

**LAPORAN TAHUN TERAKHIR
PENELITIAN DOSEN MUDA**



**PENERAPAN AUTOREGRESIF ORDE SATU
PADA PREDIKSI HARGA EMAS**

TIM PENELITI

| | |
|----------------------------------------|-------------------|
| Retno Tri Vulandari, S.Si, M.Si | 0613038801 |
| Setiyowati S.Kom., M.Kom. | 0630118401 |
| Sri Harjanto, S.Kom., M.Kom. | 0626016803 |

**SEKOLAH TINGGI MANAJEMEN INFOMATIKA DAN KOMPUTER
(STMIK) SINAR NUSANTARA
SURAKARTA
2020**

**LAPORAN TAHUN TERAKHIR
PENELITIAN DOSEN MUDA**



**PENERAPAN AUTOREGRESIF ORDE SATU
PADA PREDIKSI HARGA EMAS**

TIM PENELITI

| | |
|----------------------------------------|-------------------|
| Retno Tri Vulandari, S.Si, M.Si | 0613038801 |
| Setiyowati S.Kom., M.Kom. | 0630118401 |
| Sri Harjanto, S.Kom., M.Kom. | 0626016803 |

**SEKOLAH TINGGI MANAJEMEN INFOMATIKA DAN KOMPUTER
(STMIK) SINAR NUSANTARA
SURAKARTA
2020**

HALAMAN PENGESAHAN

Judul Penelitian : PENERAPAN AUTOREGRESIF ORDE SATU PADA
PREDIKSI HARGA EMAS

Ketua Peneliti

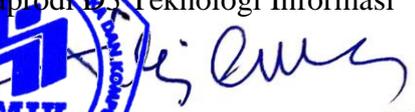
a. Nama Lengkap : Retno Tri Vlandari, S.Si., M.Si.
b. NIDN / NIK : 0613038801 / 110 000 093
c. Jabatan Fungsional : Lektor
d. Program Studi : Teknologi Informasi
e. Nomor HP : 085888120395
f. Surel (e-mail) : retnotv@sinus.ac.id

Anggota Peneliti (1) : Setiyowati, S.Kom., M.Kom. – 0630118401

Anggota Peneliti (2) : Sri Harjanto, S.Kom., M.Kom. – 0626016803

Pelaksanaan : 1 tahun

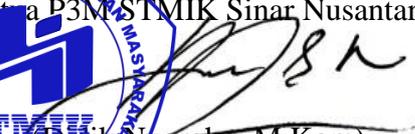
Biaya Penelitian : Rp 7.500.000, 00

Mengetahui
Kaprodik3 Teknologi Informasi

(Dwi Remawati, S.Kom., M.Kom.)
NIP. 0006 0373 0 1

Surakarta, Agustus 2021

Peneliti,

(Retno Tri Vlandari, S.Si., M.Si.)
NIK 110 000 093

Menyetujui,
Ketua P3M STMIK Sinar Nusantara

(Dwik Nugroho, M.Kom.)
NIK 111 000 024

RINGKASAN

Emas merupakan salah satu jenis logam mulia terpercaya yang dapat mempertahankan nilainya dan digunakan dalam transaksi (Baur dan Mc Dermott, 2010). Harga emas tergantung kondisi ekonomi dunia. Bagaimanapun, emas adalah instrumen yang paling stabil dan likuid dalam menentukan modal dan tabungan di masa depan. Menurut Suharto (2013), emas merupakan salah satu instrumen yang paling stabil dan efektif untuk simpanan pokok (investasi). Selain itu, emas sering disebut sebagai ukuran modal dan kekayaan yang tertua dan paling efektif. Oleh karena itu diperlukan suatu model yang dapat digunakan untuk memprediksi harga emas. Data harga emas untuk data tahun 2000 - 2019 mengikuti pola data stasioner. Berdasarkan pola ACF dan PACF pada korelogram menunjukkan bahwa data dapat dimodelkan dengan model ARIMA, terputus setelah lag pertama. Data harga emas periode 2000 - 2019 mengikuti pola data stasioner, memiliki pola grafik ACF yang turun secara eksponensial dan grafik PACF yang pecah setelah lag pertama, artinya dapat dimodelkan menggunakan AR (1). Uji diagnostik kesalahan model untuk data harga emas periode 2000 - 2019 terpenuhi bebas autokorelasi dan distribusi normal kesalahan model. Namun asumsi homoskedastisitas terpenuhi. Model terbaik untuk data harga emas tahun 2000 - 2019 adalah AR (1) yang memiliki nilai MAPE 0,0730101 atau error 7,30101% pada prediksi data dengan model ini.

Kata Kunci: Harga Emas, ARIMA, Otoregresif

PRAKATA



Assalamu'alaikum Wr. Wb

Puji syukur kehadiran Allah SWT yang telah melimpahkan rahmat dan hidayah- Nya sehingga peneliti berhasil menyelesaikan laporan penelitian. Penelitian ini merupakan salah satu tugas lembaga pendidikan tinggi untuk melaksanakan Tri Dharma Perguruan Tinggi. Pada tahun 2016 wilayah Surakarta bagian timur mengalami banjir dikarenakan harga emas melebihi batas normal level 10, maka dalam penelitian ini peneliti mengambil judul “Analisa Harga emas dengan Model ARIMA-GARCH”

Dalam melakukan kegiatan penelitian dan penyusunan laporan penelitian ini tidak lepas dari bantuan berbagai pihak. Pada kesempatan ini perkenankanlah peneliti mengucapkan rasa terima kasih yang sedalam-dalamnya kepada :

1. Ibu Kumaratih Sandradewi, S.P., M.Kom, selaku ketua STMIK Sinar Nusantara Surakarta.
2. Rekan-rekan dan semua pihak yang tidak dapat peneliti sebutkan satu persatu.

Penulis menyadari bahwa penyusunan laporan penelitian ini tentunya banyak kekurangannya, maka segala kritik dan saran sangat diharapkan. Semoga laporan ini bermanfaat bagi para pembaca pada umumnya, mahasiswa dan dosen-dosen STMIK Sinar Nusantara Surakarta pada khususnya.

Wassalamu'alikum Wr. Wb.

Surakarta, Agustus 2021

Tim Peneliti

DAFTAR ISI

| | |
|----------------------------------------|------|
| HALAMAN JUDUL | i |
| HALAMAN PENGESAHAN | ii |
| RINGKASAN | iii |
| PRAKATA | iv |
| DAFTAR ISI | vi |
| DAFTAR TABEL | viii |
| DAFTAR GAMBAR | ix |
| BAB I. PENDAHULUAN | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Batasan Masalah | 2 |
| 1.3 Perumusan Masalah | 2 |
| 1.4 Tujuan Penelitian | 2 |
| BAB II. TINJAUAN PUSTAKA | 3 |
| 2.1 Harga Emas | 3 |
| 2.2 Uji Stasioneritas | 3 |
| 2.3 Fungsi ACF dan PACF | 4 |
| 2.4 Sifat Model Stasioner | 4 |
| 2.5 Estimasi Parameter Model Stasioner | 7 |
| 2.6 Model Diagnostik | |
| 2.7 Uji Keasimetrisan | 16 |
| 2.8 Model ARCH dan model GARCH | 16 |
| 2.9 Penelitian yang Relevan | 17 |
| BAB III. TUJUAN DAN MANFAAT | 19 |
| 3.1 Tujuan Penelitian | 19 |
| 3.2 Manfaat Penelitian | 19 |
| BAB IV. METODE PENELITIAN | 20 |
| 4.1 Prosedur Pengolahan Data | 20 |
| 4.2 Analisa Data | 20 |
| 4.3 Kerangka Pikir | 22 |
| BAB V. HASIL DAN LUARAN YANG DICAPAI | 24 |

| | |
|---------------------------------------------------------------------|----|
| 5.1 Hasil Penelitian | 24 |
| 5.2 Luaran Penelitian | 32 |
| BAB VI KESIMPULAN DAN SARAN | 34 |
| DAFTAR PUSTAKA | |
| Lampiran 1 <i>Draft</i> Artikel Ilmiah dan Bukti Submit IJAS | |

DAFTAR TABEL

| | |
|------------------------------------------|----|
| Tabel 2.1 Penelitian Terdahulu | 17 |
| Tabel 5.1 Uji Stasioner | 26 |
| Tabel 5.2 Estimasi Parameter Model ARIMA | 27 |
| Tabel 5.3 Uji Heteroskedastisitas White | 29 |

DAFTAR GAMBAR

| | |
|------------------------------------------------------------------|----|
| Gambar 2.1 Grafik ACF Model AR | 5 |
| Gambar 4.1 Kerangka Pikir Penelitian | 23 |
| Gambar 5.1 Perbandingan Harga Emas tahun 2000 - 2019 | 24 |
| Gambar 5.2 ACF dan PACF HARGA EMAS 2000 - 2019 | 26 |
| Gambar 5.3 Perbandingan Residual, Actual, dan Fitted Model ARIMA | 27 |
| Gambar 5.4 Uji Autokorelasi Error Model ARIMA | 28 |
| Gambar 5.5 Uji Normalitas Error Model ARIMA | 28 |

BAB I PENDAHULUAN

1.1 Latar Belakang

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 harga emas, 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 Batasan Masalah

Penelitian ini menggunakan data rata-rata harga emas tahun 2000 - 2019. Metode yang digunakan adalah analisa runtun waktu Box Jenkin Autoregresif Orde Satu.

1.3 Rumusan Masalah

Penelitian ini menfokuskan pada permasalahan :

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

Adapun tujuan 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.

BAB II

TINJAUAN PUSTAKA

2.1 Harga Emas

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, proxy 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.

2.2 Uji Stasioneritas

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

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

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

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

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

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

2.3 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.

2.4 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

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

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

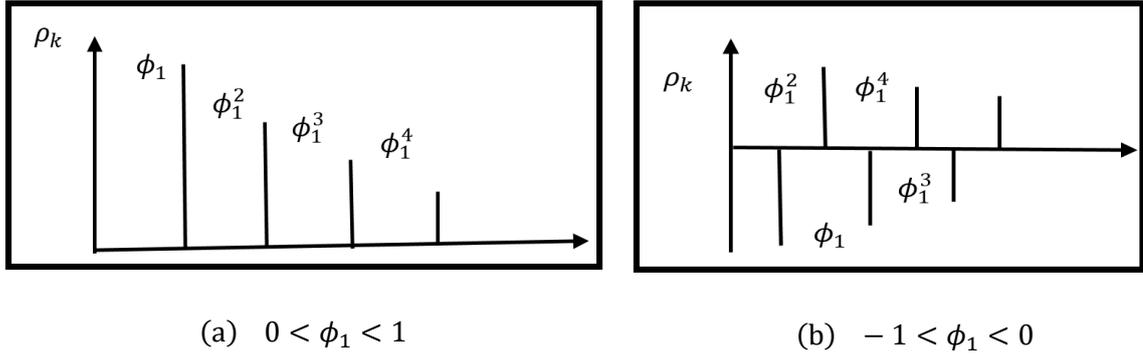
$$Cov(Y_t Y_{t-1}) = \frac{\phi_1 \sigma_e^2 (1 - \phi_1^{2t})}{(1 - \phi_1^2)}$$

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

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

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

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



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 $e_t \sim WN(\mu_e, \sigma_e^2)$. Autokovariansi model AR(p) diperoleh sebagai berikut

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

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

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

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

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

2.5 Estimasi Parameter Model Stasioner

2.5.1 Estimasi Parameter Model Autoregressive (AR)

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

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

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

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.

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

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

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

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.

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

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

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

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

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

misal

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

maka Persamaan (2.6) dapat ditulis menjadi

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

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

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

2.6 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.

2.6.1 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.

2.6.2 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 $obs. R^2 > \chi_{k,\alpha}^2$

2.7 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 algoritharga emas akan implementasikan dengan menggunakan RapidMiner 5.1. Pengukuran kinerja dilakukan dengan menghitung rata-rata error yang terjadi melalui besaran Root Mean Square Error |

| No | Peneliti (Tahun) | Hasil Penelitian |
|----|------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | | (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

TUJUAN DAN MANFAAT

3.1 Tujuan Penelitian

Penelitian ini memiliki tujuan sebagai berikut

1. Penentuan alur pemodelan *Autoregressive Integrated Moving Average* (ARIMA) data harga emas.
2. Penentuan alur pemodelan *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) data harga emas.
3. Perbandingan model terbaik ARIMA-GARCH data harga emas.

3.2 Manfaat Penelitian

Penelitian ini diharapkan dapat bermanfaat sebagai berikut

1. Pihak Masyarakat

Hasil perbandingan model dapat digunakan sebagai acuan prediksi harga emas. Hasil penelitian dapat digunakan sebagai tambahan referensi penelitian harga emas.

2. Pihak STMIK Sinar Nusantara

Hasil penelitian dapat digunakan sebagai tambahan referensi penelitian dosen pemula dan menambah pengetahuan pemodelan data runtun waktu ARIMA-GARCH.

BAB IV METODE PENELITIAN

4.1 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.

4.2 Analisa Data

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

4.2.1 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 $t > t_{\alpha, (T-1)}$

4.2.2 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.

4.2.3 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 Becti (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).

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

4.2.4 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

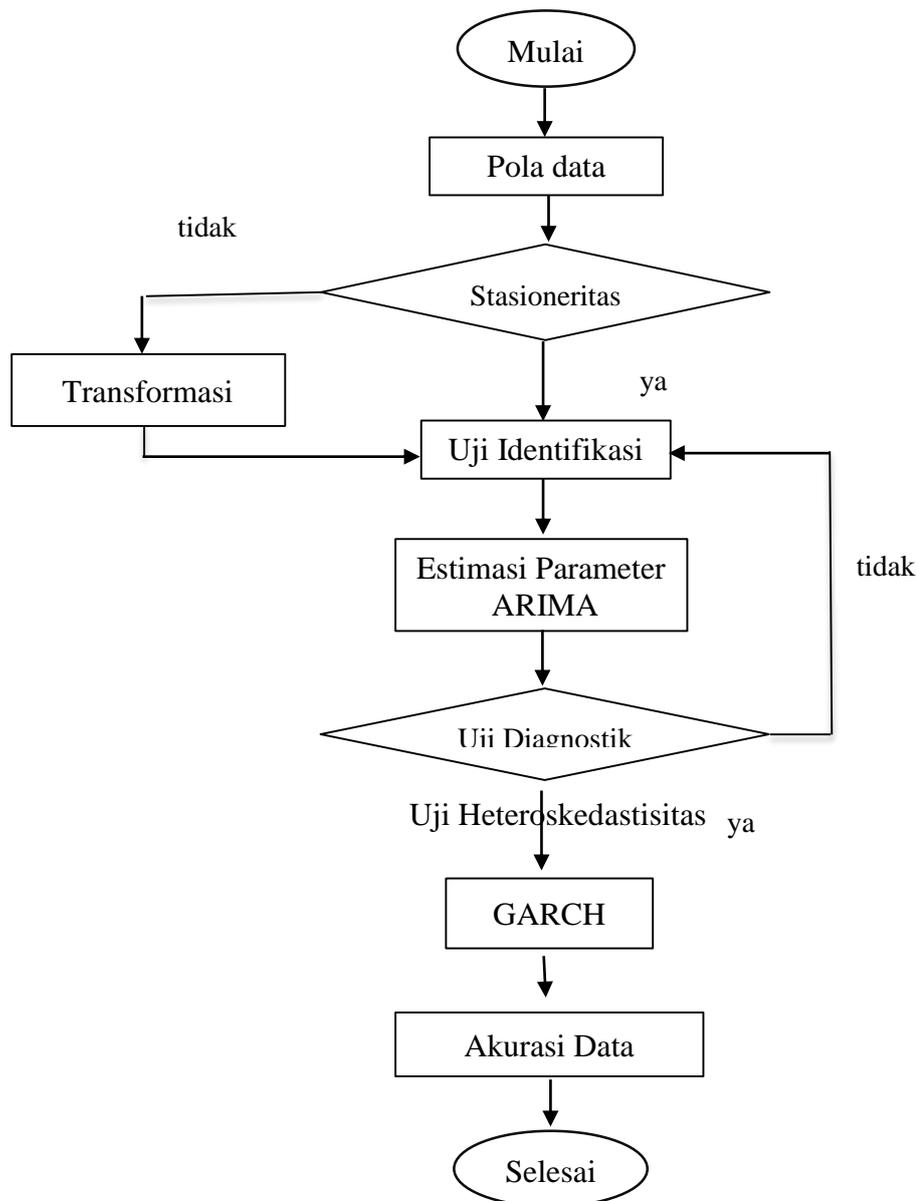
MSE yang kecil. Oleh karena itu, dilakukan uji autokorelasi error, uji homogenitas variansi dan penghitungan nilai MSE. Apabila error tidak memenuhi tiga hal tersebut, maka model yang diperoleh kurang cocok dengan data, sehingga perlu dilakukan identifikasi dan estimasi lagi.

4.3 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 error yang dihasilkan oleh model tersebut. Error 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 4.1 Kerangka Pikir Penelitian

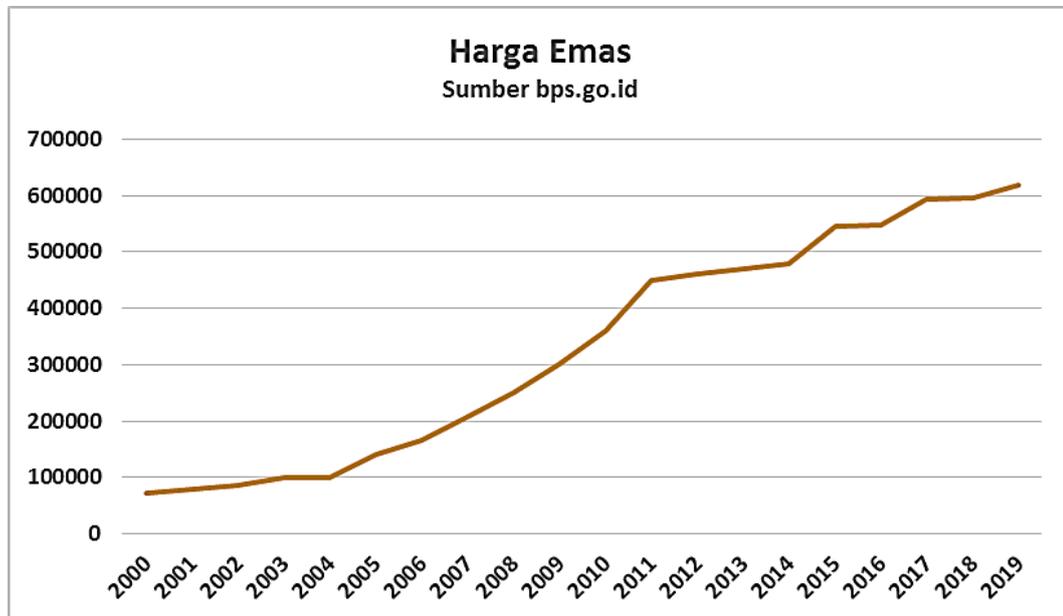
BAB V HASIL DAN LUARAN YANG DICAPAI

5.1 Hasil Penelitian

Pada penelitian ini digunakan data harga emas tahunan mulai 2000 sampai dengan 2019. Berikut adalah hasil penelitian untuk data harga emas 2000 - 2019.

5.1.1. Deskripsi dan Pola Data

Berdasarkan metode penelitian yang telah dirancang, maka langkah pertama yang dilakukan adalah deskripsi data. Gambar 5.1, menunjukkan harga emas berpola trend naik.



Gambar 5.1. Perbandingan Harga emas dari tahun 2000 - 2019

Tabel 5.1. Uji Stasioner

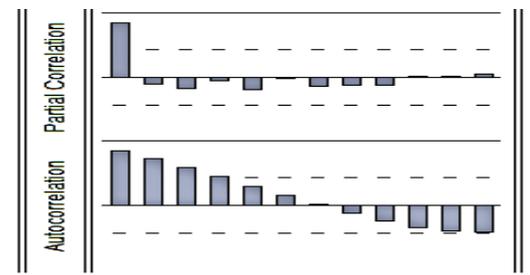
| Null Hypothesis: HARGA EMAS | t-Statistic | Prob.* |
|----------------------------------------|-------------|--------|
| Augmented Dickey-Fuller test statistic | 0,094685 | 0,9565 |

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

5.1.2. 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 5.2. Nilai PACF terputus setelah lag pertama dan ACF turun secara eksponensial maka model rata-rata bersyarat yang digunakan adalah AR (1).



Gambar 5.2 ACF dan PACF

5.1.3. 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 5.2.

Tabel 5.2. Estimasi Parameter Model ARIMA

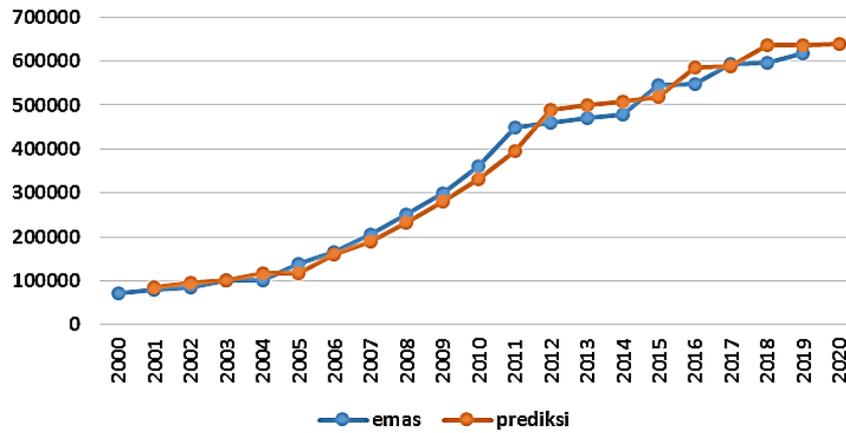
| Variabel | AR(1) | |
|----------|-----------|--------|
| | Koefisien | Prob |
| C | 14,59809 | 0,0000 |
| AR(1) | 0,947994 | 0,0000 |
| MAPE | 0,0730101 | |
| MSE | 0,128073 | |

Berdasarkan Tabel 5.2, 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 5.2, 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 5.2. Perbandingan Harga Emas (Sebenarnya), dan Prediksi

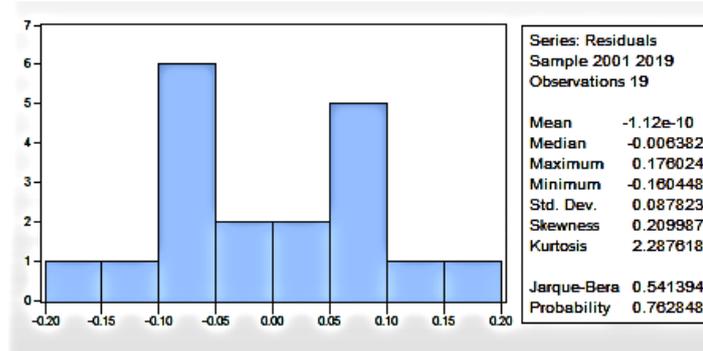
5.1.4. Uji Diagnostik Model ARIMA

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 5.3. Semua nilai berada dalam garis Barlett. Hal ini menuntukan tidak terdapat autokorelasi pada eror model AR(1).

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
|-----------------|---------------------|----|--------|--------|--------|-------|
| | | 1 | 0.125 | 0.125 | 0.3477 | |
| | | 2 | -0.057 | -0.073 | 0.4228 | 0.516 |
| | | 3 | 0.103 | 0.122 | 0.6863 | 0.710 |
| | | 4 | -0.102 | -0.143 | 0.9651 | 0.810 |
| | | 5 | -0.030 | 0.025 | 0.9902 | 0.911 |
| | | 6 | 0.167 | 0.143 | 1.8462 | 0.870 |
| | | 7 | 0.100 | 0.086 | 2.1805 | 0.902 |
| | | 8 | -0.182 | -0.215 | 3.3757 | 0.848 |
| | | 9 | -0.007 | 0.031 | 3.3777 | 0.908 |
| | | 10 | -0.116 | -0.145 | 3.9783 | 0.913 |
| | | 11 | -0.053 | 0.074 | 4.1204 | 0.942 |
| | | 12 | -0.136 | -0.268 | 5.1747 | 0.922 |

Gambar 5.3. Uji Autokorelasi Eror Model ARIMA

Berdasarkan Gambar 5.3, diperoleh hasil uji normalitas eror model. Gambar 5.4 menunjukkan uji normalitas eror model AR(1) signifikan prob 0,000 lebih kecil dari $\alpha = 0,05$ artinya eror normal.



Gambar 5.4. Uji Normalitas Error Model ARIMA

Suatu keadaan dikatakan heteroskedastisitas, jika suatu data memiliki variansi eror 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 5.3.

Tabel 5.3. Uji Heteroskedastisitas White

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

Berdasarkan Tabel 5.3 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.

5.2 Luaran Penelitian

Luaran penelitian ini adalah model terbaik untuk menentukan harga emas periode 2000 - 2019, sehingga hal ini dapat dijadikan sebagai bahan pertimbangan untuk pengambilan keputusan. Selain itu, luaran berupa draft artikel ilmiah dan bukti submit, Indonesian Journal of Applied Statistics.

BAB VI

KESIMPULAN DAN SARAN

6.1 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.

6.2 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.

[Home](#) / [User](#) / [Author](#) / [Submissions](#) / #176 / [Summary](#)

#176 Summary

Summary | [Review](#) | [Editing](#)

Submission

Authors Retno Tri Vulandari, Setiyowati Setiyowati, Sri Harjanto
Title Application of Autoregressive Method on Prediction of Gold Price
Original file 176-526-1-SM.docx 2020-08-21
Supp. files None [Add a Supplementary File](#)

Submitter Mrs Retno Tri Vulandari 
Date submitted August 21, 2020 - 02:34 PM
Section Articles
Editor None assigned

Status

Status Awaiting assignment
Initiated 2020-08-21
Last modified 2020-08-21

Submission Metadata

[Edit Metadata](#)

Authors

Name Retno Tri Vulandari 
Affiliation STMIK Sinar Nusantara
Country Indonesia
Bio Statement —
Principal contact for editorial correspondence.

Name Setiyowati Setiyowati 
Affiliation STMIK Sinar Nusantara Surakarta
Country Indonesia

Name Sri Harjanto 
Affiliation STMIK Sinar Nusantara Surakarta
Country Indonesia
Bio Statement —

Title and Abstract

MENU-MENU

[Editorial Board](#)
[Peer Reviewers](#)
[Focus & Scope](#)
[Author Guidelines](#)
[Publication Ethics](#)
[Open Access Policy](#)
[Peer Review Process](#)
[Online Submission](#)
[Article Processing Cost](#)
[Abstracting & Indexing](#)
[Contact](#)

ISSN BARCODE



9 772621 848002

E-ISSN: 2621-8488

SPONSORED MEMBER



User

You are logged in as...

retnotv

[My Profile](#)

[Log Out](#)

[Activate Windows](#)

[Go to Settings to activate Windows.](#)

ARTICLE TEMPLATE



TOOLS



Title Application of Autoregressive Method on Prediction of Gold Price

Abstract Gold is a type of trusted precious metal that can maintain its value and is used in transactions (Baur and Mc Dermott, 2010). The price of gold depends on world economic conditions. However, gold is the most stable and liquid instrument in the fixation of future capital and savings. According to Suharto (2013), gold is one of the most stable and effective instruments for principal savings (investment). In addition, gold is often referred to as the oldest and most effective measure of capital and wealth. Therefore we need a model that can be used to predict the price of gold. Gold price data for 2000 - 2019 data follows a stationary data pattern. Based on the ACF and PACF patterns on the corelogram, it shows that the data can be modeled with the ARIMA model, disconnected after the first lag. Gold price data for the period 2000 - 2019, following a stationary data pattern, has an ACF chart pattern that drops exponentially and a PACF chart that breaks after the first lag, meaning that it can be modeled using AR (1). The model error diagnostic test for gold price data for the period 2000 - 2019, is fulfilled free of autocorrelation and the normal distribution of model errors. But the homoscedasticity assumption is fulfilled. The best model for gold price data for 2000 - 2019 is AR (1) which has a MAPE value of 0.0730101 or 7.30101% error in prediction of data with this model.

Indexing

Academic discipline and sub-disciplines —

Keywords Gold Price, ARIMA, Autoregressive

Type, method or approach —

Language en

Supporting Agencies

Agencies —

References

References

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.

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.



VISITOR STATISTICS

Visitors

| | |
|-----------|-------|
| ID 14,267 | PL 83 |
| US 2,863 | IT 82 |
| IN 1,124 | SG 74 |
| PK 601 | RU 72 |
| NG 558 | NL 69 |
| TR 553 | HK 67 |
| PH 483 | ET 63 |
| MY 289 | SA 59 |
| CA 265 | ZW 58 |
| AU 212 | FR 54 |
| GR 201 | GH 51 |
| GB 198 | ES 47 |
| BR 182 | VN 46 |
| IR 137 | IL 45 |
| TH 134 | TW 43 |

| | |
|--------|-------|
| ZA 116 | FI 39 |
| IQ 115 | PT 37 |
| DZ 97 | KR 37 |
| DE 88 | RO 37 |

Pageviews: 72,111

FLAG counter

00079395

View IJTMER Stats

Notifications

View (18 new) Manage

Author

Submissions

Active (2)

Archive (1)

New Submission

Journal Content

Search

Search Scope

All

Search

Activate Windows

Go to Settings to activate Windows.

All

Search

Browse

By Issue

By Author

By Title

Information

For Readers

For Authors

For Librarians

Policies

[Focus and Scope](#)
[Section Policies](#)
[Peer Review Process](#)
[Publication Frequency](#)
[Open Access Policy](#)
[Archiving](#)

Submissions

[Online Submissions](#)
[Author Guidelines](#)
[Copyright Notice](#)
[Privacy Statement](#)

Other

[Journal Sponsorship](#)
[Site Map](#)
[About this Publishing System](#)

Share

[Tweet](#)

[Share 0](#)



International Journal of Trends in Mathematics
Education Research (IJTMER)

E-ISSN 2621-8488 | DOI Prefix 10.33122/ijtmer

Publisher : IIES Independent

Website : <http://www.ijtmer.com>

E-mail : ijtmer@gmail.com or cc to mursalin@unimal.ac.id

ISSN Online : 2621-8488



IJTMER is licensed under a Creative Commons
Attribution-ShareAlike 4.0 International License.

Activate Windows
Go to Settings to activate Windows.

Application of Autoregressive Method on Prediction of Gold Price

Retno Tri Vulandari¹, Setiyowati², Sri Harjanto³

¹Information Technology, STMIK Sinar Nusantara, Surakarta, Indonesia, 57142

²Information System, STMIK Sinar Nusantara, Surakarta, Indonesia, 57142

³Accounting Information System, STMIK Sinar Nusantara, Surakarta, Indonesia, 57142

*Corresponding Author : retnotv@sinus.ac.id

How to Cite: Hasbi, M., Lukito, A., & Sulaiman, R. (2020). The Realistic of Mathematic Educational Approach to Enhancing Ability Mathematical Connections. *International Journal of Trends in Mathematics Education Research*, 2(4), 179-183. doi: [10.33122/ijtmer.v2i4.82](https://doi.org/10.33122/ijtmer.v2i4.82)

ARTICLE HISTORY

Received: x Month 2020

Revised: x Month 2020

Accepted: x Month 2020

KEYWORDS

Gold Price

ARIMA

Autoregressive

ABSTRACT

Gold is a type of trusted precious metal that can maintain its value and is used in transactions (Baur and Mc Dermott, 2010). The price of gold depends on world economic conditions. However, gold is the most stable and liquid instrument in the fixation of future capital and savings. According to Suharto (2013), gold is one of the most stable and effective instruments for principal savings (investment). In addition, gold is often referred to as the oldest and most effective measure of capital and wealth. Therefore we need a model that can be used to predict the price of gold. Gold price data for 2000 - 2019 data follows a stationary data pattern. Based on the ACF and PACF patterns on the corelogram, it shows that the data can be modeled with the ARIMA model, disconnected after the first lag. Gold price data for the period 2000 - 2019, following a stationary data pattern, has an ACF chart pattern that drops exponentially and a PACF chart that breaks after the first lag, meaning that it can be modeled using AR (1). The model error diagnostic test for gold price data for the period 2000 - 2019, is fulfilled free of autocorrelation and the normal distribution of model errors. But the homoscedasticity assumption is fulfilled. The best model for gold price data for 2000 - 2019 is AR (1) which has a MAPE value of 0.0730101 or 7.30101% error in prediction of data with this model.

This is an open access article under the CC-BY-SA license.



1. INTRODUCTION.

Economic growth in Indonesia in the last 5 years has always decreased. Even though in 2015 it increased until the third quarter, economic growth was still slower than in previous years. From the release of the latest data from the Central Statistics Agency (BPS), Indonesia's economic growth in the third quarter of 2015 was 4.73 percent, an increase compared to the second quarter of 2015 which grew 4.67 percent. This 0.06 percent increase indicates a positive outlook for the Indonesian economy going forward. However, the growth in the third quarter of 2015 slowed down compared to the previous year's achievement, namely in the third quarter of 2014 which grew 4.92 percent.

Gold is a type of trusted precious metal that can maintain its value and is used in transactions (Baur and Mc Dermott, 2010). The price of gold depends on world economic conditions. However, gold is the most stable and liquid instrument in the fixation of future capital and savings. According to Suharto (2013), gold is one of the most stable and effective instruments for principal savings (investment). In addition, gold is often referred to as the oldest and most effective measure of capital and wealth. Therefore we need a model that can be used to predict the water level, so that early warning of flood hazards can be carried out. The price of gold is time series data which is measured every day.

According to Bollerslev (1986), time series data can be compiled

with a stationary model, such as the Autoregressive Integrated Moving Average (ARIMA). This model can be identified by the Autocorrelation Function (ACF) and Partial Autocorrelation Function (PACF). The ARIMA model assumes homoscedasticity or fixed error variance. However, if the time series data for water level has an error variance varies from time to time or heteroscedasticity occurs.

There are several models that can be used to overcome the problem of heteroscedasticity, such as in Engle's (1982) research on estimating inflation variance in England, Engle introduced the Autoregressive Conditional Heteroscedasticity (ARCH) model. In Bollerslev's (1986) study introduced Generalized Autoregressive Conditional Heteroscedasticity (GARCH) (Setiawan, 2013).

2. RESEARCH METHOD

4.1 Data Processing Procedures

In this study the data processing procedures used include:

1. Data Collection, The data needed in this study are time series data and measurement results, namely gold price data for 2000 - 2019
2. Input Data Processing, Prior to analysis using the ARIMA method, data identification was carried out with the original data plot to determine the distribution pattern of the data, then performed a stationarity test because the ARIMA model could only be used by stationary data.

4.2 Data Analysis

The process of forming the ARIMA stationary model consisting of stationary tests, the identity of the ACF and PACF models, estimating parameters of the ARIMA model, and diagnostic tests.

a. Stationarity Test

The stationarity of the data can be determined using the unit root test. The hypothesis in the test in Tsay (2002) is written as $H_0: \eta = 1$ (data has a unit root)

$H_1: \eta < 1$ (data does not have a unit root).

The test statistic is the ratio of the estimated coefficient minus 1 compared to the standard deviation. Augmented Dickey-Fuller (ADF) or the ratio t is defined as

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

where $\eta = 0$, T is the sample size and is the t -th observation data.

H_0 is rejected when the ratio $t > t_{\alpha, (T - 1)}$

b. Identification of the ACF and PACF Models

According to Bollerslev (1986), the tools for identifying ARMA models are ACF and PACF. The autocorrelation function is a function that shows the magnitude of the correlation between observations at time t and observations at previous times, while PACF is a function that shows the magnitude of the partial correlation between observations at time t and observations at previous times.

c. Estimation of Stationary Model Parameters

Floros (2005) explains that ARMA is a form of linear time series model that seeks to identify equations using only past values or a combination of past values and past errors. The ARMA model contains two components, namely the AR and MA models with the order of AR is p and the order of MA is q . Here is a stationary model according to Bektı (2011)

1. Autoregressive (AR)

Autoregressive (AR) is an observation at time t expressed as a linear function of the previous time p plus a random error e_t . The general form of the p order autoregressive model is

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \alpha_3 Y_{t-3} + \dots + \alpha_p Y_{t-p} + e_t$$

2. Moving Average (MA)

Moving average (MA) is used to explain a phenomenon in which an observation at time t is expressed as a linear combination of a number of random errors. The general form of the q -order moving average model

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

3. Autoregressive Moving Average (ARMA)

Autoregressive Moving Average (ARMA) is a combination of AR and MA, here is a general model of ARMA (p, q).

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

d. Diagnostic Model

Diagnostic model is used to determine whether the model is suitable for use. The fit of the model is seen from the error, the error of the model is said to be good if there is no autocorrelation, the variance is homogeneous and has a small MSE value. Therefore, the autocorrelation error test, the homogeneity of variance test and the MSE value were calculated. If the error does not fulfill these three things, then the model obtained does not match the data, so it is necessary to identify and estimate again.

4.3 Framework

Following are the operational steps to achieve the research objectives.

1. Make a data plot to determine the data distribution pattern
2. Performing the stationarity test using the unit root test, if the data is stationary then direct data can be modeled.
3. If the data is not stationary, the \ln transformation is performed. Then perform the unit root test again.
4. After the data is stationary, the identification of the model is carried out using the ACF and PACF plots. Then give a conclusion from the stationary data model by determining the size of the parameters.
5. After the stationary model is formed then a diagnostic test is performed on the error generated by the model. An error is the difference between the predicted data and the actual data.

These steps can be seen clearly in Figure 4.1.

3. RESULTS AND DISCUSSION

3.1 Description and Pattern of Data

Based on the research method that has been designed, the first step is a description of the data. Figure 1 shows the gold price with an uptrend pattern.

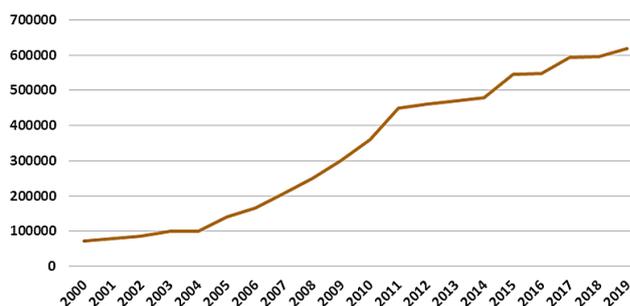


Figure 1. Comparison of gold prices from 2000 - 2019

Table 1. Stationary Test

| Null Hypothesis Harga Emas has a unit root | t-Statistic | Prob* |
|--------------------------------------------|-------------|--------|
| Augmented Dickey-Fuller test statistic | 0,094685 | 0,9565 |

Based on Table 1, gold price data is not stationary on average. This is confirmed using the unit root stationary test. Augmented Dickey-Fuller (ADF) probability value is 0.9565. The probability value is greater than the significance level $\alpha = 0.05$, meaning that it fails to be rejected, which indicates that the data has a unit root, so the data is not stationary. Based on the data pattern and ACF PACF chart, gold data is not stationary to the mean.

3.2 Identification of the ARIMA Average Stationary Model

Modeling the conditional average of stationary data can use ARIMA. To identify the ARIMA model, ACF and PACF are used as shown in Figure 2. The PACF value is interrupted after the first lag and the ACF drops exponentially, the conditional average model used is AR (1).

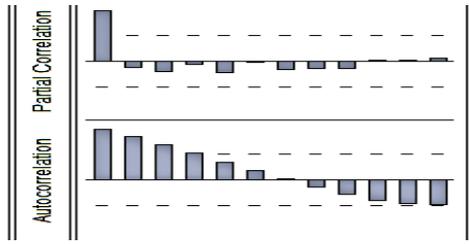


Figure 2. ACF and PACF

Based on the identification of the model, the gold price for the period 2000 - 2019 can be modeled with AR (1). Estimated parameters for the AR model (1) are in Table 2.

Table 2. Estimation of ARIMA Model Parameters

| Variable | AR(1) | |
|----------|-------------|--------|
| | Coefficient | Prob |
| C | 14,59809 | 0,0000 |
| AR(1) | 0,947994 | 0,0000 |
| MAPE | 0,0730101 | |
| MSE | 0,128073 | |

Based on Table 2, the Autoregressive model of the order $p = 1$, AR (1) is obtained for gold price data for 2000 - 2019.

$$Y_t = 0.947994 Y_{t-1} + 14.59809 + e_t$$

Where Y_t is gold price data in period t and Y_{t-1} is gold price data in period $t - 1$. Figure 2, Actual, Residual, and Prediction gold price data patterns using AR Model (1). The Mean Absolute Percentage Error (MAPE) value is 0.0730101 or 7.301% the average error of the gold price prediction for the period 2000 - 2019 using AR (1).

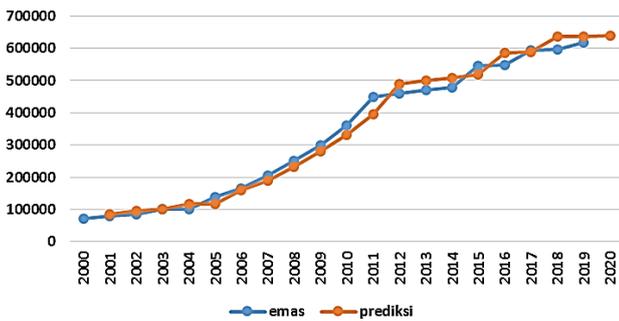


Figure 2. Gold Price Comparison (Actual), and Prediction

3.3 ARIMA Model Diagnostic Test

The model error diagnostic test consists of autocorrelation, normality test, and heteroscedasticity. Autocorrelation can be seen from the ACF and PACF error graphs of the ARIMA model, as in Figure 5.3. All values are within the Bartlett line. This shows that there is no autocorrelation in the AR model error (1).

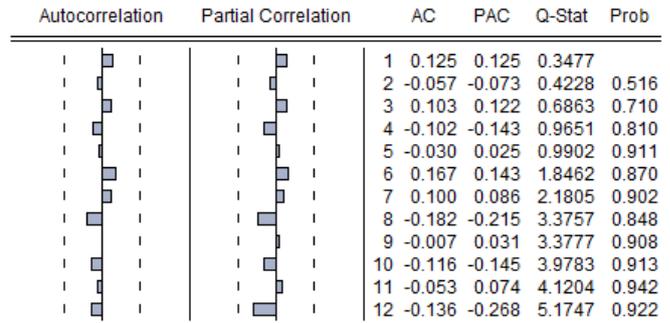


Figure 3. ARIMA Model Error Autocorrelation Test

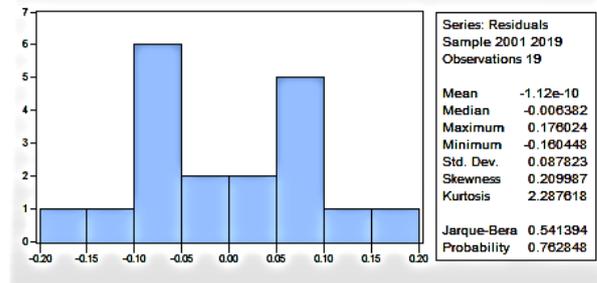


Figure 4. ARIMA Model Error Normality Test

Based on Figure 3, the results of the model error normality test are obtained. Figure 4, shows the normality test for the AR model error (1) is significant, the probability is 0.000 smaller than $\alpha = 0.05$, which means that the error is normal.

A condition is said to be heteroscedasticity, if the data has an error variance that is not constant for each observation. Heteroscedasticity data tends to be data whose value fluctuates rapidly. Volatility is used to describe the fluctuation of a data. Volatility can be defined as the variance of data over time. Volatility can be described by the tendency for data to fluctuate rapidly from time to time so that the error variance changes over time or is not constant. This can be seen through White's test as shown in Table 3.

Table 3. White's Heteroscedasticity Test

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

Based on Table 3, the probability value of both data is less than $\alpha = 0.05$. the probability value of both data is more than $\alpha = 0.05$. so that H_0 fails to be rejected, which means that there is no heteroscedasticity.

4. CONCLUSION

The conclusions obtained from the research that have been done are as follows. Gold price data for 2000 - 2019 data follows a stationary data pattern. Based on the ACF and PACF patterns on the corelogram, it shows that the data can be modeled with the ARIMA model, disconnected after the first lag. Gold price data for the period 2000 - 2019, following a stationary data pattern, has an ACF chart pattern that drops exponentially and a PACF chart that breaks after the first lag, meaning that it can be modeled using AR (1). The model error diagnostic test for gold price data for the period 2000 - 2019, is fulfilled free of autocorrelation and the normal distribution of model errors. But the homoscedasticity assumption is fulfilled. The best model for gold price data for 2000 - 2019 is AR (1) which has a MAPE value of 0.0730101 or 7.30101% error in prediction of data with this model.

REFERENCES

- Anandhita, T. (2015). Analisis Pengaruh Back Water terhadap Banjir Sungai Rangku 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.