Rozdział 4

IDENTYFIKACJA EFEKTÓW ZEWNĘTRZNYCH FUNKCJONOWANIA KLASTRÓW PRZEMYSŁOWYCH W POLSCE

Dorota Ciołek, Tomasz Brodzicki

4.1. Wprowadzenie

Liczne badania empiryczne wskazują, że podmioty ulokowane w efektywnie funkcjonującym klastrze charakteryzuje wyższa wydajność (wyższa produktywność) oraz wyższy stopień innowacyjności (Breschi 2007). Nie oznacza to jednak, że każdy podmiot w klastrze jest bardziej innowacyjny niż funkcjonujący poza klastrem – po prostu liczba innowacyjnych firm w klastrach jest wyższa (Beaudry i Breschi 2003). Innymi słowy, rozkład innowacyjności firm w klastrach (koncentracjach przemysłowych) przesunięty jest w prawo w stosunku do rozkładu obejmującego wszystkie podmioty gospodarcze funkcjonujące w danym sektorze – także poza koncentracjami. W dłuższym okresie przekłada się to oczywiście na ich większy potencjał konkurencyjny (Porter 1998) oraz percepcję konkurencyjności i atrakcyjności inwestycyjnej regionów, w których są zlokalizowane. Dzieje się tak pod warunkiem przekroczenia przez klaster pewnej masy krytycznej ilości podmiotów i wiążących je interakcji. Badanie Brusco i in. (1996) dla dystryktów przemysłowych włoskiego regionu Emilia-Romagna w odniesieniu do ogółu włoskiego przemysłu z wykorzystaniem metod panelowych pokazało, że firmy działające w klastrach wypadają lepiej na tle średniej w takich kategoriach, jak dochody pracowników (poziom wynagrodzeń), wielkość firmy (a tym samym jej produktywność) czy poziom eksportu (odzwierciedlenie konkurencyjności międzynarodowej).

Ponieważ korzyści z funkcjonowania klastra nie mogą być w pełni zinternalizowane przez funkcjonujące w nim podmioty, klastry generują korzyści zewnętrze, które mogą być istotne z perspektywy rozwoju regionów lokalizacji klastra. Co ciekawe, indywidualni przedsiębiorcy często nie są w pełni świadomi funkcjo-

nowania w klastrze i/lub związanych z tym korzyści dla swojego podmiotu gospodarczego. Te dodatkowe korzyści powodują, że klastry mogą potencjalnie odegrać kluczowe znaczenie w stymulowaniu rozwoju regionalnego. Korzyści z skali mikro przekładają się tym samym na poziomy mezo (sektora) i makro, nie ograniczają się wyłącznie do jednego sektora działalności gospodarczej.

Sugeruje się, że funkcjonowanie klastra w konkretnej lokalizacji niesie ze sobą szereg wymiernych korzyści ekonomicznych dla danego obszaru, czyli następujących potencjalnych efektów zewnętrznych (Brodzicki, Szultka 2002):

- wzrost produktywności lokalnych przedsiębiorstw (spowodowany dostępem do relatywnie tanich, wyspecjalizowanych czynników produkcji i różnorodnych nakładów wykorzystywanych w działalności produkcyjnej, a jednocześnie większą wzajemną konkurencją);
- wzrost innowacyjności stymulowany przestrzenną bliskością podmiotów gospodarczych (szybsza dyfuzja wiedzy i rozwiązań między innymi poprzez imitację i rotację pracowników);
- przyrost nowych miejsc pracy generowany przez dynamiczny wzrost liczby nowych przedsiębiorstw (szczególnie w fazach wzrostowej i ekspansji klastra);

oraz korzyści zewnętrznych mających znacznie dla całego regionu:

- wzrost dostępności specjalistycznych usług okołobiznesowych oraz wyspecjalizowanych poddostawców, które powstały na potrzeby uczestników klastra;
- inwestycje w specyficzną dla podmiotów klastra bądź ogólną infrastrukturę;
- zwiększenie dochodów ludności, które prowadzi do wzrostu popytu wewnętrznego, a przez to stymuluje rozwój rynku lokalnego;
- wzrost potencjału eksportowego – rozwój bazy eksportowej;
- poprawę wizerunku regionu – co może przełożyć się na wzrost atrakcyjności inwestycyjnej.

To właśnie możliwość wystąpienia efektów zewnętrznych działalności klastrów stała się jednym z głównym powodów zainteresowania tym tematem interesariuszy polityki gospodarczej. Trwałe podniesienie poziomu konkurencyjności przedsiębiorstw i ich innowacyjności na poziomie lokalnym, regionalnym, a także w skali całej gospodarki, powinno przyczynić się do przyśpieszenia wzrostu gospodarczego, a tym samym osiągnięcia wyższego poziomu rozwoju gospodarczego w dłuższej perspektywie czasowej.

Większość państw członkowskich OECD oraz niezależnie instytucje Unii Europejskiej prowadzą badania zmierzające do identyfikacji istniejących klastrów oraz poznania genezy ich powstania, determinant i uwarunkowań rozwoju (Cheshire, Malecki, 2004). Celem tych badań jest opracowanie właściwej polityki wspierania rozwoju klastrów na wszystkich szczeblach władzy – od lokalnego (w tym również w ramach gmin miejskich i aglomeracji), przez regionalny, centralny, aż po szczebel międzynarodowy.

Warto podkreślić, że w nowszych publikacjach Porter (2003) stwierdza, że jedynie klastry zorientowane proeksportowo są w stanie wpływać pozytywnie na rozwój regionów[1]. Nie każdy klaster, nie na każdym etapie swego cyklu życia może stać się siłą napędową rozwoju regionalnego.

Ponadto należy zwrócić uwagę, iż oceny realnej skali oddziaływania klastrów na rozwój regionów są rozbieżne (Asheim i in. 2008; Breschi i in. 2007). Również zdaniem Bliena i Maiera (2008) przełożenie klastrów na wzrost gospodarczy regionów jest niejednoznaczne. Z jednej strony występowanie klastra przekłada się na wyższy poziom produktywności podmiotów w nim uczestniczących, z drugiej strony może prowadzić do obniżenia tempa wzrostu zatrudnienia. Potwierdza to jeden z zasadniczych wniosków analiz empirycznych zakorzenionych w teoriach nowej geografii ekonomicznej, mówiący, że podmioty działające w miastach (efekty aglomeracji), przeciętnie rzecz biorąc, osiągają wyższy poziom produktywności. Zdaniem Tichy'ego (2001) potencjał oddziaływania klastra na rozwój regionu jego lokalizacji zależy od fazy rozwoju klastra oraz fazy rozwoju sektora (przemysłu), w którym on funkcjonuje.

W konkretnym regionie może funkcjonować więcej niż jeden klaster. Klastry mogą funkcjonować w symbiozie opartej o mutualizm bądź komensalizm zarówno o charakterze obligatoryjnym, jak i fakultatywnym. Mogą też występować między nimi zależności hierarchiczne (dominacja, podporządkowanie). Jednak dwa klastry mogą konkurować o te same zasoby – wtedy ich współwystępowanie może się wiązać z pojawieniem się negatywnych współzależności. Upraszczając rozważania, możemy stwierdzić, iż korzyści z funkcjonowania większej ilości klastrów mogą być znaczne – zachodzić mogą między nimi efekty synergiczne. Możemy tym samym mówić, na gruncie teoretycznym, o wpływie ogólnego poziomu „*klasteryzacji gospodarki*" na poziom jej rozwoju. Istotne znaczenie odgrywać mogą takie czynniki, jak: ilość funkcjonujących klastrów, ich zróżnicowanie branżowe i potencjalne interakcje (np. poprzez międzysektorowe rozlewanie się wiedzy w ramach pewnych trajektorii technologicznych), faza rozwoju (embrionalne, wzrostowe, dojrzałe, schyłkowe), głębokość i wielkość, udział w gospodarce regionu. Zależności te mogą mieć charakter nieliniowy – zgodnie z modelami NEG w pewnym momencie negatywne aspekty przestrzennej koncentracji (aglomeracji) mogą przeważyć nad jej pozytywnymi aspektami.

Mimo znacznego zainteresowania występowaniem efektów zewnętrznych klastrów i dużej liczby prac teoretycznych poświęconych temu tematowi, wciąż znajdujemy mało badań empirycznych, których celem jest wykazanie występowania takich efektów w praktyce (Brodzicki, Szultka, 2002). Większość analiz pro-

[1] W tym kontekście Porter (2003) zbliża się koncepcyjnie do modeli heterogenicznych firm charakterystycznych dla nowej nowej teorii handlu oraz nowej nowej geografii ekonomicznej Melitza (2003) czy Melitza i Ottaviano (2008), w której występują efekty selekcji oraz przestrzennego sortowania się firm na bazie poziomu produktywności.

wadzonych w tym kierunku to badania jakościowe, tzw. *case-studies*, czyli studia przypadków przykładowych, często najbardziej znanych systemów klastrowych. Również badania prowadzone przez *Observatory of European SMEs* w ramach *Regional Clusters in Europe* (2002), gdzie obok identyfikacji klastrów w poszczególnych krajach, zbadane zostało znaczenie funkcjonowania systemów klastrowych dla gospodarek lokalnych i całego kraju, nie odpowiadają na szereg istotnych pytań. Analiza jakościowa miała za zadanie jedynie odpowiedzieć na pytania: jaka część PKB wytwarzana jest w ramach klastrów i ile procent ogółu zatrudnionych to pracujący w przedsiębiorstwach należących do klastrów.

Innym przykładem studium przypadku jest badanie zaprezentowane przez McCanna i Aritę (2006), w którym omawia się funkcjonowanie czterech klastrów wysokich technologii typu hub&spoke związanych z firmami gigantami: Hitachi i Matsushita w Japonii oraz Motorola i Texas Instruments w USA. Również w związku z gwałtownym rozwojem gospodarki chińskiej powstaje coraz więcej prac poświęconych badaniu funkcjonowania i znaczenia klastrów w Państwie Środka. Na przykład Tan (2006) opisuje Pekiński Park Naukowy Zhongguancun, a Fan i Scott (2003) analizują przykłady klastrów w prowincjach przymorskich Chin.

Jednakże, pomimo iż w tych konkretnych przypadkach daje się zaobserwować, obok korzystnych efektów wewnętrznych, również efekty stymulujące innowacyjność, konkurencyjność, a w konsekwencji rozwój danego regionu, trudno założyć, że nie są to przypadki odosobnione oraz że jest to ogólna prawidłowość. Inaczej mówiąc, wciąż mało jest badań, które w metodologicznie poprawny sposób wykazują występowanie efektów zewnętrznych jako konsekwencje istnienia klastrów w danym regionie.

Główną przyczyną małej ilości badań empirycznych na ten temat są problemy z mierzeniem wzajemnych interakcji pomiędzy uczestnikami klastrów, np. dyfuzji wiedzy w postaci procesu wzajemnego uczenia się. Powoduje to na przykład problemy w zdefiniowaniu odpowiednich zmiennych, które mogłyby być wykorzystane w modelach empirycznych weryfikujących znaczenie klastrów dla gospodarki regionu. Rodriguez-Pose i Comptour (2010) sugerują, że istnieją przynajmniej dwa argumenty, dla których zastosowanie bardziej zaawansowanych analiz staje się możliwe i potrzebne. Pierwszy to fakt, że zainteresowanie tematem klastrów przemysłowych w ostatnich dziesięcioleciach doprowadziło do zgromadzenia znacznej liczby obserwacji dotyczących występowania, funkcjonowania i znaczenia systemów klastrowych. Informacje te mogą być wykorzystane w zaawansowanych modelach empirycznych. Drugim argumentem są wciąż toczące się dyskusje na ten temat zarówno pomiędzy teoretykami ekonomii, przedsiębiorcami, jak i politykami. Stąd potrzeba obiektywnego potwierdzenia lub zaprzeczenia występowania istotnych efektów zewnętrznych funkcjonowania klastrów przemysłowych.

Pomimo stosunkowo rozpowszechnionej argumentacji na gruncie teoretycznym przemawiającej za potencjalnie pozytywnym wpływem klastrów na rozwój regionów, za stosunkowo nieliczne uznać należy pogłębione analizy empiryczne wykorzystujące zaawansowane metody ilościowe. Rodriguez-Pose i Comptour (2010), analizując wpływ „klasteryzacji" gospodarki na rozwój gospodarczy regionów Unii Europejskiej poziomu NUTS2, pokazali, że ma ona znaczenie wtórne w stosunku do uwarunkowań instytucjonalno-społecznych poszczególnych regionów. Pierwsze wyniki badań uzyskane w bieżącym projekcie dla Polski z wykorzystaniem zmodyfikowanego podejścia Rodríguez-Posa i Comptoura dla Polski (Ciołek, Brodzicki 2012) są jednak obiecujące. Klastry wydają się generować pozytywne efekty zewnętrzne na tyle silne, aby oddziaływać na rozwój regionów.

Rosnące znaczenie klastrów w determinowaniu rozwoju regionów doprowadziły do wyłonienia się polityki opartej na klastrach[2]. Zasadniczym argumentem za jej wprowadzeniem jest występowanie efektów zewnętrznych korzystnych dla rozwoju regionu. W literaturze przedmiotu podkreśla się jednak, że potencjalne korzyści wynikające z funkcjonowania klastrów nie są dostatecznym uzasadnieniem do podejmowania interwencji publicznej na rzecz ich tworzenia czy rozwoju (Andersson 2004). Uzasadnienie interwencji publicznej powinno sięgać głębiej i bazować na trzech zasadniczych argumentach: niedoskonałości rynku, niedoskonałości polityki publicznej oraz niedoskonałości systemowej.

4.2. Modelowanie efektów zewnętrznych klastrów

Celem prezentowanego badania empirycznego jest identyfikacja efektów zewnętrznych funkcjonowania klastrów przemysłowych na różnych poziomach terytorialnych: województw, podregionów, a także powiatów. Chodzi zatem o określenie, czy obecność klastrów w danym regionie ma istotny wpływ na poziom PKB *per capita* i jego tempo wzrostu oraz czy wpływ ten jest dodatni, czy ujemny. Ciołek (2011) zaproponowała różne sposoby testowania istotności wpływu klastrów na rozwój i pozycję gospodarki regionalnej. W opisanym poniżej badaniu do identyfikacji efektów zewnętrznych wykorzystano metodę, która jest modyfikacją podejścia Rodrigeza-Pose i Comptoura (2010).

Jednym z istotnych aspektów występowania i rozwoju klastrów w gospodarce jest ich znaczenie dla poziomu rozwoju i wzrostu gospodarczego danego regionu, a co za tym idzie, ze względu na współzależności przestrzenne, rozwoju gospodarki krajowej. Z tego też względu identyfikacja efektów zewnętrznych klastrów może polegać na oszacowaniu regresji wyjaśniającej wzrost PKB *per capita*

[2] Polityce opartej na klastrach poświęcony jest rozdział 2 niniejszej monografii.

w regionie, w której obok klasycznych czynników wzrostu uwzględniane są również zmienne odzwierciedlające obecność i siłę klastrów. Podejście to opiera się na metodologii empirycznej weryfikacji procesu konwergencji rozwojowej zaproponowanej przez Baumola (1986), DeLonga (1988), a rozbudowanej przez Mankiwa i in. (1992) oraz Barro i Sala-i-Martina (1992). W przypadku badania wpływu obecności klastrów przemysłowych na gospodarkę lokalną, regresja ma charakter regionalny. Oznacza to, że dane wykorzystywane do szacowania dotyczą mniejszych jednostek terytorialnych, ale również czynniki objaśniające w regresji są zdefiniowane w taki sposób, by właściwie opisywały lokalną gospodarkę. Odpowiednio sformułowane regionalne regresje wzrostu zastosowano m.in. w pracach Rodrigez-Pose'a i Comptoura (2010) oraz Kubisa, Bracherta i Titze (2010).

Jak wspomniano wyżej, dotychczasowy brak kompleksowych empirycznych analiz efektów zewnętrznych klastrów w dużej mierze wynikał z problemów z właściwym zdefiniowaniem mierników mogących reprezentować specyfikę klastrów i zachodzących w nich procesów. W pracach Rodrigez-Pose'a i Crescenzi'a (2008) oraz Rodrigez-Pose'a i Comptoura (2010) zaproponowano wykorzystanie w regresji wzrostu wskaźników syntetycznych zbudowanych za pomocą Analizy Głównych Składowych (ang. *Principal Component Analysis* – PCA). Każdy z tych wskaźników ma za zadanie odzwierciedlać łączny wpływ grupy zmiennych reprezentujących pewną sferę uwarunkowań gospodarki lokalnej. Jednym z tych mierników może być również ogólny wskaźnik klasteryzacji, oddający równocześnie liczbę, zróżnicowanie i siłę klastrów w danym regionie. Podejście takie pozwala na znalezienie jedynie ogólnych prawidłowości, ale istotnie zmniejsza liczbę parametrów do oszacowania, co znacząco poprawia dokładność wyników estymacji.

4.2.1. Czynniki wzrostu gospodarczego w regionach

Ważnym etapem budowy regionalnej regresji wzrostu jest wybór odpowiednich zmiennych ekonomicznych objaśniających tempo i poziom rozwoju gospodarek regionalnych. Przy aktualnym stanie rozwoju teorii wzrostu gospodarczego oraz dostępie do danych statystycznych liczba zmiennych, które mogłyby być rozpatrywane jako potencjalne czynniki wzrostu, jest bardzo duża. Wybór odpowiednich czynników staje się trudny i w badaniach empirycznych wzrostu gospodarczego coraz częściej polega na zastosowaniu takich metod, jak np. Bayesowski Model Uśredniania (ang. *Bayesian Model Averaging* – BMA)[3]. Jednakże niektóre czynniki ekonomiczne uznawane są bezsprzecznie za kluczowe dla wzrostu gospodarczego zarówno na poziomie krajowym, jak i regionalnym.

[3] Dla danych regionalnych np. Cuaresma i in. (2009).

W neoklasycznej teorii wzrostu, począwszy od Kaldora (1961), za główną determinantę wzrostu uznawano akumulację kapitału fizycznego. Obecnie w ekonomii twierdzi się, że kapitał fizyczny może być głównym motorem wzrostu tylko w początkowym etapie rozwoju (zwłaszcza w fazie wczesnej industrializacji). Nowsze teorie, a zwłaszcza teorie endogenicznego wzrostu sugerują, że kluczowe znaczenie dla wzrostu gospodarczego we współczesnej gospodarce mają czynniki reprezentujące poziom kapitału ludzkiego i jego akumulację[4]. Odpowiedni poziom tego kapitału pozwala na powstawanie innowacji w danym regionie, ale również na lepszą adaptację technologii i wiedzy z zewnątrz. Znaczenie kapitału ludzkiego na poziomie gospodarek regionalnych badane było m.in. przez Brunow i Hirte, (2009) czy Fischer i in. (2009). Obok kapitału ludzkiego istotny jest również tzw. potencjał społeczny mający swoje odzwierciedlenie szczególnie na rynku pracy i w strukturze wiekowej społeczeństwa. Innymi znaczącymi determinantami wzrostu są wielkość i zaawansowanie sektora działalności badawczo-rozwojowej, który wpływa na ilość generowanych innowacji, oraz produktywność regionu. Przykłady takich badań na poziomie regionów można znaleźć np. u Sterlacchiniego (2008) czy Bronziniego i Piselli (2009).

Biorąc pod uwagę przytoczone teorie, jak również dostępność danych statystycznych i ograniczoną liczbę stopni swobody (pojemność modelu) ze zbioru wszystkich potencjalnych czynników mogących wyjaśniać zmiany PKB *per capita* w regionie, wybrano kilka[5], które posłużyły do budowy wskaźników syntetycznych odpowiadających trzem różnym procesom gospodarczym. Nazwane zostały one: potencjałem społecznym, potencjałem kapitału ludzkiego i potencjałem badawczo-rozwojowym. Mierniki te powstały na bazie następujących obserwowalnych zmiennych statystycznych[6]:

- **potencjał społeczny** (*SocFilter*)**:**
  - stopa bezrobocia długookresowego w regionie,
  - udział pracujących w rolnictwie w ogólnej liczbie pracujących w regionie,
  - stosunek liczby osób młodych (w wieku 15–24 lat) do ogólnej liczby ludności w regionie;
- **potencjał kapitału ludzkiego** (*HCFilter*):
  - odsetek osób aktywnych zawodowo z wykształceniem wyższym,
  - odsetek osób w wieku 25–64 kształcących się ustawicznie,
  - współczynnik skolaryzacji na poziomie średnim,
  - współczynnik skolaryzacji na poziomie wyżej niż średnim, ale nie wyższym,
  - współczynnik skolaryzacji na poziomie wykształcenia wyższego,
  - liczba łóżek w szpitalach na 1000 mieszkańców;

[4] Za prekursora tego nurtu w teorii wzrostu uznaje się Lucasa (1988).

[5] Wybór podyktowany został przede wszystkim dostępnością danych statystycznych oraz wynikami analizy głównych składowych.

[6] Wszystkie dane statystyczne pochodzą z Banku Danych Lokalnych GUS.

– **potencjał badawczo-rozwojowy** (*BRFilter*)**:**
  – zatrudnienie w B+R wyrażone w EPC – ekwiwalentach pełnego czasu pracy[7],
  – zatrudnienie w B+R w przeliczeniu na 1000 osób aktywnych zawodowo,
  – nakłady na działalność badawczo-rozwojową w mln zł,
  – relacja nakładów na B+R do PKB w cenach bieżących.

Niestety zmienne opisujące potencjał badawczo-rozwojowy dostępne są tylko na poziomie województw, dlatego wskaźnik syntetyczny opisujący tę sferę gospodarki nie został uwzględniony w analizie przeprowadzonej dla podregionów.

W empirycznym modelu, którego celem jest sprawdzenie, czy klastry mają wpływ na poziom i wzrost PKB *per capita*, muszą być uwzględnione również czynniki reprezentujące obecność i siłę klastrów w poszczególnych regionach. A. Rodrigez-Pose i F. Comptour (2010) do konstrukcji syntetycznej miary klasteryzacji wykorzystali wyniki badań tzw. Europejskiego Obserwatorium Klastrów (*European Cluster Observatory* – ECO). Prezentowana tutaj analiza efektów zewnętrznych funkcjonowania klastrów poprzedzona została badaniem opisanym w drugim rozdziale niniejszej publikacji, którego celem była identyfikacja klastrów i ich rodzajów w poszczególnych powiatach, a następnie w podregionach i województwach. Na podstawie uzyskanych map klastrów wyliczone zostały trzy niezależne mierniki klasteryzacji oddające różne aspekty potencjalnego wpływu klastrów na gospodarkę regionów:

– indeks specjalizacji (SQ) – pokazuje, o ile silniejsza jest specjalizacja zatrudnienia w wiązkach klastrowych w danym regionie w stosunku do reszty kraju;
– indeks zróżnicowania (DIV) – odzwierciedla występowanie poszczególnych typów klastrów w regionach – wysokie wartości oznaczają, że siła klastrów w danym sektorze w regionie jest duża;
– indeks wagi dla gospodarki regionu (SIGMA) – oddaje znaczenie klastrów dla rynku pracy regionu – wskazuje, czy w danym regionie występują klastry w różnych sektorach, czy też tylko w jednym. Przypuszcza się, że jeżeli w regionie występuje kilka klastrów w różnych sektorach, prowadzi to do większych korzyści dla gospodarki lokalnej[8].

Formuły wyliczania tych mierników omówione zostały w rozdziale drugim, natomiast w tabelach 3.6 i 3.7 załączonych na końcu rozdziału trzeciego pokazane zostały wartości wszystkich trzech zmiennych reprezentujących klastry, wyznaczone dla polskich województw i podregionów. W celu jednoczesnego uwzględnienia w modelu wszystkich powyższych miar, na podstawie trzech indeksów obliczono syntetyczny indeks klasteryzacji (***potencjał klasteryzacji*** **–** *ClusFilter*).

[7] Jednostki przeliczeniowe służące do ustalania faktycznego zatrudnienia w działalności badawczo-rozwojowej; jeden ekwiwalent pełnego czasu pracy (EPC) oznacza jeden osobo-rok poświęcony wyłącznie na działalność B+R (za GUS).

[8] Korzyści zewnętrzne typu Jacobs opisano w rozdziale 1 monografii.

Wszystkie powyżej opisane mierniki syntetyczne zostały skonstruowane na podstawie Analizy Głównych Składowych (*Principal Component Analysis* – PCA)[9]. Cząstkowe wyniki analiz wykonanych dla podregionów i województw zaprezentowano odpowiednio w tabeli 4.1 i w tabeli 4.2. Należy przy tym wyjaśnić, że wskaźniki syntetyczne skonstruowane zostały w taki sposób, aby były stymulantami wzrostu PKB *per capita*.

Interpretację wyników analizy PCA w przypadku każdej zmiennej syntetycznej należy rozpocząć od sprawdzenia, czy tzw. wartość własna pierwszej głównej składowej wyraźnie przekracza *k*/2, gdzie *k* oznacza ilość zmiennych cząstkowych uwzględnionych w budowie miernika syntetycznego. Wówczas mamy pewność, że wyznaczona miara syntetyczna zawiera w sobie więcej niż połowę łącznej zmienności wszystkich zmiennych cząstkowych. Jak widać, w tablicach 4.1 i 4.2 dla każdej ze skonstruowanych miar warunek ten jest spełniony.

Tabela 4.1. Wyniki analizy głównych składowych uzyskane przy budowie zmiennych syntetycznych – dane przekrojowe dla podregionów

Zmienne cząstkowe wchodzące w skład miernika syntetycznego	Zmienna syntetyczna (pierwsza główna składowa – wynik *PCA*)	
	korelacja zmienna syntetyczna – zmienna cząstkowa	wkłady zmiennych cząstkowych w zmienną syntetyczną
Potencjał społeczny		
zatr_roln (stym)	0,816959	0,433411
bezrob_dług (stym)	0,851043	0,470330
udz_młod (stym)	0,385008	0,096259
wartość własna pierwszej głównej składowej	1,539927	
Potencjał kapitału ludzkiego		
wsp_schol_śred	0,935170	0,260796
wsp_schol_postliceal	0,928455	0,257064
szkol_wyższe	0,926613	0,256045
licz_łóżek_szpit	0,870735	0,226095
wartość własna pierwszej głównej składowej	3,353363	
Klasteryzacja		
SQ	0,995259	0,367016
DIV	0,910219	0,306976
SIGMA	0,938013	0,326009
wartość własna pierwszej głównej składowej	2,698907	

Źródło: Obliczenia własne w programie STATISTICA 9.

[9] Metodologia budowy miar syntetycznych z wykorzystaniem analizy głównych składowych opisana została np. w OECD (2008, s. 63–69).

Tabela 4.2. Wyniki analizy głównych składowych uzyskane przy budowie zmiennych syntetycznych – dane panelowe dla województw

Zmienne cząstkowe wchodzące w skład miernika syntetycznego	Zmienna syntetyczna (pierwsza główna składowa – wynik *PCA*)	
	korelacja zmienna syntetyczna – zmienna cząstkowa	wkłady zmiennych cząstkowych w zmienną syntetyczną
Potencjał społeczny		
zatr_roln (stym)	0,186712	0,023976
bezrob_dług (stym)	0,843335	0,489128
udz_młod (stym)	0,841409	0,486897
wartość własna pierwszej głównej składowej	1,854045	
Potencjał kapitału ludzkiego		
Dokształcanie	0,853523	0,464170
zatrud_wykszt_wyższe	0,832481	0,441566
licz_łóżek_szpit	0,384635	0,094264
wartość własna pierwszej głównej składowej	1,769471	
Potencjał badawczo-rozwojowy		
zatrud B+R	0,981948	0,262260
udz_zatrud B+R	0,962439	0,251942
nakłady na B+R	0,954571	0,247840
udz_nakład B+R w PKB	0,935348	0,237958
wartość własna pierwszej głównej składowej	3,676592	
Klasteryzacja		
SQ	0,995082	0,377248
DIV	0,891946	0,303100
SIGMA	0,915977	0,319652
wartość własna pierwszej głównej składowej	2,624770	

Źródło: Obliczenia własne w programie STATISTICA 9.

Zmienna nazwana potencjałem społecznym dla podregionów dobrze reprezentuje zatrudnienie w rolnictwie oraz bezrobocie długookresowe, natomiast odsetek ludzi młodych jest odzwierciedlany w tej zmiennej w bardzo małym stopniu (korelacja zmiennej syntetycznej ze zmienną cząstkową wynosi zaledwie 0,385). Ważne, aby pamiętać o tym w trakcie interpretacji wyników analizy wykorzystującej tak wyznaczoną zmienną syntetyczną.

Dwie pozostałe miary wyliczone dla podregionów w równomierny sposób odzwierciedlają zmienności wszystkich zmiennych wkładowych. Świadczą o tym przede wszystkim wartości wkładów poszczególnych zmiennych cząstkowych w zmienną syntetyczną.

Wyniki analizy głównych składowych przeprowadzonej dla zmiennych opisujących gospodarki województw zamieszczone zostały w tabeli 4.2. Jak widać, podobnie jak dla podregionów, każda ze zmiennych syntetycznych odzwierciedla więcej niż połowę łącznej zmienności wszystkich zmiennych cząstkowych. Tym razem w tzw. potencjale społecznym zmienną najsłabiej reprezentowaną jest zatrudnienie w rolnictwie, natomiast w potencjale kapitału ludzkiego niewystarczająco odzwierciedlona została zmienność liczby łóżek w szpitalach. Dwie pozostałe zmienne syntetyczne, tj. potencjał badawczo-rozwojowy oraz indeks klasteryzacji, równomiernie oddają zmienność wszystkich cząstkowych elementów.

Prawidłowa identyfikacja wpływu klasteryzacji gospodarki na jej poziom rozwoju powinna uwzględniać również ogólne siły aglomeracji występujące w poszczególnych regionach. 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 czasie, jak i w przestrzeni (przestrzenna koncentracja procesów rozwojowych w silnych ośrodkach aglomeracyjnych, występowanie opóźnień w fazach rozwoju między ośrodkami). Z tego też względu w celu uwzględnienia oddziaływania sił aglomeracyjnych na procesy rozwojowe polskich województw w jednym z etapów analizy wykorzystano proponowane w literaturze indeksy aglomeracji – logarytm z udziału populacji największego miasta, trzech bądź pięciu największych ośrodków miejskich w całkowitej populacji województwa (indeksy A1, A3, A5)[10].

4.2.2. Empiryczne regresje efektów zewnętrznych

Narzędziem weryfikacji hipotezy o istotnym znaczeniu klastrów w regionach były regresje wyjaśniające poziom i wzrost PKB *per capita* w regionach, w których czynnikami objaśniającymi były opisane powyżej zmienne.

W pierwszym etapie modelowania ekonometrycznego oszacowano modele dla 66 podregionów, czyli jednostek terytorialnych wyodrębnionych w ramach NUTS3. Niestety dla tych jednostek terytorialnych w statystyce publicznej nie są dostępne szeregi czasowe PKB w cenach stałych. Brak też indeksów cen, które pozwoliłyby na wyznaczenie w rzetelny sposób takich szeregów na postawie dostępnego PKB w cenach bieżących. Dlatego podjęto decyzję, że modelowanie dla podregionów przeprowadzone zostanie tylko przekrojowo, bez uwzględnienia zmian w czasie. Zatem wyjaśnione zostaną przyczyny zróżnicowania PKB *per ca-*

[10] W konstrukcji indeksu aglomeracji uwzględniono największe powiaty grodzkie występujące w poszczególnych województwach Polski. Do analizy posłużyły dane demograficzne z Bazy Danych Lokalnych Głównego Urzędu Statystycznego.

pita pomiędzy podregionami. Stąd regresja będąca przedmiotem oszacowania dla podregionów przedstawia się następująco:

$$\ln PKBpc_i = \beta_0 + \beta_1 SocFilter_i + \beta_2 HCFilter_i + \beta_3 ClusFilter_i + \varepsilon_i \qquad [4.1]$$
$$i = 1,...,66$$

gdzie: $PKBpc_i$ – Produkt Krajowy Brutto *per capita* w *i*-tym podregionie, ε_i – składnik zakłócający w modelu, pozostałe zmienne objaśniające to zdefiniowane wcześniej mierniki syntetyczne

Drugi etap modelowania polegał na oszacowaniu regresji dla województw, dla których dysponujemy znacznie większą ilością danych statystycznych. W związku z tym możliwe jest wyjaśnianie zmienności PKB *per capita*, a także jego zmian zarówno w przestrzeni, jak i w czasie. Dlatego w tym przypadku oszacowany został następujący model przestrzenno-czasowy (panelowy):

$$\ln PKBpc_{i,t} = \mu_i + \beta_1 Aglom_{it} + \beta_2 SocFilter_{i,t} + \beta_3 HCFilter_{i,t} + \\ + \beta_4 BRFilter_{i,t} + \beta_5 ClusFilter_{i,t} + \varepsilon_{i,t} \qquad [4.2]$$
$$i = 1,...,16,\ t = 1,...,T$$

gdzie: $PKBpc_{i,t}$ – Produkt Krajowy Brutto *per capita* w *i*-tym województwie w roku *t*, a zmienna $Aglom_{it}$ oznacza wybraną zmienną reprezentującą siłę aglomeracji

Dzięki identyfikacji klastrów przemysłowych przeprowadzonej na dość niskim poziomie agregacji danych w wymiarze przestrzennym możliwe stało się zbadanie, czy obecność i funkcjonowanie klastrów ma wpływ na rozwój poszczególnych powiatów w Polsce. Jest to szczególnie istotne ze względu na fakt, że w koncepcji klastrów, z definicji, ważna jest bliskość geograficzna jednostek je tworzących. Już na początku należy jednak zaznaczyć, że uzyskane wyniki obciążone są mankamentami statystyki publicznej, czyli faktem, że dane rejestrowane nie zawsze dokładnie odzwierciedlają rzeczywistość gospodarczą. Na przykład powiat, w którym zarejestrowana jest firma nie musi być tym samym powiatem, w którym firma funkcjonuje i generuje ewentualne efekty zewnętrzne.

W przypadku powiatów, inaczej niż dla województw i podregionów, nie jest wyznaczana wartość regionalnego Produktu Krajowego Brutto, stąd pojawia się konieczność znalezienia innych zmiennych, które mogłyby w pewien sposób reprezentować poziom rozwoju regionu. Zakładając, że zamożność regionu zależy, a także ma wpływ na zamożność jego mieszkańców, można przyjąć, że zmienną mogącą odzwierciedlać efekty zewnętrzne funkcjonowania klastrów może być przeciętne wynagrodzenie miesięczne w danym powiecie. Dlatego oszacowany został model wyjaśniający zróżnicowanie wynagrodzeń w polskich powiatach w roku 2006, czyli roku dla którego dokonana została identyfikacja klastrów. Zmiennymi objaśniającymi w tym modelu są: liczba ludności w powiecie (*ludn*), stopa bezrobocia rejestrowanego (*bezrob*), zmienna zerojedynkowa wyróżniająca

powiaty miejskie (*pow_m*) oraz wyznaczony wcześniej syntetyczny indeks klasteryzacji w powiatach (*ClusFilter*). Ostatecznie zmienność wynagrodzeń w powiatach wyjaśniona została za pomocą następującego modelu[11]:

$$\ln(wyn_i) = \beta_0 + \beta_1 \ln(ludn_i) + \beta_2 \ln(bezrob_i) + \beta_3 pow_m_i + \beta_4 ClusFilter_i + \varepsilon_i \quad [4.3]$$
$$i = 1,...,370$$

gdzie: wyn_i – przeciętne miesięczne wynagrodzenie w *i*-tym powiecie w roku 2006, ε_i – składnik zakłócający, a pozostałe zmienne zostały zdefiniowane powyżej

Oszacowano także następujący model, w którym zmienną objaśnianą był wzrost przeciętnego miesięcznego wynagrodzenia w powiatach w latach 2002–2010:

$$wzr_wyn_i = \beta_0 + \beta_1 \ln(ludn_i) + \beta_2 \ln(bezrob_i) + \beta_3 pow_m_i + \beta_4 ClusFilter_i + \varepsilon_i \quad [4.4]$$
$$i + 1,...,370$$

gdzie przeciętna stopa wzrostu wynagrodzeń w okresie 2002–2010 (8 lat) została wyznaczona jako:

$$wzr_wyn_i = \frac{1}{8} \ln\left(\frac{wyn_{i,2010}}{wyn_{i,2002}}\right)$$

Ponadto, zgodnie z teorią klastrów, działalność dobrze funkcjonujących klastrów powinna mieć pozytywny i zauważalny wpływ na dochody władz samorządowych. Dlatego oszacowana została również następująca regresja wyjaśniająca zróżnicowanie dochodów własnych powiatów w roku 2006:

$$\ln(doch_i) = \beta_0 + \beta_1 \ln(ludn_i) + \beta_2 \ln(bezrob_i) + \beta_3 pow_m_i + \beta_4 ClusFilter_i + \varepsilon_i \quad [4.5]$$
$$i + 1,...,370$$

a także regresja wyjaśniającą zróżnicowanie stopy zmian dochodów własnych powiatów w okresie 2002–2010:

$$wzr_doch_i = \beta_0 + \beta_1 \ln(ludn_i) + \beta_2 \ln(bezrob_i) + \beta_3 pow_m_i + \beta_4 ClusFilter_i + \varepsilon_i \quad [4.6]$$
$$i + 1,...,370$$

We wszystkich omówionych powyższej regresjach występuje wiele zmiennych, które z punktu widzenia opisywanych zjawisk mogą być ze sobą skorelowane. Stąd w celu uniknięcia problemów związanych ze współliniowością, przed oszacowaniem każdej regresji testowana była potencjalna współliniowość zmiennych objaśniających za pomocą testu VIF[12].

---

[11] Podobny model określany jako krzywa płac szacowany był przez Garretsena, Schramma i Brakmana (2003).

[12] Test VIF (*Variance Inflation Factor*) polega na wyznaczeniu następującej wartości $VIF = \frac{1}{tolerance}$, gdzie $tolerance = 1 - R^2$. Wartość wskaźnika *tolerance* mniejsza niż 0,2 lub 0,1 oraz/lub wartość VIF powyżej 10 sugeruje występowanie współliniowości w modelu (O'Brien, 2007).

Mankamentem badania Rodrigez-Pose'a i Comptoura (2010) jest brak uwzględniania potencjalnych współzależności pomiędzy regionami. Należy pamiętać, iż jedną z kluczowych cech regionalnego systemu produkcji jest jego lokalizacja. Stąd w badaniach wpływu klastrów na gospodarkę regionalną, w której są zlokalizowane, należy uwzględnić również obecność klastrów w regionach sąsiednich. Oznacza to, że w regresji wzrostu powinna być odzwierciedlona możliwość wystąpienia przestrzennych współzależności pomiędzy regionami, inaczej mówiąc, przestrzennej autokorelacji.

W pewien sposób występowanie takiej autokorelacji założyli w swoim badaniu Kubis, Brachert i Titze (2010). Współzależności przestrzenne uwzględniono tam poprzez wykorzystanie w regresji macierzy zawierającej wartości średnie zmiennych objaśniających wyznaczane dla regionów sąsiadujących z danym regionem. Jest to jeden z możliwych sposobów uwzględnienia przestrzennej współzależności w regresji. Zaproponowany przez autorów model jest określany mianem modelu z przestrzenną filtracją zmiennych objaśniających. Wydaje się jednak nieuzasadnione wprowadzenie takiego modelu bez wcześniejszej wnikliwej analizy statystycznej pozwalającej na znalezienie najlepszego w danym przypadku sposobu odzwierciedlenia autokorelacji przestrzennej. Dlatego kolejny podrozdział zawiera opis wykorzystanych w badaniu metod ekonometrycznego modelowania przestrzennego.

4.2.3. Metodologia modelowania przestrzennego

W analizach ilościowych, w których mamy do czynienia z danymi zlokalizowanymi, to znaczy z jednostkami, których położenie w przestrzeni geograficznej jest stałe, należy wziąć pod uwagę potencjalne współzależności przestrzenne pomiędzy badanymi obiektami. Interakcje przestrzenne obrazują prawidłowość, że przestrzeń nie składa się z wzajemnie izolowanych jednostek, bowiem to, co dzieje się w jednym obiekcie, może mieć wpływ na inne. Co więcej, relacje zachodzące pomiędzy dwoma obiektami mogą mieć wpływ również na pozostałe jednostki (Suchecki 2010).

Tak jak zostało to opisane w poprzednim rozdziale, jednym z podstawowych narzędzi pozwalającym uwzględnić przestrzeń w badaniu, są macierze sąsiedztwa określające położenie analizowanych jednostek względem siebie. Dobór odpowiedniej macierzy powinien być pierwszym krokiem ekonometrycznego modelowania przestrzennego. LeSage i Pace (2009) sugerują, że dobrą metodą wyboru optymalnej macierzy wag w modelu ekonometrycznym jest oszacowanie tego samego modelu z różnymi wagami i porównanie wartości funkcji logarytmu wiarygodności w każdym z nich. Najwyższą wartość tej funkcji wskazuje model z najwłaściwszą macierzą wag.

Macierz wag powstaje na podstawie określonej macierzy sąsiedztwa lub odległości odzwierciedlającej charakter interakcji przestrzennych pomiędzy jednostkami. Możliwe jest wykorzystanie jednej z następujących macierzy:
- macierz najbliższego sąsiedztwa (macierz kontyngencji pierwszego rzędu),
- macierz k najbliższych sąsiadów,
- macierz odległości euklidesowych pomiędzy geometrycznymi środkami regionów,
- macierz odległości euklidesowych pomiędzy stolicami regionów oraz
- macierze różnie zdefiniowanych odległości ekonomicznych.

Należy pamiętać, że macierz odległości powinna być skonstruowana w taki sposób, aby odzwierciedlała fakt, że intensywność współzależności pomiędzy regionami maleje wraz ze wzrostem odległości pomiędzy nimi[13]. Stąd w macierzach wag obliczonych na podstawie miar odległości poszczególne elementy są najczęściej funkcjami odwrotnymi lub wykładniczo-odwrotnymi miar odległości. Dokładna konstrukcja poszczególnych macierzy została omówiona w rozdziale drugim.

Kolejnym pytaniem, na które należy udzielić odpowiedzi, jest rodzaj modelu najlepiej odwzorowującego przestrzenne współzależności pomiędzy obiektami. W literaturze proponowanych jest szereg różnych modeli pozwalających na dokładną analizę kwestii wpływu sąsiedztwa na badane zależności. Jeżeli współzależności przestrzenne miałyby być uwzględnione w regresji szacowanej jako model ekonometryczny, to możliwe jest zastosowanie różnych rozwiązań[14].

Pierwszym typem modelu, najczęściej wykorzystywanym w badaniach empirycznych, jest Model Autoregresji Przestrzennej (*Spatial Autoregressive Model* – SAR) nazywany inaczej Modelem Opóźnień Przestrzennych (*Spatial Lag Model* – SLM). Postać tego modelu można zapisać w następujący sposób:

$$y_i = \beta_0 + \rho \boldsymbol{W} y_i + \beta_1 x_{1i} + \beta_2 x_{2i} + \ldots + \beta_k x_{ki} + \varepsilon_i \qquad [4.7]$$
$$\varepsilon_i \sim N(0, \sigma^2)$$
$$i = 1,\ldots,N$$

gdzie: y_i – wartość zmiennej objaśnianej w i-tej lokalizacji, $\boldsymbol{W}$ – macierz wag przestrzennych, ρ – współczynnik autoregresji przestrzennej zmiennej objaśnianej y, ε_i – składnik zakłócający w modelu

Jak widać, jest to model, w którym zakłada się, że wartość zmiennej objaśnianej w danym regionie zależy od wartości tej samej zmiennej w regionach sąsiednich, gdzie sąsiedztwo określone jest za pomocą macierzy $\boldsymbol{W}$.

[13] Prawo Toblera (Tobler 1970).

[14] Pełny przegląd modeli ekonometrii przestrzennej zawarty został w książce pod redakcją Sucheckiego (2010).

Inny możliwy do zastosowania model przestrzenny to Model z Autokorelacją Przestrzenną Składnika Losowego (*Spatial Error Model* – SEM), w którym przyjmuje się, że:

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \ldots + \beta_k x_{ki} + \xi_i \qquad [4.8]$$
$$\xi_i = \lambda \boldsymbol{W} \xi_i + \varepsilon_i$$
$$i = 1,\ldots,N$$

gdzie: λ – współczynniki autokorelacji przestrzennej zakłóceń losowych modelu. Ponadto składnik losowy ε_i jest funkcją czysto losowego składnika zakłócającego spełniającego klasyczne założenia $\varepsilon_i \sim N(0, \sigma^2)$

W takim modelu zakłada się istnienie współzależności przestrzennych, spowodowanych działaniem czynników przypadkowych, niemierzalnych lub błędów pomiaru. Efekty działania tych czynników mają charakter globalny dla wszystkich jednostek (Suchecki 2010).

Jako trzecią grupę modeli przestrzennych należy wymienić Modele z Przestrzenną Filtracją Zmiennych Objaśniających, w których interakcje przestrzenne uwzględnia się wyłącznie w zbiorze zmiennych objaśniających:

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \ldots + \beta_k x_{ki} + \psi_1 \boldsymbol{W} x_{1i} + \psi_2 \boldsymbol{W} x_{2i} \ldots \psi_k \boldsymbol{W} x_{ki} + \varepsilon_i \qquad [4.9]$$
$$\varepsilon_i \sim N(0, \sigma^2)$$
$$i = 1,\ldots,N$$

W modelu tym zakładamy, że wartości zmiennej objaśnianej w danym regionie zależą od wartości wybranych zmiennych *x* z danego obiektu przestrzennego oraz od ważonych wartości tych samych zmiennych z regionów sąsiednich, zgodnie z przyjętym w macierzy wag ***W*** schematem sąsiedztwa.

Szczególnym przypadkiem modelu przestrzennego jest model mieszany, w którym uwzględniona jest zarówno przestrzenna autoregresja zmiennej objaśnianej, jak i przestrzenna autokorelacja zakłóceń losowych (*Spatial Autoregressive Spatial Error Model* – SAR-SEM). Jest to model następującej postaci:

$$y_i = \beta_0 + \rho \boldsymbol{W} y_i + \beta_1 x_{1i} + \beta_2 x_{2i} + \ldots + \beta_k x_{ki} + \xi_i \qquad [4.10]$$
$$\xi_i = \lambda \boldsymbol{W} \xi_i + \varepsilon_i$$
$$i = 1,\ldots,N$$

Należy zwrócić uwagę, że w praktyce obie macierze ***W*** nie muszą być takie same, czyli wzajemne oddziaływanie regionów poprzez wartości zmiennej objaśnianej *y* może przebiegać zgodnie z innym schematem sąsiedztwa niż oddziaływania w przestrzeni zakłóceń losowych w modelu.

W związku z tym, że możliwe jest zastosowanie różnych modeli regresji przestrzennych, pojawia się problem wyboru właściwego wariantu modelu, który powinien być wykorzystany w przypadku konkretnego analizowanego zjawiska. Stosuje się wówczas jedną z dwóch procedur modelowania: od szczególnego do

ogólnego lub od ogólnego do szczególnego. W praktyce w badaniach wykorzystujących modele ekonometrii przestrzennej częściej stosuje się podejście pierwsze, patrz np.: Angelin i Rey (1991), Angelin i Florax (1995), Florax i in. (2005). Oznacza to, że najpierw szacuje się model z największą liczbą elementów przestrzennych, sprawdzając istotność parametrów reprezentujących współzależności przestrzenne. Następnie estymacji podlegają modele z pojedynczymi miernikami przestrzennymi. Wybór optymalnego modelu przestrzennego dokonywany jest na podstawie odpowiednich testów istotności oraz testu ilorazu wiarygodności.

Oszacowanie parametrów strukturalnych opisanych powyżej modeli dokonywane jest za pomocą odpowiednio skonstruowanej Metody Największej Wiarygodności. Należy dodać, że dostępne są pakiety komputerowe z odpowiednimi modułami pozwalającymi na estymację tych modeli[15].

W prezentowanym badaniu empirycznym modele ekonometryczne dla województw szacowane są na danych panelowych, a w tym przypadku na danych przestrzenno-czasowych, czyli 16 województw obserwowanych jest w kilku okresach. Należy wówczas rozważyć możliwość procesu, w którym charakter powiązań pomiędzy regionami może zmieniać się w czasie. Oczywiście takie charakterystyki jak odległość geograficzna, wspólna granica, są niezmienne, 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 $\boldsymbol{W}$ jest macierzą blokowo-diagonalną o wymiarze NTxNT. Jeżeli prawdziwe jest założenie o niezmienności w czasie powiązań pomiędzy jednostkami, wówczas panelowa macierz wag to ($\boldsymbol{I}_T \otimes \boldsymbol{W}$). Natomiast jeżeli macierz $\boldsymbol{W}$ zmienia się w czasie, to bloki na diagonali panelowej macierzy wag są różne.

Mając określony, za pomocą macierzy $\boldsymbol{W}$, charakter powiązań pomiędzy obserwacjami przestrzennymi, można zdefiniować model uwzględniający przestrzenne współzależności i tak na przykład najbardziej ogólny panelowy model przestrzenny przedstawia się następująco (Elhorst 2003):

$$\begin{aligned} y_{it} &= \lambda \boldsymbol{W}_1 y_{it} + x_{it}\beta + \mu_i + u_{it} \\ u_{it} &= \rho W_2 u_{it} + \varepsilon_{it} \qquad \varepsilon_{it} \sim N(0, \sigma^2) \\ i &= 1,...,N \qquad\qquad t = 1,...,T \end{aligned} \tag{4.11}$$

gdzie macierze $\boldsymbol{W}_1$ i $\boldsymbol{W}_2$ są macierzami wag reprezentującymi powiązania pomiędzy jednostkami o wymiarach NTxNT, λ jest współczynnikiem autoregresji przestrzennej, ρ to współczynnik przestrzennej autokorelacji zakłóceń losowych, μ_i – to efekt indywidualny i-tego regionu, który może być efektem ustalonym (model *Fixed Effects* – FE) lub efektem losowym (model *Random Effects* – RE)

[15] Jest to wykorzystany w opisywanym badaniu R Cran, ale również STATA i MATLAB.

Zdefiniowanie dwóch różnych macierzy $\boldsymbol{W}$ oznacza, że zakładamy możliwość, iż autoregresja może zachodzić w inny sposób niż przestrzenna autokorelacja zakłóceń. W praktyce jednak najczęściej stosuje się tę samą macierz wag w obu komponentach modelu. Model (4.11) w literaturze określany jest mianem panelowego modelu przestrzennej autoregresji z przestrzenną autokorelacją zakłóceń rzędu (1,1) (*Panel Spatial Autoregresive and Spatially Autocorrelated Model* – PSARAR (1,1)). Szczególnymi przypadkami takiego modelu są najczęściej stosowane w badaniach empirycznych panelowe modele SAR (*Panel Spatial Autoregresive Model* – PSAR), w których zakłada się, że interakcje pomiędzy regionami mają charakter autoregresji: parametr $\rho = 0$, a $\lambda \neq 0$ oraz panelowe modele SEM (*Panel Spatial Error Model* – PSEM), gdzie $\rho \neq 0$, $\lambda = 0$.

Uwzględnianie w modelu elementów przestrzennych znacząco wpływa na sposób estymacji tego modelu. I tak, w przypadku przestrzennego modelu panelowego z efektami ustalonymi (*SFE*) trzeba wziąć pod uwagę przynajmniej dwie kwestie. Po pierwsze, endogeniczność $\boldsymbol{W}y_{it}$, czyli $E(\boldsymbol{W}y_{it}\, \varepsilon_{it}) \neq 0$, 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. Wyprowadzenie estymatorów dla panelowych modeli SAR i SEM znaleźć można w pracy Elhorsta[16].

Wszystkie empiryczne regresje omówione w podrozdziale 4.3 zostały zbudowane dla regionów: województw, podregionów i powiatów, czyli jednostek przestrzennie zlokalizowanych. Dlatego każdy z tych modeli był szacowany jako model przestrzenny lub panelowo-przestrzenny. I tak, model wyjaśniający zmienność PKB *per capita* w podregionach w najbardziej ogólnej postaci szacowany był jako:

$$\ln PKBpc_i = \beta_0 + \lambda \boldsymbol{W} \ln PKBpc_i + \beta_1 SocFilter_i + \beta_2 HCFilter_i + \beta_3 ClusFilter_i + \xi_i \quad [4.12]$$
$$\xi_i = \rho \boldsymbol{W} \xi_i + \varepsilon_i$$
$$i = 1,...,66$$

Również pozostałe modele szacowane były jako modele uwzględniające elementy przestrzenne, a wybór odpowiedniej macierzy wag i klasy modelu dokonywany był oddzielnie dla każdej regresji. W kolejnym podrozdziale zaprezentowane zostały uzyskane wyniki estymacji oraz ich interpretacja.

[16] Elhorst, *Spatial panel data models,* dostępne na stronie: http://www.regroningen.nl/elhorst/doc/Spatial%20Panel%20Data%20Models.pdf.

4.3. Interpretacja wyników estymacji modeli

W celu sprawdzenia, czy funkcjonowanie klastrów w danej lokalizacji ma znaczenie dla gospodarki lokalnej, przeprowadzono badanie składające się z trzech etapów. W etapie pierwszym analiza dokonana została na poziomie 66 polskich podregionów, etap drugi dotyczył 16 województw, trzeci etap to wnioskowanie przeprowadzone na poziomie 370 powiatów[17].

4.3.1. Podregiony

Podregiony w Polsce wyodrębnione zostały ze względu na wymagania europejskiej klasyfikacji NUTS3. Nie są funkcjonującymi jednostkami administracyjnymi, a podział dokonany według niejednoznacznego kryterium, wciąż ulega pewnym zmianom, często z powodu nacisków lokalnych administracji samorządowych. Stąd dane dostępne w statystyce publicznej mają charakter raczej przybliżony, a w wielu przypadkach brak porównywalnych szeregów czasowych. Dlatego analiza efektów funkcjonowania klastrów ma charakter raczej wstępnej oceny. Jak wcześniej wspomniano, analiza ilościowa przeprowadzona została w ujęciu przekrojowym bez uwzględnienia zmian w czasie badanych zmiennych ekonomicznych.

Ze względu na trudny do określenia z góry charakter możliwych interakcji pomiędzy podregionami zbadano szereg różnych macierzy wag przestrzennych reprezentujących położenie regionów względem siebie. Stosując kryterium największej wartości funkcji logarytmu wiarygodności w każdym z szacowanych modeli, stwierdzono, że najodpowiedniejszą macierzą sąsiedztwa jest macierz kontyngencji stopnia pierwszego, czyli za sąsiadów uznawane są te regiony, które mają przynajmniej jeden punkt wspólnej granicy.

W tabeli 4.4 zamieszczono wyniki oszacowania regresji, wyjaśniającej zróżnicowanie poziomu PKB *per capita* w podregionach, zdefiniowanej wzorem 4.1. Pokazane zostały wyniki oszacowania trzech klas modeli przestrzennych. Okazało się, że odpowiednim modelem w tym przypadku jest model z przestrzenną autokorelacją zakłóceń losowych (SEM) oznaczony w tablicy 4.3 jako Model R2, dlatego tylko dla tego modelu dokonana została interpretacja uzyskanych wyników.

[17] Aktualnie terytorium Polski podzielone jest na 381 powiatów, w tym 66 powiatów miejskich. W związku ze zmianami granic jednostek terytorialnych, które następowały w badanym okresie, w celu zachowania porównywalności dokonano modyfikacji pierwotnych danych pochodzących z GUS, polegającej na połączeniu niektórych powiatów i zsumowaniu wartości analizowanych zmiennych. W wyniku tej modyfikacji liczebność jednostek terytorialnych podlegających badaniu na poziomie NUTS4 wyniosła 370.

Tabela 4.3. Wyniki oszacowania przestrzennego modelu efektów zewnętrznych klastrów przemysłowych dla polskich podregionów w roku 2006

Zmienna objaśniająca	Model R1	Model R2	Model R3
	zmienna objaśniana: ln (*PKBpc*)		
	klasa modelu przestrzennego		
	SAR	SEM	SAR_SEM
stała	6,5939 [0,0000]	10,3339 [0,0000]	8,6016 [0,0002]
ρ (autoregr. przestrz.)	0,3768 [0,0810]	–	0,1749 [0,4641]
λ (autokorel. przestrz.)	–	0,4541 [0,0040]	0,3288 [0,2132]
SocFilter	0,1050 [0,0032]	0,1079 [0,0042]	0,1067 [0,0002]
HCFilter	0,1614 [0,0000]	0,1439 [0,0000]	0,1526 [0,0000]
ClusFilter	0,0256 [0,4202]	**0,0567** **[0,0700]**	0,0456 [0,2002]
Liczba obserwacji	66	66	66
Test F	10,305 [0,001]	11,417 [0,004]	8,951 [0,011]
Funkcja log-likehood	25,88488	26,5096	25,269

Uwagi:

1) dla każdego modelu oddzielnie za pomocą odpowiednich testów dokonano wyboru właściwego modelu przestrzennego: SAR – model autoregresji przestrzennej; SEM – model z autokorelacją przestrzenną składnika losowego; SAR-SEM – model z przestrzenną autoregresją i przestrzenną autokorelacją składnika losowego

2) wyniki oszacowania uzyskano z wykorzystaniem Metody Największej Wiarygodności

3) w nawiasach kwadratowych pod ocenami parametrów znajduje się prawdopodobieństwo empiryczne testu istotności t-Studenta (np. wartość $p<0,05$ świadczy o istotności zmiennej na 5 procentowym poziomie istotności)

Źródło: Obliczenia własne z wykorzystaniem pakietu spdep R Cran.

Po pierwsze, należy stwierdzić, że pomiędzy podregionami występują istotne współzależności przestrzenne. Poziom PKB *per capita* w danym regionie zależy od nieobserwowalnych i nieprzewidywalnych zakłóceń losowych mających miejsce w tym regionie, ale również od czynników losowych zachodzących w regionach sąsiednich. Takimi czynnikami losowymi, mającymi wpływ na zamożność regionu, mogą być np. klęski żywiołowe, nieurodzaj w rolnictwie, ale też efekty mody, naśladownictwa, nieformalne rozlewanie się wiedzy, wzrost atrakcyjności inwestycyjnej danej części kraju. Dodatni znak współczynnika przestrzennej autokorelacji zakłóceń świadczy o tym, że wpływ zakłóceń, mających miejsce w danym regionie, ma taki sam kierunek w tym regionie, jak i w regionach sąsiednich – na przykład niekorzystne wydarzenie losowe z danym regionie generuje ujemne skutki również w regionach sąsiednich.

Zmienna syntetyczna, reprezentująca potencjał społeczny regionu, ma statystycznie istotny, dodatni wpływ na poziom PKB *per capita* w tym regionie. Jest to potwierdzeniem ogólnie znanej prawidłowości, że niższe bezrobocie długookresowe, niższy udział zatrudnionych w rolnictwie oraz niższy odsetek osób młodych wiąże się z wyższym poziomem zamożności w danym regionie. Dziwić może jedynie ujemny wpływ udziału osób młodych. Wytłumaczeniem tego faktu może być obserwowane obecnie, nie tylko w polskiej gospodarce, wysokie bezrobocie wśród młodych ludzi.

Inwestycje w szeroko rozumiany kapitał ludzki mają również istotny pozytywny wpływ na gospodarkę w podregionie. Zatem wyższe współczynniki skolaryzacji i lepszy dostęp do opieki medycznej, aproksymujące zasoby kapitału ludzkiego regionu, przyczyniają się do wyższego poziomu zamożności. Można tutaj zwrócić uwagę na wartości ocen parametrów strukturalnych w regresji, które wskazują na większą siłę oddziaływania kapitału ludzkiego w porównaniu z tzw. potencjałem społecznym. Oczywiście w zakresie zmiennych społeczno-ekonomicznych uwzględnionych w obu miernikach syntetycznych.

Kluczowa z punktu widzenia celu budowy tego modelu jest jednak ocena wpływu indeksu klasteryzacji, reprezentującego obecność i siłę klastrów, na poziom PKB *per capita* w podregionach. Okazuje się, że zmienna ta jest statystycznie istotna zaledwie na 10-procentowym poziomie istotności, zatem wpływ klastrów reprezentowany miernikiem skonstruowanym w badaniu nie jest wyraźnie znaczący. Świadczyć to może o tym, że przy analizie rozpatrywanej zależności konieczne jest jednak uwzględnienie zmian w czasie bądź też o tym, że rzeczywiście wpływ klasteryzacji w podregionach nie jest obserwowany. Jednakże w związku z tym, że zmienna nie okazała się zupełnie nieistotna, możemy zwrócić uwagę na fakt, że uzyskano dodatni znak oceny parametru. Zatem jeżeli daje się zauważyć jakikolwiek wpływ klastrów na gospodarki podregionów, to jest on dodatni. Daje się też zauważyć, że wpływ klasteryzacji był wyraźnie słabszy niż oddziaływanie potencjału społecznego i potencjału kapitału ludzkiego, dla których uzyskane oceny parametrów przyjęły wyższe wartości i były bardziej istotne.

Komentując wyniki uzyskane w analizie efektów zewnętrznych na poziomie podregionów, należy jeszcze raz zaznaczyć, że mogą one mieć charakter tylko badania występnego.

4.3.2. Województwa

Druga część badania przeprowadzona została dla 16 polskich województw w latach 2003–2010, czyli w relatywnie krótkim czasie. Przedmiotem oszacowania był model zdefiniowany za pomocą formuły [4.2], wyjaśniający zróżnicowanie PKB *per capita* w czasie i w przestrzeni. Wszystkie specyfikacje modelu oszacowano jako dwukierunkowe panelowe modele przestrzenne z efektami ustalonymi.

Wybór modelu z efektami ustalonymi (*FE*) dokonany został na mocy przestrzennego testu Hausmana. Macierzą wag, która po wcześniejszej weryfikacji statystycznej została przyjęta w modelowaniu, podobnie jak w przypadku podregionów, była macierz wag kontyngencji stopnia pierwszego. Wstępna część modelowania polegała na doborze odpowiedniego typu panelowego modelu przestrzennego. Okazało się, że najlepszym modelem efektów zewnętrznych dla województw jest opisany formułą [4.11] panelowy model z przestrzenną autoregresją zmiennej objaśnianej i przestrzenną autokorelacją zakłóceń losowych (PSARAR). Wyniki estymacji parametrów modelu zamieszczone zostały w tabeli 4.4.

Tabela 4.4. Wyniki oszacowania przestrzennego modelu efektów zewnętrznych klastrów przemysłowych dla polskich województw w latach 2003–2009

Zmienna	Zmienna objaśniana: $\ln PKBpc_{it}$						
	Model W1	Model W2	Model W3	Model W4	Model W5	Model W6	Model W7
ρ	0,2848 [0,0036]	0,3581 [0,0001]	0,3601 [0,0000]	0,3582 [0,001]	0,2877 [0,0031]	0,2890 [0,0028]	0,2869 [0,0033]
λ	-0,6658 [0,0003]	-0,7576 [0,0000]	-0,7719 [0,0000]	-0,7564 [0,0000]	-0,6667 [0,0002]	-0,6738 [0,0002]	-0,6633 [0,0003]
SocFilter	0,1134 [0,0000]	0,0998 [0,0000]	0,1000 [0,0000]	0,0993 [0,0000]	0,1093 [0,0000]	0,1098 [0,0000]	0,1099 [0,0000]
HCFilter	-0,0092 [0,5185]	0,0301 [0,0099]	0,0309 [0,0078]	0,0309 [0,0083]	-	-	-
BRFilter	0,0877 [0,0000]	-	-	-	0,0795 [0,0000]	0,0789 [0,0000]	0,0795 [0,0000]
ClusFilter	**0,0656 [0,0000]**	**0,1135 [0,0000]**	**0,1122 [0,0000]**	**0,1122 [0,0000]**	**0,0686 [0,0000]**	**0,0681 [0,0000]**	**0,0677 [0,0000]**
ln(*ln_A*)	1,9514 [0,0097]	1,2413 [0,0016]	-	-	1,1161 [0,0059]	-	-
ln(*ln_A3*)	-	-	2,7922 [0,0016]	-	-	2,7017 [0,0067]	-
ln(*ln_A5*)	-	-	-	3,1892 [0,0022]	-	-	3,1952 [0,0067]

Uwagi:
1) w nawiasach pod ocenami parametrów znajdują się wartości prawdopodobieństwa empirycznego testu istotności t-Studenta
2) liczba obserwacji w każdym modelu równa była 112
3) każdy z modeli szacowany był jako dwukierunkowy model panelowy z efektami ustalonymi
4) metoda szacowania: Metoda Największej Wiarygodności

Źródło: Obliczenia własne z wykorzystaniem pakietu splm R Cran.

We wszystkich rozpatrywanych specyfikacjach parametr autoregresji wskazuje na występowanie statystycznie istotnej i dodatniej współzależności przestrzennej zmiennej objaśnianej, czyli realnego PKB *per capita*. Oznacza to, że wyższy poziom PKB w danym województwie wpływa dodatnio na PKB w woje-

wyższy poziom PKB w danym województwie wpływa dodatnio na PKB w województwach sąsiednich i odwrotnie – województwo biedniejsze oddziałuje negatywnie na sąsiadujące z nim regiony. Natomiast wpływ nieprzewidywalnych czynników losowych mających miejsce w województwach sąsiadujących, reprezentowany jest przez ujemny współczynnik autokorelacji. Można to zinterpretować jako prawidłowość polegającą na tym, że np. niekorzystne wydarzenia losowe w jednym województwie przynoszą korzystne efekty w województwach sąsiednich. Mamy zatem do czynienia ze zjawiskiem odwrotnym niż w przypadku podregionów. Wytłumaczeniem może być fakt, że województwa są w zasadzie dość niezależnymi gospodarkami lokalnymi o dużym zasięgu terytorialnym, stąd można zasugerować, że łatwiej o zjawisko, które określane jest jako uczenie się na cudzych błędach. Jednak pozytywne zakłócenie losowe w jednym województwie może przyczynić się np. do odpływu inwestorów z regionów sąsiednich. Interpretacja współzależności przestrzennych nie jest łatwa i wymaga bliższego prześledzenia zjawisk zachodzących w poszczególnych regionach, należy jednak zauważyć, iż pominięcie tych elementów w modelowaniu poziomu rozwoju w regionach byłoby znaczącym niedopatrzeniem.

W modelu oznaczonym symbolem W1 wśród zmiennych objaśniających uwzględniono wszystkie wskaźniki syntetyczne opisane w poprzednim podrozdziale. Przy takiej specyfikacji okazało się jednak, że miernik reprezentujący wpływ kapitału ludzkiego na poziom realnego PKB *per capita* jest statystycznie nieistotny. W celu dokładniejszej oceny wpływu tej zmiennej oszacowano model W2, w którym pominięto zmienną syntetyczną reprezentującą potencjał badawczo-rozwojowy regionu. W takiej specyfikacji potencjał kapitału ludzkiego wykazuje statystycznie istotny pozytywny wpływ na PKB *per capita*. Wynik ten można zinterpretować jako dowód na wysokie skorelowanie zmiennych reprezentujących kapitał ludzki z czynnikami opisującymi sektor B+R w województwach. Należy przy tym zaznaczyć, że do budowy obu wskaźników syntetycznych użyte zostały zupełnie inne zmienne ekonomiczne.

Identyfikując determinanty poziomu PKB *per capita* w województwach na podstawie wyników estymacji zamieszczonych w tabeli 4.4, należałoby stwierdzić, że najbardziej znaczącym potencjałem gospodarki regionalnej jest potencjał społeczny, a następnie potencjał badawczo-rozwojowy. Natomiast wyraźnie mniej istotny okazał się potencjał kapitału ludzkiego reprezentowany przez zmienne wykorzystane do budowy wskaźnika syntetycznego dla województw: odsetek osób aktywnych zawodowo z wykształceniem wyższym, odsetek osób w wieku 25–64 kształcących się ustawicznie oraz liczba łóżek w szpitalach. Można tutaj odnieść się do wyników uzyskanych przez Rodrígueza-Pose i Comptoura (2010), którzy wykazali, że potencjał społeczny (zdefiniowany podobnie jak w niniejszym badaniu) okazał się najbardziej istotnym czynnikiem determinującym rozwój gospodarczy regionu.

zachodzących w województwach. Wprowadzenie efektów aglomeracji poprzez logarytm z indeksów reprezentujących koncentrację populacji regionu z uwzględnieniem największego ośrodka miejskiego bądź w grupy największych ośrodków miejskich wskazuje na ich statystycznie istotny i pozytywny wpływ na poziom rozwoju. Okazało się również, że wykorzystywanie różnych zmiennych aglomeracyjnych nie wpływa w znaczący sposób na zmianę ocen parametrów strukturalnych w modelu.

Jednakże najistotniejszym wnioskiem z przeprowadzonej analizy jest stwierdzenie, że niezależnie od specyfikacji modelu występowanie klastrów przemysłowych w regionie, mierzone syntetycznym indeksem klasteryzacji, ma statystycznie istotny i pozytywny wpływ na poziom dochodu w województwach. Oznacza to, że im większa ilość klastrów, większe ich zróżnicowanie i większe znaczenie dla rynku pracy, tym wyższy poziom PKB *per capita* w województwie.

Kolejnym wnioskiem z analizy jest stwierdzenie wyraźnego powiązania klastrów z potencjałem badawczo-rozwojowym województwa. Porównując wyniki oszacowania modeli W2, W3 i W4 z modelami W5, W6 i W7, daje się zauważyć znaczną różnicę ocen parametrów reprezentujących wpływ klastrów na dochód w regionie. Zastąpienie potencjału kapitału ludzkiego przez potencjał B+R powoduje, że ocena siły wpływu klastrów wyraźnie spada, co oznacza istotną korelację pomiędzy oboma czynnikami. Może to obrazować prawidłowość, że klastry powstają i funkcjonują lepiej w regionach z większymi możliwościami innowacyjnymi, ale równocześnie mogą je stymulować poprzez zwiększanie popytu na nowe technologie. Jak wiemy z rozważań w rozdziale 1 – klastry stanowią istotny, integralny element regionalnych systemów innowacji.

Podjęta została również próba oszacowania modelu wyjaśniającego stopę wzrostu realnego PKB *per capita*, jednakże oceny wpływu wszystkich analizowanych zmiennych okazały się statystycznie nieistotne. Otrzymane wyniki estymacji mogą być potwierdzeniem implikacji 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. Identyfikacja wpływu klasteryzacji gospodarki na wzrost możliwa wydaje się wyłącznie w przypadku dysponowania dłuższymi szeregami danych obejmujących co najmniej dwa pełne cykle gospodarcze.

4.3.3. Powiaty

Po analizie przeprowadzonej dla województw i podregionów warto przeprowadzić dalsze analizy na najniższym dostępnym poziomie agregacji, czyli na poziomie powiatów. Wyniki modelowania na tym poziomie powinny być szczególnie ważne ze względu na fakt, że koncepcja klastrów przemysłowych dotyczy współpracy firm i instytucji funkcjonujących w zbliżonej lokalizacji geograficznej.

Dlatego też efekty zewnętrzne klastrów powinny być najwyraźniej widoczne właśnie na poziomie małych jednostek terytorialnych, jakimi są powiaty. Część analizy, polegająca na doborze optymalnego modelu ekonometrycznego, przeprowadzona został w sposób opisany już wcześniej w analizie województw.

W pierwszym etapie badania oszacowany został model zdefiniowany przez formułę 4.3, w której objaśniany jest logarytm przeciętnego miesięcznego wynagrodzenia w powiecie. Oszacowanie modelu P1 pokazuje, że zgodnie z oczekiwaniami poziom wynagrodzeń w statystycznie istotny sposób zależy od liczby ludności w powiecie – im większa liczba mieszkańców, tym wyższe przeciętne wynagrodzenie. Ponadto, zgodnie z implikacjami teorii ekonomii, wyższe bezrobocie istotnie obniża wynagrodzenie w regionie. Statystycznie istotna okazała się również zmienna zerojedynkowa dla powiatów miejskich – przeciętne miesięczne wynagrodzenie w tych powiatach jest istotnie wyższe niż w powiatach niemiejskich.

Z nieistotności parametru przy zmiennej *ClusFilter* w modelu P1, wynika, że nie udało się wykazać istotnego wpływu indeksu klasteryzacji na zróżnicowanie wynagrodzeń w powiatach. Może to oznaczać, że funkcjonowanie klastrów w powiecie nie ma wpływu na przeciętny poziom wynagrodzeń wszystkich pracujących.

Zadaniem modelu P2 było udzielenie odpowiedzi na pytanie, czy klasteryzacja wpływała na wzrost wynagrodzeń w powiatach w latach 2002–2010. Okazało się, że podobnie jak w przypadku poziomu wynagrodzeń, również ich wzrost nie zależał od klastrów reprezentowanych indeksem klasteryzacji – ocena parametru przy tej zmiennej okazała się także statystycznie nieistotna. Oceniając wyniki tej analizy, należy jednak pamiętać, że samo przeciętne miesięczne wynagrodzenie nie jest miarą w pełni oddającą dochody mieszkańców danego powiatu.

Skoro nie udało się wykazać wpływu funkcjonowania klastrów na dochody mieszkańców, reprezentowane przez przeciętne wynagrodzenie miesięczne, warto zadać pytanie o dochody samorządowych jednostek administracyjnych. Dlatego w dwóch kolejnych modelach wyjaśniane były całkowite dochody własne budżetów powiatów w roku 2006 (model P3) oraz ich wzrost w latach 2002–2010 (model P4). Wyniki estymacji wykazały, że dało się odnotować tylko pewien pozytywny wpływ obecności i siły klastrów na średnią stopę wzrostu dochodów własnych budżetów w analizowanym okresie. Oznaczać to może, że rzeczywiście funkcjonowanie klastrów wiązało się z pewnymi efektami zewnętrznymi w postaci szybszego przyrostu dochodów własnych jednostek samorządowych.

Na całkowite dochody własne budżetów powiatów składają się takie elementy, jak:

- podatek dochodowy od osób fizycznych,
- podatek dochodowy od osób prawnych,

– dochody z majątku powiatu,
– pozostałe dochody, a w tym środki na dofinansowanie własnych zadań pozyskiwane z innych źródeł.

Tabela 4.5. Wpływ obecności i siły klastrów na wysokość i wzrost przeciętnego wynagrodzenia i dochodów budżetów ogółem oraz dochodów z PIT w powiatach w latach 2002–2010

Zmienna objaśniająca	Model P1	Model P2	Model P3	Model P4	Model P5	Model P6
	zmienna objaśniana					
	ln (wyn)	wzr_wyn	ln (doch)	wzr_doch	ln (PIT)	wzr_PIT
	klasa modelu przestrzennego					
	SAR	SEM	SAR	SAR-SEM	SAR	SEM
stała	4,8318 [0,0000]	0,2867 [0,0000]	3,9526 [0,0000]	0,2169 [0,0000]	4,4419 [0,0000]	0,4384 [0,0000]
ρ (autoregr, przestrz,)	0,3415 [0,0000]	-	0,2130 [0,0000]	-0,5903 [0,0000]	0,5417 [0,0000]	-
λ (autokorel, przestrz,)	-	0,1512 [0,0483]	-	0,6329 [0,0000]	-	0,5247 [0,0000]
ln wyn_2002	-	-0,0327 [0,0000]	-	-	-	-
ln doch_2002	-	-	-	-0,0096 [0,0009]	-	-
ln PIT_2002	-	-	-	-	-	-0,0184 [0,0000]
ln ludn	0,0497 [0,0000]	0,0017 [0,0413]	0,9519 [0,0000]	0,0102 [0,0021]	1,0756 [0,0000]	0,0176 [0,0000]
ln bezrob	-0,0575 [0,0000]	-0,0022 [0,0523]	-0,2111 [0,0000]	-0,0065 [0,0364]	-0,2552 [0,0000]	-0,0088 [0,0057]
pow_m	0,0799 [0,0000]	-0,0002 [0,8619]	0,7903 [0,0000]	0,0122 [0,0000]	-	-
ClusFilter	-0,0025 [0,6884]	0,0003 [0,5455]	0,0234 [0,2504]	**0,0024 [0,0500]**	**0,1548 [0,0000]**	**0,0069 [0,0000]**
Liczba obserwacji	370	370	370	370	305	305
Test F	30,353 0,000]	4,084 [0,043]	32,707 [0,000]	15,054 [0,000]	285,29 [0,000]	14,24 [0,000]

Uwagi:
1) dla każdego modelu oddzielnie za pomocą odpowiednich testów dokonano wyboru właściwego modelu przestrzennego: SAR – model autoregresji przestrzennej; SEM – model z autokorelacją przestrzenną składnika losowego; SAR-SEM – model z przestrzenną autoregresją i przestrzenną autokorelacją składnika losowego
2) wyniki oszacowania uzyskano z wykorzystaniem Metody Największej Wiarygodności
3) w nawiasach kwadratowych pod ocenami parametrów znajduje się prawdopodobieństwo empiryczne testu istotności t-Studenta (wartość $p<0,05$ świadczy o istotności zmiennej na 5 procentowym poziomie istotności)

Źródło: Obliczenia własne z wykorzystaniem pakietu spdep R Cran.

Dlatego w kolejnym etapie analizy oszacowana została regresja wyjaśniająca dochody własne z tytułu podatku dochodowego od osób fizycznych (PIT). Jednakże ze względu na brak dostępu do pełnych danych statystycznych próba ograniczona została tylko do 305 powiatów ziemskich (wyłączyliśmy z analizy powiaty grodzkie).

Wyniki estymacji modelu P5 wykazują zdecydowanie istotny statystycznie wpływ klastrów na poziom dochodów budżetów z tytułu PIT. Co więcej, siła tego oddziaływania jest wysoka i oznacza, że jeżeli wartość indeksu klasteryzacji w pewnym regionie jest wyższa o jedną jednostkę niż w innym, charakteryzującym się tymi samymi wartościami pozostałych zmiennych ekonomicznych, to przychody z podatku dochodowego od osób fizycznych w tym regionie są wyższe średnio o 15 procent. Model P6 wyjaśnia natomiast zmienność średniej stopy wzrostu przychodów z PIT w powiatach ziemskich w latach 2002–2010. Ponownie okazało się, że funkcjonowanie klastrów w powiatach w znaczący sposób podwyższyło tempo przyrostu przychodów z podatku dochodowego od osób fizycznych. Oznacza to, że efektem zewnętrznym funkcjonowania klastrów, który wyraźnie dało się zidentyfikować na poziomie powiatów jest przyrost dochodów jednostek samorządowych z tytuły PIT. Tworzy to naturalny bodziec dla polityków lokalnych do wspierania lokalnych klastrów.

Należy jednak zadać pytanie: na ile uzyskanie tak jednoznacznych wyników zostało spowodowane wyeliminowaniem z próby powiatów miejskich. Może tak wyraźne efekty zewnętrzne funkcjonowania klastrów daje się zaobserwować w regionach niemiejskich, natomiast funkcjonowanie powiatów miejskich zdeterminowane jest przez wiele innych procesów ekonomicznych.

Analizowany był również wpływ klasteryzacji na przychody powiatów z tytułu podatku dochodowego od osób prawnych. W tym przypadku jednak nie udało się wykazać żadnych istotnych zależności pomiędzy badanymi zmiennymi.

4.4. Podsumowanie

Pierwszym wnioskiem z przeprowadzonej analizy jest stwierdzenie, że uwzględnienie przestrzennych współzależności pomiędzy regionami jest ważne, a pominięcie tych elementów jest znaczącym błędem specyfikacji w tego rodzaju badaniach. Na przykładzie modelu efektów zewnętrznych klastrów przemysłowych w województwie dało się zaobserwować istotne zależności przestrzenne pomiędzy regionami. Interakcje te mają charakter zarówno autoregresji przestrzennej PKB *per capita* i zmiennych mierzących dochody w powiatach, jak i przestrzennej autokorelacji zakłóceń losowych.

Jednakże najważniejszym wynikiem z przeprowadzonej analizy jest wykazanie, że występowanie klastrów przemysłowych w regionie, mierzone syntetycz-

nym indeksem klasteryzacji, ma statystycznie istotny i dodatni wpływ na funkcjonowanie gospodarek regionalnych.

Na podstawie analizy przestrzenno-czasowej przeprowadzonej dla województw stwierdzamy, że siła tego oddziaływania jest równie ważna jak czynników reprezentujących kapitał społeczny i potencjał badawczo-rozwojowy. Dodatkowym wnioskiem jest wykazanie znaczących powiązań pomiędzy sektorem badawczo-rozwojowym a funkcjonowaniem klastrów w regionach. Można przypuszczać, że silny sektor badawczo-rozwojowy stymuluje powstawanie klastrów i na odwrót funkcjonowanie klastrów w regionie pozytywnie wpływa na rozwój sektora B+R. Klastry wydają się stanowić integralny element lokalnych i regionalnych systemów innowacji.

Z punktu widzenia racjonalności prowadzenia polityki wspierania klastrów czy polityki rozwoju opartej na klastrach uzyskane wyniki są istotne. Klasteryzacja gospodarki wydaje się mieć statystycznie istotny wpływ na poziom rozwoju polskich regionów. Zasadnicze efekty zewnętrzne funkcjonowania klastrów wydają się ujawniać na wyższych poziomach agregacji, takich jak podregiony i województwa. Na poziomie województw wpływ klastrów na rozwój regionalny niezależny jest od ogólnego poziomu aglomeracji gospodarki.

Tabela 4.6. Wartości indeksów klasteryzacji gospodarki dla polskich województw (2006)

Województwo	Indeks SQ	Indeks DIV	Indeks SIGMA
Dolnośląskie	0,645	0,600	122,547
Kujawsko-Pomorskie	0,950	0,600	264,131
Lubelskie	0,220	0,257	34,286
Lubuskie	0,239	0,229	43,794
Łódzkie	0,966	0,600	274,459
Małopolskie	**1,189**	**0,886**	**337,014**
Mazowieckie	**1,615**	**0,857**	**806,822**
Opolskie	0,527	0,286	177,750
Podkarpackie	0,243	0,314	29,588
Podlaskie	0,159	0,171	20,884
Pomorskie	0,903	0,600	277,424
Śląskie	**1,465**	0,657	**803,689**
Świętokrzyskie	0,504	0,257	183,794
Warmińsko-Mazurskie	0,220	0,314	24,702
Wielkopolskie	0,847	**0,857**	131,964
Zachodniopomorskie	0,553	0,371	148,232

Źródło: Opracowanie własne.

Tabela 4.7. Wartości indeksów klasteryzacji gospodarki dla polskich podregionów (2006)

Podregion (kod)	Indeks SQ	Indeks DIV	Indeks SIGMA
Jeleniogórski	0,074	0,114	6,389
Legnicko-Głogowski	0,095	0,029	31,975
Wałbrzyski	0,498	0,257	220,438
Wrocławski	0,826	0,429	215,925
M. Wrocław	**1,125**	0,400	560,313
Bydgosko-Toruński	**1,773**	0,571	966,704
Grudziądzki	0,019	0,057	0,811
Włocławski	0,272	0,143	88,494
Bialski	0,062	0,029	13,552
Chełmsko-Zamojski	0,084	0,114	8,743
Lubelski	0,390	0,171	155,054
Puławski	0,125	0,114	24,252
Gorzowski	0,298	0,086	134,622
Zielonogórski	0,200	0,171	28,802
Łódzki	**1,393**	0,486	765,010
M. Łódź	**1,352**	0,486	583,511
Piotrkowski	0,451	0,229	103,652
Sieradzki	0,562	0,200	245,908
Skierniewicki	0,395	0,143	142,302
Krakowski	0,845	0,629	271,154
M. Kraków	**1,640**	0,514	818,308
Nowosądecki	0,573	0,200	257,143
Oświęcimski	**1,161**	0,629	507,384
Tarnowski	0,745	0,143	703,718
Ciechanowsko-Płocki	0,277	0,143	62,668
Ostrołęcko-Siedlecki	0,014	0,029	0,739
Radomski	0,743	0,257	348,256
M. Warszawa	**1,996**	0,486	1367,144
Warszawski wschodni	0,953	0,571	252,852
Warszawski zachodni	**1,323**	0,600	443,579
Nyski	0,000	0,000	0,000
Opolski	0,802	0,286	410,805
Krośnieński	0,157	0,114	30,862
Przemyski	0,019	0,029	1,244
Rzeszowski	0,341	0,171	156,458
Tarnobrzeski	0,321	0,200	74,829
Białostocki	0,253	0,143	63,307

Podregion (kod)	Indeks SQ	Indeks DIV	Indeks SIGMA
Łomżyński	0,042	0,057	6,082
Suwalski	0,086	0,029	26,480
Gdański	**1,098**	0,429	614,183
Słupski	0,292	0,257	42,464
Starogardzki	0,098	0,114	10,131
Trójmiejski	**1,380**	0,429	687,329
Bielski	**1,260**	0,514	594,301
Bytomski	**1,552**	0,543	970,801
Częstochowski	**1,211**	0,400	752,817
Gliwicki	**1,976**	0,514	1367,138
Katowicki	**1,296**	0,514	612,269
Rybnicki	**1,156**	0,286	836,064
Sosnowiecki	**1,770**	0,543	1175,086
Tyski	**1,983**	0,514	1440,793
Kielecki	0,693	0,229	364,257
Sandomiersko-Jędrzejowski	0,068	0,086	8,102
Elbląski	0,212	0,143	57,578
Ełcki	0,068	0,029	16,747
Olsztyński	0,278	0,200	56,841
Kaliski	0,707	0,286	268,137
Koniński	0,288	0,257	61,772
Leszczyński	0,273	0,229	108,367
Pilski	0,242	0,143	64,276
Poznański	**1,249**	0,771	360,377
M. Poznań	**1,456**	0,514	650,078
Koszaliński	0,205	0,114	48,902
Stargardzki	0,458	0,314	114,078
M. Szczecin	0,914	0,286	593,001
Szczeciński	0,643	0,314	179,234

Źródło: Opracowanie własne.

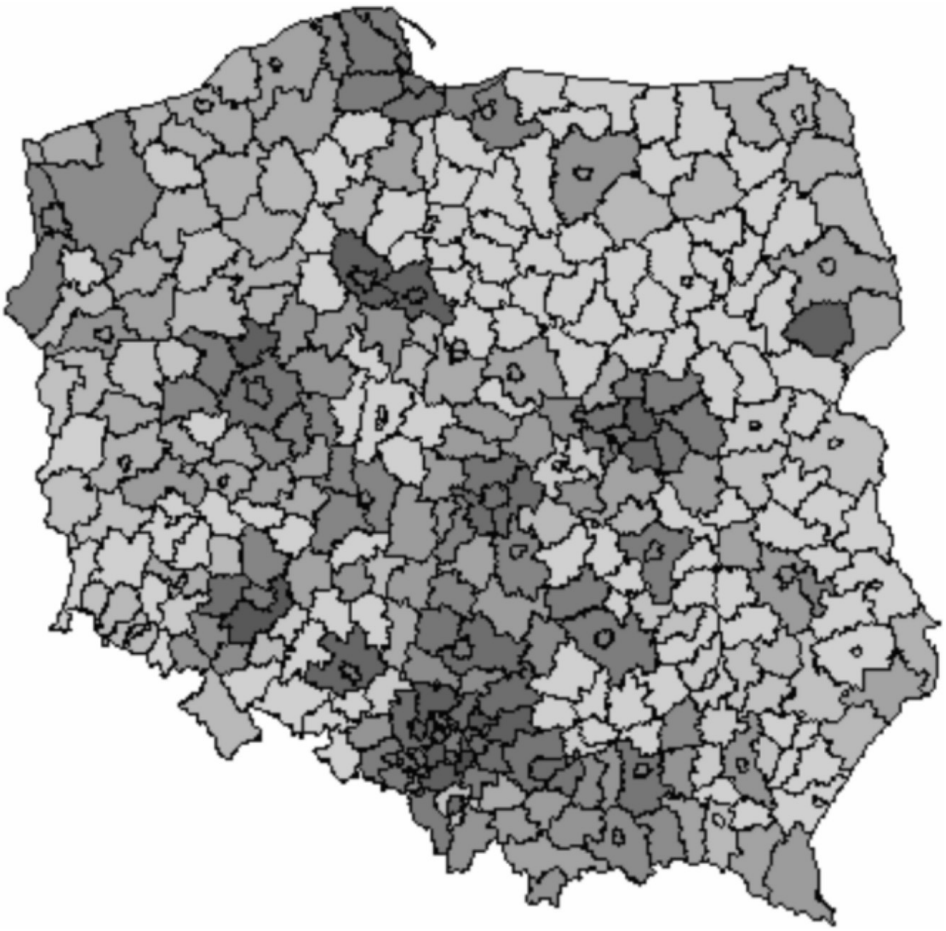

Mapa 4.1. Ogólny indeks klasteryzacji w polskich powiatach w roku 2006

Źródło: Opracowanie własne.