

# Pengaruh Agregasi terhadap Parameter *Long Memory* *Time Series* (Studi Kasus : Data Saham LQ 45)

Moch. Koesniawanto dan Heri Kuswanto  
Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember (ITS)  
Jl. Arief Rahman Hakim, Surabaya 60111  
*E-mail:* heri\_k@statistika.its.ac.id

**Abstrak**—Proses identifikasi terhadap fenomena *Long Memory* tidaklah mudah. Berbagai alat identifikasi seperti plot ACF dan berbagai statistik uji lain masih sangat lemah. Beberapa penelitian mengungkapkan bahwa beberapa model nonlinear dapat dengan mudah teridentifikasi sebagai *Long Memory* yang sering dikenal sebagai *Spurious Long Memory*. Oleh karena itu, dalam tugas akhir ini akan disimulasikan pengaruh *flow aggregation* dan *stock aggregation* sebagai alternatif cara untuk mendeteksi *Long Memory*. Saham digunakan sebagai studi kasus karena proses pencatatannya sama dengan penerapan dari *stock aggregation* dan beberapa penelitian menyatakan bahwa harga mutlak dari *return* saham sering tertangkap sebagai fenomena *Long Memory*, namun tidak sedikit penelitian yang memodelkan *return* saham dengan model nonlinear, contohnya seperti ESTAR, sehingga simulasi dibangun dengan membangkitkan data *Long Memory* dan ESTAR sebagai *Spurious Model* dengan ukuran sampel 2000 dan 5000, lalu diagregasi masing-masing dengan kedua jenis agregasi hingga 10 level agregasi. Hasil simulasi menunjukkan bahwa *temporal aggregation* terbukti dapat mendeteksi *Long Memory* dan membedakannya dengan ESTAR dari pola parameter integrasinya. Pada data ESTAR, kedua agregasi menunjukkan bahwa nilai parameternya tidak berpola atau random seiring naiknya level agregasi, sedangkan untuk *Long Memory* memiliki pola khusus untuk setiap jenis agregasi. Tiga saham yang dijadikan studi kasus yaitu BMRI, BBNI, dan BBRI lebih baik dimodelkan dengan ARFIMA daripada ESTAR karena menghasilkan *forecast* yang akurasiya lebih baik.

**Kata Kunci**—*Long Memory*, *Spurious Long Memory*, Agregasi, ARFIMA, ESTAR.

## I. PENDAHULUAN

Bagian dari time series yang memiliki dependensi jangka panjang dikenal dengan *Long Memory*. Proses identifikasi *Long Memory* tidak mudah. Plot ACF *Short Memory* dapat menyerupai *Long Memory* [1], kemudian banyak model nonlinear dapat dengan mudah digolongkan ke dalam *Long Memory* [2], yang dikenal sebagai *Spurious Long Memory*. Beberapa statistik uji yang dikembangkan untuk mendeteksi *Long Memory* seperti *Hurst test*, *R/S test*, *V/S test* masih lemah membedakan *Long Memory* dan *Spurious Long Memory* [3]. Oleh karena itu, mengembangkan pengujian yang dapat membedakan *Real Long Memory* dari *Spurious*

*Long Memory* masih sangat penting dalam rangka untuk memiliki pilihan model yang tepat dan berujung pada hasil peramalan yang akurat.

Alternatif lain untuk mendeteksi *Long Memory* adalah dengan menggunakan prinsip agregasi yang terbagi menjadi 2 jenis yaitu *flow aggregation* dan *stock aggregation*. Penelitian sebelumnya yang telah dikembangkan dengan *flow aggregation* yang dilakukan oleh [4] dapat diterapkan dan terbukti berhasil secara simulasi untuk mengidentifikasi fenomena *Long Memory*. Penelitian tentang performa *stock aggregation* belum pernah dilakukan. Pada kenyataannya, kedua agregasi tersebut memiliki prosedur sampling yang berbeda sehingga konsekuensinya tidak bisa begitu saja digeneralisasi bahwa performa dari *stock aggregation* sama dengan *flow aggregation*.

Salah satu penerapan sifat *stock aggregation* adalah saham. Volatilitas pendapatan saham baik dijelaskan dengan proses *Long Memory* [5]. Dependensi jangka panjangnya secara umum terdeteksi dalam kuadrat atau harga mutlak dari nilai balik modal (*return*). Di sisi lain, model-model nonlinier seperti ESTAR yang tergolong *Spurious Long Memory* juga sering digunakan untuk pemodelan *return* saham. Oleh karena itu, pada penelitian ini akan diaplikasikan teori agregasi untuk mengidentifikasi apakah data saham tersebut tergolong fenomena *Long Memory*. Data saham yang dijadikan kasus adalah saham-saham yang tergolong dalam indeks LQ 45.

Tujuan yang ingin dicapai dalam tugas akhir ini adalah mendapatkan hasil simulasi pengidentifikasian *Long Memory* dan *Spurious Long Memory* (ESTAR) dengan prinsip *flow aggregation* dan *stock aggregation*, mengetahui perbandingan pola parameter yang dihasilkan dari kedua agregasi tersebut, dan dapat menerapkannya untuk kepentingan pemodelan dan peramalan harga saham LQ 45. Batasan masalah pada penelitian ini yaitu data yang digunakan untuk mengetahui kekuatan metode agregasi ini adalah data bangkitan dengan menggunakan *software* R dan estimator parameter yang digunakan adalah GPH karena faktor kesederhanaan. Sedangkan untuk data saham yang dijadikan contoh kasus adalah 3 saham unggulan dari indeks LQ 45. Selanjutnya akan dilakukan pemodelan dengan sifat

Long Memory dan model ESTAR sebagai *Spurious Long Memory*, kemudian dipilih model terbaik hingga dilakukan peramalan 3 periode ke depan untuk masing-masing data saham.

## II. TINJAUAN PUSTAKA

### A. Estimator GPH (Geweke Porter-Hudak)

Estimator yang digunakan adalah GPH yang diperkenalkan oleh [6].

$$\hat{d}_{GPH} = \frac{-0,5 \sum_{j=1}^m (\tilde{X}_j - \tilde{X}) \log I_j}{\sum_{j=1}^m (\tilde{X}_j - \tilde{X})^2} \quad (1)$$

dimana estimator ini dapat dimunculkan dengan menggunakan model:

$$\log I_j = \log c_f - 2d \tilde{X}_j + \log \xi_j$$

### B. Temporal Aggregation

Variabel agregat  $Y_t$  diamati sebagai berikut:

Jika  $X_t$  adalah stock variable, maka  $Y_t = X_{nt}, t = 1, \dots, T$ .

Jika  $X_t$  adalah flow variable, maka

$$Y_t = \sum_{i=0}^{n-1} X_{nt-i} = \sum_{i=1}^{n-1} B^i X_{nt,t=1,\dots,T_y}; T_y = \frac{T_x}{n}$$

### C. Model ESTAR

$G(s_t; \gamma, c)$  adalah fungsi transisi yang mengatur pergerakan dari satu rezim ke rezim yang lain dan  $s_t$  adalah variabel transisi sehingga  $s_t = y_{t-1}$ . Menurut [7] variabel transisi umumnya dipilih untuk lag satu periode yaitu  $l = 1$ . Variabel  $\gamma$  menentukan derajat kelengkungan fungsi transisi dan  $c$  adalah parameter threshold. Jika fungsi transisi berupa fungsi eksponensial, maka fungsi transisi eksponensial dapat ditulis sebagai

$$G(s_t; \gamma, c) = \frac{1}{1 + \exp(-\gamma(s_t - c))} \quad (2)$$

Fungsi transisi tersebut sering dinamakan ESTAR. Fungsi ini asimetris karena tidak tergantung pada fakta bahwa variabel transisi bergerak di atas atau di bawah threshold. Parameter mengontrol derajat nonlinier.

### D. Model ARFIMA

Model ARFIMA secara umum sama dengan model ARIMA. Perbedaan ARFIMA dengan model ARIMA terletak pada parameter pembedanya yaitu :

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t \text{ dimana}$$

$$(1-B)^d = \sum_{r=0}^{\infty} \frac{\Gamma(r-d)}{\Gamma(r+1)\Gamma(-d)} B^r \quad (3)$$

### E. Pemilihan Model Terbaik

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (4)$$

dimana  $n$  adalah banyaknya sampel yang diramalkan. Model terbaik adalah model yang mempunyai nilai RMSE terkecil.

## III. METODOLOGI PENELITIAN

### A. Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder, yaitu data 3 saham yang termasuk ke dalam indeks LQ 45, yaitu BMRI, BBNI, dan BBRI yang diambil mulai periode 1 Januari 2001 hingga 31 Desember 2011.

### B. Langkah Analisis

Bagian Pertama (Analisis Data Simulasi)

1. Membangkitkan data simulasi *Long Memory* dan ESTAR dengan  $n = 2000$  dan  $n = 5000$ . Untuk *Long Memory*, data dibangkitkan masing-masing dengan parameter  $d$  untuk nilai  $d = 0,1; 0,2; 0,3; 0,4$ .
2. Setiap data bangkitan diaggregasi baik dengan properti *stock aggregation* maupun *flow aggregation*, masing-masing dengan level aggregasi sebesar  $m$ , dimana  $m$  bernilai  $1, 2, \dots, 10$ .
3. Setiap data hasil aggregasi pada langkah nomor 2, akan diestimasi nilai parameter  $d$  dan standart deviasinya dengan estimator GPH dengan *bandwith* optimum  $0,5$  dan  $0,8$ .
4. Langkah nomor 1 hingga 4, diulang sebanyak  $1000$  kali sehingga terdapat  $1000$  nilai estimasi  $d$  beserta standart deviasinya.
5. Membuat vektor  $db$  dan  $sb$ . Masing-masing vektor berukuran  $10 \times 1$ . Setiap komponen dari vektor  $db$  didapatkan dari nilai rata-rata hasil estimasi parameter  $d$  untuk tiap level aggregasi  $m$ . Begitu pula dengan vektor  $sb$  didapatkan dari rata-rata standart deviasi  $d$  hasil estimator GPH.
6. Untuk properti *stock aggregation*, pada setiap nilai parameter  $d$  dibuat selang kepercayaan  $95\%$  untuk tiap level aggregasi ( $m = 1, 2, \dots, 10$ ) baik untuk  $n = 2000$  maupun  $n = 5000$ .
7. Melakukan hal sama seperti langkah nomor 6 namun untuk properti *flow aggregation*.
8. Membandingkan hasil selang kepercayaan untuk setiap level aggregasi  $m > 1$  dengan selang kepercayaan saat  $m = 1$ .
9. Jika selang kepercayaan masih beririsan, maka disimpulkan bahwa pada setiap level aggregasi menghasilkan parameter  $d$  yang sama, namun jika ada minimal satu selang kepercayaan yang tidak beririsan, maka dinyatakan bahwa data aggregasi menghasilkan

nilai  $d$  yang berbeda dengan data aslinya.

10. Membandingkan hasil simulasi antara *stock aggregation* dan *flow aggregation* dan disimpulkan metode agregasi terbaik untuk identifikasi proses *Long Memory*.

Bagian Kedua (Analisis Data Saham)

1. Mengunduh data harga saham harian dari 3 saham terbesar yang termasuk indeks LQ 45 dari periode 1 Januari 2001 hingga 31 Desember 2011.
2. Setiap data saham dibuat plot ACF dan PACF sebagai pendugaan secara visual indikasi proses *Long Memory*.
3. Membuat periodogram untuk masing-masing data saham
4. Pada masing-masing data saham akan diaggregasi dengan properti *stock aggregation* dengan level agregasi  $m = 1,2,\dots,10$ .
5. Pada setiap level agregasi akan diestimasi nilai  $d$  dan diamati polanya.
6. Melakukan pemodelan untuk setiap data saham dengan ARFIMA sebagai pendekatan sifat *Long Memory* dan model ESTAR sebagai pendekatan *Spurious Long Memory*.
7. Memilih model terbaik untuk ketiga data saham berdasarkan nilai RMSE terkecil.
8. Melakukan cek diagnosa apakah model yang dihasilkan untuk masing-masing data saham memenuhi asumsi residual berdistribusi normal dan *white noise*.
9. Melakukan peramalan untuk 3 tahap ke depan untuk masing-masing model yaitu periode 2-4 Januari 2012.

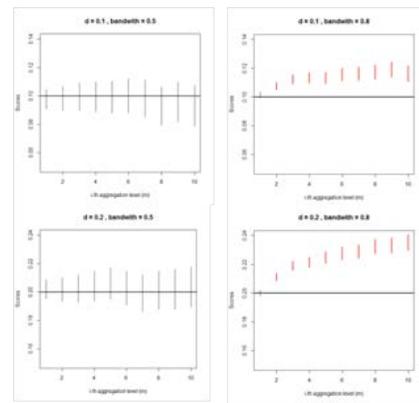
IV. ANALISIS DAN PEMBAHASAN

A. Simulasi Flow Aggregation

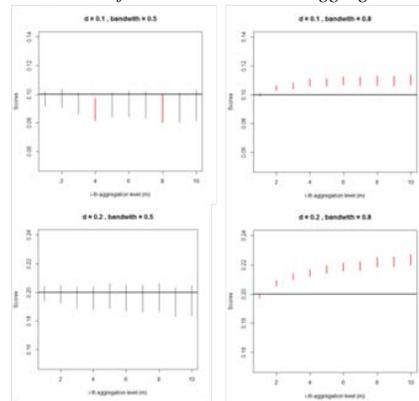
Berdasarkan Gambar 1 dan Gambar 2, didapatkan kesimpulan bahwa pada bandwidth 0,5 terlihat bahwa seiring dengan naiknya level agregasi, parameter  $d$  yang dihasilkan tidak berubah ditunjukkan dengan berisannya selang kepercayaan. Berbeda kondisi dengan bandwidth 0,8 yang memiliki bias yang lebih besar dan selang kepercayaannya tidak berisiran.

B. Simulasi Stock Aggregation

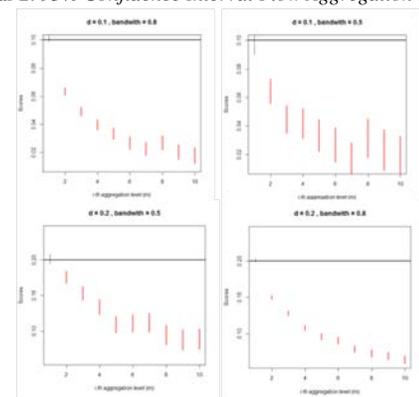
Gambar 3. dan Gambar 4. jelas menunjukkan bahwa *stock aggregation* dalam mendeteksi *Long Memory* akan menghasilkan pola nilai  $d$  yang monoton turun seiring dengan naiknya level agregasi utamanya hingga level 5.



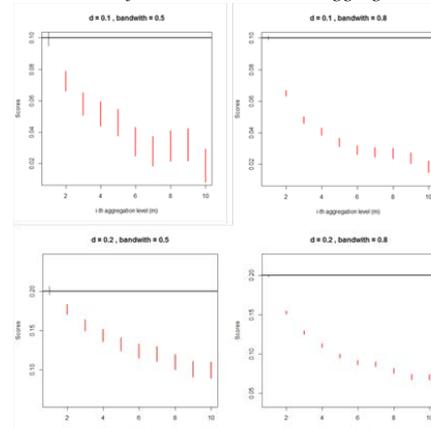
Gambar 1. 95% Confidence Interval Flow Aggregation n = 2000



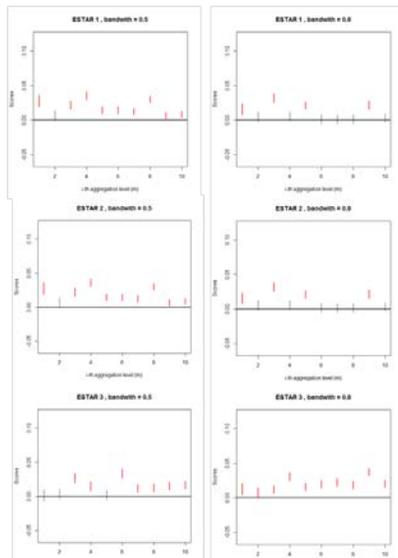
Gambar 2. 95% Confidence Interval Flow Aggregation n = 5000



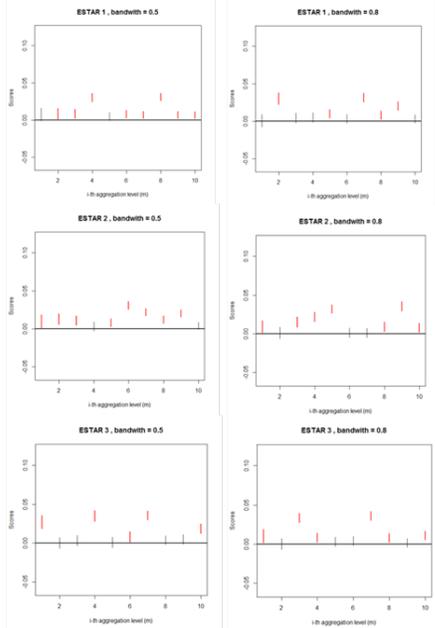
Gambar 3. 95% Confidence Interval Stock Aggregation n = 2000



Gambar 4. 95% Confidence Interval Stock Aggregation n = 5000



Gambar 5. 95% Confidence Interval Stock Aggregation ESTAR n = 2000



Gambar 6. 95% Confidence Interval Stock Aggregation ESTAR n = 5000

C. Simulasi Stock Aggregation pada Model ESTAR

Model ESTAR yang dibangkitkan yaitu :

1. ESTAR 1 : ESTAR ( $\gamma = 25, c = 0.06$ )
2. ESTAR 2 : ESTAR ( $\gamma = 25, c = 0.07$ )
3. ESTAR 3 : ESTAR ( $\gamma = 25, c = 0.08$ )

Hasil selang kepercayaan 95% sebagaimana yang ditampilkan pada Gambar 5. dan Gambar 6. jelas menunjukkan bahwa tidak adanya trend tertentu dari estimasi parameter  $d$  seiring dengan naiknya level aggregasi.

D. Pemilihan Bandwith

Berdasarkan penelitian yang dilakukan oleh [8] dan [9], estimator GPH sangat dipengaruhi oleh pemilihan bandwith yang tepat. Pemilihan bandwith mempengaruhi bias estimasi yang dihasilkan. Berdasarkan hasil simulasi, berikut adalah bias yang dihasilkan oleh GPH dengan bandwith 0,5 dan 0,8.

Tabel 1. Bias Estimasi GPH

m	N = 2000		N = 5000	
	0.5	0.8	0.5	0.8
1	0.032137	0.111111	0.02188	0.084859
2	0.043279	0.137288	0.029254	0.103049
3	0.051783	0.157016	0.034762	0.117603
4	0.058845	0.17038	0.039295	0.127467
5	0.065235	0.181265	0.043279	0.137288
6	0.070857	0.194281	0.046862	0.146225
7	0.076116	0.21019	0.050257	0.153178
8	0.081352	0.219632	0.05327	0.157031
9	0.08585	0.230301	0.056241	0.165579
10	0.090263	0.230427	0.058845	0.17038

Tabel 1 menunjukkan nilai bias yang dihasilkan estimator GPH saat menggunakan bandwith 0,5 dan 0,8. Berdasarkan nilai bias tersebut dapat diambil 2 kesimpulan, yaitu bias yang dihasilkan GPH saat menggunakan bandwith 0,5 lebih kecil daripada bandwith 0,8 kemudian bertambahnya jumlah sampel dapat memperkecil bias yang dihasilkan.

E. Aplikasi ke Data Saham LQ 45

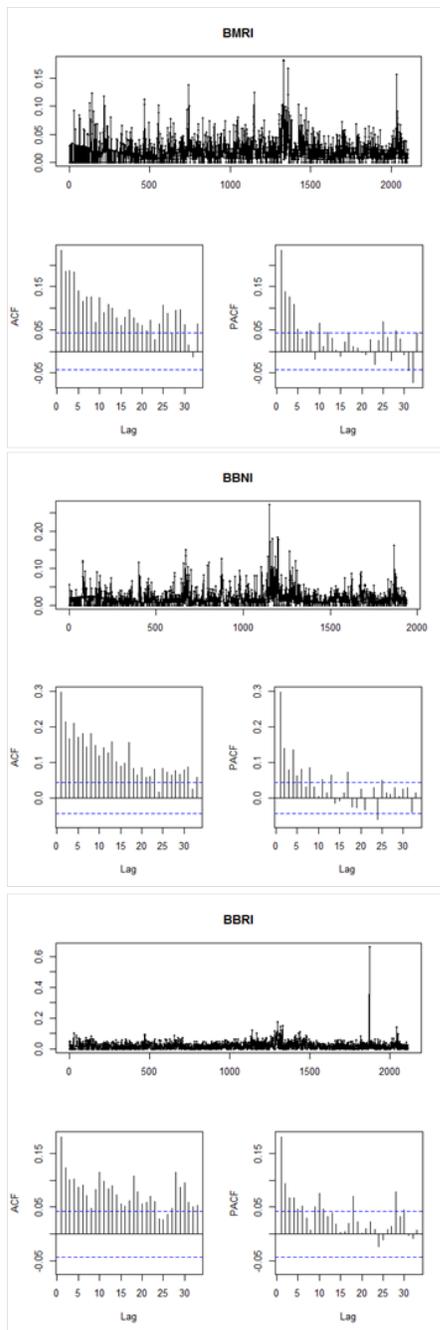
Saham LQ 45 yang dijadikan bahan studi kasus dalam tugas akhir ini adalah saham BMRI, BBNI, dan BBRI. Ketiga jenis indeks saham tersebut diambil datanya mulai awal Januari 2001 hingga akhir Desember 2011. Bagian yang dianalisis adalah absolut dari nilai *return* harga saham, bukan harga saham secara langsung sebab kenyataannya investor lebih tertarik mengetahui informasi pergerakan *return* saham daripada harga saham itu sendiri [5], [10], [11]. Berikut adalah sajian deskripsi series data return saham dari masing-masing indeks saham.

Pada deskripsi series saham yang ditunjukkan pada Gambar 7 adalah data saham yang semula ditransformasi dalam bentuk logaritma natural untuk mengatasi *stationarity* dalam varians, kemudian setelah itu baru didapatkan nilai returnnya. Melihat plot ACF dari ketiga series tersebut, terlihat bahwa plot ACF terkesan turun melambat namun tidak seperti biasanya, meskipun turun melambat namun berbentuk hiperbolik naik turun. Hal tersebut memunculkan 2 kemungkinan, yaitu data series tersebut non stasioner atau data tersebut sebenarnya mengikuti fenomena *Long Memory*.

F. Identifikasi Data dengan Temporal Aggregation

Berikut adalah proses identifikasi dengan menggunakan *stock aggregation* hingga 10 level.

Tabel 2. menunjukkan estimasi parameter  $d$  dari ketiga series hingga 10 level aggregasi. Berdasarkan kesimpulan simulasi dengan *stock aggregation*, jika data tersebut bersifat *Long Memory*, maka estimasi  $d$  akan monoton turun seiring dengan naiknya level aggregasi dan seringnya hingga level 5 aggregasi namun Hasil aggregasi tersebut menunjukkan bahwa tidak sepenuhnya ketiga series tersebut menyerupai sifat *Long Memory*. Hal ini disebabkan karena pada data *real return* saham banyak sekali intervensi yang tidak dijumpai seperti saat melakukan simulasi. Oleh karena itu, dalam pemodelan nantinya akan dicoba kemungkinan kedua model



Gambar 7. Deskripsi Series Data Return Saham BMRI, BBNI, dan BBRI

Tabel 2. Estimasi Nilai  $d$  dengan  $m$  Level Agregasi

M	BMRI	BBNI	BBRI
1	0.365632	0.338576	0.36565
2	0.254603	0.319744	0.348989
3	0.230007	0.312706	0.356939
4	0.019567	0.365594	0.193799
5	0.294126	0.159461	0.18676
6	0.027015	0.318211	0.264771
7	0.204972	0.508531	0.251953
8	0.098254	0.331549	0.313476
9	0.18846	0.260105	0.254668
10	0.422946	0.045438	0.211442

Tabel 3. Pemodelan Series

Series	Model	RMSE
BMRI	ARFIMA(1, 0.3656, 1)	0.0212
	ESTAR( $\gamma = 37.8, c = 0.0838$ )	0.0199
BBNI	ARFIMA(4, 0.3386, 0)	0.0208
	ESTAR(0.0221, -0.0221, 43.3)	0.0212
BBRI	ARFIMA(1, 0.3657, 1)	0.0211
	ESTAR(0.9318, -0.9318, 9.98)	0.0237

Tabel 4.

Forecast Saham Model ARFIMA

	BMRI		BBNI		BBRI	
	Actual	Forecast	Actual	Forecast	Actual	Forecast
	-0.0074	-0.0154	0.0066	0.0144	0.0074	0.0141
	0.0148	0.016	0.0194	0.0143	0.0146	0.0154
	0.0073	0.0163	0.0064	0.0143	0.0072	0.0158
RMSE	0.007		0.0071		0.0063	

Tabel 5.

Forecast Saham Model ESTAR

	BMRI		BBNI		BBRI	
	Actual	Forecast	Actual	Forecast	Actual	Forecast
	-	-0.0195	0.006	0.0132	0.007	0.0163
	0.0074		6		4	
	0.0148	0.0128	0.019	0.0122	0.014	0.0166
			4		6	
	0.0073	0.0123	0.006	0.0154	0.007	0.0187
			4		2	
RMSE	0.00765		0.00767		0.00848	

yaitu model ARFIMA sebagai *Long Memory* dan ESTAR sebagai *Spurious Long Memory* untuk dibandingkan error terkecilnya.

G. Model dan Ramalan Data Saham

Berikut ini adalah hasil pemodelan dan peramalan ketiga series tersebut. Berdasarkan hasil pemodelan yang dipaparkan pada Tabel 3. dapat terlihat bahwa *fitting model* yang baik untuk data series BBNI dan BBRI adalah ARFIMA, namun untuk series BMRI adalah ESTAR. Namun nilai RMSE yang dihasilkan memiliki selisih yang sangat kecil sehingga untuk peramalan (*forecast*) dari ketiga series tersebut akan digunakan semua modelnya dan dibandingkan kembali nilai RMSE untuk mengetahui model manakah yang menghasilkan *forecast* yang lebih akurat. Berikut adalah hasil *forecast return* saham 3 tahap ke depan.

Tabel 4. adalah *forecast return* saham menggunakan model ARFIMA sedangkan Tabel 5. adalah *forecast return* saham menggunakan model ESTAR. Hasil kedua tabel tersebut dibandingkan *actual return* dan ramalannya dan perbandingan tersebut diwakili dengan nilai RMSE. Berdasarkan hasil Tabel 4. dan Tabel 5. menunjukkan bahwa model ARFIMA lebih akurat ramalannya daripada model ESTAR tanpa terkecuali untuk series BMRI karena meskipun *fitting model* datanya lebih baik menggunakan ESTAR, namun hasil ramalannya lebih akurat jika menggunakan

model ARFIMA.

## V. KESIMPULAN/RINGKASAN

Berdasarkan analisis dan pembahasan yang telah dilakukan, berikut beberapa kesimpulan yang diperoleh adalah pengidentifikasian sifat *Long Memory* dalam suatu series data dapat dilakukan dengan agregasi baik *flow aggregation* maupun *stock aggregation*. *Flow aggregation* dalam mendeteksi *Long Memory* akan menghasilkan pola parameter integrasi yang nilainya secara statistik sama atau tidak berbeda meskipun data tersebut diaggregasi, sedangkan untuk sifat *stock aggregation* menghasilkan pola untuk parameter integrasinya memiliki trend turun untuk rata-rata hingga level 5 agregasi. Berdasarkan hasil simulasi, kedua metode agregasi ini menghasilkan perilaku yang sama dalam parameternya untuk *Spurious Long Memory* (studi kasus ESTAR), yaitu random, tidak memiliki trend turun atau naik jika seriesnya diaggregasi.

Pemodelan dari absolut *return* saham dari ketiga series terpilih yaitu BMRI, BBNI, dan BBRI didapatkan bahwa model ARFIMA lebih baik dalam *fitting model* kecuali pada series BMRI yang menunjukkan bahwa ESTAR lebih baik dalam *fitting model*. Namun ketika dilakukan *forecasting* 3 tahap ke depan, hasilnya sama-sama menunjukkan bahwa model ARFIMA memberikan hasil *forecast* yang lebih baik dan akurat dari pada ESTAR pada ketiga series tanpa terkecuali BMRI yang dalam fitting modelnya menyatakan ESTAR lebih baik.

## UCAPAN TERIMA KASIH

Penulis M.K. mengucapkan terimakasih kepada Dr. rer. pol. Heri Kuswanto, S. Si, M. Si. yang telah membimbing dengan baik dan sabar sehingga Penulis dapat menyelesaikan jurnal ini dengan baik, serta kepada Dr. Brodjol Sutijo, S.U., M. Si. dan Dr. Irhamah, S. Si, M. Si yang telah banyak memberikan koreksi dan saran terhadap penulisan jurnal ini.

## DAFTAR PUSTAKA

- [1] F. X. Diebold and C.A. Inoue, "Long Memory And Regime Switching". *Journal of Econometrics*, Vol. 105, No. 1, (2001) 131-159.
- [2] H. Kuswanto and P. Sibbertsen, "A Study On Spurious Long Memory In Nonlinear Time Series Models". *Applied Mathematical Science*, Vol. 2, No.55, (2008) 2713-2734.
- [3] H. Kuswanto and P. Sibbertsen, *Testing long memory against ESTAR nonlinearities. Discussion Paper no. 427*, Leibniz Hannover University, Germany, (2009).
- [4] H. Kuswanto, "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 (2011).
- [5] Z. Ding, R.F. Engle, and C.W.J. Granger, "A Long Memory Property Of Stock Market Returns And A New Model". *Journal of Empirical Finance* 1, (1993) 83-106.
- [6] J. Geweke and S. Porter-Hudak, "The Estimation And Application Of Long Memory Time Series Models". *Journal of Time Series Analysis* 4, (1983) 221-237.
- [7] S.J. Taylor, Consequences for option pricing of a long memory in volatility. Unpublished Manuscript. Department of Accounting and Finance, Lancaster University, (2000).
- [8] L.R. Souza, "Spectral Properties Of Temporally Aggregated Long Memory Process". *Brazilian Journal of Probability and Statistics*, Vol. 22, No. 2, (2008) 135-155.
- [9] L.R. Souza, "Temporal Aggregation And Bandwidth Selection In Estimating Long Memory". *Journal of Time Series Analysis* Vol. 28, No. 5, (2003) 701-722.
- [10] T. Anderson, T. Bollerslev, F.X. Diebold, and P. Labys, "Modeling and Forecasting Realized Volatility". *Econometrica* 71, (2003) 579-626.
- [11] P. Sibbertsen, "Long memory versus structural change: An overview". *Statistical Papers* 45, (2004) 465-515.