

JOANNA GÓRNA, KAROLINA GÓRNA
Wydział Nauk Ekonomicznych i Zarządzania
Uniwersytet Mikołaja Kopernika w Toruniu

Analiza konwergencji gospodarczej wybranych regionów Europy w latach 1995–2009

Streszczenie

Artykuł ma na celu zbadanie konwergencji dochodów *per capita* regionów NUTS 2 Unii Europejskiej oraz regionów według tej samej klasyfikacji wybranych grup krajów należących do UE w latach 1995–2009. Cel ten ma być zrealizowany przez wykorzystanie wybranych modeli danych panelowych. Opracowany zostanie model z efektami stałymi (EF) oraz zmiennymi (RE). Podjęte będą próby estymacji modelu dynamicznego za pomocą uogólnionej metody momentów (GMM). Wykorzystanie do obliczeń modeli panelowych umożliwia uzyskanie estymatorów zgodnych i nieobciążonych, poprzez uwzględnienie efektów grupowych. Pozwala to otrzymać model lepiej opisujący rzeczywistość. Analizowana będzie zarówno β -konwergencja, jak i σ -konwergencja. W artykule zostaną również wskazane różnice w dopasowaniu modeli wynikające z różnic w doborze regionów do badania (test Chowa). Ponadto będzie przedstawione porównanie metod opartych na danych panelowych z metodą polegającą na wprowadzeniu efektów przestrzennych.

Słowa kluczowe: dynamiczny model danych panelowych, efekty stałe, efekty zmienne, konwergencja, metoda największej wiarygodności, model danych panelowych, przestrzenny model danych panelowych, systemowa uogólniona metoda momentów, uogólniona metoda momentów

1. Wprowadzenie

Celem artykułu jest zaprezentowanie i porównanie kilku wybranych podejść stosowanych do modelowania β -konwergencji gospodarczej. Realizacja tego celu zostanie dokonana poprzez zestawienie wyników uzyskanych przy

wykorzystaniu podejścia klasycznego, dodatkowo rozszerzonego o metody ekonometrii przestrzennej z podejściem właściwym dla modelowania danych panelowych, również w wersji przestrzennej. Przegląd ten ma pokazać, że włączenie do modelu zależności przestrzennych oraz możliwości oferowanych przez modelowanie panelowe pozwala na dokładniejszy opis zjawiska β -konwergencji.

Neoklasyczny model wzrostu Solowa–Swana, pochodzący z 1956 r., stał się punktem wyjścia bardzo wielu badań. Na przestrzeni lat pojawiało się wiele rozszerzeń tego modelu. Jednym z najbardziej popularnych oraz najważniejszych zagadnień związanych z modelem Solowa jest hipoteza konwergencji gospodarczej, mówiąca o tym, że w gospodarkach działają pewne mechanizmy, które powodują wyrównanie się poziomów bogactwa między różnymi krajami (regionami). Do najbardziej popularnych rodzajów konwergencji należy konwergencja typu β . Zakłada ona, że kraje (regiony) charakteryzujące się mniejszym poziomem PKB *per capita* mają szybsze tempo wzrostu niż kraje początkowo bogatsze. Prowadzi to do zrównania poziomów dochodów *per capita* między krajami.

Dodatkowo wyróżnia się konwergencję warunkową i absolutną. Konwergencja absolutna oznacza, że wszystkie badane gospodarki zmierzają do tego samego poziomu zamożności, wyrażonego przez PKB *per capita*. Konwergencja warunkowa oznacza, że każdy kraj dąży do swojego własnego stanu wzrostu zrównoważonego, zależnego od cech gospodarki. Podobne poziomy tego stanu (ang. *steady state*) mają więc kraje o podobnych czynnikach determinujących wzrost.

2. Wcześniejsze badania na temat konwergencji

Szeroka debata dotycząca konwergencji została zapoczątkowana w 1986 r. przez Williama Baumolą. Do szczególnie znaczących prac dotyczących modelowania wzrostu i konwergencji należy zaliczyć opracowania następujących autorów: Barro i Sala-i-Martina¹, Mankiwa, Romera i Weila². Tematyka ta do tej pory jest często rozważana i podejmowana.

Hipoteza konwergencji była testowana dla bardzo wielu różnych gospodarek. Tematyka wzrostu gospodarczego i konwergencji na różnych szczeblach

¹ R.J. Barro, X. Sala-i-Martin, *Public Finance in Models of Economic Growth*, C.E.P.R. Discussion Papers, 1992.

² N.G. Mankiw, D. Romer, D.N. Weil, *A contribution to the empirics of economic growth*, „The Quarterly Journal of Economics” 1992, vol. 107, issue 2, s. 407–437.

(krajowym bądź regionalnym) podejmowana była także przez wielu polskich autorów. Wśród istotnych prac z tego zakresu należy wymienić m.in. opracowania: Gawlikowskiej-Hueckel³, Wójcika⁴, Próchniaka⁵, Markowskiej-Przybyły⁶.

W badaniach dotyczących analizy wzrostu gospodarczego i konwergencji mniej znane, ale w ostatnich latach coraz częściej stosowane jest podejście bayesowskie, polegające na szacowaniu bardzo dużej liczby równań, a następnie uśrednianiu uzyskanych wyników. Jako przykłady takiego ujęcia tematu należałoby np. wspomnieć prace: Cuaresmy i Doppelhofera⁷ oraz Próchniaka i Witkowskiego⁸.

Tradycyjny model β -konwergencji można zapisać w następującej postaci:

$$\ln\left(\frac{PKB_{iT}}{PKB_{i0}}\right) = \beta_0 + \beta \ln(PKB_{i0}) + \delta^T X_i + \varepsilon_i.$$

Aby zajście procesu konwergencji mogło zostać stwierdzone, parametr β w powyższym modelu powinien być ujemny i statystycznie istotny. Wynika to z faktu, że w trakcie procesu dostosowawczego, prowadzącego do osiągnięcia przez gospodarkę poziomu zrównoważonego rozwoju, szybkość wzrostu jest ujemnie zależna od początkowego poziomu PKB *per capita*. Powoduje to, że kraje (regiony) biedniejsze będzie charakteryzował szybszy rozwój niż kraje bogatsze.

W niniejszej pracy zostały przedstawione różne modyfikacje modelu tradycyjnego oraz odpowiednie podejścia do estymacji rozważanych modeli. Istotnym założeniem upraszczającym, ale niezmnieszającym ogólności rozważań, jest pominięcie dodatkowych zmiennych objaśniających charakteryzujących poszczególne gospodarki i uzależnienie wartości PKB tylko od wartości wcześniejszych.

³ K. Gawlikowska-Hueckel, *Konwergencja regionalna w Unii Europejskiej*, „Gospodarka Narodowa” 2002, nr 10, s. 91–113.

⁴ P. Wójcik, *Konwergencja regionów Polski w latach 1990–2001*, „Gospodarka Narodowa” 2004, nr 11–12, s. 69–86.

⁵ M. Próchniak, *Analiza zbieżności wzrostu gospodarczego województw w latach 1995–2000*, „Gospodarka Narodowa” 2004, nr 3, s. 27–44.

⁶ U. Markowska-Przybyła, *Konwergencja regionalna w Polsce w latach 1999–2007*, „Gospodarka Narodowa” 2010, nr 11–12, s. 85–110.

⁷ J.C. Cuaresma, G. Doppelhofer, *Nonlinearities in cross-country growth regressions: A Bayesian averaging of thresholds (BAT) approach*, „Journal of Macroeconomics” 2007, vol. 29, issue 3, s. 541–554.

⁸ M. Próchniak, B. Witkowski, *Time stability of the beta convergence among EU countries: Bayesian model averaging perspective*, „Economic Modelling” 2013, vol. 30, s. 322–333.

3. Respecyfikacje modelu tradycyjnego i metody estymacji

- Model tradycyjny uwzględniający powiązania przestrzenne.

Pierwszą w niniejszym opracowaniu modyfikacją modelu β -konwergencji jest uwzględnienie powiązań przestrzennych między regionami. Włączenie do modelu powiązań przestrzennych umożliwia uwzględnienie wpływu, jaki na wzrost rozwoju badanego regionu ma wzrost rozwoju regionów sąsiednich. Jest to możliwe poprzez wykorzystanie odpowiedniej macierzy sąsiedztwa. Macierz taka definiuje strukturę przestrzenną sąsiedztwa⁹. Najczęściej w analizach stosuje się macierz pierwszego rzędu, uwzględniającą tylko sąsiedztwo poprzez wspólną granicę, standaryzowaną rzędami do jedności¹⁰ w postaci:

$$\mathbf{W} = [w_{ij}]_{N \times N},$$

gdzie: w_{ij} – wagi kwantyfikujące powiązania między i -tą oraz j -tą jednostką przestrzenną, przy czym $[w_{ij}] = 0$, jeśli $i = j$ oraz $\sum_{j=1}^N w_{ij} = 1$ dla $i = 1, 2, \dots, N$. Wskazana modyfikacja jest uzasadniona również z tego względu, iż ignorowanie ważnych dla opisu wzrostu gospodarek powiązań przestrzennych skutkuje autokorelacją składnika losowego stosowanych regresji.

Model uwzględniający zależności przestrzenne określany jest w literaturze także mianem modelu opóźnienia przestrzennego (*spatial lag model*). Jest to wówczas model autoregresyjny w postaci:

$$y = \alpha + \beta X + \rho W y + u.$$

Model tego typu szacuje się metodą największej wiarygodności (MNW). Na etapie weryfikacji takiego modelu ważne jest to, czy parametr ρ jest istotny statystycznie.

W przekrojowych modelach regresji pomija się indywidualne cechy poszczególnych gospodarek, sprawiając, że stają się one częścią czynnika zakłócającego. Ponadto, stosowanie takich modeli napotyka często na trudności związane z małą liczbą obserwacji. Dlatego stosuje się inne podejścia, np. modele dla danych panelowych (podejście przekrojowo-czasowe).

⁹ K. Kopczevska, *Ekonometria i statystyka przestrzenna z wykorzystaniem programu R CRAN*, CeDeWu, Warszawa 2007, s. 55.

¹⁰ Ibidem, s. 56.

- Model pooled (model połączonych danych przekrojowo-czasowych).

Model ten zakłada estymację współczynników kierunkowych przy zmiennych objaśniających oraz stałej, ale nie uwzględnia efektów grupowych ani czasowych. Szacuje się go za pomocą KMNK. Stanowi on punkt odniesienia dla testowania istotności efektów stałych bądź losowych¹¹. Przyjmuje następującą ogólną postać:

$$y_{it} = \alpha + X_{it}'\beta + \varepsilon_{it}.$$

Główną zaletą zastosowania danych panelowych jest możliwość uwzględnienia w modelu efektów indywidualnych specyficznych dla każdej gospodarki oraz efektów okresowych wpływających na wszystkie gospodarki. Efekty takie trudno jest ująć w postaci konkretnych zmiennych ekonomicznych.

- Model ze sztucznymi zmiennymi (model efektów stałych, *fixed effects*, FE) – następuje dekompozycja wyrazu wolnego.

Modele z efektami stałymi stosuje się najczęściej do długich paneli. Różnice między badanymi jednostkami daje się uchwycić jako różnice w wyrazie wolnym.

- a) Model ze stałymi efektami grupowymi.

Efekty grupowe są to indywidualne charakterystyki poszczególnych jednostek badania (np. gospodarek). Nie podlegają one zmianom w czasie. Model panelowy uwzględniający stałe efekty grupowe można zapisać w postaci macierzowej:

$$y = \alpha i_{NT} + X\beta + u = Z\delta + u$$

$$u = Z_{\mu}\mu + v.$$

Po przyjęciu następujących założeń: μ – wektor nielosowych parametrów, v – wektor składników losowych o rozkładach $v_{it} : N(0, \sigma_v^2)$; $E(X_{it}, v_{it}) = 0$, otrzymuje się model:

$$y = Z\delta + Z_{\mu}\mu + v,$$

który można szacować za pomocą KMNK.

Otrzymany w ten sposób estymator nosi nazwę estymatora metody najmniejszych kwadratów ze sztucznymi zmiennymi (*Least Squares Dummy Variables* – LSDV) – $\tilde{\beta}_{LSDV}$.

¹¹ K. Koczczevska, T. Koczczewski, P. Wójcik, *Metody ilościowe w R. Aplikacje ekonomiczne i finansowe*, CeDeWu, Warszawa 2009, s. 309–310.

b) Model ze stałymi efektami czasowymi.

Efekty czasowe są to efekty, które pozostają stałe dla wszystkich jednostek badania w danym okresie. Odzwierciedlają one wydarzenia w gospodarce światowej, które wpływają jednocześnie na każdą badaną jednostkę (kraj, region).

Model panelowy uwzględniający stałe efekty czasowe można zapisać w postaci:

$$y = \alpha i_{NT} + X\beta + u = Z\delta + u$$

$$u = Z_\lambda \lambda + v.$$

Przy przyjęciu takich samych założeń jak w poprzedniej metodzie (λ jest wektorem nielosowych parametrów) model

$$y = Z\delta + Z_\lambda \lambda + v$$

można estymować metodą KMNK za pomocą estymatora $\tilde{\beta}_{LSVD}$.

- Model z efektami losowymi (model efektów zmiennych, model ze składnikami błędu, model RE) – następuje dekompozycja składnika losowego.

W tym wypadku zakłada się, że efekty grupowe (czasowe) są zmiennymi losowymi. Możliwe są więc uogólnienia wniosku na całą populację.

a) Model z losowymi efektami grupowymi.

Model panelowy, w którym uwzględnione są losowe efekty grupowe, można zapisać w postaci:

$$y = \alpha i_{NT} + X\beta + u = Z\delta + u$$

$$u = Z_\mu \mu + v,$$

przy założeniach: μ i v są niezależne; μ i v są wektorami zmiennych losowych o rozkładach $\mu_{it} : N(0, \sigma_\mu^2)$ i $v_{it} : N(0, \sigma_v^2)$; X_{it} są niezależne od μ_{it} i v_{it} .

Tak zdefiniowany model estymuje się metodą UMNK za pomocą estymatora $\tilde{\beta}_{UMNK}$.

b) Model z losowymi efektami czasowymi.

Model taki ma następującą postać:

$$y = \alpha i_{NT} + X\beta + u = Z\delta + u$$

$$u = Z_\lambda \lambda + v,$$

przy następujących założeniach: λ i ν są niezależne; λ i ν są wektorami zmiennych losowych o rozkładach $\lambda_{it} : N(0, \sigma_\lambda^2)$ i $\nu_{it} : N(0, \sigma_\nu^2)$; X_{it} są niezależne od λ_{it} i ν_{it} .

Model z losowymi efektami czasowymi estymuje się metodą UMNK za pomocą estymatora $\tilde{\beta}_{UMNK}$.

W praktyce może pojawić się problem dotyczący wyboru pomiędzy modelem FE a RE. Wyboru można dokonać np. w zależności od relacji między liczbą obiektów i liczbą okresów. Istotną modyfikacją wskazanych wyżej modeli dla danych panelowych (pooled, FE i RE) jest wprowadzenie do nich zależności przestrzennych opisywanych za pomocą macierzy \mathbf{W} (macierz sąsiedztwa). W ten sposób uzyskuje się tzw. przestrzenne modele panelowe. Modele takie mogą być estymowane m.in. za pomocą metody największej wiarygodności (MNW) bądź uogólnionej metody momentów (GMM)¹².

Podane wcześniej metody estymacji na podstawie danych panelowych są metodami tradycyjnymi, odpowiednimi dla tzw. modeli statycznych. Jednak to, że hipoteza β -konwergencji ma charakter dynamiczny, powoduje, że stosowanie estymatorów opartych na KMNK i UMNK daje obciążone oceny parametrów. Estymacja dynamicznych modeli wzrostu wymaga użycia odpowiednich metod, ze względu na występowanie następujących problemów¹³: nierealistycznego założenia, że efekty dotyczące danego obiektu lub danego okresu nie są skorelowane ze zmiennymi objaśniającymi w modelu wzrostu, oraz faktu, że przynajmniej część zmiennych objaśniających ma charakter endogeniczny.

Aby uniknąć powyższych problemów, należy zastosować specjalne metody modelowania dynamicznych danych panelowych. Do metod takich należy uogólniona metoda momentów (*General Moments Method* – GMM).

- Uogólniona metoda momentów (GMM) – Caselli, Esquivel i Lefort jako pierwsi wykorzystali tę metodę do modelowania wzrostu na podstawie dynamicznych danych panelowych.

Ogólny zarys stosowania uogólnionej metody momentów przedstawia się następująco (metoda Arellano i Bond – 1991):

1. Zapisanie równania regresji wzrostu w postaci dynamicznej (ze zmienną opóźnioną).

¹² *Ekonometria przestrzenna II. Modele zaawansowane*, red. B. Suhecki, C.H. Beck, Warszawa 2012, s. 109.

¹³ F. Caselli, G. Esquivel, F. Lefort, *Reopening the Convergence Debate: A New Look At Cross-Country Growth Empirics*, „Journal of Economic Growth” 1996, vol. 1, s. 363–389.

2. Wyznaczenie różnic Δ w celu eliminacji efektów indywidualnych dla poszczególnych obiektów. Jeżeli dla okresu t model ma postać:

$$y_{it} = \alpha + (1 - \beta)y_{i,t-1} + \mu_i + v_{it}$$

oraz dla okresu $t - 1$:

$$y_{i,t-1} = \alpha + (1 - \beta)y_{i,t-2} + \mu_i + v_{i,t-1},$$

model można zapisać w postaci pierwszych różnic:

$$\Delta y_{it} = (1 - \beta)\Delta y_{i,t-1} + \Delta v_{it}.$$

W modelu opartym na pierwszych różnicach nie występują efekty indywidualne. Spełnienie założenia o braku korelacji między zmienną objaśniającą a efektami indywidualnymi przestaje być wymagane.

3. Zastosowanie w równaniu zmiennych instrumentów w celu wyeliminowania endogeniczności zmiennych. Powoduje to wyeliminowanie niezgodności estymatora. Dobrym instrumentem jest zmienna skorelowana ze zmienną, dla której potrzebny jest instrument, ale nie jest skorelowana ze składnikiem losowym szacowanego równania. Zazwyczaj wartości opóźnione zmiennych objaśniających są dobrymi kandydatami na instrumenty.

W pewnych przypadkach estymator GMM pierwszych różnic może okazać się estymatorem obciążonym. Ma to miejsce wtedy, kiedy wybrane instrumenty są słabe, czyli są słabo skorelowane ze zmienną objaśniającą¹⁴. Sytuacja taka występuje np. wówczas, gdy liczba obserwacji w czasie jest mała. Wykorzystywane są wtedy szeregi czasowe o wysokim stopniu trwałości. Powoduje to obciążenie ocen parametrów modelu w dół. Szczególnie duże obciążenie ma miejsce wówczas, gdy instrumentami są tylko opóźnione wartości zmiennej objaśnianej, a pominięte są dodatkowe zmienne objaśniające.

Kolejnym podejściem, eliminującym problem wysokiego stopnia trwałości szeregów czasowych, jest rozwinięcie GMM, nazywane systemową uogólnioną metodą momentów.

¹⁴ S. Bond, A. Hoeffler, J. Temple, *GMM Estimation of Empirical Growth Models*, 2001, s. 23.

- Systemowa uogólniona metoda momentów (SGMM).

Główną ideą systemowego estymatora GMM jest estymacja następującego układu równań: T-2 równań pierwszych różnic i T-2 równań w poziomach. Przy zastosowaniu równań w poziomach w modelu zostają zachowane efekty indywidualne (grupowe). Powoduje to, że niezbędne są dodatkowe restrykcje. Według Blundella i Bonda¹⁵, jest to:

$$E(\mu_i \Delta y_{i2}) = 0 \text{ dla } i = 1, \dots, N.$$

Poniżej zostały zaprezentowane empiryczne modele β -konwergencji obejmujące różne specyfikacje modelu tradycyjnego. Modele te zostały oszacowane i zweryfikowane przy wykorzystaniu odpowiednich metod.

4. Dane

Badaniem objęto 40 regionów klasyfikacji NUTS 2 ośmiu krajów Unii Europejskiej: Czech, Estonii, Węgier, Łotwy, Litwy, Polski, Słowacji i Słowenii w latach 1995–2009 (dane roczne). W tym okresie kraje te przechodziły zmiany ustrojowo-gospodarcze, starały się o członkostwo w Unii oraz wszystkie otrzymały je w 2004 r. Dane wykorzystane w badaniu dotyczą PKB *per capita* i pochodzą z bazy Eurostatu oraz stron urzędów statystycznych poszczególnych państw.

5. Wyniki empiryczne

- Model tradycyjny:

$$\ln\left(\frac{PKB_{it}}{PKB_{i0}}\right) = \beta_0 + \beta \ln(PKB_{i0}) + \varepsilon_i \cdot$$

¹⁵ R. Blundell, S. Bond, *Initial conditions and moment restrictions in dynamic panel data models*, „Journal of Econometrics” 1998, vol. 87, s. 115–143.

Tabela 1. Wyniki estymacji i weryfikacji modelu tradycyjnego

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr (> z)
β_0	2.5350	0.7175	3.533	0.0011
β	-0.1783	0.0895	-1.992	0.0536
S ² (e): 0.2315				
R ² : 0.09454				
Statystyka F: 3.967, <i>p</i> -value: 0.05361				
Autokorelacja reszt Test Morana: 3.2602, <i>p</i> -value: 0.0005566				

Główną niedoskonałością prezentowanego modelu empirycznego jest autokorelacja reszt. Dlatego wnioskowanie na temat istnienia konwergencji na podstawie oszacowanego parametru β nie jest wiarygodne. Przyczyną występowania autokorelacji może być uwzględnienie w modelu jedynie jednej zmiennej objaśniającej, bez wzięcia pod uwagę wielu istotnych czynników (w tym specyficznych) determinujących wzrost regionów, przede wszystkim zaś powiązań przestrzennych między regionami w zakresie wzrostu gospodarczego.

- Model tradycyjny rozszerzony o zależności przestrzenne:

$$\ln\left(\frac{PKB_{iT}}{PKB_{i0}}\right) = \beta_0 + \beta \ln(PKB_{i0}) + \rho \mathbf{W} \ln\left(\frac{PKB_{iT}}{PKB_{i0}}\right) + \varepsilon_i$$

Tabela 2. Wyniki estymacji i weryfikacji przestrzennego modelu autoregresyjnego

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
β_0	0.908755	0.612167	1.4845	0.1377
β	-0.059492	0.071643	-0.8304	0.4063
$\rho = 0.60913$ test LR: 11.774, <i>p</i> -value: 0.0006				
Statystyka Walda: 20.712, <i>p</i> -value: 0.0000 AIC: -9.3784 (AIC dla lm: 0.39546)				
Autokorelacja reszt Test LM: 0.081017, <i>p</i> -value: 0.77592 Test Morana: 0.3355, <i>p</i> -value: 0.3686				

Rozszerzenie modelu tradycyjnego o składnik uwzględniający powiązania przestrzenne poprawiło jakość modelu. Współczynnik konwergencji β wyraźnie stracił na istotności. Natomiast istotny statystycznie okazał się parametr au-

to regresji p . Można wobec tego wnioskować o silnej zależności tempa wzrostu PKB *per capita* w danym regionie od tempa wzrostu w regionach sąsiednich. Ponieważ w badanym okresie wszystkie kraje, których dotyczy przeprowadzona analiza, starały się o członkostwo w UE, a także przechodziły podobne transformacje ustrojowe, ta silna wzajemna zależność gospodarek wydaje się uzasadniona. Model nie wykazuje autokorelacji reszt.

- Model pooled:

$$\ln PKB_{it} = \beta_0 + (1 + \beta)\ln PKB_{i,t-1} + \varepsilon_{it}.$$

Tabela 3. Wyniki estymacji i weryfikacji modelu pooled

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
β_0	0.4091865	0.0606251	6.7495	0.0000
$(1 + \beta)$	0.9616259	0.0070355	136.6823	0.0000
β	-0.0058348			
R ² : 0.971				
Statystyka F: 18682.1, <i>p</i> -value: 0.0058348				

Wyniki estymacji modelu pooled są traktowane jako punkt odniesienia do zbadania istotności efektów stałych i losowych. Tabele 4 i 5 prezentują wyniki analizy, które pozwoliły na ocenę tego, czy dekompozycje wyrazu wolnego i błędów losowych są zasadne.

- Model FE efekty grupowe:

$$\ln PKB_{it} = \beta_i + (1 + \beta)\ln PKB_{i,t-1} + \varepsilon_{it}.$$

Tabela 4. Wyniki estymacji i weryfikacji modelu ze stałymi efektami grupowymi

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
$(1 + \beta)$	0.925477	0.009773	94.697	0.0000
β	-0.074523			
R ² : 0.94529				
Statystyka F: 8967.6, <i>p</i> -value: 0.0084214				
Test Breuscha–Godfrey’a na autokorelację reszt χ^2 : 321.7355, <i>p</i> -value: 0.0000				
Test F na istotność efektów: 1.2709, <i>p</i> -value: 0.1309				

Test F (test Walda) służy do badania tego, czy wprowadzenie zróżnicowanych wyrazów wolnych dla wszystkich obiektów daje dokładniejsze oszacowanie parametrów. Otrzymane wyniki testu nie dają podstaw do odrzucenia hipotezy zerowej, mówiącej, że wszystkie wyrazy wolne są równe. Zatem można wnioskować, iż badane regiony są do siebie podobne pod kątem specyfiki tempa wzrostu i nie wymagają w tym aspekcie różnicowania.

- Model FE efekty czasowe:

$$\ln PKB_{it} = \beta_t + (1 + \beta) \ln PKB_{i,t-1} + \varepsilon_{it}.$$

Tabela 5. Wyniki estymacji i weryfikacji modelu ze stałymi efektami czasowymi

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
(1 + β)	0.9891422	0.0060398	163.77	0.0000
β	-0.0108578			
R ² : 0.98008				
Statystyka F: 26820.5, p-value: 0.0048697				
Test Breuscha–Godfrey na autokorelację reszt χ ² : 70.5458, p-value: 0.0000				
Test F na istotność efektów: 69.6576, p-value: 0.0000				

W przypadku dekompozycji wyrazu wolnego na efekty czasowe test na istotność tych efektów daje podstawę do odrzucenia hipotezy zerowej na korzyść hipotezy alternatywnej, mówiącej o istotności efektów czasowych. Wynik taki można spróbować wyjaśnić, zwracając uwagę na kilka istotnych wydarzeń, które miały miejsce we wszystkich regionach w zbliżonych okresach, w czasie starania o akcesję do UE (a tym samym spełnienie określonych wymagań dotyczących rozwoju gospodarczego), następnie równoczesne wstąpienie wszystkich 8 krajów w tym samym roku do Wspólnoty, a w konsekwencji przyjęcie statusu beneficjentów unijnych środków pieniężnych.

Reasumując: z dwóch powyższych modeli model z efektami czasowymi charakteryzuje się lepszymi właściwościami.

W ramach przeprowadzonego badania zostały wyestymowane też modele z dekompozycją składnika losowego (modele RE): z losowymi efektami grupowanymi i losowymi efektami czasowymi. W celu dokonania wyboru pomiędzy modelami FE oraz RE zastosowano test Hausmana. Wynik χ²: 36.9566, p-value: 0.0000 oznacza, że model FE jest lepszy.

- Model przestrzenny pooled (MNW):

$$\ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) = \beta_0 + \beta \ln(PKB_{i,t-1}) + \rho \mathbf{W} \ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) + \varepsilon_{it}.$$

Tabela 6. Wyniki estymacji i weryfikacji przestrzennego modelu dla danych przekrojowo-czasowych

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
β_0	0.0399872	0.0264243	1.5133	0.1302
β	-0.0033509	0.0030479	-1.0994	0.2716
$\rho = 0.85819$ test LR: 772.73, <i>p</i> -value: 0.0000				
Statystyka Walda: 2256.2, <i>p</i> -value: 0.0000 AIC: -1915.2 (AIC dla lm: - 1144.5)				
Autokorelacja reszt Test LM: 54.268, <i>p</i> -value: 0.0000 Test Morana: -4.1996, <i>p</i> -value: 1				

Podobnie jak w przekrojowym modelu przestrzennym parametr β jest tutaj nieistotny statystycznie, a wartość i istotność parametru ρ zdaje się potwierdzać tezę, że tempo wzrostu każdego z badanych regionów jest związane z tempem wzrostu jego sąsiadów. Jednak istotną słabością rozważanego modelu jest autokorelacja reszt. Problem autokorelacji wynika z dynamicznego charakteru modelowanego zjawiska. Należy zatem zastosować taką metodę, która pozwala ów problem wyeliminować. Dwie kolejne specyfikacje modelu β -konwergencji są przestrzennym rozszerzeniem modeli typu FE oraz RE.

- Model przestrzenny z efektami grupowymi (MNW):

$$\ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) = \beta_0 + \beta_i + \beta \ln(PKB_{i,t-1}) + \rho \mathbf{W} \ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) + \varepsilon_{it}.$$

Tabela 7. Wyniki estymacji i weryfikacji przestrzennego modelu ze stałymi efektami grupowymi

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
β_0	0.13481130	0.03703351	3.6403	0.0003
β	-0.01303399	0.00428169	-3.0441	0.0023
$\rho = 0.85757$ test LR: 798.12, <i>p</i> -value: 0.0000				

Statystyka Walda: 2242.8, p -value: 0.0000 AIC: -1913.7 (AIC dla lm: - 1117.6)
Autokorelacja reszt Test LM: 58.939, p -value: 0.0000 Test Morana: -4.3781, p -value: 1

- Model przestrzenny z efektami czasowymi (MNW):

$$\ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) = \beta_0 + \beta_t + \beta \ln(PKB_{i,t-1}) + \rho \mathbf{W} \ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) + \varepsilon_{it}.$$

Tabela 8. Wyniki estymacji i weryfikacji przestrzennego modelu ze stałymi efektami czasowymi

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
β_0	-0.03467674	0.03956123	-0.8765	0.3807
β	-0.00039256	0.00421061	-0.0932	0.9257
$\rho = 0.69699$ test LR: 297.04, p -value: 0.0000				
Statystyka Walda: 521.84, p -value: 0.0000 AIC: -1961.7 (AIC dla lm: -1666.7)				
Autokorelacja reszt Test LM: 14.42, p -value: 0.0001 Test Morana: -1.4783, p -value: 0.9303				

W trzech powyżej przedstawionych modelach empirycznych występuje autokorelacja reszt. Jest to istotny problem związany z modelowaniem, oznaczający, że przeszłe wartości błędów mogą wpływać na wartości bieżące lub zmiany w jednej grupie mogą oddziaływać na inną grupę. W przypadku występowania autokorelacji reszt można zastosować kilka podejść. Jednym z nich jest zastosowanie uogólnionej metody momentów do dynamicznych danych panelowych¹⁶.

- GMM:

$$\ln PKB_{it} = \beta_0 + (1 + \beta) \ln PKB_{i,t-1} + \rho \mathbf{W} \ln\left(\frac{PKB_{it}}{PKB_{i,t-1}}\right) + \varepsilon_{it}.$$

Badanie właściwości modelu GMM opiera się na zbadaniu tego, czy instrumenty są właściwe, czyli nieskorelowane ze składnikami losowymi. W tym celu stosowany jest test Sargana, którego hipoteza zerowa mówi, że instrumenty

¹⁶ K. Kopczewska, T. Kopczewski, P. Wójcik, op.cit., s. 326.

zostały odpowiednio dobrane, a hipoteza alternatywna zakłada, że dobór instrumentów jest nieprawidłowy. Wynik tego testu dla rozważanego modelu (χ^2 : 316.512, p -value: 0.0000) daje podstawy do odrzucenia hipotezy zerowej i przyjęcia hipotezy o złym doborze instrumentów.

Kolejnym estymowanym modelem był jednostopniowy systemowy GMM. Dla tegoż modelu wyniki testu Sargana (χ^2 : 749.691, p -value: 0.0000) sugerowały odrzucenie hipotezy o prawidłowym doborze instrumentów. W związku z tym w przeprowadzonym badaniu wykorzystano dwustopniowy estymator systemowy GMM.

- *GMM-sys two-step* (dwustopniowa SGMM):

Tabela 9. Wyniki estymacji za pomocą dwustopniowej systemowej uogólnionej metody momentów

Parametr	Ocena parametru	Błąd standardowy	Statystyka z	Pr(> z)
β_0	0.00022	0.0048	0.0459	0.9634
(1 + β)	0.158452	0.0263844	6.0055	0.0000
β	-0.841548			
ρ	-0.92565			0.0001
$s^2(e)$: 0.695216				
Liczba instrumentów: 80				
Test AR(1) dla błędu z: -5.11262, p -value: 0.0000 Test AR(2) dla błędu z: -3.40984, p -value: 0.0007				
Test Sargana – nadmiernej identyfikacji χ^2 : 39.9595, p -value: 0.9998				
Test Walda χ^2 : 45.1988, p -value: 0.0000				

Test Sargana dla tego modelu nie daje podstaw do odrzucenia hipotezy zerowej. Oznacza to, że zastosowane instrumenty są odpowiednio dobrane. Oszacowany model wskazuje na występowanie zjawiska konwergencji gospodarczej na wyodrębnionym obszarze krajów w rozważanym okresie. Jednocześnie wskazuje na fakt istotnego związku tempa wzrostu danego regionu z tempem wzrostu w regionach sąsiadujących.

6. Wnioski

Reasumując wyniki przeprowadzonej analizy, należy stwierdzić, że uwzględnienie w modelach konwergencji gospodarczej powiązań przestrzennych między

regionami poprawia jakość statystyczną modeli i interpretowalność uzyskanych na ich podstawie wyników. Ważną zaletą takiego podejścia jest to, iż szacunek parametru nie znajduje się wtedy pod wpływem pominięcia przestrzennych zależności.

Z drugiej strony, przy badaniu konwergencji należy uwzględnić jej dynamiczny charakter. W modelowaniu pojawiają się istotne problemy wynikające z takiego podejścia, głównie w postaci autokorelacji składnika losowego. Wykorzystanie GMM pozwala na wyeliminowanie tego typu problemów poprzez wprowadzenie dodatkowych restrykcji.

Bibliografia

1. Barro R.J., Sala-i-Martin X., *Public Finance in Models of Economic Growth*, C.E.P.R. Discussion Papers, 1992.
2. Blundell R., Bond S., *Initial conditions and moment restrictions in dynamic panel data models*, „Journal of Econometrics” 1998, vol. 87, s. 115–143.
3. Bode E., Rey S.J., *The spatial dimension of economic growth and convergence*, Papers in Regional Science, vol. 85, 2006.
4. Bond S., Hoeffler A., Temple J., *GMM estimation of empirical growth models*, September 12, 2001.
5. Caselli F., Esquivel G., Lefort F., *Reopening the convergence debate: a new look at cross-country growth empirics*, „Journal of Economic Growth” 1996, vol. 1, s. 363–389.
6. Ciołek D., *Badanie konwergencji krajów Europy Środkowo-Wschodniej z wykorzystaniem danych panelowych*, w: *Dynamiczne modele ekonometryczne*, Wydawnictwo Uniwersytetu Mikołaja Kopernika, Toruń 2003, s. 329–342.
7. Cuaresma J.C., Doppelhofer G., *Nonlinearities in cross-country growth regressions: A Bayesian averaging of thresholds (BAT) approach*, „Journal of Macroeconomics” 2007, vol. 29, issue 3, s. 541–554.
8. Dańska-Borsiak B., *Dynamiczne modele panelowe w badaniach ekonomicznych*, Wydawnictwo Uniwersytetu Łódzkiego, Łódź 2011.
9. Dańska-Borsiak B., *Przestrzenno-czasowe modelowanie zmian w działalności produkcyjnej w Polsce. Zastosowanie modeli panelowych*, w: *Dane panelowe i modelowanie wielowymiarowe w badaniach ekonomicznych*, red. B. Suchecki, Absolwent, Łódź 2000.
10. Dańska-Borsiak B., *Zastosowanie panelowych modeli dynamicznych w badaniach mikroekonomicznych i makroekonomicznych*, „Przegląd Statystyczny” 2009, z. 2, s. 27–41.

11. *Ekonometria przestrzenna II. Modele zaawansowane*, red. B. Suhecki, C.H. Beck, Warszawa 2012.
12. Elhorst J.P., *Spatial panel models* (w druku).
13. Gawlikowska-Hueckel K., *Konwergencja regionalna w Unii Europejskiej*, „Gospodarka Narodowa” 2002, nr 10, s. 91–113.
14. Kopczewska K., *Ekonometria i statystyka przestrzenna z wykorzystaniem programu R CRAN*, CeDeWu, Warszawa 2007.
15. Kopczewska K., Kopczewski T., Wójcik P., *Metody ilościowe w R. Aplikacje ekonomiczne i finansowe*, CeDeWu, Warszawa 2009.
16. Mankiw N.G., Romer D., Weil D.N., *A contribution to the empirics of economic growth*, „The Quarterly Journal of Economics” 1992, vol. 107, issue 2, s. 407–437.
17. Markowska-Przybyła U., *Konwergencja regionalna w Polsce w latach 1999–2007*, „Gospodarka Narodowa” 2010, nr 11–12, s. 85–110.
18. Próchniak M., *Analiza zbieżności wzrostu gospodarczego województw w latach 1995–2000*, „Gospodarka Narodowa” 2004, nr 3, s. 27–44.
19. Próchniak M., Witkowski B., *Time stability of the beta convergence among EU countries: Bayesian model averaging perspective*, „Economic Modelling” 2013, vol. 30, s. 322–333.
20. Wójcik P., *Konwergencja regionów Polski w latach 1990–2001*, „Gospodarka Narodowa” 2004, nr 11–12, s. 69–86.

* * *

Analysis of economic convergence among selected European regions in 1995–2009

The paper presents analysis of β -convergence in separated area of eight European countries in period 1995–2009. The aim of the paper is to present different approaches to estimating β -convergence. Under consideration will be taken models which include spatial dependence, fixed and random effects. Also attention will be paid to issue of dynamic in panel data.

Keywords: convergence, dynamic panel data model, fixed effects, general moments method, maximum likelihood method, panel data model, random effects, spatial panel data model, system general moments method

Zgodnie z deklaracją autorek, ich udział w przygotowaniu artykułu wynosi odpowiednio: Joanna Górna – 50%, Karolina Górna – 50%.