
PERFORMANSI GPH TERKOREKSI TERHADAP SKIP SAMPLING PADA PROSES *LONG MEMORY* DAN *SPURIOUS LONG MEMORY*

¹Gede Suwardika, ²Heri Kuswanto

¹Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Terbuka

²Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember, Surabaya

Alamat e-mail : ¹isuwardika@ut.ac.id

ABSTRAK

Proses *long memory* telah diamati dalam banyak hal, seperti hidrologi, telekomunikasi, ekonomi dan keuangan. *Long Memory* adalah salah satu fenomena dalam *time series*, dimana dependensi antara kejadian masih ada dan dapat diamati untuk waktu yang lama, yang dicirikan oleh nilai *difference* yang tidak bulat (*fractional*). Parameter *differencing* ini biasanya diestimasi menggunakan GPH *estimator*. Dengan estimator ini, seringkali menghasilkan kesimpulan yang *spurious* untuk model-model seperti Estar, Markov switching, STOP-BREAK dan level shift. Tesis ini akan melakukan simulasi model-model tersebut dan estimasi parameter GPH terkoreksi pada proses agregasi. Selanjutnya dilakukan pemodelan menggunakan ARFIMA dan Markov Switching pada data *stock price* LQ45. Pengidentifikasian sifat *Long Memory* dalam suatu series data dapat dilakukan dengan agregasi baik *flow aggregation* maupun *stock aggregation*. Dimana pada kasus ini hanya menggunakan *stock aggregation*. Berdasarkan hasil simulasi, stok agregasi ini menghasilkan perilaku yang sama dalam parameternya untuk *Spurious Long Memory*, yaitu random, tidak memiliki *trend* turun atau naik jika seriesnya diagregasi. Pemodelan dari absolut *return* saham dari kedua series terpilih yaitu Indosat dan Telkom, didapatkan bahwa model Markov Switching lebih baik dibandingkan model ARFIMA. Hasil aplikasi saham menunjukkan nilai estimasi GPH untuk data teragregasi memiliki pola yang random, dilihat dari nilai AIC terkecil berdasarkan kedua model, model ARFIMA memiliki nilai AIC terkecil, sehingga GPH standar tidak bisa digunakan untuk mendeteksi *Spurious Long Memory*, dimana *return* saham dari kedua series adalah mengandung *outlier*.

Kata Kunci : *Long Memory, GPH Estimator, ARFIMA, Markov Swtiching, Stock Price*

PENDAHULUAN

Proses *long memory* telah diamati dalam banyak hal, seperti hidrologi, telekomunikasi, ekonomi dan keuangan. *Long memory* adalah salah satu fenomena dalam *time series*, dimana dependensi antara kejadian masih ada dan dapat diamati untuk waktu yang lama. *Long memory* merupakan kondisi dimana setiap observasi memiliki korelasi yang cukup

kuat dengan observasi lainnya meskipun jarak waktu antar observasi cukup jauh. *Long memory* dicirikan oleh plot *Autocorrelation Function* (ACF) yang turun secara *hyperbolic* atau juga dari nilai *difference* yang tidak bulat (*fractional*). Parameter *differencing* ini biasanya diestimasi menggunakan GPH estimator yang diperkenalkan oleh Geweke dan Porter Hudak^[2]. Untuk mendeteksi adanya *long memory* pada data, dapat dilakukan estimasi *d* dengan

menggunakan *Hurst Exponent* maupun uji *Rescaled range statistics (R/S)* dan *Modified rescaled range statistics (MR/S)*, *rescaled varians (V/S)*, *GPH (long pe-riodgram estimation)* dan lain sebagainya.

Pada penelitian sebelumnya telah dikembangkan untuk menguji *spurious long memory*^[4]. Kedua peneliti menggunakan sifat *invariance* dari parameter *long memory* terhadap temporal aggregation (*flow aggregation*). Adapun hasil dari penelitian tersebut menunjukkan bahwa *flow aggregation* dapat diterapkan dan dapat membedakan *spurious long memory* dengan tingkat akurasi yang bagus. Namun, tes yang sudah dikembangkan tidak cukup efisien jika diterapkan pada data hasil *stock aggregasi (skip sampling)*. Artinya, jika dilakukan pengujian terhadap data hasil *stock aggregation* dengan tes tersebut, kesimpulan yang didapatkan hanya sebatas prosesnya *long memory atau spurious*.

Penelitian tentang kekuatan tes yang diterapkan pada kasus *stock aggregation* belum pernah dilakukan. Kedua prosedur agregasi memiliki sifat yang sama tentang *invariance* dari parameter *long memory*^[1]; ^[6]. Dimana kedua agregasi memiliki prosedur sampling yang berbeda sehingga konsekuensinya tidak bisa begitu saja digeneralisasi bahwa kekuatan tes dari *stock aggregation* sama dengan *flow aggregation*. Oleh karena itu, pada penelitian ini akan dilakukan simulasi untuk mempelajari pattern yang terbentuk dari estimasi GPH pada data *long memory* dan *spurious process* yang teragregasi. Estimasi GPH yang diaplikasikan adalah *bias corrected GPH*^[5]. Diharapkan dari estimator ini, akan didapatkan kesimpulan mengenai sifat *invariance long memory* pada proses tersebut, sehingga hasil simulasi bisa dijadikan sebagai dasar membedakan *long memory* dan *spurious long memory*. Saham merupakan contoh aplikasi data series yang dihasilkan dari

proses *stock aggregation* atau *skip sampling*. Hasil simulasi akan divalidasi dengan data harga saham untuk bisa mengetahui apakah kesimpulan yang didapatkan dari simulasi sesuai dengan data empiris.

METODE PENELITIAN

Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder, yaitu data harian dari dua saham Indosat dan Telkom, yang termasuk ke dalam saham LQ45 dari tahun 2000 sampai 2011 yang diambil adalah saham saham bidang telekomunikasi.

Metode Analisis

Langkah analisis yang dilakukan untuk mencapai tujuan dari penelitian ini adalah sebagai berikut :

1. Melakukan proses simulasi dengan data bangkitan dan mengestimasi GPH terkoreksi dengan $n = 500$ dan $n = 2000$. Simulasi dilakukan pada masing-masing jenis agregasi. Setiap jenis agregasi dilakukan pengulangan simulasi sebanyak 1000 kali pada tiap-tiap level agregasi m , dimana $m = 1, 2, \dots, 10$ dan dilakukan untuk setiap fraksi integrasi d dengan $d = 0,1; 0,2; 0,3; 0,4$. Setiap data hasil dari agregasi akan diestimasi nilai parameter d dan standart deviasinya dengan estimator GPH dengan *bandwith* optimum 0,5. Jenis-jenis agregasi yang digunakan adalah :

a. Markov-Switching Process

Model yang digunakan dalam proses Markov-switching adalah :

$$x_t = \begin{cases} \phi_1 x_{t-1} + \varepsilon_t & \text{jika } \delta_t = 1 \\ \phi_2 x_{t-1} + \varepsilon_t & \text{jika } \delta_t = 2 \end{cases}$$

Dengan $\varepsilon_t \sim N(0,1)$ dan peluang p_{00} dan p_{11}

Model *Markov Switching* yang dibangkitkan ada 3 macam, yaitu:

1. MS 1 : ($\Phi_1 = 0.5, \Phi_2 = -0.5, P_{00} = 0.9, P_{11} = 0.9, bandwidth = 0.5$)
2. MS 2 : ($\Phi_1 = 0.7, \Phi_2 = -0.2, P_{00} = 0.9, P_{11} = 0.9, bandwidth = 0.5$)
3. MS 3 : ($\Phi_1 = 0.5, \Phi_2 = -0.4, P_{00} = 0.9, P_{11} = 0.9, bandwidth = 0.5$)

b. *STOP-BREAK Process*

Model yang digunakan dalam proses *STOP-BREAK* adalah :

$$x_t = \mu_t + \varepsilon_t, \mu_t = \mu_{t-1} + \frac{\varepsilon_{t-1}^2}{\gamma + \varepsilon_{t-1}^2} \varepsilon_{t-1}$$

Dengan $\varepsilon_t \sim N(0,1)$

Model *Stop Break* yang dibangkitkan ada 3 macam, yaitu:

1. *Stop Break* 1: (gamma 50)
2. *Stop Break* 2: (gamma 100)
3. *Stop Break* 3: (gamma 180)

c. *Stationary Random Level Shift Process*

Model yang digunakan dalam proses *Stationary random level shift* adalah :

$$x_t = \mu_t + \varepsilon_t, \mu_t = (1 - j_t)\mu_{t-1} + j_t\varepsilon_t$$

Dengan j_t mengikuti IID Bernoulli (p), ε_t dan ε_t adalah proses *short memory* dengan mean 0 dan varian $\sigma_{\varepsilon_t}^2$

Model *Random Level Shift* yang dibangkitkan ada 3 macam, yaitu:

1. *Random Level Shift* 1 (Probabilitas=0.005)
 2. *Random Level Shift* 2 (Probabilitas=0.01)
 3. *Random Level Shift* 3 (Probabilitas=0.1)
2. Mengevaluasi pattern yang teramati dari hasil simulasi untuk masing-masing proses

- a. Mengestimasi nilai GPH terkoreksi pada data 3 saham LQ45 dengan sampling interval 10 serta menduga model *long memory/spurious* berdasarkan hasil simulasi
- b. Setiap data saham dibuat plot ACP
- c. Pada data saham akan dilakukan agregasi dengan stock aggregation dimana level agregasi $m = 1, 2, \dots, 10$, dan diestimasi nilai d serta diamati polanya
- d. Memodelkan data return saham LQ45 dengan ARFIMA sebagai pendekatan long memory
 - Plot ACF
 - Estimasi nilai d dengan GPH estimator
 - Estimasi parameter AR dan MA
 - Pengujian parameter model ARFIMA
 - Pengujian residual untuk diagnostic check
- e. Memodelkan data LQ45 dengan *Markov Switching* sebagai pendekatan *spurious long memory* dengan cara Membentuk dan memperoleh hasil pemodelan *Markov Switching* dengan langkah sebagai berikut.
 - Estimasi parameter AR dan MA
 - Membentuk matrik transisi probabilitas
 - Melakukan estimasi probabilitas pada setiap *state* untuk sesuai persamaan $P(S_{p+1} = i | Y_{t-2})$, untuk $i = 1, 2, \dots, k$
 - Membentuk model *Markov switching* sesuai persamaan $y_t = \mu_{S_t} + X_t\phi_{S_t} + a_t$
- f. Membandingkan keakuratan hasil pemodelan antara ARFIMA dengan *Markov Switching* dari kedua data saham telekomunikasi tersebut dengan memilih model

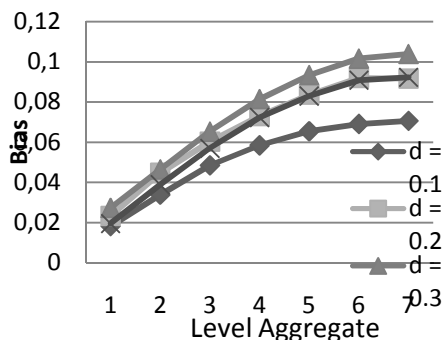
terbaik berdasarkan nilai AIC terkecil.

Membandingkan hasil simulasi dengan hasil pemodelan data empiris.


HASIL PENELITIAN

Simulasi Stock Aggregation

Hasil estimasi GPH terkoreksi (GPH1) dan GPH tak terkoreksi (GPH2) untuk data *long memory* yang di skip sampling dimana hasil Simulasi Stock Aggregation $n = 500$ menjelaskan GPH terkoreksi hanya mampu mengestimasi sampai dengan level agregasi 8. Hal ini dikarenakan jumlah sampel yang kecil, sehingga dengan agregasi 10, Salah satu komponen penting dari untuk mendekteksi pattern hasil estimasi adalah bias estimasi.



Gambar 1 GPH Terkoreksi untuk $n = 500$




Gambar 2 GPH Tak Terkoreksi untuk $n = 500$


Pada Gambar 1 dan 2 dijelaskan bahwa untuk data dengan level *aggregation* yang semakin besar akan menghasilkan bias yang cenderung lebih besar juga. Namun, terdapat perbedaan jelas dari kedua plot diatas, dimana bias yang dihasilkan oleh

GPH terkoreksi cenderung monoton naik seiring dengan naiknya level agregasi. Begitu juga dengan bias hasil dari GPH tak terkoreksi

Untuk melihat apakah hasil diatas apakah cukup konsisten, berikut adalah hasil simulasi penggunaan *stock aggregation* dengan $n=2000$. Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 3 dan Gambar 4.



Gambar 3 GPH Terkoreksi untuk $n = 2000$



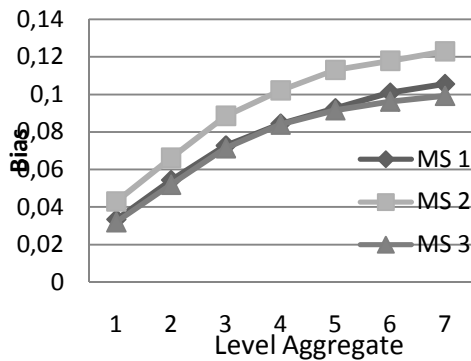
Gambar 4 GPH Tak Terkoreksi untuk $n = 2000$

Gambar 3 serta Gambar 4, jelas menunjukkan bahwa dengan $n = 2000$, pada bandwidth 0,5 menghasilkan bias yang cukup besar. Hal ini ditunjukkan dengan rata-rata parameter d yang dihasilkan untuk masing-masing level agregasi berbeda cukup jauh. Pada semua setting simulasi dengan estimator GPH terkoreksi, teramati jelas bahwa level bias naik dengan naiknya level agregasi, Bias yang dihasilkan oleh GPH tak terkoreksi juga monoton naik, namun dengan besaran yang tidak konstan.


Simulasi Stock Aggregation pada model spurious long memory

Model Markov Switching

Hasil estimasi GPH untuk data *Markov switching* yang telah teragregasi secara skip sampling seperti halnya pada simulasi sebelumnya, untuk jumlah sampel 500 tidak mencukupi dalam estimasi parameter GPH terkoreksi jika diagregasi 9 atau 10. Pemilihan parameter model *Markov Switching* sudah tepat dalam arti telah mampu menghasilkan parameter d yang berada pada domain long memory. Hal ini terlihat dari parameter d pada agregasi 1. Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 5 dan Gambar 6.




Gambar 5 GPH Terkoreksi untuk n = 500




Gambar 6 GPH Tak Terkoreksi untuk n = 500

Model *markov switching* merupakan salah satu metode dalam menangani adanya lompatan model dari regime satu ke *regime* yang lainnya. Penggunaan properti *stock aggregation* dalam kasus ini

dapat menyebabkan nilai d yang dihasilkan naik dan turun atau tidak monoton. bahwa pada GPH Terkoreksi terlihat bahwa tidak adanya trend tertentu dari estimasi parameter d seiring dengan naiknya level agregasi, tetapi pada GPH tak terkoreksi tidak terlihat *trend* yang monoton seiring dengan bertambahnya level agregasi. Selanjutnya akan disimulasikan dengan sampel yang lebih besar yaitu 2000. Hasil simulasi penggunaan *stock aggregation* pada bangkitan model *markov switching* dengan sampel 2000 menunjukkan bias yang terjadi disajikan pada Gambar 7 dan Gambar 8.



Gambar 7 GPH Terkoreksi untuk n = 2000



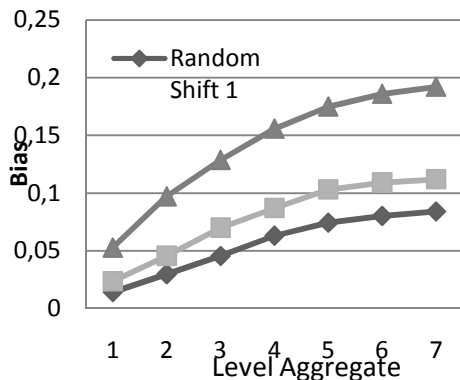
Gambar 8 GPH Tak Terkoreksi untuk n = 2000

Hasil simulasi kembali menunjukkan sekaligus memperkuat keterangan bahwa model *markov switching* menghasilkan pattern yang berbeda untuk kedua macam GPH dengan harapan akan semakin memperkuat kesimpulan di awal saat mensimulasikan *markov switching* dengan sampel sebanyak 500. Gambar 8 menunjukkan bahwa penambahan jumlah sampel n tidak memberikan efek signifikan terhadap hasil estimasi parameter d ketika


diaggregasi, plot yang ditampilkan memang jelas tetap menunjukkan bahwa tidak adanya pola yang jelas (random) terhadap naiknya level aggregasi untuk GPH tidak terkoreksi.

Model Stationary Random Level Shift Process

Model kedua yang disimulasikan adalah proses *Stationary random level shift*, hasil simulasi *stock aggregation* untuk model *random level shift* $n = 500$ terlihat jelas dari hasil estimasi parameter di atas, bahwa model *random level shift* dengan parameter di atas mampu menghasilkan parameter d yang termasuk *long memory*. Namun, untuk $p = 0.01$, didapatkan d yang merupakan *long memory nonstasioner*. Untuk memudahkan evaluasi hasil simulasi, akan ditampilkan plot bias estimator. Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 9 dan Gambar 10.



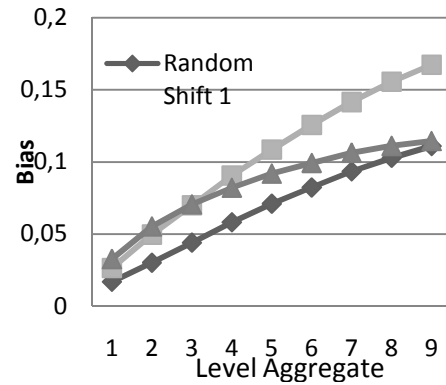
Gambar 9 GPH Terkoreksi untuk $n = 500$



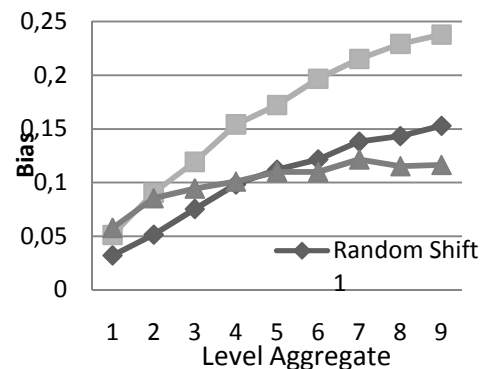
Gambar 10 GPH Tak Terkoreksi untuk $n = 500$

Pada sampel 500 terlihat bahwa dengan penambahan jumlah level tidak memberikan efek signifikan terhadap hasil estimasi parameter d ketika diaggregasi.

Selanjutnya disimulasikan dengan sampel yang lebih besar yaitu 2000. Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 11 dan Gambar 12.



Gambar 11 GPH Terkoreksi untuk $n = 2000$



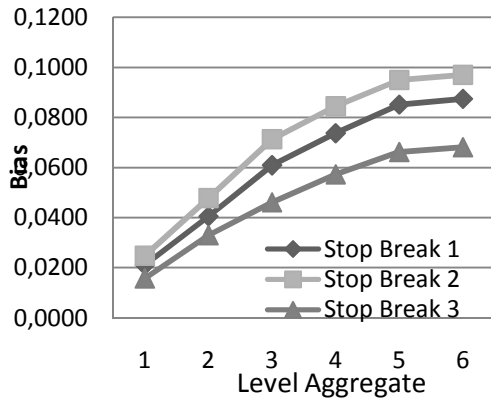
Gambar 12 GPH Tak Terkoreksi untuk $n = 2000$

Hasil simulasi menunjukkan bahwa pada probabilitas dan *pattern* yang berbeda pada kedua macam GPH menunjukkan kembali keterangan bahwa model *random shift* kembali menghasilkan nilai d yang kecil dengan harapan akan semakin jelas menunjukkan kerandoman dari pergerakan parameter d dan memperkuat kesimpulan di awal saat mensimulasikan *random shift* dengan sampel sebanyak 500. Gambar 11 dan Gambar 12, menunjukkan bahwa penambahan jumlah sampel n tidak memberikan efek signifikan terhadap hasil estimasi parameter d ketika diaggregasi, plot yang ditampilkan memang jelas tetap menunjukkan bahwa tidak adanya pola


yang jelas (random) terhadap naiknya level agregasi untuk GPH tidak terkoreksi.

Model Stop Break

Hasil simulasi *stock aggregation* untuk model *stop break* $n = 500$. Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 13 dan Gambar 14.



Gambar 13 GPH Terkoreksi untuk $n = 500$




Gambar 14 GPH Tak Terkoreksi untuk $n = 500$


Dengan pengujian menggunakan tiga parameter berbeda dimana terlihat dengan semakin besarnya penggunaan gamma akan dihasilkan nilai d yang kecil menunjukkan keterangan bahwa model *stop break* menghasilkan nilai d yang kecil dan jelas menunjukkan kerandoman dari pergerakan parameter d , dimana nilai d akan cenderung monoton turun dengan naiknya level agregasi. Gambar 13 dan Gambar 14, menunjukkan bahwa penambahan jumlah level tidak memberikan efek signifikan terhadap hasil estimasi parameter d ketika diagregasi, plot yang ditampilkan memang jelas tetap menunjukkan bahwa tidak adanya pola

yang jelas (random) terhadap naiknya level agregasi.

Selanjutnya akan disimulasikan dengan sampel yang lebih besar yaitu 2000. Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 15 dan Gambar 16.



Gambar 15 GPH Terkoreksi untuk $n = 2000$



Gambar 16 GPH Tak Terkoreksi untuk $n = 2000$

Dengan bertambahnya sampel n terlihat kembali bawah dengan bandwidth 0.5 bahwa model *stop break* menghasilkan nilai d kecil dan random monoton turun yang sangat jelas menunjukkan kerandoman dari pergerakan parameter d . Penambahan jumlah level tidak memberikan efek signifikan juga terhadap hasil estimasi parameter d ketika diagregasi, plot yang ditampilkan juga tetap menunjukkan bahwa tidak adanya pola yang jelas (random) terhadap naiknya level agregasi GPH tidak terkoreksi.

1. Hasil Dan Pembahasan Simulasi

Properti *stock aggregation* dalam mendeteksi fenomena *Long Memory*

dimana bias yang dihasilkan dengan menggunakan agregasi ini lebih besar. Baik menggunakan estimator GPH dengan bandwidth 0,5. Trend estimasi nilai d yang dihasilkan dengan agregasi adalah menurun, artinya semakin besar level agregasi yang digunakan akan cenderung menghasilkan estimasi nilai d yang lebih kecil bahkan bisa saja hampir setengah dari parameter d awalnya dengan tanpa agregasi. Hal ini tidak sesuai dengan gagasan awal bahwa untuk mendeteksi fenomena *Long Memory*, parameter d hasil agregasi tidak berbeda dengan parameter d tanpa agregasi. Namun perlu diakui bahwa meskipun parameter d yang dihasilkan berbeda, namun masih berada dalam range nilai d untuk *Long Memory*. Hal ini bisa saja terjadi karena dengan menggunakan metode *stock aggregation* yang mirip dengan *skip sampling* ini akan menghilangkan beberapa informasi data dan semakin besar level agregasinya akan semakin besar pula informasi yang hilang. Pada kasus bangkitan *Markov Switching*, *Random Level Shift* dan *Stop Break*, pengaruh agregasi ini menunjukkan bahwa tidak ditemukan trend, dimana terlihat pada ketiga model dengan menggunakan sampel 500 dan sampel 2000 tidak terlihat memberikan efek yang signifikan terhadap hasil estimasi parameter d ketika diagregasi dengan GPH terkoreksi maupun GPH tidak terkoreksi.

2. Aplikasi ke Saham LQ45


Bagian ini dimaksudkan untuk memvalidasi hasil simulasi terhadap kasus riil pada LQ45 yang dijadikan bahan studi kasus dalam tesis ini adalah saham Indosat dan Telkom. Kedua jenis indeks saham tersebut diambil datanya mulai awal Januari 2001 hingga akhir Desember 2011. Seperti biasa, yang dianalisis adalah absolut dari nilai *return* harga saham, bukan harga saham secara langsung sebab kenyataannya investor lebih tertarik

mengetahui informasi pergerakan *return* saham daripada harga saham itu sendiri (Ding *et al.*(1993), Andersen *et al.*(2003), Sibbertsen (2004).


3. Identifikasi *Long Memory*

Plot ACF

Cara paling sederhana untuk mendeteksi fenomena *Long Memory* adalah secara visual melalui plot ACF. Jika plot ACF turun secara hiperbolik naik turun seperti gelombang, maka ada indikasi awal bahwa series tersebut masuk ke dalam fenomena *Long Memory*. Hal serupa terjadi pada series saham Indosat dan Telkom, plot ACF dapat dilihat pada Gambar 18.a dan 18.b.



Gambar 18.a Plot ACF Indosat



Gambar 18.b Plot ACF Telkom

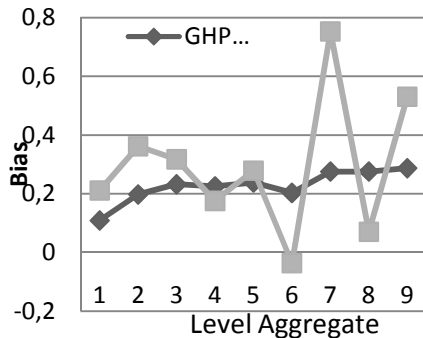
Pada Gambar 18.a dan 18.b tersebut terlihat bahwa plot ACF untuk series Indosat turun secara hiperbolik namun hanya pada beberapa lag saja, sedangkan plot ACF untuk series Telkom nampak jelas turun secara hiperboliknya. Hal ini memberikan dugaan awal bahwa kedua series tersebut tergolong *Long Memory*. Namun begitu, plot ACF hanyalah cara

visual untuk deteksi, kenyataannya seringkali plot ACF tidak menampilkan pola yang sempurna untuk bisa benar-benar memutuskan apakah datanya *long memory* atau tidak.

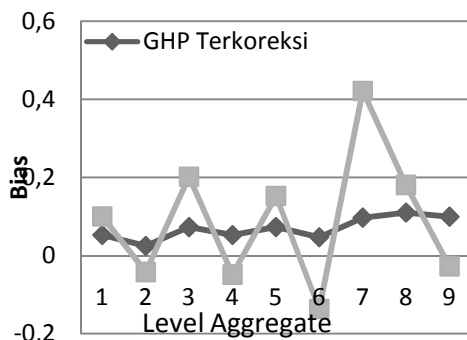
Identifikasi Data Dengan *Stock Aggregation*

Sebagaimana telah disimpulkan dari hasil simulasi bahwa *temporal aggregation* dapat digunakan untuk mengidentifikasi data bersifat *long memory* atau tidak. Oleh karena itu kedua series tersebut akan diidentifikasi dengan menggunakan properti dari salah satu jenis agregasi yang sesuai. Pencatatan harga saham menyerupai sifat dari *skip sampling*, maka untuk mengidentifikasi kedua series ini digunakan *stock aggregation*.

Model GPH tak terkoreksi tidak digunakan untuk mengidentifikasi model, sebagaimana yang dihasilkan dari simulasi.



Gambar 19 Plot Bias Estimasi Nilai d Indosat



Gambar 20 Plot Bias Estimasi Nilai d Telkom

Selanjutnya akan dilakukan identifikasi berdasarkan orde-orde model terbaik berdasarkan nilai AIC terkecil untuk memodelkan ARFIMA (*long memory*) dan

model *Makov Switching* sebagai model *spurious long memory* sehingga didapat model mana yang terbaik (Tabel 10 lihat lampiran). Tabel 10 didapatkan ordo ARFIMA yang berdasarkan nilai terkecil, selanjutnya akan dilakukan cek asumsi *residual white noise* dan berdistribusi normal. *White Noise Test* adalah uji untuk mengetahui apakah residual sudah *white noise*. Statistik uji yang digunakan adalah *Ljung-Box Test* dengan H_0 adalah residual *white noise*. Dari hasil pengujian *white noise*, diketahui bahwa residual dari model tidak *white noise* karena plot *p-value* hingga lag-12 berada di bawah nilai $\alpha = 0.05$ yang berarti tolak H_0 .

Tahapan evaluasi yang lain adalah *Normality Test* yang berguna untuk mengetahui apakah residual sudah berdistribusi normal. Statistik uji yang akan digunakan adalah *Kolmogorov-Smirnov Test* dengan H_0 adalah residual berdistribusi normal. Uji normalitas untuk residual dari model ARFIMA untuk series data indosat, hasil uji menggunakan *Kolmogorof-Smirnov Test* nilai KS = 0.4868 dengan *p-value* = 2.2e-16 kurang dari $\alpha = 0,05$, Oleh karena *p-value* < α , maka tolak H_0 dan disimpulkan bahwa residual yang dihasilkan kedua model tidak berdistribusi normal. Selanjutnya akan dimodelkan untuk series data Telkom. Setelah diperoleh ordo ARFIMA, selanjutnya akan dilakukan uji residual *white noise* dan berdistribusi normal untuk series data Telkom. Dari hasil masing-masing model ARFIMA didapatkan *Ljung-Box Test* untuk uji asumsi residual *white noise* untuk model ARFIMA (1,d,1), (2,d,2) dan (5,d,5) sudah *white noise* karena *p-value* hingga lag-12 berada di atas nilai $\alpha = 0.05$ yang berarti terima H_0 , tetapi pada model ARFIMA (2,d,2) ada yang tidak *white noise* pada lag-6, sehingga tetap diputuskan bahwa tolak H_0 , yang artinya tidak *white noise* pada model tersebut.

Selanjutnya, uji normalitas untuk residual dari model ARFIMA untuk series

data telkom, hasil uji menggunakan *Kolmogorof-Smirnov Test* model ARFIMA pada Tabel 1.

Tabel 1 Normality Test

Model Arfima	N	KS	P-Value
(1,d,1)	3128	0.4874	2.2e-16
(2,d,2)	3127	0.4872	2.2e-16
(5,d,5)	3127	0.4872	2.2e-16

Hasil uji normalitas diperoleh nilai KS dan *p-value*, sehingga dapat disimpulkan untuk ketiga model ARFIMA tersebut menunjukkan bahwa residual tidak berdistribusi normal, dikarenakan nilai *P-value* kurang dari $\alpha = 0,05$, Oleh karena *p-value* < α , maka tolak H_0 , hanya model Arfima (5,d,5) yang nilai *p-value*nya lebih dari $\alpha = 0,05$. Dapat dijelaskan bawah, pada series data Indosat, diduga kemungkinan modelnya ARFIMA (3,d,3) dengan AIC = 8158,22. Sedangkan untuk series data Telkom, menunjukkan kemungkinan modelnya adalah ARFIMA (1,d,1) dengan AIC = 8406,35, ARFIMA (2,d,2) dengan AIC = 8402,73, serta ARFIMA (5,d,5) dengan AIC = 8400,23. Sehingga jika dilihat dari estimasi parameter pada Tabel di atas untuk semua model yang signifikan, model dugaan ARFIMA untuk series data Indosat adalah ARFIMA (3, 0.18888, 3) dan series data Telkom adalah ARFIMA (5, 0.18712, 5).

4. Pemodelan Markov Switching

Pada model *Markov Switching* dengan 2 *regime*, dilakukan *fitting* model secara langsung yang menghasilkan AIC terkecil dan menghasilkan parameter yang signifikan pula, dengan demikian akan dilakukan pemilihan ordo berdasarkan parameter yang sesuai terlebih dahulu.

A. Series Data Indosat

Berdasarkan nilai AIC dan parameter yang signifikan baik pada *regime* 1 dan *regime* 2 diperoleh model *Markov Switching* yang terbaik mengikuti proses AR (1) dan MA (1)

Dari ordo ARIMA pada Tabel 12 di atas, selanjutnya akan dilakukan uji *residual white noise* dan berdistribusi normal untuk series data Indosat. Model ARMA didapatkan hasil dengan *Ljung-Box Test* untuk uji asumsi residual white noise untuk model ARIMA(1,0,0) dan (0,0,1) tidak *white noise* karena *p-value* hingga *lag-12* berada di atas nilai $\alpha = 0.05$ yang berarti terima H_0 , dikarenakan model ARMA diatas tidak *white noise*, selanjutnya akan dilakukan uji normalitas untuk residual, hasil uji menggunakan *Kolmogorof-Smirnov Test* pada Tabel 2.

Tabel 2 Normality Test

Model Markov	N	KS	P-Value
AR(1)	3128	0.4901	2.2e-16
MA(1)	3129	0.4895	2.2e-16

Hasil uji normalitas diperoleh nilai KS dan *p-value*, sehingga dapat disimpulkan untuk kedua model ARMA tersebut menunjukkan bahwa residual tidak berdistribusi normal, dikarenakan nilai *P-value* kurang dari $\alpha = 0,05$, Oleh karena *p-value* < α , maka tolak H_0 .

Selanjutnya didapat matrik transisinya dari model AR (1) dan model MA (1) sebagai berikut :

$$P = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix}$$

Matrik Markov Transition Probabilities AR (1) :

$$p = \begin{bmatrix} 0.96096 & 0.039038 \\ 0.74292 & 0.25708 \end{bmatrix}$$

Matrik Markov Transition Probabilities MA (1):

$$p = \begin{bmatrix} 0.99349 & 0.0065125 \\ 1.0000 & 1.4525e - 011 \end{bmatrix}$$

Model *Markov-switching* dengan proses AR(*p*) sesuai dengan persamaan yang dijelaskan oleh Zivot dan Wang (2006).

$$\begin{aligned} \phi_{p,st}(B)Y_t &= a_t \quad \text{untuk } t \\ &= 1, 2, \dots, t \\ y_t &= \mu_{st} + \phi_{1,st}y_{t-1} + \phi_{2,st}y_{t-2} \\ &\quad + \dots + \phi_{p,st}y_{t-p} \\ &\quad + a_t \\ y_t &= \mu_{st} + X_t\phi_{st} + a_t \end{aligned}$$

dimana $X_t = (y_{t-1}, y_{t-2}, \dots, y_{t-p})$ dan ϕ_{S_t} adalah vektor koefisien AR berukuran $p \times 1$.

Berdasarkan Tabel 12 diperoleh model *Markov Switching* pada *regime 1* dan *regime 2* untuk AR (1):

$$y_t = \mu_{S_t} + \phi_{1,S_t}y_{t-1} + \phi_{2,S_t}y_{t-2} + \dots + \phi_{p,S_t}y_{t-p} + a_t$$

$$y_t = \mu_1 + \phi_{1,1}y_{t-1} + a_t$$

$$y_t = 0.01578 + 0.10024y_{t-1} + a_t \dots\dots$$

Regime 1

$$y_t = 0.01578 + 0.1.07575y_{t-1} +$$

$$a_t \dots\dots \text{Regime 2}$$

Sehingga dari persamaan diatas diperoleh :

$$y_t = \begin{cases} \mu_0 + \phi_1 y_{t-1} + a_t \\ \mu_0 + \phi_2 y_{t-1} + a_t \\ 0.01578 + 0.10024 y_{t-1} + a_t \\ 0.01578 + 0.1.07575 y_{t-1} + a_t \end{cases}$$

Berdasarkan Tabel 12 diperoleh model *Markov Switching* untuk *regime 1* dan *regime 2* untuk MA (1) :

$$y_t = \mu_{S_t} - \theta_{1,S_t}a_{t-1} - \theta_{2,S_t}a_{t-2} - \dots - \theta_{p,S_t}a_{t-p}$$

$$y_t = \mu_1 - \theta_{1,1}a_{t-1}$$

$$y_t = 0.01611 - 0.13604a_{t-1} \dots\dots$$

Regime 1

$$y_t = 0.01611 - 0.84443a_{t-1} \dots\dots$$

Regime 2

Sehingga dari persamaan diatas diperoleh :

$$y_t = \begin{cases} \mu_0 + \theta_1 y_{t-1} + a_t \\ \mu_0 + \theta_2 y_{t-1} + a_t \\ 0.01611 - 0.13604 y_{t-1} + a_t \\ 0.01611 - 0.84443 y_{t-1} + a_t \end{cases}$$

B. Series data Telkom

Berbeda dengan series data pada indosat, untuk series data Telkom model yang terbaik dilihat dari nilai AIC baik pada *regime 1* maupun *regime 2* dan parameter yang dihasilkan signifikan diperoleh model *Markov Switching* yang terbaik mengikuti proses AR (1) dan MA (1)

Dari ordo ARIMA diatas, selanjutnya akan dilakukan uji *residual white noise*

dan berdistribusi normal untuk series data Telkom Model ARMA didapatkan hasil dengan *Ljung-Box Test* untuk uji asumsi residual *white noise* untuk model AR(1) dan MA (1) tidak *white noise* karena *p-value* hingga lag-12 berada di atas nilai $\alpha = 0.05$ yang berarti terima H_0 , dikarenakan model ARMA diatas tidak *white noise*, selanjutnya akan dilakukan uji normalitas untuk residual, hasil uji menggunakan *Kolmogorof-Smirnov Test* pada Tabel 3.

Tabel 3 Normality Test

Model Markov	N	KS	P-Value
AR(1)	3128	0.4899	2.2e-16
MA(1)	3129	0.4897	2.2e-16

Hasil uji normalitas diperoleh nilai KS dan *p-value*, sehingga dari tabel diatas dapat disimpulkan untuk kedua model ARMA tersebut menunjukkan bahwa residual tidak berdistribusi normal, dikarenakan nilai *p-value* kurang dari $\alpha = 0,05$, Oleh karena *p-value* < α , maka tolak H_0 .

Selanjutnya didapat matrik transisinya dari model AR(1) dan model MA (1) sebagai berikut :

$$P = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix}$$

Matrik Markov Transition Probabilities AR (1):

$$p = \begin{bmatrix} 0.10782 & 0.89218 \\ 0.044902 & 0.95510 \end{bmatrix}$$

Matrik Markov Transition Probabilities MA (1):

$$p = \begin{bmatrix} 0.99075 & 0.0092519 \\ 0.68634 & 0.31366 \end{bmatrix}$$

Model *Markov Switching* pada *regime 1* dan *regime 2* untuk AR (1) :

$$y_t = \mu_{S_t} + \phi_{1,S_t}y_{t-1} + \phi_{2,S_t}y_{t-2} + \dots + \phi_{p,S_t}y_{t-p} + a_t$$

$$y_t = \mu_1 + \phi_{1,1}y_{t-1} + a_t$$

$$y_t = 0.01552 + 1.32619y_{t-1} + a_t \dots\dots$$

Regime 1

$$y_t = 0.01552 - 1.23108y_{t-1} + a_t \dots\dots$$

Regime 2

Sehingga dari persamaan diatas diperoleh :

$$y_t = \begin{cases} \mu_0 + \phi_1 y_{t-1} + a_t \\ \mu_0 + \phi_2 y_{t-1} + a_t \end{cases}$$

$$y_t = \begin{cases} 0.01552 + 1.32619 y_{t-1} + a_t \\ 0.01552 - 1.23108 y_{t-1} + a_t \end{cases}$$

Model *Markov Switching* untuk *regime 1* dan *regime 2* untuk MA (1) :

$$y_t = \mu_{st} - \theta_{1,st} a_{t-1} - \theta_{2,st} a_{t-2} - \dots - \theta_{p,st} a_{t-p}$$

$$y_t = \mu_1 - \theta_{1,1} a_{t-1}$$

$$y_t = 0.01583 - 0.12431 a_{t-1} \quad \dots\dots$$

Regime 1

$$y_t = 0.01583 - 0.84802 a_{t-1} \quad \dots\dots$$


Regime 2

Sehingga dari persamaan diatas diperoleh :


$$y_t = \begin{cases} \mu_0 + \theta_1 y_{t-1} + a_t \\ \mu_0 + \theta_2 y_{t-1} + a_t \end{cases}$$

$$y_t = \begin{cases} 0.01583 - 0.12431 y_{t-1} + a_t \\ 0.01583 - 0.84802 y_{t-1} + a_t \end{cases}$$

Dari diagnosa test apakah model ARFIMA dan *Markov Switching white noise* dan berdistribusi normal residuals, ternyata diperoleh hasil bahwa kedua model baik ARFIMA dan *Markov Switching* tidak *white noise* dan tidak berdistribusi normal, jika dilihat hasil dari kedua uji baik uji *white noise* dan uji normalitas dapat disimpulkan tidak sesuai, maka akan dilakukan cek apakah series data indosat maupun telkom tersebut *outlier* atau tidak dengan metode *boxplot* seperti pada gambar 21 dan gambar 22.



Gambar 21 Boxplot Indosat



Gambar 22 Boxplot Telkom

Dilihat dari boxplot untuk series data Indosat maupun series data Telkom dapat disimpulkan bahwa data kedua series adalah *outlier*, *Boxplot* dapat memberikan gambaran yang lebih spesifik tentang distribusi data, terlihat jelas disana series data Indosat maupun Telkom banyak yang *outlier* dan tidak berada pada median dan dapat dipastikan series data Indosat adalah *spurious long memory* dan series data Telkom juga *spurious long memory*.

Hasil evaluasi akhir tentang ARFIMA dengan *Markov Switching* menunjukkan hasil simulasi terlihat bahwa sifat stock aggregate memiliki pola yang random baik untuk GPH terkoreksi maupun GPH tak terkoreksi. Sedangkan pada aplikasi model berdasarkan nilai AIC terkecil dan parameter yang signifikan, ARFIMA lebih baik dibandingkan *Markov Switching*, ternyata data dari kedua return saham LQ45 datanya mengandung *outlier* sehingga dengan hasil simulasi yang menunjukkan bahwa untuk data *spurious long memory*, maka hasil estimator GPH untuk data teragregasi tidak menunjukkan pola tertentu, tetapi jika dilihat pemodelannya dimana kedua series data menunjukkan *outlier* dan sudah dapat dipastikan bahwa memang *spurious long memory*.

KESIMPULAN

Berdasarkan analisis dan pembahasan yang telah dilakukan, berikut beberapa kesimpulan yang diperoleh adalah :

1. Pengidentifikasi sifat *Long Memory* dalam suatu series data dapat dilakukan dengan agregasi baik *flow aggregation* maupun *stock aggregation*. Dimana pada kasus ini hanya menggunakan *stock aggregation*. Berdasarkan hasil simulasi, stok agregasi ini menghasilkan perilaku yang sama dalam parameternya untuk *Spurious Long Memory*, yaitu random, tidak memiliki trend turun atau naik jika seriesnya diagregasi.
2. Pemodelan dari absolut *return* saham dari kedua series terpilih yaitu Indosat dan Telkom, didapatkan bahwa model ARFIMA lebih baik dibandingkan model *Markov Switching*. Hasil aplikasi saham menunjukkan nilai estimasi GPH untuk data teragregasi memiliki pola yang random, dilihat dari nilai AIC terkecil berdasarkan kedua model, model ARFIMA memiliki nilai AIC terkecil, sehingga GPH standart tidak bisa digunakan untuk mendeteksi *spurious long memory*, dimana *return* saham dari kedua series terpilih adalah mengandung *outlier*.

Mathematical Science, 2(55), 2713-2734.

- [4] Kuswanto, H. 2011. A New Test Against Spurious Long Memory Using Temporal Aggregation. *Journal Of Statistical Computation And Simulation*, I-First Published On 17 January 2011. DOI: 10.1080/00949655.2010.483231
- [5] Souza, L. R. 2005. Temporal Aggregation And Bandwidth Selection In Estimating Long Memory. *Journal Of Time Series Analysis* 28(5), 701-722.
- [6] Souza, L. R. 2008. Spectral properties of temporally aggregated long memory process. *Brazilian Journal of Probability and Statistics* 22(2), 135-155.

DAFTAR PUSTAKA

- [1] Chambers, M. J., 1998, *Long Memory And Aggregation In Macroeconomic Time Series*. *International Economic Review* 39, 1053-1072.
- [2] Geweke, J. And S. Porter-Hudak (1983) The Estimation And Application Of Long Memory Time Series Models. *Journal Of Time Series Analysis* 4, 221-237.
- [3] Kuswanto, H. and Sibbertsen, P. 2008. A study on spurious long memory in nonlinear time series models. *Applied*