

## SENSITIFITAS MODEL GARCH UNTUK MENGATASI HETEROKEDASTIK PADA DATA DERET WAKTU

Asep Saefuddin, Anang Kurnia dan Sutriyati

Departemen Statistika FMIPA IPB

### Ringkasan

Data deret waktu pada bidang keuangan sering kali memiliki galat yang tidak homogen (heteroskedastik). Hal ini bersifat alami terutama yang berhubungan dengan resiko memegang aset, dimana semakin besar resiko akan semakin besar pengembalian yang diterima dan sebaliknya. Metode yang cukup sederhana yang menggunakan informasi ragam galat sebelumnya untuk menghitung ragam galat saat ini adalah Model GARCH. Penelitian ini mencoba untuk mempelajari sensitifitas model GARCH dalam mengatasi heterokedastik pada data deret waktu. Hasil penelitian menunjukkan bahwa kemunculan nilai ekstrim  $> 1\%$  secara berurutan pada akhir periode, membuat pemodelan berbias untuk berbagai nilai  $T$ . Sedangkan apabila ekstrim menyebar secara acak di tengah periode pengamatan, menyebabkan penduga berbias pada  $T$  kecil (500). Untuk  $T=2000$ , penduga akan bias apabila terdapat nilai ekstrim lebih dari 10, sehingga untuk mendapatkan model yang kekar diperlukan jumlah data cukup besar (lebih dari 1000). Adapun untuk  $T$  kecil, ketika mulai terdapat volatilitas yang besar maka model cenderung untuk bias.

Kata kunci : Heterokedastis, GARCH.

### PENDAHULUAN

#### Latar Belakang

Salah satu kegunaan analisis data deret waktu adalah untuk menemukan pola sistematis sehingga dapat menyusun suatu model matematika yang dapat menjelaskan perilaku masa lalu dari deret tersebut. Kegunaan lain adalah untuk meramalkan nilai yang akan datang dari deret tersebut, yang pada akhirnya dapat mendukung proses pengambilan keputusan berdasarkan ketidakpastian. Pada umumnya, pemodelan dilakukan dengan asumsi galat konstan (*homoscedastic*). Pengalaman praktis menunjukkan banyak deret waktu yang memperlihatkan adanya periode-periode dengan volatilitas besar diikuti oleh periode-periode yang relatif tenang. Dalam hal ini, asumsi galat konstan menjadi tidak terpenuhi. Apabila analisis dengan asumsi galat konstan digunakan pada data seperti ini, akan mengakibatkan pengujian hipotesis mengenai parameter menjadi tidak sah. Lo (2003) mencatat beberapa karakteristik khusus dari peubah ekonomi yang tidak dapat diatasi oleh analisis deret waktu biasa, yaitu

1. Sebaran tak bersyarat dari data deret waktu memiliki ekor yang lebih panjang dari sebaran normal (*fat tail*).

2. Nilai  $Y_t$  tidak memiliki autokorelasi yang tinggi, tetapi nilai  $Y_t^2$  memiliki autokorelasi yang tinggi.
3. Perubahan pada  $Y_t$  cenderung menggerombol. Perubahan besar/kecil pada  $Y_t$  diikuti oleh perubahan yang besar/kecil pada periode berikutnya (*volatility clustering*).

Ada beberapa pendekatan yang dapat digunakan untuk menangani heteroskedastisitas. Salah satu pendekatan adalah secara eksplisit memasukkan peubah bebas yang dapat membantu memprediksi volatilitas. Akan tetapi pemilihan peubah bebas ini tidak mudah, karena dalam bidang ekonomi banyak sekali peubah bebas yang diduga berpengaruh tetapi bersifat kualitatif. Selain itu, peubah bebas yang digunakan harus memiliki periode yang sama (berpasangan).

Bollerslev dalam Enders (1995) menunjukkan, selain menggunakan peubah bebas dan melakukan transformasi, ada cara lain yaitu memodelkan rata-rata dan ragam secara simultan. Model ini dikenal dengan nama model GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*). Model GARCH adalah model tak linier bagi proses yang stasioner, dengan memasukkan ragam bersyarat sebagai parameter. Ragam diduga dari sisaan. Adapun sisaan tersebut tidak harus berasal dari model

autoregresi, tetapi dapat merupakan sisaan dari model ARMA atau model regresi standar.

Salah satu masalah yang dihadapi dalam penggunaan model GARCH adalah penentuan jumlah data yang digunakan. Umumnya, dalam analisis deret waktu semakin banyak data yang digunakan, akan menghasilkan pemodelan yang lebih baik. Anggapan ini akan tidak berlaku apabila sifat data mengalami perubahan perilaku yang mencolok dari waktu ke waktu.

Penelitian ini menggunakan pendekatan simulasi untuk melihat sejauh mana jumlah data pengamatan menimbulkan pendugaan yang berbias. Setelah diperoleh jumlah pengamatan optimum, dilanjutkan dengan simulasi untuk melihat pengaruh nilai-nilai ekstrim pada akhir pengamatan. Model GARCH yang dikaji dalam simulasi adalah GARCH(1,1) dengan fungsi rata-rata berupa konstanta. Model ini dipilih karena merupakan model yang sering dijumpai dalam aplikasi. Secara matematis dituliskan sebagai :

$$y_t = c + u_t; \quad u_t = \sqrt{h_t} \cdot v_t;$$

$$h_t = \delta_0 + \delta_1 h_{t-1} + \alpha_1 u_{t-1}^2$$

### Tujuan

Penelitian ini bertujuan untuk :

1. Menentukan banyaknya pengamatan yang optimal untuk pemodelan data dengan ragam galat tak homogen.
2. Menganalisis pengaruh nilai-nilai ekstrim terhadap pendugaan koefisien GARCH.
3. Menganalisis hasil pemodelan secara menyeluruh dibandingkan hasil pemodelan dengan pemotongan horison waktu.

### DATA DAN METODE

Data yang digunakan dalam penelitian ini adalah data simulasi proses GARCH(1,1). Langkah-langkah yang akan dilakukan dalam penelitian ini adalah :

1. Simulasi penentuan jumlah pengamatan optimal; dengan melakukan pemodelan menggunakan parameter awal yang berbeda-beda dengan jumlah pengamatan  $T = \{50, 100, 150, 200, 250, 300, 400, 500, 600, 1000, 2000\}$ .
2. Simulasi pemodelan melibatkan nilai-nilai ekstrim; data ekstrim sebanyak 1% sampai 25% dari jumlah data diletakkan secara acak ditengah pengamatan maupun secara berurutan pada akhir pengamatan.

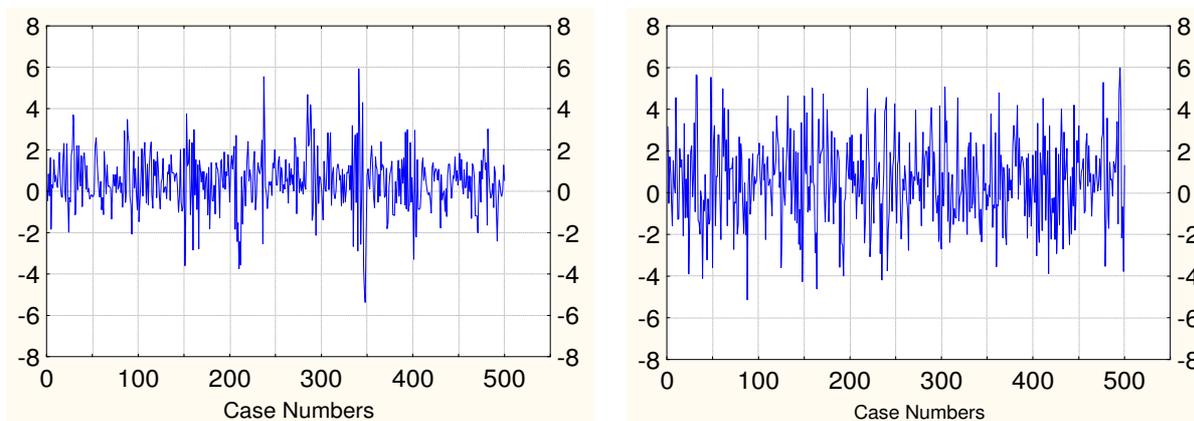
Simulasi dilakukan dengan langkah-langkah rekursif sebagai berikut:

1. Membangkitkan data  $v_t$  dari sebaran normal(0,1)
2. Nilai awal  $h_1 = \delta_0 / (1 - \delta_1 - \alpha_1)$  dan  $y_1 = c + u_1$
3. Menghitung  $h_t$  dan  $y_t$  secara rekursif untuk  $t=2, 3, \dots, T$ .
4. Simulasi diulang sebanyak 300 kali untuk mendapatkan selang kepercayaan 95% bagi rata-rata penduga  $\delta_1$

## HASIL DAN PEMBAHASAN

### Simulasi Penentuan Jumlah Pengamatan Optimal

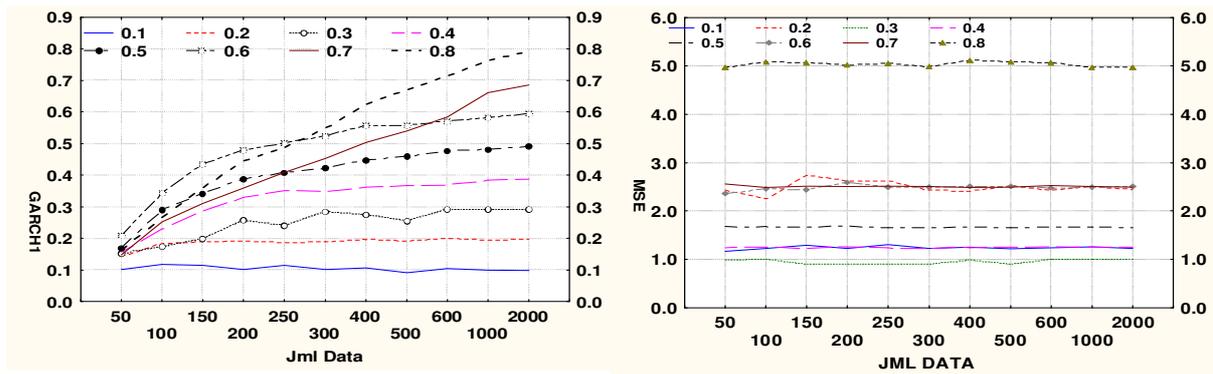
Simulasi dilakukan dengan membangkitkan data dari model GARCH(1,1) dengan parameter  $\delta_1 = (0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8)$ . Nilai-nilai ini dipilih berdasarkan syarat bahwa ragam bernilai positif dan  $0 < (\delta_1 + \alpha_1) < 1$  sehingga menghasilkan deret yang stasioner. Sebelum melakukan simulasi, terlebih dahulu dilihat karakteristik data dengan ragam galat tak homogen. Gambar 1 adalah contoh plot data dengan fungsi rata-rata berupa konstanta ( $c$ ) dan fungsi ragam GARCH(1,1) dengan persamaan :  $y_t = c + u_t; \quad u_t = \sqrt{h_t} \cdot v_t; \quad h_t = \delta_0 + \delta_1 h_{t-1} + \alpha_1 u_{t-1}^2$ . Hasil pembangkitan data dengan parameter



a).  $c = 0.5, \delta_1 = 0.2, \alpha_1 = 0.6$

b).  $c = 0.5, \delta_1 = 0.8, \alpha_1 = 0.1$

Gambar 1. Contoh hasil pembangkitan data dengan ragam galat tak homogen.



a). Penduga  $\delta_1$ ,

b). Mean Square Error (MSE)

Gambar 2. Grafik statistik hasil simulasi pemodelan GARCH(1,1) untuk berbagai jumlah pengamatan.

$\delta_1=0.2$  (Gambar 1.a) memiliki volatilitas yang lebih tenang dibandingkan pola data dengan parameter  $\delta_1=0.8$  (Gambar 1.b). Bagaimana pengaruh volatilitas seperti ini dalam proses pendugaan parameter disajikan dalam Gambar 2.

Kemiringan plot yang berbeda-beda pada Gambar 2.a menunjukkan bahwa semakin besar parameter  $\delta_1$ , semakin banyak jumlah pengamatan ( $T$ ) yang diperlukan untuk mendapatkan penduga yang tak bias. Hasil penduga beserta selang kepercayaan bagi rata-rata penduga disajikan pada Lampiran 1. Untuk  $\delta_1 \leq 0.2$ , 50 titik data sudah menghasilkan penduga yang tak bias, sedangkan untuk  $\delta_1 \geq 0.5$  memerlukan 500 titik data atau lebih. Hal ini berkaitan dengan makna model GARCH(1,1), dimana nilai  $\delta_1$  berbanding lurus dengan volatilitasnya. Volatilitas yang besar berarti memiliki banyak nilai-nilai yang dapat dianggap ekstrim. Banyaknya nilai ekstrim akan mengganggu proses pemodelan terutama pada  $\delta_1 \geq 0.7$  dimana untuk membuat model yang tak bias diperlukan  $T \geq 1000$ .

Pengaruh keheterogenan ragam sulit dideteksi untuk jumlah pengamatan ( $T$ ) yang kecil. Pada Gambar 2 terlihat bahwa untuk  $T = 50$ , dan  $\delta_1 \geq 0.2$ , penduga yang diperoleh selalu berada di sekitar 0.2 atau selalu lebih kecil dari parameternya. Hal ini dapat terjadi karena proses pendugaan dilakukan dengan cara iterasi. Secara umum iterasi dilakukan dengan nilai awal nol. Alternatif pemecahan masalah penduga yang *underestimated* adalah dengan membuat batasan nilai awal koefisien  $\delta_1$  yang tidak terlalu jauh dari nilai sebenarnya. Berdasarkan hasil simulasi di atas, dapat digunakan nilai awal = 0.2. Cara lain untuk mendapatkan nilai awal adalah menggunakan koefisien  $\delta_1$  adalah dari koefisien yang diperoleh dari penduga OLS dari regresi diri nilai sisaan kuadrat ( $u_t^2$  pada persamaan [3]).

Keuntungan menggunakan nilai awal adalah memperoleh penduga yang tak bias serta mempercepat proses kekonvergenan

Pola garis lurus pada Gambar 2.b mengindikasikan bahwa MSE (ragam sisaan) tidak dipengaruhi oleh  $T$ , makin besar  $\delta_1$ , makin besar juga MSE, artinya sejalan dengan penduga  $\delta_1$ , makin besar  $\delta_1$  sebenarnya, makin sulit untuk memperoleh model yang *fit* akibat banyaknya nilai-nilai ekstrim. MSE yang diperoleh hampir sama untuk semua  $T$ , tetapi sebenarnya pendugaan berbias untuk  $T$  yang kecil. Oleh karena itu MSE tidak dapat diandalkan untuk memeriksa keefisienan model.

### Simulasi Pengaruh Nilai Ekstrim dalam Pendugaan Parameter $\delta_1$

Simulasi dilakukan dengan membangkitkan nilai-nilai ekstrim antara 1% sampai 25% relatif terhadap jumlah data asal ( $T = 500, 1000, 2000$ ). Nilai ekstrim diletakkan pada akhir pengamatan secara berurutan. Data asal dibangkitkan dengan parameter  $\delta_{11}$  dan  $c_1$ , sedangkan data ekstrim dari populasi dengan parameter  $\delta_{12}$  dan  $c_2$ . Skenario disusun untuk bentuk : perubahan sedang ( $c_1=0.5$  menjadi 2 dan  $\delta_1$  berubah sebesar 0.1); perubahan sangat ekstrim pada nilai tengah ragam ( $c_1 = 0.5$  menjadi 5 atau  $\delta_1$  berubah sebesar 0.3). Ada 4 skenario awal, yaitu :

- $\delta_{11}=0.4 \ \delta_{12}=0.5 \ c_1=0.5 \ c_2=2;$
- $\delta_{11}=0.4 \ \delta_{12}=0.7 \ c_1=0.5 \ c_2=2$
- $\delta_{11}=0.4 \ \delta_{12}=0.5 \ c_1=0.5 \ c_2=5;$
- $\delta_{11}=0.6 \ \delta_{12}=0.7 \ c_1=0.5 \ c_2=2$

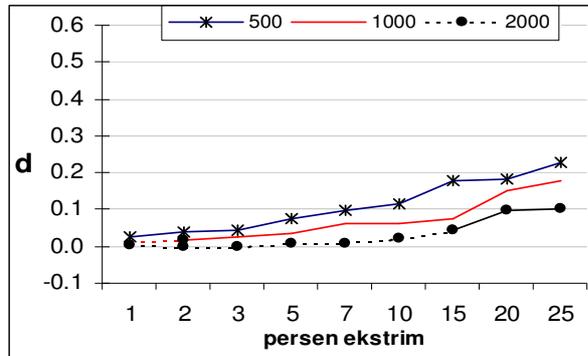
Model dievaluasi dengan menghitung selisih penduga  $\delta_1$  (setelah ada ekstrim -sebelum ada ekstrim). Dari 300 kali ulangan, diperoleh rata-rata selisih penduga  $\delta_1$  beserta selang kepercayaan 95%. Pendugaan dikatakan berbias

apabila selisih penduga  $\delta_1$  berada diluar selang kepercayaan 95% (berbeda nyata dari nol).

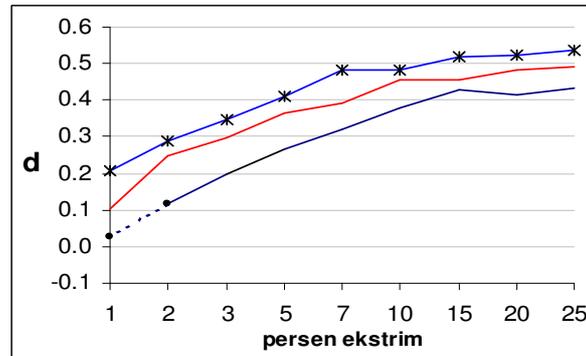
Hasil pendugaan skenario a-d dapat dilihat pada Lampiran 2. Hasil pendugaan untuk skenario a memperlihatkan bahwa kemunculan nilai-nilai ekstrim lebih dari 1% akan menghasilkan dugaan yang bias. MSE relatif sama untuk berbagai nilai T. MSE akan berubah menjadi besar ketika persentase ekstrim melebihi

kemudian mengalami perubahan yang besar.

Gambar 3 adalah bias dari penduga  $\delta_1$ . Garis terputus artinya penduga tidak bias. Semakin banyak jumlah data yang digunakan, semakin kecil pengaruh nilai-nilai ekstrim yang ditunjukkan oleh nilai d. Perbedaan pola garis dari Gambar 3.a dan 3.b menunjukkan bahwa kemunculan ekstrim secara berurutan akan menyebabkan penyimpangan dari model secara



a) Nilai ekstrim acak



b). Nilai ekstrim di akhir

Gambar 3. Bias (d) penduga  $\delta_1$  dengan Menambahkan Nilai-Nilai Ekstrim dengan Parameter  $\delta_{11}=0.40$   $\delta_{12}=0.50$   $c_1=0.5$   $c_2=5$

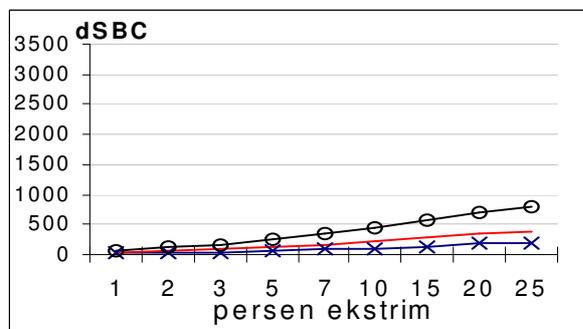
Ket. gambar: garis terputus artinya penduga tidak berbias.  
 d = selisih penduga  $\delta_1$  setelah dan sebelum ditambah data ekstrim

5%. Dari empat skenario yang dievaluasi, rata-rata penduga akan berbias pada penambahan nilai ekstrim lebih dari 1% dan bias semakin besar dengan bertambahnya T.

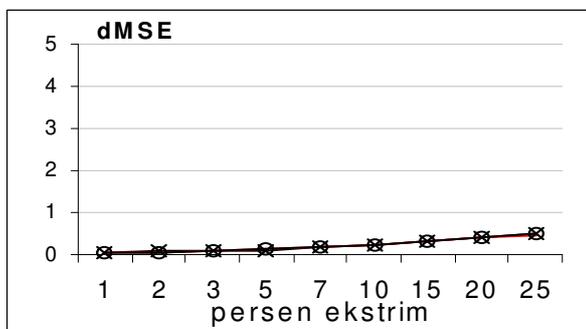
Berdasarkan hasil di atas, dikembangkan simulasi untuk menghitung bias secara umum dengan mengambil parameter dari skenario c. Simulasi dilakukan dengan : a) menambahkan ekstrim secara acak di tengah periode pengamatan; b) menambahkan ekstrim secara berurutan pada akhir periode pengamatan. Ide dasar dari bentuk (b) adalah apabila mulai terjadi perubahan perilaku deret secara mencolok (ekstrim) dari kondisi yang relatif tenang

lebih cepat dan lebih besar. Hal ini terlihat dari kemiringan garis yang lebih tajam serta adanya bias yang lebih besar.

Adanya nilai-nilai ekstrim secara acak sejumlah kurang dari 15% tidak akan mengakibatkan pendugaan berbias pada T=2000. Kemunculan nilai ekstrim secara berurutan akan menyebabkan penduga berbias kecuali untuk T = 500 dan nilai ekstrim = 1%. Dari hasil ini dapat disimpulkan bahwa untuk mendapatkan model yang kekar diperlukan jumlah data yang banyak (lebih dari 1000). Sedangkan kegunaan model dengan jumlah data sedikit adalah akan dapat digunakan untuk deteksi adanya nilai-nilai yang



a) Nilai ekstrim acak



b). Nilai ekstrim di akhir

Gambar 4. Grafik selisih SBC maupun MSE pendugaan parameter

Ket. gambar : dSBC = selisih SBC setelah dan sebelum ditambah data ekstrim  
 dMSE = selisih MSE setelah dan sebelum ditambah data ekstrim

tak wajar.

Pengaruh persentase nilai ekstrim terhadap pendugaan dapat dilihat dari besarnya selisih SBC maupun selisih MSE (Gambar 4). SBC dan MSE meningkat secara linier dengan meningkatnya persentase nilai ekstrim yang terlibat.

Dari 300 ulangan, penduga  $\delta_1$  tidak menyebar normal, karena banyak ditemukan kasus hasil dugaan  $\delta_1 = 0$ , meskipun parameter sebenarnya adalah 0.4.

## KESIMPULAN

Hasil penelitian menunjukkan bahwa jumlah pengamatan yang diperlukan untuk memperoleh penduga yang tak bias tergantung pada volatilitas data (nilai  $\delta_1$ ), dimana semakin besar volatilitas semakin banyak jumlah data yang diperlukan.

Simulasi nilai ekstrim menunjukkan bahwa kemunculan nilai ekstrim lebih besar dari 1% secara berurutan pada akhir periode, membuat pemodelan berbias untuk berbagai nilai T. Sedangkan apabila ekstrim menyebar secara acak di tengah periode pengamatan, menyebabkan penduga berbias pada T kecil (500). Untuk T cukup besar (2000) penduga akan bias apabila terdapat nilai ekstrim lebih dari 10% .

Untuk mendapatkan model yang kekar diperlukan jumlah data yang cukup besar (lebih dari 1000) dan jika T kecil, ketika mulai terdapat volatilitas yang besar maka model cenderung untuk bias.

## DAFTAR PUSTAKA

- Arsham, H.** 2002. Time Series Analysis and Forecasting techniques. <http://ubmail.ubalt.edu/~harsham/stat-data/opre330Forecast.htm>. Dikunjungi pada tanggal 16 September 2002
- Campbell, J. Y., A. W. Lo. & A.C. MacKinlay.** 1996. The Econometrics of Financial Markets. University Press. Princeton.
- Cryer, J. D.** 1986. Time-series Analysis. PWS Publishers. USA.
- Enders, W.** 1995. Applied Econometric Time Series. 1<sup>st</sup> ed. John Wiley & Sons, Inc. Canada.
- Engle, R. F.** 2001. The Use of ARCH/GARCH models in Applied Econometrics. Journal of Economic Perspectives 4.157-168.
- Eviews User's Guide.** 2<sup>nd</sup> Edition. 1994. Quantitative Micro Software. USA.

**Hamilton, J. D.** 1994. Time Series Analysis. Princeton University Press. New Jersey.

**Li, W. K, Ling, S, McAleer, M.** 2001. A Survey of Recent Theoretical Result for Time Series Models with GARCH Errors. The Institute of Social & Economic Research, Osaka University.

**Lo, M.S.** 2003. Generalized Autoregressive Conditional Heteroscedasticity Time Series Model. Thesis Department of Statistics and Actuarial Science. Simon Fraser University, Spanyol.

**Mankiw, N. G.** 2000. Ed.4. Teori Makroekonomi. Alih bahasa, Imam Nurmawan. Erlangga, Jakarta.

**SAS Institute Inc.** 1988. SAS/ETS<sup>®</sup> User's Guide. Version 6, First Edition. Cary, NC : SAS Institute Inc.

**Wei, W. W. S.** 1994. Time Series Analysis. Addison-Wesley Publishing Company. USA.

Lampiran 1. Hasil simulasi pendugaan parameter GARCH(1,1) pada berbagai kombinasi koefisien GARCH1 dan jumlah data pengamatan

a. Penduga GARCH1

| Jml Data | GARCH1=0.1  |      |      | GARCH1=0.2  |      |      | GARCH1=0.3  |      |      | GARCH1=0.4  |      |      | GARCH1=0.5  |      |      | GARCH1=0.6  |      |      | GARCH1=0.7  |      |      | GARCH1=0.8  |      |      |
|----------|-------------|------|------|-------------|------|------|-------------|------|------|-------------|------|------|-------------|------|------|-------------|------|------|-------------|------|------|-------------|------|------|
|          | LCLM        | UCLM |      | LCLM        | UCLM |      | LCLM        | UCLM |      | LCLM        | UCLM |      | LCLM        | UCLM |      | LCLM        | UCLM |      | LCLM        | UCLM |      | LCLM        | UCLM |      |
| 50       | <b>0.10</b> | 0.08 | 0.12 | 0.14        | 0.12 | 0.16 | 0.15        | 0.13 | 0.18 | 0.16        | 0.13 | 0.18 | 0.17        | 0.14 | 0.20 | 0.21        | 0.18 | 0.24 | 0.15        | 0.12 | 0.18 | 0.16        | 0.13 | 0.19 |
| 100      | <b>0.12</b> | 0.10 | 0.14 | <b>0.18</b> | 0.16 | 0.20 | 0.17        | 0.15 | 0.20 | 0.23        | 0.20 | 0.26 | 0.29        | 0.26 | 0.32 | 0.34        | 0.31 | 0.38 | 0.25        | 0.22 | 0.29 | 0.27        | 0.23 | 0.30 |
| 150      | <b>0.11</b> | 0.10 | 0.13 | <b>0.19</b> | 0.17 | 0.21 | 0.20        | 0.17 | 0.22 | 0.29        | 0.26 | 0.32 | 0.34        | 0.31 | 0.37 | 0.43        | 0.40 | 0.47 | 0.31        | 0.28 | 0.35 | 0.36        | 0.32 | 0.40 |
| 200      | <b>0.10</b> | 0.09 | 0.11 | <b>0.19</b> | 0.18 | 0.21 | 0.26        | 0.23 | 0.29 | 0.33        | 0.30 | 0.36 | 0.39        | 0.36 | 0.42 | 0.48        | 0.45 | 0.51 | 0.36        | 0.32 | 0.39 | 0.45        | 0.41 | 0.48 |
| 250      | <b>0.11</b> | 0.10 | 0.13 | <b>0.19</b> | 0.17 | 0.20 | 0.24        | 0.22 | 0.27 | 0.35        | 0.33 | 0.38 | 0.41        | 0.38 | 0.44 | 0.50        | 0.48 | 0.53 | 0.41        | 0.38 | 0.44 | 0.49        | 0.45 | 0.52 |
| 300      | <b>0.10</b> | 0.09 | 0.11 | <b>0.19</b> | 0.18 | 0.20 | <b>0.28</b> | 0.26 | 0.31 | 0.35        | 0.32 | 0.38 | 0.42        | 0.40 | 0.45 | 0.52        | 0.50 | 0.54 | 0.45        | 0.42 | 0.49 | 0.55        | 0.51 | 0.59 |
| 400      | <b>0.11</b> | 0.10 | 0.12 | <b>0.20</b> | 0.19 | 0.21 | <b>0.27</b> | 0.25 | 0.30 | <b>0.36</b> | 0.34 | 0.39 | 0.45        | 0.43 | 0.47 | 0.56        | 0.54 | 0.58 | 0.50        | 0.47 | 0.54 | 0.63        | 0.59 | 0.66 |
| 500      | <b>0.09</b> | 0.08 | 0.10 | <b>0.19</b> | 0.18 | 0.20 | 0.26        | 0.24 | 0.28 | <b>0.37</b> | 0.34 | 0.39 | <b>0.46</b> | 0.44 | 0.48 | 0.56        | 0.54 | 0.58 | 0.54        | 0.51 | 0.57 | 0.67        | 0.64 | 0.70 |
| 600      | <b>0.10</b> | 0.10 | 0.11 | <b>0.20</b> | 0.19 | 0.21 | <b>0.29</b> | 0.27 | 0.31 | <b>0.37</b> | 0.35 | 0.39 | <b>0.48</b> | 0.46 | 0.49 | <b>0.57</b> | 0.56 | 0.59 | 0.59        | 0.56 | 0.61 | 0.71        | 0.69 | 0.74 |
| 1000     | <b>0.10</b> | 0.09 | 0.11 | <b>0.19</b> | 0.19 | 0.20 | <b>0.29</b> | 0.27 | 0.31 | <b>0.38</b> | 0.37 | 0.40 | <b>0.48</b> | 0.47 | 0.50 | <b>0.58</b> | 0.57 | 0.59 | <b>0.66</b> | 0.65 | 0.68 | 0.76        | 0.75 | 0.78 |
| 2000     | <b>0.10</b> | 0.09 | 0.10 | <b>0.20</b> | 0.19 | 0.20 | <b>0.29</b> | 0.28 | 0.30 | <b>0.39</b> | 0.38 | 0.40 | <b>0.49</b> | 0.48 | 0.50 | <b>0.60</b> | 0.59 | 0.60 | <b>0.69</b> | 0.68 | 0.69 | <b>0.79</b> | 0.79 | 0.80 |

b. MSE (Mean Square Error)

| Jml Data | GARCH1=0.1 |      |      | GARCH1=0.2 |      |      | GARCH1=0.3 |      |      | GARCH1=0.4 |      |      | GARCH1=0.5 |      |      | GARCH1=0.6 |      |      | GARCH1=0.7 |      |      | GARCH1=0.8 |      |      |
|----------|------------|------|------|------------|------|------|------------|------|------|------------|------|------|------------|------|------|------------|------|------|------------|------|------|------------|------|------|
|          | MSE        | LCLM | UCLM |
| 50       | 1.17       | 1.10 | 1.23 | 2.43       | 2.13 | 2.72 | 0.99       | 0.95 | 1.02 | 1.24       | 1.20 | 1.29 | 1.67       | 1.61 | 1.74 | 2.36       | 2.26 | 2.46 | 2.56       | 2.47 | 2.64 | 4.97       | 4.74 | 5.20 |
| 100      | 1.23       | 1.17 | 1.30 | 2.25       | 2.06 | 2.44 | 1.00       | 0.97 | 1.02 | 1.25       | 1.22 | 1.28 | 1.67       | 1.63 | 1.72 | 2.47       | 2.38 | 2.55 | 2.49       | 2.43 | 2.54 | 5.08       | 4.90 | 5.26 |
| 150      | 1.29       | 1.22 | 1.35 | 2.73       | 2.12 | 3.35 | 0.90       | 0.89 | 0.92 | 1.23       | 1.20 | 1.25 | 1.68       | 1.64 | 1.72 | 2.45       | 2.38 | 2.52 | 2.51       | 2.46 | 2.56 | 5.07       | 4.92 | 5.22 |
| 200      | 1.23       | 1.18 | 1.28 | 2.63       | 2.14 | 3.11 | 0.90       | 0.89 | 0.92 | 1.26       | 1.24 | 1.28 | 1.70       | 1.66 | 1.73 | 2.59       | 2.52 | 2.66 | 2.51       | 2.46 | 2.55 | 5.02       | 4.89 | 5.14 |
| 250      | 1.31       | 1.15 | 1.46 | 2.62       | 1.98 | 3.27 | 0.90       | 0.89 | 0.91 | 1.24       | 1.22 | 1.26 | 1.66       | 1.63 | 1.68 | 2.49       | 2.44 | 2.55 | 2.51       | 2.47 | 2.55 | 5.05       | 4.95 | 5.16 |
| 300      | 1.23       | 1.20 | 1.26 | 2.43       | 2.28 | 2.58 | 0.91       | 0.90 | 0.92 | 1.23       | 1.21 | 1.25 | 1.66       | 1.63 | 1.69 | 2.49       | 2.44 | 2.54 | 2.50       | 2.46 | 2.54 | 4.98       | 4.89 | 5.07 |
| 400      | 1.25       | 1.22 | 1.28 | 2.41       | 2.28 | 2.54 | 0.98       | 0.97 | 1.00 | 1.24       | 1.23 | 1.26 | 1.67       | 1.64 | 1.70 | 2.51       | 2.46 | 2.55 | 2.49       | 2.46 | 2.51 | 5.11       | 5.01 | 5.21 |
| 500      | 1.22       | 1.19 | 1.24 | 2.53       | 2.32 | 2.75 | 0.91       | 0.90 | 0.91 | 1.25       | 1.24 | 1.26 | 1.66       | 1.64 | 1.68 | 2.51       | 2.47 | 2.55 | 2.49       | 2.46 | 2.52 | 5.08       | 5.00 | 5.17 |
| 600      | 1.24       | 1.22 | 1.27 | 2.42       | 2.31 | 2.53 | 1.00       | 0.99 | 1.01 | 1.26       | 1.24 | 1.27 | 1.67       | 1.65 | 1.69 | 2.47       | 2.44 | 2.50 | 2.52       | 2.49 | 2.55 | 5.06       | 4.99 | 5.13 |
| 1000     | 1.26       | 1.23 | 1.29 | 2.51       | 2.37 | 2.66 | 1.00       | 0.99 | 1.01 | 1.25       | 1.23 | 1.26 | 1.67       | 1.65 | 1.68 | 2.50       | 2.47 | 2.52 | 2.50       | 2.48 | 2.52 | 4.96       | 4.91 | 5.02 |
| 2000     | 1.23       | 1.22 | 1.25 | 2.44       | 2.36 | 2.52 | 1.00       | 1.00 | 1.01 | 1.25       | 1.25 | 1.26 | 1.66       | 1.65 | 1.67 | 2.50       | 2.48 | 2.52 | 2.49       | 2.48 | 2.51 | 4.97       | 4.93 | 5.01 |

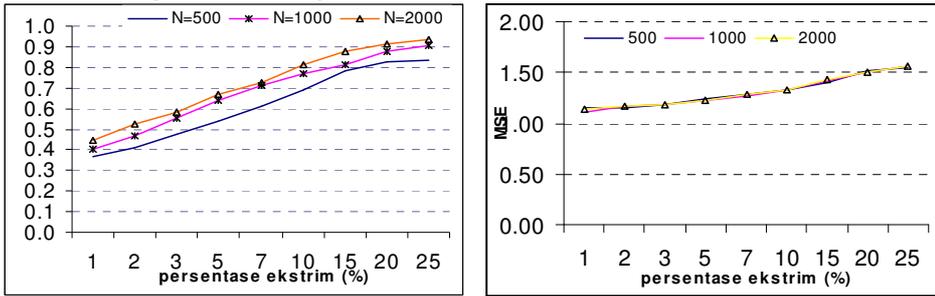
Keterangan :

LCLM = Lower Confidence Limit of Mean

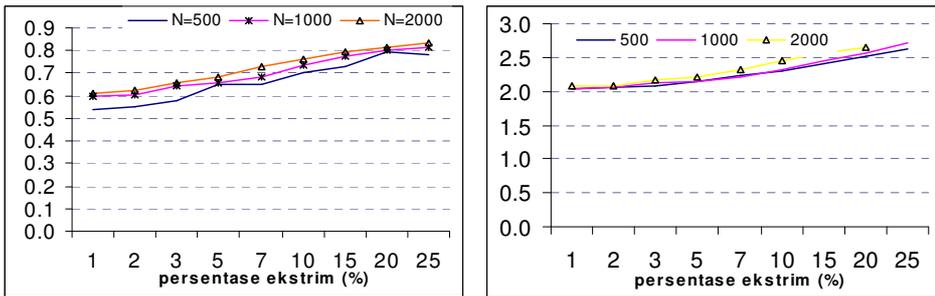
UCLM = Upper Confidence Limit of Mean

Lampiran 2. Hasil pendugaan GARCH1 dengan Menambahkan Nilai-Nilai Ekstrim dengan beberapa kombinasi parameter

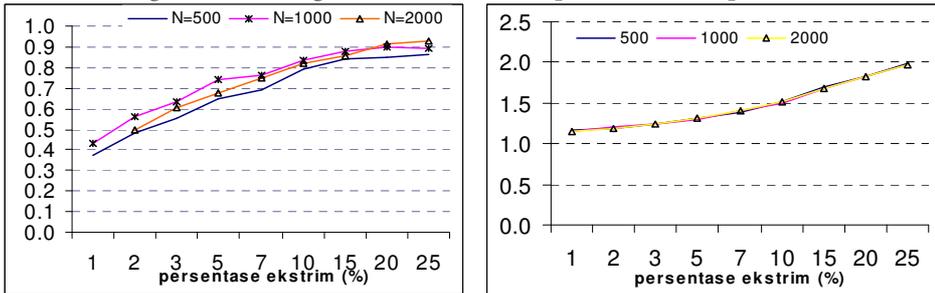
Skenario A:  $garch1=0.600$   $garch2=0.500$   $intercep1= 0.5$   $intercept2=2$



Skenario B:  $garch1=0.600$   $garch2=0.700$   $intercep1= 0.5$   $intercept2=2$



Skenario C:  $garch1=0.400$   $garch2=0.700$   $intercep1= 0.5$   $intercept2=2^*/$



Skenario D:  $garch1=0.400$   $garch2=0.500$   $intercep1= 0.5$   $intercept2=5$

