikan juga minimum. Model MS(2)AR(3) dengan parameter $\alpha_1 = 0.031119$ dan $\alpha_2 = -0.000504$, dimana saat state=1 maka rata-rata laju perubahan nilai tukar rupiah terhadap dolar Amerika adalah 0.031119 per hari, sedangkan saat state=2 rata-rata laju perubahan nilai tukar rupiah terhadap dolar Amerika sebesar -0.000504 per hari. Model MR(2)AR(3) memiliki persamaan sebagai berikut

$$(z_t - \tilde{s}_t) = 0.314591(z_{t-1} - \tilde{s}_{t-1}) + 0.136174(z_{t-2} - \tilde{s}_{t-2}) - 0.040981(z_{t-3} - \tilde{s}_{t-3}) + v_t$$

DAFTAR PUSTAKA

- [1] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [2] J. D. Hamilton, "Time Series Analysis, Princeton University Press, New Jersey," 1994.
- [3] F. D. Ariyani, B. Warsito, and H. Yasin, "Pemodelan Markov Switching Autoregressive," *J. Gaussian*, vol. 3, no. 3, pp. 381–390, 2014.
- [4] A. Prasyanti, M. Usman, and D. Aziz, "PEMODELAN MARKOV SWITCHING AUTOREGRESSIVE (MSAR) PADA DATA TIME SERIES," in *Prosiding Seminar Nasional METODE KUANTITATIF 2017*, 2017, vol. 1, no. 1, pp. 263–277.
- [5] W. L. Winston and J. B. Goldberg, *Operations research: applications and algorithms*, vol. 3. Thomson/Brooks/Cole Belmont eCalif Calif, 2004.
- [6] J. D. Hamilton, "A new approach to the economic analysis of nonstationary time series and the business cycle," *Econom. J. Econom. Soc.*, pp. 357–384, 1989.
- [7] D. N. Gujarati, D. C. Porter, and S. Gunasekar, *Basic econometrics*. Tata McGraw-Hill Education, 2012.