

Grażyna Trzpiot

Uniwersytet Ekonomiczny w Katowicach

ALTERNATYWNE OCENY RYZYKA SYSTEMATYCZNEGO W MODELU CAMP

Wprowadzenie

Obserwujemy rozwój miar zmienności zwłaszcza w zastosowaniach opisu rynków finansowych. Miary te są postrzegane jako miary ryzyka finansowego i często interpretowane jako poziom zabezpieczenia, niezbędny na wypadek nieoczekiwanych strat. Kwantylowe miary ryzyka¹ wykorzystują *VaR* (*Value-at-Risk*), który jest zdefiniowany bazowo jako kwantyl, wysokiego rzędu, wyznaczany dla rozkładu strat [Jorion, 1997].

Z pytaniem jak mierzyć ryzyko finansowe jest połączony problem jak wskazać czynniki wpływające na ryzyko, odpowiedzialne za konkretne rodzaje ryzyka. Identyfikacja problemów, które mają wpływ na ryzyko jest najczęściej najistotniejszym zadaniem w zarządzaniu ryzykiem. Znany standardowy rozwiązanie wykorzystywane do pomiaru ryzyka, jest nim najczęściej odchylenie standardowe rozkładu strat. To rozwiązanie nie może być wprost przeniesione do zastosowań i wykorzystane do miar powiązanych z *VaR*, jeżeli rozkład nie należy do rodziny rozkładów eliptycznych.

Problem identyfikacji czynników ryzyka był podejmowany przez wielu autorów. Przedstawimy pomiar ryzyka z zastosowaniem podejścia znanego z definicji miar wrażliwości oraz wykorzystamy różniczkowanie kwantyli. Metoda ta jest użyteczna, ponieważ opiera się na rozkładach średnich warunkowych, które mogą być interpretowane jako poziom satysfakcji. Zróżniczkowane kwantyle otwierają ścieżkę do przeprowadzenia (tak jak to opracowano dla zastosowań ekonomicznych) analizy wrażliwości lub optymalizacji portfelowej [Gouriéroux et al., 1999; Uryasev, 2000].

Problem pomiaru ryzyka jest ważny w badaniach statystycznych. Możemy wykorzystać miarę, taką jak współczynnik determinacji liniowej regresji. W regresji liniowej współczynnik ten informuje, jaki procent wariancji zmiennej objaśnianej jest wyjaśniony zmianami zmiennej wyjaśniającej przez dopasowaną funkcję liniową.

¹ Trzpiot [2004].

1. Regresja liniowa

Rozpatrujemy próbę o wartościach $(x_1, y_1), \dots, (x_n, y_n)$. Wartości x_1, \dots, x_n nie są losowe i nie są wszystkie sobie równe. Wartości $y_i, i=1, \dots, n$ są realizacjami zmiennej losowej zapisanej jako:

$$Y_j = ax_i + b + hW_i, \quad (1)$$

gdzie $a, b \in R$ oraz $h > 0$ są stałymi oraz W_1, \dots, W_n są niezależnymi zmiennymi losowymi o takim samym rozkładzie oraz są interpretowane jako błąd pomiaru. Zazwyczaj parametry a, b oraz h są nieznanne *a priori* i muszą być estymowane. Rozkład W jest przyjmowany jako normalny.

Stosując metodę najmniejszych kwadratów (MNK), zapisujemy dekompozycję empirycznej wariancji:

$$\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2. \quad (2)$$

Równanie to jest dekompozycją empirycznej wariancji wektora y_1, \dots, y_n względem metryki L^2 dla y_1, \dots, y_n oraz $\hat{y}_1, \dots, \hat{y}_n$ i empirycznej wariancji wektora $\hat{y}_1, \dots, \hat{y}_n$. Jest zazwyczaj interpretowane jako dekompozycja wariancji y_1, \dots, y_n na część wyjaśnioną przez obserwowane wartości x_1, \dots, x_n oraz część spowodowaną błędem lub wpływem nieobserwowanych czynników [Casella, Berger, 1990].

Współczynnik determinacji dla próby jest zatem zdefiniowany jako proporcja wyjaśnionej do całkowitej wariancji zmiennej objaśnianej:

$$R^2 = \frac{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}. \quad (3)$$

Wariancja nie jest jedyną, ale analitycznie najbardziej sprawną miarą opisu dyspersji w próbie. Inną równie popularną miarą jest średnia absolutnych odchyleń (odchylenie przeciętne) oraz interkwartył (odchylenie ćwiartkowe) i są postrzegane jako miary bardziej odporne². Zastosowanie miary interkwartyłowej wydaje się bardzo naturalnym podejściem w powiązaniu z regresją kwantylową. W przypadku obydwu wymienionych podejść nie mamy tak prostego rozkładu zmienności na dwa składniki jak w równaniu (3).

² Trzpiot [2013b].

2. Wygładzanie jądrowe

Opiszemy próbę o wartościach $(x_1, y_1), \dots, (x_n, y_n)$ przez dwie niezależne zmienne losowe X i W , gdzie X jest dyskretną zmienną losową, a W jest błędem pomiaru. Zmienna losowa:

$$Y = aX + b + hW \quad (4)$$

jest zatem wynikiem wartości dla zmiennej losowej X z losowym błędem pomiaru W . To oznacza, że mamy model o ustalonych własnościach, w tym szczególnym sensie, że jest to przypadek losowego modelu.

Podstawową zaletą powyższego modelu w porównaniu z poprzednim jest fakt, że możemy interpretować obydwa składniki po prawej stronie jako estymatory dyspersji implikowanych stochastycznie (nawet w przypadku znanych współczynników a i b). Dodatkową zaletą tego modelu jest fakt, że problem regresji jest wyrażony jedynie za pomocą dwóch zmiennych niezależnie od wielkości próby. Ten model w matematycznym sensie jest modelem jądrowego wygładzania stosowanym w estymacji jądrowej funkcji gęstości³.

Dla dalszych rozważań zakładamy, że znamy estymatory stałych a , b i h oraz rozkład W^4 . Jeżeli W jest całkowalne względem L^2 , możemy model podstawowy MNK zapisać równoważnie jako:

$$\min_{\alpha, \beta} E[(Y - (\alpha X + \beta))^2], \quad (5)$$

zatem:

$$D^2(Y) = E[(Y - (aX + b))^2] + D^2[aX + b] = h^2 E(W^2) + a^2 D^2(X).$$

Możemy zapisać współczynnik determinacji R^2 jako funkcję błędu współczynnika skali h :

$$R^2(h) = \frac{a^2 D^2(X)}{h^2 E(W^2) + a^2 D^2(X)}. \quad (6)$$

Można zapisać dalszą dekompozycję poprzez odchylenie standardowe $\sigma(h) = \sqrt{D^2(Y)}$, dla zmiennej losowej Y , czyli:

$$\sigma(h) = \frac{h^2 E(W^2)}{\sigma(h)} + \frac{a^2 D^2(X)}{\sigma(h)}. \quad (7)$$

³ Simonoff [1996].

⁴ Estymacja parametrów a , b lub h nie jest celem tej pracy.

Zdefiniujemy $R_{absdev}(h)$ jako percentyl odchylenia standardowego $\sigma(h)$ dla zmiennej losowej X . Otrzymujemy z (7) $R_{absdev}(h) = R^2(h)$. Zapiszemy inną dekompozycję $\sigma(h)$, wykorzystując średnie rozkładów warunkowych i własności momentów zmiennych losowych.

$$\begin{aligned}\sigma(h) &= E[Y|Y = E(Y) + \sigma(h) - E(Y)] \\ &= hE[W|Y = E(Y) + \sigma(h)] + E[aX + b|Y = E(Y) + \sigma(h)] - E[aX + b].\end{aligned}$$

Wykorzystując powyższe przekształcenie, możemy określić jako $R_{absdev}(h)$:

$$R_{absdev}(h) = \frac{E[aX + b|Y = E(Y) + \sigma(h)] - E[aX + b]}{\sigma(h)}. \quad (8)$$

Oczywiście wówczas $R_{absdev}(h)$ nie jest równe $R^2(h)$, zatem poszukujemy kryterium, które uzasadni dekompozycję $\sigma(h)$ oraz pomoże zmierzyć dyspersję.

3. Warunkowa wartość oczekiwana jako miara dyspersji

Dekompozycja odchylenia standardowego zmiennej losowej Y może być zapisana z wykorzystaniem ortogonalizacji zmiennych X i W . Inną drogą jest różniczkowanie.

$$\frac{a^2 D^2(X)}{\sigma(h)} = \frac{\partial}{\partial u} \sqrt{D^2[u(aX + b) + hW]} \Big|_{u=1}$$

oraz

$$\frac{h^2 E(W^2)}{\sigma(h)} = \frac{\partial}{\partial v} \sqrt{D^2[aX + b + vW]} \Big|_{v=1}$$

Zapiszemy kwantyl rzędu α , dla zmiennej losowej X i dowolnego $\alpha \in (0, 1)$:

$$Q_\alpha(X) = \inf\{x \in R : P(X \leq x) \geq \alpha\}.$$

W szczególności dla $\alpha = 1/2$ otrzymujemy medianę rozkładu X .

Następnie zapiszemy średnie absolutne odchylenie w próbie:

$$\sigma_{abs}(h) \stackrel{def}{=} E[|Y - Q_{1/2}(Y)|] = E[Y] - E[Y|Y < Q_{1/2}(Y)]. \quad (9)$$

Jeżeli rozkład błędów W jest absolutnie ciągły z gęstością f oraz gęstość zmiennej Y dla wartości mediany jest dodatnia, możemy zapisać następujące pochodne [Tasche, 1999]:

$$\begin{aligned}\frac{\partial \sigma_{abs}(h)}{\partial u} \Big|_{u=1} &= \frac{\partial}{\partial u} E[u(aX + b) + hW - Q_{1/2}(u(aX + b) + hW)] \Big|_{u=1} \\ &= E[aX + b] - E[aX + b | Y < Q_{1/2}(Y)] \\ \frac{\partial \sigma_{abs}(h)}{\partial v} \Big|_{v=1} &= \frac{\partial}{\partial v} E[aX + b + v hW - Q_{1/2}(aX + b + v hW)] \Big|_{v=1} . \\ &= -E[hW | Y < Q_{1/2}(Y)]\end{aligned}$$

Następnie zapiszemy interkwantyl:

$$\sigma_{(\alpha, \beta)}(h) = Q_{\alpha}(Y) - Q_{\beta}(Y), \quad (10)$$

dla $0 < \beta < \alpha < 1$ jako różnicę pomiędzy dwoma kwantylami dla rozkładu zmiennej losowej Y . Tę miarę możemy wykorzystać jako odporną alternatywę odchylenia standardowego w opisie poziomu zmienności. Jeżeli przyjmiemy $\beta = 1/4$ oraz $\alpha = 3/4$, otrzymujemy interkwantyl. Przyjmując założenia jak poprzednio, otrzymujemy:

$$\begin{aligned}\frac{\partial \sigma_{(\alpha, \beta)}(h)}{\partial u} \Big|_{u=1} &= \frac{\partial}{\partial u} (Q_{\alpha}(u(aX + b) + hW) - Q_{\beta}(u(aX + b) + hW)) \Big|_{u=1} \\ &= \frac{E[(aX + b)f(Q_{\alpha}(Y) - (aX + b))]}{E[f(Q_{\alpha}(Y) - (aX + b))]} - \frac{E[(aX + b)f(Q_{\beta}(Y) - (aX + b))]}{E[f(Q_{\beta}(Y) - (aX + b))]} \\ &= E[(aX + b) | Y = Q_{\alpha}(Y)] - E[(aX + b) | Y = Q_{\beta}(Y)].\end{aligned}$$

Kwantyle są funkcją homogeniczną rzędu pierwszego. Zredukowana forma różniczki jest wartością warunkowej średniej przekształconej i zapisanej z wykorzystaniem wartości kwantyli $Q_{\alpha}(Y)$ i $Q_{\beta}(Y)$.

Możemy zatem zdefiniować współczynnik $R_{abs}(h)$ oraz $R_{(\alpha, \beta)}(h)$ dla średniego absolutnego odchylenia oraz wykorzystać kwantylową regresję:

$$R_{abs}(h) = \frac{E[aX + b] - E[aX + b | Y \leq Q_{1/2}(Y)]}{E[|Y - Q_{1/2}(Y)|]} \quad (11)$$

oraz

$$R_{(\alpha, \beta)}(h) = \frac{E[aX + b | Y = Q_{\alpha}(Y)] - E[aX + b | Y = Q_{\beta}(Y)]}{Q_{\alpha}(Y) - Q_{\beta}(Y)}. \quad (12)$$

Aby porównać powyższe definicje z ogólnym⁵ R^2 , należałoby po przekształceniu zapisać następująco:

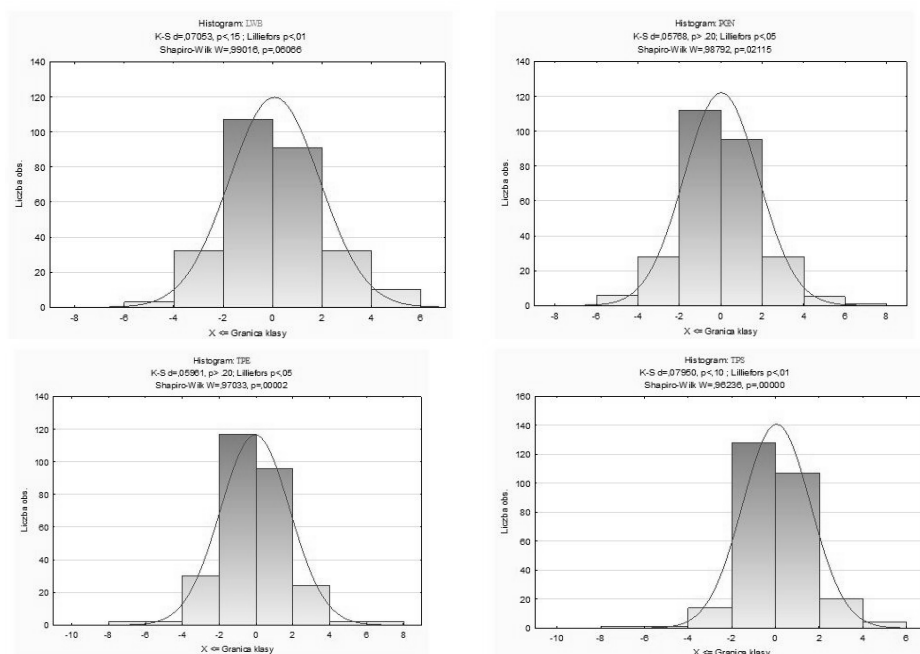
⁵ Znanym z pracy: Anderson-Sprecher [1994].

$$R_{abs}(h) = \frac{E[|Y - Q_{1/2}(Y)|] - hE[|W|]}{E[|Y - Q_{1/2}(Y)|]}. \quad (13)$$

Następnie należy wykorzystać ostatnie równanie jako definicję $R_{abs}(h)$. Zakładamy także, że całkowity udział zmiennej losowej W w poziomie dyspersji Y jest zapisany jako $hE(|W|)$ niezależnie od rozkładu zmiennej losowej X .

4. Wybrane odporne regresje w estymacji ryzyka systematycznego

Podjęto analizę empiryczną ryzyka systematycznego dla spółek wchodzących w skład portfela WIG 20. Uwagę skupiono na największych spółkach tego portfela przyjmując okres badawczy 13.07.2011-8.08.2012. Wstępna analiza struktury dziennych stóp zwrotu badanych aktywów wykazała występowanie obserwacji odstających (rys. 1) oraz ekstremalnych w przypadku wszystkich badanych spółek w badanym okresie.



Rys. 1. Analiza struktury stopy zwrotu aktywów w okresie 13.07.2011-8.08.2012

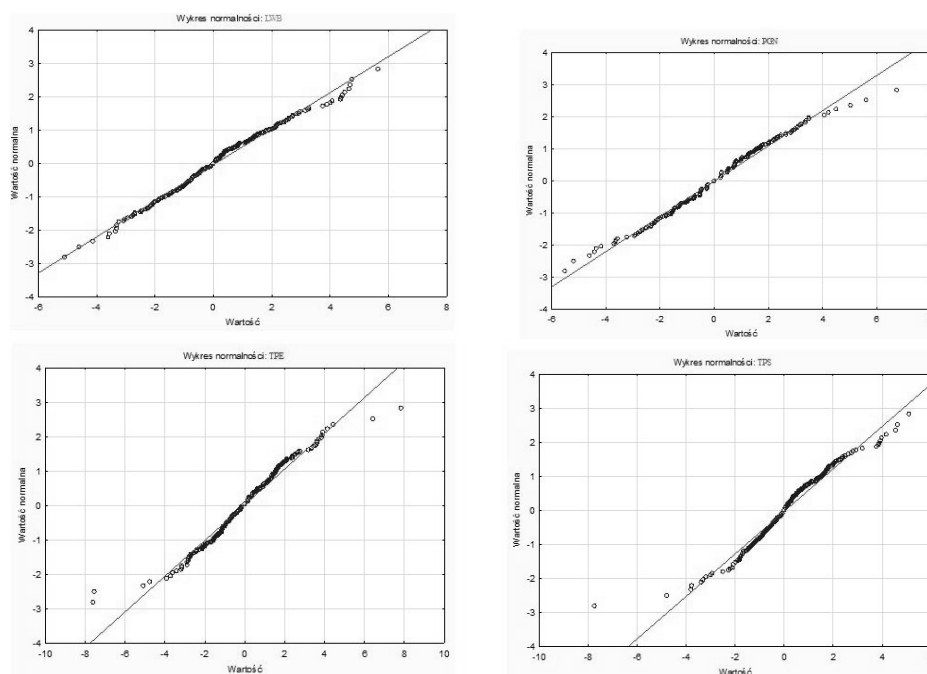
Rozważamy model rynku, w którym stopy zwrotu z inwestycji są losowe i ciągłe o łącznej funkcji gęstości $f(R_k, M)$, gdzie R_k jest stopą zwrotu akcji k oraz M jest portfelem rynkowym. Zapiszemy jako f_M , F_M , μ_M , oraz σ_M^2 odpowiednio

gęstość brzegową, dystrybuantę brzegową, wartość oczekiwaną i wariancję M . Celem dalszych badań jest analiza ryzyka systematycznego mierzona jako wartość β w równaniu regresji. Celem estymacji wartości β akcji, zazwyczaj zakłada się następującą zależność zwaną modelem CAMP:

$$R_k = \alpha_k + \beta_k M + \varepsilon_k,$$

z dodatkowym założeniem o składnikach losowych ε_k – że są niezależne, o takim samym rozkładzie z wartością oczekiwaną zero i stałą wariancją.

Wybrano cztery spółki BOGDANKA (LWB), PGNIG (PGN), TAURONPE (TPE) oraz TPSA (TPS). Kryterium doboru spółek do dalszej analizy, ze zbioru 20 spółek, była najniższa wartość współczynnika determinacji R^2 – równanie 3. W drugiej części analizy statystycznej przeprowadzono testy zgodności (rys. 2) badanych zmiennych z rozkładem normalnym (tab. 1), potwierdzając brak zgodności z rozkładem normalnym.



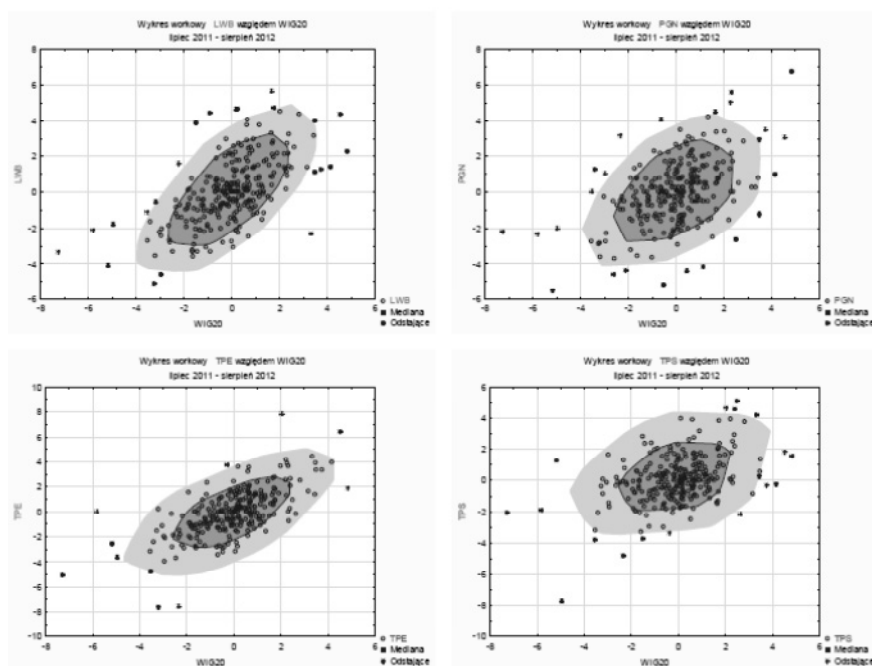
Rys. 2. Analiza zgodności stopy zwrotu aktywów w okresie 13.07.2011-8.08.2012 z rozkładem normalnym

Tabela 1

Wyniki testu Shapiro-Wilka zgodności z rozkładem normalnym

Nazwa aktywów	BOGDANKA (LWB)	PGNIG (PGN)	TAURONPE (TPE)	TPSA (TPS)
Wartość testu S-W	0,99016	0,98792	0,97033	0,96236
p-value	0,06066	0,02115	0,000002	0,00000

Następnie przeprowadzono estymację trzech wybranych modeli regresji. Model klasyczny MNK jest zestawiony z modelem najmniejszych uciętych kwadratów LTS⁶. Klasyczny model jest z założenia modelem liniowym, a dwuwymiarowa analiza nie potwierdza tych założeń (rys. 3). Obserwujemy liczne obserwacje odstające. Dodatkowo wyznaczamy zatem regresję kwantylową. Ryzyko systematyczne jest mierzone współczynnikiem kierunkowym linii regresji, względem *benchmarku* rynku (WIG 20). W tab. 2-5 zapisano wyniki estymacji modelu liniowego MNK, najmniejszych uciętych kwadratów LTS (dla usunięcia obserwacji wykorzystano analizę reszt⁷) oraz modelu regresji kwantylowej QR⁸ dla wybranego poziomu kwantyla 0,01 ($Var_{0,01}$) dla grupy analizowanych spółek. Diagnostyka obserwacji wpływowych przeprowadzona przy estymacji modelu LTS zmusza do zadania pytań, istotnych dla dalszej analizy ryzyka systematycznego, o wiarygodność wniosków, które można wyciągnąć na podstawie dopasowanej funkcji regresji, jak również o występowanie w zbiorze obserwacji wartości wpływowych.



Rys. 3. Wykresy dwuwymiarowe obserwacji odstających dla spółek BOGDANKA (LWB), PGNIG (PGN), TAURONPE (TPE) oraz TPSA (TPS)

⁶ Fox [1991]; Huber [1981]; Koenker [1982]; Trzpiot [2013b].

⁷ Trzpiot [2013a].

⁸ Trzpiot [2007, 2008].

Tabela 2

Wyniki estymacji modeli dla spółki Bogdanka

MNK		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,358$	0,107	0,089	1,202	0,231	$R^2_{abs} = 0,889$
$\hat{\beta}$	$N = 275$	0,676	0,055	12,345	0,000	$R^2_{(\alpha,\beta)} = 0,397$
LTS		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,377$	0,010	0,081	0,127	0,899	$R^2_{abs} = 0,968$
$\hat{\beta}$	$N = 267$	0,632	0,050	12,663	0,000	$R^2_{(\alpha,\beta)} = 0,401$
QR _{0,01}		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,704$	-1,046	0,128	-8,181	0,000	$R^2_{abs} = 0,007$
$\hat{\beta}$	$N = 274$	0,606	0,024	25,431	0,000	$R^2_{(\alpha,\beta)} = 0,201$

Modele zostały oszacowane i ocenione dodatkowo poprzez pomiar dyspersji za pomocą współczynników $R_{abs}(h)$ oraz $R_{(\alpha,\beta)}(h)$ dla średniego absolutnego odchylenia oraz dla regresji kwantylowej – równania (11) i (12).

Tabela 3

Wyniki estymacji modeli dla spółki PGING

MNK		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,221$	0,044	0,096	0,461	0,645	$R^2_{abs} = 0,962$
$\hat{\beta}$	$N = 275$	0,521	0,059	8,809	0,000	$R^2_{(\alpha,\beta)} = 0,520$
LTS		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,264$	0,065	0,080	0,809	0,419	$R^2_{abs} = 0,968$
$\hat{\beta}$	$N = 257$	0,483	0,051	9,562	0,000	$R^2_{(\alpha,\beta)} = 0,433$
QR _{0,01}		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,386$	-3,042	0,127	-24,007	0,000	$R^2_{abs} = 0,002$
$\hat{\beta}$	$N = 274$	0,309	0,024	13,076	0,000	$R^2_{(\alpha,\beta)} = 0,627$

W tabelach przedstawiono wartości estymowanych parametrów dla trzech modeli regresji kalibrowanych dla analizowanych szeregów czasowych. Podano dodatkowo błąd standardowy szacunku. Wnioskowanie statystyczne dla wyznaczonych modeli obejmuje wnioskowanie o istotności parametrów $\hat{\beta}$ i $\hat{\alpha}$ z wykorzystaniem testu *t*-Studenta wraz z podaniem poziomu istotności tego testu. Wartości współczynników regresji klasycznej MNK powinny być przyjmowane

z uwzględnieniem wyników testów przedstawionych w tab. 1. Regresja kwantylowa została zapisana dla bardzo małej wartości kwantyla; taką wartość przyjmujemy, jeżeli do opisu zachowań rynku dodatkowo wykorzystamy *VaR* (*Value-at-Risk*), a wyniki dopasowania modeli są najkorzystniejsze względem R^2 . Analizując miary dyspersji, mamy potwierdzenie konkluzji PGING oraz TPSA, dla pozostałych dwóch spółek miary dyspersji dają inną ocenę: dla aktywu Bogdanka i TAURONPE powinniśmy raczej wybrać model ucięty LTS.

Tabela 4

Wyniki estymacji modeli dla spółki TAURONPE

MNK		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,433$	-0,012	0,086	-0,143	0,886	$R_{abs}^2 = 0,943$
$\hat{\beta}$	$N = 275$	0,764	0,053	14,439	0,000	$R_{(\alpha,\beta)}^2 = 0,429$
LTS		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,509$	-0,082	0,075	-1,100	0,272	$R_{abs}^2 = 0,880$
$\hat{\beta}$	$N = 266$	0,776	0,047	16,542	0,000	$R_{(\alpha,\beta)}^2 = 0,438$
QR _{0,01}		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,713$	1,281	0,287	4,468	0,000	$R_{abs}^2 = 0,013$
$\hat{\beta}$	$N = 274$	1,390	0,053	26,024	0,000	$R_{(\alpha,\beta)}^2 = 0,125$

Tabela 5

Wyniki estymacji modeli dla spółki TPSA

MNK		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,172$	0,070	0,086	0,818	0,414	$R_{abs}^2 = 0,897$
$\hat{\beta}$	$N = 275$	0,399	0,053	7,535	0,000	$R_{(\alpha,\beta)}^2 = 0,514$
LTS		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,213$	0,057	0,082	0,690	0,491	$R_{abs}^2 = 0,916$
$\hat{\beta}$	$N = 270$	0,441	0,052	8,523	0,000	$R_{(\alpha,\beta)}^2 = 0,484$
QR _{0,01}		Współczynniki	Błąd standardowy	t Stat	Wartość-p	Dyspersja
$\hat{\alpha}$	$R^2 = 0,794$	1,791	0,190	9,450	0,000	$R_{abs}^2 = 0,023$
$\hat{\beta}$	$N = 274$	1,144	0,035	32,396	0,000	$R_{(\alpha,\beta)}^2 = 0,922$

Podsumowanie

Celem pracy było wykorzystanie współczynnika determinacji wraz z jego modyfikacjami dla odpornych zadań regresji, takich jak najmniejsze medianowe kwadraty (*least median of squares* – LMS) oraz najmniejsze absolutne odchylenia (*mean absolute deviation* – MAD) w szacowaniu ryzyka systematycznego. Wybrano grupę spółek i zbadano dopasowanie trzech typów regresji z wykorzystaniem trzech mierników. Miary są definiowane na innych podstawach teoretycznych, ale niezależnie od sposobu kalibracji modeli odnoszą się do całej próby oraz mogą służyć do porównania wyników regresji. Interesującym jest fakt, że potrafimy wskazać model regresji lepszy od innych pod względem przyjętego kryterium, pomimo iż wyniki nie zawsze są zadowalające.

Literatura

- Anderson-Sprecher R. (1994): *Model Comparisons and R²*. „Amer. Statist.”, 48.
- Casella G., Berger R.L. (1990): *Statistical Inference*. Wadsworth, Belmont.
- Fox J. (1991): *Regression Diagnostics*. C. A. Sage, Newbury Park.
- Gouriéroux C., Laurent J.P., Scaillet O. (1999): *Sensitivity Analysis of Values at Risk*. Discussion paper, Université Catholique de Louvain.
- Huber P. (1981): *Robust Statistics*. John Wiley, New York.
- Jorion P. (1997): *Value at Risk: The New Benchmark for Controlling Market Risk*. Irwin, Chicago.
- Koenker R. (1982): *Robust Methods in Econometrics*. „Econometric Reviews”, 1.
- Simonoff J.S. (1996): *Smoothing Methods in Statistics*. Springer, New York.
- Tasche D. (1999): *Risk Contributions and Performance Measurement*. Preprint, Technische Universität München, <http://www.ma.tum.de/stat/>.
- Trzpiot G. (2004): *Kwantylowe miary ryzyka*. „Prace Naukowe AE Wrocław”, 1022.
- Trzpiot G. (2007): *Regresja kwantylowa a estymacja VaR*. „Prace Naukowe AE Wrocław”, 1176.
- Trzpiot G. (2008): *Implementacja metodologii regresji kwantylowej w estymacji VaR*. „Studia i Prace” nr 9, Uniwersytet Szczeciński, Szczecin 2008.
- Trzpiot G. (2013a): *Selected Robust Methods for CAMP Model Estimation*. „Folia Oeconomica Stetinensia” 2013, Vol. 12, Iss. 2.

Trzpiot G. (2013b): *Wybrane statystyki odporne*. W: *Metody wnioskowania statystycznego w badaniach ekonomicznych*. Red. J.L. Wywiół. Wydawnictwo UE, Katowice.

Uryasev S. (2000): *Introduction to the Theory of Probabilistic Functions and Percentiles (Value-at-risk)*. Research Report # 2000-7, University of Florida.

ALTERNATIVE METHOD OF SYSTEMATIC RISK MEASUREMENT IN CAMP MODEL

Summary

In linear regression model, estimated by last square method, the coefficient of determination gives as an information about ratio of variance of dependence variable describe by chosen in linear relation independence variable. We give the new range of this concept by description the coefficient of determination for chosen robust regression models.

We proposed the description of the problem in economic contests, instead that the problem of measurement of systematic risk is a very general issue.