



Monograf

Analisa Prediksi Harga Emas Dengan Menggunakan Model Autoregresif Orde Satu



Retno Tri Vlandari, S.Si, M.Si
Setiyowati, S.Kom, M.Kom
Sri Harjanto S.Kom, M.Kom

MONOGRAF

ANALISA PREDIKSI HARGA EMAS DENGAN MENGGUNAKAN MODEL AUTOREGRESIF ORDE SATU

Retno Tri Vulandari, S.Si., M.Si.

Setiyowati, S.Kom., M.Kom.

Sri Harjanto, S.Kom., M.Kom.

MONOGRAF
ANALISA PREDIKSI HARGA EMAS DENGAN MENGGUNAKAN MODEL
AUTOREGRESIF ORDE SATU



Retno Tri Vulandari, S.Si., M.Si.
Setiyowati, S.Kom., M.Kom.
Sri Harjanto, S.Kom., M.Kom.

Penerbit

LEMBAGA PENELITIAN DAN PENGABDIAN KEPADA MASYARAKAT
UNIVERSITAS DIAN NUSWANTORO
SEMARANG
2021

**MONOGRAF: ANALISA PREDIKSI HARGA EMAS DENGAN
MENGUNAKAN MODEL AUTOREGRESIF ORDE SATU**

Penulis

Retno Tri Vulandari, S.Si., M.Si.
Setiyowati, S.Kom., M.Kom.
Sri Harjanto, S.Kom., M.Kom.

ISBN:978-623-5683-03-4

Penerbit :

Lembaga Penelitian dan Pengabdian Kepada Masyarakat
Universitas Dian Nuswantoro Semarang

Redaksi :

LPPM Udinus
Jl. Nakula I No.5-11
Semarang 50131

Telp: (024) 352-7261, 352-0165

Fax : (024) 356-9684

Desain Layout :

Pencetak :

Percetakan Universitas Dian Nuswantoro Semarang

Hak Cipta 2021 dilindungi oleh undang-undang
Dilarang mengutip sebagian atau seluruh isi tanpa seijin penulis

KATA PENGANTAR



Puji syukur kami panjatkan kehadiran Allah SWT yang telah melimpahkan berkah, rahmat dan hidayah- Nya sehingga penulis berhasil menyelesaikan monograf dengan judul Analisa Prediksi Harga Emas dengan Menggunakan Model Autoregresif Orde Satu.

Harapan penulis semoga Buku monograf ini bermanfaat dan dapat menjadi referensi bagi para peneliti. Penulis menyadari bahwa penyusunan buku monograf ini tentunya tidak luput dari kekurangan. Oleh karena itu kritik dan saran perbaikan yang sifatnya membangun, akan penulis terima untuk memperbaiki kualitas penulisan berikutnya.

Akhir kata semoga analisis prediksi harga emas dapat bermanfaat bagi pelaku investasi emas pada khususnya, serta dapat memberikan manfaat kepada masyarakat pada umumnya.

Surakarta, Oktober 2021
Penulis

DAFTAR ISI

KATA PENGANTAR	v
DAFTAR ISI.....	vi
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Gambaran Objek Penelitian.....	2
1.3. Perumusan Masalah.....	3
1.4. Tujuan Penelitian.....	3
1.5. Luaran.....	3
BAB II TINJAUAN PUSTAKA.....	4
2.1 Uji Stasioneritas	4
2.2 Fungsi ACF dan PACF.....	4
2.3 Sifat Model Stasioner	4
2.4 Estimasi Parameter Model Stasioner.....	8
2.4.1 Estimasi Parameter Model <i>Autoregressive</i> Orde Satu	8
2.4.2 Estimasi Parameter Model <i>Autoregressive</i> Orde Dua	9
2.4.3 Estimasi Parameter Model <i>Autoregressive</i> Orde p	10
2.5 Model Diagnostik	13
2.5.1 Uji Autokorelasi	13
2.5.2 Heteroskedastisitas	13
2.6 Penelitian yang Relevan	14
BAB III METODOLOGI PENELITIAN.....	16
3.1. Prosedur Pengolahan Data.....	16
3.2. Analisa Data	16
3.2.1 Uji Stasioneritas	16
3.2.2 Identifikasi Model ACF dan PACF	17

3.2.3	Estimasi Parameter Model Stasioner	17
3.2.4	Model Diagnostik.....	17
3.3.	Kerangka Pikir.....	18
BAB IV. HASIL DAN PEMBAHASAN		20
4.1	Deskripsi dan Pola Data	20
4.2	Identifikasi Model Stasioner Rata-rata ARIMA	21
4.3	Estimasi Parameter Model Rata-rata ARIMA.....	21
4.4	Uji Diagnostik Model ARIMA.....	22
BAB V. KESIMPULAN DAN SARAN.....		25
5.1.	Kesimpulan	25
5.2.	Saran	25
DAFTAR PUSTAKA		26

BAB I PENDAHULUAN

1.1. Latar Belakang Masalah

Pertumbuhan ekonomi di Indonesia sejak 5 tahun terakhir selalu mengalami penurunan. Walaupun pada tahun 2015 mengalami peningkatan hingga kuartal III, pertumbuhan ekonomi masih melambat dibandingkan dengan tahun-tahun sebelumnya. Dari rilis data terbaru Badan Pusat Statistik (BPS), Pertumbuhan Ekonomi Indonesia pada kuartal III-2015 sebesar 4,73 persen meningkat dibanding kuartal II-2015 yang tumbuh 4,67 persen. Peningkatan 0,06 persen ini mengindikasikan hal positif terhadap perekonomian Indonesia kedepannya. Namun pertumbuhan di kuartal III-2015 ini melambat dibanding capaian tahun sebelumnya yaitu di kuartal III-2014 yang tumbuh 4,92 persen.

Emas adalah sejenis logam mulia terpercaya yang bisa mempertahankan nilainya dan digunakan dalam transaksi (Baur and Mc Dermott, 2010). Harga emas bergantung kepada kondisi ekonomi dunia. Namun emas merupakan instrumen yang paling stabil dan liquid dalam fiksasi modal dan tabungan masa depan. Menurut Suharto (2013), emas merupakan salah satu instrumen simpanan pokok (investasi) yang paling stabil dan efektif. Selain itu juga emas sering disebut sebagai pengukur modal dan dimensi kekayaan yang paling tua dan efektif. Oleh karena itu diperlukan suatu model yang dapat digunakan untuk memprediksi tinggi muka air, agar dapat dilakukan peringatan dini bahaya banjir. Harga emas merupakan data runtun waktu yang diukur tiap hari.

Menurut Bollerslev (1986), data runtun waktu dapat disusun dengan model stasioner, seperti *Autoregressive Integrated Moving Average* (ARIMA). Model ini dapat diidentifikasi dengan *Autocorelation Function* (ACF) dan *Partial Autocorelation Function* (PACF). Model ARIMA memiliki asumsi homoskedastisitas atau variansi eror tetap. Tetapi jika data runtun waktu tinggi muka air memiliki variansi eror berubah-ubah setiap saat atau terjadi heteroskedastisitas.

Ada beberapa model yang dapat digunakan untuk mengatasi masalah heteroskedastisitas, seperti dalam penelitian Engle (1982) mengenai estimasi variansi inflasi di Inggris, Engle memperkenalkan model *Autoregressive Conditional Heteroscedasticity* (ARCH). Dalam penelitian Bollerslev (1986) memperkenalkan *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) (Setiawan, 2013).

1.2. Gambaran Objek Penelitian.

Harga emas adalah harga spot yang terbentuk dari akumulasi penawaran dan permintaan di pasar emas London. Harga emas yang digunakan adalah hasil lelang kelima anggota London Gold Fixing. Data harga emas dunia yang digunakan adalah harga penutupan (close price-Gold P.M) akhir bulan. Kurs atau nilai tukar adalah nilai tukar mata uang (nominal) yang membandingkan nilai mata uang dua negara. Dalam penelitian ini, proksi nilai tukar yang digunakan adalah nilai tukar mata uang Rupiah terhadap mata uang Dolar Amerika Serikat. Data kurs yang digunakan adalah kurs penutupan (close price) akhir bulan. Terdapat beberapa penyebab Harga Emas Dunia turun drastis. Alasan pertama disebabkan oleh rencana The Federal Reserve mengenai kebijakan pengurangan stimulus fiskal berupa pembelian obligasi negara sebesar US\$ 85 milyar per bulan. Apabila perekonomian Amerika Serikat terus mengalami peningkatan, maka The Fed akan mengurangi pemberian stimulus secara bertahap mulai awal 2014, kemudian dievaluasi setiap kuartal, sebelum benar-benar dihentikan pada pertengahan 2014. Pengurangan stimulus menyebabkan jumlah Dolar AS berkurang di pasar sehingga nilai mata uang Dolar AS menguat. Akan tetapi, langkah The Fed ini menyebabkan emas kehilangan momentum dan mengakibatkan banyak investor beralih dari emas ke Dolar AS (www.forum.kompas.com). Penyebab kedua adalah penurunan permintaan emas dari India dan China yang merupakan negara terbesar pengimpor emas. Kedua negara ini mengalami perlambatan pertumbuhan ekonomi sehingga membebani harga emas dunia. All India Gems and Jewelry Trade Federation telah menghentikan penjualan

emas batangan dan koin. Hal ini dilakukan untuk memotong impor emas yang mengakibatkan neraca perdagangan India mengalami defisit.

1.3. Perumusan Masalah

Identifikasi Masalah adalah sebagai berikut :

1. Bagaimana proses pemodelan autoregresif orde satu pada data runtun waktu harga emas?
2. Bagaimana menentukan model autoregresif orde satu yang terbaik pada data harga emas?

1.4. Tujuan Penelitian

Tujuan dari penelitian ini adalah analisa harga emas dengan model Autoregresif Orde Satu. Analisa ini dilihat dari pengamatan tiap periode dan menentukan model Autoregresif Orde Satu terbaik untuk periode 2000 - 2019.

1.5. Luaran

Penelitian ini menghasilkan luaran berupa Jurnal ilmiah dengan judul *Application of Autoregressive Method on Prediction of Gold*.

BAB II TINJAUAN PUSTAKA

2.1 Uji Stasioneritas

Kestasioneran data dapat diketahui dengan menggunakan uji akar unit. Hipotesis dalam uji tersebut dalam Tsay (2002) dituliskan sebagai

$$H_0 : \eta = 1 \text{ (data mempunyai akar unit)}$$

$$H_1 : \eta < 1 \text{ (data tidak mempunyai akar unit).}$$

Statistik uji merupakan rasio dari koefisien estimasi dikurangi 1 dibandingkan dengan standar deviasinya. *Augmanted* Dickey-Fuller (ADF) atau rasio t dirumuskan sebagai

$$ADF = \frac{\eta - 1}{\sigma(\eta)} = \frac{\frac{\sum_{t=1}^T y_{t-1} y_t - 1}{\sum_{t=1}^T y_{t-1}^2}}{\sqrt{\frac{\sum_{t=1}^T (y_t - \eta y_{t-1})^2}{T-1}}}$$

dengan T adalah ukuran sampel dan y_t adalah data pengamatan ke- t . H_0 ditolak ketika rasio $|t| > \tau_{(T-1)}$

2.2 Fungsi ACF dan PACF

Menurut Bollerslev (1986), alat untuk mengidentifikasi model ARMA adalah ACF dan PACF. Fungsi autokorelasi adalah fungsi yang menunjukkan besarnya korelasi antara pengamatan pada waktu ke- t dengan pengamatan pada waktu-waktu sebelumnya, sedangkan PACF adalah fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke- t dengan pengamatan-pengamatan pada waktu-waktu sebelumnya.

2.3 Sifat Model Stasioner

Floros (2005) menjelaskan bahwa ARMA merupakan bentuk model runtun waktu linear yang berusaha untuk mengidentifikasikan persamaan dengan hanya menggunakan nilai masa lalunya atau kombinasi nilai masa lalu dan eror masa lalunya. Model ARMA mengandung dua komponen yaitu model AR dan MA dengan order dari AR adalah p dan order dari MA adalah q .

Berikut adalah model stasioner menurut Cryer (2010)

1. Autoregressive (AR)

Autoregressive (AR) adalah model rata-rata yang menggambarkan suatu pengamatan pada waktu t dipengaruhi pada nilai-nilai pengamatan sepanjang p periode sebelumnya. Bentuk umum model *autoregressive* orde p adalah

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t \quad (2.1)$$

Model AR(1)

Model AR(1) adalah besarnya nilai-nilai pengamatan pada waktu t dipengaruhi oleh nilai-nilai pengamatan sepanjang 1 periode sebelumnya, didefinisikan berikut

$$Y_t = \phi_1 Y_{t-1} + e_t$$

Model AR(1) dengan $e_t \sim WN(\mu_e, \sigma_e^2)$. Model AR(1) merupakan model stasioner. Suatu proses dikatakan stasioner jika tidak dipengaruhi pada nilai t .

$$Y_t = \phi_1 Y_{t-1} + e_t$$

$$Y_{t-1} = \phi_1 Y_{t-2} + e_{t-1}$$

$$Y_{t-2} = \phi_1 Y_{t-3} + e_{t-2}$$

$$Y_{t-3} = \phi_1 Y_{t-4} + e_{t-3}$$

$$Y_t = e_t + \phi_1 e_{t-1} + \phi_1^2 e_{t-2} + \dots + \phi_1^k e_{t-k} + \dots + \phi_1^{t-1} e_1$$

Mean model autoregresi orde 1 diperoleh sebagai berikut

$$E(Y_t) = \frac{\mu_e(1 - \phi_1^t)}{(1 - \phi_1)}$$

Untuk $t \rightarrow \infty$ dan $|\phi_1| < 1$ maka

$$E(Y_t) = \frac{\mu_e}{(1 - \phi_1)}$$

Variansi model autoregresi orde 1 diperoleh sebagai berikut

$$Var(Y_t) = \frac{\sigma_e^2(1 - \phi_1^{2t})}{(1 - \phi_1^2)}$$

Untuk $t \rightarrow \infty$ dan $|\phi_1| < 1$ maka

$$\text{Var}(Y_t) = \frac{\sigma_\varepsilon^2}{(1 - \phi_1^2)}$$

Kovariansi model AR(1) untuk $k = 1$ diperoleh sebagai berikut

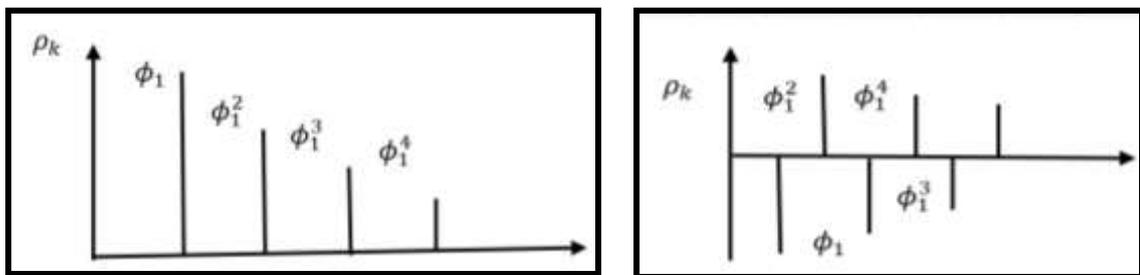
$$\text{Cov}(Y_t, Y_{t-1}) = \frac{\phi_1 \sigma_\varepsilon^2 (1 - \phi_1^{2t})}{(1 - \phi_1^2)}$$

Untuk $t \rightarrow \infty$ dan $|\phi_1| < 1$ maka

$$\gamma_1 = \frac{\phi_1 \sigma_\varepsilon^2}{(1 - \phi_1^2)}$$

kemudian secara umum untuk $k = p$ diperoleh $\gamma_p = \frac{\phi_1^p \sigma_\varepsilon^2}{(1 - \phi_1^2)}$. Autokorelasi (ACF),

diperoleh $\rho_p = \phi_1^p$ sehingga diperoleh grafik ACF sebagai berikut



(a) $0 < \phi_1 < 1$

(b) $-1 < \phi_1 < 0$

Gambar 2.1 Grafik ACF Model AR

Berdasarkan Gambar 2.1 terlihat grafik ACF untuk $0 < \phi_1 < 1$ turun cepat secara eksponensial dan untuk $-1 < \phi_1 < 0$ turun cepat secara sinusoidal.

Model AR(p)

Model AR(p) adalah besarnya nilai-nilai pengamatan pada waktu t dipengaruhi oleh nilai-nilai pengamatan sepanjang p periode sebelumnya, didefinisikan seperti pada Persamaan (2.1). Model AR(p) dengan $e_t \sim WN(\mu_\varepsilon, \sigma_\varepsilon^2)$. Autokovariansi model AR(p) diperoleh sebagai berikut

$$\gamma_k = \text{cov}(Y_t, Y_{t-k})$$

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p}$$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}$$

untuk $k = 1$ diperoleh $\rho_1 = \phi_1 + \phi_2\rho_1 + \dots + \phi_p\rho_{p-1}$

untuk $k = 2$ diperoleh $\rho_2 = \phi_1\rho_1 + \phi_2 + \dots + \phi_p\rho_{2-p}$

untuk $k = p$ diperoleh $\rho_p = \phi_1\rho_{p-1} + \phi_{p-2} + \dots + \phi_p$

sehingga diperoleh variansi model **AR(p)** sebagai berikut

$$\gamma_0 = \phi_1\gamma_1 + \phi_2\gamma_2 + \dots + \phi_p\gamma_p + \sigma_e^2$$

2. Autoregressive Moving Average (ARMA)

Autoregressive Moving Average (ARMA) adalah gabungan antara AR dan MA, berikut adalah model umum ARMA (p, q).

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.3)$$

ARMA(1,1)

ARMA(1,1) adalah proses autoregresif orde 1 dan proses *moving average* orde 1 sebagai berikut

$$Y_t = \phi Y_{t-1} + e_t - \theta e_{t-1}$$

sehingga diperoleh fungsi autokovariansi sebagai berikut

untuk $k = 0$ diperoleh

$$E(Y_t Y_t) = \gamma_0 = \phi\gamma_1 + \sigma_e^2 - \theta(\phi - \theta)\sigma_e^2 \quad (2.4)$$

untuk $k = 1$ diperoleh

$$E(Y_t Y_{t-1}) = \gamma_1 = \phi\gamma_0 - \theta\sigma_e^2 \quad (2.5)$$

dengan substitusi Persamaan (2.5) ke Persamaan (2.4) diperoleh

$$\gamma_0 = \frac{(1-2\theta\phi+\theta^2)}{(1-\phi^2)}\sigma_e^2 \text{ dan } \gamma_1 = \frac{(1-\theta\phi)(\phi-\theta)}{(1-\phi^2)}\sigma_e^2$$

untuk $k = 2$, diperoleh fungsi autokovariansi

$$\gamma_2 = \frac{(1-\theta\phi)(\phi-\theta)}{(1-\phi^2)}\phi\sigma_e^2$$

untuk $k = k$ diperoleh

$$\gamma_k = \frac{(1-\theta\phi)(\phi-\theta)}{(1-\phi^2)}\phi^{k-1}\sigma_e^2$$

Sedangkan fungsi autokorelasi, untuk $k = 1$

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{(1 - \theta\phi)(\phi - \theta)}{1 - 2\theta\phi + \theta^2}$$

untuk $k = 2$

$$\rho_2 = \frac{\gamma_2}{\gamma_0} = \frac{(1 - \theta\phi)(\phi - \theta)\phi}{1 - 2\theta\phi + \theta^2}$$

untuk $k = k$

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{(1 - \theta\phi)(\phi - \theta)\phi^{k-1}}{1 - 2\theta\phi + \theta^2}$$

ARMA(p, q)

ARMA(p, q) adalah proses autoregresif orde p dan proses *moving average* orde q seperti pada Persamaan (2.3). Kemudian dengan mengalikan kedua ruas dengan Y_{t-k} sehingga diperoleh bentuk

$$Y_t Y_{t-k} = \phi_1 Y_{t-1} Y_{t-k} + \dots + \phi_p Y_{t-p} Y_{t-k} + e_t Y_{t-k} - \theta_1 e_{t-1} Y_{t-k} - \dots - \theta_q e_{t-q} Y_{t-k}$$

sehingga fungsi autokovariansi

$$\gamma_k = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p} + E(e_t Y_{t-k}) - \theta_1 E(e_{t-1} Y_{t-k}) - \dots - \theta_q E(e_{t-q} Y_{t-k})$$

karena $E(e_{t-i} Y_{t-k}) = 0$ untuk $k > i$ maka $\gamma_k = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p}$ untuk $k \geq q + 1$ dan fungsi autokorelasi diperoleh sebagai berikut

$$\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p} \text{ untuk } k \geq q + 1$$

2.4 Estimasi Parameter Model Stasioner

2.4.1 Estimasi Parameter Model *Autoregressive* Orde Satu

Model AR(1)

Berikut adalah model autoregresi orde satu dengan mean μ

$$Y_t - \mu = \phi_1 (Y_{t-1} - \mu) + e_t$$

Persamaan tersebut dapat dilihat sebagai model regresi dengan variabel prediktor Y_{t-1} dan variabel respon Y_t . Estimasi kuadrat terkecil dihasilkan dengan meminimalkan jumlah kuadrat erornya.

$$(Y_t - \mu) - \phi_1 (Y_{t-1} - \mu)$$

Karena hanya Y_1, Y_2, \dots, Y_n yang diamati, maka diperoleh jumlahan dari $t = 2$ sampai $t = n$ sebagai berikut

$$S_c(\phi_1, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu)]^2$$

kemudian estimasi dari mean ($\hat{\mu}$) diperoleh melalui

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi_1(Y_{t-1} - \mu)](-1 + \phi_1) = 0$$

$$\mu = \frac{1}{(n-1)(1-\phi_1)} \left[\sum_{t=2}^n Y_t - \phi_1 \sum_{t=2}^n Y_{t-1} \right]$$

untuk n besar dapat diperoleh

$$\frac{1}{(n-1)} \sum_{t=2}^n Y_t \approx \frac{1}{(n-1)} \sum_{t=2}^n Y_{t-1} \approx \bar{Y}$$

$$\hat{\mu} \approx \frac{1}{(1-\phi_1)} [\bar{Y} - \phi_1 \bar{Y}] = \bar{Y}$$

kemudian estimasi dari ϕ_1 diperoleh

$$\frac{\partial S_c(\phi_1, \bar{Y})}{\partial \phi_1} = \sum_{t=2}^n 2[(Y_t - \bar{Y}) - \phi_1(Y_{t-1} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0$$

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2}$$

2.4.2 Estimasi Parameter Model Autoregressive Orde Dua

Model AR(2)

Berikut adalah model autoregresi orde dua dengan mean μ

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + e_t$$

Persamaan tersebut dapat dilihat sebagai model regresi dengan variabel prediktor Y_{t-1} dan variabel respon Y_t . Estimasi kuadrat terkecil dihasilkan dengan meminimalkan jumlah kuadrat erornya.

$$(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \phi_2(Y_{t-2} - \mu)$$

$$S_c(\phi_1, \phi_2, \mu) = \sum_{t=3}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \phi_2(Y_{t-2} - \mu)]^2$$

kemudian estimasi dari mean ($\hat{\mu}$) diperoleh melalui

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=3}^n 2[(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \phi_2(Y_{t-2} - \mu)](-1 + \phi_1 + \phi_2) = 0$$

$$\mu = \frac{1}{(n-1)(1 - \phi_1 - \phi_2)} \left[\sum_{t=3}^n Y_t - \phi_1 \sum_{t=3}^n Y_{t-1} - \phi_2 \sum_{t=3}^n Y_{t-2} \right]$$

untuk n besar dapat diperoleh

$$\frac{1}{(n-1)} \sum_{t=3}^n Y_t \approx \frac{1}{(n-1)} \sum_{t=3}^n Y_{t-1} \approx \frac{1}{(n-1)} \sum_{t=3}^n Y_{t-2} \approx \bar{Y}$$

$$\hat{\mu} \approx \frac{1}{(1 - \phi_1 - \phi_2)} [\bar{Y} - \phi_1 \bar{Y} - \phi_2 \bar{Y}] = \bar{Y}$$

kemudian diperoleh estimasi dari ϕ_1 dan ϕ_2 berikut

$$\hat{\phi}_1 = \frac{r_1(1 - r_2)}{1 - r_1^2} \quad \text{dan} \quad \hat{\phi}_2 = \frac{r_1^2 - r_2}{r_1^2 - 1}$$

dengan

$$r_1 = \frac{\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=3}^n (Y_{t-1} - \bar{Y})^2} \quad \text{dan} \quad r_2 = \frac{\sum_{t=3}^n (Y_t - \bar{Y})(Y_{t-2} - \bar{Y})}{\sum_{t=3}^n (Y_{t-2} - \bar{Y})^2}$$

2.4.3 Estimasi Parameter Model *Autoregressive* Orde p

Model AR(p)

Berikut adalah model autoregresi orde p dengan mean μ

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + e_t$$

Persamaan tersebut dapat dilihat sebagai model regresi dengan variabel prediktor Y_{t-1} dan variabel respon Y_t . Estimasi kuadrat terkecil dihasilkan dengan meminimalkan jumlah kuadrat erornya.

$$\begin{aligned} S_c(\phi_1, \phi_2, \dots, \phi_p, \mu) &= \sum_{t=p+1}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \phi_2(Y_{t-2} - \mu) - \dots \\ &\quad - \phi_p(Y_{t-p} - \mu)]^2 \end{aligned}$$

kemudian estimasi dari mean ($\hat{\mu}$) diperoleh

$$\hat{\mu} \approx \frac{1}{(1 - \phi_1 - \phi_2 - \dots - \phi_p)} [\bar{Y} - \phi_1 \bar{Y} - \phi_2 \bar{Y} - \dots - \phi_p \bar{Y}] = \bar{Y}$$

Estimasi dari ϕ_1 diperoleh

$$\frac{\partial S_c(\phi_1, \phi_2, \dots, \phi_p, \bar{Y})}{\partial \phi_1} = 0$$

$$\sum_{t=3}^n 2[(Y_t - \bar{Y}) - \phi_1(Y_{t-1} - \bar{Y}) - \phi_2(Y_{t-2} - \bar{Y}) - \dots - \phi_p(Y_{t-p} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0$$

$$\hat{\gamma}_1 = \hat{\gamma}_0 \phi_1 + \hat{\gamma}_1 \phi_2 + \hat{\gamma}_2 \phi_3 + \dots + \hat{\gamma}_{p-1} \phi_p$$

$$\hat{\rho}_1 = \phi_1 + \hat{\rho}_1 \phi_2 + \hat{\rho}_2 \phi_3 + \dots + \hat{\rho}_{p-1} \phi_p$$

$$r_1 = \phi_1 + r_1 \phi_2 + r_2 \phi_3 + \dots + r_{p-1} \phi_p$$

Estimasi dari ϕ_2 diperoleh

$$\frac{\partial S_c(\phi_1, \phi_2, \dots, \phi_p, \bar{Y})}{\partial \phi_2} = 0$$

$$\sum_{t=3}^n 2[(Y_t - \bar{Y}) - \phi_1(Y_{t-1} - \bar{Y}) - \phi_2(Y_{t-2} - \bar{Y}) - \dots - \phi_p(Y_{t-p} - \bar{Y})](Y_{t-2} - \bar{Y}) = 0$$

$$\hat{\gamma}_2 = \hat{\gamma}_1 \phi_1 + \hat{\gamma}_0 \phi_2 + \hat{\gamma}_1 \phi_3 + \dots + \hat{\gamma}_{p-2} \phi_p$$

$$\hat{\rho}_2 = \hat{\rho}_1 \phi_1 + \phi_2 + \hat{\rho}_1 \phi_3 + \dots + \hat{\rho}_{p-2} \phi_p$$

$$r_2 = r_1 \phi_1 + \phi_2 + r_1 \phi_3 + \dots + r_{p-2} \phi_p$$

Kemudian estimasi dari ϕ_p diperoleh

$$\frac{\partial S_c(\phi_1, \phi_2, \dots, \phi_p, \bar{Y})}{\partial \phi_p} = 0$$

$$\sum_{t=3}^n 2[(Y_t - \bar{Y}) - \phi_1(Y_{t-1} - \bar{Y}) - \phi_2(Y_{t-2} - \bar{Y}) - \dots - \phi_p(Y_{t-p} - \bar{Y})](Y_{t-p} - \bar{Y}) = 0$$

$$\hat{\gamma}_p = \hat{\gamma}_{p-1} \phi_1 + \hat{\gamma}_{p-2} \phi_2 + \hat{\gamma}_{p-3} \phi_3 + \dots + \phi_p$$

$$\hat{\rho}_p = \hat{\rho}_{p-1} \phi_1 + \hat{\rho}_{p-2} \phi_2 + \hat{\rho}_{p-3} \phi_3 + \dots + \phi_p$$

$$r_p = r_{p-1} \phi_1 + r_{p-2} \phi_2 + r_{p-3} \phi_3 + \dots + \phi_p$$

sehingga diperoleh p persamaan linear sebagai berikut

$$r_1 = \phi_1 + r_1 \phi_2 + r_2 \phi_3 + \dots + r_{p-1} \phi_p$$

$$r_2 = r_1 \phi_1 + \phi_2 + r_1 \phi_3 + \dots + r_{p-2} \phi_p$$

$$\vdots \qquad \qquad \qquad \vdots$$

$$r_p = r_{p-1} \phi_1 + r_{p-2} \phi_2 + r_{p-3} \phi_3 + \dots + \phi_p$$

persamaan linear tersebut dapat diubah ke bentuk matriks sebagai berikut

$$\begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 & \cdots & r_{p-1} \\ r_1 & r_2 & r_3 & \cdots & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} \quad (2.6)$$

misal untuk $k = 2$ diperoleh

$$\begin{bmatrix} r_1 \\ r_2 \end{bmatrix} = \begin{bmatrix} 1 & r_1 \\ r_1 & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \end{bmatrix}$$

maka diperoleh estimasi parameter AR(2)

$$\hat{\phi}_1 = \frac{r_1(1-r_2)}{1-r_1^2} \quad \text{dan} \quad \hat{\phi}_2 = \frac{r_2-r_1^2}{1-r_1^2}$$

untuk $k = 3$ diperoleh

$$\begin{bmatrix} r_1 \\ r_2 \\ r_3 \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 \\ r_1 & r_2 & r_3 \\ r_2 & r_3 & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \phi_3 \end{bmatrix}$$

maka diperoleh estimasi parameter AR(3)

$$\hat{\phi}_1 = \frac{\begin{vmatrix} r_1 & r_1 & r_2 \\ r_2 & r_2 & r_3 \\ r_3 & r_3 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & r_1 & r_2 \\ r_1 & r_2 & r_3 \\ r_2 & r_3 & 1 \end{vmatrix}} \quad \hat{\phi}_2 = \frac{\begin{vmatrix} 1 & r_1 & r_2 \\ r_1 & r_2 & r_3 \\ r_2 & r_3 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & r_1 & r_2 \\ r_1 & r_2 & r_3 \\ r_2 & r_3 & 1 \end{vmatrix}} \quad \text{dan} \quad \hat{\phi}_3 = \frac{\begin{vmatrix} 1 & r_1 & r_1 \\ r_1 & r_2 & r_2 \\ r_2 & r_3 & r_3 \end{vmatrix}}{\begin{vmatrix} 1 & r_1 & r_2 \\ r_1 & r_2 & r_3 \\ r_2 & r_3 & 1 \end{vmatrix}}$$

Untuk $k = p$ diperoleh

$$\begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 & \cdots & r_{p-1} \\ r_1 & r_2 & r_3 & \cdots & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix}$$

misal

$$\mathbf{R} = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix}, \mathbf{P} = \begin{bmatrix} 1 & r_1 & r_2 & \cdots & r_{p-1} \\ r_1 & r_2 & r_3 & \cdots & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & 1 \end{bmatrix}, \mathbf{\Phi} = \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix}$$

maka Persamaan (2.6) dapat ditulis menjadi

$$\mathbf{R} = \mathbf{P}\mathbf{\Phi}$$

$$\mathbf{\Phi} = \mathbf{P}^{-1}\mathbf{R}$$

maka diperoleh estimasi parameter AR(p) adalah $\hat{\mathbf{\Phi}} = \hat{\mathbf{P}}^{-1}\mathbf{R}$.

2.5 Model Diagnostik

Menurut Winarno (2007), model diagnostik digunakan untuk mengetahui apakah model cocok untuk digunakan. Kecocokan model dilihat dari erornya, eror dari model dikatakan baik apabila sudah tidak terdapat autokorelasi, variansinya homogen dan memiliki nilai MSE yang kecil. Oleh karena itu, dilakukan uji autokorelasi eror, uji homogenitas variansi dan penghitungan nilai MSE. Apabila eror tidak memenuhi tiga hal tersebut, maka model yang diperoleh kurang cocok dengan data, sehingga perlu dilakukan identifikasi dan estimasi lagi.

2.5.1 Uji Autokorelasi

Model rata-rata bersyarat dan model heteroskedastisitas dikatakan baik apabila eror yang dihasilkan sudah tidak memiliki autokorelasi. Hal ini dapat dilihat dari plot ACF dan PACF. Apabila tidak ada nilai yang signifikan berbeda dengan nol berarti sudah tidak ada autokorelasi dalam eror dan menandakan bahwa model sudah cukup baik.

Bentuk plot ACF dan PACF merupakan gambaran awal adanya autokorelasi. Uji statistik perlu dilakukan untuk meyakinkan hal itu. Oleh karena itu, digunakan uji Breusch-Godfrey untuk mengetahui autokorelasi data.

H_0 : tidak ada autokorelasi di dalam eror model rata-rata bersyarat

H_1 : ada autokorelasi di dalam eror model rata-rata bersyarat.

Uji Breusch-Godfrey dirumuskan sebagai

$$t^* = (T - k)R^2$$

dengan T adalah ukuran sampel dan R^2 adalah koefisien determinasi dari model. Statistik uji t^* dibandingkan dengan nilai tabel χ_k^2 . Apabila nilai t^* lebih besar dari nilai χ_k^2 maka H_0 ditolak.

2.5.2 Heteroskedastisitas

Heteroskedastisitas adalah model yang memiliki variansi eror yang tidak konstan. Perubahan variansi eror terjadi setiap saat. Dalam penelitian ini untuk mengidentifikasi heteroskedastisitas digunakan uji White.

H_0 : homoskedastisitas

H_1 : heteroskedastisitas

dengan statistik uji $obs.R^2$. H_0 ditolak jika $obs.R^2 > \chi_{k,\alpha}^2$

2.6 Penelitian yang Relevan

Penelitian mengenai harga emas yang dapat dijadikan referensi dapat dilihat pada Tabel 2.1.

Tabel 2.1 Penelitian Terdahulu yang Berkaitan dengan harga emas

No	Peneliti (Tahun)	Hasil Penelitian
1	Analisa Distribusi Kecepatan Aliran Sungai Musi (Fathona, 2014)	Dalam penelitian ini dibahas mengenai analisis distribusi kecepatan aliran akan dilakukan untuk mengetahui distribusi kecepatan aliran pada permukaan serta debit, dan bagaimana menentukan karakteristik aliran. Kemudian distribusi kecepatan aliran sungai diplot dengan menggunakan program Surfer 11. Data dari lapangan diolah dan dianalisis. Karakteristik aliran kemudian ditentukan dengan menggunakan Bilangan Froude dan Bilangan Reynold. Hasil penelitian menunjukkan bahwa aliran adalah turbulen dan subkritis.
2	Analisis Pengaruh <i>Back Water</i> terhadap Banjir Sungai Rangkui Kota Pangkal Pinang (Anandhita, 2015)	Dalam penelitian ini dibahas mengenai menganalisis pengaruh <i>back water</i> (air balik) terhadap banjir Sungai Rangkui Kota Pangkalpinang. Metode yang digunakan dalam penelitian ini adalah metode penelusuran aliran melalui pemodelan aliran tak seragam (<i>unsteady flow</i>) menggunakan perangkat lunak HEC-RAS.
3	Prediksi Tinggi Muka Air menggunakan Support Vector Machine berbasis Particle Swarm Optimization (Setiawan, 2016)	Tinggi Muka Air Akibat dari Pasang surut air laut yang merupakan fenomena naik turunnya muka laut secara periodik yang terjadi di seluruh belahan bumi akibat adanya gaya pembangkit pasang surut yang utamanya berasal dari matahari dan bulan. Tujuan penulisan penelitian ini adalah untuk menganalisa hasil ketinggian muka air khususnya di daerah Marabahan Kabupaten Barito Kuala Kalimantan Selatan. Metode yang diusulkan SVM dengan PSO yang menggunakan data dari instansi terkait khususnya di daerah Marabahan,. Masing-masing algorithma emas akan implementasikan dengan menggunakan RapidMiner 5.1. Pengukuran kinerja dilakukan dengan menghitung rata-rata error yang

No	Peneliti (Tahun)	Hasil Penelitian
		terjadi melalui besaran Root Mean Square Error (RMSE) .Semakin kecil nilai dari masing-masing parameter kinerja ini menyatakan semakin dekat nilai prediksi dengan nilai sebenarnya. Dengan demikian dapat diketahui algoritharga emas yang lebih akurat. Hasil RMSE Support Vector Machines Berbasis PSO adalah 37,685.

BAB III METODOLOGI PENELITIAN

3.1. Prosedur Pengolahan Data

Dalam penelitian ini prosedur pengolahan data yang digunakan di antaranya:

1. Pengumpulan Data

Data-data yang diperlukan dalam penelitian ini berupa data *time series* dan hasil pengukuran yaitu data harga emas tahun 2000 - 2019

2. Pengolahan Data *Input*

Sebelum dilakukan analisis dengan metode ARIMA maka dilakukan identifikasi data dengan plot data asli untuk mengetahui pola sebaran data, kemudian dilakukan uji stasioneritas karena model ARIMA hanya dapat digunakan oleh data stasioner.

3.2. Analisa Data

Proses pembentukan model stasioner ARIMA yang terdiri dari uji stasioneritas, identitas model ACF dan PACF, estimasi parameter model ARIMA, dan uji diagnostik.

3.2.1 Uji Stasioneritas

Kestasioneran data dapat diketahui dengan menggunakan uji akar unit. Hipotesis dalam uji tersebut dalam Tsay (2002) dituliskan sebagai

$$H_0 : \eta = 1 \text{ (data mempunyai akar unit)}$$

$$H_1 : \eta < 1 \text{ (data tidak mempunyai akar unit).}$$

Statistik uji merupakan rasio dari koefisien estimasi dikurangi 1 dibandingkan dengan standar deviasinya. *Augmanted* Dickey-Fuller (ADF) atau rasio t dirumuskan sebagai

$$ADF = \frac{\eta - 1}{\sigma(\eta)}$$

dengan $x_0 = 0$, T adalah ukuran sampel dan x_t adalah data pengamatan ke- t . H_0 ditolak ketika rasio $t > \tau_{(T-1)}$

3.2.2 Identifikasi Model ACF dan PACF

Menurut Bollerslev (1986), alat untuk mengidentifikasi model ARMA adalah ACF dan PACF. Fungsi autokorelasi adalah fungsi yang menunjukkan besarnya korelasi antara pengamatan pada waktu ke- t dengan pengamatan pada waktu-waktu sebelumnya, sedangkan PACF adalah fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke- t dengan pengamatan-pengamatan pada waktu-waktu sebelumnya.

3.2.3 Estimasi Parameter Model Stasioner

Floros (2005) menjelaskan bahwa ARMA merupakan bentuk model runtun waktu linear yang berusaha untuk mengidentifikasi persamaan dengan hanya menggunakan nilai masa lalunya atau kombinasi nilai masa lalu dan eror masa lalunya. Model ARMA mengandung dua komponen yaitu model AR dan MA dengan order dari AR adalah p dan order dari MA adalah q . Berikut adalah model stasioner menurut Bekti (2011)

1. *Autoregressive (AR)*

Autoregressive (AR) merupakan suatu observasi pada waktu t dinyatakan sebagai fungsi linier terhadap p waktu sebelumnya ditambah dengan sebuah eror acak e_t . Bentuk umum model *autoregressive* orde p adalah

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + e_t$$

2. *Moving Average (MA)*

Moving average (MA) digunakan untuk menjelaskan suatu fenomena bahwa suatu observasi pada waktu t dinyatakan sebagai kombinasi linier dari sejumlah eror acak. Bentuk umum model *moving average* orde q

$$Y_t = e_t - \beta_1 e_{t-1} - \beta_2 e_{t-2} - \dots - \beta_q e_{t-q}$$

3. *Autoregressive Moving Average (ARMA)*

Autoregressive Moving Average (ARMA) adalah gabungan antara AR dan MA, berikut adalah model umum ARMA (p, q).

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + e_t - \beta_1 e_{t-1} - \beta_2 e_{t-2} - \dots - \beta_q e_{t-q}$$

3.2.4 Model Diagnostik

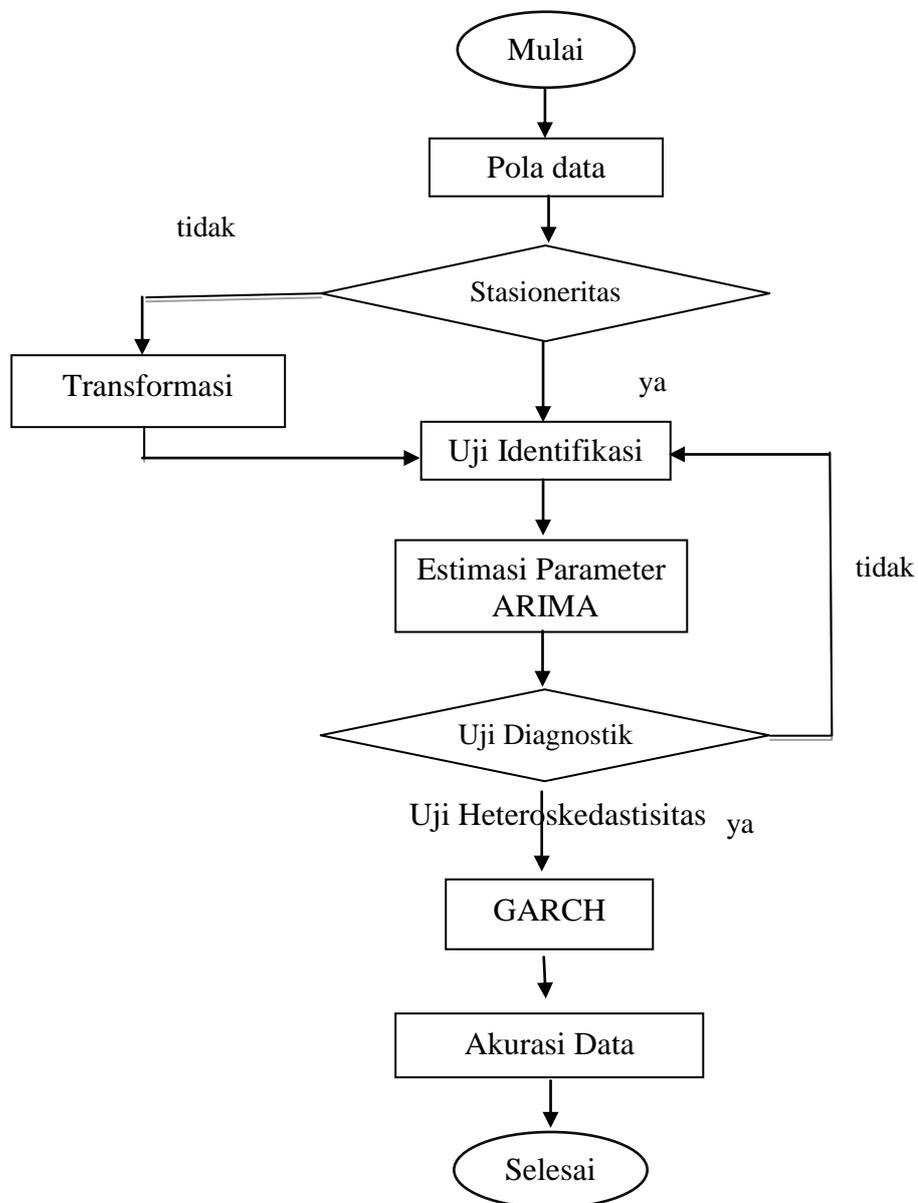
Model diagnostik digunakan untuk mengetahui apakah model cocok untuk digunakan. Kecocokan model dilihat dari erornya, eror dari model dikatakan baik apabila sudah tidak terdapat autokorelasi, variansinya homogen dan memiliki nilai MSE yang kecil. Oleh karena itu, dilakukan uji autokorelasi eror, uji homogenitas variansi dan penghitungan nilai MSE. Apabila eror tidak memenuhi tiga hal tersebut, maka model yang diperoleh kurang cocok dengan data, sehingga perlu dilakukan identifikasi dan estimasi lagi.

3.3. Kerangka Pikir

Berikut adalah langkah-langkah operasional untuk mencapai tujuan penelitian.

1. Membuat plot data untuk mengetahui pola sebaran data
2. Melakukan uji stasioneritas menggunakan uji akar unit, jika data stasioner maka data langsung dapat dimodelkan.
3. Jika data tidak stasioner, maka dilakukan transformasi \ln . Kemudian melakukan uji akar unit kembali.
4. Setelah data stasioner maka dilakukan identifikasi model dengan menggunakan plot ACF dan PACF. Kemudian memberikan kesimpulan dari model stasioner data tersebut dengan menentukan besarnya parameter.
5. Setelah model stasioner terbentuk kemudian dilakukan uji diagnostik pada eror yang dihasilkan oleh model tersebut. Eror adalah selisih data prediksi dengan data sebenarnya.
6. Melakukan tahapan simulasi tersebut dengan menggunakan MATLAB.

Langkah-langkah tersebut dapat dilihat dengan jelas pada Gambar 4.1.

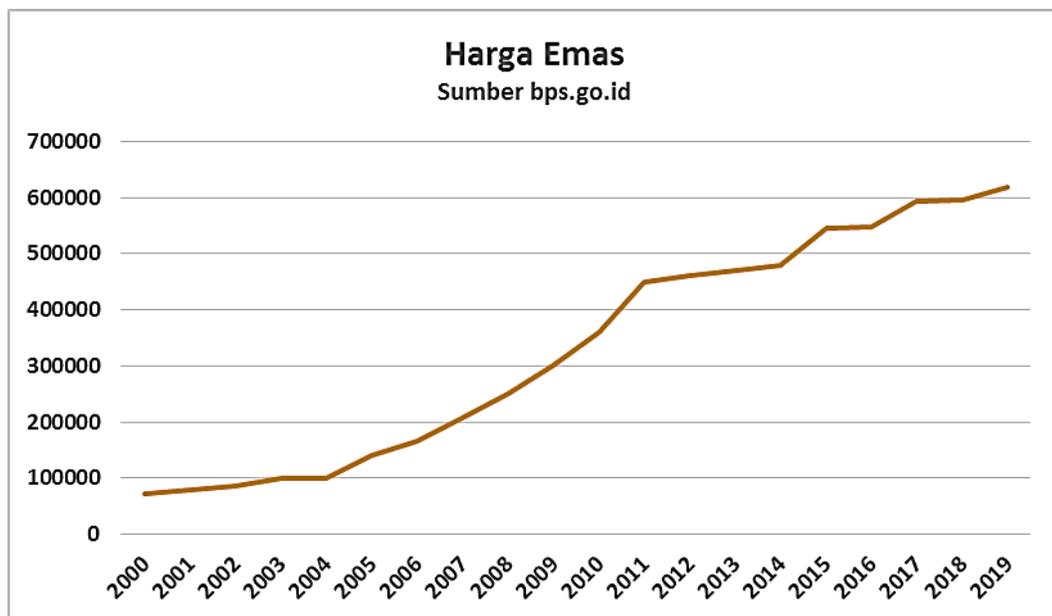


Gambar 3.1 Kerangka Pikir Penelitian

BAB IV. HASIL DAN PEMBAHASAN

4.1 Deskripsi dan Pola Data

Pada penelitian ini digunakan data harga emas tahunan mulai 2000 sampai dengan 2019. Berikut adalah hasil penelitian untuk data harga emas 2000 - 2019. Berdasarkan metode penelitian yang telah dirancang, maka langkah pertama yang dilakukan adalah deskripsi data. Gambar 4.1, menunjukkan harga emas berpola trend naik.



Gambar 4.1. Perbandingan Harga emas dari tahun 2000 - 2019

Tabel 4.1. Uji Stasioner

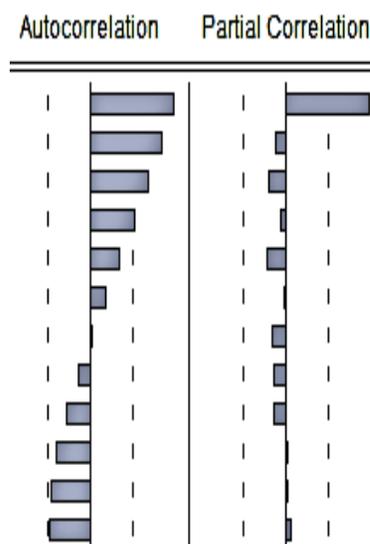
Null Hypothesis: HARGA EMAS	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0,094685	0,9565

Data harga emas tidak stasioner dalam rata-rata. Hal ini diperkuat menggunakan uji stasioner unit root. Nilai probabilitas Augmented Dickey-Fuller (ADF) adalah 0,9565. Nilai probabilitas tersebut lebih besar dari tingkat signifikansi

$\alpha = 0,05$, artinya H_0 gagal ditolak yang menunjukkan data memiliki akar unit maka data tidak stasioner. Berdasarkan pola data dan grafik ACF PACF, data emas tidak stasioner terhadap rata-rata

4.2 Identifikasi Model Stasioner Rata-rata ARIMA

Pemodelan rata-rata bersyarat dari data stasioner dapat menggunakan ARIMA. Untuk mengidentifikasi model ARIMA digunakan ACF dan PACF seperti yang terlihat pada Gambar 4.2. Nilai PACF terputus setelah lag pertama dan ACF turun secara eksponensial maka model rata-rata bersyarat yang digunakan adalah AR (1).



Gambar 4.2 ACF dan PACF

4.3 Estimasi Parameter Model Rata-rata ARIMA

Berdasarkan identifikasi model, harga emas periode 2000 - 2019 dapat dimodelkan dengan AR(1). Estimasi parameter untuk model AR(1) pada Tabel 4.2.

Tabel 4.2. Estimasi Parameter Model ARIMA

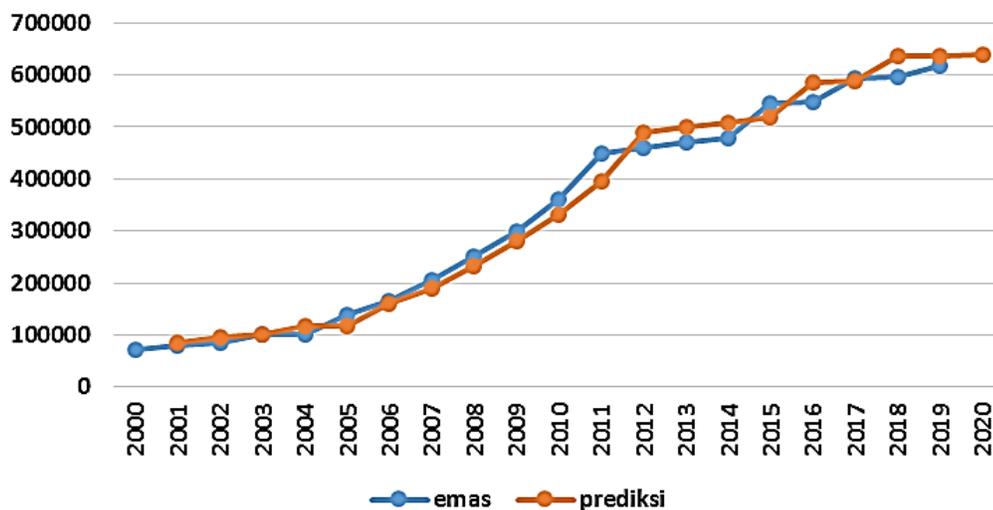
Variabel	AR(1)	
	Koefisien	Prob
C	14,59809	0,0000
AR(1)	0,947994	0,0000

Variabel	AR(1)	
	Koefisien	Prob
MAPE	0,0730101	
MSE	0,128073	

Berdasarkan Tabel 4.2, diperoleh model Autoregresif orde $p = 1$, AR(1) untuk data harga emas tahun 2009 - 2018

$$Y_t = 0,947994 Y_{t-1} + 14,59809 + e_t$$

dengan Y_t adalah data harga emas pada periode t dan Y_{t-1} adalah data harga emas pada periode $t - 1$. Gambar 4.2, Pola data harga emas Aktual, Residual, dan Prediksi dengan Model AR(1). Nilai *Mean Absolute Percentage Error* (MAPE) adalah 0,0730101 atau 7,301 % rata-rata kesalahan terhadap prediksi harga emas periode 2000 - 2019 dengan menggunakan AR(1).

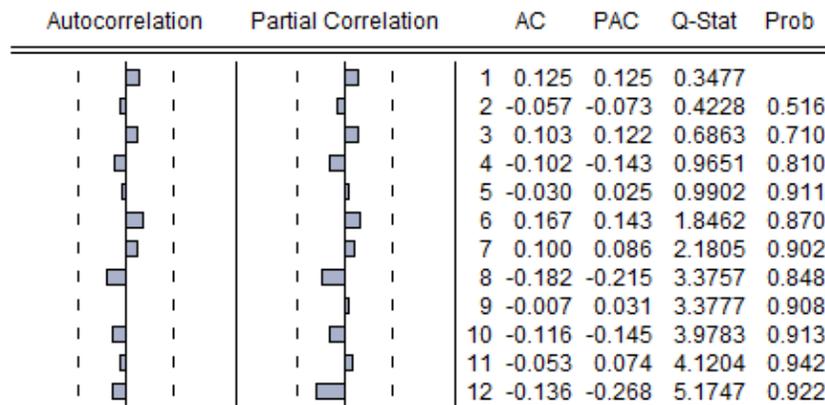


Gambar 4.2. Perbandingan Harga Emas (Sebenarnya), dan Prediksi

4.4 Uji Diagnostik Model ARIMA

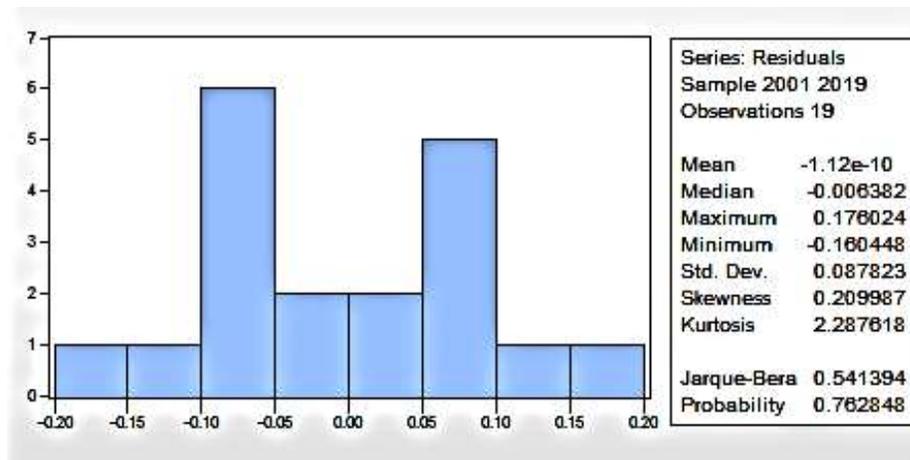
Uji diagnostik eror model terdiri dari autokorelasi, uji normalitas, dan heteroskedastisitas. Autokorelasi dapat dilihat dari grafik ACF dan PACF eror model

ARIMA, seperti pada Gambar 4.3. Semua nilai berada dalam garis Barlett. Hal ini menuntukan tidak terdapat autokorelasi pada error model AR(1).



Gambar 4.3. Uji Autokorelasi Error Model ARIMA

Berdasarkan Gambar 4.3, diperoleh hasil uji normalitas error model. Gambar 4.4 menunjukkan uji normalitas error model AR(1) signifikan prob 0,000 lebih kecil dari $\alpha = 0,05$ artinya error normal.



Gambar 4.4. Uji Normalitas Error Model ARIMA

Suatu keadaan dikatakan heteroskedastisitas, jika suatu data memiliki variansi error yang tidak konstan untuk setiap pengamatan. Data yang bersifat heteroskedastisitas cenderung merupakan data yang nilainya berfluktuasi dengan cepat. Volatilitas digunakan untuk menggambarkan fluktuasi dari suatu data. Volatilitas dapat didefinisikan sebagai variansi data terhadap waktu. Volatilitas dapat

digambarkan dengan adanya kecenderungan suatu data berfluktuasi secara cepat dari waktu ke waktu sehingga variansi eror berubah setiap waktu atau tidak konstan. Hal ini dapat diketahui melalui uji White seperti pada Tabel 4.3.

Tabel 4.3. Uji Heteroskedastisitas White

	AR(1)
Prob F(2,16)	0,1643
Probabilitas χ^2	0,1466

Berdasarkan Tabel 4.3 nilai probabilitas kedua data, kurang dari $\alpha = 0,05$. nilai probabilitas kedua data, lebih dari $\alpha = 0,05$. sehingga H_0 gagal ditolak yang artinya tidak terdapat heteroskedastisitas.

BAB V. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Adapun kesimpulan yang diperoleh dari penelitian yang telah dilakukan adalah sebagai berikut

1. Data harga emas untuk data 2000 – 2019 mengikuti pola data stasioner. Berdasarkan pola ACF dan PACF pada korelogram, menunjukkan data dapat dimodelkan dengan model ARIMA, terputus setelah lag pertama.
2. Data harga emas periode 2000 - 2019, mengikuti pola data stasioner, memiliki pola grafik ACF yang turun secara eksponensial dan grafik PACF yang terputus setelah lag pertama, artinya dapat dimodel menggunakan AR(1). Uji diagnostik eror model untuk data harga emas periode 2000 - 2019, terpenuhi bebas autokorelasi dan normal sebaran eror model. Tetapi asumsi homokedastisitas terpenuhi.
3. Model terbaik untuk data harga emas tahun 2000 – 2019 adalah AR(1) memiliki nilai MAPE 0,0730101 atau 7,30101 % kesalahan prediksi data dengan model tersebut.

5.2. Saran

Berdasarkan perbandingan kesimpulan data testing dan data training, maka terlihat analisa runtun waktu sulit untuk dimodelkan karena fluktuasi data dipengaruhi oleh banyak faktor sesuai dengan karakteristik data masing-masing. Oleh karena itu pada penulisan selanjutnya, hal yang dapat dikembangkan dengan model lain seperti TGARCH, MGARCH, dan APARCH. Model tersebut merupakan model yang sesuai untuk data runtun waktu yang bersifat asimetris.

DAFTAR PUSTAKA

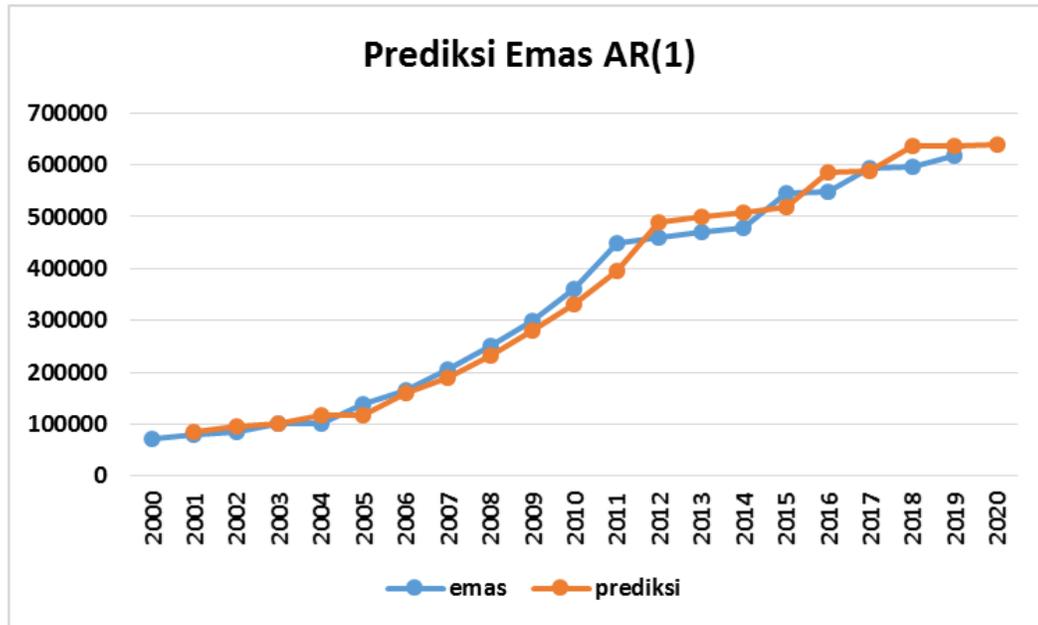
- Anandhita, T. (2015). Analisis Pengaruh Back Water terhadap Banjir Sungai Rangkui Kota Pangkal Pinang. *Jurnal Fropil*. Vol 3 No 2. 375-389.
- Asdak, C. (2010). *Hidrologi dan Pengelolaan Daerah Aliran Sungai*. Yogyakarta: Gadjah Mada University Press.
- Bekti, A. (2011). *Model Jaringan Saraf Tiruan RBF-EGARCH untuk Peramalan Data Time Series*. Surabaya: Pascasarjana Matematika Institut Teknologi Sepuluh Nopember.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroscedasticity. *Journal of Econometrics* Vol 31, 307-327.
- Fathona .(2014). Analisis Distribusi Kecepatan Aliran Sungai Musi. *Jurnal Teknik Sipil dan Lingkungan*. Vol 2 No 3, 543-552.
- Floros, C. (2005). Forecasting The UK Unemployment Rate: Model Comparisons. *International Journal of Applied Econometrics and Quantitative Studies* Vol 2, 57-72.
- Lai, B. (2012). Pricing to Market using EGARCH-ECM. *International Journal of Strategic Decision Sciences* Vol 3, 1-59.
- Mahmuda, A. F. (2012). *Analisis Kuantitas dan Kualitas Air Sungai Pampang Kotamadya Makasar*. Makasar: Universitas Hassanudin.
- Ruminta. (2008). Model Temporal Curah Hujan dan Debit Sungai Citarum Berbasis ANFIS. *Jurnal Sains Dirgantara* Vol 6 No 1, 22-38.
- Setiawan, A. (2013). *Aplikasi Peramalan Penjualan Kosmetik dengan ARIMA*. Surabaya: Universitas Kristen Petra.
- Setiawan, A. (2016). Prediksi Tinggi Muka Air menggunakan Support Vector Machine berbasis Particle Swarm Optimization. *Jurnal Technologia*. Vol 7 No 2. 69-74.

Tsay, S. R. (2002). *Analysis of Financial Time Series*. Canada: John Wiley & Sons Inc.

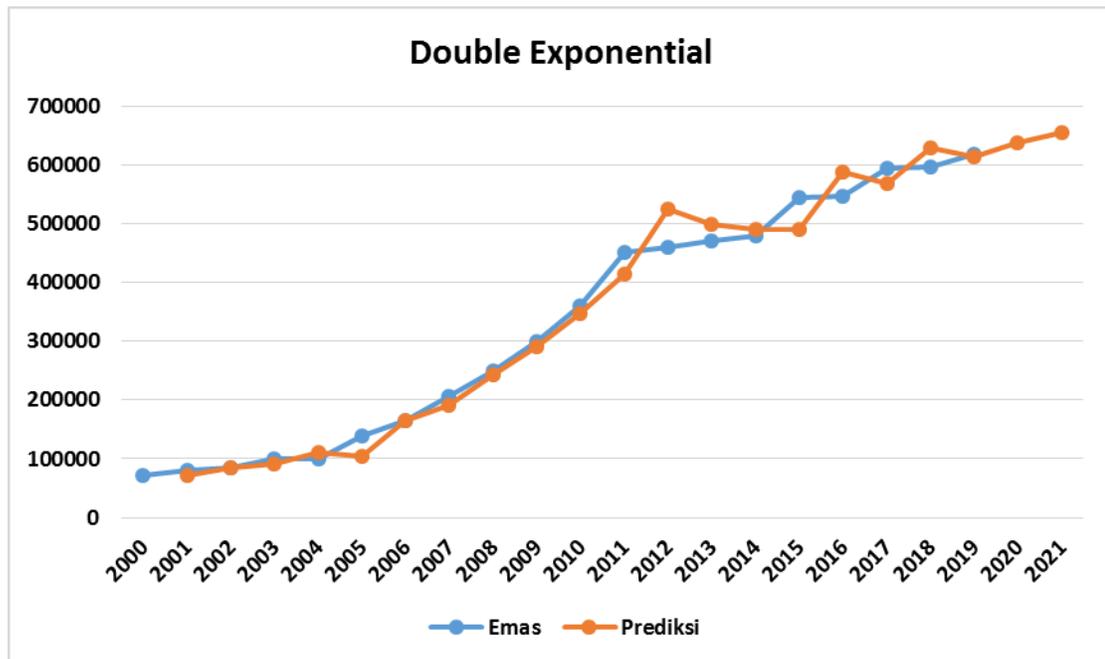
Lampiran 1. Hasil Pengolahan E-Views

Period	Emas	Transformasi
2000	71875	11.1826838
2001	80000	11.2897819
2002	85000	11.3504065
2003	100000	11.5129255
2004	100000	11.5129255
2005	140000	11.8493977
2006	165000	12.0137008
2007	206667	12.2388641
2008	250000	12.4292162
2009	300000	12.6115378
2010	360000	12.7938593
2011	450000	13.0170029
2012	460000	13.0389818
2013	470000	13.060488
2014	478402	13.0782067
2015	545000	13.2085411
2016	547000	13.2122041
2017	593790	13.294281
2018	595810	13.2976771
2019	618000	13.3342437
2020		

Periode	Emas	Prediksi
2000	71875	
2001	80000	85845.1182
2002	85000	95015.9451
2003	100000	100639.49
2004	100000	117406.788
2005	140000	117406.788
2006	165000	161506.392
2007	206667	188735.152
2008	250000	233654.779
2009	300000	279847.475
2010	360000	332667.909
2011	450000	395418.509
2012	460000	488551.417
2013	470000	498869.591
2014	478402	509151.045
2015	545000	517777.038
2016	547000	585838.832
2017	593790	587892.86
2018	595810	635457.188
2019	618000	637493.908
2020		639793.022



Period	Emas	Prediksi	At	A't	at	bt	Error
2000	71875		71875	71875	71875	0	
2001	80000	71875	78293.75	76945.81	79641.69	5070.813	8125
2002	85000	84712.5	83591.69	82196.05	84987.32	5250.241	287.5
2003	100000	90237.56	96554.25	93539.03	99569.48	11342.98	9762.437
2004	100000	110912.5	99276.39	98071.55	100481.2	4532.515	10912.46
2005	140000	105013.8	131448	124439	138457.1	26367.43	34986.25
2006	165000	164824.5	157954.1	150915.9	164992.3	26476.94	175.4623
2007	206667	191469.2	196437.3	186877.8	205996.8	35961.88	15197.8
2008	250000	241958.7	238751.8	227858.3	249645.4	40980.48	8041.338
2009	300000	290625.9	287137.9	274689.2	299586.6	46830.88	9374.139
2010	360000	346417.5	344699	329996.9	359401	55307.73	13582.52
2011	450000	414708.7	427886.8	407329.9	448443.7	77333.01	35291.26
2012	460000	525776.7	453256.2	443611.7	462900.8	36281.79	65776.66
2013	470000	499182.5	466483.8	461680.7	471287	18068.97	29182.54
2014	478402	489355.9	475899.2	472913.3	478885.1	11232.63	10953.92
2015	545000	490117.7	530488.8	518398	542579.7	45484.67	54882.31
2016	547000	588064.4	543532.7	538254.4	548810.9	19856.4	41064.36
2017	593790	568667.3	583236	573789.8	592682.1	35535.45	25122.66
2018	595810	628217.5	593169.5	589099.7	597239.2	15309.91	32407.55
2019	618000	612549.1	612785.6	607811.6	617759.6	18711.83	5450.922
2020		636471.4					
2021		655183.3					



SUMMARY OUTPUT

<i>Regression Statistics</i>	
Multiple R	0.984566
R Square	0.96937
Adjusted R Square	0.967668
Standard Error	36223.54
Observations	20

ANOVA

	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	1	7.47E+11	7.47E+11	569.6617	4.46E-15
Residual	18	2.36E+10	1.31E+09		
Total	19	7.71E+11			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>	<i>Lower 95.0%</i>	<i>Upper 95.0%</i>
Intercept	12325.21	15610.38	0.789552	0.440067	-20471	45121.41	-20471	45121.41
X Variable 1	33526.52	1404.688	23.86759	4.46E-15	30575.38	36477.67	30575.38	36477.67

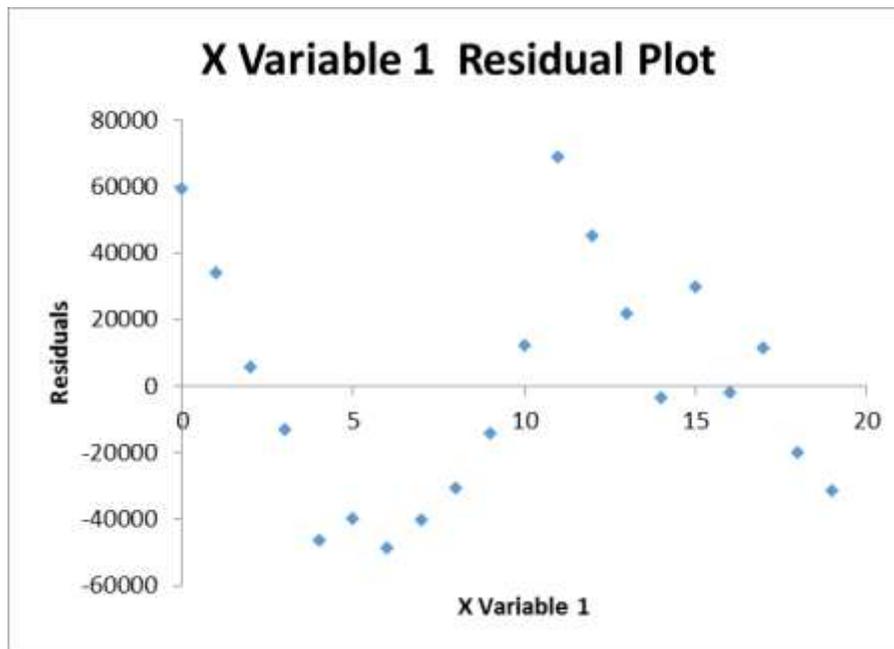
RESIDUAL OUTPUT

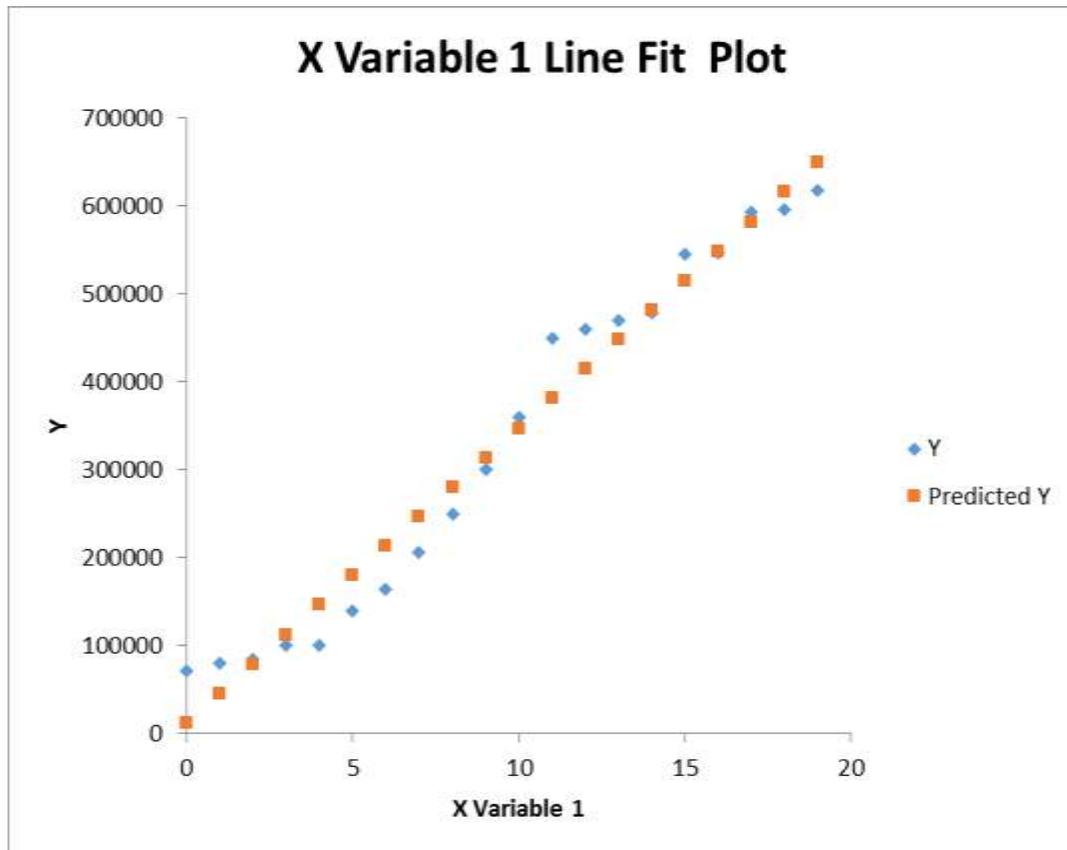
<i>Observation</i>	<i>Predicted Y</i>	<i>Residuals</i>
1	12325.21	59549.79
2	45851.74	34148.26
3	79378.26	5621.736
4	112904.8	-12904.8
5	146431.3	-46431.3
6	179957.8	-39957.8
7	213484.4	-48484.4
8	247010.9	-40343.9
9	280537.4	-30537.4
10	314063.9	-14063.9
11	347590.5	12409.54
12	381117	68883.01
13	414643.5	45356.49
14	448170	21829.96
15	481696.6	-3294.56

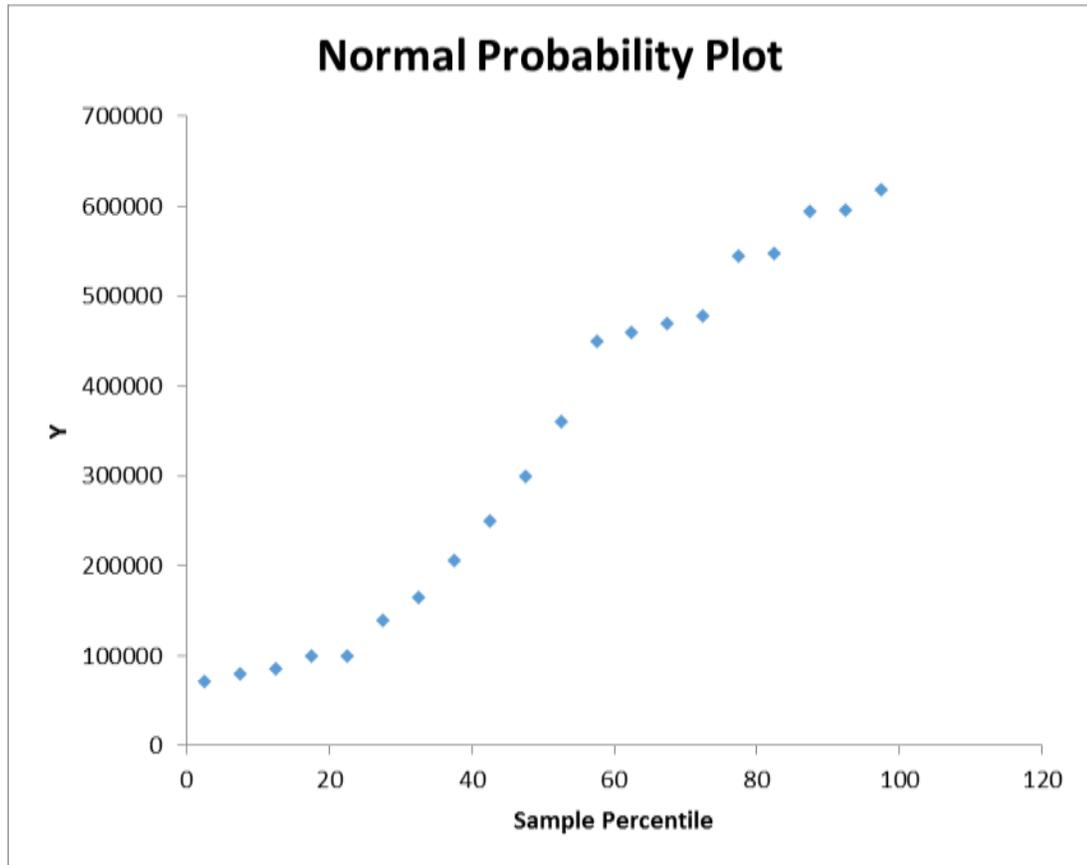
RESIDUAL OUTPUT

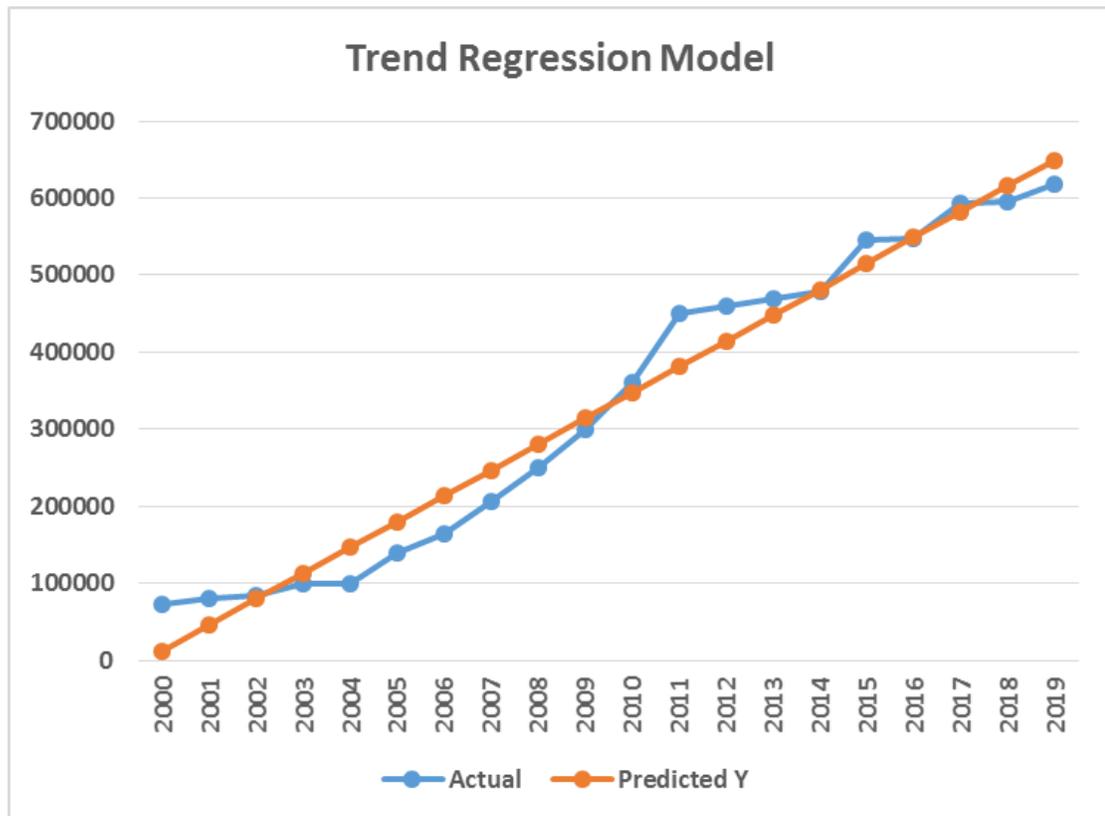
<i>Observation</i>	<i>Predicted Y</i>	<i>Residuals</i>
16	515223.1	29776.91
17	548749.6	-1749.61
18	582276.1	11513.86
19	615802.7	-19992.7
20	649329.2	-31329.2

<i>Period</i>	<i>Actual</i>	<i>Predicted Y</i>
2000	71875	12325.21
2001	80000	45851.74
2002	85000	79378.26
2003	100000	112904.8
2004	100000	146431.3
2005	140000	179957.8
2006	165000	213484.4
2007	206667	247010.9
2008	250000	280537.4
2009	300000	314063.9
2010	360000	347590.5
2011	450000	381117
2012	460000	414643.5
2013	470000	448170
2014	478402	481696.6
2015	545000	515223.1
2016	547000	548749.6
2017	593790	582276.1
2018	595810	615802.7
2019	618000	649329.2
2020	Prediksi	682855.7









Time	True	Exp Smoothing	Forecasting
Period	Value	Forecast	Error
2000	71875	0	71,875
2001	80000	71,803	8,197
2002	85000	79,992	5,008
2003	100000	84,995	15,005
2004	100000	99,985	15
2005	140000	100,000	40,000
2006	165000	139,960	25,040
2007	206667	164,975	41,692
2008	250000	206,625	43,375
2009	300000	249,957	50,043
2010	360000	299,950	60,050
2011	450000	359,940	90,060
2012	460000	449,910	10,090
2013	470000	459,990	10,010
2014	478402	469,990	8,412
2015	545000	478,394	66,606
2016	547000	544,933	2,067
2017	593790	546,998	46,792
2018	595810	593,743	2,067
2019	618000	595,808	22,192
	prediksi	617,978	

MAPE	0.103317182
Smoothing Constant	
α	0.999

Initial Estimate	
Average =	0
Mean Absolute Deviation	
MAD =	30,930
Mean Square Error	
MSE =	1,647,545,228

