

## **DYNAMICZNE MODELE EKONOMETRYCZNE**

X Ogólnopolskie Seminarium Naukowe, 4–6 września 2007 w Toruniu  
Katedra Ekonometrii i Statystyki, Uniwersytet Mikołaja Kopernika w Toruniu

---

*Mateusz Pipień*

*Akademia Ekonomiczna w Krakowie*

### **Wykorzystanie warunkowej asymetrii w badaniu zależności pomiędzy oczekiwaną stopą zwrotu a poziomem ryzyka. Bayesowska analiza dla indeksu WIG**

#### **1. Wprowadzenie**

Celem artykułu jest zastosowanie wnioskowania bayesowskiego w badaniu relacji pomiędzy oczekiwaną stopą zwrotu a poziomem ryzyka na Gieldzie Papierów Wartościowych w Warszawie. Na podstawie międzyokresowego modelu CAPM (ang. Intertemporal-CAPM), zaproponowanego przez Mertona (1973), zbudowano ogólny model próbkowy, w którym możliwe jest testowanie omawianej relacji. W rozważanym modelu statystycznym jednym ze źródeł zależności pomiędzy oczekiwanym zwrotem a poziomem ryzyka jest asymetria rozkładu warunkowego stóp zmian. Propozycja ta wykorzystuje koncepcję GARCH-In-Mean Osiewalskiego i Pipienia (2000) oraz dostarcza formalnej, ekonomicznej interpretacji skośności występującej w modelu próbkowym.

W artykule rozważamy wiele konkurencyjnych specyfikacji dopuszczających warunkową asymetrię. W szczególności zastosowano mechanizm ukrytego ucięcia, alternatywne skalowania wokół modalnej, transformacje rozkładem Beta, gęstości Bersteina oraz podejście konstruktywne.

Na podstawie danych dotyczących notowań indeksu WIG dokonujemy analizy wpływu wprowadzenia do modelu warunkowej asymetrii stóp zmian na postulowaną relację pomiędzy oczekiwaną stopą zmian a poziomem ryzyka. Prezentowane są też dodatkowo wyniki bayesowskiego porównania modeli oraz dyskusja nad źródłami różnic w mocy wyjaśniającej rozważanych specyfikacji.

## 2. Wprowadzenie asymetrii do rozkładu prawdopodobieństwa

W pracy rozważamy ogólne podejście do narzucenia skośności na gęstość symetrycznego jednowymiarowego rozkładu prawdopodobieństwa, które wykorzystuje transformację dystrybuanty. Rodzina zmiennych losowych  $IP = \{\varepsilon_s, \varepsilon_s: \Omega \rightarrow R\}$ , o gęstości  $s(\cdot | \theta, \eta_p)$  jest nazywana uskośnieniem rodziny  $I$  (zmiennych losowych o symetrycznych jednomodalnych gęstościach  $f(\cdot | \theta)$  i dystrybuantach  $F(\cdot | \theta)$ , takich, że wartość modalna jest osiągnięta dla  $x=0$ ) jeśli  $s$  jest dane przez iloczyn:

$$s(x | \theta, \eta_p) = f(x | \theta) \cdot p(F(x | \theta) | \eta_p), \text{ for } x \in R, \quad (1)$$

gdzie  $p(\cdot | \eta_p)$  to gęstość rozkładu prawdopodobieństwa określona na  $(0,1)$ . Zgodnie z (1) asymetryczną gęstość  $s(\cdot | \theta, \eta_p)$  uzyskujemy z  $f(\cdot | \theta)$  przez zastosowanie  $p(\cdot | \eta_p)$  jako funkcji wagowej. Jeśli  $p(\cdot | \eta_p)$  jest gęstością rozkładu jednostajnego, to  $s=f$ . W ramach (1) możliwe jest zarówno wprowadzenie skośności poprzez definicję odpowiedniej rodziny rozkładów  $p(\cdot | \eta_p)$ , jak również rozważenie już istniejących rodzin gęstości dopuszczających asymetrię. Tabela 1 prezentuje przegląd mechanizmów uskośnienia stosowanych w części empirycznej. W każdym z rozważanych rozkładów  $p(\cdot | \eta_p)$  jest możliwe przywrócenie symetrii (w sensie równości  $s$  i  $f$ ) poprzez odpowiednią restrykcję narzuconą na parametr  $\eta_p$ .

## 3. Konkurencyjne modele GARCH-In-Mean

Oznaczmy przez  $x_j$  wartość akcji lub indeksu giełdowego w dniu  $j$ . Przedmiotem naszego zainteresowania jest różnica pomiędzy logarytmiczną dzienną stopą zmian  $r_j = 100 \ln[x_j/x_{j-1}]$  oraz stopą zwrotu z inwestycji wolnej od ryzyka  $r_j^f$ . Różnicę tą, nazywaną w literaturze angielskiej *excess return*, oznaczamy przez  $y_j = r_j - r_j^f$ . Testowanie zależności pomiędzy zwrotem a ryzykiem odbywać się może w ramach międzyokresowego modelu CAPM (ang. Intertemporal Capital Asset Pricing Model), który zaproponował Merton (1973). Zgodnie z założeniami teorii Mertona oczekiwana stopa zwrotu  $y_j$  jest proporcjonalna do odchylenia standardowego (warunkowo względem zbioru informacji, oznaczanego przez  $\psi_{j-1}$ ):

$$E(y_j | \psi_{j-1}) = \alpha^* D(y_j | \psi_{j-1}). \quad (2)$$

Współczynnik  $\alpha^*$  w (2) mierzy względną awersję inwestora do ryzyka i powinien mieć znak dodatni. Za pracami Engle, Lilien i Robins (1987), French, Schwert i Stambaugh (1987) oraz Osiewalski i Pipień (2000) rozważamy dla  $y_j$  prostą wersję modelu GARCH-In-Mean:

$$y_j = [\alpha + E(z_j)] h_j^{0.5} + u_j, j=1, 2, \dots, \quad (3)$$

gdzie  $u_j = [z_j - E(z_j)]h_j^{0.5}$ , zaś  $z_j$  to ciąg niezależnych zmiennych losowych o tym samym rozkładzie prawdopodobieństwa, dla których  $E(z_j) < +\infty$ . Czynniki skalujące  $h_j$  jest zadany przez równanie GARCH(1,1); por. Bollerslev (1986):

$$h_j = \alpha_0 + \alpha_1 u_{j-1}^2 + \beta_1 h_{j-1}.$$

Typ rozkładu warunkowego stóp zmian  $y_j$  jest ściśle zależny od rozkładu prawdopodobieństwa zmiennych losowych  $z_j$ . Jako punkt wyjścia, w modelu oznaczonym przez  $M_0$ , zakładamy, iż  $z_j$  jest ciągiem zmiennych losowych o rozkładzie  $t$ -Studenta z liczbą stopni swobody  $\nu > 1$ , o zerowej modalnej i jednostkowej odwrotności precyzji:

$$z_j | M_0 \sim \text{St}(0, 1, \nu), \nu > 1.$$

Gęstość zmiennej  $z_j$  w  $M_0$  oznaczamy jako  $f_t(z|0, 1, \nu)$ . W ramach modelu  $M_0$ ,  $E(z_j) = 0$  oraz  $u_j = z_j h_j^{0.5}$ , stąd (3) redukuje się do prostszej postaci  $y_j = \alpha h_j^{0.5} + u_j$ . Oznaczmy przez  $\theta = (\alpha, \alpha_0, \alpha_1, \beta_1, \nu)$  wektor wszystkich parametrów w modelu  $M_0$ . Rozkład warunkowy (względem przeszłości  $\psi_{j-1}$ ) składnika losowego  $u_j$  jest w  $M_0$  rozkładem  $t$ -Studenta o liczbie stopni swobody  $\nu > 1$ , zerowej modalnej oraz odwrotności precyzji  $h_j$ :

$$p(u_j | \psi_{j-1}, \theta, M_0) = h_j^{-0.5} f_t(h_j^{-0.5} u_j | 0, 1, \nu), j=1, 2, \dots$$

W konsekwencji rozkład warunkowy stóp zmian  $y_j$  w chwili  $j$  ma postać:

$$p(y_j | \psi_{j-1}, \theta, M_0) = h_j^{-0.5} f_t(h_j^{-0.5} (y_j - \alpha h_j^{0.5}) | 0, 1, \nu), j=1, 2, \dots$$

W ramach modelu  $M_0$  oczekiwana stopa zmian  $y_j$  jest proporcjonalna do pierwiastka z odwrotności precyzji  $h_j$ :

$$E(y_j | \psi_{j-1}, \theta, M_0) = \alpha h_j^{0.5}. \quad (4)$$

Zatem parametr  $\alpha \in R$  mierzy zależność pomiędzy oczekiwaną stopą zwrotu (skorygowaną o zwrot z inwestycji wolnej od ryzyka)  $E(y_j | \psi_{j-1}, M_0, \theta)$  a zmiennością (mierzoną przez  $h_j^{0.5}$ ), która wyraża bieżący poziom ryzyka.

W celu skonstruowania zbioru konkurencyjnych specyfikacji GARCH-In-Mean  $\{M_i, i=1, \dots, k\}$  narzucamy asymetrię na rozkład warunkowy  $p(y_j | \psi_{j-1}, \theta, M_0)$ . Skośny rozkład warunkowy dla  $y_j$  uzyskujemy poprzez uskośnienie rozkładu zmiennej  $z_j$ , zgodnie z metodami, których przegląd zawarto w Tabeli 1. Gęstość rozkładu prawdopodobieństwa  $z_j$  ma, zgodnie z (1), następującą ogólną postać:

$$p(z | M_i) = f_t(z|0, 1, \nu) \cdot p[F_t(z) | \eta_i, M_i], z \in R, i=1, 2, \dots, k,$$

gdzie  $p(\cdot | \eta_i, M_i)$  definiuje mechanizm uskośnienia parametryzowany przez wektor  $\eta_i$ , zaś  $F_t(\cdot)$  to dystrybuanta rozkładu  $t$ -Studenta o  $\nu > 1$  stopniach swobody, zerowej modalnej i jednostkowej precyzji. W konsekwencji uzyskujemy ogólną postać na rozkład warunkowy składnika losowego  $u_j$  w modelu  $M_i$ :

$$p(u_j | \psi_{j-1}, \theta, \eta_i, M_i) = h_j^{-0.5} f_t(h_j^{-0.5} u_j | 0, 1, \nu) \cdot p(F_t(h_j^{-0.5} u_j) | \eta_i, M_i), j=1, 2, \dots,$$

oraz gęstość rozkładu warunkowego stopu zwrotu  $y_j$ :

$$p(y_j | \psi_{j-1}, \theta, \eta_i, M_i) = h_j^{-0.5} f_i(h_j^{-0.5}(y_j - \mu_j) | 0, 1, \nu) \cdot p[F_t(h_j^{-0.5}(y_j - \mu_j)) | \eta_i, M_i], j=1, \dots \quad (5)$$

gdzie  $\mu_j = [\alpha + E(z_j)] h_j^{0.5}$ . W modelu  $M_1$ , rozważamy GARCH z warunkowym rozkładem skośnym  $t$ -Studenta zaproponowanym przez Fernández i Steela (1998). W mechanizmie uskośnienia  $p[\cdot | \eta_1, M_1]$   $\eta_1 = \gamma_1 > 0$ , oraz  $\gamma_1 = 1$  redukuje  $M_1$  do  $M_0$ . Model  $M_2$  uzyskujemy poprzez narzucenie mechanizmu uskośnienia ukrytego ucięcia. W tym przypadku  $\eta_2 = \gamma_2 \in R$ , oraz  $\gamma_2 = 0$  definiuje warunkową symetrię. W modelu  $M_3$  stosujemy transformację rozkładem Beta z jednym swobodnym parametrem;  $\eta_3 = \gamma_3 > 0$ , oraz  $\gamma_3 = 1$  wyznacza warunkową symetrię. Specyfikacja  $M_4$  bazuje na transformacji rozkładem Beta z dwoma swobodnymi parametrami. W mechanizmie  $p[\cdot | \eta_4, M_4]$ ,  $\eta_4 = (a, b)$ , zaś  $a = b = 1$  redukuje  $M_4$  do  $M_0$ . W  $M_5$  stosujemy transformację rozkładem Bernsteina z  $m=2$  swobodnymi parametrami. W  $p[\cdot | \eta_5, M_5]$   $\eta_5 = (w_1, w_2)$  oraz  $w_1 = w_2 = 1/3$  przywraca symetrię rozkładu warunkowego  $y_j$ . W modelu  $M_6$  stosujemy konstrukcję Ferreiry i Steela (2006). W mechanizmie uskośnienia  $p[\cdot | \eta_6, M_6]$   $\eta_6 = \gamma_4 \in R$  oraz  $\gamma_4 = 0$  definiuje warunkową symetrię. W Tabeli 1 zawarto dodatkowo mechanizm uskośnienia możliwy do wydobywania z gęstości rozkładu skośnego  $t$ -Studenta zaproponowanego przez Hansena (1994). Można jednak udowodnić, iż propozycja Hansena (1994) jest równoważna z uskośnieniem stosowanym w modelu  $M_1$ . Stąd pomijamy ten przypadek jako równoważny z  $M_1$  (z dokładnością reparametryzacji).

Wszystkie sformułowane specyfikacje modelowe zakładają, iż rozkład warunkowy stóp zmian  $y_j$  jest heteroskedastyczny, gdzie zmienna w czasie miara zmienności  $h_j$  jest określona równaniem GARCH(1,1). Liczba stopni swobody  $\nu > 1$  umożliwia modelowanie grubych ogonów rozkładu  $p(y_j | \psi_{j-1}, \theta, \eta_i, M_i)$ , jak również testowanie warunkowej normalności. Narzucenie mechanizmu uskośnienia umożliwia modelowanie jak i wskazanie źródeł warunkowej asymetrii. Asymetria rozkładu  $z_j$  w  $M_i$  powoduje, iż  $E(z_j) \neq 0$ . A zatem zgodnie z (3) warunkowa wartość oczekiwana stopy zmian  $y_j$  przyjmuje postać:

$$E(y_j | \psi_{j-1}, \theta, \eta_i, M_i) = [\alpha + E(z_j)] h_j^{0.5}, \text{ dla } E(z_j) \neq 0. \quad (6)$$

Stąd w każdym z modeli  $M_i$  warunkowa skośność rozkładu  $y_j$  może być interpretowana jako dodatkowe źródło zależności pomiędzy oczekiwanym zwrotem a poziomem ryzyka. Takie podejście w pełni wykorzystuje sugestię zawartą w pracy Harvey i Siddique (2000), że skośność rozkładów finansowych szeregów czasowych jest wszechobecna, ponieważ determinuje premię za ryzyko.

Oznaczmy przez  $y^{(t)} = (y_1, \dots, y_t) \in Y$  wektor zaobserwowanych do dnia  $t$  stóp zmian rozważanego aktywu finansowego, zaś przez  $y_f^{(t)} = (y_{t+1}, \dots, y_{t+n}) \in Y_f$  wektor stóp zmian podlegających prognozie. Następujący iloczyn prezentuje ogólną formułę na  $i$ -ty model próbkowy:

$$p(y^{(t)}, y_f^{(t)} | \theta, \eta_i, M_i) = \prod_{j=1}^{t+n} p(y_j | \psi_{j-1}, \theta, \eta_i, M_i), \quad i=1, 2, 3, 4, 5, 6.$$

Model Bayesowski, zdefiniowany łączną gęstość wektora obserwacji i parametrów modelu  $(\theta, \eta_i)$  przyjmuje postać:

$$p(y^{(t)}, y_f^{(t)}, \theta, \eta_i | M_i) = p(y^{(t)}, y_f^{(t)} | \theta, \eta_i, M_i) \cdot p(\theta, \eta_i | M_i) \quad (7)$$

i wymaga specyfikacji rozkładu a priori  $p(\theta, \eta_i | M_i)$  w każdym z modeli  $M_i$ . Ogólnie zakładamy następującą niezależność a priori pomiędzy parametrami wspólnymi  $\theta$  a parametrami swoistymi modelu  $M_i$ , czyli  $\eta_i$ :

$$p(\theta, \eta_i | M_i) = p(\theta | M_i) \cdot p(\eta_i | M_i), \quad i=1,2,3,4,5,6. \quad (8)$$

Dodatkowo przyjmujemy, iż:

$$p(\theta | M_i) = p(\theta) = p(\alpha) p(\alpha_0) p(\alpha_1) p(\beta_1) p(\nu),$$

gdzie  $p(\alpha)$  jest gęstością rozkładu normalnego o zerowej średniej i wariancji 10,  $p(\alpha_0)$  wyznacza rozkład wykładniczy o średniej 1,  $p(\alpha_1)$  oraz  $p(\beta_1)$  to gęstości rozkładów jednostajnych określonych na przedziale (0,1), oraz  $p(\nu)$  definiuje rozkład wykładniczy o średniej 10.

Rozkłady a priori  $p(\eta_i | M_i)$  określają w każdym z modeli wstępną wiedzę o możliwym nasileniu efektu warunkowej asymetrii gęstości  $p(y_j | \psi_{j-1}, \theta, \eta_i, M_i)$ . Celem naszym badań było narzucenie słabej i porównywalnej informacji a priori o tym fenomenie, niezależnie od rozważanego modelu. Stosując miernik skośności zaproponowany przez Arnolda i Groenvelda (1995) dokonano doboru konkretnych rozkładów  $p(\eta_i | M_i)$  przyjmując a priori, iż równe szanse (w sensie mediany a priori) ma zarówno lewostronna jak i prawostronna asymetria  $p(y_j | \psi_{j-1}, \theta, \eta_i, M_i)$ . Szczegółową procedurę doboru, jak i analizę porównawczą, rozkładów a priori opisano w pracy Pipień (2006).

#### 4. Wyniki empiryczne

Prezentowane wyniki empiryczne analizy bayesowskiej wpływu warunkowej asymetrii na relację pomiędzy oczekiwanym zwrotem a poziomem ryzyka dotyczą Giełdy Papierów Wartościowych w Warszawie. Szereg skorygowanych stóp zwrotu  $y_j$  skonstruowano na bazie dziennych stóp zmian indeksu WIG w dniach 06.01.1998 do 31.07.2006;  $T=2144$  obserwacji. Jako aproksymację krótkoterminowej stopy procentowej  $r_j^f$  przyjęto oprocentowanie lokat międzybankowych z rynku WIBOR; instrument WIBOR/n. W badaniach wykorzystano także inne przybliżenia stopy  $r_j^f$ , łącznie z przypadkiem  $r_j^f=0$ , jednak wyniki pozostały praktycznie niewrażliwe na korektę stopy zmian indeksu WIG.

Tabela 1 zawiera najważniejsze rezultaty empiryczne. Prezentujemy logarytmy dziesiętne wartości brzegowej gęstości wektora obserwacji w każdym modelu, prawdopodobieństwa a posteriori konkurencyjnych specyfikacji oraz wyniki analizy a posteriori wpływu narzucenia mechanizmu uskośnienia na zależność pomiędzy oczekiwanym zwrotem a poziomem ryzyka.

Model  $M_0$ , w którym nie zapewniamy możliwości warunkowej asymetrii rozkładu warunkowego dla  $y_j$ , uzyskał nieco więcej niż 8% masy prawdopodo-

bieństwa a posteriori. Pozostałe 0.92 jest rozproszone w ramach modeli z narzuconym na rozkład warunkowy mechanizmem uskośnienia. Klasa specyfikacji  $M_i$ ,  $i=1,2,3,4,5,6$  została wyraźnie podzielona na dwa zbiory ze względu na wartość prawdopodobieństwa  $P(M_i|y^{(t)})$ . Modele z mechanizmem uskośnienia zaproponowanym przez Fernández i Steela (1998), Ferreirę i Steela (2006) oraz wykorzystującym transformację rozkładem Bernsteina (a więc  $M_1$ ,  $M_5$  i  $M_6$ ) uzyskują niskie wartości prawdopodobieństwa a posteriori, co świadczy o ich słabej względnej (a więc na tle całej klasy modeli) mocy wyjaśniającej. Relatywnie wysoką wartość  $P(M_i|y^{(t)})$  uzyskuje mechanizm ukrytego ucięcia oraz obydwie wersje transformacji rozkładem Beta. Modele  $M_2$ ,  $M_3$  i  $M_4$  kumulują bowiem ponad 90% masy prawdopodobieństwa a posteriori. Najwyższą wartość prawdopodobieństwa  $P(M_i|y^{(t)})$  obserwujemy dla modelu  $M_4$ , który zbudowano na podstawie transformacji rozkładem Beta z dwoma swobodnymi parametrami. Narzucony typ skośności w gęstości  $p(y_j|\psi_{j-1},\theta,\eta_4,M_4)$  okazał się najbardziej wrażliwy na informację o tym fenomenie, która jest zawarta w rozważanym szeregu czasowym.

W dalszej kolejności dokonano porównania wpływu warunkowej asymetrii na siłę zależności pomiędzy oczekiwanym zwrotem a poziomem ryzyka w przypadku rozważanego szeregu czasowego WIG. Zgodnie z (3) zależność ta jest określana w każdym z modeli przez funkcję parametrów  $\alpha+E(z_j)$ . W Tabeli 1 zamieszczono wartości oczekiwane i odchylenia standardowe (kursywą) tej wielkości, jak również prawdopodobieństwa a posteriori dodatniego znaku  $\alpha+E(z_j)$  uzyskane w ramach każdej specyfikacji.

W modelu  $M_0$ , w którym postulujemy symetrię gęstości rozkładu warunkowej  $y_j$  (a więc  $E(z_j)=0$ ) prawdopodobieństwo  $P(\alpha+E(z_j)>0|M_0,y^{(t)})$  nieznacznie przekracza 0.91. Z jednej strony potwierdza to hipotezę Mertona o dodatniej premii za ryzyko, jednak 8% prawdopodobieństwa a posteriori przeciwnego znaku zostawia dużo niepewności co do prawdziwej siły zależności pomiędzy oczekiwanym zwrotem a poziomem ryzyka. Wprowadzenie asymetrii do rozkładu warunkowego  $y_j$  w większości modeli okazało się trafne. Obserwujemy wyraźnie wyższe wartości prawdopodobieństwa a posteriori dodatniego znaku  $\alpha+E(z_j)$  dla modeli z narzuconym mechanizmem ukrytego ucięcia oraz z transformacją rozkładami Beta lub Bernsteina. Dla specyfikacji  $M_1$  i  $M_6$ , które były odrzucane w świetle danych (miały bardzo niskie wartości  $P(M_i|y^{(t)})$ ) obserwujemy zaś brak wpływu efektu warunkowej asymetrii na siłę badanej zależności. W ramach  $M_1$  i  $M_2$  prawdopodobieństwo a posteriori dodatniej premii za ryzyko nieznacznie przekracza 0.90, podobnie jak w przypadku  $M_0$ . Dla najlepszego modelu ( $M_4$ ), który uzyskał wartość prawdopodobieństwa  $P(M_i|y^{(t)})$  około 0.40, otrzymano bardzo silne potwierdzenie dodatniego znaku  $\alpha+E(z_j)$ . W przypadku  $M_4$  prawdopodobieństwo  $P(\alpha+E(z_j)>0|M_4,y^{(t)})$  jest bowiem większe od 0.99. Mechanizm uskośnienia oparty na transformacji rozkładem Beta z dwoma swobodnymi parametrami właściwie opisując efekt warunkowej asymetrii rozkładu stóp zmian  $y_j$  wzmacnia postulowaną zależność i czyni ją zdecydowanie praw-

dziwą w świetle danych. Silne potwierdzenie teorii Mertona o dodatniej premii za ryzyko otrzymujemy także narzucając mechanizm ukrytego ucięcia (model  $M_2$ ) oraz stosując transformację rozkładem Bernsteina. Tak silny rozdział pomiędzy mechanizmami uskośnienia, które nie dostarczają źródła zależności pomiędzy oczekiwanym zwrotem i poziomem ryzyka (modele  $M_1$  i  $M_6$ ), a mechanizmami wrażliwymi na ten typ zależności tłumaczy wyniki Bayesowskiego porównania modeli w oparciu o prawdopodobieństwa a posteriori. Na podstawie przeprowadzonych badań można stwierdzić, iż wysoką wartość prawdopodobieństwa  $P(M_i|y^{(t)})$  uzyskały modele, które były w sposób istotny wzmocnić siłę postulowanej relacji. Pozostałe modele były odrzucane w świetle rozważanego szeregu czasowego.

## Literatura

- Azzalini, A. (1985), A Class of Distributions which Includes the Normal Ones, *Scandinavian Journal of Statistics* 12, 171–178.
- Bollerslev, T. (1986), Generalised Autoregressive Conditional Heteroscedasticity, *Journal of Econometrics* 31, 307–327.
- Engle, R.F., Lilien, D.M., Robins R.P. (1987), Estimating Time-varying Risk Premia in the Term Structure: The ARCH-M Model, *Econometrica* 55, 391–408.
- Fernández, C., Steel, M.F.J. (1998), On Bayesian Modelling of Fat Tails and Skewness, *Journal of the American Statistical Association* 93, 359–371.
- Ferreira, J.T.A.S, Steel, M.F.J. (2006), A Constructive Representation of Univariate Skewed Distributions, *Journal of the American Statistical Association* 101, 823–839.
- French, K.R., Schwert, G.W., Stambaugh, R.F. (1987), Expected Stock Returns and Volatility, *Journal of Financial Economics* 19, 3–29.
- Hansen, B.E. (1994), Autoregressive Conditional Density Estimation, *International Economic Review* 35, 705–730.
- Harvey, C.R., Siddique, A. (2000), Conditional Skewness in Asset Pricing Models, *Journal of Finance* 55, 1263–1295.
- Jones, M.C. (2004), Families of Distributions Arising from Distributions of Order Statistics, *Test* 13, 1–43.
- Jones, M.C., Faddy, M.J. (2003), A Skew Extension of the  $t$ -Distribution, with Applications, *Journal of Royal Statistical Association B* 65, 159–174.
- Merton, R.C. (1973), An Intertemporal Capital Asset Pricing Model, *Econometrica* 41, 867–887.
- Osiwalski, J., Pipień, M., (2000), GARCH-In-Mean through Skewed  $t$  Conditional Distributions: Bayesian Inference for Exchange Rates, *26-th International Conference MACROMODELS'99*, ed. Welfe W., Wdowiński P., Łódź, 354–369.
- Pipień, M. (2006), Bayesian Comparison of GARCH Processes with Skewness Mechanism in Conditional Distributions, *Acta Physica Polonica B* 11, 3105–3121.

Tabela 1. Zestawienie konkurencyjnych mechanizmów uskośnienia

<p><b>Ukryte ucięcie</b> Azzalini (1985) <math>\gamma_2 \in \mathbb{R}</math> <math>p(y \gamma_2) = 2 \cdot F(\gamma_2 \cdot F^{-1}(y) \theta)</math></p> <p>symetria: <math>\gamma_2 = 0</math></p>	<p><b>Rozkład Beta I</b> Jones (2004) <math>\gamma_3 &gt; 0</math> <math>p(y \gamma_3) = Be(y \gamma_3, \gamma_3^{-1})</math></p> <p>symetria: <math>\gamma_3 = 1</math></p>	<p><b>Rozkład Beta II</b> Jones, Faddy (2003) <math>a &gt; 0, b &gt; 0</math> <math>p(y a, b) = Be(y a, b)</math></p> <p>symetria: <math>a = b = 1</math></p>	<p><b>Bernstein</b> (2 parametry) <math>p(y w_1, w_2) = w_1 \cdot Be(y 1, 3) + w_2 \cdot Be(y 2, 2) + (1 - w_1 - w_2) \cdot Be(y 3, 1)</math> symetria: <math>w_i = 1/3, i = 1, 2, 3</math></p>
<p><b>Ferreira, Steel (2006)</b> <math>p(y \gamma_4) = 1 + I(\gamma_4)[g(y \gamma_4) - 1]</math></p> <p>symetria: <math>\gamma_4 = 0</math></p>	<p><b>Fernández, Steel (1998)</b> <math>p(y \gamma_1) = \frac{2}{\gamma_1 + \gamma_1^{-1}} \cdot \frac{f(\gamma_1 \cdot F^{-1}(y)I_{(0,0.5)}(y)) + f(\gamma_1^{-1} \cdot F^{-1}(y)I_{(0.5,1)}(y))}{f(F^{-1}(y))}</math></p> <p>symetria: <math>\gamma_1 = 1</math></p>	<p><b>Hansen (1994)</b> <math>p(y \gamma_5) = \frac{f\left(\frac{F^{-1}(y)}{1-\gamma_5}\right)I_{(0,0.5)}(y) + f\left(\frac{F^{-1}(y)}{1+\gamma_5}\right)I_{(0.5,1)}(y)}{f(F^{-1}(y))}</math></p> <p>symetria: <math>\gamma_5 = 0</math></p>	

Źródło: opracowanie własne.

Tabela 2. Logarytmy dziesiętne brzegowych gęstości wektora obserwacji, prawdopodobieństwa a posteriori konkurencyjnych specyfikacji oraz analiza wpływu założenia warunkowej asymetrii na zależność pomiędzy zwrotem a ryzykiem

	$M_1$	$M_2$	$M_3$	$M_4$	$M_5$	$M_6$	$M_0$
$\log p(y^{(t)} M_i)$	-1559.5	-1558.5	-1558.8	-1558.4	-1560.8	-1560.1	-1559.1
$P(M_i y^{(t)}), i=0, \dots, 6$	0.0338	0.3015	0.1582	0.3709	0.0014	0.0076	0.0830
$P(M_i y^{(t)}), i=1, \dots, 6$	0.0369	0.3288	0.1725	0.4045	0.0016	0.0083	x
$\alpha + E(z_j)$	0.0469	0.2567	0.1440	0.2148	0.2085	0.0489	0.0483
	0.0349	0.1162	0.0912	0.0852	0.0933	0.0338	0.0337
$P(\alpha + E(z_j) > 0   M_i, y^{(t)})$	0.9102	0.9894	0.9528	0.9972	0.9893	0.9230	0.9201
$P(\alpha + E(z_j) > 0   y^{(t)})$	0.9777						

Źródło: obliczenia własne.