

*Dorota Ciołek*

Wydział Zarządzania  
Uniwersytet Gdański

*Tomasz Brodzicki*

Wydział Ekonomiczny  
Uniwersytet Gdański

# PRZESTRZENNY MODEL PANELOWY ZEWNĘTRZNYCH EFEKTÓW KLASTRÓW PRZEMYSŁOWYCH W POLSCE<sup>1</sup>

## 1. Wstęp

Koncepcja klastrów przemysłowych została wprowadzona do współczesnej ekonomii przez M. Portera<sup>2</sup>, który zaproponował definicję klastra jako „geograficzne skupisko wzajemnie powiązanych firm, wyspecjalizowanych dostawców, jednostek świadczących usługi, firm działających w pokrewnych sektorach i związanych z nimi instytucji (na przykład uniwersytetów, jednostek normalizacyjnych i stowarzyszeń branżowych) w poszczególnych dziedzinach, konkurujących między sobą,

---

<sup>1</sup> Artykuł jest wynikiem prac autorów w ramach projektu KBN 1649/B/H03/2010/38 – *Identyfikacja klastrów przemysłowych w Polsce. Próba oceny ich efektów ekonomicznych. Implikacje dla polityki rozwoju regionalnego*, kierowanego przez dr. T. Brodzickiego.1 M. Porter, *The competitive advantage of nations*, The Free Press, New York 1990.

<sup>2</sup> M. Porter, *The competitive advantage of nations*, The Free Press, New York 1990.

ale również współpracujących<sup>3</sup>. Funkcjonowanie tak zdefiniowanych formacji gospodarczych w konkretnej lokalizacji niesie ze sobą szereg wymiernych korzyści ekonomicznych dla danego obszaru. Omówienie potencjalnych korzyści zewnętrznych znaleźć można m.in. w pracach T. Brodzickiego i S. Szultki<sup>3</sup> oraz D. Ciołek<sup>4</sup>.

Jednym z istotnych aspektów istnienia i rozwoju klastrów w gospodarce jest ich znaczenie dla wzrostu gospodarczego danego regionu, a także poziomu PKB *per capita* w regionie. D. Ciołek<sup>5</sup> zaproponowała różne sposoby testowania istotności wpływu klastrów na rozwój i pozycję gospodarki regionalnej. W prezentowanym badaniu do identyfikacji efektów zewnętrznych wykorzystano metodę, która jest modyfikacją podejścia A. Rodrigeza-Posego i F. Comptoura<sup>6</sup>. Proponują oni, aby w modelu wyjaśniającym wzrost gospodarczy lub PKB *per capita* wykorzystać nie pojedyncze zmienne determinujące wzrost, ale wskaźniki syntetyczne reprezentujące potencjał gospodarki regionalnej oraz tendencję do stymulowania rozwoju formacji klastrowych. Analiza empiryczna przeprowadzona została dla 16 polskich województwach w latach 2003–2009.

W badaniach, w których dane panelowe są danymi przestrzenno-czasowymi, inaczej mówiąc – danymi zlokalizowanymi, możemy mieć do czynienia z dwoma istotnymi problemami. Pierwszy to możliwość wystąpienia przestrzennych zależności pomiędzy jednostkami badania, i to zachodzących w każdym momencie czasu. Fakt, że położenie geograficzne obiektów wobec innych jednostek ma znaczenie i że odległości pomiędzy nimi wpływają na siłę wzajemnego oddziaływania (zjawisko to jest określane mianem prawa W. Toblera<sup>7</sup>), przyczynił się do powstania ekonometrii przestrzennej. Co więcej, zależności przestrzenne nie muszą być stałe w czasie. A zatem drugim potencjalnym problem jest to, że szacowane parametry strukturalne w modelu nie muszą być stałe w przestrzeni i mogą przyjmować różne wartości w różnych lokalizacjach geograficznych. W niniejszym opracowaniu skupiamy się na modelach i metodach dedykowanych rozwiązaniu problemu pierwszego, czyli modelach ze stałymi parametrami strukturalnymi.

W pierwszej części prezentowanego artykułu zostały omówione różnego typu przestrzenne modele panelowe oraz właściwe w ich przypadku metody szacowania parametrów. Z kolei w części empirycznej zostały przedstawione i pokrótce omówione częściowe wyniki analizy, której celem była identyfikacja efektów zewnętrznych funkcjonowania klastrów przemysłowych w polskich województwach.

<sup>3</sup> T. Brodzicki, S. Szultka, *Koncepcja klastrów a konkurencyjność przedsiębiorstw*, „Organizacja i Kierowanie” 2002, nr 4 (110).

<sup>4</sup> D. Ciołek, *Metody identyfikacji efektów zewnętrznych klastrów przemysłowych*, „Prace i Materiały Wydziału Zarządzania Uniwersytetu Gdańskiego” 2011, nr 4/8, s. 307–318.

<sup>5</sup> Ibidem.

<sup>6</sup> A. Rodriguez-Pose, F. Comptour, *Do Clusters Generate Greater Innovation and Growth? An Analysis of European Regions*, IMDEA Working Papers in Economics and Social Scientists, Madrid 2010.

<sup>7</sup> W. Tobler, *A computer movie simulating urban growth in the Detroit region*, „Economic Geography” 1970, nr 46 (2), s. 234–240.

## 2. Przestrzenne modele panelowe

Załóżmy, że analizowane dane pochodzą z obserwacji zbioru  $N$  obiektów przestrzennych (krajów, województw, powiatów) przez  $T$  okresów czasu. Możemy wówczas zapisać następujący model panelowy:

$$x_{it}\beta + \mu_i + \varepsilon_{it} \quad i = 1, \dots, N \quad t = 1, \dots, T, \quad (1)$$

gdzie  $y_{it}$  jest obserwacją na zmiennej zależnej dla  $i$ -tego obiektu w okresie  $t$ ,  $x_{it}$  to  $K$ -elementowy wektor obserwacji na zmiennych objaśniających,  $\beta$  to wektor nieznanych stałych parametrów,  $\varepsilon_{it}$  to wektor zakłóceń czysto losowych z zerową wartością oczekiwaną i stałą wariancją  $\sigma^2$ ,  $\mu$  to efekty indywidualne, a w tym kontekście mogą być określone jako efekty przestrzenne – stałe lub losowe (*fixed* lub *random*). Tak zapisany model panelowy nie uwzględnia specyficznych właściwości obiektów zlokalizowanych, czyli tych, których położenie jest określone i nie zmienia się w czasie. Należy zwrócić uwagę na to, że w takim przypadku, podobnie jak w analizie szeregów czasowych, możemy spostrzec wzajemne oddziaływanie pomiędzy obserwacjami znajdującymi się obok siebie. Podczas gdy oddziaływanie w czasie może mieć tylko jeden kierunek (przeszłość wpływa na okres bieżący i przyszłość), dla danych przestrzennych oddziaływanie to może odbywać się we wszystkich kierunkach geograficznych. Ponadto, gdy dysponujemy danymi przestrzenno-czasowymi, musimy mieć na uwadze możliwość, że charakter tego oddziaływania może zmieniać się w czasie.

Zanim zostanie zdefiniowany przestrzenny model panelowy, należy określić położenie jednostek względem siebie. Podstawowymi narzędziami wykorzystywanymi do tego celu są różnie zdefiniowane macierze sąsiedztwa<sup>8</sup>. Sąsiedztwo może być określone np. w następujący sposób<sup>9</sup>:

- sąsiadami są jednostki posiadające wspólną granicę, tzw. macierz kontyngencji rzędu pierwszego,
- sąsiadami są jednostki, dla których odległość pomiędzy geometrycznymi środkami (lub stolicami krajów/regionów) nie przekracza określonej liczby kilometrów,
- za sąsiadów uważa się  $n$  najbliższych położonych jednostek, np. 10 najbliższych sąsiadów,
- sąsiadami są te jednostki, dla których sieć powiązań transportowych umożliwia pokonanie odległości pomiędzy stolicami regionów w określonym czasie,

<sup>8</sup> Dyskusję na temat warunków, jakie powinny spełniać macierze sąsiedztwa dla danych panelowych, można znaleźć w pracy: J. Elhorst, *Spatial panel data models*, w: *Handbook of applied spatial analysis*, red. M.M. Fischer, A. Getis, Springer, Berlin 2010.

<sup>9</sup> Pełen przegląd możliwych do wykorzystania macierzy sąsiedztwa można znaleźć w książkach: L. Anselin, *Spatial econometrics: Methods and models*, Kluwer, Dordrecht 1988; *Ekonometria przestrzenna: Metody i modele analizy danych przestrzennych*, red. B. Suchecki, Wydawnictwo C.H. Beck, Warszawa 2010.

- sąsiadami są jednostki, dla których określona zmienna ekonomiczna przyjmuje minimalne wartości (np. minimalna wielkość wymiany handlowej).

Dla tak określonego sąsiedztwa budowana jest symetryczna macierz o wymiarze  $N \times N$ , w której elementowi  $ij$  przypisywana jest wartość 1 wówczas, gdy obiekty  $i$ -ty i  $j$ -ty są uznawane za sąsiadów, i wartość 0, jeżeli obiekty nie są sąsiadami. Zakłada się również, że dana jednostka nie jest swoim własnym sąsiadem, a zatem elementy na głównej przekątnej równe są 0. Najczęściej taka macierz poddawana jest tzw. standaryzacji wierszami, czyli doprowadzana jest do postaci, w której suma elementów w każdym wierszu jest równa 1. W ten sposób uzyskuje się macierz wag  $W$ , określającą charakter powiązań pomiędzy analizowanymi jednostkami.

Innym sposobem określania położenia obiektów względem siebie jest wykorzystanie odległości geograficznych lub transportowych. Wówczas elementami macierzy wag  $W$  są najczęściej odwrotności odległości pomiędzy jednostkami. Oznacza to, że żaden z elementów takiej macierzy nie jest równy 0<sup>10</sup>.

Przy danych przestrzenno-czasowych, gdy obserwujemy jednostki w różnych okresach czasu, ważne jest rozważenie tego, że charakter powiązań pomiędzy nimi może zmieniać się w czasie. Oczywiście takie charakterystyki jak odległość geograficzna czy wspólna granica są niezmiennie, ale już czas potrzebny do pokonania odległości pomiędzy np. stolicami regionów czy też wartości zmiennych ekonomicznych, które można wykorzystać do zdefiniowania powiązań, zmieniają się w czasie. W przestrzennych modelach panelowych macierz wag  $W$  jest macierzą blokowo-diagonalną o wymiarze  $NT \times NT$ . Jeżeli prawdziwe jest założenie o niezmienności w czasie powiązań pomiędzy jednostkami, wówczas panelowa macierz wag to  $(I_T \otimes W)$ . Natomiast jeżeli macierz  $W$  zmienia się w czasie, to bloki na diagonalu panelowej macierzy wag są różne.

Mając określony, przy pomocy macierzy  $W$ , charakter powiązań pomiędzy obserwacjami przestrzennymi, można zdefiniować następujący, najbardziej ogólny panelowy model przestrzenny<sup>11</sup>:

$$y_{it} = \lambda W_1 y_{it} + x_{it} \beta + \mu_i + u_{it} \quad u_{it} = \rho W_2 u_{it} + \varepsilon_{it}, \quad (2)$$

gdzie macierze  $W_1$  i  $W_2$  są macierzami wag reprezentującymi powiązania pomiędzy jednostkami o wymiarach  $NT \times NT$ ,  $\lambda$  jest współczynnikiem autoregresji przestrzennej,  $\rho$  to współczynnik przestrzennej autokorelacji zakłóceń losowych. Zdefiniowanie dwóch różnych macierzy  $W$  oznacza, że zakładamy fakt, iż autoregresja może zachodzić w inny sposób niż przestrzenna autokorelacja zakłóceń. W praktyce

<sup>10</sup> Wykorzystanie takiej macierzy byłoby zgodne z pierwszym prawem ekonometrii przestrzennej Toblera, które mówi: „Wszystko jest powiązane ze sobą, ale bliższe obiekty są bardziej zależne od siebie niż odległe”.

<sup>11</sup> J. Elhorst, *Specification and estimation of spatial panel data models*, „International Regional Science Review” 2003, no. 26 (3), s. 244–268.

jednak najczęściej stosuje się tę samą macierz wag w obu komponentach modelu. Jeżeli chodzi o zakłócenia losowe  $\varepsilon_{it}$ , to w ogólności nie muszą charakteryzować się sferycznością.

Model (2) w literaturze jest określany mianem panelowego modelu przestrzennej autoregresji z przestrzenną autokorelacją zakłóceń SARAR (1,1) (*Panel Spatial Autoregressive and Spatially Autocorrelated Model*). Szczególnymi przypadkami takiego modelu są panelowy model SAR (*Panel Spatial Autoregressive Model*), w którym parametr  $\rho = 0$ :

$$y_{it} = \lambda W y_{it} + x_{it} \beta + \mu_i + \varepsilon_{it} \quad \varepsilon_{it} \sim N(0, \sigma^2 I), \quad (3)$$

oraz panelowy model SEM (*Panel Spatial Error Model*), gdzie  $\lambda = 0$ :

$$y_{it} = x_{it} \beta + \mu_i + u_{it} \quad u_{it} = \rho W u_{it} + \varepsilon_{it} \quad (4)$$

$$\varepsilon_{it} \sim N(0, \sigma^2 I).$$

Według L. Anselina<sup>12</sup>, specyfikacja modelu postaci (4) niekoniecznie musi wynikać z teoretycznych założeń dla badanej zależności i zachodzących tam interakcji, a może być szczególnym przypadkiem niesferycznej macierzy wariancji i kowariancji zakłóceń.

W przypadku modeli (2), (3) i (4) warunek stacjonarności wymaga, aby wartości parametrów  $\lambda$  i  $\rho$  należały do następujących przedziałów:  $1/\omega_{\min} < \lambda < 1/\omega_{\max}$  oraz  $1/\omega_{\min} < \sigma < 1/\omega_{\max}$ , gdzie  $\omega_{\min}$  i  $\omega_{\max}$  oznaczają odpowiednio najmniejszy i największy pierwiastek charakterystyczny macierzy wag  $W$ . Dzięki temu oszacowane wartości obu współczynników  $\lambda$  i  $\rho$  należą do przedziału  $< -1, +1 >$ . Należy zaznaczyć, że zastosowanie macierzy  $W$  standaryzowanej wierszami pozwala na spełnienie takiego założenia.

Uwzględnianie w modelu panelowym elementów przestrzennych znacząco wpływa na sposób estymacji tego modelu. I tak np. w przypadku przestrzennego modelu panelowego z efektami ustalonymi (*SFE*) trzeba wziąć pod uwagę przynajmniej dwie kwestie. Po pierwsze, endogeniczność  $W y_{it}$ , czyli  $E(W y_{it} \varepsilon_{it}) \neq 0$ , która w standardowej regresji oznacza obciążenie estymatora. Po drugie, przestrzenna zależność pomiędzy obserwacjami w każdym momencie czasu może wpływać na estymację ustalonych efektów indywidualnych i okresowych.

W celu rozwiązania problemu endogeniczności do estymacji parametrów modeli wykorzystywana jest metoda największej wiarygodności (MNW). Dla modelu (3),

<sup>12</sup> L. Anselin, J. Le Gallo, H. Jayet, *Spatial panel econometrics*, w: *The econometrics of panel data, fundamentals and recent developments in theory and practice*, red. L. Matyas, P. Sevestre, Kluwer, Dordrecht 2006, s. 901–969.

czyli panelowego SAR, przy założeniu ustalonych efektów indywidualnych (*oneway FE*), otrzymujemy następujący logarytm funkcji wiarygodności<sup>13</sup>:

$$\begin{aligned} \text{Log}L = & -\frac{NT}{2} \log(2\pi\sigma^2) + T \log|I_N - \lambda W| + \\ & -\frac{1}{2\sigma^2} \sum_{i=1}^N \sum_{t=1}^T (y_{it} - \lambda W y_{it} - x_{it}\beta - \mu_i)^2. \end{aligned} \quad (5)$$

Przyrównujemy pochodne cząstkowe z formuły (5) po  $\mu_i$  do 0:

$$\frac{\partial \text{Log}L}{\partial \mu_i} = \frac{1}{\sigma^2} \sum_{t=1}^T (y_{it} - \lambda W y_{it} - x_{it}\beta - \mu_i) = 0, \quad i = 1, \dots, N. \quad (6)$$

A po rozwiązaniu układu równań (6) względem  $\mu_i$  otrzymujemy:

$$\mu_i = \frac{1}{T} \sum_{t=1}^T (y_{it} - \lambda W y_{it} - x_{it}\beta), \quad i = 1, \dots, N. \quad (7)$$

Oznacza to, że nawet w przypadku najprostszego przestrzennego modelu panelowego, jakim jest panelowy model SAR, estymacja jakichkolwiek parametrów powinna uwzględniać charakter powiązań przestrzennych. L. Anselin i S. Hudak<sup>14</sup> wyjaśniają szczegółowo to, jak parametry  $\beta$ ,  $\lambda$  i  $\sigma^2$  mogą być szacowane przy pomocy MNW w przekrojowym modelu SAR. W przypadku modeli panelowych różnica polega na tym, że mamy do czynienia nie z  $N$ , a z  $NT$  liczbą obserwacji.

Wprowadzenie estymatorów dla panelowych modeli SAR i SEM można znaleźć w pracy J. Elhorsta<sup>15</sup>. Na przykład dla modelu FE SAR estymator MNW parametrów  $\beta$  przedstawia się następująco:

$$\hat{\beta} = (X' X)^{-1} X' [Y - \lambda(I_T \otimes W)Y], \quad (8)$$

gdzie  $Y$  jest  $NT$ -elementowym wektorem kolumnowym, a  $X$  macierzą obserwacji na zmiennych niezależnych o wymiarze  $(K \times NT)$ . Wówczas wariancja resztowa wyznaczana jest jako:

$$\hat{\sigma}^2 = \frac{1}{NT} (e_0 - \lambda e_1)' (e_0 - \lambda e_1), \quad (9)$$

gdzie  $e_0$  i  $e_1$  oznaczają odpowiednio: reszty z oszacowania MNK regresji  $Y$  względem zmiennych  $X$  oraz reszty z oszacowania MNK regresji  $(I_T \otimes W)Y$  względem

<sup>13</sup> L. Anselin, op.cit.

<sup>14</sup> L. Anselin, S. Hudak, *Spatial econometrics in practice: A review of software options*, „Regional Science and Urban Economics” 1992, no. 22, s. 509–536.

<sup>15</sup> J. Elhorst, *Spatial panel data models*, <http://www.reg Groningen.nl/elhorst/doc/Spatial%20Panel%20Data%20Models.pdf>.

zmiennych  $X$ . W pracy J. Elhorsta można również znaleźć wzory na asymptotyczną macierz wariancji i kowariancji parametrów, a także formuły wyznaczania estymatorów MNW dla innych modeli panelowych.

Kolejna istotna kwestia związana ze stosowaniem przestrzennych modeli panelowych to wykorzystanie testów właściwych dla tego typu modeli. Na przykład testem, który w modelach panelowych stanowi statystyczne narzędzie pozwalające na wybór pomiędzy efektami ustalonymi i losowymi, jest test Hausmana. Nie może on być bezpośrednio stosowany do modeli przestrzennych, dlatego L. Pace i J. LeSage<sup>16</sup> wyprowadzają formułę testu pozwalającą na zastosowanie go dla danych przestrzenno-czasowych.

### 3. Identyfikacja efektów klastrów przemysłowych przy pomocy przestrzennego modelu panelowego

Omówiona powyżej metodologia przestrzennych modeli panelowych została wykorzystana w badaniu empirycznym, którego celem była identyfikacja zewnętrznych efektów klastrów przemysłowych w polskich województwach.

Badanie 16 polskich województw zostało przeprowadzone dla lat 2003–2009. Jako narzędzie do weryfikacji hipotezy o istotnym znaczeniu klastrów w regionach wykorzystano przestrzenny model panelowy, w którym zmienną objaśnianą był poziom realnego PKB *per capita* w regionie. Została również podjęta próba oszacowania modelu wyjaśniającego stopę wzrostu realnego PKB *per capita*, jednakże oceny wpływu wszystkich analizowanych zmiennych okazały się statystycznie nieistotne. Wyniki takie potwierdzają implikacje teorii wzrostu, zgodnie z którą identyfikacja determinant wzrostu gospodarczego powinna być prowadzona w długim okresie, a nie z roku na rok, jak w przypadku proponowanego modelu panelowego.

Analizy efektów zewnętrznych dokonano dzięki badaniu, którego celem była identyfikacja klastrów i ich rodzajów w poszczególnych województwach. Zostało przeprowadzone statystyczne mapowanie klastrów metodą optymalną do specyfiki polskich regionów, przy określonej dostępności danych statystycznych, z wykorzystaniem wiązek sektorów zaproponowanych przez M. Portera<sup>17</sup>.

Następnie obliczono 3 niezależne indeksy klasteryzacji oddające różne aspekty potencjalnego wpływu klastrów na gospodarkę województw: indeks specjalizacji (SQ), indeks zróżnicowania (DIV) oraz indeks wagi dla gospodarki regionu (SIGMA). Przyjęte miary są pokrewne miarom zastosowanym przez A. Rodrígueza-Posego

<sup>16</sup> R. Pace, J.P. LeSage, *A spatial Hausman test*, „Economics Letters” 2008, no. 101, s. 282–284.

<sup>17</sup> M. Porter, op.cit.

i F. Comptoura<sup>18</sup> do analizy wpływu procesów klasteryzacji na gospodarkę regionów poziomu NUTS2 państw Unii Europejskiej.

Indeks specjalizacji (*specialization quotient* – SQ) jest stosunkiem udziału zatrudnienia w klastrach w danym regionie do udziału zatrudnienia w klastrach w całej gospodarce polskiej.

$$SQ = \frac{\frac{E_{K,R}}{E_R}}{\frac{E_{K,PL}}{E_{PL}}} \quad (10)$$

Indeks pokazuje, o ile jest silniejsza specjalizacja (koncentracja) zatrudnienia w wiązkach klastrowych w danym regionie w stosunku do reszty kraju. Indeks SQ przyjmuje wartości nieujemne. Wartości SQ powyżej 1 wskazują na ponadprzeciętną specjalizację regionu na tle średniej dla kraju.

Kolejna miara to indeks zróżnicowania – odzwierciedla występowanie poszczególnych typów klastrów w regionach (w ujęciu podstawowym Porter wyróżnia 35 różnych wiązek klastrowych), oddając tym samym ogólny poziom dywersyfikacji klastrów. Indeks przyjmuje wartości od 0 do 100.

$$DIV_R = \frac{n_{K,R}}{N_K} \cdot 100 \quad (11)$$

Indeks znaczenia (SIGMA) oddaje znaczenie klastrów dla rynku pracy regionu – suma kwadratów udziałów poszczególnych wiązek klastrowych w rynku pracy regionu. Indeks sigma przyjmuje wartości od 0 do 10 000.

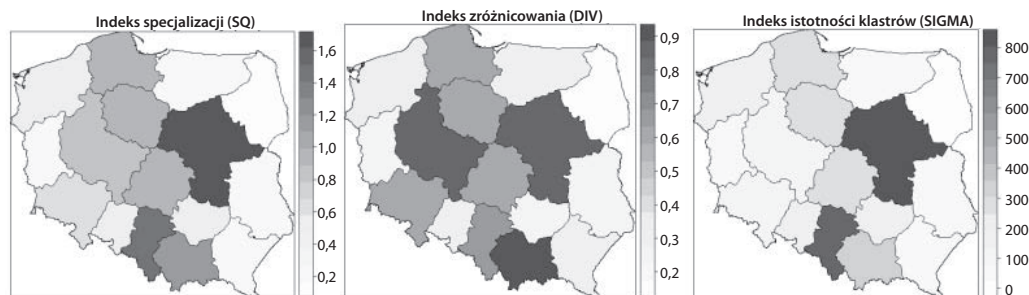
$$SIGMA = \sum_K^N \left( \frac{E_{W,K,R}}{E_R} \cdot 100 \right)^2 \quad (12)$$

Na rysunku 1 zaprezentowano zróżnicowanie poszczególnych indeksów w polskich województwach. Na podstawie 3 powyższych indeksów przy pomocy analizy głównych składowych<sup>19</sup> obliczono syntetyczny indeks klasteryzacji (**potencjał klasteryzacji** – *ClusFilter<sub>it</sub>*).

<sup>18</sup> A. Rodriguez-Pose, F. Comptour, op.cit.

<sup>19</sup> Metodologia budowy miar syntetycznych z wykorzystaniem analizy głównych składowych została opisana np. w: *Handbook on constructing composite indicators. Methodology and user guide*, OECD, 2008, s. 63–69.





**Rysunek 1. Indeksy klasteryzacji w polskich województwach w 2006 r.**

Źródło: opracowanie własne.

W kolejnym etapie ze zbioru wszystkich potencjalnych czynników mogących wyjaśniać zmiany PKB *per capita* wybrano kilka<sup>20</sup>, które posłużyły do budowy 2 dodatkowych wskaźników syntetycznych: potencjału społecznego i potencjału kapitału ludzkiego. Mierniki te powstały na bazie następujących zmiennych:

- **potencjał społeczny** ( $SocFilter_{it}$ ):
  - ◆ stopa bezrobocia długookresowego w regionie,
  - ◆ udział pracujących w rolnictwie w ogólnej liczbie pracujących w regionie,
  - ◆ stosunek liczby osób młodych (w wieku 15–24 lata) do ogólnej liczby ludności w regionie;
- **potencjał kapitału ludzkiego** ( $HCFilter_{it}$ ):
  - ◆ odsetek osób aktywnych zawodowo z wykształceniem wyższym,
  - ◆ odsetek osób w wieku 25–64 kształcących się ustawicznie,
  - ◆ liczba łóżek w szpitalach na 1000 mieszkańców.

Wszystkie 3 wskaźniki syntetyczne zostały skonstruowane w taki sposób, aby były stymulantami wzrostu PKB *per capita*.

Prawidłowa identyfikacja wpływu klasteryzacji gospodarki na jej poziom rozwoju powinna uwzględniać również ogólne siły aglomeracji występujące w obrębie poszczególnych województw. W przypadku Polski możemy mówić o występowaniu regionów metropolitalnych, zdominowanych przez silne ośrodki aglomeracyjne, oraz regionów niemetropolitalnych. Ogólna obserwacja procesów rozwojowych wskazuje, że rozwój gospodarczy jest procesem nierównomiernie zachodzącym w czasoprzestrzeni (przestrzenna koncentracja procesów rozwojowych w silnych ośrodkach aglomeracyjnych, występowanie opóźnień w fazach rozwoju między ośrodkami). W celu uwzględnienia oddziaływania sił aglomeracyjnych na procesy rozwojowe polskich województw w drugim etapie badania model poszerzono

<sup>20</sup> Wybór został podyktowany przede wszystkim dostępnością danych statystycznych oraz wynikami analizy głównych składowych.

o wykorzystywane w literaturze indeksy aglomeracji – logarytm z udziału populacji największego miasta i 3 największych ośrodków miejskich w całkowitej populacji województwa (indeksy A1, A2).

Ostatecznie empiryczny przestrzenny model panelowy przyjął następującą postać:

$$\ln PKBpc_{i,t} = \mu_i + \beta_1 Aglom_{it} + \beta_2 SocFilter_{i,t} + \beta_3 HCFilter_{i,t} + \beta_4 ClusFilter_{i,t} + \varepsilon_{i,t}, \quad (13)$$

gdzie  $i = 1, \dots, 16$ ;  $t = 1, \dots, 7$ ; a zmienna  $Aglom_{it}$  oznacza wybraną zmienną reprezentującą siłę aglomeracji.

Powyższy model oszacowano jako dwukierunkowy panelowy model przestrzenny z efektami ustalonymi – w pierwszym etapie jako model SAR postaci (model 1), w drugim jako model SEM postaci (model 2), a następnie jako zgodny z formułą (2) model SARAR (1,1) (modele 3, 4, 5). Macierzą wag, która została przyjęta w prezentowanym przykładzie, była macierz wag kontyngencji stopnia pierwszego. W każdym przypadku do estymacji wykorzystano MNW. Wybór modelu z efektami ustalonymi (FE) został dokonany na mocy przestrzennego testu Hausmana. Wyniki estymacji poszczególnych modeli zamieszczone zostały w tabeli 1.

W większości rozpatrywanych specyfikacji modelu parametr autoregresji  $\rho$  wskazuje na występowanie statystycznie istotnej i dodatniej autokorelacji przestrzennej zmiennej objaśnianej, czyli logarytmu realnego PKB *per capita*. W bazowej specyfikacji modelu wszystkie 3 grupy determinant-potencjałów mają statystycznie istotny i dodatni wpływ na poziom dobrobytu mierzonego poziomem realnego PKB *per capita* w polskich województwach. Dotyczy to, zgodnie z naszymi oczekiwaniami, zarówno potencjału społecznego, jak i potencjału kapitału ludzkiego. Zatem regiony o większych zasobach kapitału społecznego oraz kapitału ludzkiego osiągają wyższy poziom PKB *per capita*.

Występowanie klastrów przemysłowych w regionie, mierzone syntetycznym indeksem klasteryzacji, ma również statystycznie istotny i dodatni wpływ na poziom dobrobytu regionów. Ponadto, uwzględnienie ogółu procesów aglomeracyjnych zachodzących w województwach nie prowadzi do zaburzenia wpływu syntetycznego wskaźnika klasteryzacji gospodarki na poziom realnego PKB *per capita* województw.

Wprowadzenie efektów aglomeracyjnych poprzez logarytm z indeksów aglomeracji oddających koncentrację populacji regionu w jego największym ośrodku miejskim bądź w grupie największych ośrodków miejskich wskazuje na ich statystycznie istotny (na 5-procentowym poziomie) i dodatni wpływ.

**Tabela 1. Wyniki oszacowania przestrzennego modelu efektów zewnętrznych klastrów przemysłowych**

Zmienna objaśniana: $\ln PKB_{pc_{it}}$					
Model	(1)	(2)	(3)	(4)	(5)
Zmienna	SAR	SEM	SARAR	SARAR	SARAR
$\lambda$	0,0335 (0,7309)	–	0,3589 (0,0004)	0,3628 (0,0000)	0,3597 (0,0000)
$\rho$	–	–0,2064 (0,1429)	–0,6838 (0,0001)	–0,7765 (0,0000)	–0,7677 (0,0000)
<i>SocFilter</i>	0,0918 (0,0000)	0,0960 (0,0000)	0,1002 (0,0000)	0,0985 (0,0000)	0,0991 (0,0000)
<i>HCFilter</i>	0,0334 (0,0094)	0,0325 (0,0123)	0,0274 (0,0246)	0,0299 (0,0099)	0,0305 (0,0089)
<i>ClusFilter</i>	0,1164 (0,0000)	0,1155 (0,0000)	0,1159 (0,0000)	0,1130 (0,0000)	0,1124 (0,0000)
$\ln(Index\_A1)$	–	–	–	1,9093 (0,0015)	–
$\ln(Index\_A2)$	–	–	–	–	2,7922 (0,0016)

- 1) w nawiasach pod ocenami parametrów znajdują się wartości  $p$  testu istotności  $t$ -Studenta
  - 2) liczba obserwacji w każdym modelu równa była 112
  - 3) każdy z modeli był szacowany jako dwukierunkowy model panelowy z efektami ustalonymi
  - 4) metoda szacowania – metoda największej wiarygodności
- Źródło: obliczenia własne z wykorzystaniem pakietu *splm* R Cran.

## 4. Podsumowanie

W badaniach jednostek zlokalizowanych pominięcie aspektu przestrzennych powiązań pomiędzy jednostkami prowadzi do znaczącego obciążenia wyników estymacji, a co za tym idzie – wniosków ekonomicznych. Wykorzystywanie danych przestrzenno-czasowych w analizach ekonomicznych wymaga zastosowania zmodyfikowanych metod estymacji i testowania modeli ekonometrycznych. Na przykładzie modelu, którego celem było zbadanie istotności wpływu obecności i siły klastrów przemysłowych w województwie na poziom realnego PKB *per capita*, udało się zaobserwować istotne zależności przestrzenne pomiędzy regionami. Interakcje te mają charakter zarówno autoregresji przestrzennej logarytmu realnego PKB *per capita*, jak i przestrzennej autokorelacji zakłóceń losowych. Okazało się, że nie w każdym modelu można zaobserwować istotność tych zależności – tylko najbardziej ogólny model wykazał istotność obu kanałów oddziaływania.

Należy pamiętać również o tym, że – ze względu na endogeniczny charakter – przestrzenne zależności pomiędzy regionami powinny być uwzględniane również w estymacji wszystkich innych parametrów modelu. Stąd konieczność stosowania do estymacji odpowiednio skonstruowanej metody największej wiarygodności.

## Bibliografia

1. Anselin L., *Spatial econometrics: Methods and models*, Kluwer, Dordrecht 1988.
2. Anselin L., Hudak S., *Spatial econometrics in practice: A review of software options*, „Regional Science and Urban Economics” 1992, no. 22, s. 509–536.
3. Anselin L., Le Gallo J., Jayet H., *Spatial panel econometrics*, w: *The econometrics of panel data, fundamentals and recent developments in theory and practice*, red. L. Matyas, P. Sevestre, Kluwer, Dordrecht 2006, s. 901–969.
4. Baltagi B.H., Song S.H., Jung B., Koh W., *Testing panel data regression models with spatial and serial error correlation*, „Journal of Econometrics” 2007, no. 140, s. 5–51.
5. Brodzicki T., Szultka S., *Koncepcja klastrów a konkurencyjność przedsiębiorstw*, „Organizacja i Kierowanie” 2002, nr 4 (110), s. 45–59.
6. Ciołek D., *Metody identyfikacji efektów zewnętrznych klastrów przemysłowych*, „Prace i Materiały Wydziału Zarządzania Uniwersytetu Gdańskiego” 2011, nr 4/8, s. 307–318.
7. *Ekonometria przestrzenna. Metody i modele analizy danych przestrzennych*, red. B. Suchecki, Wydawnictwo C.H. Beck, Warszawa 2010.
8. Elhorst J.P., *Spatial panel data models*, w: *Handbook of applied spatial analysis*, red. M.M. Fischer, A. Getis, Springer, Berlin–Heidelberg–New York 2010, s. 377–407.
9. Elhorst J.P., *Specification and estimation of spatial panel data models*, „International Regional Science Review” 2003, no. 26 (3), s. 244–268.
10. *Handbook on constructing composite indicators. Methodology and user guide*, OECD, 2008.
11. Pace R.K., LeSage J.P., *A spatial Hausman test*, „Economics Letters” 2008, no. 101, s. 282–284.
12. Porter M.E., *The competitive advantage of nations*, The Free Press, New York 1990.
13. Rodriguez-Pose A., Comptour F., *Do Clusters Generate Greater Innovation and Growth? An Analysis of European Regions*, IMDEA Working Papers in Economics and Social Scientists, Madrid 2010.
14. Tobler W., *A computer movie simulating urban growth in the Detroit region*, „Economic Geography” 1970, no. 46 (2), s. 234–240.

## Summary

### Spatial panel data model of external effects of industrial clusters in Poland

The paper presents the research of external effects of industrial clusters in Polish regions. We implemented methodology of spatial panel data models. We described problems connected with using spatial panels and presented models with different structures of spatial dependence. We proposed composite index to measure existence and strength of clusters in regions. The estimation results presented in the empirical part of paper showed that clusters functioning in the region have significant positive influence on real GDP per capita in that region.

**Keywords:** spatial time series models, industrial clusters, regional economic activity

**JEL classification:** C23, R12, R11

Autorzy oświadczają, że ich udział w przygotowaniu artykułu wyniósł odpowiednio:  
D. Ciołek – 65%, T. Brodzicki – 35%.