

STUDI SIMULASI BIAS ESTIMATOR GPH PADA DATA SKIP SAMPLING

¹Gede Suwardika, ²Heri Kuswanto, ³Irhamah

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

^{2,3}Jurusan Statistika FMIPA Institut Teknologi Sepuluh Nopember

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 nonlinier seperti *Markov switching*, STOP-BREAK, ESTAR, level shift dan lainnya. Dalam penelitian disimulasikan performansi dari GPH dan GPH terkoreksi pada proses *long memory* dan *markov switching*. Data yang diestimasi merupakan data skip sampling dari kedua proses di atas. Hasil simulasi menunjukkan bahwa GPH terkoreksi mampu mengurangi bias parameter *long memory*. Selain itu, diamati pula bahwa terdapat perbedaan yang signifikan pola yang dihasilkan oleh estimasi pada data *long memory* dan data yang mengikuti proses *Markov switching*. Fakta ini dapat digunakan untuk membedakan antara *true* dan *spurious long memory*.

Kata Kunci : *long memory*, GPH terkoreksi, *Markov Switching*

PENDAHULUAN

Proses *long memory* telah diamati dalam banyak hal, seperti hidrologi, telekomunikasi, ekonomi dan keuangan. *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 [3]. Untuk mendeteksi adanya *long memory* pada data, dapat dilakukan estimasi dengan menggunakan *Hurst Exponent* maupun uji *Rescaled range statistics* (R/S) dan *Modified rescaled range statistics* (MR/S), *rescaled varians* (V/S), GPH (*long periodgram estimation*) dan lain sebagainya.

Model *Markov Switching* digunakan untuk memodelkan kejadian perubahan

struktur seperti fenomena krisis yaitu sebagai hasil dari variabel random tak teramati atau *state*. *Markov Switching* (MS) sebagai alternative pemodelan data *time series* yang mengalami perubahan struktur [4]. Dalam *Markov Switching*, perubahan struktur yang terjadi tidak dianggap sebagai suatu hasil peristiwa deterministic tetapi sebagai suatu hasil variabel random tak teramati (*unobservable*) dan dalam literatur sering disebut *state* atau *regime*.

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 estimator [10].

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.

Metode Analisis

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

Melakukan proses simulasi dengan data bangkitan dan mengestimasi GPH terkoreksi dengan $n = 500$ dan $n = 2000$, dilakukan pengulangan simulasi sebanyak 1000 kali pada tiap-tiap level agregasi m , Setiap data hasil dari agregasi akan diestimasi nilai parameter d dan standart deviasinya dengan estimator GPH dengan bandwidth optimum 0,5. Jenis-jenis agregasi yang digunakan adalah *Markov-switching process*, model yang digunakan dalam proses Markov-switching :

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

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

HASIL PENELITIAN

Estimator GPH berdasarkan penelitian yang dilakukan oleh [10], sangat dipengaruhi oleh pemilihan bandwidth yang tepat. Pemilihan bandwidth mempengaruhi bias estimasi yang dihasilkan, sehingga pada penelitian ini diputuskan untuk menggunakan bandwidth 0.5.

Simulasi Stock Aggregation (skip sampling)

Prosedur dari *stock aggregation* sama seperti skip sampling atau sampling sistematis. Data agregasi diambil dari data asli pada kelipatan level unit waktunya. Hasil estimasi GPH stock aggregation dapat dilihat pada penelitian tersebut [11]. Berikut hasil estimasi GPH terkoreksi (GPH1) dan GPH tak terkoreksi (GPH2) untuk data long memory yang di skip sampling.

Tabel 1. Hasil Simulasi Stock Aggregation dengan $n = 500$


m	bandwidth = 0.5			
	0.1		0.2	
	GPH 1	GPH 2	GPH 1	GPH 2
1	0.1047	0.1047	0.1990	0.1990
2	0.0865	0.0708	0.1756	0.1627
3	0.0708	0.0509	0.1543	0.1362
4	0.0563	0.0317	0.1387	0.1294
5	0.0463	0.0291	0.1259	0.1178
6	0.0393	0.0252	0.1154	0.1017
7	0.0356	0.0262	0.1071	0.0803
8	0.0341	0.0218	0.1074	0.1063
9	NaN	0.0159	NaN	0.0648
10	NaN	0.0095	NaN	0.0735

Tabel 2. Hasil Simulasi Stock Aggregation dengan $n = 500$

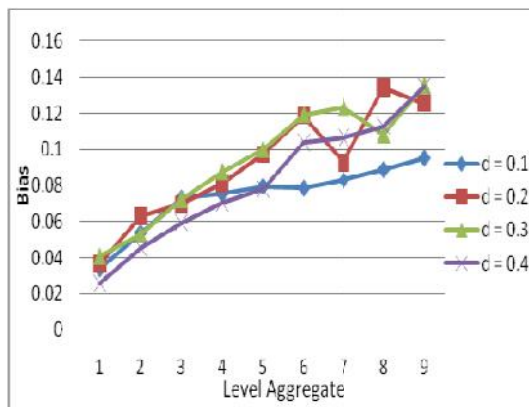
m	bandwidth = 0.5			
	0.3		0.4	
	GPH 1	GPH 2	GPH 1	GPH 2
1	0.3073	0.3073	0.4107	0.4107
2	0.2800	0.2662	0.3912	0.3848
3	0.2609	0.2542	0.3718	0.3652
4	0.2420	0.2347	0.3538	0.3512
5	0.2259	0.2194	0.3384	0.3400
6	0.2139	0.2069	0.3277	0.3326
7	0.2058	0.1878	0.3199	0.3069
8	0.2035	0.1834	0.3184	0.3043
9	NaN	0.1989	NaN	0.2979
10	NaN	0.1716	NaN	0.2761

Dari tabel di atas, GPH terkoreksi hanya mampu mengestimasi sampai dengan level agregasi 8. Hal ini dikarenakan jumlah sampel yang kecil, sehingga dengan agregasi 10, hanya didapatkan 50 sampel yang mana tidak mencukupi untuk estimasi GPH terkoreksi. Salah satu komponen penting

dari untuk mendekteksi pattern hasil estimasi adalah bias estimasi. Plot dari hasil estimasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 1 dan Gambar 2.



Gambar 1. GPH Terkoreksi n = 500



Gambar 2. GPH Tak Terkoreksi n = 500

Pada Tabel 1, Tabel 2, Gambar 1 serta Gambar 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, selanjutnya akan disimulasikan dengan sampel yang lebih besar yaitu 2000. Berikut adalah hasil simulasi penggunaan *stock aggregation*.


Tabel 3. Hasil Simulasi *Stock Aggregation* n = 2000

m	bandwidth = 0.5			
	0.1		0.2	
	GPH 1	GPH 2	GPH 1	GPH 2
1	0.1001	0.1001	0.2065	0.2065
2	0.0820	0.0691	0.1881	0.1786
3	0.0680	0.0509	0.1726	0.1599
4	0.0583	0.0455	0.1581	0.1420
5	0.0519	0.0464	0.1445	0.1249
6	0.0430	0.0208	0.1337	0.1202
7	0.0373	0.0277	0.1228	0.1016
8	0.0329	0.0265	0.1141	0.0991
9	0.0280	0.0137	0.1059	0.0851
10	0.0258	0.0265	0.1006	0.0918


Tabel 4. Hasil Simulasi *Stock Aggregation* n = 2000

m	bandwidth = 0.5			
	0.3		0.4	
	GPH 1	GPH 2	GPH 1	GPH 2
1	0.3039	0.3039	0.4032	0.4032
2	0.2894	0.2833	0.3968	0.3969
3	0.2756	0.2669	0.3870	0.3835
4	0.2631	0.2554	0.3787	0.3812
5	0.2500	0.2375	0.3680	0.3639
6	0.2386	0.2294	0.3575	0.3531
7	0.2263	0.2064	0.3477	0.3438
8	0.2171	0.2093	0.3384	0.3329
9	0.2078	0.1900	0.3304	0.3272
10	0.2010	0.1890	0.3244	0.3228

Berikut ini plot hasil simulasi yang lebih jelas menunjukkan bias :



Gambar 3. GPH Terkoreksi untuk n = 2000



Gambar 4. GPH Tak Terkoreksi untuk n = 2000

Tabel 3, Tabel 4, Gambar 3 dan 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.

Model Markov Switching

Model *Spurious Long Memory* pertama yang pernah dibahas adalah Markov Switching untuk sifat *stock aggregation*, Oleh karena itu, berikut akan disajikan hasil simulasi penerapan GPH baik terkoreksi maupun tidak terkoreksi pada data *stock aggregation* dalam mendeteksi model Markov Switching. Model yang digunakan dalam proses Markov-switching adalah :

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

dengan $\epsilon_t \sim N(0,1)$ dan peluang p_{00} dan p_{11} .

Model Markov Switching yang dibangkitkan ada 3 macam, yaitu :

- 1) MS 1 : MS ($\phi_1 = 0.5, \phi_2 = -0.5, P_{00} = 0.9, P_{11} = -0.9, bandwidth = 0.5$)

- 2) MS 2 : MS ($\phi_1 = 0.7, \phi_2 = -0.2, P_{00} = 0.9, P_{11} = -0.9, bandwidth = 0.5$)
- 3) MS 3 : MS ($\phi_1 = 0.5, \phi_2 = -0.4, P_{00} = 0.9, P_{11} = -0.9, bandwidth = 0.5$)

Setting parameter untuk model Markov di atas akan menghasilkan serangkaian data time series yang persisten, yang merupakan salah satu ciri dari *spurious long memory*. Dalam hal ini, parameter transition probability yang sangat besar menyebabkan switching dari regime 1 ke regime 2 menjadi persisten. Berikut disajikan hasil estimasi GPH untuk data Markov switching yang telah teragregasi secara skip sampling.


Tabel 3. Simulasi *Stock Aggregation* untuk Model Markov Switching n = 500

m	bandwidth = 0.5		
	$\phi_1 = 0.7, \phi_2 = -0.2, P_{00} = 0.9, P_{11} = -0.9$	$\phi_1 = 0.5, \phi_2 = -0.4, P_{00} = 0.9, P_{11} = -0.9$	$\phi_1 = 0.5, \phi_2 = -0.4, P_{00} = 0.9, P_{11} = -0.9$
	GPH 2	GPH 1	GPH 2
1	0.1715	0.1419	0.1419
2	0.0945	0.1098	0.0837
3	0.0808	0.0899	0.0671
4	0.0493	0.0704	0.0387
5	0.0538	0.0579	0.0390
6	0.0386	0.0503	0.0404
7	0.0449	0.0457	0.0349
8	0.0106	0.0427	0.0192
9	0.0236	NaN	0.0429
10	0.0123	NaN	0.0148


Tabel 4. Simulasi *Stock Aggregation* untuk Model Markov Switching n = 500

m	bandwidth = 0.5		
	$\phi_1 = 0.5, \phi_2 = -0.5, P_{00} = 0.9, P_{11} = -0.9$	$\phi_1 = 0.5, \phi_2 = -0.5, P_{00} = 0.9, P_{11} = -0.9$	$\phi_1 = 0.7, \phi_2 = -0.2, P_{00} = 0.9, P_{11} = -0.9$
	GPH 1	GPH 2	GPH 1
1	0.1404	0.1404	0.1715
2	0.1069	0.0797	0.1285
3	0.0859	0.0614	0.1053
4	0.0676	0.0397	0.0830
5	0.0559	0.0410	0.0694
6	0.0477	0.0354	0.0585
7	0.0393	0.0057	0.0536
8	0.0348	0.0005	0.0486
9	NaN	0.0126	NaN
10	NaN	0.0153	NaN

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 di atas 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. Tabel 3 dan Tabel 4 menunjukkan bukti bahwa model Markov switching secara umum menghasilkan parameter integrasi d cenderung mendekati nol (*short memory*). Penggunaan properti *stock aggregation* dalam kasus ini dapat

menyebabkan nilai d yang dihasilkan naik dan turun atau tidak monoton. Sebagaimana yang ditampilkan pada Gambar 6, jelas menunjukkan 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 monoto seiring dengan bertambahnya level agregasi.Selanjutnya akan disimulasikan dengan sampel yang lebih besar yaitu 2000. Berikut adalah hasil simulasi penggunaan *stock aggregation* pada bangkitan model markov switching dengan sampel 2000.


Tabel 5. Simulasi *Stock Aggregation* untuk Model Markov Switching $n = 2000$

m	bandwidth = 0.5		
	$\alpha_1 = 0.5$ $\alpha_2 = -0.5$	$\alpha_1 = 0.5$ $\alpha_2 = -0.5$	$\alpha_1 = 0.7$ $\alpha_2 = -0.2$
	$P_{00} = 0.9$ $P_{11} = -0.9$	$P_{00} = 0.9$ $P_{11} = -0.9$	$P_{00} = 0.9$ $P_{11} = -0.9$
	GPH 1	GPH 2	GPH 1
1	0.0460	0.04599	0.0473
2	0.0361	0.02607	0.0388
3	0.0290	0.01779	0.0323
4	0.0230	0.01059	0.0278
5	0.0194	0.01250	0.0256
6	0.0152	0.00333	0.0227
7	0.0115	-0.00023	0.0202
8	0.0088	0.00033	0.0188
9	0.0063	-0.00316	0.0172
10	0.0040	-0.00842	0.0155

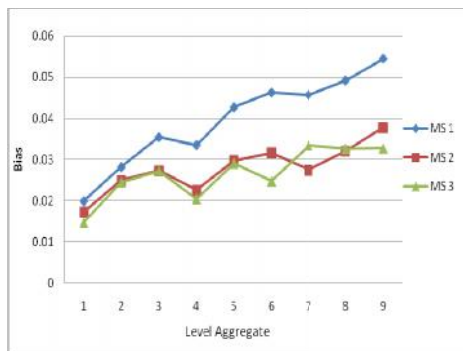
Tabel 6. Simulasi *Stock Aggregation* untuk Model Markov Switching $n = 2000$

m	bandwidth = 0.5		
	$\alpha_1 = 0.7$ $\alpha_2 = -0.2$	$\alpha_1 = 0.5$ $\alpha_2 = -0.4$	$\alpha_1 = 0.5$ $\alpha_2 = -0.4$
	$P_{00} = 0.9$ $P_{11} = -0.9$	$P_{00} = 0.9$ $P_{11} = -0.9$	$P_{00} = 0.9$ $P_{11} = -0.9$
	GPH 2	GPH 1	GPH 2
1	0.04729	0.0424	0.04244
2	0.03002	0.0354	0.02772
3	0.02232	0.0288	0.01791
4	0.01997	0.0242	0.01519
5	0.02470	0.0224	0.02196
6	0.01749	0.0195	0.01335
7	0.01564	0.0179	0.01767
8	0.01978	0.0156	0.00899
9	0.01520	0.0139	0.00986
10	0.00947	0.0127	0.00974

Plot dari hasil simulasi untuk lebih jelas menunjukkan bias yang terjadi disajikan pada Gambar 7 dan Gambar 8.



Gambar 7. GPH Terkoreksi untuk $n = 2000$



Gambar 8. GPH Tak Terkoreksi untuk $n = 2000$

Tabel 5 dan 6 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 4 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

KESIMPULAN

Properti *stock aggregation* dalam mendeteksi fenomena *Long Memory* dimana bias yang dihasilkan dengan menggunakan aggregasi ini lebih besar.

Baik menggunakan estimator GPH dengan bandwidth 0,5 Trend estimasi nilai d yang dihasilkan dengan aggregasi adalah menurun. Hal ini tidak sesuai dengan gagasan awal bahwa untuk mendeteksi fenomena *Long Memory*, parameter d hasil aggregasi tidak berbeda dengan parameter d tanpa aggregasi. 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 aggregasinya akan semakin besar pula informasi yang hilang. Pada kasus bangkitan Markov Switching, pengaruh aggregasi ini menunjukkan bahwa tidak ditemukan trend, baik menggunakan sampel 500 dan sampel 2000 tidak terlihat memberikan efek yang signifikan terhadap hasil estimasi parameter d ketika diaggregasi dengan GPH terkoreksi maupun GPH tidak terkoreksi.

DAFTAR PUSTAKA

- [1] Chambers, M. J., 1998, Long Memory And Aggregation In Macroeconomic Time Series. *International Economic Review* 39, 1053-1072.
- [2] Diebold, F. X. and Inoue, C. A. (2001) Long memory and regime switching. *Journal of Econometrics*, 105(1), 131-159.
- [3] 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.
- [4] Hamilton, J.D. (1989) A New Approach To The Economic Analysis Of Non Stationarity Times Series And The Business

-
-
- Cycle. *Econometrica* 57, 357-384.
- [5] Kuswanto, H. And Sibbertsen, P. (2008) A Study On Spurious Long Memory In Nonlinear Time Series Models. *Applied Mathematical Science*, 2(55), 2713-2734
- [6] 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
- [7] Parke, W.R. (1999) *What Is Fractional Integration? Review Of Economics And Statistics* 81, 632-638.
- [8] Timmermann, A. (2000). Moments Of Markov Switching Models. *Journal Of Econometrics* (96): 75-111.
- [9] Souza, L. R. (2003) Temporal Aggregation And Bandwidth Selection In Estimating Long Memory. *Journal Of Time Series Analysis* 28(5), 701-722.
- [10] Souza, L. R. (2005) Temporal Aggregation And Bandwidth Selection In Estimating Long Memory. *Journal Of Time Series Analysis* 28(5), 701-722.
- [11] Souza, L. R. (2008) Spectral Properties Of Temporally Aggregated Long Memory Process. *Brazilian Journal Of Probability And Statistics* 22(2), 135-155.
- [12] Zivot, E., & Wang, J. (2006). *Modelling Financial Time Series Models With S-PLUS*. New York: Springer.