

## PEMODELAN FUNGSI TRANSFER DENGAN DETEKSI OUTLIER UNTUK MEMPREDIKSI NILAI INFLASI BERDASARKAN BI RATE (Studi Kasus BI Rate dan Inflasi Periode Januari 2006 sampai Juli 2016)

Firda Dinny Islami<sup>1</sup>, Abdul Hoyyi<sup>2</sup>, Dwi Ispriyanti<sup>3</sup>

<sup>1</sup>Mahasiswa Departemen Statistika FSM Universitas Diponegoro

<sup>2,3</sup>Staf Pengajar Departemen Statistika FSM Universitas Diponegoro

### ABSTRACT

Inflation control is one of the important things in managing a country besides economic growth. Inflation received special attention in the economy of Indonesia. Every time there is a distortion in the society, politic or economic development, people always relate it to inflation. Low and stable inflation is a stimulator of economic growth. Inflation is also the final target in the monetary policy framework so the need for a central bank role to determine the policy direction. The BI Rate is one of the variables capable of controlling inflation. This study aims to forecast inflation based on the BI Rate using the transfer function model with outlier detection. The transfer function model depends on the parameters  $b$ ,  $r$ , and  $s$ . The result of the analysis has been obtained the transfer function model with the value of  $b = 1$ ,  $r = 0$ ,  $s = 1$  and the noise series ARMA (2,0). The addition of 16 outliers on the model yielded the best model with the AIC value is -868,56. The forecasting results show that the value of inflation has fluctuated, where in September 2016 it has decreased and then increased until December 2016.

**Keywords** : Inflation, BI Rate, transfer function, outlier detection, AIC

### 1. PENDAHULUAN

Inflasi merupakan salah satu permasalahan ekonomi yang dihadapi oleh hampir semua negara di dunia, hanya tingkatnya saja yang berbeda. Indonesia sebagai salah satu negara berkembang pun tak luput dari inflasi yang mempengaruhi seluruh aspek masyarakat. Seiring naik turunnya inflasi, tingkat suku bunga acuan Bank Indonesia (BI Rate) juga turut berfluktuasi. Bank Indonesia pada umumnya akan menaikkan BI rate apabila inflasi ke depan diperkirakan melampaui sasaran yang telah ditetapkan.

Metode yang dapat meramalkan BI Rate dengan inflasi salah satunya adalah metode yang dapat digunakan salah satunya adalah dengan metode fungsi transfer. Dengan memodelkan fungsi transfer, peneliti dapat memprediksi apa yang akan terjadi terhadap inflasi (deret output) jika data BI Rate (deret input) berubah. Pengamatan deret waktu seringkali ditemukan data yang nilainya jauh (ekstrim) berbeda dibanding data lainnya, nilai ekstrim tersebut dinamakan outlier /pencilan. Outlier menyebabkan kesimpulan dari analisis data menjadi tidak valid sehingga prosedur pendeteksian dan menghapus efek outlier sangat penting untuk analisis data.

### 2. TINJAUAN PUSTAKA

#### 2.1 Konsep Dasar *Time Series*

Menurut Rosadi (2012), data runtun waktu adalah data yang dikumpulkan, dicatat, atau diobservasi berdasarkan urutan waktu. Salah satu ciri dalam

pembentukan model *time series* adalah mengasumsikan data dalam keadaan stasioner. Kondisi stasioner terdiri atas dua hal yaitu stasioner dalam *mean* dan stasioner dalam varian. Uji stasioner data dalam varian dapat menggunakan transformasi *Box-Cox* yang dirumuskan sebagai berikut (Wei, 2006):

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}$$

Uji stasioner data dalam *mean* dapat menggunakan uji *Dickey Fuller*. Pada data yang tidak stasioner dalam *mean* perlu dilakukan pembedaan (*differencing*). Secara umum, apabila terdapat *differencing* orde ke-*d* maka ditulis sebagai berikut:

$$Z_t^d = (1 - B)^d Z_t$$

Suatu proses yang stasioner  $\{Z_t\}$  mempunyai rata-rata dan variansi yang konstan yaitu rata-rata  $E(Z_t) = \mu$  (konstan) dan variansi  $var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$  (konstan), serta kovariansi  $cov(Z_t, Z_s)$  yang merupakan fungsi dari perbedaan waktu  $|t-s|$ . Sehingga kovariansi antara  $Z_t$  dan  $Z_{t+k}$  dapat dituliskan sebagai berikut:

$$\gamma_k = cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu)$$

Korelasi antara  $Z_t$  dan  $Z_{t+k}$  didefinisikan sebagai:

$$\rho_k = \frac{cov(Z_t, Z_{t+k})}{\sqrt{var(Z_t)}\sqrt{var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0}$$

Sebagai fungsi dari  $k$ ,  $\gamma_k$  dinamakan fungsi autokovariansi dan  $\rho_k$  dinamakan fungsi autokorelasi (ACF). Ukuran korelasi yang lain pada analisis *time series* adalah fungsi autokorelasi parsial (PACF). Fungsi Autokorelasi Parsial (PACF) dapat dinyatakan sebagai berikut Wei (2006):

$$\phi_{kk} = Corr(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1})$$

## 2.2 Model Time Series ARIMA

Menurut (Soejoeti, 1987), beberapa model *time series* dapat dikelompokkan sebagai berikut:

1. Proses *Autoregressive* orde  $p$  atau AR ( $p$ ).  
Bentuk umum dari model AR orde  $p$ :  
 $Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$
2. Proses *Moving Average* orde  $q$  atau MA ( $q$ ).  
Bentuk umum dari model MA orde  $q$ :  
 $Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$
3. Proses *Autoregressive Moving Average* atau ARMA ( $p, q$ ).  
Bentuk umum dari model ARMA ( $p, q$ ):  
 $\phi_p(B)Z_t = \theta_q(B)a_t$   
dengan:  $\phi_p(B) = 1 - \phi_1 B^1 - \dots - \phi_p B^p$  dan  $\theta_q(B) = 1 - \theta_1 B^1 - \dots - \theta_q B^q$
4. Proses *Autoregressive Integrated Moving Average* ARIMA ( $p, d, q$ ).  
Bentuk umum dari model ARMA ( $p, q$ ):  
 $\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t$   
dengan:  $\phi_p(B) = 1 - \phi_1 B^1 - \dots - \phi_p B^p$  dan  $\theta_q(B) = 1 - \theta_1 B^1 - \dots - \theta_q B^q$

### 2.3 Pemodelan Fungsi Transfer

Menurut Wei (2006), model fungsi transfer adalah suatu model yang menggambarkan nilai prediksi masa depan dari suatu *time series* (disebut deret *output* atau  $Y_t$ ) berdasarkan pada nilai-nilai masa lalu dari deret itu sendiri dan berdasarkan pula pada satu atau lebih *time series* yang berhubungan dengan deret *output* (disebut deret *input* atau  $X_t$ ).

Model umum fungsi transfer adalah sebagai berikut:

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} x_{t-b} + \frac{\theta_q(B)}{\phi_p(B)} a_t$$

Dengan  $\omega(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s$

$$\delta(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

Tahap-tahap dalam pembentukan model fungsi transfer untuk variabel *input*  $X$  dan variabel *output*  $Y$  (Makridakis *et al.*, 1999):

#### 1. Mempersiapkan deret *input* dan deret *output*

Dalam mempersiapkan data deret *input* dan *output* untuk pemodelan fungsi transfer, apabila data tersebut tidak stasioner maka diperlukan proses *differencing* dan transformasi untuk menghilangkan ketidakstasioneran.

#### 2. *Prewhitening* deret *input*

Tahap ini dilakukan dengan tujuan untuk menghilangkan pola yang ada pada deret *input* supaya yang tertinggal hanya deret *input* yang *white noise*.

$$\alpha_t = \frac{\phi_x(B)}{\theta_x(B)} x_t$$

#### 3. *Prewhitening* deret *output*

Tahapan *prewhitening* pada deret *input*  $x_t$  harus diterapkan juga pada deret *output*  $y_t$ . Hal ini dilakukan untuk menjaga integritas hubungan fungsional karena fungsi transfer memetakan  $x_t$  ke dalam  $y_t$ . Namun transformasi pada  $y_t$  ini tidak harus mengubah  $y_t$  menjadi *white noise*.

$$\beta_t = \frac{\phi_y(B)}{\theta_y(B)} y_t$$

#### 4. Perhitungan korelasi silang dan autokorelasi untuk deret *input* dan deret *output* yang telah diputihkan.

Tahap selanjutnya adalah mendeteksi dan mengukur hubungan kekuatan antara  $\alpha_t$  dan  $\beta_t$  dengan menggunakan fungsi korelasi silang atau *Cross Correlation Function* (CCF). Sebelum menghitung korelasi silang, terlebih dahulu mengetahui kovarian silang antara dua variabel yang ditetapkan sebagai berikut:

$$C_{xy}(k) = \frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X})(Y_{t+k} - \bar{Y})$$

Adapun untuk mendapatkan korelasi silang

$$r_{xy}(k) = \hat{\rho}_{XY} = \frac{C_{XY}(k)}{\sqrt{C_{XX}(0)C_{YY}(0)}} = \frac{C_{XY}(k)}{S_X S_Y}$$

dengan  $k$  merupakan *time lag*, untuk  $k = 0, \pm 1, \pm 2, \pm 3, \dots$

#### 5. Penaksiran langsung bobot respons impuls

Setelah menghitung korelasi silang, langkah selanjutnya adalah penaksiran langsung bobot respons impuls, adapun rumus untuk penaksiran bobot respons impuls adalah sebagai berikut:

$$v_k = \frac{r_{\alpha\beta(k)}s_\beta}{s_\alpha}$$

dengan  $r_{\alpha\beta}$  merupakan korelasi silang antara deret output dan deret input yang telah diputihkan.

#### 6. Penetapan b, r, s untuk model fungsi transfer

Tiga parameter kunci dalam membentuk model fungsi transfer adalah (b, r, s), parameter r menunjukkan derajat fungsi  $\delta(B)$  yang menunjukkan seberapa lama deret output waktu-t dipengaruhi oleh deret output pada waktu t-k, s menunjukkan derajat fungsi  $\omega(B)$  yang menunjukkan seberapa lama deret *output* dipengaruhi deret *input*, dan b menunjukkan keterlambatan yang dicatat pada  $x_{t-b}$  dari persamaan:

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} x_{t-b} + \frac{\theta_q(B)}{\phi_p(B)} a_t$$

Parameter b dapat dideteksi terlebih dahulu dibandingkan parameter r dan s melalui plot *cross correlation function* (CCF) yaitu dengan melihat nilai korelasi setelah *lag* ke nol yang lebih besar dan berbeda daripada *lag* sebelumnya. Nilai r+s sama dengan jumlah *lag* pada plot CCF yang memotong garis signifikansi atau secara signifikan lebih besar dari nol.

#### 7. Pengujian pendahuluan deret *noise*

Taksiran awal dari deret *noise* didefinisikan sebagai berikut:

$$n_t = y_t - v(B)x_t$$

$$n_t = y_t - v_0x_t - v_1x_{t-1} - v_2x_{t-2} - \dots - v_gx_{t-g}$$

dengan g adalah nilai praktis yang dipilih oleh peneliti.

#### 8. Penetapan (p<sub>n</sub>,q<sub>n</sub>) untuk model ARIMA (p<sub>n</sub>,0,q<sub>n</sub>) dari deret residual

Setelah menggunakan taksiran awal deret *noise* tersebut, maka akan diperoleh suatu model. Model ini mengikuti model ARIMA (p<sub>n</sub>, 0, q<sub>n</sub>) tertentu dan dapat diidentifikasi dengan menyelidiki plot ACF dan PACF, sehingga didapatkan nilai p<sub>n</sub> untuk *autoregressive* dan q<sub>n</sub> untuk *moving average*. Dengan cara ini, fungsi  $\phi_n(B)$  dan  $\theta_n(B)$  untuk deret  $noise N_t$  dapat diperoleh sehinggadidapatkan persamaan:

$$\phi_n(B)N_t = \theta_n(B)a_t$$

## 2.4 Deteksi Outlier

Outlier dapat menyebabkan kesimpulan dari analisis data yang dihasilkan tidak valid sehingga prosedur yang mendeteksi dan menghapus efek outlier sangat penting untuk analisis data. Dalam runtun waktu, outlier diklasifikasikan menjadi *Innovational Outlier* (IO), *Additive Outlier* (AO), *Temporary Change* (TC), dan *Level Shift* (LS). *Additive Outlier* (AO) hanya berpengaruh pada pengamatan ke-T, sedangkan tiga jenis *outlier* lainnya yaitu *Innovational Outlier* (IO).

### 2.4.1 Additive Outlier (AO)

Menurut Wei (2006), diasumsikan bahwa  $X_t$  mengikuti model ARMA (p,q) dengan  $Z_t$  adalah data pengamatan dan  $X_t$  merupakan data yang bebas dari outlier. Sehingga bentuk umum additive outlier:

$$\begin{aligned} Z_t &= \begin{cases} X_t, & t \neq T \\ X_t + \omega, & t = T \end{cases} \\ &= \frac{\theta(B)}{\phi(B)} \alpha_t + \omega I_t^{(T)} \end{aligned}$$

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

#### 2.4.2 Inovational Outlier (IO)

Bentuk umum persamaan Inovational Outlier (IO) didefinisikan sebagai berikut (Wei,2006) :

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

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

$$\text{dengan } I_t^{(T)} = \begin{cases} 1, & t \geq T \\ 0 & t < T \end{cases}$$

#### 2.4.3 Level Shift (LS)

Level shift outlier merupakan kejadian yang mempengaruhi deret pada satu waktu tertentu yang memberikan suatu perubahan tiba-tiba dan permanen. Bentuk umum persamaan Level Shift (LS) didefinisikan sebagai berikut (Wei,2006) :

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

$$\text{dengan } I_t^{(T)} = \begin{cases} 1, & t \geq T \\ 0 & t < T \end{cases}$$

#### 2.4.4 Temporary Change (TC)

Temporary Change outlier adalah suatu kejadian dimana outlier menghasilkan efek awal sebesar  $\omega$  pada waktu  $t$ , kemudian secara perlahan sesuai dengan besarnya  $\delta$ . Bentuk umum persamaan Temporary Change didefinisikan sebagai berikut (Wei,2006) :

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

$$\text{dengan } I_t^{(T)} = \begin{cases} 1, & t \geq T \\ 0 & t < T \end{cases}$$

Pada saat  $\delta=0$  maka TC akan menjadi kasus additive outlier, sedangkan saat  $\delta=1$  maka akan menjadi kasus level shift

## 2.5 Definisi BI Rate dengan inflasi

### 2.5.1 BI rate

BI rate adalah suku bunga kebijakan yang mencerminkan sikap atau *stance* kebijakan moneter yang ditetapkan oleh bank Indonesia dan diumumkan kepada publik. Dengan mempertimbangkan pula faktor-faktor lain dalam perekonomian, Bank Indonesia pada umumnya akan menaikkan BI *rate* apabila inflasi ke depan diperkirakan melampaui sasaran yang telah ditetapkan, sebaliknya Bank Indonesia akan menurunkan BI *rate* apabila inflasi ke depan diperkirakan berada di bawah sasaran yang telah ditetapkan (Siamat, 2001 ).

### 2.5.2 Inflasi

Menurut Suparmoko (2000), inflasi adalah suatu proses meningkatnya harga-harga secara umum dan terus-menerus (kontinu) berkaitan dengan mekanisme pasar yang dapat disebabkan oleh berbagai faktor, antara lain, konsumsi masyarakat yang meningkat, berlebihnya likuiditas di pasar yang memicu konsumsi atau bahkan spekulasi, sampai termasuk juga akibat adanya ketidaklancaran distribusi barang.

### 3. METODOLOGI PENELITIAN

Data yang digunakan dalam penelitian ini adalah data sekunder meliputi BI rate dan data inflasi sebanyak 127 observasi yang diperoleh melalui situs [www.bi.go.id](http://www.bi.go.id) selama periode Januari 2006 sampai Juli 2016. Variabel yang digunakan dalam penelitian ini menggunakan data runtun waktu  $Z_t$ ,  $t = 1, 2, \dots, n$ . Apapun variabel penelitian yang digunakan adalah:

1. Data bulanan BI Rate merupakan variabel yang akan digunakan pada model ARIMA, dan juga sebagai deret input (variabel X) pada model fungsi transfer
2. Data bulanan inflasi sebagai deret output (variabel Y) pada model fungsi transfer

### 4. HASIL DAN PEMBAHASAN

#### 4.1 Identifikasi Proses ARIMA

Pemodelan ARIMA untuk deret *input* BI rate dengan transformasi  $\lambda = -2$  yakni transformasi  $\frac{1}{Z_t^2}$  dan dengan differencing sebanyak satu kali, dapat ditentukan menggunakan plot ACF dan PACF. Untuk mendapatkan model ARIMA terbaik dapat dilihat pada Tabel 1

**Tabel 1** Penentuan ARIMA Terbaik Deret *Input* BI Rate

Model ARIMA	Signifikansi Parameter	White Noise	MSE
(0,1,1)	Ya	Ya	58,28
(1,1,0)	Ya	Ya	55,42

Berdasarkan Tabel 1, model ARIMA terbaik untuk BI Rate adalah ARIMA (1,1,0) karena semua parameter model tersebut signifikan, memenuhi asumsi *white noise* residual serta memiliki MSE paling kecil.

#### 4.2 *Prewhitening* Deret *Input* dan Deret *Output*

Setelah dilakukan identifikasi maka diperoleh model untuk variabel deret *input* BI Rate yaitu ARIMA (1,1,0). Kemudian proses *prewhitening* dilakukan dengan mengonversi deret  $x_t$  menjadi deret  $\alpha_t$ .

$$(1 - \phi_1 B)x_t = \alpha_t$$
$$x_t - \phi_1 x_{t-1} = \alpha_t$$

dengan  $\phi_1 = 0,5839$  maka *prewhitening* deret *input* menjadi  $\alpha_t = x_t - 0,5839 x_{t-1}$

*Prewhitening* deret *output* inflasi juga menggunakan model deret *input* ARIMA (1,1,0). Hal ini dilakukan untuk menjaga integritas model fungsi transfer yang terbentuk. Sehingga *prewhitening* deret *output* inflasi menjadi

$$\beta_t = y_t - 0,5839 y_{t-1}$$

#### 4.3 Perhitungan Korelasi Silang

Adapun hasil dari perhitungan korelasi silang tersebut dapat dilihat dari plot korelasi silang pada Gambar 1.





#### 4.6 Pembentukan Model Fungsi Transfer

Pemodelan secara menyeluruh dengan memasukan semua kemungkinan nilai (b,r,s) yakni (1,0,0), (1,0,1), (1,0,2), (1,1,0), (1,1,1), dan (1,2,0) dengan model deret *noise* yakni ARMA (0,1), ARMA (0,2), ARMA (1,0), ARMA (1,1), ARMA (1,2), ARMA (2,0), ARMA (2,1), dan ARMA (2,2). Sehingga kombinasi model fungsi transfer yang terbentuk adalah sebanyak 48 model. Kemudian diambil model fungsi transfer dengan semua parameternya signifikan yang disajikan pada Tabel 2 berikut.

**Tabel 2.** Identifikasi Model Fungsi Transfer

(b,r,s)	(p <sub>n</sub> ,q <sub>n</sub> )	AIC	Semua Parameter Model Signifikan
(1,0,1)	(0,1)	-645,482	Ya
(1,0,1)	(1,0)	-640,834	Ya
(1,0,1)	(2,0)	-646,709	Ya

Dengan membandingkan nilai AIC terkecil pada tabel 2 sehingga dapat disimpulkan model fungsi transfer dengan (b,r,s)= (1,0,1) dengan model deret *noise* engan orde (p<sub>n</sub>,q<sub>n</sub>) = (2,0) merupakan model terbaik.

#### 4.7 Model Fungsi Transfer yang Terbaik

Model yang terbentuk adalah sebagai berikut:

$$y_t = \frac{\omega(B)}{\delta(B)} x_{t-b} + N_t$$

$$y_t = (\omega_0 - \omega_1 B)x_{t-1} + \frac{1}{(1 - \phi_1 B - \phi_2 B^2)} a_t$$

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \omega_0 x_{t-1} - (\omega_0 \phi_1 + \omega_1) x_{t-2} + (-\omega_0 \phi_2 + \omega_1 \phi_1) x_{t-3} + \omega_1 \phi_2 x_{t-4} + a_t$$

$$y_t = 0,26975y_{t-1} - 0,26252y_{t-2} - 0,00064x_{t-1} - 0,88927x_{t-2} + 0,23976x_{t-3} - 0,23350x_{t-4} + a_t$$

Setelah didapat model fungsi transfer terbaik yakni model fungsi transfer dengan nilai b=1, r=0, s=1 dengan model deret *noise* (2,0) maka dilakukan pengujian diagnostik terhadap model tersebut. Pada tahap ini dilakukan pengujian asumsi residual dari model, yaitu uji *white noise* residual, uji normalitas residual, dan uji homoskedastisitas residual. Dari ketiga asumsi yang harus dipenuhi hanya asumsi normalitas yang tidak terpenuhi.

#### 4.8 Pendeteksian Outlier pada Model ARIMA

Berdasarkan uji normalitas residual pada model fungsi transfer, model fungsi transfer memiliki residual yang tidak berdistribusi normal karena diduga adanya outlier. Untuk mengetahui ada atau tidaknya outlier dalam data, maka dilakukan deteksi outlier. Tabel 3 disajikan waktu terjadinya outlier dan juga tipe outliernya. Nilai *p-value* yang dipergunakan dalam pendeteksian outlier mengikuti distribusi Chi-square. dilihat *p-value* semua outlier yang terdeteksi lebih kecil dari nilai  $\alpha = 0,05$ , yang artinya outlier yang terdeteksi signifikan dan dapat ditambahkan ke dalam model fungsi transfer.

**Tabel 3.** Deteksi Outlier Model Fungsi Transfer

Obs	Tipe	Estimate	P value
9	Shift	-0.11472	<.0001
10	Additive	-0.02265	<.0001
41	Shift	-0.03592	<.0001
119	Additive	-0.02216	<.0001
90	Additive	0.02173	<.0001
102	Shift	-0.03283	<.0001



107	Additive	0.01965	0.0002
106	Shift	0.02742	0.0013
36	Shift	-0.02345	0.0058
118	Shift	-0.02236	0.0056
42	Shift	-0.02172	0.0044
24	Shift	0.02172	0.0040
28	Shift	0.02114	0.0019
66	Shift	-0.02062	0.0025
74	Shift	0.01970	0.0036
92	Shift	-0.01780	0.0085

Hasil pengujian model fungsi transfer (1,0,1) dengan model deret *noise* (2,0) dengan penambahan outlier terangkum dalam Tabel 4 yang berisi perbandingan dari model fungsi transfer (1,0,1) deret *noise* (2,0) dengan penambahan setiap satu outlier di dalamnya.

**Tabel 4.** Pemodelan Terbaik Banyaknya Outlier yang Ditambahkan ke Model

Asumsi	Banyaknya Outlier yang Ditambahkan ke Model															
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
<b>Signifikansi Parameter</b>	x	x	x													
<b>White Noise</b>	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	
<b>Normalitas</b>	x	x	x	x												
<b>Homoskedastisitas</b>	x	x	x	x	x	x	x			x						

dengan x merupakan asumsi yang tidak terpenuhi

#### 4.9 Model Fungsi Transfer dengan Outlier yang Terbaik

Setelah diketahui nilai estimasi semua parameter dari model fungsi transfer dengan penambahan 16 outlier signifikan pada tingkat kepercayaan  $\alpha = 5\%$ , Serta memenuhi asumsi *white noise* residual, berdistribusi normal serta tidak terjadi kasus heteroskedastisitas. Model fungsi transfer dengan 16 outlier setelah dilakukan estimasi adalah sebagai berikut:

$$\begin{aligned}
 y_t = & 0.46776y_{t-1} - 0.38372y_{t-2} - 0.0000486x_{t-1} - 0.900857x_{t-2} + 0.421377x_{t-3} \\
 & - 0.34569x_{t-4} + a_t + \frac{-0,13004}{(1-B)} I_t^{(9)} - 0,02614 I_t^{(10)} - \frac{0,04084}{(1-B)} I_t^{(41)} \\
 & - 0,02562 I_t^{(119)} + 0,02421 I_t^{(90)} - \frac{0,02891}{(1-B)} I_t^{(102)} + 0,0255 I_t^{(107)} \\
 & + \frac{0,02724}{(1-B)} I_t^{(106)} - \frac{0,02302}{(1-B)} I_t^{(36)} - \frac{0,02069}{(1-B)} I_t^{(118)} - \frac{0,02405}{(1-B)} I_t^{(42)} \\
 & + \frac{0,02196}{(1-B)} I_t^{(24)} + \frac{0,0195}{(1-B)} I_t^{(28)} - \frac{0,02038}{(1-B)} I_t^{(66)} + \frac{0,01517}{(1-B)} I_t^{(74)} \\
 & - \frac{0,01646}{(1-B)} I_t^{(92)}
 \end{aligned}$$

#### 4.10 Peramalan

Peramalan menggunakan model fungsi transfer dengan 16 outlier untuk 5 periode kedepan mulai bulan Agustus 2016 sampai Desember 2016 hasil peramalannya disajikan dalam Tabel 5.

**Tabel 5.** Hasil Peramalan Inflasi 5 Periode ke Depan

Periode	Peramalan
Agustus 2016	0,032652
September 2016	0,032544
Oktober 2016	0,032689
November 2016	0,032870
Desember 2016	0,033015

## 5. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dilakukan, maka dapat diambil kesimpulan yaitu:

1. Prosedur pemodelan fungsi transfer diawali dengan penentuan model ARIMA terbaik dari deret input yakni dari data BI Rate. Model ARIMA terbaik dari deret input adalah ARIMA (1,1,0).

2. Model fungsi transfer terbaik adalah model fungsi transfer dengan nilai  $b=1$ ,  $r=0$ ,  $s=1$  dengan model deret *noise* (2,0). Model yang terbentuk adalah sebagai berikut:

$$y_t = 0,26975y_{t-1} - 0,26252y_{t-2} - 0,00064x_{t-1} - 0,88927x_{t-2} + 0,23976x_{t-3} - 0,23350x_{t-4} + a_t$$

3. Model fungsi transfer dengan 16 outlier yang terbentuk adalah sebagai berikut:

$$y_t = 0,46776y_{t-1} - 0,38372y_{t-2} - 0,0000486x_{t-1} - 0,900857x_{t-2} + 0,421377x_{t-3} - 0,34569x_{t-4} + a_t + \frac{-0,13004}{(1-B)} I_t^{(9)} - 0,02614 I_t^{(10)} - \frac{0,04084}{(1-B)} I_t^{(41)} - 0,02562 I_t^{(119)} + 0,02421 I_t^{(90)} - \frac{0,02891}{(1-B)} I_t^{(102)} + 0,0255 I_t^{(107)} + \frac{0,02724}{(1-B)} I_t^{(106)} - \frac{0,02302}{(1-B)} I_t^{(36)} - \frac{0,02069}{(1-B)} I_t^{(118)} - \frac{0,02405}{(1-B)} I_t^{(42)} + \frac{0,02196}{(1-B)} I_t^{(24)} + \frac{0,0195}{(1-B)} I_t^{(28)} - \frac{0,02038}{(1-B)} I_t^{(66)} + \frac{0,01517}{(1-B)} I_t^{(74)} - \frac{0,01646}{(1-B)} I_t^{(92)}$$

4. Pemodelan fungsi transfer dengan 16 outlier menghasilkan model yang lebih baik dibandingkan model fungsi transfer tanpa outlier, hal ini dapat dilihat dari nilai AIC model fungsi transfer dengan outlier sebesar -868,56 lebih kecil dari model fungsi tranfer tanpa outlier yakni sebesar -654,70.

## DAFTAR PUSTAKA

- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. 1999. *Metode dan Aplikasi Peramalan, Jilid 1 Edisi Kedua*. Diterjemahkan oleh: Andrianto dan Basith. Jakarta: Erlangga.
- Rosadi, D. 2012. *Ekonometrika & Analisis Runtun Waktu Terapan dengan Eviews*. Yogyakarta: Penerbit ANDI.
- Siamat, D. 2001. *Manajemen Lembaga Keuangan, Edisi Ketiga*. Jakarta: Badan Penerbit FE Universitas Indonesia.
- Soejoeti, Z. 1987. *Materi Pokok Analisis Runtun Waktu*. Jakarta: Penerbit Karunika.
- Suparmoko, 2000. *Pengantar Ekonomika Makro*, Edisi 4. Yogyakarta : BPFE
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. New York: Addison Wesley.