

## Perbandingan Bagan Kendali Modifikasi Shewhart dan Bagan Kendali ARMAST pada ARMA(1,1)

Syandriana Syarifuddin<sup>1</sup>, Erna Tri Herdiana<sup>2</sup>, M. Saleh AF<sup>3</sup>

### Abstrak

Pada umumnya asumsi dasar untuk data pada bagan kendali adalah bersifat saling bebas dan menyebar normal. Namun tidak semua data dapat memenuhi asumsi tersebut salah satunya ketika terjadi autokorelasi. Jika terdapat autokorelasi pada data dapat mempengaruhi tingkat alarm palsu sehingga permasalahan autokorelasi perlu untuk diatasi. Cara untuk mengatasi data berautokorelasi pada bagan kendali dapat dilakukan dengan menggunakan bagan kendali modifikasi Shewhart dan bagan kendali ARMAST. Hasil penelitian menunjukkan pada bagan kendali ARMAST lebih sensitif terhadap data yang *out of control* dibandingkan dengan bagan kendali modifikasi Shewhart karena nilai ARL yang diperoleh pada bagan kendali ARMAST lebih kecil dibandingkan dengan ARL pada bagan kendali modifikasi Shewhart. Sehingga dalam penelitian ini disimpulkan bahwa *performance* bagan kendali ARMAST lebih baik dibandingkan bagan kendali modifikasi Shewhart.

**Kata kunci:** Autokorelasi, modifikasi Shewhart, ARMAST, ARL

## 1. Pendahuluan

Asumsi dasar penggunaan bagan kendali adalah data yang diperoleh bersifat saling bebas dan menyebar normal dengan nilai tengah  $\mu$  dan ragam  $\sigma^2$  dimana nilai  $\mu$  dan  $\sigma^2$  tetap [6].. Namun, dalam prakteknya tidak semua asumsi dapat terpenuhi salah satunya ketika proses yang terjadi bersifat autokorelasi. Jika terdapat autokorelasi pada data dapat mempengaruhi tingkat alarm palsu sehingga permasalahan autokorelasi ini perlu untuk diatasi [7]. Cara untuk mengatasi permasalahan autokorelasi pada bagan kendali yaitu dengan memodelkan menggunakan runtun waktu.

Beberapa peneliti telah menerapkan bagan kendali dengan model runtun waktu diantaranya yaitu Choirunnisa (2014) meneliti pengaruh autokorelasi pada bagan kendali  $\bar{x}$  dengan menggunakan model AR(1) diperoleh hasil sisaan model yang menyebar normal dan saling bebas menunjukkan bahwa tidak terdapat autokorelasi pada data dan proses terkendali. Hal ini berarti bahwa model AR(1) dapat digunakan untuk memperbaiki pengaruh autokorelasi pada bagan kendali. Fitriani (2015) meneliti bagan kendali *Cumulative Sum* (CUSUM) untuk pengontrolan proses dengan model AR(1) diperoleh hasil pada bagan kendali *Cumulative Sum* (CUSUM) tradisional *out of control* lebih cepat terdeteksi dibandingkan dengan bagan kendali *Cumulative*

<sup>1</sup> Syandriana022@gmail.com, <sup>2</sup>herdiani.erna@gmail.com, <sup>3</sup>afsaleh54@yahoo.co.id  
<sup>1,2,3</sup>Program Studi Statistika, Departemen Matematika FMIPA, Universitas Hasanuddin

*Sum* (CUSUM) untuk pengontrolan proses dengan model AR(1) hal ini karena bagan kendali *Cumulative Sum* (CUSUM) tadisional *underestimate*.

Pada sebagian besar penelitian mengenai bagan kendali yang menggunakan model runtun waktu data yang sering digunakan yaitu data berpola AR(1) sedangkan dalam permasalahan autokorelasi dapat saja ditemukan data dengan pola yang lain. Misalkan, jika suatu data memiliki pola ARMA(1,1). Jika data berpola ARMA(1,1) pengaruh autokorelasi dapat diatasi dengan menggunakan bebrapa bagan kendali yang dimodelkan dengan ARMA(1,1). Untuk mengatasinya dapat dilakukan dengan menggunakan bagan kendali modifikasi Shewhart dan juga bagan kendali ARMAST yaitu bagan kendali ARMA yang mengalami autokorelasi [10]. Sehingga pada penelitian ini bertujuan membandingkan kinerja bagan kendali modifikasi Shewhart dan bagan kendali ARMAST pada data ARMA(1,1) .

## 2. Tinjauan Pustaka

### 2.1 Model ARMA ( $p, q$ )

Bentuk umum untuk ARMA ( $p, q$ ) dapat dinyatakan dalam persamaan

$$\dot{X}_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

Sehingga bentuk umum untuk model ARMA(1,1) dapat dinyatakan dalam persamaan

$$\dot{X}_t = \phi_1 X_{t-1} + a_t - \theta_1 a_{t-1}$$

dengan:

$\theta_1$  = parameter-parameter *moving average* ke 1

$a_{t-1}$  = nilai kesalahan pada saat  $t - 1$

$a_t$  adalah proses *white noise* dengan  $a_t \sim N(0, \sigma^2)$

$\phi_1$  = parameter autoregresi ke-1

$\dot{X}_t = X_t - \mu$

[9]

### 2.2 Autokorelasi

Autokorelasi menyatakan hubungan antara variabel yang sama dengan waktu yang berbeda sehingga terdapat perbedaan antara korelasi dan autokorelasi. Korelasi yaitu mengukur hubungan linier antara dua buah variabel yang berbeda sedangkan autokorelasi mengukur hubungan linier antara variabel yang sama dengan waktu yang berbeda [9]

Fungsi Autokorelasi atau *Autocorrelation Function* (ACF) adalah suatu fungsi yang menunjukkan besarnya korelasi antara pengamatan waktu ke-t dengan pengamatan pada waktu yang sebelumnya. Fungsi autokorelasi menunjukkan koefisien autokorelasi yang merupakan pengukuran korelasi antara observasi pada waktu yang berbeda [3].

Fungsi autokorelasi parsial (*partial autocorrelation function*) digunakan untuk mengukur tingkat keeratan antara  $X_t$  dan  $X_{t-k}$ , apabila pengaruh dari *lag* waktu (*time lag*) dianggap terpisah [1].

**Tabel 1.** Ciri-ciri teoritis ACF dan PACF untuk proses stasioner

Model	ACF	PACF
AR(p)	Turun secara eksponensial atau membentuk gelombang sinus	Terpotong setelah <i>lag</i> p

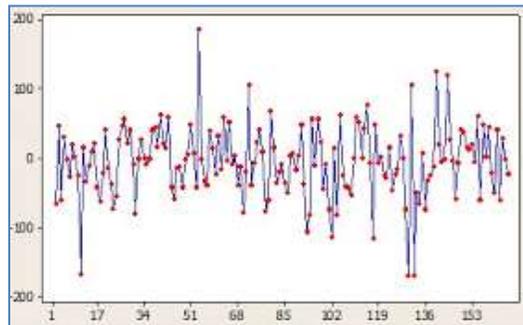
MA(q)	Terpotong setelah <i>lag</i> q	Turun secara eksponensial atau membentuk gelombang sinus
ARMA(p,q)	Turun cepat setelah <i>lag</i> (q-p)	Turun cepat setelah <i>lag</i> (p-q)

Sumber : Wei, 2006

### 2.3 Kestasioneran

Box dan Jenkins (1976) menjelaskan bahwa pada deret waktu yang bersifat stasioner kuat, waktu pengamatan tidak berpengaruh terhadap rata-rata  $\mu$ , variansi  $\sigma^2$ , dan kovariansi  $\gamma_k$ . Ini berarti bahwa deret  $X_t$  akan berfluktuasi disekitar  $\mu$  dan variansi  $\sigma^2$  yang tetap, dan dapat dikatakan bahwa deret  $X_t$  stasioner dalam  $\mu$  dan  $\sigma^2$  [9].

Pemeriksaan kestasioneran suatu data dapat digunakan diagram runtun waktu (*time series plot*) yaitu diagram pencar antara nilai peubah  $X_t$  dengan waktu t. Jika diagram berfluktuasi disekitar garis yang sejajar sumbu waktu (t) maka dikatakan data stasioner dalam rata-rata [1]. Grafik suatu data yang stasioner dapat dilihat pada Gambar 2.4 dan yang tidak stasioner dapat dilihat pada Gambar 2.5



**Gambar 1.** Plot Time Series Stasioner  
(Sumber: Aswi dan Sukarna, 2006)

Pemeriksaan kestasioneran suatu data dapat juga menggunakan uji *unit root*. Uji *unit root* yang biasa digunakan adalah uji *augmented Dickey–Fuller*. Uji lain yang serupa yaitu uji *Phillips–Perron*. Keduanya mengindikasikan keberadaan *unit root* sebagai hipotesis nol.

Pengujian *augmented Dickey–Fuller*

Hipotesis

$H_0 : \delta = 0$  (data tidak stasioner)

$H_1 : \delta \neq 0$  (data stasioner)

Statistik uji

$$t = \frac{\hat{\delta} - \delta}{SE(\hat{\delta})}$$

Daerah Kritis

$\alpha = 0.05$

Kriteria keputusan:

$H_0$  ditolak jika  $|t_{hit}| > t_{\frac{\alpha}{2}, n-1}$

[8].

Suatu proses yang stasioner  $\{X_t\}$  mempunyai sifat:

1. Mean  $X_t$  yaitu  $E(X_t) = \mu$
2. Variansi  $X_t$  yaitu  $\text{Var}(X_t) = E(X_t - \mu)^2 = \sigma^2$
3. Kovariansi  $X_t$  yaitu  $\text{Cov}(X_t, X_{t+k}) = \gamma_k$  (fungsi dari perbedaan waktu)  
 $\gamma_k = \text{Cov}(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu)$
4. Korelasi antara  $X_t$  dan  $X_{t+k}$  (autokorelasi)

$$\rho_k = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})}} = \frac{\gamma_k}{\gamma_0}$$

#### 2.4 White Noise Process

Suatu proses  $\{a_t\}$  dinamakan *white noise process* (proses yang bebas dan identik) jika bentuk peubah acak yang berurutan tidak saling berkorelasi dan mengikuti distribusi tertentu [9].

Suatu *white noise process*  $\{a_t\}$  adalah stasioner dengan beberapa sifat berikut:

$$E(a_t) = \mu_a = 0, \quad \text{Var}(a_t) = \sigma_a^2 \quad \text{dan} \quad \gamma_k = \text{cov}(a_t, a_{t+k}) = 0 \quad \text{untuk } k \neq 0$$

Fungsi autovariansi:

$$\gamma_k = \begin{cases} \sigma_a^2, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases}$$

Fungsi autokorelasi:

$$\rho_k = \begin{cases} 1, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases}$$

Fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases}$$

Langkah pengujian *Ljung-Box*:

1. Hipotesis

$H_0: r_1 = r_2 = \dots = r_k = 0$  ( Tidak ada korelasi pada residu )

$H_1: \text{Minimal terdapat satu } r_k \neq 0$ , untuk  $k = 1, 2, 3, \dots, K$  (Ada korelasi pada residu )

2. Statistik uji yang digunakan adalah statistic *Ljung-Box* yaitu

$$Q_K = n(n+2) \sum_{k=1}^K \frac{r_k^2}{n-k}$$

dengan  $n$  adalah banyaknya observasi,  $K$  adalah banyaknya lag yang diuji,  $r_k$  adalah nilai koefisien autokorelasi pada lag- $k$ .

3. Kriteria keputusan: Tolak  $H_0$  jika  $Q > \chi_{\alpha; df}^2$  dengan  $df = k - p$

[9].

#### 2.5 Pengujian Signifikansi Parameter

Pada runtun waktu setelah diperoleh dugaan model awal dengan melihat plot ACF dan PACF selanjutnya dilakukan uji signifikansi parameter. Uji signifikan parameter dapat dilakukan dengan langkah-langkah berikut:

1. Hipotesis

$H_0 : \theta = 0$  dan  $\phi = 0$  (parameter tidak signifikan)

$H_1 : \theta \neq 0$  dan  $\phi \neq 0$  (parameter signifikan)

2. Statistik uji yang digunakan dapat dilihat pada persamaan

$$t = \frac{\hat{\theta}}{SE(\hat{\theta})} \text{ dan } t = \frac{\hat{\phi}}{SE(\hat{\phi})}$$

3. Kriteria keputusan:  $H_0$  ditolak jika

$$|t_{hit}| > t_{\frac{\alpha}{2}, n-1}$$

## 2.6 Pemilihan Model Terbaik

Pemilihan model terbaik dapat dilakukan dengan membandingkan nilai *Mean Square Error* (MSE). *Mean Square Error* (MSE) adalah suatu kriteria pemilihan model terbaik berdasarkan pada hasil sisa peramalan. Persamaan dari *Mean Square Error* yaitu

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{X}_i - X_i)^2$$

Semakin kecil nilai *Mean Square Error* yang dihasilkan berarti model yang dipilih semakin baik.

## 2.7 Bagan Kendali Shewhart

Misalkan  $w$  sebagai sampel statistik yang akan diukur kualitasnya dengan nilai mean  $\mu_w$  dan standar deviasi  $w$  adalah  $\sigma_w$  maka UCL, CL, LCL pada bagan kendali shewhart sebagai berikut:

$$\begin{aligned} UCL &= \mu_w + L\sigma_w \\ CL &= \mu_w \\ LCL &= \mu_w - L\sigma_w \end{aligned}$$

$L$  adalah jarak batas kontrol dari garis tengah, dinyatakan dalam unit standar deviasi [6]. Nilai  $L$  pada umumnya yaitu 1, 2, dan 3. Semakin besar nilai  $L$  menunjukkan semakin lebar batas suatu bagan kendali

## 2.8 Average Run Length

Kriteria yang digunakan untuk dapat membandingkan bagan kendali adalah dengan mengukur seberapa cepat diagram kontrol tersebut membangkitkan sinyal *out of control*. Bagan kendali yang lebih cepat mendeteksi sinyal *out of control* disebut lebih sensitif terhadap perubahan proses [5]. Salah satu cara untuk mengukur kinerja diagram kontrol adalah dengan menggunakan *Average Run Length* (ARL). *Average Run Length* (ARL) adalah jumlah rata-rata titik sampel yang harus di plot pada bagan kendali sebelum suatu titik menunjukkan keadaan tak terkendali (*out of control*) [6]. Semakin kecil ARL, semakin cepat grafik kendali mendeteksi adanya pergeseran. Persamaan ARL yaitu :

$$ARL = \frac{1}{P(\text{suatu titik diluar kendali})}$$

atau

$$ARL_1 = \frac{1}{1-\beta}$$

### 3. Metode Analisis

Jenis data yang digunakan terdiri atas dua data yaitu data simulasi dan data asli. Data simulasi yaitu berupa data yang dibangkitkan dengan menggunakan program *R 3.4.3* sebanyak 500 data dan 5.000 data. Data yang dibangkitkan berupa data yang berdistribusi normal dengan nilai mean 0 dan nilai variansi 1. Data asli yaitu data Inflasi Bulanan Indonesia Januari 2005 -Desember 2017 diperoleh dari Badan Pusat Statistika.

Tahapan yang dilakukan dalam penelitian ini adalah sebagai berikut:

Tahap I menggunakan data simulasi

1. Menentukan rumus mean dan variansi
2. Menentukan rumus bagan kendali bagan kendali modifikasi Shewhart dan ARMAST untuk data ARMA(1,1)
3. Membangkitkan data ARMA(1,1) dengan menggunakan persamaan  $X_t = \phi X_{t-1} + a_t - \theta a_{t-1}$  dengan nilai mean  $a_t = 0$  dan nilai variansi  $a_t = 1$
4. Menguji kestasioneran data yang telah di bangkitkan
5. Mengestimasi Parameter, mendiagnostik model, dan menentukan model terbaik dari data yang telah dibangkitkan untuk membuktikan data yang telah di bangkitkan memiliki model ARMA(1,1)
6. Menghitung nilai bagan kendali moifikasi Shewhart dan bagan kendali ARMAST untuk model data ARMA(1,1)
7. Membandingkan *performance* bagan kendali modifikasi Shewhart dan ARMAST pada data ARMA(1,1) dengan melihat nilai ARL

Tahap II menggunakan data asli

1. Menguji kestasioneran data
2. Mengestimasi Parameter, mendiagnostik model, dan menentukan model terbaik dari data yang telah dibangkitkan untuk membuktikan data yang telah di bangkitkan memiliki model ARMA(1,1)
3. Menghitung nilai mean dan nilai variansi residual dari data
4. Menghitung nilai bagan kendali Moifikasi Shewhart dan bagan kendali ARMAST untuk data ARMA(1,1)
5. Membandingkan *performance* bagan kendali modifikasi Shewhart dan ARMAST pada data ARMA(1,1) dengan melihat hasil UCL dan LCL

#### 4. Hasil dan Pembahasan

##### 4.1 Penentuan Bagan kendali Modifikasi Shewhart

bentuk umum *Autoregressive Moving Average* (ARMA) ordo (1,1) atau ARIMA (1,0,1) yaitu

$$\check{X}_t = \phi \check{X}_{t-1} + a_t - \theta a_{t-1}$$

Dalam penentuan bagan kendali ARMA(1,1) terlebih dahulu ditentukan mean dan variansi ARMA(1,1). Dari hasil penelitian diperoleh mean  $\mu$  dan variansi  $\frac{(1-2\theta\phi+\theta^2)\sigma_a^2}{(1-\phi^2)}$  Sehingga bagan kendali Shewhart pada ARMA(1,1) adalah

$$\begin{aligned}
UCL &= \mu + L \sqrt{\frac{(1-2\theta\phi+\theta^2)\sigma_a^2}{(1-\phi^2)}} \\
CL &= \mu \\
LCL &= \mu - L \sqrt{\frac{(1-2\theta\phi+\theta^2)\sigma_a^2}{(1-\phi^2)}}
\end{aligned} \tag{1}$$

#### 4.2 Penentuan Bagan Kendali ARMAST

Bagan kendali *Autoregressive Moving Average* untuk data yang mengalami autokorelasi disebut dengan ARMAST. Dimana  $Z_t$  adalah data yang berautokorelasi. Dengan rumus korelasi  $\rho(\tau) = \frac{\gamma(\tau)}{\gamma(0)}$  dan rumus kovariansi  $\gamma(\tau) = \text{cov}(Z_t, Z_{t-\tau})$ . Sehingga bentuk umum model *Autoregressive Moving Average* (ARMA) dapat dinyatakan sebagai berikut:

$$Z_t = \theta_0 X_t + \alpha \sum_{k=1}^{t-1} \phi^{k-1} X_{t-k}$$

dengan  $\alpha = \phi\theta_0 - \theta$  dan  $\theta_0 = 1 + \theta - \phi$

Dalam menentukan bagan kendali terlebih dahulu ditentukan mean dan variansi dari bagan kendali ARMA. Dari hasil penelitian diperoleh mean  $\mu$  dan variansi  $\sigma_z^2 = \left\{ \theta_0^2 + \frac{\alpha^2}{1-\phi^2} + 2 \left( \theta_0 \alpha + \frac{\phi \alpha^2}{1-\phi^2} \right) \frac{\rho(1)}{1-\phi u} \right\} \sigma_x^2$

dengan

$$\rho(1) = u - v \frac{\sigma^2}{\sigma_x^2}$$

$$\sigma_z^2 = \left\{ \theta_0^2 + \frac{\alpha^2}{1-\phi^2} + 2 \left( \theta_0 \alpha + \frac{\phi \alpha^2}{1-\phi^2} \right) \frac{\rho(1)}{1-\phi u} \right\} \sigma_x^2$$

$$u = \phi$$

$$v = \frac{\theta}{\theta_0}$$

Sehingga diperoleh bagan kendali ARMAST (1,1) yaitu

$$\begin{aligned}
UCL &= \mu_z + L \sqrt{\left\{ \theta_0^2 + \frac{\alpha^2}{1-\phi^2} + 2 \left( \theta_0 \alpha + \frac{\phi \alpha^2}{1-\phi^2} \right) \frac{\rho(1)}{1-\phi u} \right\} \sigma_x^2} \\
CL &= \mu_z \\
LCL &= \mu_z - L \sqrt{\left\{ \theta_0^2 + \frac{\alpha^2}{1-\phi^2} + 2 \left( \theta_0 \alpha + \frac{\phi \alpha^2}{1-\phi^2} \right) \frac{\rho(1)}{1-\phi u} \right\} \sigma_x^2}
\end{aligned} \tag{2}$$

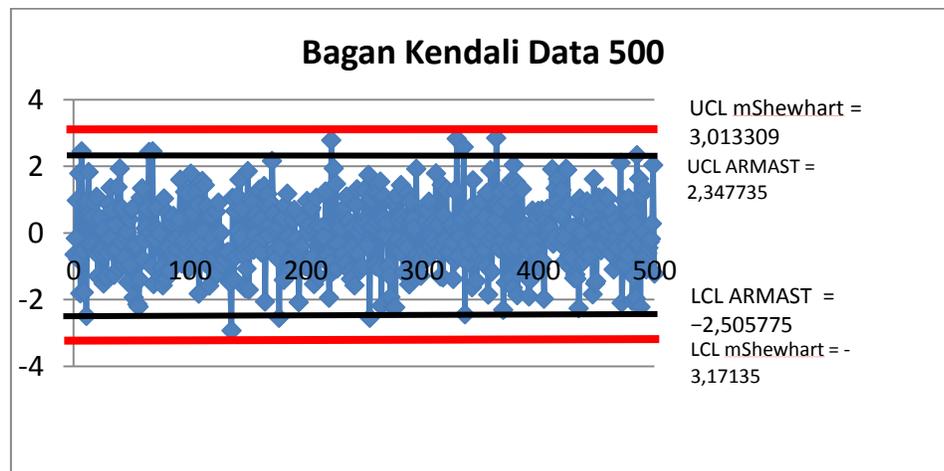
#### 4.3 Studi Kasus I

Pada bab ini akan dibangkitkan data ARMA(1,1) yaitu 500 dan 5.000 data dengan menggunakan R 3.4.3 yang memiliki nilai error ( $a_t$ ) beproses *white noise* dengan nilai mean  $a_t = 0$ , nilai variansi  $a_t = 1$ ,  $\theta = 0,4$ . dan  $\phi = 0,6$ .

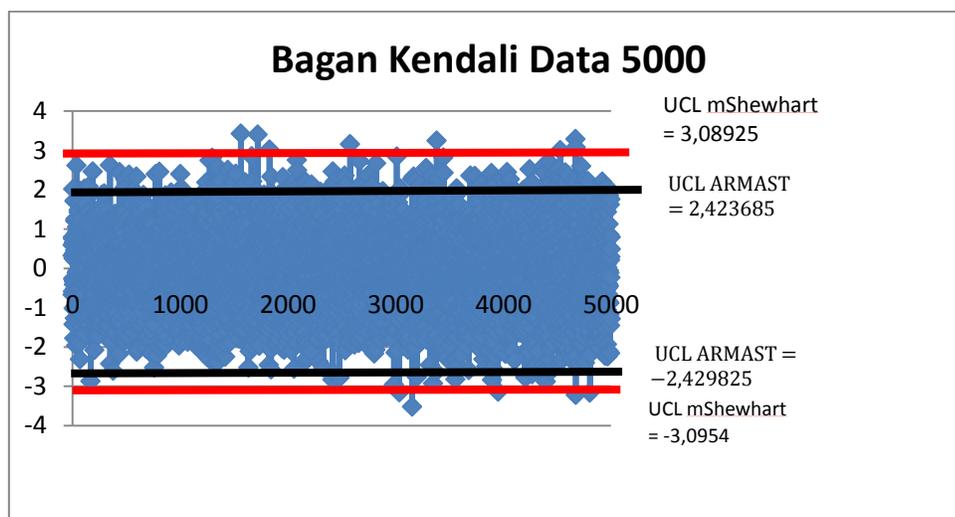
#### 4.3.2 Bagan Kendali

Berdasarkan hasil perhitungan nilai UCL, CL, dan LCL dengan menggunakan persamaan (1) diperoleh bagan kendali modifikasi Shewhart pada ARMA(1,1) untuk data 500 yaitu  $UCL = 3,013309$ ,  $CL = -0,07902$ , dan  $LCL = -3,17135$ . Dengan menggunakan persamaan (2) diperoleh hasil bagan kendali ARMAST yaitu  $UCL = 2,347735$ ,  $CL = -0,07902$ , dan  $LCL = -2,505775$ .

Hasil perhitungan bagan kendali pada 5000 diperoleh nilai bagan kendali modifikasi Shewhart yaitu  $UCL = 3,08925$ ,  $CL = -0,00308$  dan  $LCL = -3,0954$ . Nilai bagan kendali ARMAST yaitu  $UCL = 2,423685$ ,  $CL = -0,00308$  dan  $LCL = -2,429825$ . Secara visual grafik bagan kendali pada  $n = 500$  dan  $n = 5.000$  dapat dilihat pada Gambar 2 dan Gambar 3



Gambar 2. Bagan Kendali Data 500



Gambar 3. Bagan Kendali Data 5000

#### 4.3.2 Perhitungan Average Run Length

Untuk mengetahui *performance* dari suatu bagan kendali dapat dilakukan dengan melihat nilai *Average Run Length* (ARL). Semakin kecil ARL, semakin cepat grafik kendali mendeteksi adanya pergeseran. Dengan bantuan *software R 3.4.3* didapatkan nilai ARL yang dapat dilihat pada Tabel 2

**Tabel 2.** Nilai ARL

Shift	MShewhart		ARMAST	
	n =500	n = 5.000	n =500	n = 5.000
0	35,084	34,7054	16,3600	15,8240
0,5	22,264	21,0928	12,0760	10,4736
1	9,872	9,8720	5,7300	5,4636
2	2,730	2,7300	2,0040	1,8272
4	1,064	1,0160	1,0000	1,0054

**Sumber:** Data diolah, 2018

Berdasarkan Tabel 2 nilai ARL untuk *shift* 0 pada bagan kendali modifikasi Shewhart dengan  $n = 500$  adalah 35,084 dan pada bagan kendali ARMAST adalah 16,3600. Berdasarkan hasil nilai ARL menunjukkan untuk *shift* 0 nilai ARL dari bagan kendali ARMAST jauh lebih kecil dibandingkan bagan kendali modifikasi Shewhart. Pada nilai *shift* 0,5 , 1, 2, dan 4 untuk  $n=5000$  juga menunjukkan nilai ARL bagan kendali ARMAST lebih kecil dibandingkan bagan kendali modifikasi Shewhart.

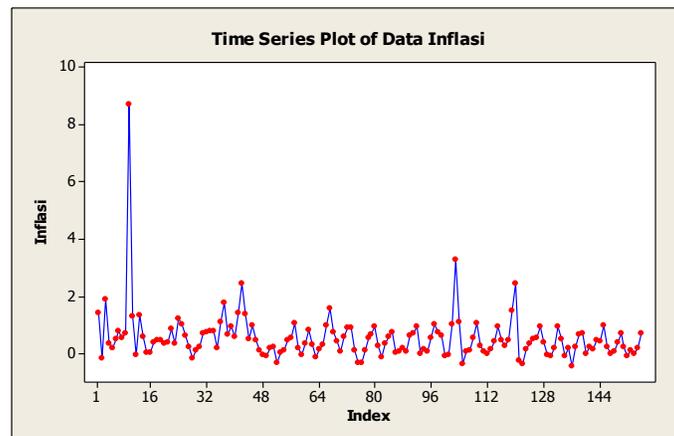
Untuk  $n= 5.000$  pada *shift* 0 nilai ARL bagan kendali modifikasi Shewhart adalah 34,7054 dan pada bagan kendali ARMAST adalah 15,8240. Hal ini menunjukkan untuk *shift* 0 dengan  $n = 5.000$  nilai ARL dari bagan kendali ARMAST jauh lebih kecil dibandingkan bagan kendali modifikasi Shewhart. Pada nilai *shift* 0,5 , 1, 2, dan 4 untuk  $n= 5.000$  juga menunjukkan nilai ARL bagan kendali ARMAST lebih kecil dibandingkan bagan kendali modifikasi Shewhart.

#### 4.4 Studi Kasus II

Pada bab ini digunakan data Inflasi Bulanan Indonesia Januari 2005 - Desember 2017

##### 4.4.1 Uji Kestasioneran Data

Sebelum melakukan identifikasi model terlebih dahulu dilakukan uji kestasioneran. Untuk mengetahui data telah stasioner atau tidak dapat dilihat pada grafik data. Dapat dilihat pada Gambar 4.

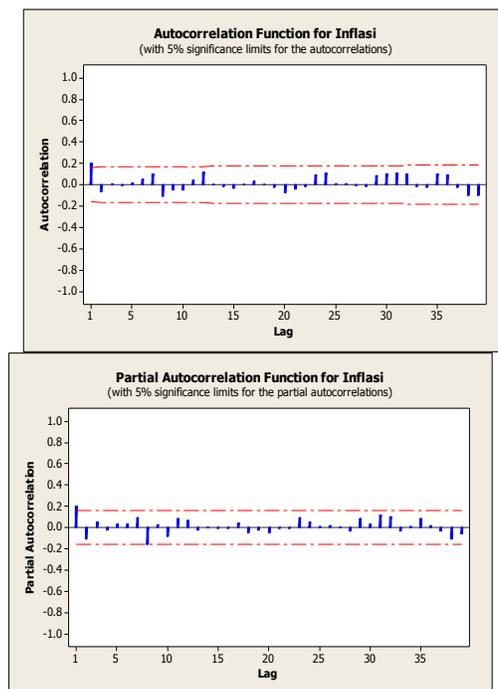


**Gambar 4.** Grafik Data Inflasi Bulanan

Berdasarkan Gambar 4 menunjukkan data tidak mengalami *trend* naik ataupun *trend* turun tetapi berada di sekitaran rata-rata hal ini berarti data telah stasioner. Selain dengan grafik dapat dilakukan uji kestasioneran data dengan uji ADF. Dengan menggunakan bantuan *software R 3.4.3* didapatkan hasil pengujian untuk data yaitu Dickey-Fuller =  $-5.1329$ , *Lag order* = 5, *p-value* = 0.01. Karena nilai *p-value*  $< 0.05$  sehingga  $H_0$  ditolak yang berarti data stasioner.

#### 4.4.2 Identifikasi model ARIMA

Untuk menentukan dugaan model ARIMA dapat dilakukan dengan melihat pada plot ACF dan PACF. Dapat dilihat pada Gambar 5.



**Gambar 5.** Plot ACF dan PACF Data Inflasi Bulanan

Berdasarkan Gambar 5 menunjukkan pada grafik ACF terjadi *cut off* pada *lag* 1 dan pada grafik PACF menunjukkan terjadi *cut off* pada *lag* 1 sehingga didapatkan beberapa dugaan model. Dapat dilihat pada Tabel 4.4.

**Tabel 3.** Hasil Estimasi Parameter

Model	Parameter		p-value	MSE
ARMA(1,1)	AR(1)	-0,5818	0,001	0,702
	MA(1)	-0,71917	0,000	
	Konstanta	0,8513	0,000	
AR(1)	AR(1)	0,2005	0,012	0,714
	Konstanta	0,4305	0,000	
MA(1)	MA(1)	-0,2497	0,002	0,707
	Konstanta	0,53894	0,000	

**Sumber:** Data diolah, 2018

Berdasarkan Tabel 3. pada semua dugaan model nilai MSE terkecil berada pada model ARMA(1,1) yaitu 0,702 dan semua parameter ARMA(1,1) signifikan. Sehingga dapat disimpulkan model data jumlah orang yang dimakamkan adalah ARMA(1,1) dengan parameter AR = -0,5818 dan MA = -0,71917.

#### 4.4.3 Uji White Noise

Hasil nilai statistik Ljung-Box untuk pengujian *white noise* dapat dilihat pada Tabel 4.5

**Tabel 4.** Hasil Ljung-Box

Lag	$\chi^2$	DF	p-value
12	7,6	9	0,577
24	12,2	21	0,935
36	20,6	33	0,955
48	30,3	45	0,955

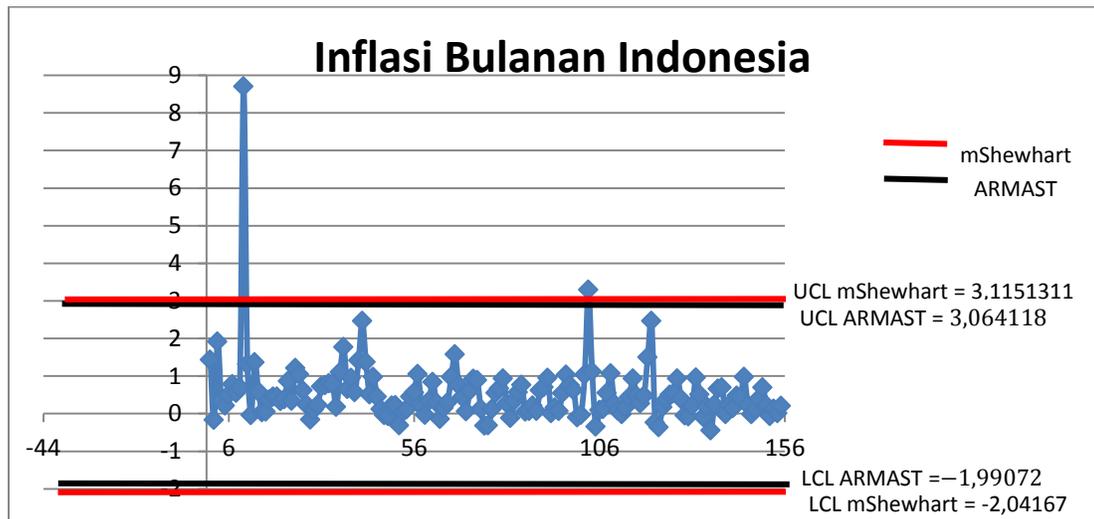
**Sumber:** Data diolah, 2018

Nilai statistik Ljung-Box pada lag 12 menunjukkan nilai statistik antara *lag* t dengan *lag* 12. Pada Tabel 4. menunjukkan bahwa pada *lag* 12 nilai *p-value* adalah  $0,577 > 0,05$  yang berarti tidak cukup bukti untuk menolak  $H_0$  sehingga diperoleh kesimpulan yaitu tidak ada korelasi antara residual pada *lag* t dengan residual pada *lag* 12. Untuk lag 24, 36, dan 48 nilai *p-value*  $> 0,05$  artinya antara sisaan pada *lag* t dan pada lag 24, 36, dan 48 tidak ada yang saling berkorelasi. Karena tidak ada yang mengalami korelasi sehingga dapat disimpulkan residual telah memenuhi syarat *white noise*.

#### 4.4.4 Bagan Kendali

Berdasarkan hasil perhitungan nilai UCL, CL, dan LCL dengan menggunakan persamaan (1) diperoleh bagan kendali modifikasi Shewhart pada ARMA(1,1) untuk data 500

yaitu  $UCL = 3,1151311$ ,  $CL = 0,5367$ , dan  $LCL = -2,04167$ . Dengan menggunakan persamaan (2) diperoleh hasil bagan kendali ARMAST yaitu  $UCL = 3,064118$ ,  $CL = 0,5367$ , dan  $LCL = -2,04167$ . Secara visual dapat dilihat pada Gambar 6.



**Gambar 6.** Bagan Kendali Inflasi Bulanan Indonesia

Secara visual pada Gambar 6. menunjukkan pada kedua bagan kendali terdapat dua data yang keluar dari bagan kendali yaitu pada bulan Oktober 2005 dan Juli tahun 2017. Jika dibandingkan bagan kendali modifikasi Shewhart dan ARMAST maka didapatkan bagan kendali modifikasi Shewhart lebih lebar dibandingkan bagan kendali ARMAST. Hal ini mengindikasikan bahwa ARMAST lebih sensitif terhadap data *out of control* dibandingkan dengan modifikasi Shewhart.

## 5. Kesimpulan

Berdasarkan penelitian terhadap data yang berpola ARMA(1,1) pada data simulasi diperoleh bagan kendali modifikasi Shewhart lebih lebar dibandingkan bagan kendali ARMAST. Untuk data Inflasi Bulanan Indonesia Januari 2005 hingga Desember 2017 diperoleh Bagan kendali Shewhart adalah  $UCL = 3,1151311$ ,  $CL = 0,5367$  dan  $LCL = -2,04167$  dan Bagan kendali ARMAST adalah  $UCL = 3,064118$ ,  $CL = 0,5367$ , dan  $LCL = -1,99072$ . Berdasarkan hasil bagan kendali pada data Inflasi Bulanan Indonesia Januari 2005 hingga Desember 2017 juga menunjukkan bagan kendali modifikasi Shewhart lebih lebar dibandingkan bagan kendali ARMAST. Hal ini mengindikasikan bahwa ARMAST lebih sensitif terhadap data *out of control* dibandingkan dengan modifikasi Shewhart. Berdasarkan nilai ARL diperoleh hasil nilai ARL bagan kendali ARMAST lebih kecil dibandingkan dengan bagan kendali modifikasi Shewhart Sehingga dapat disimpulkan *performance* bagan kendali ARMAST lebih baik dibandingkan dengan modifikasis Shewhart.

**DAFTAR PUSTAKA**

- [1] Aswi dan Sukarna. 2006. *Analisis Deret Waktu : Teori Dan Aplikasi*. Makassar : Andhira Publisher.
- [2] BPS. 2018. *Indeks Harga Konsumen dan Inflasi Bulanan Indonesia*. dari [www.bps.go.id](http://www.bps.go.id): <https://www.bps.go.id/statictable/2009/06/15/907/indeks-harga-konsumen-dan-inflasi-bulanan-indonesia-2005-2017.html>
- [3] Cryer, D.J. 1986. *Time Series Analysis*. Boston: PWS-KENT Publishing Company
- [4] Dawod, A. B. 2016. On Model Selection for Autocorrelated Processes in Statistical Process Control. *Quality and Reability Engineering International*, 33(4): 867-882
- [5] Fitriani, A. 2014. *Diagram Kontrol Cumulative Sum Untuk Pengontrolan Proses dengan Model Autoregresive Orde Pertama (AR(1))* [skripsi]. Bandung: Universitas Islam Bandung.
- [6] Montgomery, C. Douglas. 2009. *Statistical Quality Control (6th ed)*. Asia: John Wiley & Sons (Asia) Pte. Ltd.
- [7] Padgett, C.S., Thombs L.A. and Padgett, W. J. 1992. On the QUOTE -risk for Shewhart Control Chart. *Communication in Statistics, Simulation, and Computation*. 21: 1125-1147.
- [8] Rusdi. 2011. Uji Akar-Akar Unit dalam Model Runtun Waktu Autoregresif. *Forum Teori dan Aplikasi Statistika* , 11(2): 67-78.
- [9] Wei, William, W.S. 2006. *Time series Analysis: Univariate and Multivariate Methods, . 2nd Edition*. USA: Pearson Educations, Inc.
- [10] W. Jiang, K.L. Tsui, and W.H. Woodall. 2000. A new SPC monitoring method: The ARMA chart. *Technometrics*.42(4): 399-410.