

ESTIMASI MODEL TERBAIK UNTUK PERAMALAN HARGA SAHAM PT. POLYCHEM INDONESIA Tbk. DENGAN ARIMA

BEST ESTIMATION MODEL FOR FORECASTING STOCK PRICE OF PT. POLYCHEM Tbk. BY USING ARIMA

Darvi Mailisa Putri^{1§} Aghsilni²

¹Universitas Islam Negeri Imam Bonjol Padang, Indonesia [Email: darvimailisa@uinib.ac.id]

²Universitas Islam Negeri Imam Bonjol Padang, Indonesia [Email: aghsilni@uinib.ac.id]

[§]Corresponding Author

Received 2019; Accepted 2019; Published 2019

Abstrak

Saham merupakan hal yang masih sangat menarik dibahas dalam dunia investasi. Investasi dalam bentuk saham sangat dihadapkan dengan resiko yang tinggi. Hal ini disebabkan harga saham bersifat fluktuatif dan stokastik. Sehingga bagi suatu perusahaan harus memiliki dasar pengambilan keputusan yang tepat dan akurat agar bisa meminimalisir kerugian dalam berinvestasi. Analisis deret waktu merupakan analisis yang biasa digunakan untuk memodelkan data deret waktu. Analisis ini dapat digunakan untuk meramalkan harga saham kedepannya dengan menggunakan data sebelumnya. Model Autoregressive Integrated Moving Average (ARIMA) adalah salah satu model deret waktu yang dapat digunakan untuk memodelkan harga saham. Persamaan pada model ARIMA yang diperoleh akan membantu meramalkan harga saham periode selanjutnya. Pada penelitian ini digunakan data harga saham penutupan pada PT. Polychem Tbk. dengan periode harian. Data harga saham yang ada diolah dengan menggunakan program eviews. Melalui program eviews dikaji nilai AIC, SIC, dan HQC minimum untuk memilih model terbaik. Model ARIMA(1,1,0) menjadi model terbaik dalam meramalkan harga saham PT. Polychem Indonesia Tbk.

Kata Kunci: saham, analisis deret waktu, ARIMA

Abstract

The stocks are very interesting matters discussed in the investment world. Investment in the form of shares is very faced by high risk. This is due to fluctuating and stochastic stock prices. So to minimize losses in investment, a company must have appropriate and accurate decision-making standards. Time series analysis is an analysis commonly used to model time series data. This analysis can be used to forecast future stock prices by using previous data. The Integrated Moving Average Autoregressive Model (ARIMA) is a time series model that can be used to model stock prices. Equations obtained in the ARIMA model will help predict future stock prices. The data used in this study is the closing stock price data at PT. Polychem Tbk. in daily periods. Existing stock price data is processed using the eviews program. Through the eviews program, the minimum AIC, SIC, and HQC values are examined to choose the best model. ARIMA model (1,1,0) is the best model in predicting the stock price of PT. Polychem Indonesia Tbk.

Keywords: stock, analysis time series, ARIMA

1. Pendahuluan

Saham adalah salah satu media investasi dan merupakan sebuah bukti kepemilikan nilai sebuah perusahaan. Harga saham bersifat fluktuatif dan stokastik sehingga berinvestasi dalam bentuk saham dihadapkan dengan resiko yang tinggi. Oleh karena itu, saham masih menjadi hal yang menarik dibahas sampai saat ini dan mengkaji berbagai model peramalan harga saham untuk memperoleh nilai harga saham yang mendekati dengan nilai aktualnya.

Pada tahun 2000, Mulyono mengkaji peramalan harga saham dan nilai tukar dengan teknik Box-Jenkins [9]. Anityaloka dan Ambarwati juga meneliti peramalan saham jakarta islamic index menggunakan metode ARIMA pada tahun 2013 [1]. Selanjutnya, pada tahun 2015 Utami dan Darsyah menggunakan model winter's untuk melakukan peramalan harga saham [10].

Model peramalan harga saham sangat dibutuhkan oleh perusahaan penerbit saham dan para investor. Dengan model peramalan harga saham, perusahaan penerbit saham dapat meminimumkan resiko yang ada. Sedangkan bagi para investor, model peramalan harga saham dipakai untuk mengetahui fluktuasi harga saham dari perusahaan penerbit saham pada periode berikutnya.

Analisis deret waktu merupakan analisis yang biasa digunakan untuk memodelkan data deret waktu. Analisis ini dapat digunakan untuk meramalkan harga saham kedepannya dengan menggunakan data sebelumnya. Model

Autoregressive Integrated Moving Average (ARIMA) adalah salah satu model deret waktu yang dapat digunakan untuk memodelkan harga saham.

Selain memodelkan harga saham, model ARIMA menjadi model yang sering digunakan untuk memodelkan berbagai kasus lainnya. Hal ini dapat terlihat dari beberapa penelitian yang telah dilakukan dari tahun ke tahun. Pada tahun 2011, Lusiani dan Habinuddin mengkaji data curah hujan di kota Bandung [7]. Selanjutnya, Hadijah juga menggunakan model ARIMA untuk peramalan operasional reservasi di tahun 2013 [5]. Selain itu, kajian mengenai prediksi kunjungan pasien baru berbangsal rawat inap dengan metode ARIMA diteliti oleh Iqbal dan Wahyuni tahun 2015 [6]. Selanjutnya pada tahun 2016, Elvani dkk mengkaji peramalan jumlah produksi tanaman kelapa sawit dengan ARIMA [4].

PT. Polychem Tbk merupakan salah satu perusahaan di Indonesia yang beroperasi sebagai produsen nilon, polyster dan kabel ban rayon. Sepanjang tahun 2018 penjualan perusahaan memang lebih baik jika dibandingkan dengan tahun 2017. Akan tetapi masih mencatat kerugian sehingga tidak membagikan dividen dari laba tahun buku 2018. Oleh sebab itu penulis tertarik untuk mengkaji peramalan harga saham PT. Polychem Indonesia pada tahun 2019.

Pada penelitian ini akan dikaji harga saham penutupan PT. Polychem Indonesia Tbk. dari 01

November 2018 sampai 31 Oktober 2019. Berdasarkan data yang ada akan dikaji bentuk model dengan menggunakan eviews. Melalui model yang diperoleh, maka didapat hasil peramalan harga saham pada periode berikutnya.

2. Kestasioneran dan Model-Model Deret Waktu

Kestasioneran terbagi atas tiga yaitu, stasioner terhadap nilai tengah (mean), stasioner terhadap ragam (varians) dan stasioner terhadap kovarian.

Misalkan $\{X_t\}$ adalah suatu data deret waktu dengan $\{X_t\}$ adalah observasi pada saat t . Deret waktu $\{X_t\}$ dikatakan stasioner pada nilai tengah jika $E\{X_t\} = \mu$, dimana nilai tengah tidak bergantung terhadap t . Stasioneritas berarti tidak terdapat pertumbuhan atau penurunan pada data [8].

Apabila data tidak stasioner dalam nilai tengah, maka untuk menghilangkan ketidakstasioneran dapat dilakukan metode pembedaan (differencing). Differencing adalah menghitung perubahan atau selisih nilai observasi. Nilai selisih yang diperoleh dicek lagi apakah stasioner atau tidak. Jika belum stasioner maka dilakukan differencing lagi. Biasanya pembedaan hanya dilakukan dua kali, karena data aktual umumnya tidak stasioner pada stage pertama atau stage kedua.

Notasi yang sangat bermanfaat adalah operator shift mundur (backward shift), dinotasikan dengan B , yang penggunaannya

adalah sebagai berikut

$$BX_t = X_{t-1}$$

dimana, B = Operator shift mundur

X_t = Nilai X pada data ke- t

X_{t-1} = Nilai X pada data ke- $t-1$

Misalkan $\{X_t\}$ adalah suatu deret waktu.

Deret waktu $\{X_t\}$ stasioner pada varians jika $Var(X_t) = E(X_t - \mu)^2 = \sigma^2$, dengan kata lain nilai ragam tidak bergantung pada t .

Transformasi Box-Cox adalah salah satu metode yang digunakan untuk menstasionerkan data yang tidak stasioner dalam varians. Misalkan $T(X_t)$ adalah fungsi transformasi dari X_t dan untuk menstabilkan varians dapat digunakan formula sebagai berikut [11]

$$T(X_t) = \frac{X_t^\lambda - 1}{\lambda}$$

dimana $\lambda \neq 0$ dengan λ adalah parameter transformasi. Transformasi logaritma merupakan transformasi yang sering digunakan untuk mengatasi ketidakstasioneran data terhadap varians.

Misalkan $\{X_t\}$ adalah suatu deret waktu. Deret waktu $\{X_t\}$ stasioner pada kovarians jika $\gamma(t+k, t)$ tidak bergantung pada t . Dimana t adalah waktu observasi dan k adalah jumlah lag (beda waktu).

Uji Kestasioneran

Adapun uji yang dapat dilakukan untuk melihat kestasioneran data adalah sebagai berikut.

1. Grafik

Analisis grafik merupakan uji yang paling sederhana untuk melihat kestasioneran data deret waktu. Pada grafik tersebut dibuat plot antara observasi dengan waktu. Jika data tersebut memiliki rata-rata dan varians konstan, maka data tersebut disimpulkan stasioner. Kelemahan dari analisis grafik ini adalah keputusan diambil secara subjektif sehingga memungkinkan terjadinya perbedaan pengambilan keputusan.

2. Uji *Augmented Dickey-Fuller* (ADF)

Uji unit root merupakan salah satu uji formal untuk menguji kestasioneran terhadap nilai tengah pada data deret waktu. Menggunakan persamaan Dickey-Fuller terhadap model differenced-lag yang diregresikan yaitu

$$\nabla X_t = \mu + \delta X_{t-1} + \sum_{i=1}^k \phi_i \nabla X_{t-1} + e_t$$

dengan $\nabla X_t = X_t - X_{t-1}$ dan k jumlah lag.

Hipotesis yang digunakan pada uji ini adalah

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

$$H_1 : \delta \neq 0 \text{ (data stasioner)}$$

Statistik uji *Augmented Dickey-Fuller* adalah sebagai berikut

$$ADF = \frac{\hat{\delta}}{SE(\hat{\delta})}$$

dimana $SE(\hat{\delta})$ adalah standar error untuk $\hat{\delta}$.

Adapun kriteria pengambilan keputusan yaitu

1. Jika nilai mutlak statistik-t > statistik uji ADF maka tolak H_0 dengan kata lain data stasioner.
2. Jika nilai mutlak statistik-t < statistik uji ADF maka terima H_0 dengan kata lain data tidak stasioner.

ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*)

Autokorelasi merupakan suatu keadaan dimana residual suatu pengamatan berkorelasi dengan residual pengamatan lainnya. Autokorelasi biasa terjadi pada data deret waktu. Koefisien autokorelasi digunakan untuk mengatur keeratan hubungan linier antara data pengamatan yang berbeda lag. Dalam analisis deret waktu, untuk mengidentifikasi orde model deret waktu digunakan ACF dan PACF.

Definisi 2.1. [2] Misalkan $\{X_t\}$ adalah data deret waktu stasioner, maka fungsi autokovarians (ACVF) dari $\{X_t\}$ pada lag k adalah

$$\gamma_k = Cov(X_t, X_{t+k}) = E[(X_t - \mu)(X_{t+k} - \mu)]$$

Fungsi autokorelasi (ACF) dari $\{X_t\}$ adalah

$$\rho_k = \frac{\gamma_k}{\gamma_0} = Corr(X_t, X_{t+k})$$

Proses *White Noise*

Suatu proses $\{X_t\}$ disebut *white noise* jika memiliki sifat-sifat berikut [11]:

1. Deretnya terdiri dari peubah acak yang tidak saling berkorelasi.

2. $E(X_t) = 0$ untuk setiap t .
3. $Var(X_t) = \sigma^2$ untuk setiap t .
4. $\gamma_k = Cov(X_{t+k}, X_t) = 0$ untuk $k \neq 0$

Proses *white noise* dinotasikan sebagai

$$X_t \sim WN(0, \sigma^2).$$

Proses *white noise* merupakan proses yang penting karena dianggap sebagai faktor pembangun bagi proses runtun waktu lainnya (*building block*). Proses *white noise* merupakan proses stasioner. Karena variabel X_t tidak berkorelasi, maka fungsi autokovariannya yaitu sebagai berikut

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

Fungsi autokorelasinya yaitu sebagai berikut

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

Fungsi autokorelasi parsialnya yaitu sebagai berikut

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

Model Autoregressive

Model *autoregressive* (AR) adalah model stasioner dari data deret waktu dimana nilai pengamatan waktu ke- t dipengaruhi oleh nilai pengamatan sebelumnya. Model *autoregressive* dengan orde p dinotasikan dengan $AR(p)$. Bentuk umum model $AR(p)$ adalah [11] :

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t$$

dimana ϕ_i adalah parameter ke- i dimana dan e_t

adalah eror kesalahan saat t dengan $e_t \sim WN(0, \sigma^2)$. Selanjutnya dengan menggunakan *backward shift*, $BX_t = X_{t-1}$ persamaan diatas dapat ditulis

$$\begin{aligned} X_t &= \phi_1 BX_t + \phi_2 B^2 X_t + \dots + \phi_p B^p X_t + e_t \\ X_t - \phi_1 BX_t - \phi_2 B^2 X_t - \dots - \phi_p B^p X_t &= e_t \\ (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t &= e_t \\ \phi_p(B) X_t &= e_t \end{aligned}$$

dengan $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$. Model $AR(p)$ memenuhi kondisi stasioner jika total koefisien $\sum_{i=1}^p \phi_i < 1$

Model Moving Average

Model *moving average* (MA) menunjukkan pengamatan pada waktu t , X_t dipengaruhi oleh galat pada q waktu-waktu t sebelumnya. Model MA dengan orde q dinotasikan dengan $MA(q)$. Bentuk umum model $MA(q)$ adalah [11] :

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

dimana θ_i adalah koefisien *moving average* dan e_t adalah error saat t dengan $e_t \sim WN(0, \sigma^2)$. Selanjutnya dengan menggunakan *backward shift*, model MA bisa dituliskan

$$\begin{aligned} X_t &= e_t - \theta_1 B e_t - \theta_2 B^2 e_t - \dots - \theta_q B^q e_t \\ &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t \\ &= \theta_q(B) e_t \end{aligned}$$

dengan $\theta_p = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$. Agar model ini stasioner jumlah koefisien model $\sum_{i=1}^q \theta_i < 1$.

Model ARMA (Autoregressive Moving Average)

Dalam kasus analisis data runtun waktu, proses AR maupun MA cukup memadai, namun kadangkala ditemui kasus dimana identifikasi model menghasilkan kesimpulan bahwa data mengikuti proses AR sekaligus MA atau sebagian mengikuti proses AR sedangkan sebagian lagi mengikuti proses MA. Dalam hal ini data dikatakan mengikuti proses ARMA.

Model umum untuk campuran proses AR dan MA adalah seperti berikut

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

Dimana ϕ_i dan θ_i adalah berturut-turut koefisien *autoregressive* dan koefisien *moving average*. Model ARMA dapat dituliskan seperti

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t$$

atau bisa ditulis

$$\phi_p(B) X_t = \theta_q(B) e_t$$

Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan model campuran AR dan MA setelah dilakukan *differencing*.

Bentuk umum model ARIMA adalah:

$$(1 - B)^d X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} + e_t$$

atau bisa ditulis sebagai berikut

$$\phi_p(B)(1 - B)^d X_t = \theta_q(B)e_t$$

dimana $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ dan $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ serta B adalah operator *backward shift* dan $(1 - B)^d X_t$ adalah deret waktu yang stasioner pada pembedaan ke- d . Proses ini dilambangkan dengan ARIMA (p, d, q).

Dalam memilih berapa p dan q pada model ARIMA dapat dibantu dengan mengamati pola fungsi *autocorrelation* dan *partial autocorrelation (correlogram)* dengan acuan sebagai berikut

Tabel 1. Pola Autokorelasi dan Autokorelasi Parsial

| ACF | PACF | Model |
|---|---|---------------------|
| Menuju nol setelah lag q | Menurun secara bertahap/ bergelombang | ARIMA ($0, d, q$) |
| Menurun secara bertahap/ bergelombang | Menuju nol setelah lag q | ARIMA ($p, d, 0$) |
| Menurun secara bertahap/ bergelombang (sampai lag q masih berbeda dari nol) | Menurun secara bertahap/ bergelombang (sampai lag p masih berbeda dari nol) | ARIMA (p, d, q) |

Pemilihan Model Terbaik

Beberapa kriteria yang digunakan dalam pemilihan model yang terbaik yaitu :

a. *Akaike's Information Criterion (AIC)*

Akaike's Information Criterion (AIC) pertama kali diperkenalkan oleh Akaike untuk mengidentifikasi model dari suatu kumpulan data.

Persamaan AIC dalam pemilihan model adalah sebagai berikut :

$$AIC = \log \hat{\sigma}^2 + \frac{2k}{n}$$

dimana : $\log \hat{\sigma}^2$ = ukuran *likelihood*

k = jumlah parameter

n = banyak pengamatan

Model dikatakan baik jika nilai AIC juga semakin kecil.

b. *Bayesian Information Criterion (BIC)*

Bayesian Information Criterion (BIC) merupakan suatu tipe metode pemilihan model dengan pendekatan *Penalized Maximum Likelihood*. Pendekatan tersebut pertama kali diperkenalkan oleh Schwartz. Persamaan BIC dalam pemilihan model adalah sebagai berikut :

$$BIC = \log \hat{\sigma}^2 + \frac{k \log(n)}{n}$$

Dimana : $\log \hat{\sigma}^2$ = ukuran *likelihood*

k = jumlah parameter

n = banyak pengamatan

Model dikatakan baik jika nilai dari BIC juga semakin kecil.

c. *Hannan and Quinn Criterion (HQ)*

Kriteria informasi HQ yang diperkenalkan pada tahun 1979 oleh Hannan dan Quinn telah banyak penerapannya dalam model autoregressive dan model regresi linier. Formula HQ dapat dituliskan sebagai berikut :

$$HQ = \log \hat{\sigma}^2 + \frac{2k \log(\log(n))}{n}$$

Dimana : $\log \hat{\sigma}^2$ = ukuran *likelihood*

k = jumlah parameter

n = banyak pengamatan

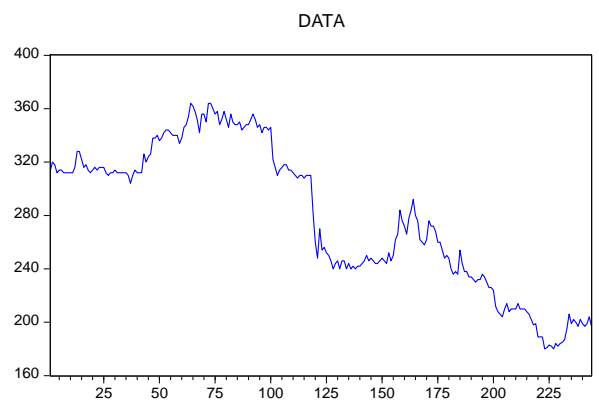
Model terbaik adalah model yang memiliki nilai HQ paling kecil.

3. Peramalan Harga Saham dengan Model ARIMA

Pada bagian ini akan dibahas tentang pengolahan data harga saham per hari PT. Polychem Indonesia Tbk. dari 01 November 2018 sampai 31 Oktober 2019 dengan model ARIMA menggunakan program *evIEWS 8*. Adapun langkah-langkah yang dilakukan untuk mencari model terbaik pada model ARIMA dengan menggunakan *evIEWS* adalah sebagai berikut

3.1 Plot Data

Langkah pertama yang harus dilakukan adalah memplot data. Dalam hal ini plot data saham berguna untuk melihat apakah data sudah stasioner dalam mean dan varians. Jika data belum stasioner dalam mean maka perlu dilakukan *differencing* dan jika data belum stasioner dalam varians maka perlu dilakukan proses transformasi. Berikut adalah hasil plot data menggunakan *evIEWS 8*.



Gambar 1. Grafik Data Harga Saham PT. Polychem


Berdasarkan plot data yang diperoleh terlihat bahwa data harga saham mengalami penurunan dan sebarannya tidak terfokus disekitar nilai tengah. Ragam (varians) dari data harga saham juga tidak konstan maka dapat disimpulkan bahwa data harga saham tidak stasioner terhadap mean dan varians. Selain dapat dilihat dari plot data, statistik uji ADF juga dapat dilakukan untuk melihat kestasioneran data terhadap nilai tengah.

Tabel 2. Hasil uji unit akar (ADF)

| | t-Statistic | Prob.* |
|--|-------------|--------|
| Augmented Dickey-Fuller test statistic | -0.304278 | 0.9209 |
| Test critical values: 1% level | -3.457173 | |
| 5% level | -2.873240 | |
| 10% level | -2.573080 | |

Hasil statistik dengan uji unit akar (ADF) diperoleh nilai statistiknya sebesar -0.304278 dan nilai kritisnya sebesar -2.873240 dengan nilai $\alpha = 0.05$. Nilai mutlak statistik uji lebih kecil jika dibandingkan dengan nilai mutlak kritisnya, maka disimpulkan bahwa data belum stasioner terhadap nilai tengah.

Selanjutnya, agar data harga saham stasioner terhadap nilai tengah maka dilakukan differencing. Berikut hasil plot dan uji unit akar (ADF) setelah dilakukan differencing pada orde pertama.



Gambar 2. Grafik Data Harga Saham PT. Polychem setelah dilakukan differencing dan transformasi

Tabel 3. Hasil uji unit akar (ADF) setelah differencing

| | t-Statistic | Prob.* |
|--|-------------|--------|
| Augmented Dickey-Fuller test statistic | -15.59833 | 0.0000 |
| Test critical values: 1% level | -3.457286 | |
| 5% level | -2.873289 | |
| 10% level | -2.573106 | |

Berdasarkan hasil plot data yang ada terlihat bahwa data telah berada di sekitar nilai tengah. Maka dapat disimpulkan bahwa data telah berada dalam keadaan stasioner.

Pada hasil uji ADF diperoleh nilai statistik sebesar -15.59833 dan nilai kritisnya sebesar -2.873289 dengan nilai $\alpha = 0.05$. Nilai mutlak statistik uji lebih besar dari pada nilai mutlak kritisnya, hal ini memperkuat bahwa data telah stasioner terhadap nilai tengah. Langkah selanjutnya adalah menganalisis data runtun waktu dengan model ARIMA (p, d, q).

3.2 Identifikasi Model ARIMA

Identifikasi model ARIMA (p, d, q) dengan melakukan plot ACF (Autocorrelation

Function) dan PACF (Partial Autocorrelation Function). Pada hasil plot tersebut akan dipilih berapa p dan q pada model ARIMA (p, d, q). Berikut hasil plot ACF dan PACF sebelum dan sesudah dilakukan transformasi log dan differencing

Tabel 4. Hasil correlogram ACF dan PACF sebelum differencing dan transformasi

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob |
|-----------------|---------------------|----------|--------|--------|------|
| 1 | 0.988 | 0.988 | 241.27 | 0.000 | |
| 2 | 0.977 | 0.017 | 478.08 | 0.000 | |
| 3 | 0.965 | -0.03... | 710.16 | 0.000 | |
| 4 | 0.954 | 0.018 | 937.81 | 0.000 | |
| 5 | 0.943 | 0.022 | 1161.4 | 0.000 | |
| 6 | 0.934 | 0.028 | 1381.2 | 0.000 | |
| 7 | 0.922 | -0.06... | 1596.6 | 0.000 | |
| 8 | 0.911 | -0.01... | 1807.5 | 0.000 | |
| 9 | 0.898 | -0.03... | 2013.6 | 0.000 | |
| 1... | 0.885 | -0.05... | 2214.5 | 0.000 | |
| 1... | 0.872 | 0.033 | 2410.5 | 0.000 | |
| 1... | 0.859 | -0.05... | 2601.2 | 0.000 | |
| 1... | 0.844 | -0.05... | 2786.4 | 0.000 | |
| 1... | 0.829 | -0.04... | 2965.6 | 0.000 | |
| 1... | 0.814 | 0.005 | 3139.2 | 0.000 | |
| 1... | 0.798 | -0.04... | 3306.7 | 0.000 | |
| 1... | 0.782 | 0.003 | 3468.6 | 0.000 | |
| 1... | 0.766 | -0.03... | 3624.5 | 0.000 | |
| 1... | 0.749 | -0.05... | 3774.2 | 0.000 | |
| 2... | 0.732 | -0.01... | 3917.7 | 0.000 | |
| 2... | 0.714 | -0.02... | 4054.9 | 0.000 | |
| 2... | 0.695 | -0.04... | 4185.6 | 0.000 | |
| 2... | 0.678 | 0.019 | 4310.3 | 0.000 | |
| 2... | 0.660 | -0.02... | 4429.0 | 0.000 | |
| 2... | 0.642 | 0.028 | 4542.0 | 0.000 | |
| 2... | 0.626 | 0.035 | 4649.9 | 0.000 | |
| 2... | 0.608 | -0.04... | 4752.3 | 0.000 | |
| 2... | 0.591 | -0.01... | 4849.2 | 0.000 | |
| 2... | 0.574 | 0.037 | 4941.2 | 0.000 | |
| 3... | 0.558 | 0.030 | 5028.4 | 0.000 | |
| 3... | 0.543 | 0.040 | 5111.3 | 0.000 | |
| 3... | 0.527 | -0.01... | 5190.1 | 0.000 | |
| 3... | 0.513 | 0.040 | 5265.0 | 0.000 | |
| 3... | 0.499 | 0.020 | 5336.2 | 0.000 | |
| 3... | 0.484 | -0.06... | 5403.5 | 0.000 | |
| 3... | 0.469 | 0.009 | 5467.1 | 0.000 | |

Tabel 5. Hasil correlogram ACF dan PACF setelah differencing dan transformasi

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob |
|-----------------|---------------------|----------|--------|--------|------|
| 1 | -0.00... | -0.00... | 0.0116 | 0.914 | |
| 2 | 0.007 | 0.007 | 0.0233 | 0.988 | |
| 3 | -0.05... | -0.05... | 0.6577 | 0.883 | |
| 4 | -0.04... | -0.04... | 1.1446 | 0.887 | |
| 5 | -0.04... | -0.04... | 1.5814 | 0.903 | |
| 6 | 0.077 | 0.075 | 3.0649 | 0.801 | |
| 7 | 0.037 | 0.034 | 3.4024 | 0.845 | |
| 8 | 0.085 | 0.080 | 5.2403 | 0.732 | |
| 9 | 0.056 | 0.062 | 6.0411 | 0.736 | |
| 1... | -0.02... | -0.01... | 6.1669 | 0.801 | |
| 1... | -0.03... | -0.02... | 6.4816 | 0.839 | |
| 1... | -0.06... | -0.05... | 7.4096 | 0.829 | |
| 1... | 0.044 | 0.047 | 7.9046 | 0.850 | |
| 1... | -0.01... | -0.02... | 7.9765 | 0.891 | |
| 1... | 0.072 | 0.049 | 9.3226 | 0.860 | |
| 1... | -0.04... | -0.05... | 9.8193 | 0.876 | |
| 1... | 0.026 | 0.018 | 9.9954 | 0.904 | |
| 1... | 0.102 | 0.123 | 12.765 | 0.805 | |
| 1... | 0.015 | 0.021 | 12.825 | 0.847 | |
| 2... | -0.00... | 0.015 | 12.826 | 0.885 | |
| 2... | 0.058 | 0.057 | 13.715 | 0.882 | |
| 2... | 0.001 | 0.014 | 13.716 | 0.911 | |
| 2... | 0.015 | 0.016 | 13.775 | 0.933 | |
| 2... | -0.06... | -0.08... | 14.949 | 0.922 | |
| 2... | 0.021 | 0.023 | 15.068 | 0.940 | |
| 2... | 0.085 | 0.070 | 17.047 | 0.908 | |
| 2... | 0.050 | 0.031 | 17.732 | 0.912 | |
| 2... | -0.05... | -0.07... | 18.429 | 0.915 | |
| 2... | -0.04... | -0.04... | 19.008 | 0.921 | |
| 3... | -0.06... | -0.04... | 20.259 | 0.910 | |
| 3... | -0.00... | -0.00... | 20.269 | 0.930 | |
| 3... | -0.07... | -0.08... | 21.844 | 0.912 | |
| 3... | -0.00... | -0.03... | 21.858 | 0.931 | |
| 3... | 0.064 | 0.056 | 23.027 | 0.923 | |
| 3... | -0.02... | -0.04... | 23.235 | 0.936 | |
| 3... | 0.017 | -0.00... | 23.322 | 0.949 | |

Dari correlogram ACF dan PACF yang dihasilkan, maka berdasarkan Tabel diperoleh model ARIMA(p,d,0) yaitu ARIMA(1,1,0). Namun pada kasus ini peneliti akan tetap melakukan estimasi model AR, MA, ARMA, dan ARIMA untuk melakukan perbandingan model yang didapat. Langkah selanjutnya adalah mengestimasi parameter model-model tersebut.

3.3 Estimasi Model Terbaik

Pada tahap ini akan dilakukan estimasi parameter model. Berikut hasil estimasi parameter yang dilakukan dengan menggunakan evIEWS 8.

Tabel 6. Beberapa hasil model yang diperoleh dengan nilai konstanta dan parameter

| Jenis Model | C | AR(1) | MA(1) |
|---|-----------------------|-----------|-----------|
| AR(1) | 58,44064 (0,9379) | 0,997826 | |
| MA(1) | 279,3797 (0,0000) | | 0,927754 |
| ARMA(1,1) | 52,22490 (0,9475) | 0,997886 | -0,005296 |
| ARIMA(1,1,0) | -0,507898 (0,1881) | -0,006872 | |
| ARIMA(0,1,1) | -0,481482 (0,2113) | | -0,006870 |
| ARIMA(1,1,1) | -0,505879 (0,1914) | -0,093839 | 0,086505 |
| AR(1) dengan Transformasi Log | 4,190063 (0,5764) | 0,998653 | |
| MA(1) dengan Transformasi Log | 5,612495 (0,0000) | | 0,935643 |
| ARMA(1,1) dengan Transformasi Log | 3,978835 (0,6839) | 0,998828 | -0,016687 |
| ARIMA(1,1,0) dengan Transformasi Log | -0,002001 (0,1530) | -0,018070 | |
| ARIMA(0,1,1) dengan Transformasi Log | -0,001918 (0,1698) | | -0,017600 |
| ARIMA(1,1,1) dengan Transformasi Log | -0,001993 (0,1561) | -0,120070 | 0,100655 |

Tabel 7. Beberapa hasil model yang diperoleh dengan nilai AIC, SIC, HQC

| Jenis Model | AIC | SIC | HQC |
|--------------|----------|----------|----------|
| AR(1) | 6,438920 | 6,467669 | 6,450500 |
| MA(1) | 9,614698 | 9,643363 | 9,626243 |
| ARMA(1,1) | 6,447122 | 6,490247 | 6,464492 |
| ARIMA(1,1,0) | 6,438622 | 6,467456 | 6,450237 |
| ARIMA(0,1,1) | 6,439257 | 6,468006 | 6,450837 |

| | | | |
|---|-----------|-----------|-----------|
| ARIMA(1,1,1) | 6,446786 | 6,490038 | 6,464210 |
| AR(1) dengan Transformasi Log | -4,778446 | -4,749696 | -4,766866 |
| MA(1) dengan Transformasi Log | -1,572164 | -1,543499 | -1,560619 |
| ARMA(1,1) dengan Transformasi Log | -4,770497 | -4,727372 | -4,753127 |
| ARIMA(1,1,0) dengan Transformasi Log | -4,778140 | -4,749305 | -4,766524 |
| ARIMA(0,1,1) dengan Transformasi Log | -4,778608 | -4,749858 | -4,767028 |
| ARIMA(1,1,1) dengan Transformasi Log | -4,769981 | -4,726729 | -4,752557 |

3.4 Pemilihan Model Terbaik

Berdasarkan hasil pengolahan hasil dari eviews dari beberapa model yang diestimasi maka dipilih beberapa model yang memiliki nilai AIC, SIC, dan HQC minimum serta diperhatikan nilai signifikan terkecil. Tabel berikut merupakan perbandingan nilai dari ketiga kriteria dalam pengambilan keputusan terbaik.

Tabel 8. Pemilihan model berdasarkan nilai AIC, SIC, HQC minimum

| | ARIMA (1,1,0) dengan Transformasi Log | ARIMA (0,1,1) dengan Transformasi Log | ARIMA (1,1,1) dengan Transformasi Log |
|-------|---|---|---|
| C | -0,002001 (0,1530) | -0,001918 (0,1698) | -0,001993 (0,1561) |
| AR(1) | -0,018070 | - | -0,129979 |
| MA(1) | - | -0,017600 | 0,100655 |

| | | | |
|-----|-----------|-----------|-----------|
| AIC | -4,778140 | -4,778608 | -4,769981 |
| SIC | -4,749305 | -4,749858 | -4,726729 |
| HQC | -4,766524 | -4,767028 | -4,752557 |

Pada Tabel diperoleh bahwa model ARIMA(1,1,0) dan ARIMA(0,1,1) memiliki nilai AIC, BIC, dan HQC minimum dibandingkan model ARIMA(1,1,1). Namun dilihat dari nilai signifikannya model ARIMA(1,1,0) lebih kecil daripada model ARIMA(0,1,1). Oleh karena itu, dapat disimpulkan bahwa model ARIMA(1,1,0) adalah model terbaik untuk data harga saham PT. Polychem Tbk. dengan persamaan model sebagai berikut

$$\nabla^1 X_t = -0,002001 - 0,018070 \nabla^1 X_{t-1} + e_t$$

dimana,

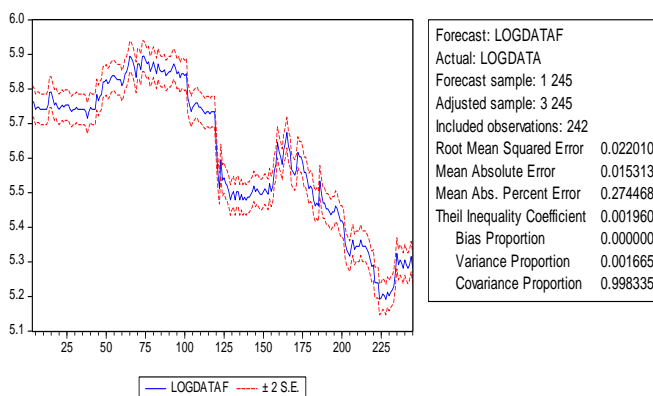
X_t = observasi orde ke - t

X_{t-1} = observasi orde ke - (t-1)

e_t = nilai kesalahan pada periode ke - t

∇^1 = notasi differencing orde pertama

Melalui model terbaik yang telah terpilih dilakukan peramalan data harga saham yang dipresentasikan melalui gambar berikut.



Gambar 3. Grafik Hasil Peramalan Data Harga Saham PT. Polychem dengan Model ARIMA(1,1,0)

Pada Gambar terlihat bahwa hasil grafik peramalan yang diperoleh dari model ARIMA(1,1,0) sangat signifikan dan memiliki eror yang sangat kecil.

4. Kesimpulan Dan Saran

Berdasarkan pengolahan data yang dilakukan pada data harga saham harian PT. Polychem Tbk. dari tanggal 01 November 2018 sampai dengan 31 Oktober 2019 dengan model ARIMA(p,d,q) diperoleh model terbaik ARIMA(1,1,0). Model ini terpilih karena didukung dengan nilai AIC, SIC, dan HQC yang minimum serta nilai signifikan juga minimum. Model ARIMA(1,1,0) memiliki persamaan sebagai berikut

$$\nabla^1 X_t = -0,002001 - 0,018070 \nabla^1 X_{t-1} + e_t$$

Hasil peramalan yang didapat dari model ARIMA(1,1,0) mendekati data aktual dengan nilai eror yang kecil.

Pada penelitian ini hanya dikaji estimasi model terbaik dari data harga saham. Disarankan untuk penelitian selanjutnya dapat mengkaji uji asumsi dari model terbaik yang telah didapat. Selain itu juga bisa dikaji model yang lebih baik yang berkaitan dengan ARIMA, seperti halnya model ARCH, GARCH.

5. Ucapan Terima Kasih

Pada artikel ini penulis ucapkan terima kasih kepada pihak-pihak yang telah terlibat dalam membantu penulisan artikel ini.

Daftar Pustaka

- [1] Anityaloka, R. N., Ambarwati, A. N. 2013. Peramalan Saham Jakarta Islamic Index Menggunakan Metode ARIMA Bulan Mei-Juli 2010. *Jurnal Statistika* 1(1). p.1-5.
- [2] Bain, L. J., M. Engelhardt. 1992. Introduction to Probability and Mathematical Statistics Second Edition. Duxbury Press, California.
- [3] Brockwell, P. J., R. A. Davis. 2002. *Introduction Time Series and Forecasting*. Springer, New York.
- [4] Elvani, S. P., Utary, A. R., Yударuddin, R. 2016. Peramalan Jumlah Produksi Tanaman Kelapa Sawit dengan Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). *Jurnal Manajemen* 8(1). p. 95-112
- [5] Hadijah. 2013. Peramalan Operasional Reservasi dengan Program Minitab Menggunakan Pendekatan ARIMA PT. Surindo Andalan. *Journal The Winners* 14(1). p.13-19.
- [6] Iqbal, M. F., Wahyuni, I. 2015. Prediksi Kunjungan Pasien Baru Perbangsal Rawat Inap Tahun 2015 dengan Metode ARIMA di BLUD RSUD Banjar. *Jurnal Manajemen Informasi Kesehatan Indonesia* 3(1).
- [7] Lusiani, A., Habinuddin, E. 2011. Pemodelan Autoregressive Integrated Moving Average (ARIMA) Curah Hujan di Kota Bandung. *Jurnal Sigma-Mu* 3(2).
- [8] Makridarkis, S., Wheelwright, S. C., Hyndman, R. J. 1998. *Forecasting Methods and Applications Third Edition*. Jhon Wiley & Sons, Inc., United States of America.
- [9] Mulyono, Sri. 2000. Peramalan Harga Saham dan Nilai Tukar: Teknik Box-Jenkins. *Ekonomi dan Keuangan Indonesia XLVIII*(2). p.125-141.
- [10] Utami, T. W., Darsyah, M. Y. 2015. Peramalan Data Saham dengan Model Winter's. *Jurnal Statistika* 3(2). p.41-44.
- [11] Wei, William W. S. 2006. *Time Series Analysis: Univariate and Multivariate*. Pearson, Boston.