

**Peramalan dengan Metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)*  
di Bidang Ekonomi  
(Studi Kasus: Inflasi Indonesia)**

*Forecasting Using Seasonal Autoregressive Integrated Moving Average (SARIMA) Method  
in Economic Sector  
(Case Study: The Inflation of Indonesia)*

**Verawaty Bettyani Sitorus<sup>1</sup>, Sri Wahyuningsih<sup>2</sup>, Memi Nor Hayati<sup>3</sup>**

<sup>1</sup>Mahasiswa Program Studi Statistika FMIPA Universitas Mulawarman

<sup>2,3</sup>Dosen Program Studi Statistika FMIPA Universitas Mulawarman

Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Mulawarman

e-mail: vera1793@yahoo.com<sup>1</sup>, swahyuningsih@gmail.com<sup>2</sup>, meminorhayati@yahoo.com<sup>3</sup>

**Abstract**

*A present event is probably a reiteration from a past event. The reiteration of an event every particular time period indicates seasonal pattern. Seasonal Autoregressive Integrated Moving Average (SARIMA) is one of the methods that is used for data forecasting which has seasonal pattern. The purposes of this research are finding out the best SARIMA model and forecasting the inflation in Indonesia for period January 2016 until December 2016 using the best SARIMA model. Sample of this research is 96 Indonesia inflation data (mtm) for period January 2008 until December 2015. The technique of this research is purposive sampling. There are five steps of SARIMA method, those are model identification, model estimating, diagnostic checking, selecting the best model, and forecasting. Based on the analysis, the best SARIMA model is SARIMA (1,0,0)(0,1,0)<sup>12</sup>. The forecasting of Indonesia inflation 2016 has similar pattern with the previous time. The inflation increases in January 2016 and decreases in February 2016 until April 2016. The inflation increases again in Mey 2016 until August 2016 and decreases in September 2016 until November 2016. At last, the inflation increases in December 2016.*

*Keywords: Inflation, SARIMA method, seasonal*

**Pendahuluan**

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini. Peramalan mempunyai posisi yang strategis dan menjelajah ke dalam banyak bidang seperti ekonomi, keuangan, pemasaran, produksi, riset operasional, administrasi negara, meteorologi, geofisika, kependudukan, dan pendidikan.

Metode SARIMA digunakan jika pola data memiliki komponen musiman. Musiman berarti kecenderungan mengulangi pola tingkah gerak dalam periode musim, biasanya satu tahun untuk data bulanan. Deret waktu musiman mempunyai karakteristik yang ditunjukkan oleh adanya korelasi beruntun yang kuat pada jarak semusim (periode musim), yakni waktu yang berkaitan dengan banyak observasi per periode musim.

Terdapat beberapa penelitian terdahulu menggunakan metode SARIMA yang menjadi acuan dalam penelitian ini, di antaranya yaitu penelitian Dewi (2014) yang meramalkan jumlah produksi air bersih dan Prabowo (2015) yang meramalkan permintaan produk.

Berdasarkan uraian di atas, maka penulis melakukan penelitian yang berjudul: "Peramalan dengan Metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*) di Bidang Ekonomi (Studi Kasus: Inflasi Indonesia).

**Stasioneritas dalam Variansi**

Stasioner dalam variansi adalah kondisi di mana data deret waktu tidak memperlihatkan adanya perubahan variansi yang jelas dari waktu ke waktu. Bila kondisi stasioner dalam variansi tidak terpenuhi, Box dan Cox (1964) dalam Aswi dan Sukarna (2006) memperkenalkan transformasi pangkat (*power transformation*) untuk menstabilkan variansi data yang tidak stasioner.

$$g(Z_t) = \begin{cases} Z_t^{(\lambda)} = \frac{Z_t^{(\lambda)} - 1}{\lambda}, & \lambda \neq 0 \\ \log Z_t & , \lambda = 0 \end{cases} \quad (1)$$

**Stasioneritas dalam Rata-Rata**

Stasioner dalam rata-rata adalah kondisi di mana tidak ada perubahan rata-rata yang jelas dari waktu ke waktu. Apabila kondisi stasioner dalam rata-rata tidak terpenuhi, dapat dilakukan *differencing*. Secara umum operasi *differencing* yang menghasilkan suatu kejadian baru yang stasioner dirumuskan sebagai berikut (Salamah dkk, 2003):

$$W_t = (1 - B)^d Z_t \quad (2)$$

Dickey-Fuller mengembangkan uji akar unit yang dikenal dengan uji *Augmented Dickey-Fuller (ADF)* yang sering digunakan untuk mendeteksi apakah data stasioner atau tidak.

**White Noise**

Suatu proses  $\{a_t\}$  dinamakan *white noise* (proses yang bebas dan identik) jika bentuk peubah acak yang berurutan tidak saling berkorelasi dan mengikuti distribusi tertentu. Rata-rata  $E(a_t) = \mu_a$  dari proses ini diasumsikan bernilai nol dan mempunyai variansi yang konstan yaitu  $v(a_t) = \sigma_a^2$  dan nilai kovariansi untuk proses ini  $\gamma_k = c_1(a_t, a_{t+k}) = 0$  untuk  $k \neq 0$ . Statistik uji yang digunakan adalah Ljung-Box (Aswi dan Sukarna, 2006):

$$Q^* = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)}, n > k(3)$$

**Fungsi Autokorelasi dan Autokorelasi Parsial**

Fungsi autokorelasi (ACF) dibentuk dengan himpunan  $\{\rho_k; k = 0, 1, 2, \dots\}$  dengan  $\rho_0 = 1$ . Nilai ACF diperoleh dengan rumus sebagai berikut:

$$\hat{\rho}_k = \frac{\bar{Y}_k}{\bar{Y}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} (4)$$

Fungsi autokorelasi parsial (PACF) digunakan untuk mengukur keeratan (*association*) antara  $Z_t$  (data pada waktu ke- $t$ ) dan  $Z_{t-k}$  apabila pengaruh dari *time lag* 1,2,3,..., dan seterusnya sampai  $k-1$  dianggap terpisah. Rumus PACF atau  $\phi_k$  adalah:

$$\phi_k = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-j} \rho_{k-j}} (5)$$

(Aswi dan Sukarna, 2006).

**Parsimoni**

Pada prinsip identifikasi awal suatu model, beberapa model diselidiki dan setelah diselidiki dengan baik, beberapa model yang berbeda disimpulkan memenuhi kriteria atau asumsi tertentu. Selanjutnya, digunakan prinsip statistik “parsimoni” yang menyatakan model yang lebih sederhana lebih disenangi dari pada model dengan parameter yang banyak.

**Identifikasi Model**

Tabel 1. Pola Teoritik ACF dan PACF dari Proses yang Stasioner

Proses	ACF	PACF
AR (p)	Turun cepat secara eksponensial	Cuts off after lag p
MA (q)	Cuts off after lag q	Turun cepat secara eksponensial
ARMA (p,q)	Turun cepat setelah lag q-p	Turun cepat setelah lag-p-q

(Salamah dkk, 2006)

Grafik ACF dan grafik PACF, dapat digunakan untuk menentukan orde model ARIMA. Secara umum, Tabel 1 dapat digunakan untuk mengidentifikasi tingkat  $p$  dan  $q$  dari suatu data deret waktu berdasarkan bentuk ACF dan PACF taksirannya.

**Asumsi Residual Berdistribusi Normal**

Uji Kolmogorov-Smirnov digunakan untuk mengetahui apakah distribusi nilai dalam sampel sesuai dengan distribusi teoritis tertentu, misalnya normalitas data. Berikut adalah tahapan uji Kolmogorov-Smirnov:

- Merumuskan hipotesis  
 $H_0$ : Residual berdistribusi normal  
 $H_1$ : Residual tidak berdistribusi normal
- Menentukan nilai taraf signifikansi ( $\alpha$ ) yang digunakan.
- Menentukan statistik uji (Siegel, 2011):  
 $D_{n,i} = s_i |F_0(X) - S_n(X)| (6)$
- Menentukan daerah kritik (daerah penolakan)  $H_0$ , yaitu:  
 $H_0$  ditolak jika nilai  $D_{n,i} > D_{(n,\alpha)}$  atau  $H_0$  ditolak jika nilai  $P\text{-value} < \alpha$ .  
 $D_{(n,\alpha)}$  didapatkan dari tabel Kolmogorov-Smirnov.
- Menarik keputusan dan kesimpulan.

**Kriteria Pemilihan Model Terbaik**

Pemilihan model terbaik (2,27) menggunakan kriteria *Root Mean Square Error* (RMSE). Kriteria RMSE dirumuskan sebagai berikut (Yamin dan Kurniawan, 2009):

$$R = \sqrt{\frac{1}{n} \sum_{t=1}^n a_t^2} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} (7)$$

Semakin kecil nilai RMSE berarti nilai taksiran semakin mendekati nilai sebenarnya, atau model yang dipilih merupakan model terbaik.

**Peramalan**

Peramalan merupakan suatu cara yang digunakan untuk mengetahui nilai atau keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan. Jika seluruh parameter model signifikan dan seluruh asumsi *residual* terpenuhi, peramalan dapat dilakukan.

**Inflasi**

Menurut Boediono (1998), inflasi digolongkan menjadi 4 macam, yaitu:

- Inflasi ringan : < 10% per tahun
- Inflasi sedang : 10 – 30% per tahun
- Inflasi berat : 30 – 100% per tahun
- Hiperinflasi :  $\geq 100\%$  per tahun

**Metodologi Penelitian**

Rancangan penelitian ini adalah rancangan penelitian kausal komparatif yang bersifat *ex post facto*, artinya data dikumpulkan setelah semua kejadian yang dipersoalkan berlangsung. Data

sekunder yang dikumpulkan adalah data inflasi Indonesia (mtm) sektor pendidikan, rekreasi, dan olahraga yang diperoleh dari *website* resmi Badan Pusat Statistik (BPS) yaitu, *www.bps.go.id*. Adapun populasi dalam penelitian ini adalah seluruh data inflasi di Indonesia. Sampel yang digunakan dalam penelitian ini adalah data inflasi Indonesia (mtm) sektor pendidikan, rekreasi, dan olahraga periode Januari 2008 sampai dengan Desember 2015, yaitu sebanyak 96 data deret waktu. Pada penelitian ini teknik *sampling* yang digunakan dalam pengambilan sampel adalah *purposive sampling*. Analisis yang digunakan adalah analisis statistika deskriptif dan metode SARIMA.

Tahapan dalam melakukan peramalan dengan metode 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 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 ACF dan grafik PACF 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 memperhatikan *lags* pada grafik PACF untuk parameter AR dan grafik ACF untuk parameter MA.
3. Pemeriksaan Diagnostik  
Pemeriksaan diagnostik dibagi dalam 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 menggunakan RMSE.
5. Peramalan  
Tahap terakhir adalah melakukan peramalan dari model SARIMA  $(p,d,q)(P,D,Q)^S$  terbaik.

## Hasil dan Pembahasan

Pada Tabel 2 ditampilkan statistika deskriptif untuk data inflasi Indonesia (mtm) sektor pendidikan, rekreasi, dan olahraga periode Januari 2008 sampai dengan Desember 2015.

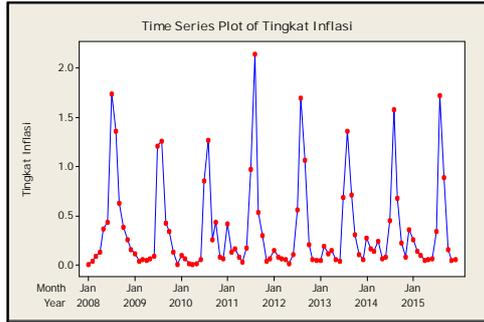
Tabel 2. Statistika Deskriptif dari Data Inflasi Indonesia (mtm)

Tahun	Rata-Rata	Standar Deviasi	Maksimum	Minimum
2008	0,47	0,54	1,74	0,01
2009	0,32	0,45	1,26	0,01
2010	0,27	0,40	1,27	0,01
2011	0,42	0,60	2,14	0,03
2012	0,35	0,52	1,70	0,02
2013	0,32	0,40	1,36	0,04
2014	0,36	0,42	1,58	0,07
2015	0,33	0,50	1,72	0,05

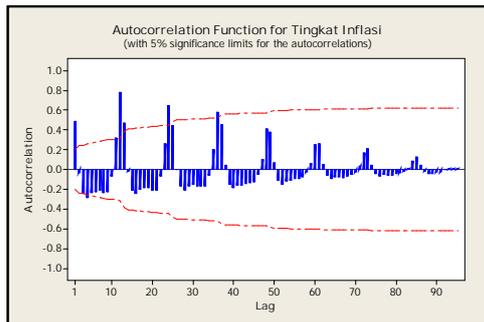
Berdasarkan Tabel 2, dapat dilihat bahwa inflasi Indonesia (mtm) memiliki rata-rata inflasi tertinggi yakni pada tahun 2008 yaitu sebesar 0,47 persen per bulan dengan inflasi tertinggi pada tahun 2008 sebesar 1,74 persen dan inflasi terendah pada tahun 2008 sebesar 0,01 persen. Keragaman inflasi pada tahun 2008 dapat dilihat dari nilai standar deviasinya yaitu sebesar 0,54 persen. Dapat dilihat juga bahwa inflasi Indonesia (mtm) memiliki rata-rata inflasi terendah yakni pada tahun 2010 yaitu sebesar 0,27 persen per bulan dengan inflasi tertinggi pada tahun 2010 sebesar 1,27 persen dan inflasi terendah pada tahun 2010 sebesar 0,01 persen. Keragaman inflasi pada tahun 2010 dapat dilihat dari nilai standar deviasinya yaitu sebesar 0,40 persen.

## Identifikasi Model

Pada Gambar 1 dan Gambar 2, ditampilkan *time series plot* dan grafik ACF untuk data inflasi Indonesia (mtm). Berdasarkan Gambar 1 dapat dilihat bahwa inflasi Indonesia (mtm) diindikasikan berpola musiman, di mana adanya pola yang sama dalam suatu periode yang tetap (pola berulang setiap lebih kurang setahun) yang panjangnya adalah 12 periode (12 bulan). Inflasi pada periode Januari 2008 sampai dengan Desember 2008 memiliki pola yang hampir sama dengan inflasi pada periode Januari 2009 sampai dengan Desember 2009 dan seterusnya secara berulang. Pada awal Januari 2008 inflasi adalah rendah dan kemudian meningkat terus sampai bulan Juli tahun 2008 dan bulan Agustus tahun 2008. Setelah itu, inflasi menurun dari bulan September tahun 2008 sampai dengan bulan Desember tahun 2008. Pola seperti ini terjadi secara berulang dari tahun 2008 sampai dengan tahun 2015.



Gambar 1. *TS*plot data inflasi Indonesia (mtm)



Gambar 2. Grafik ACF data inflasi Indonesia (mtm)

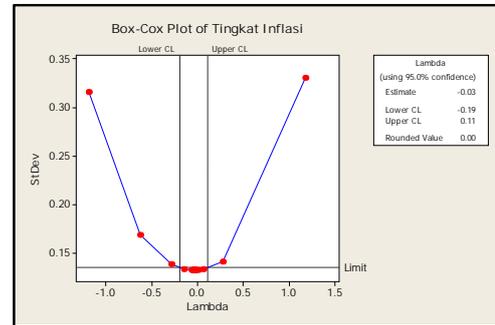
Berdasarkan Gambar 2 dapat dilihat bahwa koefisien autokorelasi pada lag 12, 24, dan 36 membentuk gelombang sinus. Bentuk fungsi autokorelasi yang demikian ditemukan pada data berpola musiman, di mana untuk data berpola musiman akan mendapatkan puncak koefisien korelasi pada lag  $S$ ,  $2S$ ,  $3S$ , dan seterusnya. Karena data memiliki pola musiman 12, maka analisis deret waktu yang digunakan adalah SARIMA  $(p,d,q)(P,D,Q)^{12}$ .

Berdasarkan Gambar 1 dapat dilihat dengan jelas bahwa data mengalami variasi fluktuasi yang terjadi setiap bulan Juli, Agustus, dan September pada tahun 2008-2015. Variasi besarnya fluktuasi dari waktu ke waktu menunjukkan adanya sifat non-stasioneritas dalam variansi. Hal ini harus distabilkan, yaitu harus diperoleh variansi yang stasioner sebelum dilakukan identifikasi model SARIMA.

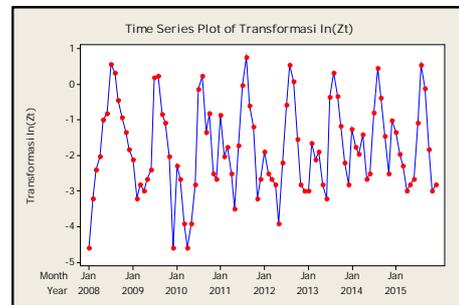
Pemeriksaan stasioneritas dalam variansi menggunakan *time series plot* saja belum cukup, karena masih bersifat subjektif. Oleh karena itu, digunakan Box-Cox *plot* untuk memeriksa stasioneritas dalam variansi karena lebih bersifat objektif.

Berdasarkan Gambar 3 dapat dilihat bahwa data inflasi Indonesia (mtm) belum stasioner dalam variansi, karena data memiliki nilai *rounded value* sebesar  $\neq 0$ . Untuk menstabilkan variansi data yang tidak stasioner dalam variansi, diperlukan transformasi Box-Cox. Transformasi yang sesuai adalah transformasi  $(\ln Z_t)$ . Pada

tahap peramalan, hasil peramalan harus dikembalikan dengan cara melakukan transformasi eksponensial terhadap data hasil peramalan.



Gambar 3. Box-Cox *plot* data inflasi Indonesia (mtm)

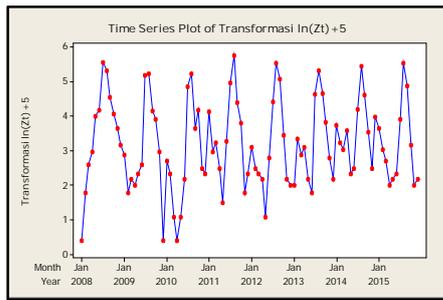


Gambar 4. *TS*plot data hasil transformasi  $(\ln Z_t)$

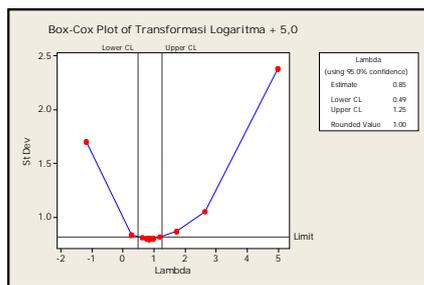
Berdasarkan Gambar 4, sebagian besar data hasil transformasi  $(\ln Z_t)$  berada di bawah nol (bernilai negatif). Oleh karena itu, pengecekan stasioneritas dalam variansi menggunakan Box-Cox *plot* tidak dapat dilakukan. Agar seluruh deret bernilai positif, maka seluruh data ditambah dengan konstanta sebesar 5 (tergantung peneliti). Penambahan konstanta pada data hasil transformasi  $(\ln Z_t)$  tidak akan mengubah pola dari data tersebut. Pada Gambar 5 akan ditampilkan *TS plot* untuk data transformasi  $(\ln Z_t + 5)$ .

Berdasarkan Gambar 5, dapat dilihat bahwa seluruh data telah berada di atas nol (bernilai positif). Sehingga, pengecekan stasioneritas dalam variansi menggunakan Box-Cox *plot* dapat dilakukan. Berikut adalah Box-Cox *plot* untuk data inflasi setelah dilakukan transformasi  $(\ln Z_t + 5)$ .

Berdasarkan Gambar 6 dapat dilihat bahwa nilai *rounded value* sebesar  $=1$ , sehingga data hasil transformasi  $(\ln Z_t)$  disimpulkan telah stasioner dalam variansi. Selanjutnya, akan dilihat apakah data telah stasioner dalam rata-rata.



Gambar 5. *TSplot* data hasil transformasi  $(\ln Z_t + 5)$



Gambar 6. Box-Cox *plot* data hasil transformasi  $(\ln Z_t + 5)$

Berdasarkan Gambar 4, dapat dilihat data hasil transformasi  $(\ln Z_t)$  tidak stasioner dalam rata-rata, karena terjadi kenaikan jangka panjang pada data inflasi (*trend*) hasil transformasi. Untuk itu, diperlukan *differencing* terhadap data inflasi tersebut. Namun, untuk memastikan bahwa data tidak stasioner dalam rata-rata, maka akan dilakukan pengujian ADF terhadap data inflasi hasil transformasi  $(\ln Z_t)$ .

Hipotesis

$$H_0: \gamma = 0 \text{ (Data inflasi tidak stasioner)}$$

$$H_1: \gamma \neq 0 \text{ (Data inflasi stasioner)}$$

Taraf signifikansi

$$\alpha = 1\%$$

Statistik uji

$$|\tau| = \left| \frac{\hat{\gamma}}{S(\hat{\gamma})} \right| = 2,134529$$

Daerah kritik

$H_0$  ditolak jika nilai  $|\tau| > |\tau|_{Mc.Kinnon}$   
 atau  $H_0$  ditolak jika nilai  $P\text{-value} < \alpha$

Keputusan

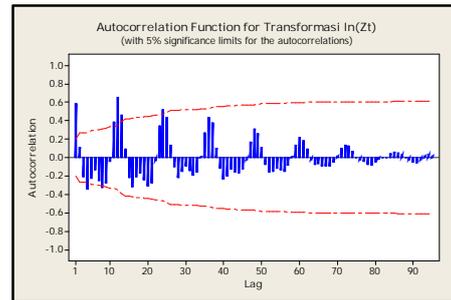
Karena nilai  $|\tau| = 2,134529 < |\tau|_{Mc.Kinnon} = 4,071006$  atau nilai  $P\text{-value} = 0,5191 > \alpha = 0,01$ , maka diputuskan  $H_0$  gagal ditolak

Kesimpulan

Data inflasi tidak stasioner

Berdasarkan hasil pengujian ADF, dapat disimpulkan data hasil transformasi  $(\ln Z_t)$  adalah tidak stasioner. Oleh karena itu, *differencing* dilakukan pada data inflasi hasil transformasi  $(\ln Z_t)$  untuk menstasionerkan data dalam rata-

rata. Pada Gambar 7 akan ditampilkan grafik ACF dari data hasil transformasi  $(\ln Z_t)$  untuk menentukan jenis *differencing* yang harus digunakan.



Gambar 7. Grafik ACF data hasil transformasi  $(\ln Z_t)$

Berdasarkan Gambar 7 dapat dilihat bahwa nilai ACF untuk *lag* non-musiman (*lag* 1,2,3...) cenderung tidak turun secara lambat. Hal ini dapat dilihat dari nilai-nilai ACF pada setiap *lag* non-musiman yang relatif berbeda jauh dengan *lag* sebelumnya, yaitu nilai ACF pada *lag* 1 sebesar 0,58, nilai ACF pada *lag* 2 sebesar 0,10, dan nilai ACF pada *lag* 3 sebesar -0,20. Sehingga berdasarkan nilai-nilai ACF pada *lag* non-musiman tersebut dapat dikatakan data inflasi hasil transformasi  $(\ln Z_t)$  telah stasioner dalam rata-rata non-musiman dan tidak memerlukan *differencing* non-musiman.

Dari Gambar 7 untuk *lag* musiman (*S*, *2S*, *3S*,...), nilai ACF cenderung turun lambat atau turun secara linier. Hal ini dapat dijelaskan dari nilai ACF untuk *lag* musiman yang relatif tidak berbeda jauh dengan *lag* sebelumnya, yaitu nilai ACF pada *lag* 1 adalah 0,58, nilai ACF pada *lag* 12 adalah 0,64, dan nilai ACF pada *lag* 24 adalah 0,52. Berdasarkan nilai-nilai ACF tersebut dapat diindikasikan data inflasi hasil transformasi  $(\ln Z_t)$  masih belum stasioner dalam rata-rata musiman. Sehingga, diperlukan *differencing* musiman untuk menstasionerkan data inflasi tersebut dalam rata-rata musiman.

*Differencing* musiman yang digunakan adalah *differencing* musiman 12 orde satu, dengan cara mengurangi nilai pengamatan pada waktu *t* dengan nilai pengamatan pada waktu sebelumnya (*t - S*). *Differencing* musiman 12 orde satu dapat ditulis  $W_t = (1 - B^{12}) \ln Z_t$  atau  $D=1$ , di mana akan dilakukan *differencing* musiman 12 orde satu  $W_t = \ln Z_t - \ln Z_{t-12}$  terhadap data inflasi hasil transformasi  $\ln Z_t$ . Data hasil *differencing* musiman 12 orde satu selanjutnya disimbolkan dengan  $W_t$ . Setelah seluruh data inflasi dilakukan *differencing*, maka langkah selanjutnya adalah menguji apakah data inflasi telah stasioner dalam rata-rata. Uji yang digunakan adalah uji ADF dan data yang digunakan adalah  $W_t$ . Berikut adalah pengujian ADF terhadap data inflasi ( $W_t$ ):

Hipotesis

$$H_0: \gamma = 0 \text{ (Data inflasi tidak stasioner)}$$

$$H_1: \gamma \neq 0 \text{ (Data inflasi stasioner)}$$

Taraf signifikansi

$$\alpha = 1\%$$

Statistik uji

$$|\tau| = \left| \frac{\hat{\gamma}}{S(\hat{\gamma})} \right| = 6,310428$$

Daerah kritik

$H_0$  ditolak jika nilai  $|\tau| > |\tau|_{Mc. Kinnon}$  atau  $H_0$  ditolak jika nilai  $P\text{-value} < \alpha$

Keputusan

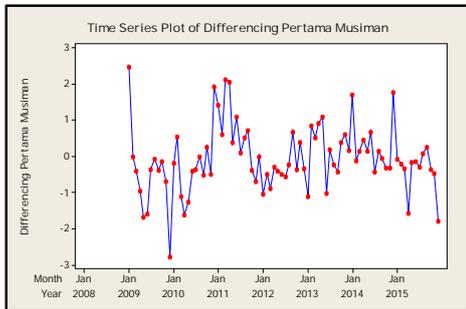
Karena nilai  $|\tau| = 6,310428 < |\tau|_{Mc. Kinnon} = 2,593121$  atau nilai  $P\text{-value} = 0,000 < \alpha = 0,01$ , maka diputuskan  $H_0$  ditolak

Kesimpulan

Data inflasi stasioner

Berdasarkan hasil pengujian ADF, dapat disimpulkan bahwa data hasil differencing musiman 12 orde satu telah membuat data inflasi menjadi stasioner. Sehingga data inflasi telah stasioner dalam rata-rata.

Berdasarkan Gambar 8, data yang dihasilkan tidak memiliki trend, di mana tidak ada perubahan rata-rata dan variansi dari waktu ke waktu. Oleh karena itu, dapat dikatakan data inflasi hasil transformasi dan differencing telah stasioner dalam rata-rata dan variansi.

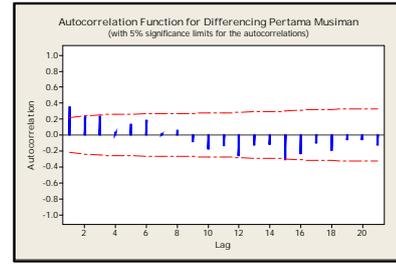


Gambar 8. *TSplot* data hasil differencing musiman 12 orde satu

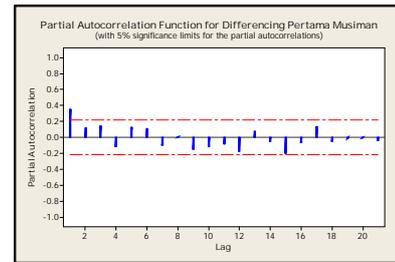
Karena data inflasi Indonesia periode Januari 2008 sampai dengan Desember 2015 adalah data berpola musiman 12, maka model peramalan yang digunakan adalah model SARIMA  $(p,d,q)(P,D,Q)^{12}$ . Pada Gambar 9, akan ditampilkan grafik ACF dan grafik PACF untuk menentukan orde-orde pada model SARIMA.

Pada Gambar 9 (a) dapat dilihat bahwa nilai ACF *cut off* pada lag 1 sehingga orde  $MA(q)$  adalah 1. Pada Gambar 9 (b) dapat dilihat bahwa nilai PACF *cut off* pada lag 1 sehingga orde untuk AR  $(p)$  adalah 1. Berikut adalah kombinasi dari model SARIMA sementara:

1. SARIMA  $(0,0,1)(0,1,0)^{12}$
2. SARIMA  $(1,0,0)(0,1,0)^{12}$
3. SARIMA  $(1,0,1)(0,1,0)^{12}$



(a)



(b)

Gambar 9. Grafik ACF dan grafik PACF untuk data hasil differencing musiman

### Penaksiran Parameter Model SARIMA Sementara

Pada Tabel 3, ditampilkan nilai taksiran untuk setiap parameter dari model-model SARIMA sementara:

Tabel 3. Penaksiran Parameter Model-Model SARIMA Sementara

Model SARIMA	Parameter
$(0,0,1)(0,1,0)^{12}$	$\hat{\theta}_1 = -0,367$
$(1,0,0)(0,1,0)^{12}$	$\hat{\phi}_1 = 0,407$
$(1,0,1)(0,1,0)^{12}$	$\hat{\phi}_1 = 0,702$
	$\hat{\theta}_2 = 0,363$

### Pengujian Signifikansi Parameter Model

Model SARIMA yang baik adalah model yang menunjukkan nilai-nilai parameter yang signifikan dengan nol. Berikut akan dilakukan pengujian signifikansi parameter untuk model SARIMA  $(0,0,1)(0,1,0)^{12}$ :

Hipotesis untuk parameter  $\theta_1$  pada model SARIMA  $(0,0,1)(0,1,0)^{12}$

$$H_0: \theta_1 = 0 \text{ (Parameter } \theta_1 \text{ pada model SARIMA } (0,0,1)(0,1,0)^{12} \text{ tidak signifikan berbeda dengan nol)}$$

$$H_1: \theta_1 \neq 0 \text{ (Parameter } \theta_1 \text{ pada model SARIMA } (0,0,1)(0,1,0)^{12} \text{ signifikan berbeda dengan nol)}$$

Taraf signifikansi

$$= 1\%$$

Statistik uji

$$t_{hit} = \frac{\hat{\theta}_1}{S(\hat{\theta}_1)} = \frac{-0,367}{0,103} = -3,54$$

$$t_{(\frac{\alpha}{2}, a - n - n_p)} = t_{(0,05, 9)} = 2,63$$

Nilai  $|t_{hit}| = 3,54 > t_{(0,05, 9)} = 2,63$  dan nilai  $P\text{-value} = 0,001 < \alpha = 0,01$ , maka diputuskan  $H_0$  ditolak. Dengan demikian, parameter  $\theta_1$  pada model SARIMA (0,0,1)(0,1,0)<sup>12</sup> signifikan berbeda dengan nol. Pengujian signifikansi parameter model SARIMA dilakukan untuk semua model, yaitu SARIMA (0,0,1)(0,1,0)<sup>12</sup>, SARIMA (1,0,0)(0,1,0)<sup>12</sup>, dan SARIMA (1,0,1)(0,1,0)<sup>12</sup>.

Pada Tabel 4, ditampilkan hasil pengujian signifikansi parameter model SARIMA. Berdasarkan Tabel 4 dapat dilihat bahwa parameter model SARIMA (0,0,1)(0,1,0)<sup>12</sup> dan SARIMA (1,0,0)(0,1,0)<sup>12</sup> telah memenuhi, karena semua parameternya signifikan berbeda dengan nol. Kedua model tersebut mempunyai nilai probabilitas yang lebih kecil dari  $\alpha = 0,01$ . Sedangkan model SARIMA (1,0,1)(0,1,0)<sup>12</sup> tidak memenuhi, dikarenakan terdapat parameter yang tidak signifikan berbeda dengan nol.

Tabel 4. Hasil Pengujian Signifikansi Parameter Model SARIMA Sementara

Model SARIMA	$t_{hitung}$	$P\text{-value}$	Keputusan
*(0,0,1)(0,1,0) <sup>12</sup>	-3,54	0,001	$H_0$ ditolak
*(1,0,0)(0,1,0) <sup>12</sup>	3,98	0,000	$H_0$ ditolak
(1,0,1)(0,1,0) <sup>12</sup>	3,94	0,000	$H_0$ ditolak
	1,57	0,120	$H_0$ gagal ditolak

Keterangan (\*) model yang signifikan

**Uji Asumsi Residual White Noise**

Pengujian asumsi *residual white noise* dalam penelitian ini menggunakan statistik uji Ljung-Box. Pada Tabel 5 akan ditampilkan hasil pengujian *residual white noise*.

Adapun uji hipotesisnya adalah:

$$H_0: \rho_1 = \rho_2 = \dots = \rho_9 = 0 \text{ (Residual memenuhi syarat white noise)}$$

$$H_1: \text{Minimal ada satu } \rho_i \neq 0, \text{ untuk } i = 1, 2, 3, \dots, 96 \text{ (Residual tidak memenuhi syarat white noise)}$$

Taraf signifikansi

$$= 1\%$$

Statistik uji

$$Q = 96(96 + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(96 - k)}, n > k$$

Tabel 5. Pengujian Asumsi Residual White Noise

Model SARIMA	$P\text{-value}$	Keputusan
*(0,0,1)(0,1,0) <sup>12</sup>	0,035	$H_0$ gagal ditolak
	0,023	$H_0$ gagal ditolak
	0,126	$H_0$ gagal ditolak
	0,205	$H_0$ gagal ditolak
*(1,0,0)(0,1,0) <sup>12</sup>	0,064	$H_0$ gagal ditolak
	0,048	$H_0$ gagal ditolak
	0,244	$H_0$ gagal ditolak
	0,292	$H_0$ gagal ditolak

Keterangan (\*) model yang *white noise*

Berdasarkan pengujian asumsi *residual white noise*, tidak terdapat nilai  $P\text{-value}$  untuk setiap lag yang lebih kecil dari  $\alpha = 0,01$ , maka diputuskan  $H_0$  gagal ditolak. Dapat disimpulkan model SARIMA (0,0,1)(0,1,0)<sup>12</sup> dan model SARIMA (1,0,0)(0,1,0)<sup>12</sup> untuk setiap lag tidak terdapat korelasi antar *residual*, hal ini berarti kedua model telah memenuhi asumsi *white noise*.

**Uji Asumsi Residual Berdistribusi Normal**

Tahap selanjutnya adalah melakukan pengujian asumsi *residual* berdistribusi normal untuk model SARIMA (0,0,1)(0,1,0)<sup>12</sup> dan SARIMA (1,0,0)(0,1,0)<sup>12</sup>. Pengujian kenormalan *residual* ini menggunakan statistik uji Kolmogorov-Smirnov. Berikut adalah pengujiannya:

Tabel 6. Pengujian Asumsi Residual Berdistribusi Normal

Model SARIMA	$P\text{-value}$	Keputusan
*(0,0,1)(0,1,0) <sup>12</sup>	0,150	$H_0$ gagal ditolak
*(1,0,0)(0,1,0) <sup>12</sup>	0,150	$H_0$ gagal ditolak

Keterangan (\*) model yang signifikan

Adapun uji hipotesis yang digunakan adalah

$$H_0: \text{Residual berdistribusi normal}$$

$$H_1: \text{Residual tidak berdistribusi normal}$$

Taraf signifikansi

$$\alpha = 1\%$$

Statistik uji

$$D_{hit} = s_i |F_0(X) - S_n(X)|$$

Berdasarkan pengujian asumsi *residual* berdistribusi normal, model yang memenuhi adalah model SARIMA (0,0,1)(0,1,0)<sup>12</sup> dan SARIMA (1,0,0)(0,1,0)<sup>12</sup>, karena kedua model tersebut mempunyai nilai probabilitas yang lebih besar dari nilai  $\alpha = 0,01$ .

**Kriteria Pemilihan Model Terbaik**

Untuk menentukan model terbaik dari kedua model yang memenuhi syarat, maka dapat digunakan kriteria RMSE. Model terbaik dipilih dengan nilai kriteria RMSE terkecil.

Tabel 7. Hasil Perhitungan Akurasi

Model SARIMA	RMSE
$(0,0,1)(0,1,0)^{12}$	0,85
$*(1,0,0)(0,1,0)^{12}$	0,83

Keterangan (\*) model dengan RMSE terkecil

Berdasarkan Tabel 7, dapat disimpulkan model SARIMA terbaik yang diperoleh adalah model SARIMA  $(1,0,0)(0,1,0)^{12}$  dengan nilai kriteria RMSE terkecil yaitu sebesar 0,83.

**Peramalan**

Model SARIMA  $(1,0,0)(0,1,0)^{12}$  adalah sebagai berikut:

$$Z_t = a_t + 0,407Z_{t-1} + Z_{t-1} - 0,407Z_{t-1} \text{ di mana:}$$

$Z_t$  =inflasi Indonesia (mtm)

$Z_{t-1}$  =inflasi Indonesia (mtm) periode ke  $(t - 12)$

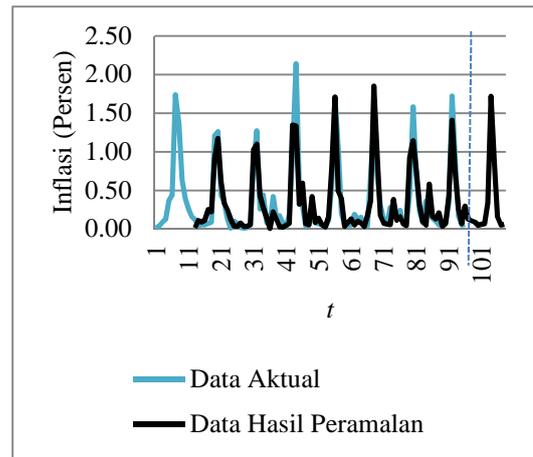
$Z_{t-1}$  =inflasi Indonesia (mtm) periode ke  $(t - 13)$

$$Z_t = \ln Z_t$$

$a_t$  = residual periode ke  $t$

Pada Tabel 8 ditampilkan hasil peramalan inflasi Indonesia (mtm) untuk periode Januari 2016 sampai dengan Desember 2016.

Berdasarkan Tabel 8 dan Gambar 10, pola peramalan inflasi Indonesia (mtm) periode Januari 2016 sampai dengan Desember 2016 sama dengan pola pada waktu-waktu sebelumnya. Di mana, peningkatan inflasi Indonesia (mtm) terjadi pada bulan Januari 2016 dan penurunan inflasi Indonesia (mtm) terjadi pada bulan Februari 2016 sampai dengan April 2016. Peningkatan kembali inflasi Indonesia (mtm) terjadi pada bulan Mei 2016 sampai dengan Agustus 2016. Penurunan kembali inflasi Indonesia (mtm) terjadi pada bulan September 2016 sampai dengan November 2016. Peningkatan inflasi Indonesia (mtm) terjadi pada bulan Desember 2016.



Gambar 10. TS plot untuk data aktual dan data hasil peramalan

Tabel 8. Peramalan Inflasi Indonesia (mtm) SARIMA  $(1,0,0)(0,1,0)^{12}$

t	Bulan	Peramalan (persen)
97	Januari 2016	0,12
98	Februari 2016	0,10
99	Maret 2016	0,08
100	April 2016	0,04
101	Mei 2016	0,05
102	Juni 2016	0,06
103	Juli 2016	0,33
104	Agustus 2016	1,71
105	September 2016	0,89
106	Oktober 2016	0,16
107	November 2016	0,05
108	Desember 2016	0,06

**Kesimpulan**

Berdasarkan hasil analisis data penelitian inflasi Indonesia, diperoleh kesimpulan sebagai berikut:

1. Model SARIMA terbaik untuk meramalkan inflasi Indonesia periode Januari 2016 sampai dengan Desember 2016 adalah model SARIMA  $(1,0,0)(0,1,0)^{12}$ .

2. Hasil peramalan dari model terbaik SARIMA (1,0,0)(0,1,0)<sup>12</sup> adalah peramalan inflasi Indonesia periode Januari 2016 sampai dengan Desember 2016 memiliki pola yang sama dengan pola pada waktu-waktu sebelumnya. Di mana, inflasi Indonesia meningkat pada bulan Januari 2016 dan menurun pada bulan Februari 2016 sampai dengan April 2016. Inflasi Indonesia meningkat kembali pada bulan Mei 2016 sampai dengan Agustus 2016 dan menurun kembali pada bulan September 2016 sampai dengan November 2016. Terakhir, inflasi Indonesia meningkat pada bulan Desember 2016.

#### Daftar Pustaka

- Aswi dan Sukarna. 2006. *Analisis Deret Waktu: Teori dan Aplikasi*. Makassar: Andira Publisher.
- Boediono. 1998. *Ekonomi Moneter*. BPFE. Yogyakarta.
- Dewi, U. M. 2014. Peramalan Jumlah Produksi Air Bersih (m<sup>3</sup>) pada Perusahaan Daerah Air Minum (PDAM) Tirta Kencana Samarinda dengan Metode Winters dan *Seasonal ARIMA*. Skripsi tidak diterbitkan. Samarinda: FMIPA Universitas Mulawarman.
- Prabowo, B. A. 2015. Peramalan Permintaan Produk dengan Model SARIMA dan Metode *Silver-Meal* untuk Meminimumkan Ongkos Total Persediaan dengan Analisa *Safety Stock* dan *Reorder Point*. Skripsi tidak diterbitkan. Samarinda: FMIPA Universitas Mulawarman.
- Salamah, M., Suhartono, dan Wulandari. 2003. *Analisis Time Series*. Buku Ajar. Surabaya: FMIPA Institut Teknologi Sepuluh Nopember.
- Siegel, S. 1992. *Statistik Nonparametrik untuk Ilmu-Ilmu Sosial*. Jakarta: PT Gramedia Pustaka Utama.
- Yamin, S. dan Kurniawan, H. 2009. *SPSS Complete Teknik Analisis Statistika Terlengkap dengan Software SPSS*. Jakarta: Salemba Infotek.

