
PERAMALAN DENGAN METODE SARIMA PADA DATA INFLASI DAN IDENTIFIKASI TIPE *OUTLIER*

(Studi Kasus: Data Inflasi Indonesia Tahun 2008-2014)

Iin Fadliani¹, Ika Purnamasari², Wasono³

¹Laboratorium Statistika Ekonomi dan Bisnis FMIPA Universitas Mulawarman

²Laboratorium Matematika Komputasi FMIPA Universitas Mulawarman

E-mail: ¹iinfadlianiy@gmail.com, ²ika.purnamasari@fmipa.umul.ac.id,

³wason.khayla32@gmail.com

ABSTRACT

Inflation is defined as rising prices of goods in general and continuously. The effect of inflation on the economy can cause the currency to decline, resulting in the country's economic power becoming weak. Time series data is data arranged in order of time or data collected over time. Changes in the inflation rate tend to make inflation data unstable and affect the forecasting process in the time series data. The method used in this study is the seasonal autoregressive integrated moving (SARIMA) method to predict the time series in one or two periods ahead. This study also used outlier identifiers on models that still have outlier tendencies in residuals. The forecasting results of the SARIMA method become inaccurate when residual data contains outliers. The presence of outlier data in residual data results in residuals is not a normal distribution. The method used obtained the best model results, namely the SARIMA model (0,1,1) (0,1,1)₁₂ with inflation forecast value for January to May 2015 is in the range of 5-6 %. On SARIMA models (0,1,1) (1,1,1)₁₂ and SARIMA models (1,1,0) (2,1,0)₁₂ outliers are detected in residual are Additive Outlier (AO) and Temporary Change (TC) type.

Keywords: Additive Outlier, Inflation, SARIMA, Temporary Change

PENDAHULUAN

Peramalan merupakan suatu kegiatan yang dilakukan untuk mengukur ketidakpastian masa depan dan sebagai upaya membantu perusahaan atau pemerintah untuk mengambil suatu keputusan. Peramalan pada umumnya dilakukan pada data *time series*. Data *time series* adalah data yang terurut berdasarkan waktu. Peramalan pada data *time series* adalah peramalan dengan menggunakan analisa pola hubungan antara variabel yang akan diramalkan dengan variabel waktu.

Salah satu metode dalam ilmu peramalan pada data *time series* yaitu *Autoregressive Integrated Moving Average* (ARIMA). Metode ARIMA adalah metode peramalan yang dikembangkan oleh George Box dan

Jenkins yang sering juga disebut metode runtun waktu Box-Jenkins. Pada model ARIMA sendiri mengalami perkembangan menjadi metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Model SARIMA hampir mirip dengan model ARIMA hanya saja pada model SARIMA ada penambahan periode musiman pada data *time series*.

Deteksi *outlier* telah menjadi bagian penting dari analisis *time series* dan dapat mempengaruhi permodelan, pengujian, dan inferensi, karena pencilan dapat mengarah ke model yang salah saat proses pengidentifikasian model, estimasi parameter yang bias, prakiraan yang buruk dan tidak tepat. *Outlier* adalah suatu data

yang ekstrim (menyimpang) dari pola sekumpulan data yang lain [3].

Outlier untuk data *time series* terdiri dari empat tipe yaitu *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC). Empat tipe *outlier* mempengaruhi rangkaian waktu yang diamati dengan cara yang berbeda. Efeknya dari *outlier* tipe AO, TC dan LS, tidak sama sekali mempengaruhi model ARIMA sedangkan efek IO adalah data *time series* yang diamati dari guncangan awal terjadinya *outlier* akan merambat pada pengamatan selanjutnya dan memberikan pengaruh pada model ARIMA [2].

Pendeteksian terhadap *outlier* pada suatu data dilakukan dengan menguji efek *outlier* terhadap residual yang diasumsikan sebagai parameter dari deret waktu yang diteliti. Berdasarkan uraian diatas, penelitian ini ingin mengetahui tipe *outlier* pada data inflasi di Indonesia pada model ARIMA Musiman, maka tugas akhir ini akan menganalisis tentang identifikasi tipe *outlier* pada data *time series* musiman untuk data inflasi yang ada di Indonesia. **Konsep Dasar Analisis Deret Waktu**

Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilistik keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan. Analisis deret waktu diperkenalkan pada tahun 1970 oleh George E. P. Box dan Gwilym M. Jenkins melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. Sejak saat itu, deret waktu mulai banyak dikembangkan [1].

Tujuan analisis deret waktu secara umum adalah untuk menemukan bentuk atau pola variasi dari data dimasa lampau dan menggunakan pengetahuan ini untuk melakukan peramalan terhadap sifat-sifat dari data di masa yang akan datang. Data yang stasioner menjadi sangat penting, karena sifat-sifat masa lalu dari data tidak

berubah karena perubahan waktu (bersifat *time invariant*) dan dapat digunakan untuk meramalkan sifat-sifat data di masa yang akan datang [8].

Stasioneritas

Ciri-ciri pembentukan model analisis runtun waktu adalah dengan mengasumsikan bahwa data dalam keadaan stasioner. Runtun waktu dikatakan stasioner jika tidak ada perubahan kecenderungan dalam rata-rata dan perubahan variansi. Dengan kata lain, runtun waktu yang stasioner adalah relatif tidak terjadi kenaikan atau penurunan nilai secara tajam pada data (fluktuasi data berada pada sekitar nilai rata-rata yang konstan).

Kondisi stasioner terdiri atas dua hal, yaitu stasioner dalam rata-rata dan stasioner dalam variansi. Bila kondisi stasioner dalam variansi tidak terpenuhi, box dan Cox (1964) dalam [1] memperkenalkan transformasi pangkat (*power transformation*) untuk menstabilkan.

Menurut [5], apabila data tidak stasioner pada rata-rata, maka dapat dikonversikan menjadi runtun data stasioner melalui *differencing*, yaitu runtun data asli diganti dengan selisih.

Metode Box-Jenkins

Model *Autoregressive Integrated Moving Average* (ARIMA) terdiri dari dua aspek, yaitu *Autoregressive* dan *Moving Average* (rata-rata bergerak). Secara umum, model ARIMA ini dituliskan dengan notasi ARIMA (p,d,q) dimana p menyatakan orde dari proses *Autoregressive* (AR), d menyatakan perbedaan (*differencing*), dan q menyatakan orde dari proses *Moving Average* (MA).

Dasar dari pendekatan Box dan Jenkins terdiri dari empat tahap, yaitu:

1. Identifikasi model,
2. Penaksiran (*estimation*) parameter
3. Pemeriksaan diagnostik

4. Peramalan

Identifikasi Model

Sebelum melakukan analisis lanjutan terhadap data deret waktu, hal yang paling penting dilakukan adalah mengidentifikasi karakteristik data. Penetapan karakteristik seperti stasioner, musiman, non musiman, dan sebagainya memerlukan suatu pendekatan yang sistematis dan hal ini akan menolong untuk mendapatkan gambaran yang jelas mengenai model-model yang akan digunakan [1].

Apabila kondisi stasioner baik dalam rata-rata maupun dalam variansi sudah dipenuhi, langkah selanjutnya adalah menentukan model sementara menggunakan grafik FOK dan grafik FOKP. Melalui grafik FOK dan grafik FOKP, dapat ditentukan orde berapa data yang sedang dianalisis.

Pemeriksaan Diagnostik

Menurut [1], pemeriksaan diagnostik (*diagnostic checking*) dapat dibagi menjadi dua bagian, yaitu uji signifikansi parameter dan uji kesesuaian model (meliputi uji asumsi *white noise* dan residual distribusi normal). Pengujian asumsi *residual white noise* menggunakan statistik uji Ljung-Box, dan pengujian asumsi *residual* berdistribusi normal menggunakan statistik uji Kolmogorov-Smirnov [1].

1. Uji Signifikansi Parameter Model

Menurut [1], model ARIMA (p,d,q) yang baik dapat menggambarkan suatu kejadian adalah model yang salah satunya menunjukkan bahwa penaksiran parameternya signifikan berbeda dengan nol. Misalkan θ adalah suatu parameter pada model ARIMA (p,d,q) dan $\hat{\theta}$ adalah nilai taksiran dari parameter tersebut, serta SE ($\hat{\theta}$) adalah *standard residual* dari nilai taksiran $\hat{\theta}$.

2. Uji Kesesuaian Model

Uji kesesuaian model meliputi kecukupan model (uji apakah residual

white noise) dan uji asumsi distribusi normal.

a. Pengujian Residual *White noise*

Secara ringkas, uji residual *white noise* dapat dituliskan sebagai berikut :

a. Merumuskan hipotesis

H_0 : Model sudah memenuhi syarat cukup (residual memenuhi syarat *white noise*).

H_1 : Model belum memenuhi syarat cukup (residual tidak memenuhi syarat *white noise*).

Atau dapat ditulis sebagai berikut:

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k$ (tidak ada korelasi antar residual)

H_1 : Minimal ada satu $\rho_j \neq 0$, $j=1,2, \dots, k$ (ada korelasi antar residual)

b. Menentukan nilai tingkat signifikansi (α) yang digunakan.

c. Statistik uji yang digunakan yaitu statistik uji *Ljung-Box* atau *Box-pierce Modifect*:

$$Q = m(m + 2) \sum_{j=1}^k \frac{\hat{\rho}_j^2}{(m - j)} \quad (1)$$

Statistik Q berdistribusi χ^2 dengan derajat bebas (k-n), di mana k adalah lag maksimum dan n adalah banyaknya parameter pada model.

d. Menentukan daerah kritik (daerah penolakan) H_0 yaitu: Menolak H_0 jika nilai $Q > \chi^2_{(\alpha; k-n)}$, dengan $\chi^2_{(\alpha; k-n)}$ dapat diperoleh dari tabel *chi-square* atau $P\text{-value} < \alpha$

e. Menarik kesimpulan.

b. Pengujian Residual Berdistribusi Normal

Menurut [1], uji asumsi ini bertujuan untuk mengetahui apakah data telah memenuhi asumsi kenormalan atau belum. Salah satu cara yang dapat ditempuh untuk melakukan uji asumsi kenormalan ini adalah uji *Kolmogorov-Smirnov* dengan menggunakan pedoman

pengambilan keputusan sebagai berikut:

Tahapan dalam pengujian kenormalan residual adalah sebagai berikut:

- a. Merumuskan Hipotesis
 - H_0 : *Residual* berdistribusi normal
 - H_1 : *Residual* tidak berdistribusi normal.
- b. Menentukan nilai tigtat signifikansi (α) yang digunakan Z_t

Menentukan statistik uji yang digunakan, yaitu:

$$D = \text{Sup} |F_\theta(X) - S_n(X)| \quad (2)$$

dimana:

sup : supremum dari sejumlah jarak D kumulatif relatif dari data

$S_n(X)$: Frekuensi kumulatif teoritis dari data

D : nilai *Kolmogorov-smirnov Test*

- c. Menentukan daerah kritik (daerah penolakan) H_0 , yaitu :
Menolak H_0 jika nilai $D > D_{(n,\alpha)}$ atau $p\text{-value} < \alpha$
- d. Menarik keputusan dan kesimpulan

Kriteria Pemilihan Model Terbaik

Menurut [1], pada pemodelan data runtun waktu ada kemungkinan terdapat beberapa model yang sesuai yaitu semua parameternya signifikan, residual memenuhi asumsi *white noise* serta berdistribusi normal. Untuk menentukan model yang terbaik dari beberapa model yang memenuhi syarat tersebut dapat digunakan beberapa kriteria antara kriteria *Akaike's Information Criterion* (AIC). Model terbaik akan dipilih apabila memiliki nilai kriteria terkecil.

Efek Outlier

Outlier adalah dua pengamatan yang tidak konsisten pada seriesnya. Efek kejadian tersebut dapat dihitung dengan model intervensi jika waktu dan penyebab diketahui. Ada empat macam jenis outlier yaitu *Innovation Outlier* (IO), *Additive Outlier* (AO), *Temporary Change* (TC), dan *Level Shift* (LS). Deteksi outlier

pertama kali dikemukakan Fox (1972) dalam [10] yang memperkenalkan *outlier* tipe 1 atau *Additive Outlier* (AO) dan tipe 2 atau *Innovation Outlier* (IO).

a. Additive Outlier (AO)

Additive Outlier adalah kejadian yang mempunyai efek pada data deret waktu hanya pada satu periode saja yaitu pada pengamatan ke-T.

bentuk umum sebuah *Additive Outlier* (AO) dalam proses ARMA diuraikan sebagai berikut :

$$Z_t = \begin{cases} X_t & t \neq T \\ X_t + \omega, & t = T \end{cases}$$

Sehingga nilai Z_t pada $t=T$ adalah :

$$Z_t = X_t + \omega I_t^{(T)} = \frac{\theta(B)}{\phi(B)} \alpha_t + \omega I_t^{(T)} \quad (3)$$

Dimana X_t adalah data tanpa *outlier*, Z_t adalah data pengamatan, ω adalah bobot dari AO dan $I_t^{(T)}$ adalah sebuah variabel waktu yang digunakan untuk menunjukkan terjadinya sebuah AO, di mana :

$$I_t^{(T)} = \begin{cases} 0 & t \neq T \\ 1 & t = T \end{cases}$$

b. Innovation Outliers

Innovation Outliers adalah kejadian yang efeknya mengikuti proses ARMA. Bertentangan dengan jenis outlier lain, efek IO bergantung pada model yang dipilih dan pada estimasi parameter.

Dalam hal ini diperlihatkan bahwa, dalam beberapa keadaan, pengaruh IO dapat meningkat karena tanggal kemunculannya menjadi lebih jauh ke masa lalu, yang merupakan sesuatu yang sulit ditafsirkan atau diasumsikan. IO memiliki potensi yang menarik karena dapat menangkap *outlier* musiman. Jenis *outlier* lain tidak dapat menangkap pola musiman. Namun demikian, dalam beberapa kasus mungkin lebih baik untuk mencari pergeseran tingkat musiman. Bentuk umum sebuah *Innovation Outliers* didefinisikan sebagai berikut :

$$= X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)}$$

$$\begin{aligned}
 &= \frac{\theta(B)}{\phi(B)} \alpha_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \\
 &= \frac{\theta(B)}{\phi(B)} (\alpha_t + \omega I_t^{(T)}) \quad (4)
 \end{aligned}$$

dimana X_t adalah data tanpa *outlier*, Z_t adalah data pengamatan, $\frac{\theta(B)}{\phi(B)}$ adalah model ARIMA dari data residual yang dimodelkan kembali, ω adalah bobot dari IO dan $I_t^{(T)}$ adalah sebuah variabel waktu yang digunakan untuk menunjukkan terjadinya sebuah IO, di mana :

$$I_t^{(T)} = \begin{cases} 0 & t \neq T \\ 1 & t = T \end{cases}$$

c. Level Shift (LS) dan Temporary Change (TC)

Suatu LS adalah kejadian yang mempengaruhi deret pada satu waktu tertentu yang memberikan suatu perubahan tiba-tiba dan permanen. Model outlier LS dinyatakan sebagai :

$$Z_t = X_t + \frac{1}{(1-B)} \omega I_t^{(T)} \quad (5)$$

Sedangkan TC adalah suatu kejadian di mana outlier menghasilkan efek awal sebesar ω pada waktu t , kemudian secara perlahan sesuai dengan besarnya δ . Model TC dapat dituliskan sebagai berikut :

$$Z_t = X_t + \frac{1}{(1-\delta B)} \omega I_t^{(T)} \quad (6)$$

Pada saat $\delta = 0$ maka TC akan menjadi kasus *Additive Outier* (AO), sedangkan pada saat $\delta = 1$ maka TC akan menjadi kasus *Level Shift* (LS).

Z-score

Deteksi terhadap adanya *outlier* univariat dapat dilakukan dengan menentukan nilai ambang batas yang akan dikategorikan sebagai *outlier* dengan cara mengkonversi nilai data penilaian kedalam standard *score* atau yang biasa disebut *z-score*, yang mempunyai rata-rata nol dengan standar deviasi sebesar satu. Bila nilai-nilai itu telah dinyatakan dalam format yang standar (*z-score*), maka perbandingan antar besaran nilai dengan mudah dapat dilakukan. Untuk sampel besar (di atas 80 observasi), pedoman evaluasi adalah nilai ambang batas dari *z-score* ini berada pada rentang 2 sampai

dengan 3, Oleh karena itu kasus-kasus atau observasi-observasi yang mempunyai *z-score* $> 3,0$ akan dikategorikan *outlier* [4]. *Z-score* juga sering disebut dengan nilai **baku** atau nilai **standar**. *Z-score* dapat digunakan untuk membantu menentukan apakah sebuah data bernilai ekstrem, atau *outlier*. Skor standar (*Z*) adalah angka yang merupakan perbedaan antara nilai data dan rata-rata, dibagi dengan standar deviasi. Bila dituliskan rumusnya sebagai berikut:

$$Z_t = \frac{\alpha_t - \text{mean}(\alpha_t)}{\text{stdv}(\alpha_t)} \quad (7)$$

METODOLOGI PENELITIAN

Metode Analisis SARIMA dan Identifikasi Outlier

a. Analisis Statistika Deskriptif

Menurut [7] analisis statistika deskriptif adalah analisis yang menekankan pada pembahasan data-data dan sunjek penelitian dengan menyajikan data-data secara sistematis dan tidak menyimpulkan hasil penelitian. Analisis statistika deskriptif bertujuan untuk menggambarkan dan menjelaskan keseluruhan dari data. Analisis ini dilakukan dengan bantuan *software R*.

b. Deteksi Outlier

Teknik analisis data dalam penelitian ini adalah menentukan model SARIMA dengan bantuan *software R*. Adapun beberapa tahap yang harus dilakukan dalam model SARIMA adalah sebagai berikut :

1. Identifikasi Model

Identifikasi model dilakukan dengan membuat *time series plot* (TS plot) untuk melihat apakah ada indikasi data berpola musiman atau tidak dan melihat apakah data sudah stasioner atau belum. Jika data belum stasioner dalam variansi, maka dilakukan transformasi Box-Cox. Jika data belum stasioner dalam rata-rata, maka dilakukan proses *differencing*. Untuk memastikan bahwa data telah

stasioner dalam rata-rata dapat dilakukan uji akar unit. Setelah itu, membuat grafik FOK dan grafik FOKP menggunakan data yang telah stasioner untuk menentukan model-model SARIMA sementara.

2. Penaksiran Parameter Model Sementara

Setelah orde SARIMA $(p,d,q)(P,D,Q)^S$ diperoleh, maka tahap selanjutnya adalah menaksir parameter model sementara. Penaksiran parameter ini dilakukan dengan mempertimbangkan *lags* pada grafik FOKP untuk parameter AR dan grafik FOK untuk parameter MA.

3. Pemeriksaan Diagnostik

Pemeriksaan diagnostik dibagi menjadi dua tahap, yaitu pengujian signifikansi parameter model SARIMA sementara dan pengujian kesesuaian model. Pengujian kesesuaian model terbagi menjadi dua pengujian, yaitu pengujian asumsi *residual white noise* dengan menggunakan statistik uji Ljung-Box dan pengujian asumsi *residual* berdistribusi normal dengan menggunakan statistik uji Kolmogorov-Smirnov.

4. Kriteria Pemilihan Model Terbaik

Apabila terdapat lebih dari satu model yang memenuhi syarat, maka dilakukan pemilihan model terbaik. Dalam penelitian ini digunakan kriteria AIC untuk memilih model terbaik.

5. Untuk model yang tidak memenuhi syarat pemeriksaan diagnosa yaitu pada pengujian asumsi *residual* berdistribusi normal tidak terpenuhi maka akan dilakukan deteksi outlier.

6. Pendeteksian *Outlier*


Mendeteksi adanya *outlier* yaitu dengan membuat plot *z-score* pada data *residual*.

7. Pendeteksian tipe *outlier* dan penentuan periode data yang terjadi *outlier*

8. Pengidentifikasian *outlier* dapat dilihat dari plot *z-score* pada data residual model kemudian melihat tipe *outlier* apa saja yang muncul pada plot tersebut dapat ditentukan dengan menggunakan bantuan *software R*.

HASIL PENELITIAN DAN PEMBAHASAN

Hasil analisis diketahui bahwa inflasi tertinggi di Indonesia terjadi pada bulan september 2008 yaitu sebesar 12,14%, di mana pada periode tersebut terjadi kenaikan yang cukup ekstrim dibandingkan periode lainnya sedangkan terjadi penurunan terendah pada bulan November 2009 sebesar 2,41%. Grafik runtun waktu inflasi Indonesia dari waktu ke waktu cenderung membentuk pola musiman karena pada data terlihat pola data yang berulang. Pola berulang terjadi dalam periode tahunan atau periode dua belas bulan. Berdasarkan Gambar 1 terlihat *time series* plot belum stasioner dalam variansi selanjutnya akan dilakukan transformasi pangkat untuk menstasionerkan dalam variansi.




Gambar 1. Grafik runtun waktu data inflasi Indonesia tahun 2008-2014 (Z_t)

1. Identifikasi model sementara


Estimasi nilai λ yang diperoleh sebelum dilakukan transformasi Box-Cox adalah sebesar 0,04529299 yang menunjukkan nilai tersebut belum mendekati 1 sehingga diketahui belum stasioner dalam variansi. Dengan demikian data inflasi Tahun 2008-2014 tersebut perlu dilakukan transformasi

menggunakan transformasi pangkat (Z_{1t}^λ) dan diperoleh nilai λ sebesar 0,9999998 yang menunjukkan bahwa benar data telah stasioner dalam variansi karena telah mendekati nilai 1 dan berikut grafik FOK data Inflasi Indonesia periode tahun 2008-2014 setelah transformasi (Z_{1t}^*) yang ditampilkan pada Gambar 2 sebagai berikut:




Gambar 2. Grafik FOK Z_{1t}^*

Berdasarkan Gambar 2 dapat diketahui bahwa data Z_{1t}^* belum stasioner dalam rata-rata, dikarenakan data cenderung fluktuatif dan tidak berada disekitar nilai rata-rata yang konstan dari waktu ke waktu. Pemeriksaan stasioneritas dalam rata-rata juga dapat dilakukan dengan melihat grafik FOK dan berdasarkan Gambar 2 terlihat bahwa grafik FOK cenderung turun lambat dan turun secara linier, dengan kata lain FOK pada satu lag relatif tidak jauh berbeda dengan lag sebelumnya. Sehingga dapat disimpulkan bahwa data tersebut tidak stasioner dalam rata-rata. Dengan demikian data perlu dilakukan *differencing* pada orde satu non-musiman dan *differencing* orde satu musiman $Z_{1t}^*(d=1)(D=1)$, dan diperoleh grafik runtun waktu pada Gambar 5 dan sebagai berikut :




Gambar 3 Grafik runtun waktu Z_{1t}^{**}

Berdasarkan Gambar 3 dapat diketahui bahwa data $Z_{1t}^{**}(d=1)(D=1)$ stasioner dalam rata-rata, dikarenakan data lebih terlihat berada disekitar nilai rata-rata yang konstan dari waktu ke waktu. Pemeriksaan stasioneritas dalam rata-rata dapat dilakukan lebih lanjut dengan melihat grafik FOK data yang ditunjukkan pada Gambar 4. Secara visual dapat terlihat grafik FOK telah stasioner dalam rata-rata. Grafik FOK menunjukkan bahwa terjadi *cut off* setelah *lag* 1. Hal ini menjelaskan bahwa data telah stasioner dalam rata-rata non-musiman. Selain itu, pada Gambar 4 menunjukkan bahwa grafik FOK *cut off* setelah *lag* 12, maka dapat diketahui data telah stasioner dalam rata-rata musiman.



Gambar 4 Grafik FOK data Z_{1t}^{**}



Gambar 5 Grafik FOKP Z_{1t}^{**}

Identifikasi model sementara dibentuk dengan melihat grafik FOK pada Gambar 6 dan grafik FOKP pada Gambar 7 untuk menentukan orde pada model AR dan MA baik musiman maupun non musiman. Berdasarkan Gambar 4 dapat diketahui bahwa orde untuk MA non-musiman adalah 1 (nilai FOK *cut off* setelah *lag* 1) dan berdasarkan Gambar 5 orde untuk AR non-musiman adalah 1 (nilai FOKP *cut off* setelah *lag* 1), dengan *differencing* non-musiman (d) sebanyak 1 kali. Selain itu, berdasarkan pada Gambar 5 dapat

diketahui bahwa grafik nilai FOK *cut off* setelah *lag* 12, sehingga orde untuk MA musiman adalah 1. Serta pada Gambar 5 dapat diketahui bahwa grafik nilai FOKP *cut off* setelah *lag* 12, sehingga orde untuk AR musiman adalah 2, dan orde *differencing* musiman (*D*) adalah 1. Sehingga diperoleh lima belas kombinasi model sementara.

Dari lima belas kombinasi model yang diperoleh dilakukan estimasi parameter dengan menggunakan metode *Maximum Likelihood* untuk mengetahui model yang signifikan terhadap parameternya. Setelah itu dilakukan pemeriksaan diagnostik yaitu pemeriksaan *white noise* dan kenormalan residual. Dari pengujian signifikansi parameter dan pemeriksaan diagnostik yaitu pengujian *white noise* diperoleh lima model yang memenuhi asumsi signifikan parameter dan pemeriksaan *white noise*. Selanjutnya dilakukan pengujian kenormalan residual dan diperoleh tiga model SARIMA yang memenuhi asumsi residual berdistribusi normal dapat dilihat pada Tabel 1 sebagai berikut:

Tabel 1. Model SARIMA yang memenuhi Asumsi Residual Berdistribusi Normal

Model	AIC
SARIMA (0,1,1)(0,1,1) ¹²	-281,13
SARIMA (1,1,0)(1,1,1) ¹²	-211,6
SARIMA (0,1,1)(2,1,0) ¹²	-201,19

Berdasarkan nilai AIC terkecil pada Tabel 1, maka didapatkan model SARIMA terbaik adalah SARIMA (0,1,1)(0,1,1)¹² yaitu dengan nilai AIC sebesar -281,13. Secara matematis model SARIMA(0,1,1)(0,1,1)¹² dapat ditulis dengan persamaan sebagai berikut :

$$Z_{t_r}^* = Z_{t_r-1}^* + Z_{t_r-12}^* - Z_{t_r-13}^* + 0,5918a_{t_r-1} - a_{t_r-12} + 0,5918a_{t_r-13} + a_t$$

Dengan persamaan yang diperoleh kemudian diramalkan untuk 5 periode kedepan, sehingga didapatkan hasil peramalan data Inflasi Indonesia pada bulan Januari 2015 sampai dengan bulan Mei 2015 sebagai berikut dapat dilihat pada Tabel 2

Tabel 2. Hasil Peramalan Model SARIMA (0,1,1)(0,1,1)¹²


Periode	Data peramalan inflasi	Data aktual inflasi
Januari 2015	5,98	6,96
Februari 2015	6,16	6,29
Maret 2015	6,11	6,38
April 2015	6,47	6,79
Mei 2015	6,84	7,15

Selain tiga model terbaik yang memenuhi asumsi residual berdistribusi normal terdapat dua model yang tidak memenuhi asumsi kenormalan residual. Model yang tidak memenuhi asumsi residual berdistribusi normal yaitu pada model SARIMA (0,1,1)(1,1,1)¹² dan SARIMA (0,1,1)(2,1,0)¹² yang selanjutnya akan dilakukan pendeteksian *outlier*.

2. Pendeteksian Outlier

a. Menghitung Nilai Z-score model SARIMA (0,1,1)(1,1,1)¹²

Nilai *z-score* yang diperoleh kemudian di plotkan menjadi grafik *z-score* data residual model SARIMA (0,1,1)(1,1,1)¹² pada Gambar 6 sebagai berikut :




Gambar 6. Garik Z-score SARIMA (0,1,1)(1,1,1)¹²

Berdasarkan Gambar 6 hasil pendeteksian *outlier* menggunakan nilai *z-score* yaitu nilai standardisasi residual model yang telah dihitung dan *outlier* diperoleh ketika nilai *z-score* lebih besar dari 1,96 dan lebih kecil dari -1,96. Pada gambar 6 terdapat tujuh titik data yang keluar dari batas yang telah ditentukan maka data tersebut adalah data *outlier* yang selanjutnya akan dilakukan pendeteksi tipe *outlier* dan efek *outlier* yang terjadi.

b. Menghitung Nilai Z-score model SARIMA (1,1,0) (2,1,0)¹²

Nilai *z-score* yang diperoleh kemudian di plotkan menjadi grafik *z-score* data residual model SARIMA (1,1,0)(2,1,0)¹² pada Gambar 7 sebagai berikut :

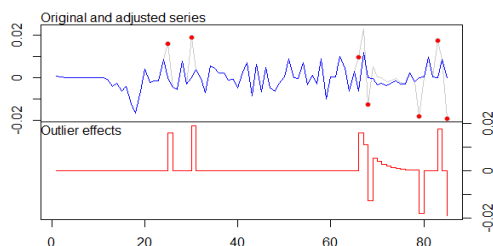


Gambar 7. Garik Z-score SARIMA (1,1,0)(2,1,0)¹²


Berdasarkan Gambar 7 hasil pendeteksian *outlier* menggunakan nilai *z-score* yaitu nilai standardisasi residual model, *outlier* yang diperoleh ketika nilai *z-score* lebih besar dari 1,96 dan lebih kecil dari -1,96. Pada gambar 7 terdapat tiga titik data yang diperoleh keluar dari batas yang telah ditentukan maka data tersebut adalah data *outlier* yang selanjutnya akan dilakukan pendeteksi tipe *outlier*.

c. Identifikasi tipe *outlier* dan periode terjadi *outlier*

Setelah mengetahui terdapat beberapa data *outlier* kemudian dideteksi kembali tipe *outlier* apa yang terdeteksi pada model dan pada periode keberapa outlier tersebut muncul serta dapat diketahui efek dari *outlier* yang terjadi. Berikut hasil pengidentifikasian tipe *outlier* dapat dilihat pada Gambar 8 dan Gambar 9



Gambar 8. Plot Tipe *outlier* data residual model SARIMA (0,1,1)(1,1,1)¹²



Gambar 9. Plot Tipe *outlier* data residual model SARIMA (1,1,0)(2,1,0)¹²

Berdasarkan Gambar 8 terdapat enam data *outlier* tipe *Additive Outlier* (AO) pada periode ke 25, 30, 68, 79, 83, 84, kemudian satu *outlier* tipe TC pada periode ke 66. Pada Gambar 8 juga dapat terlihat bahwa efek *outlier* tipe AO hanya sementara yaitu terjadi hanya satu periode waktu ke-t saja yaitu pada periode ke 25,30,68,79,83,dan 84 sedangkan efek *outlier* tipe TC sendiri dapat berubah kapan saja dan perubahannya sangat cepat jika pada saat $\delta = 0$ maka TC akan menjadi kasus *Additive Outier* (AO) dan pada saat $\delta = 1$ maka TC akan menjadi kasus *Level Shift* (LS). Sedangkan pada Gambar 9 terdapat dua *outlier* tipe *Additive Outlier* (AO) pada period eke 67 dan periode ke 84 kemudian satu *outlier tipe* TC pada periode ke 83. Pada Gambar 9 juga dapat terlihat bahwa efek *outlier* tipe AO hanya sementara yaitu terjadi hanya satu periode waktu ke t yaitu pada periode data ke 67 dan 84 saja sedangkan efek *outlier* tipe TC sendiri dapat berubah kapan saja dan perubahannya sangat cepat jika pada saat $\delta = 0$ maka TC akan menjadi kasus *Additive Outier* (AO) dan pada saat $\delta = 1$ maka TC akan menjadi kasus *Level Shift* (LS).

KESIMPULAN

Berdasarkan hasil analisis dan penelitian mengenai identifikasian tipe *outlier* pada data *time series* musiman menggunakan data Inflasi Indonesia tahun 2008-2014 maka dapat diperoleh

kesimpulan dari penelitian ini sebagai berikut:

1. Model SARIMA terbaik yang diperoleh untuk data Inflasi Indonesia periode Januari 2008–Desember 2014 adalah model SARIMA(0,1,1)(0,1,1)¹² dengan persamaan sebagai berikut :

$$Z_{it}^* = Z_{it-1}^* + Z_{it-12}^* - Z_{it-13}^* + 0,5918a_{t-1} - a_{t-12} + 0,5918a_{t-13} + a_t$$
2. Berdasarkan pengidentifikasian outlier diperoleh tujuh outlier Pada model SARIMA (0,1,1) (1,1,1)¹² yaitu terdapat enam outlier tipe AO pada periode ke 25, 30, 68, 79, 83, 84, kemudian satu outlier tipe TS pada periode ke 66. Sedangkan pada model SARIMA (1,1,0) (2,1,0)¹² terdeteksi dua outlier tipe AO pada periode ke 67 dan periode ke 84 kemudian satu outlier tipe TS pada periode ke 83.

DAFTAR PUSTAKA

- [1] Aswi dan Sukarna. (2006). *Analisis Deret Waktu: Teori dan Aplikasi*. Makassar: Andira Publisher.
- [2] Chen, C., & Liu, L. M. (1993). *Joint Estimation of Model Parameters and Outlier Effect in Time Series*. *Journal of the American Statistical Association*, 88, 284-297.
- [3] Ferguson, TS, (1961). *Pada Penolakan Outlier, Dalam Prosiding Keempat Simposium Berkelet tentang Statistik Matematika dan Probabilitas*, vol. 1, 253-287.
- [4] Hair J. F. et. Al. (1995). *"Multivariate Data Analysis With Reading"*, Fourht Edision, Prientice Hall. New Jersey.
- [5] Hanke, J.E.,Reitsch, A.G. dan Wichern,D.W. (2003). *Peramalan Bisnis*. Edisi Ketujuh. Jakarta. Alih Bahasa: Devi Anantanur. PT. Prenhallindo.
- [6] Hadi, A., Hertatik, dan Pramesti, G. (2012). *Aplikasi SPSS dalam Saham*. Jakarta: PT Elex Media Komputindo.
- [7] Priyanto. (2010). *Teknik Mudah dan Cepat Melakukan Analisis Data Penelitian dengan SPSS*. Yogyakarta. Gava Media.
- [8] Rosadi, D. (2011). *Analisis Ekonometrika dan RUntun Waktu Terapan dengan R*. Yogyakarta: ANDI.
- [9] Sukirno, S. (2004). *Makroekonomi Teori Pengantar*. Edisi ketiga. Jakarta: Rajawali Pers.
- [10] Wei, W.W.S. (2006). *Time Series Analysis: Univariate and Multivariate Methods*. Kanada: Addison Wesley Publishing Company.