

PREDIKSI SIMPANAN BERJANGKA PADA BANK UMUM DAN BPR MENGUNAKAN METODE ARIMA DENGAN *OUTLIERS* DAN ARIMA *BOOTSTRAP*

Shinta Karunia Permata Sari¹, Rukun Santoso², Suparti³

¹Mahasiswa Departemen Statistika FSM Universitas Diponegoro

^{2,3}Staff Pengajar Departemen Statistika FSM Universitas Diponegoro

shinta_kps19@yahoo.com, rukunsantoso@undip.ac.id, supartisudargo@yahoo.com

ABSTRACT

Time deposits or often referred to as deposits are deposits that take it in accordance with the time agreed. The position of time deposits in commercial banks and BPRs is monitored by Bank Indonesia, Because large time deposits affect the level of the economy in Indonesia, one of them to facilitate public credit in an opening and building businesses. However, in the course of this term deposit data position is influenced by many other factors that resulted in the existence of the data of this condition leads to the assumption of normality becomes unfulfilled. Some methods that can be used to overcome this problem include ARIMA Box-Jenkins with outliers detection and Bootstrapping ARIMA. In this case, the data is public time deposits at commercial banks and BPR from January 2010 to April 2016. The best ARIMA model is ARIMA (1,1,0), With the best method is ARIMA Bootstrap because it has MAPE value (out sample) of 4.8257% less than MAPE value's ARIMA with outliers detection which it has 6.1610%. Based on these results it is concluded that in this case the nonparametric method is more appropriate to be used by ignoring the distribution assumption.

Keywords : Deposits, ARIMA, Outliers detection, Bootstrap ARIMA

1. PENDAHULUAN

Bank Indonesia mempunyai tugas menetapkan dan melaksanakan kebijakan moneter, mengatur dan menjaga kelancaran sistem pembayaran, serta mengatur dan mengawasi perbankan di Indonesia. Berdasarkan UU No. 10 tahun 1998 (pasal 5) bank di Indonesia terdiri dari bank umum dan bank perkreditan rakyat. Sebagai satu-satunya bank sentral, Bank Indonesia bertugas untuk mengambil segala kebijakan yang dapat menjaga kestabilan perekonomian Indonesia sebagai fungsinya yaitu sebagai lembaga negara yang independen. Salah satu tugasnya itu dapat dilihat dari pengawasan posisi simpanan berjangka rupiah Bank Umum dan Bank Perkreditan Rakyat.

Kadangkala dalam prediksi sering dihadapi oleh jumlah sampel yang relatif kecil atau terdapat pencilan pada data, sehingga sulit terpenuhinya asumsi-asumsi dalam analisis statistika klasik, akibatnya inferensi statistik tidak dapat dilakukan terhadap parameter model. Untuk mengatasi masalah kecilnya jumlah sampel yang diperoleh maka dapat digunakan metode *bootstrap*, sedangkan untuk menangani terdapatnya pencilan pada deret runtun waktu dilakukan deteksi *outliers*.

Pada penelitian kali ini akan diramalkan besarnya posisi simpanan masyarakat pada Bank Umum dan BPR pada bulan Januari 2010 sampai dengan April 2016. Simpanan masyarakat perlu diramalkan untuk membantu tugas Bank Indonesia dalam memoneter segala kegiatan yang berkaitan dengan perbankan, salah satunya untuk melihat tingkat perekonomian masyarakat berdasarkan simpanan berjangka yang disimpan pada bank

umum maupun BPR. Salah satu metode dalam prediksi yang dapat digunakan adalah ARIMA Box-Jenkins dengan deteksi *outliers* dan ARIMA *Bootstrap*.

2. TINJAUAN PUSTAKA

2.1 Simpanan Berjangka pada Bank Umum dan BPR

Simpanan berjangka menurut Kasmir (2012) adalah Deposito berjangka merupakan deposito yang diterbitkan dengan jenis jangka waktu tertentu. Sedangkan Bank umum adalah bank yang melaksanakan kegiatan usaha secara konvensional dan atau berdasarkan prinsip syariah, yang dalam kegiatannya memberikan jasa dalam lalu lintas pembayaran dan Bank Perkreditan Rakyat (BPR) adalah Bank yang melaksanakan kegiatan usaha secara konvensional atau berdasarkan prinsip syariah, yang dalam kegiatannya tidak memberikan jasa dalam lalu lintas pembayaran (www.ojk.go.id).

2.2 Analisis Time Series

Time series adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadian dengan interval waktu yang tetap (Wei, 2006: 1). Berbagai metode telah dikembangkan dalam mengolah data *time series* untuk memperoleh suatu model yang memberikan hasil ramalan yang lebih akurat. Salah satu metodenya yaitu adalah ARIMA Box Jenkins. Untuk dapat diolah dengan menggunakan metode ARIMA Box-Jenkins, suatu data *time series* harus memenuhi syarat stasioneritas (Makridakis *et al.*, 1995). Menurut Soejoeti (1987), misalkan Z_1, Z_2, \dots, Z_t merupakan proses stokastik untuk *time series* diskrit. Proses tersebut disebut stasioner jika mean dan variansinya konstan untuk setiap titik t dan kovarian yang konstan untuk setiap selang waktu k .

$$\begin{aligned} E(Z_t) &= \mu && \text{konstan untuk semua } t \\ \text{Var}(Z_t) &= \sigma^2 = \gamma_0 && \text{konstan untuk semua } t \\ \text{Cov}(Z_t, Z_{t-k}) &= \gamma_k && \text{konstan untuk semua } k. \gamma_k \text{ adalah} \\ &&& \text{autokovariansi pada lag } k. \end{aligned}$$

Untuk keperluan pengujian stasioneritas, dapat dilakukan dengan beberapa metode seperti grafik acf/pacf dan plot time series, serta uji akar-akar unit. Untuk menguji apakah data bersifat stasioner dalam mean atau tidak, umumnya digunakan uji akar unit

Augmented Dickey Fuller (ADF), dimana $T = \frac{\hat{\phi}_1 - 1}{SE(\hat{\phi}_1 - 1)}$. Untuk melihat apakah data

stasioner dalam varian atau tidak maka dapat dilihat dan diatasi dengan Transformasi Box-Cox. Box Cox mempertimbangkan kelas transformasi berparameter tunggal, yaitu λ yang dipangkatkan pada variabel respon Y , sehingga transformasinya menjadi Y^λ . Salah satu model matematis yang umum digunakan dalam pemodelan time series adalah model ARIMA Box-Jenkins yang didefinisikan sebagai berikut : $\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t$, dengan $a_t \sim NID(0, \sigma^2)$.

2.3 ARIMA dengan Deteksi Outliers

Dalam kasus runtun waktu, outlier diklasifikasikan menjadi Additive Outlier (AO), Innovative Outlier (IO), Level Shift (LS) dan Temporary Change (TC). Additive Outlier (AO) hanya berpengaruh pada pengamatan ke- T , sedangkan tiga jenis outlier lainnya yaitu Innovative Outlier (IO), Level Shift (LS) dan Temporary Change (TC) berpengaruh pada pengamatan ke- $T, T+1, T+2, \dots$. Diasumsikan bahwa (X_t) mengikuti model ARMA (p,q), dengan Z_t adalah data pengamatan dan X_t adalah data outlier bebas.

$$\phi_p(B)X_t = \theta_q(B)a_t$$

Bentuk umum dari sebuah *outliers* didefinisikan sebagai berikut :

$$\text{Additive Outlier (AO)} \quad : \quad Z_t = \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)}, \quad \text{dengan } a_t \sim NID(0, \sigma^2)$$

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

$I_t^{(T)}$ adalah variabel indikator AO yang mewakili ada atau tidaknya outlier pada waktu T.

$$\text{Innovational Outlier (IO)} \quad : \quad Z_t = X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} = \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)}),$$

Dengan $a_t \sim NID(0, \sigma^2)$

$$\text{Level Shift (LS)} \quad : \quad Z_t = X_t + \frac{1}{(1-B)} \omega I_t^{(T)}, \quad \text{dengan } a_t \sim NID(0, \sigma^2)$$

$$\text{Temporary Change (TC)} \quad : \quad Z_t = X_t + \frac{1}{(1-\delta B)} \omega I_t^{(T)}, \quad \text{dengan } a_t \sim NID(0, \sigma^2)$$

Temporary change outlier adalah suatu kejadian ketika outlier menghasilkan efek awal sebesar ω pada waktu T, kemudian secara perlahan sesuai dengan besarnya δ .

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

$I_t^{(T)}$ adalah indikator *outliers* IO, LS, dan TC yang mewakili ada atau tidaknya outlier pada waktu T.

2.3.1 Estimasi Residual Efek Outlier

Sebuah kasus khusus ketika *outlier* dan semua parameter pada persamaan ARMA diketahui, misalkan : $\pi(B) = \frac{\phi(B)}{\theta(B)} = (1 - \pi_1 B - \pi_2 B^2 - \dots)$ dan mendefinisikan

$$e_t = \pi(B)Z_t$$

Dengan menggunakan persamaan tersebut estimasi residual dari sebuah *outliers* dapat ditulis sebagai berikut :

$$\text{Additive Outlier (AO)} \quad : \quad e_t = \omega \pi(B) I_t^{(T)} + a_t \quad (1)$$

$$\text{Innovational Outlier (IO)} \quad : \quad \hat{e} = \omega I_t^{(T)} + a_t \quad (2)$$

$$\text{Level Shift (LS)} \quad : \quad \hat{e} = \omega \{ \pi(B) / (1-B) \} I_t^{(T)} + a_t \quad (3)$$

$$\text{Temporary Change (TC)} \quad : \quad \hat{e} = \omega \{ \pi(B) / (1-\delta B) \} I_t^{(T)} + a_t \quad (4)$$

Berdasarkan persamaan (1-4) didapatkan persamaan umum dari residual sebagai berikut : $\hat{e} = \omega x_{it} + a_t$, untuk $i=1=AO, 2=IO, 3=TC, \text{ dan } 4=LS$.

Misalkan $\hat{\omega}$ adalah penduga dari ω , selanjutnya dapat mengestimasi parameter dari $\hat{\omega}$ dengan metode OLS dengan cara mencari turunan pertama dari residual kuadrat a_t .

Beberapa uji hipotesis yang dikemukakan oleh Liu dan Chen (1993) yang dapat digunakan untuk mendeteksi jenis outlier sebagai berikut :

H_0 : Z_T bukan merupakan AO, IO, LS atau TC (tidak terdapat outlier)

H_1 : Z_T adalah AO

H_2 : Z_T adalah IO

H_3 : Z_T adalah LS

H_4 : Z_T adalah TC

Statistik uji :

- a. Terdapat sebuah AO ketika H_0 vs H_1 dengan $\lambda_{1,T} = \{ \hat{\omega}_{AO}(T) / \hat{\sigma}_a \} \left(\sum_{t=T}^n x_{it}^2 \right)^{1/2}$

- b. Terdapat sebuah IO ketika H_0 vs H_2 dengan $\lambda_{2,T} = \{\hat{\omega}_{IO}(T) / \hat{\sigma}_a\}$
- c. Terdapat sebuah LS ketika H_0 vs H_3 dengan $\lambda_{3,T} = \{\hat{\omega}_{LS}(T) / \hat{\sigma}_a\} (\sum_{t=T}^n x_{3t}^2)^{1/2}$
- d. Terdapat sebuah TC ketika H_0 vs H_4 dengan $\lambda_{4,T} = \{\hat{\omega}_{TC}(T) / \hat{\sigma}_a\} (\sum_{t=T}^n x_{4t}^2)^{1/2}$

Kriteria Uji :

H_0 ditolak jika $\hat{\lambda}_T = |\hat{\lambda}_{i,T}| > C$, untuk $i=1,2,3,4$ dengan titik kritis C yang ditetapkan sebelumnya, yaitu antara 3 dan 4. Jika nilai $n=50$ maka $C=3$, jika nilai $n \geq 450$ maka nilai $C=4$, dan untuk nilai diantara keduanya dapat dihitung dengan $3+0.0025*(n-50)$.

2.3.2 Pendeteksian *Outlier* dengan Prosedur Iteratif

Prosedur iterasi deteksi *outlier* akan diterapkan dalam memodelkan data yang diduga mengandung *outlier*. Adapun prosedur iterasi deteksi *outlier* yang dikemukakan oleh Chang dan Tiao dalam Wei (2006) sebagai berikut :

Langkah 1. Model *time series* $\{Z_t\}$ diasumsikan tidak mempunyai *outlier*. Hitung residual dari estimasi model yaitu :

$$\hat{e}_t = \hat{\pi}(B)Z_t = \frac{\hat{\phi}(B)}{\hat{\theta}(B)} Z_t$$

dengan $\hat{\phi}_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ dan $\hat{\theta}_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ dan hitung penduga dari σ_a yaitu (Liu dan Chen, 1993):

$$\hat{\sigma}_a = 1.483 \times \text{median}\{|\hat{e}_t - \tilde{e}|\}$$

dengan \tilde{e} adalah median dari e .

Langkah 2. Hitung $\hat{\lambda}_{1,t}, \hat{\lambda}_{2,t}, \hat{\lambda}_{3,t}$ dan $\hat{\lambda}_{4,t}$ untuk $t = 1, 2, \dots, n$ menggunakan estimasi model.

Kemudian untuk menentukan outlier dapat digunakan persamaan berikut :

$$\hat{\lambda}_T = \max_t \max_i \{|\hat{\lambda}_{i,t}|\}$$

dengan T menunjukkan waktu terjadi maksimum. Jika $\hat{\lambda}_T = |\hat{\lambda}_{i,t}| > C$, maka terdapat outlier. Kemudian memodifikasi residual sesuai dengan tipe outlier yang terdeteksi, yaitu:

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{AT} \hat{\pi}(B)I_t^{(T)}, \text{ untuk AO} \quad (5)$$

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{IT} I_t^{(T)}, \text{ untuk IO} \quad (6)$$

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{LT} \frac{1}{(1-B)} \hat{\pi}(B)I_t^{(T)}, \text{ untuk LS} \quad (7)$$

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{LT} \frac{1}{(1-\delta B)} \hat{\pi}(B)I_t^{(T)}, \text{ untuk TC} \quad (8)$$

Estimasi baru $\tilde{\sigma}_a^2$ dihitung dari residual modifikasi.

Langkah 3. Hitung ulang $\hat{\lambda}_{1,t}, \hat{\lambda}_{2,t}, \hat{\lambda}_{3,t}$ dan $\hat{\lambda}_{4,t}$ setelah didapatkan residual baru dan $\tilde{\sigma}_a^2$ lalu ulangi langkah 2 sampai semua outlier teridentifikasi.

2.4 Metode Bootstrap untuk *Time Series*

Metode Bootstrap merupakan suatu metode pendekatan nonparametrik untuk menaksir berbagai kuantitas statistik seperti mean, standar error, dan bias suatu estimator atau untuk membentuk interval konfidensi dengan memanfaatkan kecanggihan teknologi komputer. Dengan metode bootstrap tidak perlu melakukan asumsi distribusi dan asumsi-

asumsi awal untuk menduga bentuk distribusi dan pengujian-pengujian statistiknya (Rahayu & Tarno, 2006).

Dalam penelitian ini data akan dianalisis menggunakan metode *bootstrap* resampling residual. Pendekatan resampling residual pada dasarnya adalah melakukan pengambilan sampel (*resampling*) dengan pengembalian dari sampel residual dengan replikasi B kali ($n \ll B \ll n^n$).

Setelah didapatkan parameter *bootstrap*, langkah selanjutnya metode *bootstrap* dapat digunakan untuk menghitung selang kepercayaan parameter, dengan rumus sebagai

berikut: $\pm \bar{\theta} Z_{\alpha/2} Se$, dimana $\bar{\theta} = \frac{1}{B} \sum_{i=1}^B \theta_i$ dan $Se = \left[\frac{1}{B-1} \sum_{i=1}^B (\hat{\theta}_i - \bar{\theta})^2 \right]^{1/2}$.

2.5 Pemilihan Model Terbaik

Pemilihan model terbaik ini dipilih berdasarkan model yang mempunyai nilai AIC terkecil. Akaike dalam Wei (2006) memperkenalkan sebuah kriteria informasi yaitu AIC. (Akaike's Information Criterion) yang didefinisikan sebagai berikut :

$$AIC = n \ln(\hat{\sigma}_a^2) + 2(p + q)$$

2.6 Ketepatan Model Peramalan

Menurut Makridakis *et al*(1995), kesalahan atau *error* dapat dihitung sebagai berikut :

Kesalahan Presentase (*Precentage Error*)

$$PE_t = \left(\frac{X_t - F_t}{X_t} \right) (100)$$

Nilai Tengah Kesalahan Presentase Absolut (*Mean Absolute Precentage Error*)

$$MAPE = \sum_{i=1}^n |PE_i| / n$$

3. METODE PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan sebagai studi kasus dalam Tugas Akhir ini berupa data skunder yang diambil dari situs resmi Bank Indonesia divisi moneter mengenai data Posisi Simpanan Berjangka pada Bank Umum dan BPR periode 1 bulan.

3.2 Tahapan Analisis Data

Langkah – langkah analisis untuk melakukan prediksi Posisi Simpanan Berjangka pada Bank Umum dan BPR adalah sebagai berikut :

1. Menyunting data dan menentukan data *in sample* dan *out sample*.
2. Mengimport data yang telah disunting ke dalam software R
3. Melakukan pengolahan data dengan langkah-langkah awal yaitu:

- Deteksi Stasioneritas Data
 - Identifikasi Model
 - Pendugaan Paramater Model
 - Verifikasi Model
- Bagian ini meliputi pemeriksaan diagnostik residual model dan overfitting.
- Pemilihan Model Terbaik

Setelah itu, dilakukan perbandingan model dengan membandingkan nilai AIC terkecil.


4. Tahapan ARIMA dengan deteksi *outliers* :
 - Deteksi *Outliers*
 - Identifikasi Model ARIMA dengan *outliers*
 - Estimasi Parameter ARIMA dengan *outliers*
 - Verifikasi Model dengan *outliers*
 - Peramalan dengan model ARIMA dengan outlier
5. Tahapan dalam ARIMA *Bootstrap* :
 - Parameter ϕ diestimasi dengan $\hat{\phi}$ dengan menggunakan metode kuadrat terkecil (least square). Jika $\hat{\phi}$ telah diketahui maka kita dapat menghitung $\hat{\varepsilon}_t$, yaitu $\hat{\varepsilon}_t = Z_t - \hat{\phi}Z_{t-1}$. Sehingga F_ε dapat diestimasi dengan fungsi distribusi empiris dari $\hat{\varepsilon}_t$ yaitu dengan mengambil masa peluang $1/n$ terhadap $\hat{\varepsilon}_t - \bar{\varepsilon}$.
 - Data Bootstrap dibangkitkan dari model tersebut dengan (ϕ, F_ε) diganti dengan $(\hat{\phi}, \hat{F}_\varepsilon)$ Dengan kata lain dibangkitkan data independen dan berdistribusi identik $\varepsilon_1^*, \varepsilon_2^*, \dots, \varepsilon_n^*$ dari \hat{F}_ε dan didefinisikan $Z_t^* = \hat{\phi}Z_{t-1} + \varepsilon_t^*$.
 - Dengan metode kuadrat terkecil dihitung $\hat{\phi}^*$ berdasarkan data $Z_1^*, Z_2^*, \dots, Z_n^*$
 - Ulangi langkah b dan c sebanyak B kali sebagai replikasi Bootstrap.
 - Setelah didapatkan $\hat{\phi}^*$ sebanyak B kali, maka untuk mencari parameter akhir dalam bootstrap dilakukan rata-rata terhadap $\hat{\phi}_B^*$.
 - Mencari nilai selang kepercayaan pada parameter
6. Perbandingan

Setelah didapatkan hasil peramalan untuk 1 bulan kedepan, selanjutnya dibandingkan MAPE terkecil.


4. HASIL DAN PEMBAHASAN

4.1 Identifikasi Awal Model ARIMA

Langkah paling awal dalam menganalisis data menggunakan metode runtun waktu yaitu dengan melihat grafik runtun waktu (*plot time series*), stasioneritas dalam mean dan stasioneritas dalam varian, dapat dilihat sebagai berikut :



Gambar 1. Grafik *Time Series* data awal




Gambar 2. Uji Transformasi Box-Cox Data Awal


Tabel 2. Tabel Uji Augmented Dickey Fuller Data Awal

Data	Dickey Fuller	P-value
Posisi Simpanan Berjangka	-1,8112	0,6526

Berdasarkan hasil tersebut dapat disimpulkan bahwa data tidak stasioner dalam mean dan varian serta berdasarkan grafik *time series* data naik terus menerus atau dapat dikatakan data mempunyai *tren*. Untuk itu perlu dilakukan transformasi dan diferensi untuk mengatasi ketidakstasioneran tersebut. Setelah data dilakukan transformasi dan diferensi sebanyak 1 kali, maka didapatkan :



Gambar 3. Grafik time series yang telah stasioner




Gambar 4. Uji Transformasi Box-Cox setelah stasioner


Tabel 2. Uji Augmented Dickey Fuller setelah di Differensi pertama

Data	Dickey Fuller	P-value
Data Transformasi	-4,0087	0,01401

Setelah data stasioner, langkah selanjutnya adalah membuat *plot acf* dan *pacf* untuk menentukan orde dari ARIMA :



Gambar 5. Grafik ACF



Gambar 6. Grafik PACF

Setelah data di Transformasi dan didiferensi sebanyak 1 kali, berdasarkan gambar 5 dan 6 dapat diduga model ARIMA awal. Pada plot ACF terpotong pada lag 3 sedangkan pada plot PACF terpotong pada lag ke 1, Sehingga model ARIMA yang mungkin adalah :
 ARIMA (1,1,3) ARIMA (1,1,2) ARIMA (1,1,1) ARIMA (0,1,3)
 ARIMA (0,1,2) ARIMA (0,1,1) ARIMA (1,1,0)

Setelah didapatkan model sementara, maka akan diuji asumsi untuk semua model sementara seperti uji signifikansi parameter model, uji normalitas residual, uji *white noise* residual, uji homoskedastisitas residual. Setelah dilakukan uji asumsi maka langkah selanjutnya memilih nilai *error* terkecil dengan AIC, didapatkan hasil sebagai berikut :

Tabel 3. Pemilihan Model Terbaik ARIMA

Model	Signifikansi Parameter	White Noise	Homoskedastisitas	Normalitas	AIC
ARIMA (1,1,3)	Ya	Ya	Ya	Tidak	162,92
ARIMA (0,1,2)	Ya	Ya	Ya	Tidak	161,14
ARIMA (1,1,0)	Ya	Ya	Ya	Tidak	160,49
ARIMA (0,1,1)	Ya	Ya	Ya	Tidak	166,15

Berdasarkan Tabel 3, didapatkan kesimpulan bahwa model terbaik adalah model ARIMA (1,1,0) karena memenuhi semua asumsi dan memiliki nilai AIC terkecil. Sehingga didapatkan persamaan model ARIMA (1,1,0) sebagai berikut :

$$Z_t = 0,471Z_{t-1} + 0,5290Z_{t-2} + a_t$$

4.2 Model ARIMA dengan *Outliers*

Langkah selanjutnya kita mendapatkan nilai residual yang nantinya akan dideteksi *outliers* dari model ARIMA terbaik. Setelah *outliers* dideteksi maka langkah selanjutnya adalah memasukkan *outliers* tersebut ke dalam model ARIMA terbaik yaitu ARIMA (1,1,0). Selanjutnya akan diuji asumsi kembali seperti uji asumsi pada ARIMA sebelumnya yaitu dengan uji signifikansi parameter, uji normalitas residual, uji *white noise* residual, dan uji homoskedastisitas residual dengan melihat nilai AIC terkecil untuk mendapatkan model ARIMA dengan *outliers* terbaik. Setelah dianalisis didapatkan hasil model terbaik sebagai berikut:

Tabel 4. Model ARIMA dengan *Outliers* Terbaik

Penambahan <i>Outliers</i>	Signifikansi Parameter	White Noise	Normalitas	Homoskedas-tisitas	AIC
LS3, AO41, LS56, TC38, LS48, AO75, AO76, AO4, LS60, AO36, TC44, AO51, LS7, LS21, AO23, LS64	Ya	ya	ya	ya	44,58

Dapat disimpulkan bahwa model ARIMA terbaik dengan *outliers* adalah dengan menambahkan 16 *outliers* dengan tipe AO,LS, dan TC. Sehingga persamaannya dapat ditulis sebagai berikut :

$$Z_t = 0,1687Z_{t-1} + 0,8313Z_{t-2} + \frac{2,8570}{(1-B)}I_t^{(3)} - 1,4216 I_t^{(41)} + \frac{1,3514}{(1-B)}I_t^{(56)} - \frac{1,7131}{(1-0,7B)}I_t^{(38)} + \frac{1,5175}{(1-B)}I_t^{(48)} + 1,2093 I_t^{(75)} - 1,1174 I_t^{(76)} + 1,5780 I_t^{(4)} + \frac{1,0221}{(1-B)}I_t^{(60)} - 0,9580 I_t^{(36)} + \frac{0,8923}{(1-0,7B)}I_t^{(44)} - 0,9316 I_t^{(51)} + \frac{0,5791}{(1-B)}I_t^{(7)} + \frac{0,6315}{(1-B)}I_t^{(21)} - 0,5737 I_t^{(23)} - \frac{0,6141}{(1-0,7B)}I_t^{(64)}$$

4.3 BOOTSTRAP ARIMA

Metode ini dimulai dengan membootstrap residual dari model ARIMA terbaik yaitu ARIMA (1,1,0) yang telah didapatkan, sehingga nantinya didapatkan data baru. Setelah didapatkan parameter sejumlah B=100 kali, langkah selanjutnya yaitu mencari parameter bootstrap ARIMA dengan cara mencari rata-rata dari semua parameter model

ARIMA yang telah di bootstrap, sehingga didapatkan nilai parameternya $\bar{\phi}_b = \frac{1}{B} \sum_{b=1}^B \phi_b = -$

0.5189 dengan standar errornya adalah $SE(\bar{\phi}_b) = 0,0822$. Dengan begitu model Bootstrap ARIMA (1,1,0) nya adalah :

$$Z_t = 0.4811Z_{t-1} - 0.5189Z_{t-2} + a_t$$

Sehingga didapatkan selang kepercayaan parameternya adalah

$$\bar{\theta} \pm Z_{\alpha/2} Se$$

$$= -0,5189 - (1,96 \times 0,0822) \leq -0,5189 \leq -0,5189 + (1,96 \times 0,0822)$$

$$= -0,6799 \leq -0,5189 \leq -0,3281$$

4.4 Prediksi dan Pemilihan Metode Terbaik

Berdasarkan analisis yang telah dilakukan menggunakan metode deteksi outliers dan bootstrap ARIMA didapatkan hasil peramalan data besarnya simpanan berjangka masyarakat pada bank umum dan BPR dari bulan Januari 2010 sampai dengan bulan April 2016 untuk lima periode ke depan untuk masing-masing metode adalah :

Tabel 5. Hasil Prediksi dan nilai error setiap metode

ARIMA dengan deteksi outliers			Bootstrap ARIMA		
Prediksi	Aktual	Error	Prediksi	Aktual	Error
912320,893	882004,92	30315,9734	867973,444	882004,92	14031,4763
818443,852	782703,81	35740,0416	832352,597	782703,81	49648,7871
895964,751	849825,79	46138,9608	850701,627	849825,79	875,836875
831167,848	814013,6	17154,2482	841144,235	814013,6	27130,6349
884786,197	739466,54	145319,657	846093,827	739466,54	106627,287
MAPE (out sample)		6,265512%	MAPE (out sample)		4,70243%

5. KESIMPULAN

Berdasarkan permasalahan yang dikemukakan dalam tulisan ini, maka dapat diambil kesimpulan sebagai berikut :

1. Model terbaik untuk metode ARIMA Box-Jenkins dengan penambahan outliers adalah model ARIMA (1,1,0) dengan penambahan 16 outliers yang bertipe AO,LS, dan TC. Model ini terbukti dapat mengatasi pelanggaran asumsi normalitas residual dari tidak

terpenuhi menjadi terpenuhi setelah memasukkan *outliers* ke dalam model ARIMA (1,1,0). Memasukkan *outliers* ke dalam model dapat juga memperkecil nilai *error* yang semula nilai AIC pada ARIMA (1,1,0) adalah 160,49 menjadi 44,58. Model ARIMA (1,1,0) dengan penambahan 16 *outliers* ini dapat dituliskan sebagai berikut :

$$Z_t = 0.1687Z_{t-1} + 0.8313Z_{t-2} + \frac{2.8570}{(1-B)} I_t^{(3)} - 1.4216I_t^{(41)} + \frac{1.3514}{(1-B)} I_t^{(56)} - \frac{1.7131}{(1-0.7B)} I_t^{(38)} + \frac{1.5175}{(1-B)} I_t^{(48)}$$

$$+ 1.2093I_t^{(75)} - 1.1742I_t^{(76)} - 1.5780I_t^{(4)} + \frac{1.0221}{(1-B)} I_t^{(60)} - 0.9580I_t^{(36)} + \frac{0.8923}{(1-0.7B)} I_t^{(44)} - 0.9316I_t^{(51)}$$

$$+ \frac{0.5791}{(1-B)} I_t^{(7)} + \frac{0.6315}{(1-B)} I_t^{(21)} - 0.5737I_t^{(23)} - \frac{0.6141}{(1-0.7B)} I_t^{(64)}$$

2. Metode penanganan lain jika residual model ARIMA tidak berdistribusi normal adalah dengan metode *bootstrap*, model ARIMA (1,1,0) yang telah didapatkan dari *bootstrapping* sebanyak 100 kali adalah :

$$Z_t = 0,4811Z_{t-1} - 0,5189Z_{t-2} + a_t$$

Dengan interval parameternya $-0,6799 \leq -0,5189 \leq -0,3578$

3. Berdasarkan analisis yang telah dijelaskan sebelumnya didapatkan hasil bahwa data peramalan posisi simpanan berjangka masyarakat pada bank umum dan BPR lebih tepat dianalisis dengan menggunakan metode *Bootstrap* ARIMA karena mempunyai hasil peramalan yang lebih mendekati dan mempunyai nilai MAPE terkecil.

DAFTAR PUSTAKA

- Bank Indonesia. 2016. *Meta Data Simpanan Masyarakat*. http://www.bi.go.id/id/statistik/metadata/seki/Documents/4_Simpanan_Masyarakat_Indonesia.pdf. Diakses pada 10 Februari 2017 Pukul 17.00.
- Chen, C., dan Liu, L. M. 1993. Joint Estimation Of Model Parameters and Outlier Effect in Time Series. *Journal of the American Statistical Association*, Vol. 88, No. 421
- Kasmir. 2003. *Manajemen Perbankan*. Jakarta: PT. RajaGrafindo Persada.
- Makridakis; Wheelwright & McGee. 1999. *Metode dan Aplikasi Peramalan*. Jakarta: Binarupa Aksara.
- Otoritas Jasa Keuangan. Pengertian Bank Perkreditan Rakyat. <http://ojk.go.id/id/kanal/perbankan/Pages/BankPerkreditanRakyat.aspx>. Diakses pada 10 Februari 2017 Pukul 17.20.
- Rahayu, S. & Tarno. 2006. Prediksi Produksi Jagung di Jawa Tengah dengan Arima dan Bootstrap. ISBN : 979.704.427.0 . *Prosiding SPMIPA*. Semarang: Universitas Diponegoro.
- Soejoeti, Z.1987. *Materi Pokok Analisis Runtun Waktu*. Jakarta: Karunika, Universitas Terbuka.
- Tarno. 2013. Kombinasi Prosedur Pemodelan Subset Arima dan Deteksi Outlier untuk Prediksi Data Runtun Waktu. ISBN: 978-602-14387-0-1 *Prosiding Seminar Nasional Statistika* UNDIP Semarang.
- Wei, W.W.S. 2006. *Time Series Univariate and Multivariate Methods*. USA : Pearson Education, Inc.