

PEMODELAN *MARKOV SWITCHING* *AUTOREGRESSIVE* (MSAR) PADA INFLASI DKI JAKARTA

FARHAH ANGGANA, DODI DEVIANTO*, FERRA YANUAR

*Departemen Matematika dan Sains Data,
Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Andalas,
Kampus Unand Limau Manis Padang, Indonesia
email : farhah.anganaa@gmail.com, ddevianto@sci.unand.ac.id, ferrayanuar@sci.unand.ac.id*

Diterima 28 Desember 2022 Direvisi 7 Januari 2023 Dipublikasikan 30 Januari 2023

Abstrak. Inflasi merupakan salah satu indikator penting dalam menganalisis perekonomian suatu negara. Tingkat inflasi dapat dikendalikan dengan menetapkan target inflasi, namun pada kenyataannya volatilitas di dalam sektor finansial sangat sensitif terhadap perubahan-perubahan, sehingga diperlukan metode yang sesuai dalam menganalisisnya. Salah satu pemodelan yang dapat menjelaskan perubahan-perubahan tersebut adalah Model *Markov Switching Autoregressive* (MSAR). Oleh karena itu, pada penelitian ini akan ditentukan model terbaik untuk data inflasi DKI Jakarta, besar peluang perpindahan dan bertahannya suatu *state*, serta besarnya dugaan durasi masing-masing *state* menggunakan metode MSAR. Pada inflasi DKI Jakarta, dimisalkan terjadi dua *state* (peningkatan dan penurunan) dan tiga *state* (peningkatan, stabil, dan penurunan). Diperoleh bahwa model terbaik adalah MS(2)AR(1) dengan peluang bertahan pada *state* peningkatan adalah 0,729880, peluang transisi peningkatan ke penurunan adalah 0,270120, sedangkan peluang bertahan pada *state* penurunan adalah 0,732562, peluang transisi penurunan ke peningkatan adalah 0,267438. Dugaan durasi yang diperoleh pada peningkatan 3,702058 bulan dan durasi pada penurunan 3,200829 bulan.

Kata Kunci: Inflasi, *State*, *Markov Switching Autoregressive* (MSAR), Perubahan Struktur, Peluang Transisi

1. Pendahuluan

Inflasi merupakan salah satu indikator penting dalam menganalisis perekonomian sebuah negara. Perkembangan tingkat inflasi yang positif membawa dampak yang baik terhadap para pengusaha atau investor, karena menambah gairah untuk meningkatkan produksinya. Akan tetapi bagi para konsumen membawa dampak yang tidak baik, karena melemahnya daya beli masyarakat. Tingkat inflasi dapat dikendalikan dengan menetapkan target inflasi. Target inflasi merupakan kebijakan dengan mengumumkan kepada publik mengenai target inflasi jangka menengah. Hal ini sangat bergantung pada terbentuknya pemodelan yang tepat. Namun

*penulis korespondensi

pada kenyataannya, volatilitas di dalam sektor finansial sangat sensitif terhadap perubahan-perubahan kebijakan moneter, ketidakstabilan politik bahkan yang sifatnya sekedar rumor. Sehingga diperlukan metode yang sesuai untuk menganalisis data time series dengan mempertimbangkan fluktuasi yang terjadi [6].

Hamilton mengenalkan suatu model *Markov Switching Autoregressive* (MSAR) yang merupakan suatu metode pemodelan pada data deret waktu yang mengalami perubahan kondisi. Pada model *Markov Switching*, perubahan kondisi dianggap sebagai suatu variabel tak teramati (*unobservable variable*) yang dalam literatur sering disebut dengan *state* atau *regime*. Dengan memperhatikan adanya perubahan kondisi, model *Markov Switching* dapat menangkap dinamika yang lebih kompleks dari pergerakan data [1]. Oleh karena itu, pada penelitian ini akan dibahas bagaimana bentuk model, besar peluang perpindahan dan bertahannya suatu *state*, serta besarnya dugaan durasi masing-masing *state* inflasi DKI Jakarta menggunakan metode MSAR.

2. Landasan Teori

2.1. Stasioneritas Data

Pengujian kestasioneran terhadap nilai tengah dapat dilakukan dengan uji *Augmented Dickey-Fuller* (ADF) disajikan dalam bentuk persamaan regresi sebagai berikut [8]:

$$\nabla Y_t = \mu + \delta Y_{t-1} + \sum_{i=1}^k \phi_i \nabla Y_{t-i} + \epsilon_t, \quad (2.1)$$

dengan $\delta = 1 - \rho$, $\nabla Y_t = Y_t - Y_{t-1}$, k adalah jumlah lag, ϕ dan μ adalah parameter model serta t adalah waktu pengamatan. Hipotesis yang digunakan dalam uji ini yaitu.

$H_0 : \delta = 0$ (data tidak stasioner),

$H_1 : \delta \neq 0$ (data stasioner).

Statistik uji yang digunakan adalah sebagai berikut.

$$ADF = \frac{\hat{\delta}}{SE(\hat{\delta})}, \quad (2.2)$$

dimana $SE(\hat{\delta})$ adalah *standard error* untuk $\hat{\delta}$. Kriteria pengambilan keputusan yaitu:

- (a) Jika nilai mutlak statistik uji ADF > nilai mutlak kritis tabel-t ADF maka tolak H_0 , hal ini berarti data stasioner.
- (b) Jika nilai mutlak statistik uji ADF < nilai mutlak kritis tabel-t ADF maka tidak tolak H_0 , dengan kata lain data tidak stasioner.

Dalam pengujian stasioneritas varian, transformasi *Box-Cox* adalah salah satu metode yang digunakan untuk menstasionerkan data terhadap varian. Misalkan $T(Y_t)$ adalah fungsi transformasi dari Y_t . Jika Y_t belum stasioner terhadap varian,

maka dapat ditransformasi dengan formula berikut [9]:

$$T(Y_t) = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda}, \lambda \neq 0 \\ \ln(Y_t), \lambda = 0, \end{cases} \quad (2.3)$$

dengan λ disebut parameter transformasi. Berdasarkan persamaan (2.3) dan penyederhanaan terhadap konstanta yang dapat diabaikan, diperoleh hasil transformasi nilai Y_t dari beberapa nilai λ yang umum digunakan. Hasil tersebut disajikan dalam Tabel 1 [9].

Tabel 1. Nilai Lambda

λ	Bentuk Transformasi
-1	$\frac{1}{Y_t}$
-0.5	$\frac{1}{\sqrt{Y_t}}$
0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1	Y_t (tidak ditransformasi)

2.2. Uji Perubahan Struktur

Uji perubahan struktur digunakan pada model regresi linear dengan dua *state* atau dengan satu *break* (breakpoint yang diketahui). Pengujian ini dilakukan dengan uji *Chow* dengan hipotesis sebagai berikut [7].

$H_0 : \delta = 0$ (tidak terdapat perubahan struktur)

$H_1 : \delta \neq 0$ (terdapat perubahan struktur)

Statistik uji:

$$F = \frac{(RSS_c - (RSS_1 + RSS_2))/s}{(RSS_1 + RSS_2)/(T - 2s)}, \quad (2.4)$$

dengan

RSS_c : Jumlah kuadrat residual model regresi dengan keseluruhan data (T),

RSS_1 : Jumlah kuadrat residual model regresi sebelum terjadinya break,

RSS_2 : Jumlah kuadrat residual model regresi setelah terjadinya break,

s : Banyaknya parameter yang diestimasi,

T : Banyaknya data pengamatan.

Jika statistik uji F lebih besar dari nilai $F_{\alpha, s, T-2s}$ atau nilai p -value kurang dari tingkat signifikan $\alpha = 0.05$ maka H_0 ditolak.

2.3. Markov Switching Autoregressive (MSAR)

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

Markov Switching Autoregressive [3]:

$$(y_t - \mu_{s_t}) = \sum_{p=1}^N \phi_p (y_{t-p} - \mu_{s_{t-p}}) + \epsilon_t, \quad (2.5)$$

dimana $\{y_t\}$ adalah data pengamatan, ϕ_p adalah koefisien *autoregressive*, s_t adalah state pada waktu t , μ_{s_t} konstanta yang bergantung pada state s_t dan ϵ_t residual pada waktu t dimana, $\epsilon_t \sim iidN(0, \sigma^2)$.

Untuk menduga nilai dari masing-masing parameter pada model dilakukan estimasi parameter. Estimasi parameter model MSAR menggunakan metode pendugaan kemungkinan maksimum *Maximum Likelihood Estimation* (MLE). Fungsi densitasnya sebagai berikut [5].

$$f(y_t | s_t, s_{t-1}, \Omega_{t-1}; \boldsymbol{\theta}) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[\frac{-((y_t - \mu_{s_t}) - \phi_1(y_{t-1} - \mu_{s_{t-1}}))^2}{2\sigma^2} \right], \quad (2.6)$$

dimana $\Omega_{t-1} = \{y_{t-1}, y_{t-2}, \dots, y_1\}$ adalah populasi data pengamatan, dan $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma^2, \phi_1)$ adalah populasi parameter model *MS(2)-AR(1)*. Fungsi densitas y_t bergantung pada nilai s_t dan s_{t-1} sedangkan kedua nilai tersebut nilainya tidak diketahui secara langsung melainkan diketahui berdasarkan karakteristik data pengamatan. Untuk itu, Hamilton menggunakan algoritma *filtering* dan *smoothing* untuk mengetahui peluang suatu data pengamatan berada pada *state* tertentu, kemudian mengkombinasikannya dengan metode MLE, sehingga diperoleh pendugaan parameter sebagai berikut [5].

$$\hat{\mu}_j = \frac{\sum_{t=1}^T y_t P(s_t = j | y_t; \boldsymbol{\theta})}{\sum_{t=1}^T P(s_t = j | y_t; \boldsymbol{\theta})}, \quad (2.7)$$

$$\hat{\sigma}_j^2 = \frac{\sum_{t=1}^T (y_t - \hat{\mu}_j)^2 P(s_t = j | y_t; \boldsymbol{\theta})}{\sum_{t=1}^T P(s_t = j | y_t; \boldsymbol{\theta})}, \quad (2.8)$$

$$\hat{p}_{ij} = \frac{\sum_{t=2}^T P(s_t = j, s_{t-1} = i | \Omega_T; \boldsymbol{\theta})}{\sum_{t=2}^T P(s_{t-1} = i | \Omega_T; \boldsymbol{\theta})}, \quad (2.9)$$

$$\hat{\phi}_p = \frac{\sum_{t=1}^T \left(\sum_{j=1}^{N=1} (y_t - \hat{\mu}_j) P(s_t = j | \Omega_T; \boldsymbol{\theta}) \right)}{\sum_{t=1}^T \left(\sum_{j=1}^{N=2} P(s_t = j | \Omega_T; \boldsymbol{\theta}) \right)}. \quad (2.10)$$

Dengan model MSAR juga dapat dihitung durasi masing-masing *state*. Durasi dari *state* j dihitung dengan persamaan berikut [10].

$$D = \frac{1}{1 - p_{jj}}. \quad (2.11)$$

2.4. Pemilihan Model Terbaik

Penentuan model terbaik dapat dilakukan dengan perbandingan nilai terkecil dari *Akaike Information Criterion* (AIC), *Hannan and Quinn Criterion* (HQC), dan *Schwartz Criterion* (SC) dengan persamaan sebagai berikut [4].

$$AIC = -2 \log \hat{\sigma}^2 + 2k, \quad (2.12)$$

$$BIC = \log \hat{\sigma}^2 + \frac{k \log(n)}{n}, \quad (2.13)$$

$$HQC = -2 \log \hat{\sigma}^2 + 2k \log(\log(n)), \quad (2.14)$$

dimana:

- $\log \hat{\sigma}^2$: ukuran *likelihood*,
- k : banyaknya parameter,
- n : banyak pengamatan.

3. Metode Penelitian

Data pada penelitian ini merupakan data sekunder. Data yang digunakan merupakan data *time series* bulanan inflasi DKI Jakarta dalam periode Januari 2017 sampai Desember 2021 [2].

Langkah-langkah analisis data yang dilakukan sebagai berikut.

- (1) Analisis deskripsi data.
- (2) Kestasioneritasan data.
- (3) Pemodelan MSAR.
- (4) Pemilihan model terbaik.
- (5) Dugaan durasi *state*.


4. Hasil dan Pembahasan

4.1. Deskripsi Data

Pada penelitian ini data yang digunakan adalah data bulanan inflasi DKI Jakarta pada periode Januari 2017 sampai Desember 2021 berjumlah 60 data dapat dilihat pada Gambar 1. Diketahui pada Gambar 1 inflasi tertinggi terjadi pada Januari 2017 sebesar 0,99000. Inflasi DKI Jakarta terendah terjadi pada Juni 2021 sebesar 0,27000. Rata-rata inflasi DKI Jakarta selama periode Januari 2017 sampai Desember 2021 adalah sebesar 0,219500 dan ragamnya sebesar 0,223655. Dapat dilihat pada Gambar 1 sepanjang kurun waktu 60 bulan terlihat bahwa data berfluktuasi hampir disetiap periodenya. Hal ini mengindikasikan adanya perubahan kondisi pada data inflasi DKI Jakarta.

4.2. Kestasioneran Data

Kestasioneran data terbagi menjadi dua, stasioner terhadap nilai tengah dan stasioner terhadap varian. Untuk mengetahui kestasioneran data terhadap nilai tengah dapat dilakukan uji ADF.




Gambar 1. Plot data inflasi DKI Jakarta

Tabel 2. Uji *ADF* data inflasi DKI Jakarta

	t-statistic	Probabilitas
<i>Augmented Dickey-Fuller Test Statistic</i>	-6.016240	0.0000
<i>Test critical values: 0.05 level</i>	-2.911730	

Hasil pengujian di atas menunjukkan bahwa nilai mutlak dari statistik uji *ADF* lebih besar dari nilai mutlak kritis tabel-t *ADF* pada taraf signifikan 0.05, sehingga dapat disimpulkan bahwa H_0 ditolak, artinya inflasi DKI Jakarta stasioner terhadap nilai tengah. Selanjutnya, dilakukan pengujian stasioneritas terhadap varian menggunakan metode *Box-Cox*. Dalam penggunaan metode ini, data yang digunakan memiliki syarat bernilai > 0 . Pada data inflasi DKI Jakarta yang digunakan data memiliki nilai ≤ 0 maka perlu dilakukan penambahan suatu konstanta agar data dapat memenuhi syarat, pada penulisan ini penulis menggunakan konstanta = 1. Adapun hasil pengujian transformasi *Box-Cox* diberikan pada Gambar 2 sebagai berikut.




Gambar 2. *Box-Cox* Plot Sebelum Transformasi

Dari Gambar 2 terlihat bahwa nilai *rounded value*(λ) yang diperoleh sebesar 0,5. Data ini dapat disimpulkan tidak stasioner terhadap ragam sehingga jenis transformasi yang dilakukan adalah $\sqrt{Y_t}$.

Tabel 3. Transformasi Data Inflasi

Y_t	$Z_t = \sqrt{Y_{t+1}}$
0.99	1.410673
0.33	1.153256

Pada Gambar 3 diberikan plot sesudah transformasi pada data inflasi DKI Jakarta yaitu:



Gambar 3. *Box-Cox* Plot Sesudah Transformasi

Dari Gambar 3 terlihat bahwa nilai *rounded value* (λ) yang diperoleh sebesar 1,00. Hal ini berarti, data inflasi DKI Jakarta telah stasioner terhadap ragam.


4.3. Pemodelan MSAR

Sebelum melakukan estimasi model MSAR, dilakukan identifikasi $AR(p)$ yang akan digunakan, dengan melihat plot ACF dan PACF sebagai dasar pembentukan model yang akan diestimasi.

Gambar 4 menunjukkan lag terputus pada lag-1 sehingga kandidat model yang dihasilkan adalah AR(1) dan MA(1). Namun pada penulisan ini hanya akan dibahas MSAR, sehingga hanya terdapat satu kandidat model *autoregressive* yang dipilih yaitu AR(1). Selanjutnya, dilakukan uji perubahan struktur pada data untuk mengetahui apakah suatu data mengalami perubahan pola data atau tidak menggunakan uji *chow* sebagai berikut.

Tabel 4. Hasil Uji Perubahan Struktur

Periode	F-statistic	Probabilitas
Maret 2017	7,633693	0,0077



Gambar 4. Plot ACF dan PACF inflasi DKI Jakarta

Dari Tabel 4 diketahui bahwa terdapat periode pada inflasi DKI Jakarta mempunyai nilai F -stat lebih besar dari nilai $F_{0.05,1,58} = 4,0069$ dan probabilitas kurang dari tingkat signifikansi $\alpha = 0,05$ sehingga H_0 ditolak. Artinya, dapat dikatakan data inflasi DKI Jakarta mengalami perubahan struktur.

Setelah diketahui adanya perubahan struktur pada data dilanjutkan dengan identifikasi model MSAR yang akan digunakan. Pada penelitian ini, orde $MS(m)$ yang digunakan adalah $m = 2$ dan 3 . Untuk orde AR yang digunakan adalah orde yang terpilih ketika melakukan identifikasi model AR yaitu AR(1). Oleh karena itu, dalam penulisan ini akan diselidiki manakah diantara MS(2) atau MS(3) yang lebih baik dalam menggambarkan data inflasi DKI Jakarta. Diperoleh hasil estimasi parameter terhadap MS(2)AR(1) dan MS(3)AR(1) sebagai berikut.

Tabel 5. Hasil Estimasi Parameter

	MS(2)AR(1)	MS(3)AR(1)
μ_1	1,164987(0,0000)	1,182444(0,0000)
μ_2	1,019772 (0,0000)	1,113173(0,0000)
μ_3	-	1,011239 (0,0000)
ϕ_1	0,319530 (0,0136)	0,325407 (0,0158)
σ	0,054131 (0,0000)	0,04781 (0,0000)
p_{11}	0,729880	0,581171
p_{22}	0,732562	0,457293
p_{33}	-	0,669167

Tabel 5 menunjukkan nilai koefisien dari masing-masing parameter model, dan juga nilai probabilitasnya yang dituliskan di dalam kurung, dengan μ_j menyatakan rata-rata pada kondisi saat j , σ menyatakan besar varian, ϕ_1 adalah parameter *auto-regressive* pertama, dan p_{jj} adalah peluang transisi yang bertahan pada suatu kondisi j . Terlihat juga bahwa nilai probabilitas dari seluruh koefisien parameter <

0.05, ini menunjukkan bahwa parameter dari model MS(2)AR(1) dan MS(3)AR(1) sudah signifikan.

4.4. 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. Berikut perbandingan nilai AIC, HQC, dan SC dari model MS(2)AR(1) dan MS(3)AR(1).

Tabel 6. Perbandingan Nilai AIC, HQC dan SC

Model	AIC	HQC	SC
MS(2)AR(1)	-1,9640	-1.8816	-1.7528
MS(3)AR(1)	-1.8956	-1.7444	-1.5082

Berdasarkan Tabel 6 terlihat bahwa MS(2)AR(1) memiliki nilai AIC, HQC, dan SC terkecil. Hal ini berarti data inflasi DKI Jakarta cukup digambarkan dengan 2 *state* yaitu, kondisi peningkatan inflasi dan penurunan inflasi DKI Jakarta periode Januari 2017 hingga Desember 2021. Model MS(2)AR(1) dapat dituliskan sebagai berikut.

$$(z_t - \mu_{s_t}) = 0,319530(z_{t-1} - \mu_{s_{t-1}}) + \epsilon_t, \quad (4.1)$$

dimana

$$\mu_{s_t} = \begin{cases} 1,164987, & \text{jika } s_t = 1, \\ 1,019772, & \text{jika } s_t = 2, \end{cases}$$

dengan $s_t = 1$ menyatakan kondisi peningkatan dan $s_t = 2$ menyatakan kondisi penurunan.

4.5. Durasi State

Berdasarkan hasil estimasi parameter model MS(2)AR(1) diperoleh nilai probabilitas $p_{11} = 0,729880$ dan nilai probabilitas $p_{22} = 0,732562$, maka nilai tersebut dapat dituliskan ke dalam bentuk matriks transisi MS(2)AR(1) sebagai berikut.

$$\begin{aligned} \mathbf{P} &= \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}, \\ &= \begin{pmatrix} 0,729880 & 0,270120 \\ 0,267438 & 0,732562 \end{pmatrix}. \end{aligned}$$

Dari probabilitas matriks transisi di atas, dapat diketahui bahwa probabilitas inflasi DKI Jakarta untuk bertahan pada *state* 1 sebesar 0,729880. Kemudian probabilitas inflasi DKI Jakarta mengalami perubahan *state* 1 ke *state* 2, yaitu sebesar 0.270120. Demikian juga halnya dalam kasus *state* 2, dimana probabilitas transisi dari *state* 2 ke *state* 1 sebesar 0.267438 dan probabilitas inflasi DKI Jakarta bertahan pada *state*

2 sebesar 0,732562. Dengan persamaan 2.11 dapat diketahui secara keseluruhan lama durasi dari peningkatan inflasi DKI Jakarta yaitu sebesar 3,702058 bulan, sedangkan durasi dari penurunan sebesar 3,200829 bulan.

5. Kesimpulan

Model *Markov Switching Autoregressive* (MSAR) yang terbaik dalam memodelkan inflasi DKI Jakarta pada periode Januari 2017 hingga Desember 2021 adalah MS(2)AR(1), dengan bentuk model sebagai berikut:

$$(z_t - \mu_{s_t}) = 0,319530(z_{t-1} - \mu_{s_{t-1}}) + \epsilon_t,$$

dengan $\mu_1 = 1,164987$ dan $\mu_2 = 1,019772$. Namun dalam penggunaannya, hasil dari model di atas perlu dilakukan transformasi kembali ke bentuk y_t sebagai berikut.

$$y_t = z_t^2 - 1.$$

Peluang inflasi DKI Jakarta saat t untuk bertahan pada kondisi peningkatan, sebesar 0,729880. Kemudian, peluang inflasi DKI Jakarta mengalami perubahan kondisi peningkatan ke kondisi penurunan yaitu sebesar 0,270120. Peluang inflasi DKI Jakarta saat t untuk bertahan pada kondisi penurunan sebesar 0,732562 dan peluang transisi dari kondisi penurunan ke kondisi peningkatan sebesar 0,267438.

Durasi inflasi DKI Jakarta mengalami kondisi peningkatan yaitu selama 3,702058 bulan dan durasi inflasi DKI Jakarta mengalami kondisi penurunan, yaitu selama 3,200829 bulan.

Daftar Pustaka

- [1] Ariyani, F. D., B. Warsito, H. Yasin. 2014. Pemodelan Markov Switching Autoregressive. *Jurnal Gaussian*. **3**(3): 381 – 390
- [2] BPS Provinsi DKI Jakarta. 2022. Inflasi <https://jakarta.bps.go.id>.
- [3] Cheng, J. 2016. A transitional Markov switching autoregressive model. *Communications in Statistics - Theory and Methods*. **45**(10): 2785 – 2800
- [4] Devianto, D., Maiyastri, S. Damayanti. 2015. Forecasting Long Memory Time Series for Stock Price with Autoregressive Fractionally Integrated Moving Average. *International Journal of Applied Mathematics and Statistics*. **53**(5): 86 - 95
- [5] Devianto, D., Maiyastri, U. A. Wisza, M. Wara, P. Permathasari, R. O. Marlina Zen, 2018, Time Series of Rainfall Model with Markov Switching Autoregressive. *International Conference on Applied Information Technology and Innovation (ICAITI)*: 202 – 207
- [6] Masyhuri, A.K. 2008. *Penerapan Kebijakan Moneter dalam Kerangka Inflation Targeting di Indonesia*. Pusat Pendidikan dan Studi Kebanksentralan Bank Indonesia, Jakarta
- [7] Mamuroh, Sudarno, H. Yasin, 2014, Identifikasi Breakpoint dan Pemodelan Autoregressive Structural Change Pada Data Runtun Waktu, *Jurnal Gaussian* Vol. **3**(1): 91 – 100
- [8] Paparoditis, E., Politis, D. N., 2016, The Asymptotic Size and Power of The Augmented DickeyFuller Test For a Unit Root. *Econometric Reviews* Vol. **37**(9): 955 – 973

- [9] Vlez, J. I., Correa, J. C., Marmolejo-Ramos, F., 2015, A New Approach to The BoxCox Transformation, *Frontiers in Applied Mathematics and Statistics* 1: 12
- [10] Wizza, U. A., D. Devianto, Maiyastri, 2016, Model Laju Perubahan Nilai Tukar Rupiah (IDR) Terhadap Poundsterling (GBP) dengan Metode Markov Switching Autoregressive (MSAR), *Jurnal Matematika UNAND* Vol. **5**(3): 56 – 54