

ANALISIS DATA INFLASI INDONESIA MENGGUNAKAN MODEL *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA) DENGAN PENAMBAHAN *OUTLIER*

Suparti¹ dan Alfi Faridatus Sa'adah²

¹ Staf Pengajar Jurusan Statistika FSM UNDIP

² Staf BPJS Ketenagakerjaan Kota Semarang

Abstract

The inflation data is one of the financial time series data which often has high volatility. It is caused by the presence of *outliers* in the data. Therefore, it is necessary to analyze forecasting that can make all the assumptions are fulfilled without having to ignore the presence of *outliers*. The aim of this study is analyzing the inflation data in Indonesia using ARIMA model with the *outlier* detection. By modeling annual inflation data in December 2006 to December 2013 there are two types of *outlier* that are additive *outlier* (AO) and level shift (LS) *outlier*. The results show that The ARIMA model with the addition of *outlier* are better than the ARIMA model without *outlier*. The ARIMA ([1,12], 1,0) model with the addition of 19 *outliers* meet to the all assumptions that are the significance parameters, normality, homoscedasticity, and independence of residuals as well as the smallest MSE value.

Keywords: Inflation, ARIMA, *Outlier*, MSE

1. Pendahuluan

Inflasi merupakan kecenderungan (trend) atau gerakan naiknya tingkat harga umum yang berlangsung secara terus-menerus dari suatu periode ke periode berikutnya. Inflasi yang terkendali dan rendah dapat mendukung terpeliharanya daya beli masyarakat. Sedangkan inflasi yang tidak stabil akan mempersulit dunia usaha dalam perencanaan kegiatan bisnis, baik dalam kegiatan produksi dan investasi maupun dalam penentuan harga barang dan jasa yang diproduksinya. Oleh karenanya diperlukan prediksi inflasi yang akurat di masa mendatang agar para pelaku usaha dapat melakukan perencanaan yang matang dalam melakukan kegiatan bisnisnya. Selain para pelaku usaha, prediksi inflasi juga diperlukan oleh pemerintah dalam menetapkan RAPBN dan bagi masyarakat inflasi dapat digunakan sebagai bahan pertimbangan untuk merencanakan suatu investasi.

Menurut Bunyamin dan Danila (2011), model inflasi Indonesia terbaik dengan Box-Jenkins menggunakan data inflasi tahunan 1998 - 2008 adalah model AR (2) dengan prediksi inflasi pada tahun 2009 sebesar 10,48%^[2]. Ternyata hasil prediksi ini sangat jauh dengan data riil inflasi tahun 2009 yang besarnya hanya 2,78%. Namun setelah dikaji ulang oleh penulis dengan menggunakan data inflasi tahunan (*yoy / year on year*) Bulan Desember 2006 – Desember 2011, penulis tidak menemukan model Box-Jenkins yang sesuai karena dari model Box-Jenkins yang diidentifikasi ada beberapa model yang signifikan, akan tetapi setelah diverifikasi residualnya ada asumsi yang tidak terpenuhi yaitu independensi residualnya tidak dipenuhi^[8]. Kemudian penulis melakukan kajian ulang menggunakan data inflasi Indonesia tahunan (*yoy*) Bulan Desember 2006 – Desember 2013 dan diperoleh model Box-Jenkins terbaiknya model subset ARIMA ([1,12],1,0) yang memenuhi semua asumsi residualnya namun dari datanya terdeteksi memuat *outlier*^[9]. Tujuan penelitian ini adalah melakukan analisis pemodelan inflasi di Indonesia menggunakan Model ARIMA Box-Jenkins dengan penambahan *outlier*.

2. Tinjauan Pustaka

2.1 Inflasi

Secara sederhana inflasi diartikan sebagai meningkatnya harga-harga secara umum dan terus menerus. Kenaikan harga dari satu atau dua barang saja tidak dapat disebut inflasi kecuali bila kenaikan itu meluas (atau mengakibatkan kenaikan harga) pada barang lainnya. Kebalikan dari inflasi disebut deflasi^[4].

Indikator yang sering digunakan untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK). Perubahan IHK dari waktu ke waktu menunjukkan pergerakan harga dari paket barang dan jasa yang dikonsumsi masyarakat. Sejak Juli 2008, paket barang dan jasa dalam keranjang IHK telah dilakukan atas dasar Survei Biaya Hidup (SBH) Tahun 2007 yang dilaksanakan oleh Badan Pusat Statistik (BPS)^[4]. Target atau sasaran inflasi merupakan tingkat inflasi yang harus dicapai oleh Bank Indonesia, berkoordinasi dengan Pemerintah. Penetapan sasaran inflasi berdasarkan UU mengenai Bank Indonesia dilakukan oleh Pemerintah. Sasaran inflasi yang ditetapkan oleh Pemerintah untuk periode 2012 – 2015, masing-masing sebesar 4,5%, 4,5%, 4,5%, dan 4% masing-masing dengan deviasi $\pm 1\%$ ^[6]. Cara perhitungan inflasi berdasarkan IHK terbagi 2 yaitu inflasi bulanan (*mtm*) dan inflasi tahunan (*yoy*)^[1]. Inflasi bulanan (*mtm*) dihitung dari perubahan indeks bulan tertentudan indeks bulan sebelumnya pada tahun yang sama yaitu

$$\text{Inflasi (mtm) bulan } n \text{ tahun } t = \frac{\text{IHK bulan } n \text{ tahun } t - \text{IHK bulan } (n - 1) \text{ tahun } t}{\text{IHK bulan } (n - 1) \text{ tahun } t} \times 100\%$$

Sedangkan inflasi tahunan (*yoy*) dihitung dari perubahan indeks bulan yang sama pada tahun tertentu dan tahun sebelumnya yaitu

$$\text{Inflasi (yoy) bulan } n \text{ tahun } t = \frac{\text{IHK bulan } n \text{ tahun } t - \text{IHK bulan } n \text{ tahun } (t - 1)}{\text{IHK bulan } n \text{ tahun } (t - 1)} \times 100\%$$

2.2 Analisis Runtun Waktu

Analisis runtun waktu (ARW) merupakan analisis sekumpulan data dalam suatu periode waktu yang lampau yang berguna untuk mengetahui atau meramalkan kondisi masa mendatang. Dalam analisis runtun waktu, pengamatan sekarang (Z_t) tergantung pada satu atau beberapa pengamatan sebelumnya (Z_{t-k}). Pemodelan data runtun waktu yang sering digunakan antara lain adalah metode ARIMA Box-Jenkins^[5]. Menurut Wei (2006), pemodelan data runtun waktu dengan ARIMA Box-Jenkins harus memenuhi syarat stasioneritas, yaitu nilai mean $E(Z_t) = \mu$ dan varians $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ konstan. Uji stasioneritas data dalam mean digunakan Uji Dickey-Fuller. Jika data tidak stasioner dalam mean maka dilakukan diferensi. Sedangkan untuk melihat dan mengatasi ketidakstasioneran dalam varian dapat digunakan transformasi Box-Cox^[11].

Bentuk umum model ARIMA (p, d, q) adalah

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad \text{atau} \quad Z_t = \frac{\theta_q(B)a_t}{\phi_p(B)(1-B)^d} \quad (1)$$

dengan $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ merupakan operator AR(p) yang stasioner dan $\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ merupakan operator MA(q) yang *invertible* dengan a_t merupakan residual yang independen dan berdistribusi normal dengan mean 0 dan varians konstan σ_a^2 ^[7].

Model subset ARIMA merupakan bagian dari model ARIMA tergeneralisasi^[10]. Contoh model subset ARIMA([2,4],1,[1,10]) dapat ditulis sebagai

$$(1 - \phi_2 B^2 - \phi_4 B^4)(1 - B)Z_t = (1 - \theta_1 B - \theta_{10} B^{10})a_t$$

atau
$$Z_t = \frac{(1 - \theta_1 B - \theta_{10} B^{10})a_t}{(1 - \phi_2 B^2 - \phi_4 B^4)(1 - B)} \quad (2)$$

Jika ada beberapa model yang signifikan dengan semua asumsi residual terpenuhi maka dapat dipilih satu model terbaik didasarkan pada nilai MSE terkecil pada masing-masing model yang diverifikasi^[11].

2.3 Deteksi *Outlier*

Outlier adalah nilai pengamatan yang tidak konsisten dalam data runtun waktu atau nilainya jauh berbeda dari data lainnya. Adanya *outlier* sering menyebabkan kesimpulan dari analisis data yang dihasilkan tidak valid. Ada empat macam jenis *outlier* yaitu *Innovational Outlier* (IO), *Additive Outlier* (AO), *Temporary Change* (TC), dan *Level Shift* (LS)^[11].

Additive outlier adalah kejadian yang mempunyai efek pada data runtun waktu hanya pada satu periode saja yaitu pada pengamatan ke-T. Bentuk umum sebuah *Additive Outliers* (AO) dalam proses ARMA didefinisikan sebagai berikut

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

$$= X_t + \omega I_t^{(T)}$$

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

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

adalah variabel indikator yang mewakili ada atau tidak *outlier* pada waktu T.

Innovational outliers adalah kejadian yang efeknya mengikuti proses ARMA. Bentuk umum sebuah *innovational outliers* didefinisikan sebagai

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

$$= \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)}) \quad (4)$$

Level Shift Outlier (LS) adalah kejadian yang mempengaruhi deret pada satu waktu tertentu yang memberikan suatu perubahan tiba-tiba dan permanen. Model *outlier* LS dinyatakan sebagai

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

Temporary Change Outlier (TC) adalah suatu kejadian dimana *outlier* menghasilkan efek awal sebesar ω pada waktu t, kemudian secara perlahan sesuai dengan besarnya δ . Model TC dapat dituliskan sebagai

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

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

2.4 Evaluasi Kinerja Model

Menurut Zainun *et al* (2011), suatu model dikatakan mempunyai kinerja yang sangat bagus jika nilai MAPE kurang dari 10%, dan mempunyai kinerja yang bagus jika nilai MAPE berada diantara 10% sampai 20% dengan


$$MAPE = \frac{1}{m} \sum_{i=1}^m \frac{|Y_i - \hat{Y}_i|}{Y_i} \times 100\% \quad [12].$$

3. Metodologi Penelitian

Data yang digunakan dalam penelitian ini adalah data inflasi tahunan (*yoy / year-on-year*) di Indonesia Bulan Desember 2006 – Agustus 2014 yang diambil dari situs resmi Bank Indonesia^[4]. Data dibagi menjadi 2 bagian yaitu data bulan Desember 2006 – Desember 2013 sebagai data *in sampel* yang digunakan untuk membangun model dan data bulan Januari – Agustus 2014 sebagai data *out sampel* yang digunakan untuk evaluasi model. Pertama memodelkan data *in sampel* menggunakan metode ARIMA Box-Jenkins dan menentukan model terbaiknya berdasarkan nilai MSE terkecil. Kemudian mendeteksi adanya *outlier* dalam data. Jika terdapat *outlier*, dilakukan pemodelan menggunakan ARIMA terbaik dengan penambahan *outlier* satu per satu dan melakukan uji signifikansi parameter model serta melakukan pemeriksaan diagnostik residual. Selanjutnya memilih model terbaik berdasarkan nilai MSE terkecil dari model yang memenuhi semua asumsi residual dan melakukan evaluasi kinerja model menggunakan data *out sampel*. Kemudian menganalisis prediksi inflasi pada bulan Januari 2014 – Desember 2015. Pengolahan data dilakukan menggunakan software Excel, Eviews, R dan SAS.

4. Hasil Dan Pembahasan


Data inflasi tahunan (*yoy*) Indonesia pada Bulan Desember 2006 – Desember 2013 digambarkan dalam Gambar 1.



Gambar 1. Data Inflasi Tahunan (*yoy*) Desember 2006 – Desember 2013

Data Gambar 1 terlihat belum stasioner karena secara visual, mean dan fluktuasinya tidak konstan dan setelah dilakukan uji formal dengan Plot Box-Cox dapat disimpulkan bahwa data belum stasioner dalam varian karena menghasilkan *rounded value* (λ) sebesar 0,5. Oleh karena itu dilakukan transformasi data menggunakan fungsi akar. Kemudian dilakukan Uji Dikey-Fuller dan hasilnya data belum menunjukkan stasioner dalam mean. Selanjutnya dilakukan deferensi lag 1. Setelah dilakukan uji ulang, data telah stasioner. Jadi data inflasi *yoy* Indonesia Bulan Desember 2006 - Desember 2013 bersifat stasioner

setelah ditransformasi ke dalam fungsi akar dan dilakukan diferensi lag 1, meskipun dari plot runtun waktunya terlihat ada pengamatan yang berbeda dari pengamatan lain dan diduga sebagai data *outlier* (Gambar 2).



Gambar 2. Plot Runtun waktu Diferensi lag 1 Setelah Transformasi

Dari data Gambar 2 setelah dilakukan plot *Autocorrelation* (ACF), lag-lag yang signifikan adalah lag 1, 4, 5, 12, 13, 17, 18, dan 30, sehingga dapat diidentifikasi beberapa model subset MA yang mungkin dari kombinasi MA [1,4,5,12,13,17,18,30]. Sementara dari plot *Partial Autocorrelation* / PACF, lag yang signifikan adalah lag 1, 4, dan 12 sehingga dapat diidentifikasi beberapa model subset AR yang mungkin dari kombinasi AR [1,4,12]. Dengan menggabungkan beberapa kombinasi model subset AR dan MA dengan diferensi lag 1 maka diperoleh model terbaik adalah subset ARIMA ([1,12],1,0)^[9] sehingga sesuai Persamaan (2) dan Lampiran 1, model yang terbentuk:

$$(1 - 0,39264B + 0,42134B^{12} - 0,39264B + 0,42134B^{12})(1 - B)Z_t = a_t \quad (7)$$

atau

$$Z_t = \frac{a_t}{(1 - 0,39264B + 0,42134B^{12})(1 - B)} \quad (8)$$

Model (8) mempunyai MSE sebesar 0,01109 untuk data hasil transformasi dan MSE sebesar 0,2784 setelah data dikembalikan ke aslinya.

Untuk meyakinkan ada atau tidaknya *outlier* dalam data, maka dilakukan deteksi *outlier*. Hasilnya terdeteksi 19 *outlier*, yaitu pada data ke-80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42, 47, 37, 18 dan 30, yang bertipe *Additive Outlier* (AO) pada data *outlier* ke- 56, 38, 70, 14, 22, 32, 42, 47, 18 dan *Level Shift* (LS) pada data *outlier* yang lainnya (Lampiran 2). Selanjutnya dilakukan uji signifikansi parameter dan pemeriksaan diagnostik residual pada model ARIMA terbaik dengan menambahkan *outlier* satu per satu yang hasilnya dapat dilihat pada Tabel 2. Dari Tabel 2 terlihat ada 10 model signifikan yang memenuhi semua asumsi residualnya dengan nilai MSE tertera pada Tabel 3.

Tabel 2. Uji Signifikansi Parameter dan Pemeriksaan Diagnostik Model

ARIMA ([1,12],1,0) + <i>Outlier</i> Data ke-	Signifikansi parameter	Independensi	Homokedastisitas	Normalitas
80	√	√	√	√
80, 31	√	√	√	√
80, 31, 40	√	√	√	√
80, 31, 40, 56	√	√	√	√
80, 31, 40, 56, 38	√	√	√	√
80, 31, 40, 56, 38, 26	√	x	x	√
80, 31, 40, 56, 38, 26, 70	√	x	x	√
80, 31, 40, 56, 38, 26, 70, 46	√	√	x	√
80, 31, 40, 56, 38, 26, 70, 46, 14	√	√	√	√
80, 31, 40, 56, 38, 26, 70, 46, 14, 22	√	√	√	√
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32	√	√	√	√
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76	x	√	√	√
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75	√	√	√	√
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44	x	√	√	√
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42	√	√	√	x
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42, 47	√	√	√	X
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42, 47, 37	√	√	√	X
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42, 47, 37, 18	√	√	√	X
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42, 47, 37, 18, 30	√	√	√	√

Tabel 3. Nilai MSE dari Model Data Transformasi

Model ARIMA ([1,12],1,0) + <i>Outlier</i> Data ke-	MSE
80	0,00808
80, 31	0,00643
80, 31, 40	0,00593
80, 31, 40, 56	0,00548
80, 31, 40, 56, 38	0,00513
80, 31, 40, 56, 38, 26, 70, 46, 14	0,00379
80, 31, 40, 56, 38, 26, 70, 46, 14, 22	0,00357
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32	0,00335
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75	0,00303
80, 31, 40, 56, 38, 26, 70, 46, 14, 22, 32, 76, 75, 44, 42, 47, 37, 18, 30	0,00201
Model ARIMA ([1,12],1,0)	0,01109

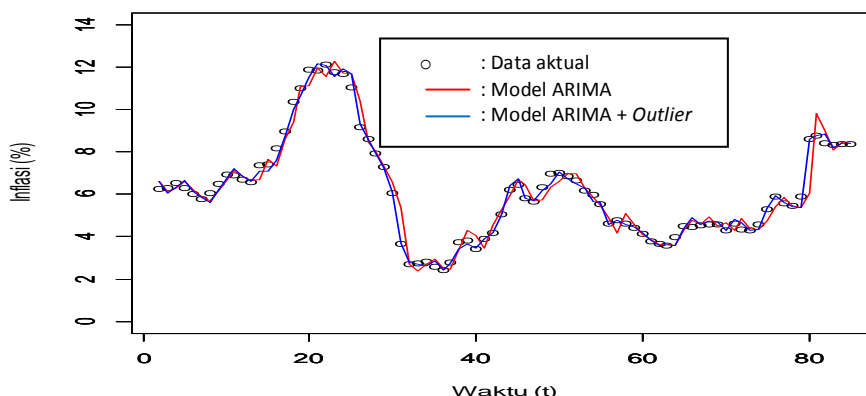
Dari perbandingan nilai MSE (Tabel 3), model ARIMA dengan penambahan *outlier* lebih bagus dari model ARIMA tanpa *outlier*. Pemilihan model terbaik berdasarkan nilai MSE terkecil yaitu model ARIMA ([1,12],1,0) dengan penambahan 19 *outlier* yang mempunyai MSE sebesar 0,00201 dari data transformasi dan setelah data dikembalikan ke bentuk aslinya diperoleh MSE sebesar 0,050978. Berdasarkan model subset ARIMA([1,12],1,0) dengan penambahan 19 *outlier* yang bertipe AO (Persamaan (3)) dan LS (Persamaan (5)) maka model yang terbentuk (sesuai Lampiran 3) adalah

$$\begin{aligned}
 Z_t = & \frac{a_t}{(1 - 0,59275B + 0,38877B^{12})(1 - B)} + \frac{0,45358}{(1 - B)} I_T^{(80)} - \frac{0,38474}{(1 - B)} I_T^{(31)} \\
 & - \frac{0,22784}{(1 - B)} I_T^{(40)} - 0,11247 I_T^{(56)} + 0,13044 I_T^{(38)} - \frac{0,11247}{(1 - B)} 0,19097 I_T^{(26)} \\
 & - 0,08896 I_T^{(70)} - \frac{0,14125}{(1 - B)} I_T^{(46)} + 0,08524 I_T^{(31)} + 0,07035 I_T^{(22)} \\
 & - 0,09534 I_T^{(32)} + \frac{0,14376}{(1 - B)} I_T^{(76)} + \frac{0,12200}{(1 - B)} I_T^{(75)} + \frac{0,13146}{(1 - B)} I_T^{(44)} - 0,06359 I_T^{(42)} \\
 & - 0,06257 I_T^{(47)} + \frac{0,09631}{(1 - B)} I_T^{(37)} + 0,07004 I_T^{(18)} - \frac{0,11002}{(1 - B)} I_T^{(30)}
 \end{aligned} \tag{9}$$

Perbandingan model ARIMA ([1,12],1,0) dan model ARIMA ([1,12],1,0) dengan penambahan 19 outlier disajikan dalam Tabel 4. Dari Tabel 4 terlihat model ARIMA ([1,12],1,0) dengan penambahan 19 outlier lebih baik dari model ARIMA ([1,12],1,0) tanpa outlier karena menghasilkan MSE yang lebih kecil, dengan kinerja model sangat bagus karena nilai MAPE < 10%. Sedangkan perbandingan data aktual, prediksi model ARIMA ([1,12],1,0) dan model ARIMA ([1,12],1,0) dengan penambahan 19 outlier disajikan dalam Gambar 3. Dari Gambar 3 terlihat prediksi model ARIMA ([1,12],1,0) dengan penambahan 19 outlier lebih dekat dengan data aktual sehingga model inflasi dengan penambahan outlier lebih baik. Kedekatan ini yang mengakibatkan besarnya nilai MSE model ARIMA dengan penambahan outlier lebih kecil dari MSE model ARIMA tanpa outlier. Jadi secara visual dan secara statistik menunjukkan bahwa model ARIMA ([1,12],1,0) dengan penambahan 19 outlier lebih baik dari model ARIMA ([1,12],1,0) tanpa outlier.

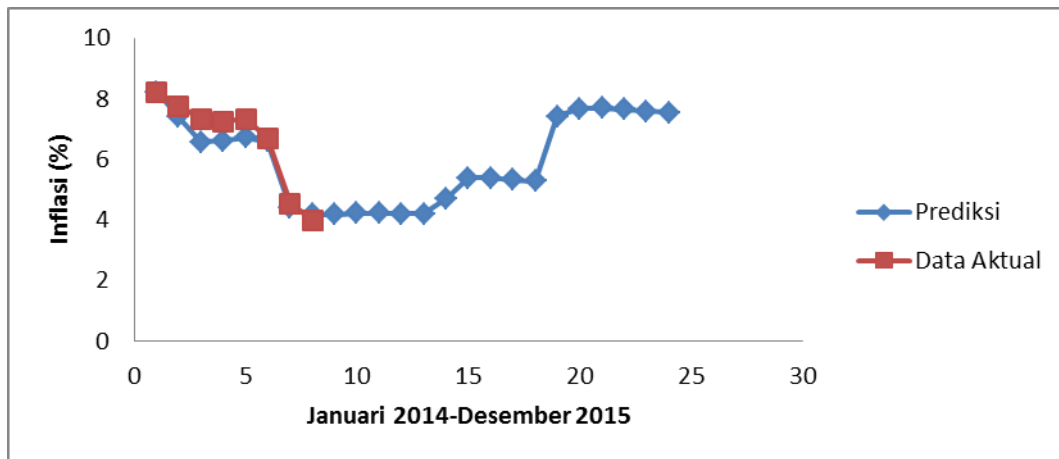
Tabel 4. Perbandingan Model ARIMA dengan dan Tanpa Outlier

Model	ARIMA([1,12],1,0)	ARIMA ([1,12],1,0) + 19 outlier
MSE in sampel	0,27844	0,05098
MSE out sampel	0,569477	0,194908
MAPE out sampel	9,6773 %	5,2294 %
Kinerja model	Sangat bagus	Sangat bagus



Gambar 3. Perbandingan Data Aktual, Model Subset ARIMA ([1,12],1,0) dan Subset ARIMA ([1,12],1,0) dengan Penambahan 19 Outlier

Perbandingan data aktual bulan Januari – Agustus 2014 dan prediksi inflasi bulan Januari 2014 – Desember 2015 menggunakan model subset ARIMA $([1,12],1,0)$ dengan penambahan 19 *outlier* disajikan dalam Gambar 4. Dari Gambar 4 terlihat prediksi pada bulan Januari – Agustus 2014 sangat dekat dengan data aktualnya bahkan pada bulan Januari, Februari, Juli dan Agustus 2014 hampir mendekati data aktualnya. Jadi penyimpangan atau error yang terjadi cukup kecil. Diprediksikan besar inflasi pada akhir tahun 2015 sekitar 8% sehingga target inflasi tahun 2015 yang telah ditetapkan pemerintah sebesar $(4\pm 1)\%$ diperkirakan tidak dapat tercapai.



Gambar 4. Prediksi Inflasi Bulan Januari 2014 – Desember 2015

5. Kesimpulan

Hasil penelitian menunjukkan bahwa model subset ARIMA $([1,12],1,0)$ dengan penambahan 19 *outlier* memenuhi semua asumsi residual (yaitu independen, berdistribusi normal dengan varian konstan) dan merupakan model terbaik dari Model ARIMA dengan penambahan *outlier* dan lebih baik dari Model ARIMA tanpa *outlier*. Dengan menggunakan model subset ARIMA $([1,12],1,0)$ dengan penambahan 19 *outlier*, diprediksikan besar inflasi pada akhir tahun 2015 sekitar 8% dan target inflasi tahun 2015 yang telah ditetapkan pemerintah sebesar $(4\pm 1)\%$ diperkirakan tidak dapat tercapai.

DAFTAR PUSTAKA

1. BPS, Data Strategis BPS, 2012.
2. Bunyamin dan Danila, N., Estimasi Inflasi di Indonesia dengan Menggunakan Metodologi Box Jenkins, *National Journals*, 2011, Vol. 18, No. 2.
3. <http://www.bi.go.id/id/moneter/inflasi/data/Default.aspx>
4. <http://www.bi.go.id/id/moneter/inflasi/pengenalan/Contents/Default.aspx>
5. Makridakis, S., Wheelwright, S.C., and McGee, V.E., *Metode dan Aplikasi Peramalan*, Jilid satu edisi kedua, Terjemahan Ir. Hari Suminto, Bina Rupa Aksara, Jakarta, 1999.
6. PMK No.66/PMK.011/2012 tanggal 30 April 2012
7. Soejoeti, Z., *Materi Pokok Analisis Runtun Waktu*, Karunika, Jakarta, 1987.
8. Suparti, Analisis Data Inflasi di Indonesia Menggunakan Model Regresi Spline, *Jurnal Media Statistika*, 2013, Vol. 6, No.1.

9. Suparti, Warsito, B. dan Mukid, M.A., The Analysis of Indonesia Inflation Data Using Box-Jenkins Models, *The 4th ISNPINSA Proceeding*, FSM Undip Semarang, 2014.
10. Tarno, Kombinasi Prosedur Pemodelan Subset Arima dan Deteksi *Outlier* untuk Prediksi Data Runtun Waktu, *Prosiding Seminar Nasional Statistika UNDIP Semarang*, 2013.
11. Wei, W.W.S., *Time Series Analysis, Univariate and Multivariate Methods*, Addison Wesley Publishing Company, Canada, 2006.
12. Zainun, N.Y., Rahman, I.A. and Eftekhari, M., Forecasting Low-Cost Housing Demand In Pahang, Malaysia Using Artificial Neural Networks. *Journal of Surveying, Construction and Property (Special Issue)*, 2011, Vol. 2.

Lampiran :

1. Estimasi Parameter Model ARIMA ([1,12],1,0)

```

The SAS System          22:23 Friday, June 25, 2014 36
The ARIMA Procedure
Conditional Least Squares Estimation
Standard Approx
Parameter Estimate Error t Value Pr > |t| Lag
AR1,1 0.39264 0.09081 4.32 <.0001 1
AR1,2 -0.42134 0.10280 -4.10 <.0001 12

Dependent Variable RESIDUAL
Residual: Actual-Forecast
Ordinary Least Squares Estimates

SSE 0.93136783 DFE 84
MSE 0.01109 Root MSE 0.10530
SBC -139.77942 AIC -139.77942
Regress R-Square 0.0000 Total R-Square 0.0000
Durbin-Watson 1.9260
    
```

2. Deteksi Outlier

```

Outlier Detection Summary
Maximum number searched 30
Number found 19

Significance used 0.05
Outlier Details

Obs Time ID Type Estimate Chi-Square Approx Prob> ChiSq
80 AUG2012 Shift 0.46613 31.93 <.0001
31 JUL2008 Shift -0.32324 22.81 <.0001
40 APR2009 Shift -0.17471 5.18 0.0229
56 AUG2010 Additive -0.10214 6.01 0.0142
38 FEB2009 Additive 0.08904 5.05 0.0246
26 FEB2008 Shift -0.15667 6.80 0.0091
70 OCT2011 Additive -0.08757 5.50 0.0190
46 OCT2009 Shift -0.12249 4.57 0.0326
14 FEB2007 Additive 0.07227 4.34 0.0372
22 OCT2007 Additive 0.07125 4.00 0.0455
32 AUG2008 Additive -0.06777 5.25 0.0220
76 APR2012 Shift 0.11154 5.00 0.0254
75 MAR2012 Shift 0.11651 5.84 0.0157
44 AUG2009 Shift 0.09573 4.55 0.0330
42 JUN2009 Additive -0.06152 5.25 0.0219
47 NOV2009 Additive -0.05943 4.91 0.0267
37 JAN2009 Shift 0.09675 6.38 0.0115
18 JUN2007 Additive 0.05899 6.37 0.0116
30 JUN2008 Shift -0.08991 5.51 0.0189
    
```

3. Estimasi Parameter Model ARIMA ([1,12],1,0) + 19 Outlier

The SAS System 10:58 Saturday, June 26, 2014 1
 The ARIMA Procedure
 Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr > t	Approx		Shift
					Lag	Variable	
AR1,1	0.59275	0.07978	7.43	<.0001	1	y	0
AR1,2	-0.38877	0.08251	-4.71	<.0001	12	y	0
NUM1	0.45358	0.04470	10.15	<.0001	0	o1	0
NUM2	-0.38474	0.04932	-7.80	<.0001	0	o2	0
NUM3	-0.22784	0.04380	-5.20	<.0001	0	o3	0
NUM4	-0.11247	0.02581	-4.36	<.0001	0	o4	0
NUM5	0.13044	0.02720	4.80	<.0001	0	o5	0
NUM6	-0.19097	0.04459	-4.28	<.0001	0	o6	0
NUM7	-0.08896	0.02530	-3.52	0.0008	0	o7	0
NUM8	-0.14215	0.04393	-3.24	0.0019	0	o8	0
NUM9	0.08524	0.02620	3.25	0.0018	0	o9	0
NUM10	0.07035	0.02537	2.77	0.0073	0	o10	0
NUM11	-0.09534	0.02749	-3.47	0.0010	0	o11	0
NUM12	0.14376	0.04983	2.88	0.0054	0	o12	0
NUM13	0.12200	0.04985	2.45	0.0172	0	o13	0
NUM14	0.13146	0.04616	2.85	0.0059	0	o14	0
NUM15	-0.06359	0.02714	-2.34	0.0223	0	o15	0
NUM16	-0.06257	0.02618	-2.39	0.0199	0	o16	0
NUM17	0.09631	0.04429	2.17	0.0334	0	o17	0
NUM18	0.07004	0.02624	2.67	0.0097	0	o18	0
NUM19	-0.11002	0.04741	-2.32	0.0236	0	o19	0