

Justyna Majewska

Metody odpornej estymacji dla modeli klasy GARCH

Studia i Prace Wydziału Nauk Ekonomicznych i Zarządzania 10, 534-543

2008

Artykuł został opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej bazhum.muzhp.pl, gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach dozwolonego użytku.

JUSTYNA MAJEWSKA

METODY ODPORNEJ ESTYMACJI DLA MODELI KLASY GARCH

Modele GARCH są obecnie najczęściej stosowanymi modelami do prognozowania zmienności (volatility) w finansowych szeregach czasowych z uwagi na uwzględnianie grubych ogonów rozkładów stóp zmian czy zjawiska grupowania wariancji.

Parametry modeli heteroskedastycznych mogą być szacowane metodą największej wiarygodności. W przypadku spełnienia założenia o normalności rozkładu metoda ta pozwala na uzyskanie asymptotycznie efektywnych ocen parametrów. Metoda quasi największej wiarygodności (QML) stała się standardową metodą estymacji modeli klasy GARCH. I choć metoda ta daje zgodne oszacowania parametrów nawet gdy rozkład nie jest rozkładem normalnym zarzuca się jej wysokie wartości błędów prognoz (RMSE) oraz nieefektywność, zwiększającą się wraz z poziomem odchylenia się od normalności (Harvey 1984, Jacquier i in. 1994).

Wybór metody estymacji parametrów modelu GARCH przekłada się na oszacowanie zmienności – kluczowego parametru w wycenie opcji i zarządzaniu ryzykiem. Odkąd modele GARCH zostały zastosowane do modelowania finansowych szeregów czasowych zaobserwowano, że szeregi reszt tych modeli nadal wykazują grube ogony. Widoczne jest to również, choć w nieco mniejszym stopniu, w powstałych rozszerzeniach modeli GARCH. Tłumaczyć to można występowaniem w finansowych szeregach czasowych obserwacji odstających, tzw. *outliers*. Szczególne znaczenie mają zjawiska jednorazowe (*additive outliers, AO*), stanowiące istotne pojedyncze odchylenie od przewidywanej wartości badanego zjawiska tylko w jednym okresie, nie wpływające na wartości szeregu w następnych okresach.

Efekt wpływu *outliers* na estymację klasy modeli (G)ARCH był niejednokrotnie analizowany. Na uwagę zasługują prace dotyczące estymacji parame-

trów tych modeli w obecności punktów odstających z zastosowaniem odpornych metod.

Jednym z podejść jest iteracyjne „przycinanie” punktów odstających i dopasowywanie modelu do pozostałych danych do momentu wyeliminowania wszystkich punktów odstających (Franses i Ghijsels, 1999). Inne propozycje koncentrują się wokół zastosowania estymatorów odpornych na punkty odstające. Na uwagę zasługują Park (2002), który zaprezentował estymator oparty na regresji odpornej LAD, Mancini (2005), Muler i Yohai (2002, 2007), którzy zaproponowali pewne modyfikacje odpornych M-estymatorów oraz Rieder, Ruckdeschel, Kohl (2002), którzy wyszli z propozycją klasy odpornych estymatorów w celu minimalizacji błędu średniokwadratowego w sąsiedztwie zaburzeń.

Głównym celem pracy jest zaprezentowanie wybranych odpornych metod estymacji dla standardowego modelu GARCH. Dokonamy porównania tych metod z szeroko stosowaną metodą – quasi największej wiarygodności w oparciu o analizę empiryczną. Autor chce przekonać, że modyfikacje metody największej wiarygodności w przypadku warunkowej heteroskedastyczności dają lepsze wyniki w oparciu o odporne metody estymacji niż gaussowska QML estymacja.

Wybrane metody odpornej estymacji dla klasy modeli (G)ARCH

Ogólne założenia estymacji odpornej

W modelach szacowanych na podstawie szeregów danych finansowych składniki losowe rzadko spełniają założenie o normalności rozkładu. W konsekwencji estymatory metody najmniejszych kwadratów są nieefektywne. Oszacowania wariancji są niepoprawne, w efekcie czego moc standardowo używanych testów jest niska. Jeżeli estymatory mają nieskończone wariancje nie powinniśmy używać klasycznych procedur testowych. Problemy związane z estymacją przy występowaniu obserwacji odstających doprowadziły do rozwinięcia odpornych metod estymacji. Metody odporne są obecne w statystyce matematycznej od ponad pół wieku, zaś głównym celem statystyki odpornej jest nie tylko dostarczanie narzędzi pozwalających na ocenę odporności klasycznych metod statystycznych, ale zarówno dostarczanie nowych estymatorów i

testów, które charakteryzują się odpornością na pewne odstępstwa od założonego modelu.

Według Hubera (1981) odporne metody estymacji winny posiadać następujące dwie własności:

- H1) Estymacja powinna być efektywna gdy wszystkie obserwacje z próby pochodzą z założonego modelu.
- H2) Zastąpienie niewielkiej części obserwacji obserwacjami odstającymi powinno mieć nieznaczny wpływ na wynik estymacji.

Tylko nieliczne estymatory proponowane w literaturze spełniają obydwie własności. W przypadku warunkowej heteroskedastyczności można wyróżnić różne podejścia jak radzić sobie z obserwacjami istotnie różniącymi się od pozostałych. Pierwsze podejście polega na identyfikacji i korekcie obserwacji odstających przed estymacją parametrów równania warunkowej wariancji. Odporne metody mogą być zastosowane do estymacji parametrów równania wariancji i/lub do oszacowania początkowej wariancji. W pracy skupimy się na oszacowaniu metodami odpornymi parametrów modelu GARCH(p,q).

M-estymacja oraz BM-estymacja

Model GARCH jest powszechnie znany, jednak dla wprowadzenia oznaczeń podajemy podstawową specyfikację modelu GARCH(p,q).

Niech r_t będzie stopą zwrotu zdefiniowana jako: $r_t = \log(p_t / p_{t-1})$, gdzie p_t jest ceną instrumentu finansowego. Model GARCH(p,q) (Engle, Bollerslev, 1986) jest zdefiniowany następująco:

$$r_t = E[r_t | \Omega_{t-1}] + \varepsilon_t, \varepsilon_t = z_t \sigma_t, z_t \sim \text{iid}(0,1), E[\varepsilon_t^2 | \Omega_{t-1}] = \sigma_t^2, \quad (1)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^q \beta_i \sigma_{t-i}^2 \quad t = 1, \dots, T, \quad (2)$$

gdzie Ω_{t-1} jest informacją dostępną do czasu $t-1$ oraz $\alpha_0 > 0, \alpha_i \geq 0 \quad i = 1, \dots, p, \beta_i \geq 0 \quad i = 1, \dots, q$.

Hall i Yao (2003) pokazali, że jawna postać σ_t^2 przybiera formę:

$$\sigma_t^2 = \frac{\alpha_0}{1 - \sum_{i=1}^q \beta_i} + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \alpha_i \sum_{k=1}^{\infty} \sum_{j_1=1}^q \dots \sum_{j_k=1}^q \beta_{j_1} \dots \beta_{j_k} \varepsilon_{t-i-j_1-\dots-j_k}^2. \quad (3)$$

Niech $x_t^2 = \log(\varepsilon_t^2)$ oraz $\omega_t = \log(z_t)$.

Wtedy otrzymujemy: $x_t = \omega_t + \log \sigma_t^2$.

Niech f będzie funkcją gęstości z_t symetryczną względem 0, wtedy funkcja gęstości ω_t jest postaci:

$$g(\omega) = e^{\frac{\omega}{2}} f(e^{\frac{\omega}{2}}). \quad (4)$$

W szczególności, gdy f jest funkcją gęstości zestandaryzowanego rozkładu normalnego mamy: $g = g_0$ gdzie

$$g_0(\omega) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(e^\omega - \omega)}. \quad (5)$$

Jak już wcześniej wspomniano do estymacji parametrów modelu GARCH(p,q) można zastosować metodę quasi największej wiarygodności, którą to funkcję-kryterium zapisujemy następująco:

$$-\frac{1}{2} \sum_{t=p+1}^T \frac{\varepsilon_t^2}{\tilde{\sigma}_t^2} - \frac{1}{2} \sum_{t=p+1}^T \log \tilde{\sigma}_t^2 \Rightarrow \max \quad (6)$$

gdzie

$$\tilde{\sigma}_t^2 = \frac{\alpha_0}{1 - \sum_{i=1}^q \beta_i} + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \alpha_i \sum_{k=1}^{\infty} \sum_{j_1=1}^q \dots \sum_{j_k=1}^q \beta_{j_1} \dots \beta_{j_k} \varepsilon_{t-i-j_1-\dots-j_k}^2 I_{t-i-j_1-\dots-j_k \geq 1}. \quad (7)$$

Uwzględniając, że $x_t^2 = \log(\varepsilon_t^2)$ (6) może być zapisana jako:

$$-\frac{1}{2} \sum_{t=p+1}^T (e^{x_t - \log \tilde{\sigma}_t^2} + \log \tilde{\sigma}_t^2).$$

Maksymalizacja (6) jest równoważna maksymalizacji :

$$L_{0,T} = \sum_{t=p+1}^T \log(g_0(x_t - \log \tilde{\sigma}_t^2)), \quad (8)$$

gdzie g_0 dana jest (5).

Następnie, maksymalizacja (8) jest równoważna minimalizacji

$$M_{0,T}(\theta) = \frac{1}{T-p} \sum_{t=p+1}^T \rho_0(x_t - \log \tilde{\sigma}_t^2), \quad (9)$$

gdzie

$$\rho_0 = -\log(g_0), \quad (10)$$

a g_0 dana jest (5).

W podobny sposób można dowieść, że estymację metodą największej wiarygodności dla GARCH(p,q) (z dowolną symetryczną funkcją f^*) otrzymujemy poprzez minimalizację

$$\frac{1}{T-p} \sum_{t=p+1}^T \rho^*(x_t - \log \tilde{\sigma}_t^2)$$

dla $\rho^* = -\log(g^*)$, g^* jest dana wzorem (4) z $f = f^*$.

Jednym z powodów braku odporności estymatora quasi największej wiarygodności jest nieograniczoność funkcji ρ_0 .

Muler i Yohai (2006) zaproponowali dwie klasy odpornych metod estymacji dla modelu GARCH. Pierwsza może być rozpatrywana jako rozszerzenie M-estymacji parametru położenia i regresji (Huber, 1964, 1973). Druga natomiast zawiera pewną dodatkową procedurę dla ograniczenia rozpowszechniania się efektu jednego punktu odstającego na oszacowanie kolejnej warunkowej wariancji.

Oznaczmy przez θ wektor nieznanych parametrów $\theta = (\alpha_0, \alpha_1, \beta_1)'$.

W celu zdefiniowania pierwszej metody estymacji niech

$$M_T(\theta) = \frac{1}{T-p} \sum_{t=p+1}^T \rho(\log \varepsilon_t^2 - \log \tilde{\sigma}_t^2). \quad (11)$$

Wtedy M-estymacja parametrów modelu GARCH zdefiniowana jest jako

$$\hat{\theta}_1 = \arg \min_{\theta} M_T(\theta). \quad (12)$$

Wyróżnia się dwa typy M-estymacji (i) M-estymację z ρ nieograniczoną oraz ρ' ograniczoną oraz (ii) M-estymację z ρ oraz ρ' ograniczonymi.

Pierwsza metoda estymacji jest odporna, gdy dla z_t został przyjęty rozkład o grubych ogonach (choć mimo to pewne punkty odstające mogą mieć wpływ na oszacowania). By zwiększyć stopień odporności należy dobrać w (11) ograniczoną funkcję ρ .¹

Estymatory uzyskane w wyniku tej metody są zgodne i asymptotycznie normalne. Metoda ta spełnia warunek H1, lecz nie spełnia H2, choć jest mniej wrażliwa na zaburzenia w próbie niż metoda QML. Zatem w celu osiągnięcia odporności M-estymacja dla modelu GARCH została zmodyfikowana, w wyniku, czego otrzymujemy następującą postać wariancji warunkowej:

$$\tilde{\sigma}_{t,k}^{*2} = \alpha_0 + \sum_{i=1}^p \alpha_i r_k \left(\frac{\varepsilon_{t-i}^2}{\tilde{\sigma}_{t-i,k}^{*2}} \right) \tilde{\sigma}_{t-i,k}^{*2} + \sum_{i=1}^q \beta_i \tilde{\sigma}_{t-i,k}^{*2}, \quad (13)$$

gdzie $\varepsilon_t = 0$ dla $t \leq 0$ oraz

$$r_k(x) = \begin{cases} x, & |x| < k \\ k, & |x| \geq k \end{cases} \quad (14)$$

¹ Estymacja metodą największej wiarygodności dla grubych ogonów z_t oraz metodą najmniej szczytów wartości bezwzględnych - LAD (Peng, Yao, 2003) są przykładami M-estymacji z ρ nieograniczoną oraz ρ' ograniczoną.

Zaobserwować można, że jeśli k przyjmuje duże wartości, to wartości $\tilde{\sigma}_t^2$ oraz $\tilde{\sigma}_{t,k}^{*2}$ są zbliżone.

Biorąc pod uwagę wpływ punktów odstających na warunkową wariancję może ona zostać zastąpiona przez (13). Równocześnie otrzymujemy zmodyfikowaną funkcję M_{Tk}^* , natomiast $\hat{\theta}_2 = \arg \min_{\theta} M_{Tk}^*(\theta)$.

BM estymator jest zdefiniowany następująco:

$$\hat{\theta}_{BM} = \begin{cases} \hat{\theta}_1, & M_T \leq M_{Tk}^* \\ \hat{\theta}_2, & M_T > M_{Tk}^* \end{cases} \quad (15)$$

Należy zauważyć, że BM-estymacja posiada własności H1) oraz H2).

W części empirycznej będziemy wyróżniać BM₁ oraz BM₂- estymator.

BM₁- estymator uzyskujemy, gdy

$$\rho(x) = m_1 \left[-\log\left(\frac{1}{\sqrt{2\pi}} \exp(e^x - x)\right) \right]. \quad (16)$$

Funkcja $m_1(x)$ jest natomiast zdefiniowana jako:

$$m_1(x) = \begin{cases} x & \text{gdy } x \leq 4,02 \\ c_4 x^4 + c_3 x^3 + c_2 x^2 + c_1 x + c_0 & \text{gdy } 4,02 < x \leq 4,3 \\ 4,16 & \text{gdy } x > 4,3 \end{cases} \quad (17)$$

gdzie $c_0 = 6777$ $c_1 = -6536,2$ $c_2 = -379,0087$ $c_4 = 22,7770$.

BM₂-estymator otrzymujemy, gdy

$$\rho(x) = 0,8m_1 \left[-\frac{1}{0,8} \log\left(\frac{1}{\sqrt{2\pi}} \exp(e^x - x)\right) \right]. \quad (18)$$

Dla BM₁- estymatora wartość k jest równa 5,02 tak, aby $P(z_t^2 \leq 5,02) = 0,975$ ($z_t \sim N(0,1)$), natomiast dla BM₂- estymatora $k = 2,72$, gdyż $P(z_t^2 \leq 2,72) = 0,9$ ($z_t \sim N(0,1)$).

Analiza empiryczna

Celem pracy jest zweryfikowanie tezy, że modyfikacje metody największej wiarygodności w przypadku warunkowej heteroskedastyczności dają lepsze wyniki w oparciu o odporne metody estymacji niż gaussowska QML estymacja.

Przedmiotem badania będzie szereg czasowy reprezentujący logarytmiczne dzienne stopy zwrotu (liczone według cen zamknięcia rynku w kolejnych dniach sesyjnych) z indeksu WIG20 z okresu 07.02.2001-31.03.2008. Przed

przystąpieniem do estymacji parametrów należy przeprowadzić analizę właściwości dotyczących kształtowania się szeregu czasowego.

Wartości współczynnika skośności (-0,27836), kurtozy (4,55903) wraz z wynikami testu Jarque-Bera wskazują na odrzucenie hipotezy zerowej o normalności rozkładu składnika losowego. Ponadto, proces resztowy ma własności białego szumu. Wartość statystyki TR^2 dla WIG20 wynosi 90,73 i oznacza, że w badanym procesie resztowym mamy do czynienia z procesem ARCH. Oznacza to, że występuje autoregresyjna zmienność wariancji warunkowej oraz konieczność estymacji parametrów modelu metodami odpornymi. W rozważanym szeregu wykrywamy prawie 6% obserwacji odstających².

Na podstawie bayesowskiego kryterium Schwarza (SC) jako wystarczający do opisu zmienności warunkowej wariancji wybrano model GARCH(1,1). Estymacji parametrów modelu GARCH(1,1) dokonamy następującymi metodami:

- quasi największej wiarygodności (QML),
- M-estymacja z funkcją straty określoną (16) (M_1),
- BM_1 -estymacja dana wzorem (15) z funkcją straty określoną (16) (BM_1),
- M-estymacja z funkcją straty określoną (17) (M_2),
- BM_2 -estymacja dana wzorem (15) z funkcją ρ określoną wzorem (17) (BM_2).

Tabela 1 prezentuje wyestymowane wartości parametrów modelu GARCH(1,1).

Niech $\hat{\sigma}_t^2$ oznacza warunkową wariancję uzyskaną w oparciu o wyestymowane wcześniej parametry modelu GARCH(1,1). Dla QML - estymacji warunkowa wariancja jest wyznaczana na podstawie:

$$\hat{\sigma}_t^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \varepsilon_{t-1}^2 + \hat{\beta}_1 \hat{\sigma}_{t-1}^2 \quad 2 \leq t \leq T, \quad (19)$$

natomiast w przypadku BM_1 oraz BM_2 -estymacji warunkowa wariancja jest wyznaczana w oparciu o (19) gdy $(\hat{\alpha}_0, \hat{\alpha}_1, \hat{\beta}_1)$ pokrywa się z $\hat{\theta}_1$ zdefiniowaną przez (12) lub też

² Przyjmujemy, że obserwacje o szczególnie dużych wartościach bezwzględnych, wykraczających poza obszar 3 odchyleń standardowych od średniej to obserwacje odstające. Identyfikowane są za pomocą wskaźnika DFTIS_i – standaryzowanej różnicy pomiędzy wartościami teoretycznymi (zob. Ostasiewicz, 1998).

$$\hat{\sigma}_t^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{\sigma}_{t-1}^2 \left(\frac{\varepsilon_{t-1}^2}{\hat{\sigma}_{t-1}^2} \right) + \hat{\beta}_1 \hat{\sigma}_{t-1}^2 \quad 2 \leq t \leq T,$$

gdy $(\hat{\alpha}_0, \hat{\alpha}_1, \hat{\beta}_1)$ pokrywa się z $\hat{\theta}_2$.

Tabela 1. Wyniki estymacji parametrów dla modelu GARCH(1,1)

Parametry	Model GARCH $p = 1 \quad q = 1$				
	QML	M ₁	BM ₁	M ₂	BM ₂
$\hat{\alpha}_0$	0,01791	0,01734	0,01278	0,01273	0,01604
$\hat{\alpha}_1$	0,05044	0,05002	0,04227	0,04964	0,05027
$\hat{\beta}_1$	0,94077	0,93753	0,92405	0,92056	0,90297

Źródło: obliczenia własne

Prognozy wariancji konstruowano na jedną sesję do przodu dla okresu 06.08.2007 do 31.03.2008 (191 sesji). Parametry wszystkich analizowanych modeli estymowano 191 razy dodając za każdym razem kolejną obserwację (logarytmiczną rzeczywistą stopę zwrotu). Ocenę trafności prognoz dokonano na podstawie: średniego absolutnego błędu MAE oraz pierwiastka błędu średniokwadratowego RMSE (Tabela 2).

Tabela 2. Błędy prognoz zmienności

Błędy prognozy	Model GARCH $p = 1 \quad q = 1$				
	QML	M ₁	BM ₁	M ₂	BM ₂
MAE	0,38565	0,31497	0,31786	0,33790	0,30563
RMSE	0,40648	0,36782	0,35762	0,37541	0,35154

Źródło: Obliczenia własne

Analizując powyższe wyniki stwierdzamy, że niskie wartości błędów MAE oraz RSME otrzymujemy w przypadku wszystkich odpornych metod estymacji. Najlepsze rezultaty daje BM₂- estymacja. Choć należy podkreślić, że podjęcie decyzji o wyborze metody estymacji powinno być poprzedzone analizą szeregu pod kątem występujących obserwacji odstających. Niewielkie różnice wartości błędów dla odpornych metod estymacji pozwalają na stwierdzenie, że wybór konkretnej odpornej metody może zależeć od preferencji potencjalnego inwestora. Choć na podstawie otrzymanych w pracy wyników obserwacje odstające mają niewątpliwie największy wpływ na estymację metodą quasi-największej wiarygodności.

Podsumowanie

Modele GARCH nie są odporne na zmiany o charakterze szokowym czy interwencyjnym. Z przedstawionych rezultatów wynika, że dla finansowych szeregów czasowych z obserwacjami odstającymi odporne metody estymacji stanowią alternatywę dla klasycznych metod. BM-estymacja zdaje się zachowywać najlepiej spośród estymacji rozważanych w tej pracy. Uwzględnienie w modelach zmienności metod estymacji odpornej prowadzi do wzrostu trafności prognoz zmienności, co może być niewątpliwie użyteczne chociażby w procesie wyceny instrumentów pochodnych. Kolejnym krokiem powinno być dokonanie analizy porównawczej klasycznego modelu GARCH z zastosowanymi odpornymi metodami estymacji z rozszerzeniami modelu GARCH.

Literatura

1. Engle R. F., Bollerslev T., *Modeling the Persistence of Conditional Variance*. Econometric Review 1986.
2. Franses P.H., Ghijssels E., *Additive Outliers, GARCH and Forecasting Volatility*. International Journal of Forecasting, 1999.
3. Grossi L., Morelli G., *Robust Volatility Forecasts and Model Selection in Financial Time Series*, 2006.
4. Harvey, A., Pierce R., *Estimating missing observations in economic time series*. Journal of the American Statistical Association 1984.
5. Huber. P. J., *Robust Statistics*. Wiley, N. Y. 1981.
6. Jacquier E., Polson NG, Rossi P.E., *Bayesian analysis of stochastic volatility models*. JBusiness and Economic Statistics 1994.
7. Muler, N., Yohai VJ., *Robust estimates for ARCH Processes*. Time Series Analysis 2002.
8. Muler, N., Yohai VJ., *Robust Estimates for GARCH Models*. Time Series Analysis 2007.
9. Ostasiewicz W., *Statystyczne metody analizy danych*, Wydawnictwo AE im. Oscara Langego, Wrocław 1998.
10. Park B., *An outlier robust GARCH model and forecasting volatility of exchange rate returns*. Journal of Forecasting, 2002.
11. Rieder. H. , Ruckdeschel. P., Kohl M., *Robust estimation for time series models based on infinitesimal neighborhoods*. Working Paper ICORS, Vancouver 2002.

STRESZCZENIE

Modele GARCH są obecnie najczęściej stosowanymi modelami do prognozowania zmienności (volatility) w finansowych szeregach czasowych z uwagi na uwzględnianie grubych ogonów rozkładów stóp zmian czy zjawiska grupowania wariancji. Jednakże modele te nie są odporne na zmiany o charakterze szokowym czy interwencyjnym. W pracy zostały zaprezentowane wybrane odporne metody estymacji dla standardowego modelu GARCH, przedstawione po raz pierwszy przez Muler i Yohai (2007). Zostały one porównane z szeroko stosowaną metodą szacowania parametrów modelu GARCH – metodą quasi największej wiarygodności na przykładzie indeksu WIG20. Głównym celem pracy jest odpowiedź na pytanie czy pewne modyfikacje metody największej wiarygodności w przypadku warunkowej heteroskedastyczności dają lepsze wyniki w oparciu o odporne metody estymacji niż gaussowska QML estymacja.

ROBUST ESTIMATION METHODS FOR GARCH MODELS

SUMMARY

The GARCH models are by now the most widely used models to forecast the timevarying volatility observed in many financial returns because they can be fitted to the financial data which have heavy-tailed distribution and volatility clustering. It appears, however, from some empirical studies that the GARCH model tends to provide poor volatility forecasts in the presence of additive outliers. To overcome the forecasting limitation in this paper we present two classes of robust estimates for GARCH models. We compare these robust estimates with the most popular - QML—estimate and the main question is: are robust estimates behave better than QML-estimates?

Translated by J. Majewska

Mgr Justyna Majewska
Akademia Ekonomiczna w Katowicach
majewskaj@wp.pl