

DYNAMICZNE MODELE EKONOMETRYCZNE

VIII Ogólnopolskie Seminarium Naukowe, 9-11 września 2003 w Toruniu
Katedra Ekonometrii i Statystyki, Uniwersytet Mikołaja Kopernika w Toruniu

Daniel Papla

Akademia Ekonomiczna we Wrocławiu

Związki pomiędzy zmianami poziomu efektywności informacyjnej i wielkością spółek na GPW w Warszawie

1. Wstęp

Referat ten stanowi próbę zweryfikowania dwóch hipotez badawczych:

- zwiększający się poziom słabej efektywności dużych spółek na giełdzie w Warszawie, gdzie poziom efektywności definiuje się jako wielkość zależną od poziomu istotności wyników testów słabej efektywności. Im poziom istotności wyników sugerujących odrzucenie tej hipotezy jest większy, tym dany rynek wykazuje mniejszy poziom efektywności.
- poziom efektywności dla spółek małych nie zwiększa się.

Referat składa się z trzech części.

W pierwszej zaprezentowano szerszej hipotezy. Zaprezentowano w niej również kryterium wyboru spółek, które powinno umożliwić wskazanie grup spółek o różnej efektywności.

Druga część zawiera metodologię badań, krótkie omówienie zastosowanych testów słabej efektywności (głównie testów błędzenia losowego).

W trzeciej części są zaprezentowane wyniki badań wraz z ich interpretacją.

2. Hipotezy badawcze

W trakcie swoich badań naukowych związanych z pisaną rozprawą doktorską (Papla (2003)), autor natknął się na pewne prawidłowości w kształtowaniu się i zmianach poziomu słabej efektywności poszczególnych spółek Giełdy Papierów Wartościowych w Warszawie.

Na początku należy zdefiniować dwa pojęcia. Po pierwsze, poziom efektywności mierzymy przy pomocy istotności testów efektywności. Jeśli hipotezą zerową testu jest istnienie efektywności, wtedy im mniejsza istotność statystyki empirycznej tego testu, tym większy poziom efektywności badanego rynku lub spółki. Efektywność danej spółki z kolei oznacza, iż wszystkie informacje dotyczące tej spółki są natychmiast i odpowiednio odzwierciedlone w cenie. W tym artykule, ze względu na dostępność i częstotliwość danych zajmujemy się jedynie słabą efektywnością, czyli będziemy badać wpływ przeszłych cen na ceny obecne.

W artykule tym spróbujemy odpowiedzieć na pytanie, czy poziom istotności i jego zmiany zależą od wielkości spółki mierzonej jej kapitalizacją. Badania, których wyniki zamieszczone są w tym artykule, mają za zadanie zweryfikowanie następujących hipotez:

- poziom słabej efektywności dużych spółek na giełdzie w Warszawie zwiększa się,
- poziom efektywności dla spółek małych pozostaje bez zmian.

Dane wykorzystane w części empirycznej obejmują notowania wszystkich spółek z okresu 1995-2002 w podziale na podokresy roczne. W każdym z tych podokresów wybrano do analizy 10 największych i 10 najmniejszych spółek.

3. Testy słabej efektywności

Testy wybrane do tego referatu badają prawdziwość następującej hipotezy H_0 : przyrosty cen akcji są niezależnymi zmiennymi losowymi o jednakowych rozkładach. Hipoteza ta podlega pewnym modyfikacjom dla testów serii, jednakże podstawy teoretyczne tego testu są na tyle zbliżone, że wydaje się uzasadnione włączenie go w tę grupę.

A. Test autokorelacji

Hipoteza H_0 : przyrosty cen akcji są niezależnymi zmiennymi losowymi o jednakowych rozkładach, H_1 : przyrosty cen akcji są zmiennymi zależnymi lub mają niejednakowe rozkłady.

Test ten należy do najprostszych testów, wynikających wprost z definicji błędzenia losowego:

$$\hat{\gamma}(k) = \frac{1}{T-k} \sum_{t=1}^{T-k} (R_t - \bar{R}_T)(R_{t+k} - \bar{R}_T) \quad (1)$$

$$\hat{\rho}(k) = \frac{\hat{\gamma}(k)}{\hat{\gamma}(0)}$$

gdzie: $\hat{\gamma}(k)$ – autokowariancja stopnia k , $\hat{\rho}(k)$ – autokorelacja stopnia k , R_t – stopa zwrotu w okresie t , \bar{R}_T – średnia stopa zwrotu. Przy założeniu, że przyrosty są niezależnymi zmiennymi losowymi o jednakowych rozkładach, można wykazać, że

$$\sqrt{T} \hat{\rho}(k) \quad (2)$$

ma rozkład asymptotyczny $N(0,1)$ (Taylor (1986)). Jeśli na przykład przyjmiemy poziom istotności 0,05, możemy odrzucić hipotezę błędzenia losowego, jeżeli wartość (2) przekroczy co do wartości bezwzględnej 1,96.

Do podstawowych zalet tego testu należy zaliczyć jego prostotę i łatwo interpretowalne wyniki. Ze względu na to, że jest on bardzo często stosowany przez różnych autorów, uzyskane wyniki można łatwo porównać z wynikami uzyskanymi dla innych rynków. Jednakże test ten nie jest pozbawiony wad. Za jedną z nich można uznać fakt, iż test ten mierzy jedynie zależność liniową, co w wypadku rynków kapitałowych może się okazać niewystarczające, zwłaszcza, jeśli weźmiemy pod uwagę efekty nieliniowe, które według niektórych autorów są na giełdach obecne (por. np. Scheinkman, LeBaron (1989)). Test ten również dopuszcza subiektywność w wyborze rzędu badanej autokorelacji, co nie pozwala czasami na porównywanie wyników uzyskanych przez różnych autorów. Subiektywność ta może stworzyć również niebezpieczeństwo niewłaściwej interpretacji, jeśli autokorelacja o wybranym przez autora opóźnieniu okaże się przypadkowo znacząca. Można temu zaradzić badając autokorelacje dla wielu opóźnień, lub stosując statystykę Q_m , omówioną dalej.

B. Statystyka Q

Hipotezy H_0 i H_1 są takie same jak hipotezy dla testu autokorelacji.

1. Statystyka Boxa-Pierce'a

Wychodząc z wniosku, że dla zwykłego błędzenia losowego wszystkie autokorelacje są równe zeru, statystyka

$$Q_n = T \sum_{k=1}^m \hat{\rho}(k)^2 \quad (3)$$

ma asymptotyczny rozkład χ_m^2 . Należy jednak bardzo uważnie dobrać wielkość m , ponieważ dla m zbyt małych można nie zauważyć znaczących autokorelacji wyższych rzędów, zaś m zbyt duże może zmniejszać moc testu ze względu z kolei na obecność nieznaczących autokorelacji wyższych rzędów (Taylor (1986)).

Gdy wartość empiryczna statystyki Q_m przekroczy wartość teoretyczną przy danym poziomie istotności i stopniach swobody, możemy odrzucić hipotezę błędzenia losowego.

2. Statystyka Boxa-Ljunga

Można opisać ją wzorem:

$$Q_n = T \cdot (T + 2) \sum_{k=1}^m \frac{\hat{\rho}(k)^2}{T - 1} \quad (4)$$

Ona również ma asymptotyczny rozkład χ_m^2 . Nadal pozostaje też problem wyboru właściwej wartości opóźnienia m . Interpretacja statystyki Boxa-Ljunga jest identyczna jak interpretacja statystyki Boxa-Pierce'a. W niniejszej pracy zaprezentowano obydwa testy ze względu na fakt, że test Boxa-Pierce'a, pomimo takich wad, jak niedostosowanie do krótkich szeregów czasowych, był dosyć często stosowany, np. w pracy Taylora (Taylora (1986)).

Obydwie statystyki Q_m są łatwe w stosowaniu i interpretacji. Są również na tyle szeroko stosowane, że, podobnie jak przy testach autokorelacji, istnieje możliwość porównywania wyników z wynikami uzyskanymi dla innych rynków. Ponieważ

jedna statystyka Q_m stanowi agregację wielu współczynników autokorelacji, możliwość niewłaściwej interpretacji ze względu na przypadkowo znaczący współczynnik dla jakiegoś opóźnienia nie jest już tak duże, jak w przypadku testu autokorelacji. Jednakże problem arbitralności nie został całkowicie wyeliminowany, badacz nadal musi wybrać rząd maksymalnego opóźnienia m . Również ten problem można próbować ominąć poprzez stosowanie wielu wartości m , wydłuża to jednak czas obliczeń i utrudnia interpretację wyników.

Ponieważ statystyka Q_m mierzy jedynie zależność liniową, nie można jej stosować do wykrywania zależności nieliniowych, może również dawać nieprawidłowe wyniki, jeśli w badanym szeregu czasowym są obecne efekty nieliniowe.

C. Ilorazy wariancji

Hipoteza H_0 : dane generowane są przez proces błędzenia losowego, H_1 : dane generowane są przez proces nie będący błędzeniem losowym.

Ważną cechą hipotez błędzenia losowego jest fakt liniowej zależności pomiędzy wariancją a przedziałem czasowym, w jakim jest ona mierzona. Jeśli logarytmy cen podlegają błędzeniu losowemu, wtedy logarytmiczne stopy zwrotu – przyrosty oznaczone jako R_t , są zmiennymi losowymi o identycznych i niezależnych rozkładach. Wariancja $R_t + R_{t-1}$ powinna być dwa razy większa niż wariancja dla R_t . Jeśli $R_t(q) = R_t + R_{t-1} + R_{t-2} + \dots + R_{t-q+1}$ to zachodzi następująca tożsamość:

$$VR(q) = \frac{Var[R_t(q)]}{q \cdot Var[R_t]}, \quad (5)$$

gdzie: $Var(R)$ – oznacza wariancję zmiennej losowej R .

W zależności od rodzaju błędzenia losowego (rodzaje błędzenia losowego zostały zaprezentowane np. w pracy Campbell, Lo, MacKinlay (1997)) możemy rozpatrywać różne estymatory wartości $VR(2)$ lub $VR(q)$. Dla RW1 (niezależne przyrosty o identycznych rozkładach) mamy następujące wzory, gdzie przez l_t oznaczamy logarytm ceny akcji:

$$\begin{aligned} \hat{Var}[R_t] &= \frac{1}{T} \sum_{k=1}^T (R_k - \bar{R})^2 \\ \hat{Var}[R_t(2)] &= \frac{1}{n} \sum_{k=1}^n (R_k(2) - 2\bar{R})^2, \\ \hat{VR}(2) &= \frac{\hat{Var}[R_t(2)]}{2\hat{Var}[R_t]} \end{aligned} \quad (6)$$

gdzie: $R_t = l_t - l_{t-1}$ – logarytmiczna stopa zwrotu w momencie t z okresu o długości 1 (jeśli miarą czasu jest dzień, to jest to dzienna stopa zwrotu), \bar{R} – średnia logarytmiczna stopa zwrotu, $R_t(2) = l_{2t} - l_{2t-2}$ – logarytmiczna stopa zwrotu w momencie $2t$ z okresu o długości 2 (dla miary czasu równej jednemu dniu jest to dwudniowa stopa zwrotu), $\hat{Var}[R_t]$ – estymator $Var[R_t]$, $\hat{Var}[R_t(2)]$ – estymator $Var[R_t(2)]$, $\hat{VR}(2)$ – estymator ilorazu wariancji stopnia drugiego, $2n = T$ – długość badanego okresu.

Wzór (6) przedstawia najprostszy przypadek ilorazu wariancji. Jak widać jest to iloraz wariancji logarytmicznych stóp zwrotu z okresów o długości 2 i 1 jednostki czasu (np. stóp dwu- i jednodniowych).

Można wykazać, że $\frac{VR(2)-1}{\sqrt{2}}$ ma asymptotycznie rozkład $N(0,1)$. Testując hipotezę błędzenia losowego postępujemy analogicznie jak w przypadku statystyki (2).

Powyższe wzory łatwo jest przekształcić dla stóp zwrotu z więcej niż dwóch okresów, co przedstawiają poniższe wzory. Poprawienie charakterystyk testu dla szeregów danych o niezbyt dużej liczbie obserwacji uzyskano poprzez zastosowanie stóp zwrotu dla nakładających się podokresów o długości q . Skorygowano również obciążenie dla estymatorów wariancji.

$$\begin{aligned} \hat{Var}[R_t(q)] &= \frac{q}{m} \sum_{k=q}^{nq} (R_t(q) - q\bar{R})^2 \\ \hat{VR}(q) &= \frac{\hat{Var}[R_t(q)]}{q \cdot \hat{Var}[R_t]} \\ m &= q(nq - q - 1) \left(1 - \frac{q}{nq}\right) \\ \psi(q) &= \frac{\sqrt{nq}(\hat{VR}(q) - 1)}{\sqrt{\frac{2(2q-1)(q-1)}{3q}}} \end{aligned} \quad , \quad (7)$$

gdzie: $R_t(q) = l_t - l_{t-q}$ – logarytmiczna stopa zwrotu w momencie t z okresu o długości q (dla miary czasu równej jednemu dniu jest to q -dniowa stopa zwrotu), $\hat{Var}[R_t(q)]$ – estymator $Var[R_t(q)]$, $\hat{VR}(q)$ – iloraz wariancji stopnia q , $\psi(q)$ – znormalizowana wartość ilorazu o rozkładzie $N(0,1)$, $qn = T$ – długość badanego okresu.

Od pewnego czasu wśród ekonomistów coraz częściej słyszy się pogląd, że hipoteza błędzenia losowego powinna być odrzucana ze względu na heteroskedastyczność stóp zwrotu. Nie jest to słuszne. Dlatego interesujące może być stworzenie testu ilorazu wariancji w oparciu o założenia RW3 (nieskorelowane przyrosty), które nie wykluczają heteroskedastyczności. Można zauważyć, że niezależnie od poziomu heteroskedastyczności iloraz wariancji nadal powinien asymptotycznie dążyć do jedności, jednakże wariancja rozkładu ilorazu wariancji będzie zależała od typu i stopnia heteroskedastyczności. Opierając się na założeniu o heteroskedastyczności stóp zwrotu otrzymujemy następujące wzory:

$$\begin{aligned}
VR(q)^* &= 1 + 2 \sum_{k=1}^{q-1} \left(1 - \frac{k}{q}\right) \hat{\rho}(k) \\
\hat{\delta}_k &= \frac{\sum_{j=k+1}^{nq} (R_j - \bar{R})^2 (R_{j-k} - \bar{R})^2}{\left[\sum_{j=1}^{nq} (R_j - \bar{R})^2 \right]^2}, \\
\hat{\theta}(q) &= 4 \sum_{k=1}^{q-1} \left(1 - \frac{k}{q}\right)^2 \hat{\delta}_k \\
\psi^*(q) &= \frac{\sqrt{nq} (VR(q) - 1)}{\sqrt{\hat{\theta}(q)}}
\end{aligned} \tag{8}$$

gdzie: $\hat{\delta}_k$ – wariancja współczynników autokorelacji stopnia k , $\hat{\theta}(q)$ – wariancja ilorazu wariancji $VR(q)$, $\psi^*(q)$ – statystyka testowa, która ma również asymptotyczny rozkład $N(0, 1)$. Wyprowadzenie (8) można znaleźć w pracy Campbell, Lo, MacKinlay (1997). Podstawą tego wyprowadzenia jest przedstawienie ilorazu wariancji jako ważonej sumy współczynników autokorelacji. Poprzez uwzględnienie w estymacji $VR(q)$ wariancji tych współczynników autokorelacji możliwe jest uwzględnienie heteroskedastyczności.

Zaletą ostatniego z zaprezentowanych testów jest uwzględnienie w nim również korekty ze względu na niewielką długość szeregu. Niestety, test ten jest dosyć skomplikowany, choć uzyskany wynik jest łatwo zinterpretować. Ponieważ test ten został skonstruowany dla RW1, jest on wrażliwy na nieliniowość. Nie jest tak rozporozważony, jak testy autokorelacji i Q , dlatego też uzyskane wyniki nie można tak szeroko porównywać. Jak wynika z przeprowadzonych przez autora badań (Papla (1998)), pomiędzy wynikami testów autokorelacji i ilorazu wariancji istnieje duże podobieństwo, co oznacza, że dodatkowa wartość informacyjna wnoszona przez testy ilorazu wariancji jest raczej niewielka. Ponieważ jednak ostatni wariant tych testów zawiera korektę ze względu na heteroskedastyczność, testy te zostały zamieszczone w tej pracy.

D. Test serii

Hipoteza H_0 : R_t^* jest generowane przez biały szum, gdzie R_t^* równa się 1, 0, -1, jeśli stopa zwrotu R_t jest odpowiednio większa, równa lub mniejsza od zera. Hipoteza H_1 zakłada, że R_t^* jest generowane przez proces nie będący białym szumem.

Zdefiniujmy serię dodatnią jako nieprzerwaną sekwencję dodatnich stóp zwrotu, analogicznie określamy serię zerową i ujemną stóp zwrotu. Niech h_t równa się 0, jeśli $R_t^* = R_{t+1}^*$ i 1 w przeciwnym przypadku. W takim razie $h_t = 1$ oznacza, że R_{t+1} rozpoczyna nową serię. Z tego względu całkowitą liczbę serii można określić za pomocą wzoru:

$$h = 1 + \sum_{t=1}^{T-1} h_t, \quad (9)$$

Załóżmy, że badany szereg składa się z T_1 dodatnich stóp zwrotu, T_2 zerowych stóp zwrotu i T_3 ujemnych stóp zwrotu. Wtedy średnią i wariancję zmiennej losowej H , której realizacją jest h , możemy określić wzorami:

$$E(H) = T + 1 - \frac{\sum_{j=1}^3 T_j^2}{T}, \quad (10)$$

$$Var(H) = \frac{\sum_{j=1}^3 T_j^2 \left(\sum_{j=1}^3 T_j^2 + T + T^2 \right) - 2T \sum_{j=1}^3 T_j^3 - T^3}{T^3 - T}. \quad (11)$$

Ponieważ dla dużej liczby danych zmienna H ma w przybliżeniu rozkład normalny możemy wykorzystać zmienną K :

$$K = \frac{H - E(H)}{\sqrt{Var(H)}}. \quad (12)$$

H_0 odrzucamy, jeśli K jest większe co do wartości bezwzględnej od 1,96, przy poziomie istotności 0,05. Jeśli $K < 0$, co oznacza liczbę serii mniejszą niż oczekiwana, możemy uznać, że w danych przeważają trendy. Dodatnia wartość K świadczy o obecności procesu powracania do średniej (por. Taylor (1986)).

Zaletą tego testu jest, przynajmniej teoretycznie, zdolność do wykrywania innych rodzajów zależności niż tylko korelacja liniowa. Niestety ze względu na utratę informacji, jaka ma miejsce przy przejściu od właściwego szeregu do szeregu R_t^* , test ten ma z reguły zbyt małą moc, aby wykazać niezbyt duże odchylenia od losowości. Pomimo to jest dosyć często stosowany, co daje możliwość porównania wyników i co stanowi powód zamieszczenia go w niniejszej pracy.

4. Wyniki badań empirycznych

Przedstawione poniżej tabele zawierają wyniki testów przedstawionych w poprzednim punkcie dla 10 największych i 10 najmniejszych spółek w danym podokresie rocznym. W tabelach tych przedstawiono średni poziom statystyki testowej otrzymanej przy pomocy danego testu dla 10 największych lub najmniejszych spółek w danym okresie. W przypadku testów autokorelacji, ilorazu wariancji i serii uśredniano wartości bezwzględne statystyk. Oczywiście uśredniona wartość statystyki w żadnym razie nie może służyć do statystycznej weryfikacji hipotezy błędzenia losowego, ma ona charakter bardziej ilustracyjny. Bardziej sformalizowane badania są jednym z celów dalszej pracy naukowej autora.

Tabela 1. Średnie wartości statystyki testowej dla testu autokorelacji

Spółki największe													
Rząd autokorelacji	1	2	3	4	5	6	7	8	9	10	20	50	100
Lata													
1995	1,769	0,803	1,113	1,073	0,632	0,680	0,668	1,029	0,457	0,601	0,597	0,475	0,682
1996	1,758	0,757	0,945	0,619	0,798	0,986	0,567	0,827	0,543	0,580	0,599	0,444	0,596
1997	1,027	0,958	0,543	0,761	0,586	0,655	0,769	0,989	0,674	1,091	0,697	0,340	0,368
1998	0,888	1,132	0,563	0,401	0,664	0,829	1,051	0,626	0,581	0,815	0,976	0,759	0,553
1999	1,138	0,605	1,359	1,128	1,351	1,055	0,794	0,998	0,619	0,706	1,043	0,649	0,547
2000	0,732	1,046	0,568	0,956	1,024	1,497	0,944	0,524	0,402	0,504	0,355	0,344	0,444
2001	2,152	0,675	1,009	0,766	0,919	1,159	0,671	0,816	0,814	1,111	0,577	0,864	0,722
2002	0,972	0,584	0,745	1,392	0,787	0,917	0,696	0,607	0,770	0,869	0,997	0,761	0,486
Spółki najmniejsze													
Rząd autokorelacji	1	2	3	4	5	6	7	8	9	10	20	50	100
Lata													
1995	1,458	1,250	0,703	0,863	0,935	0,539	0,575	0,988	0,836	0,611	0,832	0,570	0,480
1996	1,684	0,730	0,716	1,024	0,984	0,784	0,725	0,852	0,951	0,675	1,057	0,746	0,620
1997	1,122	0,789	0,800	1,106	0,719	0,792	0,722	0,649	0,782	0,741	0,642	0,591	0,530
1998	2,239	0,718	1,071	0,941	0,896	1,062	1,080	0,835	0,595	0,516	0,675	0,663	0,942
1999	2,949	1,304	0,718	1,064	0,569	0,544	0,976	0,738	0,920	1,000	0,730	0,402	0,414
2000	3,480	1,146	0,985	0,783	0,798	1,153	1,034	0,634	0,820	0,726	1,158	0,660	0,380
2001	4,223	1,066	0,615	0,920	0,622	0,657	0,909	0,663	0,869	0,775	0,708	0,526	0,475
2002	2,658	1,371	0,955	0,845	0,753	0,882	0,857	0,907	1,024	0,937	0,671	0,726	0,572

Źródło: opracowanie własne

Tabela 2. Średnie wartości statystyki testowej dla testu Boxa-Pierce'a

Rząd testu	Spółki największe				Spółki najmniejsze			
	10	20	50	100	10	20	50	100
Lata								
1995	12,3669	24,9008	55,3771	92,3123	10,8665	18,5873	40,6103	68,9431
1996	11,5682	19,4810	44,1289	81,9512	14,2673	23,0420	52,2032	80,9047
1997	9,7359	19,5202	41,1574	68,4183	10,2399	21,8697	41,6216	77,1124
1998	9,0950	21,2189	47,0207	77,5846	17,8589	28,5828	53,7906	93,7440
1999	14,1577	23,0252	44,6081	71,7324	21,1901	31,6371	53,6097	77,9247
2000	11,4599	23,4650	48,9150	73,0911	24,1894	35,7197	62,7205	92,0662
2001	17,4719	28,5141	55,5052	91,6560	30,0664	40,9770	73,5800	105,5463
2002	10,2529	19,3513	42,6611	70,7094	21,8362	33,6225	54,0729	84,0155

Źródło: opracowanie własne

Tabela 3. Średnie wartości statystyki testowej dla testu Boxa-Ljunga

Rząd testu	Spółki największe				Spółki najmniejsze			
	10	20	50	100	10	20	50	100
Lata								
1995	12,5171	25,2032	56,0497	93,4335	10,9984	18,8131	41,1036	69,7805
1996	11,7082	19,7166	44,6627	82,9425	14,4399	23,3208	52,8346	81,8834
1997	9,8542	19,7573	41,6573	69,2493	10,3642	22,1353	42,1271	78,0489
1998	9,2050	21,4756	47,5894	78,5231	18,0750	28,9285	54,4413	94,8781
1999	14,3297	23,3048	45,1499	72,6036	21,4474	32,0213	54,2608	78,8711
2000	11,5985	23,7488	49,5067	73,9753	24,4820	36,1518	63,4793	93,1801
2001	17,6833	28,8590	56,1767	92,7649	30,4301	41,4727	74,4700	106,8232
2002	10,3908	19,6116	43,2351	71,6607	22,1300	34,0748	54,8004	85,1457

Źródło: opracowanie własne

Tabela 4. Średnie wartości statystyki testowej dla testu ilorazu wariancji (wzór (6))

Lata	Spółki największe	Spółki najmniejsze
1995	1,8187	1,3662
1996	1,0244	1,8935
1997	1,8667	0,9388
1998	0,8328	2,1692
1999	0,9990	2,0005
2000	0,5466	2,7019
2001	1,3803	3,4765
2002	0,8542	2,1042

Źródło: opracowanie własne

Tabela 5. Średnie wartości statystyki testowej dla testu ilorazu wariancji (wzór (7))

q Lata	Spółki największe				Spółki najmniejsze			
	2	4	8	16	2	4	8	16
1995	1,8774	1,4165	1,0246	1,1773	1,4600	1,4785	1,3617	1,1028
1996	1,8440	1,7459	0,9661	0,6244	1,7266	1,4137	1,0083	0,9236
1997	0,9564	0,8891	1,0806	0,8640	1,1080	1,1271	1,5103	1,3875
1998	0,9969	0,8263	0,7509	1,0082	2,2128	1,9236	1,6738	1,0181
1999	1,2508	0,9194	1,0372	0,9567	2,8735	3,2729	2,7896	2,1566
2000	0,7800	1,0981	1,1884	1,0796	3,5571	3,3207	2,9143	2,3386
2001	2,3275	1,8108	1,5030	1,2155	4,1603	3,6388	3,0663	2,3841
2002	1,0071	0,5700	0,6489	0,5160	2,7088	3,0154	2,6249	1,9650

Źródło: opracowanie własne

Tabela 6. Średnie wartości statystyki testowej dla testu ilorazu wariancji (wzór (8))

q Lata	Spółki największe				Spółki najmniejsze			
	2	4	8	16	2	4	8	16
1995	1,2943	0,9994	0,7246	0,8733	1,1301	1,2096	1,2001	1,0684
1996	1,3401	1,2983	0,7617	0,5030	1,2137	1,0101	0,8459	0,7093
1997	0,5763	0,5671	0,7770	0,7500	0,8917	0,8749	1,3415	1,3656
1998	0,7895	0,6310	0,4463	0,6834	1,7354	1,5978	1,4465	0,9582
1999	0,9134	0,6838	0,8165	0,8072	2,2135	2,4973	2,2126	1,8305
2000	0,6076	0,8934	0,9955	0,9494	2,7172	2,7131	2,5292	2,1579
2001	1,6086	1,2857	1,1411	0,8195	2,1521	2,1265	2,0474	1,8601
2002	0,8396	0,5788	0,6499	0,5095	1,9871	2,3448	2,1528	1,7175

Źródło: opracowanie własne

Tabela 7. Średnie wartości statystyki testowej dla testu serii

Lata	Spółki największe	Spółki najmniejsze
1995	1,6351	0,7994
1996	1,7510	1,2830
1997	0,4304	0,8266
1998	0,9937	1,0753
1999	0,5521	0,9919
2000	0,5472	0,9905
2001	0,8424	1,2205
2002	0,9053	2,0598

Źródło: opracowanie własne

Wnioski wynikające z analizy tabel 1-7 można streścić w kilku punktach:

a) Należy jeszcze raz podkreślić, że średnie wartości statystyk mają jedynie charakter ilustracyjny, mają wskazać kierunki przyszłych badań, a nie świadczyć o braku lub istnieniu efektywności na GPW w Warszawie. Dalsze wnioski mają z tego względu charakter bardziej wskazówek, niż ostatecznych rozstrzygnięć.

b) Obydwie przedstawione we wstępie hipotezy badawcze znajdują raczej małe potwierdzenie w wynikach, głównie ze względu na wyższą wartość statystyk testowych w roku 2001. Rok ten dla większości testów charakteryzował się mniejszą efektywnością, zarówno dla spółek dużych, jak i dla spółek małych.

c) Najwyraźniejszą cechą są wyraźnie większe wartości statystyk testowych małych spółek dla wszystkich testów, zwłaszcza po roku 1998. Od tego roku różnice w „zachowaniu się” spółek małych i dużych stają się wyraźnie widoczne. Spółki większe zdają się również być bardziej efektywne.

Większa efektywność spółek o dużym kapitale może być zarówno związana z ich większą popularnością wśród inwestorów (spółki większe mają również często większy udział w obrotach giełdy, co świadczy o zainteresowaniu nimi wśród inwestorów). Większa popularność przekłada się zwykle na lepszą jakość dostępnych informacji (dostępność, szybkość, dokładność itp.), większą płynność oraz większą liczbę inwestorów, co prowadzi do zwiększenia efektywności. Oczywiście odwrotne zjawiska występują w przypadku spółek mniejszych.

Podsumowując, zastosowane testy nie potwierdzają raczej zwiększania się efektywności, wskazują jedynie na fakt większej efektywności spółek o dużym kapitale.

Literatura

- Campbell, J. Y., Lo, A. W., MacKinlay, A. C. (1997), *The Econometrics of Financial Markets*. Princeton University Press, Princeton.
- Papla, D. (1998), *Hipoteza słabej efektywności i błędzenia losowego – badania empiryczne dla spółek giełdy warszawskiej*. W: *Ekonometria czasu transformacji*. Materiały Konferencyjne XXXIV Konferencji Statystyków, Ekonometryków i Matematyków Akademii Ekonomicznych Polski Południowej. Wyd. AE Katowice 1998, s. 59-73.
- Papla, D. (2003), *Teoria efektywności i jej zastosowanie na rynku polskim*. Rozprawa doktorska. Akademia Ekonomiczna we Wrocławiu.
- Scheinkman, J. A., LeBaron, B. (1989), *Nonlinear Dynamics an Stock Returns*. Journal of Business 62, s. 311-337.
- Taylor, S. (1986), *Modelling Financial Time Series*. John Wiley & Sons, New York.