



Long Memory Volatility Model dengan ARFIMA-HYGARCH untuk Meramalkan Return Indeks Harga Saham Gabungan (IHSG)

Nurhayun Rismawati[✉], Sugiman

Jurusan Matematika, FMIPA, Universitas Negeri Semarang
Gedung D7 Lt. 1, Kampus Sekaran Gunungpati, Semarang 50229

Info Artikel

Sejarah Artikel:
Diterima November 2019
Disetujui Juni 2020
Dipublikasikan Mei 2022

Keywords:

Long memory,
volatilitas,
heteroskedastisitas,
ARFIMA,
HYGARCH,
efek asimetrik

Abstrak

Model ARFIMA-HYGARCH merupakan model yang dapat menjelaskan *time series* jangka panjang dan dapat mengatasi masalah ragam yang heterogen serta pengaruh asimetrik dalam data *return* IHSG. Tujuan dari penelitian ini adalah untuk menemukan model ARFIMA-HYGARCH terbaik pada data *return* IHSG dan meramalkan data *return* IHSG untuk periode Juni sampai dengan Juli 2019. Hasil dari penelitian ini diperoleh model ARFIMA-HYGARCH terbaik untuk data *return* IHSG yaitu ARFIMA(5,-0.0102919,4)-HYGARCH(1,d,1) yang memiliki nilai AIC -8.197636926 dan hasil peramalan untuk periode Juni sampai dengan Juli 2019 menunjukkan bahwa untuk periode tanggal 11 Juni 2019, 12 Juni 2019, 17 Juni 2019, 18 Juni 2019 dan 24 Juni 2019 plot ramalan varian berada di bawah plot ramalan *mean*. Ini berarti pada periode tersebut risiko investor dalam berinvestasi di pasar modal akan lebih besar. Utamanya untuk periode 12 Juni 2019 investor lebih baik jangan melakukan investasi karena pada periode tersebut nilai ramalannya paling tinggi. Peramalan yang diperoleh dari penelitian ini akan bermanfaat bagi para investor dalam mengambil keputusan investasi.

Abstract

ARFIMA-HYGARCH is a model that can explain long-term time series and can resolve heteroscedasticity problems and asymmetric effect in the JCI return. The purpose of this research is to find the best ARFIMA-HYGARCH model for JCI return and forecast the JCI return for the period June to July 2019. The results of this research were obtained the best ARFIMA-HYGARCH model for JCI return is ARFIMA (5, -0.0102919, 4) -HYGARCH (1, d, 1) which has an AIC value of -8.197636926 and forecast results for the period June to July 2019 indicate that for the period June 11, 2019, June 12, 2019, June 17, 2019, June 18 2019 and June 24 2019 variant forecast plots are below the mean forecast plot. This means that in this period the risk of investors investing in the capital market will be greater. Primarily for the period 12 June 2019 investors are better off not investing because in that period the forecast value is highest. Forecasting obtained from this research will be beneficial for investors in making investment decisions.

How to cite:

Rismawati, N., & Sugiman. (2022). Long Memory Volatility Model dengan ARFIMA-HYGARCH Untuk Meramalkan Return Indeks Harga Saham Gabungan (IHSG). *UNNES Journal of Mathematics*, 11(1): 80-91.

PENDAHULUAN

Indeks Harga Saham Gabungan (IHSG) merupakan salah satu pedoman bagi investor dalam berinvestasi di pasar modal karena IHSG menunjukkan pergerakan seluruh harga saham di Bursa Efek Indonesia (BEI). Investasi saham tidak dapat terhindar dari risiko, sehingga dibutuhkan model yang dapat memprediksi return dan volatilitas saham guna dijadikan acuan dalam mengambil keputusan. Untuk menghasilkan keputusan investasi jangka pendek maupun jangka panjang yang tepat, maka perlu dilakukan peramalan. Hasil peramalan ini dapat digunakan sebagai salah satu pertimbangan dalam mengambil keputusan atau sebagai acuan dalam melakukan perencanaan investasi.

Berbagai macam metode analisis *time series* yang sudah biasa digunakan antara lain metode *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA) dan metode Box-Jenkins (ARIMA). Metode tersebut merupakan metode – metode klasik dalam peramalan *time series*. Seiring perkembangan waktu dan pengetahuan, metode peramalan semakin banyak dikembangkan oleh peneliti, diantaranya adalah model *long memory*. Data *time series* yang dikategorikan dalam data *long memory* adalah data *time series* yang tidak stationer dan plot ACF-nya tidak turun secara eksponensial melainkan turun secara lambat atau hiperbolik. Untuk meramalkan data *long memory*, Hosking (1981) telah memperkenalkan metode *Autoregressive Fractionally Moving Average* (ARFIMA) yang dapat mengatasi kelemahan metode ARIMA. Menurut penelitian yang dilakukan oleh Damayanti (2012) yang membandingkan performa metode terbaik ARIMA dan metode terbaik ARFIMA untuk meramalkan tekanan udara di Kota Padang, ternyata model ARFIMA lebih baik dibandingkan model ARIMA.

Untuk data IHSG biasanya memiliki volatilitas tinggi yang ditunjukkan oleh suatu tahap dimana fluktuasinya relatif tinggi, kemudian diikuti fluktuasi yang rendah dan kembali tinggi. Implikasi dari data yang bervolatilitas tinggi adalah ragam dari galatnya menjadi heterogen. Solusi untuk mengatasi masalah keheterogenan ragam galat di antaranya yaitu dengan memodelkan fungsi ragam ARCH yang dikenalkan pertama kali oleh Engle (1982). Namun, pada data keuangan dengan tingkat volatilitas yang besar, model ARCH memerlukan orde yang sangat besar pula. Maka Bollerslev (1986) mengembangkan model ARCH menjadi Generalized ARCH

(GARCH). Model GARCH yang dikembangkan oleh Bollerslev masih memiliki kekurangan, yaitu tidak dapat mengatasi pengaruh asimetrik (efek leverage). Definisi efek leverage yaitu suatu keadaan *bad news* dan *good news* yang memberikan pengaruh asimetris terhadap volatilitas. Data dikatakan *bad news* ketika volatilitas mengalami penurunan sedangkan keadaan dikatakan *good news* ketika volatilitas mengalami kenaikan secara berkala. Selain itu, model GARCH membatasi nilai parameternya agar ragam bersyaratnya tidak negatif, serta terlalu *over* dalam memprediksi nilai volatilitasnya. Karena kekurangan tersebut, model GARCH dikembangkan lagi. Pada tahun 2010 Francq dan Zakoian menemukan model *Integrated Generalized Autoregressive Conditional Heteroskedasticity* (IGARCH) yang dapat menutupi kelemahan model GARCH. Namun, model IGARCH belum cukup baik dalam melakukan peramalan lebih dari sepuluh periode ke depan. Oleh karena itu, model IGARCH terus mengalami pengembangan.

Salah satu modifikasi dari model IGARCH adalah model FIGARCH. Untuk mendeteksi pola memori jangka panjang (*long memory*) dalam volatilitas, Baillie et al. (1996) mengusulkan model FIGARCH dengan memperluas model IGARCH. Keutuhan varian bersyarat yang disyaratkan dalam model IGARCH tampak terlalu membatasi dan tampaknya bertentangan dengan bukti empiris. Terlihat bahwa model GARCH dan IGARCH memiliki memori yang jauh lebih pendek daripada seri keuangan umumnya. Proses FIGARCH memberikan fleksibilitas tambahan yang bertujuan menangkap *long memory* dalam volatilitas. Dalam memodelkan ketergantungan volatilitas jangka panjang, ada dua proses GARCH hiperbolik yang sering digunakan yaitu FIGARCH dan HYGARCH. Davidson (2004) menemukan konsep awal metode HYGARCH dalam penelitian tersebut disarankan konsep memori hiperbolik dan proses ini dikatakan memiliki memori hiperbolik (geometris) jika koefisiennya meluruh secara hiperbolik (geometris). Pada tahun 2014 Truong Hongngoe melakukan penelitian membandingkan performa ARFIMA-FIGARCH dengan ARFIMA-HYGARCH pada data *return* ETF periode 2008-2013 dari tujuh negara di Asia yang baru muncul. Dalam penelitiannya di peroleh bahwa model ARFIMA-HYGARCH adalah model terbaik sebagai ganti dari model ARFIMA dan ARFIMA-FIGARCH. Oleh sebab kelebihan

yang dimiliki oleh model ARFIMA dan HYGARCH, serta mengingat pentingnya peramalan harga saham bagi investor untuk menghasilkan keputusan investasi yang tepat, maka dalam penelitian ini dilakukan pemodelan dan peramalan *return* Indeks Harga Saham Gabungan (IHSG) menggunakan ARFIMA-HYGARCH.

Tujuan dari penelitian ini adalah untuk memperoleh model terbaik ARFIMA-HYGARCH dan meramalkan data return IHSG untuk beberapa periode ke depan.

METODE ANALISIS TIME SERIES

Disini akan dijelaskan beberapa metode analisis *time series* yaitu ARFIMA, ARCH, GARCH, IGARCH, FIGARCH, dan HYGARCH.

Menurut Doornik dan Ooms (2012), model ARFIMA (p, d, q) dapat ditulis

$$\phi(B)\nabla^d Y_t = \theta(B)a_t, t = 1, 2, 3, \dots, T \quad (1)$$

dengan level integrasi d merupakan bilangan riil dan $a_t \sim IID(0, \sigma_t^2)$. Filter pembeda ∇^d pada persamaan (1) disebut *Long Memory Filter* (LMF) yang menggambarkan adanya ketergantungan jangka panjang dalam deret. Filter ini diekspansikan sebagai deret Binomial

$$\nabla^d = (1 - B)^d = \sum_{j=0}^{\infty} \binom{d}{j} (-1)^j B^j \quad (2)$$

dengan $\binom{d}{j} = \frac{d!}{j!(d-j)!} = \frac{\Gamma(d+1)}{\Gamma(j+1)\Gamma(d-j+1)}$ dan $\Gamma(x)$

merupakan fungsi gamma, sehingga

$$\begin{aligned} \nabla^d &= \binom{d}{0} (-1)^0 B^0 + \binom{d}{1} (-1)^1 B^1 \\ &\quad + \binom{d}{2} (-1)^2 B^2 + \binom{d}{3} (-1)^3 B^3 + \dots \\ \nabla^d &= \frac{d!}{0!(d-0)!} B^0 - \frac{d!}{1!(d-1)!} B^1 \\ &\quad + \frac{d!}{2!(d-2)!} B^2 - \frac{d!}{3!(d-3)!} B^3 + \dots \\ \nabla^d &= 1 - dB + \frac{1}{2}(1-d)dB^2 - \frac{1}{6}(1-d)(2-d)dB^3 + \dots \end{aligned} \quad (3)$$

Untuk mengatasi heteroskedastisitas yang terdapat pada sisaan model ARFIMA terbaik, Engle (1982) mengembangkan model rata-rata dan ragam suatu data deret waktu yang dimodelkan secara simultan. Model tersebut dikenal dengan model *Autoregressive Conditional Heteroscedasticity* (ARCH) yang dapat ditulis

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \quad (4)$$

Persamaan (4) menunjukkan bahwa ragam galat (σ_t^2) memiliki dua unsur, yaitu konstanta (ω) dan kuadrat galat beberapa periode yang lalu (ε_{t-i}^2).

Model ARCH dikembangkan dengan memasukkan unsur galat periode lalu dan ragam galat. Model ini dikenal sebagai model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) yang dapat dinyatakan dalam persamaan (5)

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (5)$$

Dengan ω adalah konstanta, α_i dan β_j berturut-turut adalah koefisien model ARCH dan GARCH. Persamaan (5) menunjukkan bahwa ragam galat (σ_t^2) tidak hanya dipengaruhi oleh kuadrat galat periode yang lalu (ε_{t-i}^2), tetapi juga oleh ragam galat periode yang lalu (σ_{t-j}^2) (Juanda dan Junaidi 2012). Model GARCH memiliki batasan pada parameternya agar ragam bersyarat (*conditional variance*) menjadi positif. Selain itu, model GARCH tidak mampu menangkap efek asimetrik sehingga model GARCH dikembangkan menjadi model GARCH asimetrik. Model GARCH asimetrik diantaranya adalah model IGARCH, FIGARCH, dan HYGARCH. Masing-masing persamaan model GARCH asimetrik yaitu sebagai berikut.

Menurut Francq dan Zakoian (2010) bentuk umum model IGARCH (p, q) sebagai berikut:

$$\sigma_t^2 = \sum_{i=1}^p \alpha_i a_{t-1}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (6)$$

Menurut Chang et al. (2012) spesifikasi umum model FIGARCH (p, d, q) adalah sebagai berikut:

$$\phi(L)(1-L)^d \varepsilon_t^2 = \omega + [(1-\beta(L))]v_t \quad (7)$$

atau dapat dinyatakan

$$\sigma_t^2 = \omega + (1 - [1 - \beta(L)]^{-1} \phi(L)(1-L)^d) \varepsilon_t^2 \quad (8)$$

$$\sigma_t^2 = \omega + \lambda(L) \sigma_t^2 \quad (9)$$

Dimana $\lambda(L) = \lambda_1 L + \lambda_1 L^2 + \dots$ dan $0 \leq d \leq 1$. Keberadaan *long memory* ini dapat difaktorisasikan melalui polinomial *autoregressive* $[1 + \beta(L)] = \phi(L)(1-L)^d$.

Menurut Davidson (2004) Varians bersyarat dari model HYGARCH dapat dirumuskan sebagai berikut:

$$h_t = \omega + \left(\sum_{k=1}^{\infty} \pi_k L^k\right) e_t^2 \quad (10)$$

dengan

$$\sum_{k=1}^{\infty} \pi_k L^k = \left(1 - \frac{1-\delta(L)}{1-\beta(L)}(1 - \alpha + \alpha(1-L)^{d_{FG}})\right)$$

dan

$$(1-L)^{d_{FG}} = 1 - \sum_{k=1}^{\infty} \pi_k L^k$$

sehingga

$$h_t = \omega + \left(1 - \frac{1-\delta(L)}{1-\beta(L)}(1 + \alpha[(1-L)^{d_{FG}} - 1])\right) e_t^2 \quad (11)$$

Dimana $\{\varepsilon_t\}$ adalah variabel acak dengan $Mean = 0$ dan $Varians = 1$. $\alpha > 0, \beta \geq 0, \delta \geq 0$. L adalah operator *backshift*. $0 \leq d \leq 1$ dan $\omega \geq 0$ adalah parameter memori dan bobot masing-masing. Model memori hiperbolik berasal dari struktur $(1-L)^{d_{FG}} = 1 - \sum_{k=1}^{\infty} \pi_k L^k$ untuk $0 < d < 1$.

METODE PENELITIAN

Data yang digunakan dalam penelitian ini adalah data runtun waktu sekunder yang diambil dari *Yahoo Finance Official Website* yaitu www.finance.yahoo.id yang telah dipublikasikan sehingga bebas di akses. Data yang digunakan merupakan data harga penutupan Indeks Harga Saham Gabungan (IHSG) harian. Periode yang digunakan mulai dari Januari 2011 hingga Mei 2019. Data dibagi menjadi dua bagian, yaitu data *in sample* dan data *out sample*. Periode Januari 2011 sampai dengan Desember 2018 digunakan sebagai data *in sample* sedangkan Januari 2019 sampai dengan Mei 2019 digunakan sebagai data *out sample*.

Teknik-teknik analisis data yang digunakan dalam penelitian ini adalah sebagai berikut.

1. Melakukan eksplorasi data dengan melihat plot deret waktu data IHSG dan *return* IHSG, melihat statistika deskriptif dari data IHSG dan *return* IHSG serta uji stasioneritas data IHSG dan *return* IHSG.
2. Menentukan nilai d dengan metode *estimasi Exact Maximum Likelihood (EML)*. Metode EML digunakan untuk menduga parameter-parameter dengan memaksimumkan fungsi kemungkinannya yang dibentuk dari gabungan distribusi pengamatan.

3. Identifikasi model dilakukan dengan mengamati plot ACF dan PACF dari data *return* IHSG.
4. Mengestimasi model yang sudah terbentuk.
5. Melakukan pemilihan model yang signifikan. Suatu model ARFIMA dikatakan signifikan apabila parameter-parameter model tersebut memiliki $p\text{-value} < 0,05$.
6. Memilih model ARFIMA terbaik. Berdasarkan penelitian yang dilakukan oleh Ningrum (2009), pemilihan model terbaik ARFIMA menggunakan kriteria AIC. Oleh karena itu, pada penelitian ini pemilihan model terbaik ARFIMA berdasarkan AIC. Model ARFIMA terbaik memiliki nilai AIC terkecil.
7. Diagnostik sisaan ARFIMA. Setelah mendapatkan model ARFIMA terbaik kemudian dilakukan analisis diagnostik yaitu kehomogenan ragam sisaan yang diperiksa dengan uji ARCH-LM. Jika ragam sisaan homogen, data cukup dimodelkan dengan model ARFIMA. Jika tidak, dapat diatasi dengan membangun model ragam bersyarat (*conditional variance*).
8. Membangun model ragam bersyarat ARFIMA-GARCH.
9. Melakukan uji pengaruh asimetrik pada data *return* IHSG dengan uji *Sign Bias Test (SBT)* dan plot *cross correlation* antara standar residual kuadrat model *Box Jenkins* dengan *lag* standar residual model GARCH.
10. Melakukan estimasi model. Jika terdapat heteroskedastisitas, dan terdapat pengaruh asimetrik dalam data, maka data dimodelkan dengan model ragam HYGARCH. Sebelum mendapatkan model HYGARCH sebagai model terbaik, model GARCH, IGARCH dan FIGARCH akan diestimasi terlebih dahulu untuk selanjutnya dibandingkan berdasarkan kriteria pemilihan model. Penentuan model terbaik didasarkan pada nilai AIC dan SC terkecil.
11. Membangun model HYGARCH.
12. Melakukan evaluasi model. Jika HYGARCH merupakan model yang terbaik, maka evaluasi model dilakukan dengan analisis diagnostik sisaan seperti pada model ARFIMA.
13. Melakukan peramalan data untuk beberapa periode, yaitu peramalan jangka pendek dan jangka panjang dengan menggunakan data pemodelan.
14. Melakukan validasi peramalan. Data validasi dimodelkan lagi menggunakan model terbaik sehingga diperoleh nilai ragam bersyarat aktual. Nilai ragam bersyarat aktual ini kemudian dibandingkan dengan

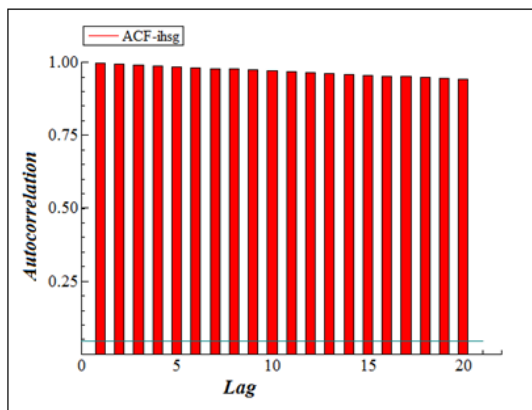
ragam bersyarat hasil peramalan yang diperoleh dari data pemodelan sehingga dapat dilihat kesalahan peramalannya.

15. Melakukan peramalan menggunakan model ARFIMA-HYGARCH terbaik untuk seluruh data guna mendapatkan nilai ramalan beberapa periode kedepan.

HASIL DAN PEMBAHASAN


Pengujian *Long Memory*

Sebelum melakukan pembentukan model ARFIMA, dilakukan pengujian *long memory* pada data *in sample* untuk mengetahui ada tidaknya ketergantungan jangka panjang. Pengujian *long memory* dilakukan dengan melihat plot ACF, plot periodogram dan uji Hurst. Plot ACF ditunjukkan pada Gambar 1 dan plot periodogram ditunjukkan pada Gambar 2.



Gambar 1. Plot ACF data IHSG

Berdasarkan Gambar 1 dapat diketahui bahwa autokorelasinya turun lambat secara hiperbolik. Oleh karena itu, dapat dikatakan data memiliki ketergantungan jangka panjang (*long memory*).



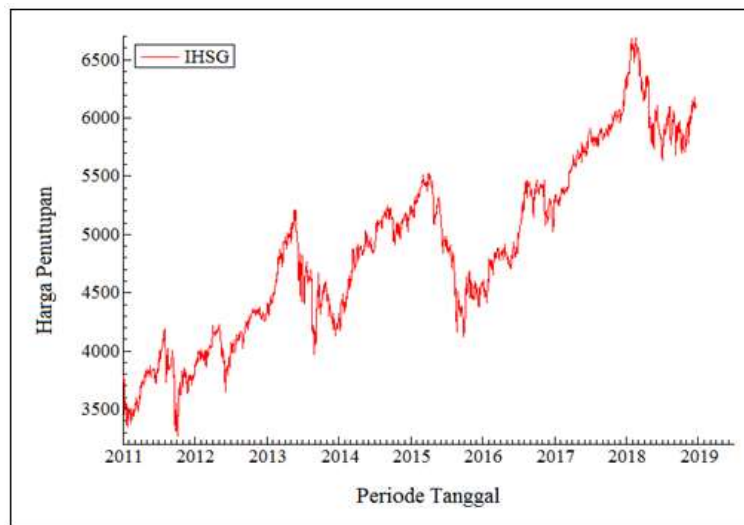
Gambar 2. Plot Periodogram

Berdasarkan Gambar 2, dapat diketahui bahwa bentuk plot periodogram untuk frekuensi yang semakin mendekati nol meningkat menuju nilai yang sangat besar tetapi berhingga. Oleh karena itu, dapat di katakan data memiliki ketergantungan jangka panjang (*long memory*).

Uji *Hurst* digunakan untuk pengujian secara formal dalam memeriksa adanya ketergantungan jangka panjang. Sifat jangka panjang pada data dapat diidentifikasi dengan menggunakan statistik *Hurst*. Hasil dari uji *Hurst* diperoleh nilai statistik *Hurst* sebesar 0,803266. Hasil tersebut menunjukkan bahwa nilai statistik *Hurst* berada pada selang 0,5 sampai dengan 1 ($0,5 < H < 1$), maka dapat disimpulkan bahwa cukup bukti untuk menyatakan data memiliki sifat ketergantungan jangka panjang (*long memory*).

Pembentukan model ARFIMA

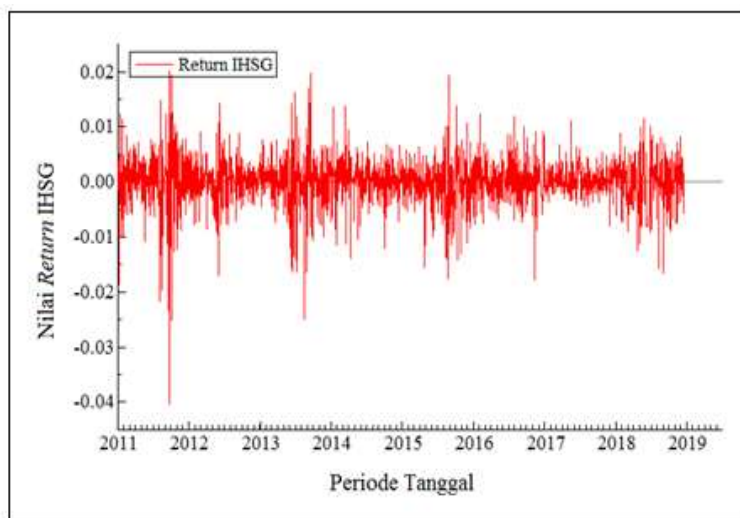
Pada pembentukan model ARFIMA dilakukan identifikasi model dengan melihat plot deret waktu data IHSG terlebih dahulu. Plot deret waktu dari data IHSG disajikan pada Gambar 3.



Gambar 3. Plot deret waktu data IHSG

Berdasarkan Gambar 3 diketahui bahwa data IHSG terus berfluktuasi menunjukkan pola naik dan turun. Jika dilihat dari Gambar 1 data dicurigai tidak stasioner terhadap varian dan mean. Berdasarkan hasil uji ADF dihasilkan nilai p -value 0,1518 lebih dari taraf nyata 5%. Berarti terima hipotesis nol, sehingga data IHSG tidak stasioner. Sehingga perlu dilakukan transformasi dan pembedaan (*differencing*).

Menurut Sanusi (2017), Nilai *Return* yang diperoleh dari $\log\left(\frac{Y_t}{Y_{t-1}}\right)$ sama halnya melakukan pembedaan dan transformasi logaritma pada nilai harian IHSG sehingga data menjadi stasioner. Berikut plot deret waktu dari *return* IHSG.



Gambar 4. Plot deret waktu data *return* IHSG

Berdasarkan Gambar 4 dapat dilihat bahwa data *return* IHSG berfluktuasi disekitar rata-rata mendekati nol. Volatilitas paling tinggi

terjadi pada tahun 2011. Pola tinggi menandakan bahwa ragam galat dari *return* IHSG heterogen. Volatilitas tinggi berada di

wilayah positif dan negatif serta fluktuasi yang lebih tinggi cenderung bergerombol dan dipisahkan oleh periode yang fluktuasinya relatif rendah. Dengan demikian, Gambar 4 menunjukkan adanya pengelompokkan volatilitas (*volatility clustering*) dimana *return* yang besar cenderung diikuti oleh *return* yang kecil pada ukuran yang sama. Berdasarkan hasil uji ADF untuk data *return* IHSG, dihasilkan nilai *p-value* 0,000 yang kurang dari taraf nyata 5%. Berarti tolak hipotesis nol dan terima hipotesis satu, sehingga data *return* IHSG stasioner.

Dalam identifikasi model ARFIMA, juga ditentukan nilai *d* dengan metode *Exact Maximum Likelihood* (EML). Hasil dari penentuan *d* dengan *Oxmetrics 7.2* diperoleh nilai $d = -0,0102919$. Oleh sebab nilai *d* telah dipunyai, maka ditetapkan beberapa kemungkinan model ARFIMA. Identifikasi model ARFIMA didapatkan berdasarkan plot ACF dan plot PACF. Diketahui bahwa pada plot ACF terdapat empat *lag* yang keluar sehingga ordo MA(4). Pada plot PACF terdapat lima *lag* yang keluar sehingga ordo AR(5).

Adapun dugaan model untuk proses *long memory* adalah model ARFIMA yaitu ARFIMA (2, *d*, 0), ARFIMA (2, *d*, 1), ARFIMA (2, *d*, 2), ARFIMA(2, *d*, 3), ARFIMA (2, *d*, 4), ARFIMA (3, *d*, 0), ARFIMA (3, *d*, 1), ARFIMA (3, *d*, 2), ARFIMA (3, *d*, 3), ARFIMA (3, *d*, 4), ARFIMA (4, *d*, 0), dan ARFIMA (5, *d*, 4) dengan $d = -0,0102919$.

Tahap selanjutnya adalah estimasi parameter untuk memperoleh koefisien-koefisien dan nilai probabilitas dari parameter model yang diduga. Suatu model ARFIMA dikatakan signifikan apabila *p-value* < 0,05. Berdasarkan hasil estimasi parameter, dipilih beberapa model yang signifikan dengan *p-value* < 0,05 yaitu ARFIMA(2, *d*, 1), ARFIMA(2, *d*, 2), ARFIMA(2, *d*, 4), dan ARFIMA(5, *d*, 4) yang merupakan model ARFIMA tanpa konstanta. Dari model ARFIMA signifikan yang telah diperoleh, dilakukan uji diagnostik yang memberikan hasil bahwa keempat model tersebut terindikasi heteroskedastisitas. Oleh sebab hasil uji diagnostik untuk keempat model sama, model

terbaik ARFIMA dipilih berdasarkan nilai AIC. Nilai AIC dari model ARFIMA yang signifikan disajikan pada Tabel 1.

Model	AIC
ARFIMA(2, -0,0102919,1)	-7.95586202
ARFIMA(2, -0,0102919,2)	-7.96284069
ARFIMA(2, -0,0102919,4)	-7.96649618
ARFIMA(5, -0,0102919,4)	-7.97252189

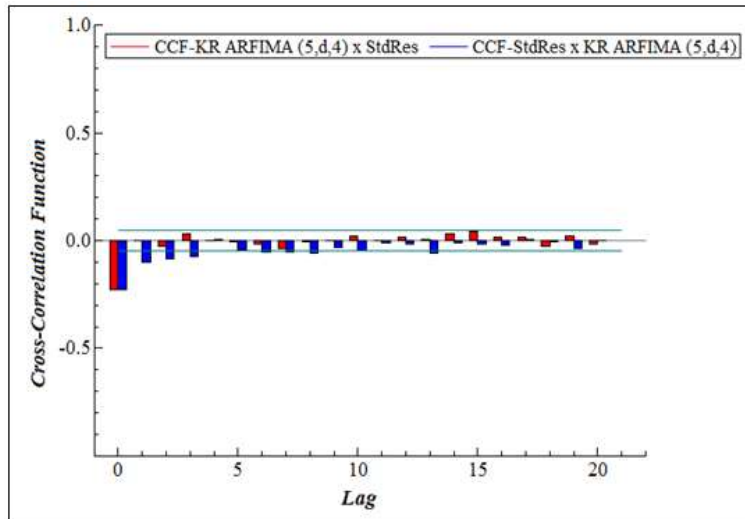
Tabel 1. Nilai AIC Model ARFIMA Signifikan

Berdasarkan Tabel 1, model terbaik ARFIMA adalah ARFIMA (5,-0.0102919,4) karena memiliki nilai AIC terkecil. Persamaan model ARFIMA (5,-0.0102919,4) yaitu

$$Y_t = 0,43633Y_{t-1} + 0,41276Y_{t-2} + 0,18311Y_{t-3} - 0,700292Y_{t-4} + 0,09187Y_{t-5} + a_t - 0,408465a_{t-1} - 0,431537a_{t-2} - 0,338160a_{t-3} + 0,720891a_{t-4}$$

Menentukan Model ARFIMA-HYGARCH

Model terbaik ARFIMA telah diperoleh. Namun, residual model tersebut terindikasi heteroskedastisitas sehingga dilakukan pembentukan model ARFIMA-ARCH. Pembentukan model ARFIMA-ARCH diawali dengan uji ARCH-LM yang memberikan hasil bahwa terdapat efek ARCH pada residual model ARFIMA terbaik. Oleh sebab efek ARCH tersebut signifikan sampai pada *lag* ke-50 maka model ARFIMA-ARCH tidak cocok sehingga dibentuk model ARFIMA-GARCH. setelah diperoleh model ARFIMA-GARCH terbaik model tersebut diuji apakah terdapat efek asimetrik atau tidak. Efek asimetrik diuji dengan *Sign Bias Test* (SBT) dan dengan melihat korelasi antara ϵ_t (standar residual kuadrat model *Box-Jenkins*) dengan ϵ_{t-p} (*lag* standar residual model GARCH) dengan menggunakan *cross correlation* atau korelasi silang. Berdasarkan uji SBT Dengan bantuan *software Oxmetrics 7.2* diperoleh *p-value* (0,00509) yang lebih kecil dibandingkan taraf nyata 5%. Artinya hipotesis nol ditolak. Hal tersebut menunjukkan adanya pengaruh asimetrik pada data. Kemudian untuk hasil plot *cross correlation* disajikan pada Gambar 5.



Gambar 5. Plot Plot korelasi silang antara ε_t (standar residual kuadrat model ARFIMA) dengan ε_{t-p} (lag standar residual model GARCH)

Dari Gambar 5 diketahui bahwa terdapat efek asimetrik sehingga data dimodelkan dengan model ragam GARCH asimetrik, diantaranya adalah model ARFIMA-GARCH, ARFIMA-IGARCH, ARFIMA-FIGARCH, dan

ARFIMA-HYGARCH. Masing-masing model di estimasi parameternya. Estimasi parameter beberapa model GARCH asimetrik menggunakan *software Oxmetrics 7.2* disajikan dalam Tabel 2.

Tabel 2. Estimasi Parameter ARFIMA-GARCH Asimetrik

Model	Parameter	Coefficient	P-value
ARFIMA(5,-0,0102919,4)-GARCH(1,1)	Alpha1	0.086256	0.0003
	Beta1	0.897263	0.0000
ARFIMA(5,-0,0102919,4)-IGARCH(1,1)	Alpha1	0.095292	0.0001
	Beta1	0.904708	0.0000
ARFIMA(5,-0,0102919,4)-FIGARCH(1,d,1)	Beta1	0.626170	0.0000
	Phi1	0.249770	0.0055
	d-Figarch	0.527021	0.0003
	delta	0.000280	0.9965
ARFIMA(5,-0,0102919,4)-HYGARCH(1,d,1)	Log Alpha	-0.056445	0.2045
	Beta1	0.681418	0.0000
	Phi1	0.213124	0.0058
	d-Figarch	0.653263	0.0000
	delta	0.060254	0.0022

Hasil dari estimasi parameter diperoleh bahwa semua model signifikan pada taraf nyata 5% sehingga langkah selanjutnya adalah uji diagnostik sisaan model yang meliputi uji

kenormalan sisaan, uji non autokorelasi sisaan, dan uji non heteroskedastisitas sisaan. Hasil dari uji diagnostik sisaan ARFIMA-GARCH Asimetrik ditunjukkan pada Tabel 3.

Tabel 3. Hasil uji diagnostik sisaan model ARFIMA-GARCH asimetrik

Model	Normalitas	Non Autokorelasi	Non Heteroskedastisitas
ARFIMA(5,-0,0102919,4)-GARCH(1,1)	Tidak	Iya	Iya
ARFIMA(5,-0,0102919,4)-IGARCH(1,1)	Tidak	Iya	Iya
ARFIMA(5,-0,0102919,4)-FIGARCH(1,d,1)	Tidak	Iya	Iya
ARFIMA(5,-0,0102919,4)-HYGARCH(1,d,1)	Tidak	Iya	Iya

Tabel 4. Perbandingan Ringkasan Estimasi Parameter Model Ragam Silmultan Berdasarkan Information Criterion

Parameter	ARFIMA (5,d,4)-GARCH (1,1)	ARFIMA (5,d,4)-IGARCH(1,1)	ARFIMA (5,d,4)-FIGARCH(1,d,1)	ARFIMA (5,d,4)-HYGARCH(1,d,1)
C	0.000278	0.000289	0.000220	-
ω	0.364764	0.212788	0.646149	1.010342
α	0.086256	0.095292	0.249770	-0.056445
β	0.897263	0.904708	0.626170	0.681418
γ	-	-	-	0.213124
δ	-0.017373	-0.020226	0.000280	0.060254
d	-	-	0.527021	0.653263
Log-Likelihood	7962.520	7959.187	7962.289	7963.609
AIC	-8.197545126	-8.195138731	-8.1962754	-8.197636926
SC	-8.211803929	-8.20839698	-8.211536751	-8.212898277

Dari hasil ketiga uji tersebut diketahui bahwa semua model yang signifikan sama untuk semua uji diagnostik yaitu keempat model memiliki residual yang tidak berdistribusi normal, tidak terindikasi autokorelasi, dan tidak terindikasi heteroskedastisitas. Maka model terbaik ARFIMA GARCH asimetrik terbaik dipilih berdasarkan AIC dan SC terkecil. Berdasarkan Tabel 4, model GARCH asimetrik yang memiliki nilai AIC dan SC terkecil adalah ARFIMA (5,d,4)-HYGARCH (1,d,1).

Model ARFIMA (5,d,4)-HYGARCH (1,d,1) dapat ditulis sebagai berikut.

Fungsi rata-rata ARFIMA (5,d,4) :

$$Y_t = 0,43633Y_{t-1} + 0,41276Y_{t-2} + 0,18311Y_{t-3} - 0,700292Y_{t-4} + 0,09187Y_{t-5} + a_t$$

$$-0,408465a_{t-1} - 0,431537a_{t-2} - 0,338160a_{t-3} + 0,720891a_{t-4}$$

Fungsi ragam HYGARCH (1,d,1) :

$$h_t = 1,010342 + \left(1 - \frac{1-0,060254(L)}{1-0,681418(L)} (1 + [(-0,056445)(1-L)^{0,653263} + 0,056445]) \right) e_t^2$$

Setelah diperoleh model GARCH asimetrik terbaik langkah selanjutnya yaitu melakukan validasi peramalan menggunakan model ARFIMA (5,d,4)-HYGARCH(1,d,1). Validasi model memberikan hasil bahwa model cukup baik digunakan untuk meramalkan nilai *return* IHSG selama sebulan ke depan.

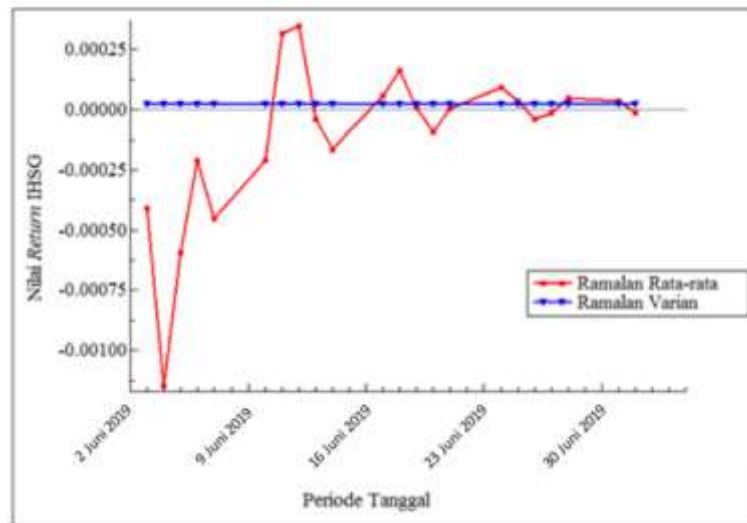
IHSG yang disajikan pada Tabel 5 dan grafiknya di sajikan pada Gambar 6.

Peramalan

Selanjutnya dilakukan peramalan untuk 22 periode ke depan. hasil peramalan menghasilkan nilai varian/ragam dan nilai rata-rata *return*

Tabel 5. Hasil peramalan untuk 22 periode kedepan

Tanggal	Peramalan untuk rata-rata	Peramalan untuk Varian
2019-06-03	-0,000410088	2,51E-05
2019-06-04	-0,001148192	2,34E-05
2019-06-05	-0,000592364	2,37E-05
2019-06-06	-0,000210985	2,37E-05
2019-06-07	-0,000450597	2,36E-05
2019-06-10	-0,000209112	2,34E-05
2019-06-11	0,000318025	2,32E-05
2019-06-12	0,000348497	2,3E-05
2019-06-13	-3,82106E-05	2,28E-05
2019-06-14	-0,000164258	2,26E-05
2019-06-17	5,96812E-05	2,24E-05
2019-06-18	0,000165105	2,23E-05
2019-06-19	1,02158E-05	2,21E-05
2019-06-20	-9,19079E-05	2,2E-05
2019-06-21	5,54578E-06	2,18E-05
2019-06-24	9,46002E-05	2,17E-05
2019-06-25	3,58521E-05	2,16E-05
2019-06-26	-3,98348E-05	2,15E-05
2019-06-27	-1,00978E-05	2,14E-05
2019-06-28	4,8521E-05	2,13E-05
2019-07-01	3,48838E-05	2,13E-05
2019-07-02	-1,07474E-05	2,12E-05



Gambar 6. Plot ramalan nilai varian dan *mean* 22 periode kedepan

Dari hasil peramalan diperoleh bahwa nilai ramalan varian berada di atas nilai ramalan *mean* kecuali untuk periode tanggal 11 Juni 2019, 12 Juni 2019, 17 Juni 2019, 18 Juni 2019 dan 24 Juni 2019. Pada periode tersebut plot ramalan varian berada di bawah plot ramalan *mean*. Ini berarti pada periode tersebut risiko investor dalam berinvestasi di pasar modal akan lebih besar. Utamanya untuk periode 12 Juni 2019 investor lebih baik tidak melakukan investasi karena pada periode tersebut nilai ramalannya paling tinggi. Maka, jika investor melakukan transaksi beli pada periode tersebut, risiko yang ditanggung akan lebih besar. Dengan memperhatikan peramalan varian dan *mean* untuk beberapa periode ke depan dapat disimpulkan bahwa data IHSN berfluktuasi menunjukkan pola naik dan turun.

SIMPULAN

Simpulan yang diperoleh dari penelitian ini adalah (1) model ARFIMA-HYGARCH terbaik adalah model ARFIMA (5,d,4)-HYGARCH (1,d,1), (2) hasil peramalan *return* IHSN untuk 22 periode kedepan berfluktuasi menunjukkan pola naik dan turun. untuk periode tanggal 11 Juni 2019, 12 Juni 2019, 17 Juni 2019, 18 Juni 2019 dan 24 Juni 2019 sebaiknya investor tidak melakukan investasi. Khususnya untuk periode 12 Juni 2019, karena pada periode tersebut nilai ramalannya paling tinggi sehingga risiko yang akan ditanggung investor akan lebih besar.

SARAN

Berdasarkan hasil penelitian yang telah dilakukan dan keterbatasan-keterbatasan yang diperoleh dalam penelitian ini, maka saran yang

dapat diberikan peneliti yaitu (1) Pada penelitian ini, model HYGARCH digunakan untuk mengatasi masalah heteroskedastisitas yang terjadi pada residual model ARFIMA dan efek asimetrik yang ada dalam data keuangan. Untuk penelitian selanjutnya, disarankan untuk melakukan olah data dengan menambahkan metode lain yang dapat mengatasi masalah autokorelasi dan distribusi yang tidak normal yang terjadi pada residual ARFIMA. (2) Investor sebaiknya jangan melakukan investasi pada tanggal 11 Juni 2019, 12 Juni 2019, 17 Juni 2019, 18 Juni 2019 dan 24 Juni 2019. Utamanya pada tanggal 12 Juni 2019 investor jangan melakukan investasi karena pada tanggal tersebut berdasarkan hasil peramalan yang dilakukan oleh peneliti dan data real di lapangan risiko investor dalam berinvestasi di pasar modal lebih besar.

DAFTAR PUSTAKA

- Baillie, R.T, Mikkelsen, & Bollerslev T. (1996). Fractionally integrated generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*,74, 3-30.
- Bollerslev T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31, 307-327.
- Chang C.L., McAleer M., & Tansuchat R. (2012). Modelling Long Memory Volatility in Agricultural Commodity Futures Returns. *Annals of Financial Economics (AFE)*. World Scientific Publishing Co. Pte. Ltd. Vol. (02):1-27.

- Davidson, J. (2004). Moment and memory properties of linear conditional heteroscedasticity models and a new model. *Journal of Business and Economic Statistics*, 22, 16-29.
- Damayanti, S. (2012). *Long memory process menggunakan model autoregressive fractionally integrated moving average (ARFIMA(p,d,q))*. Artikel. Padang: Universitas Andalas.
- Doornik, J.A., & Ooms M. (2012). *A Package for Estimating, Forecasting and Simulating ARFIMA Models: Arfima Package 1.6 for Ox*. Rotterdam: Nuffield College.
- Engle R.F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.
- Francq, C. & Zakoian, J.M. (2010). *GARCH Models (Structure, Statistical Inference and Financial Applications)*. Lille:A John Wiley and Sons, Ltd.
- Hongngoe, T. (2014). Arfima-Figarch vs. Arfima-Hygarch: Case Study ETF Returns of Emerging Asian Countries. *Asian Journal of finance & Accounting*, 6, 171-194.
- Hosking, J. R. M. (1981). *Fractional Differencing*. *Biometrika*. Vol. (68): 165-176.
- Juanda B & Junaidi. (2012). *Ekonometrika Deret Waktu*. Bogor (ID): IPB Press.
- Ningrum, L.K. (2009). Penerapan Model *Autoregressive Fractionally Integrated Moving Average (ARFIMA)* dalam Peramalan Suku Bunga Sertifikat Bank Indonesia (SBI) [skripsi]. Surakarta: Universitas Sebelas Maret Surakarta.
- Sanusi, M.A. (2017). *Pemodelan Volatilitas Long Memory Pada Indeks Harga Saham Gabungan (IHSG) Menggunakan Model FIGARCH* [skripsi]. Bogor (ID): Institut Pertanian Bogor.