

ELŻBIETA ANTCZAK

Wydział Ekonomiczno-Socjologiczny
Uniwersytet Łódzki

Estymacja przestrzenno-czasowej środowiskowej krzywej Kuznetsa za pomocą regresji ważonej geograficznie

Streszczenie

Celem artykułu jest przedstawienie możliwości zastosowania regresji ważonej geograficznie do weryfikacji zależności ekologiczno-ekonomicznych (opisanych funkcją środowiskowej krzywej Kuznetsa). Przewaga GWR nad klasycznymi modelami regresji polega na możliwości uwzględnienia heterogeniczności przestrzennej w relacji pomiędzy zmienną zależną (tu ilość zebranych odpadów komunalnych w *kg/capita*) a zmiennymi niezależnymi (tu PKB/*capita* w PPS w cenach stałych, odpowiednio zwielokrotniona wartość zmiennej – stanowiąca odwzorowanie krzywej Kuznetsa) dla poszczególnych obserwacji (wybranych krajów Europy). W modelu wykorzystano różne macierze wag przestrzennych. Wyznaczono wartości ocen parametrów (dla każdej jednostki osobno), których statystyczna istotność wskazuje na realizację badanej zależności uwarunkowanej lokalnymi czynnikami i powiązaniem regionalnymi. Analizę przeprowadzono dla lat 1990–2011 (dane uśrednione).

Słowa kluczowe: regresja geograficznie ważona, heterogeniczność przestrzenna, EKC

1. Wstęp

Wzrost dynamiki rozwoju gospodarczego, zobowiązania ponadnarodowe oraz specyfika procesów przyrodniczych, społecznych i ekonomicznych nadają zależnościom ekologiczno-ekonomicznym wielowymiarowy charakter. Z kolei wielopłaszczyznowe relacje, interakcje międzyregionalne i uwarunkowania lokalne są czynnikami pogłębiającymi heterogeniczność przestrzenną jednostek. Jednoczesna kompilacja efektów zróżnicowania (cechujących również zjawiska

przyrodnicze) oraz dynamika zachodzących zmian (jako rezultat wdrażania norm międzynarodowych, idei zrównoważonego rozwoju czy po prostu dbałości o zachowanie walorów środowiska) to aktualny problem metodyczny analityki gospodarczej w kontekście modelowania ekonometrycznego. Wyniki takich analiz stanowią natomiast o efektywności podejmowanych działań, są wytycznymi formułowania celów polityk i strategii służących realizacji promowanego paradygmatu rozwoju¹. Problemy analityczne sprzyjają poszukiwaniu nowoczesnych narzędzi ilościowych (statystycznych, ekonometrycznych), które w możliwie najwiarygodniejszy sposób odzwierciedlą rzeczywiste procesy i relacje. Jedną z takich metod jest geograficznie ważona regresja (*Geographically Weighted Regression* – GWR). Jej przewaga nad klasycznymi modelami regresji polega na możliwości uwzględnienia zróżnicowania przestrzennego (heterogeniczności przestrzennej) w relacji pomiędzy zmienną zależną a zmiennymi niezależnymi dla poszczególnych obserwacji z uwzględnieniem zależności przestrzennych.

Celem artykułu jest prezentacja możliwości zastosowania regresji ważonej geograficznie do weryfikacji zależności ekologiczno-ekonomicznej (opisanej funkcją środowiskowej krzywej Kuzneta)² w modelu, w którym zmienną zależną jest ilość zebranych zmieszanych odpadów komunalnych w kilogramach na mieszkańca, niezależnymi – PKB na osobę w PPS w cenach stałych, odpowiednio zwielokrotniona wartość zmiennej – stanowiąca odwzorowanie krzywej Kuzneta. Badaniem objęto wybrane kraje Europy w latach 1990–2011. Analizę przeprowadzono na danych uśrednionych. W modelu wykorzystano zmienne macierze wag przestrzennych. Podstawowe charakterystyki włączonych do analizy danych statystycznych zamieszczono w tabeli 1.

¹ Rada UE, *Odnowiona strategia UE dotycząca trwałego rozwoju*, Bruksela 2006.

² EKC jest krzywą wyrażającą zmianę wielkości zanieczyszczenia środowiska w zależności od wzrostu poziomu rozwoju gospodarczego (podstawowa wersja to wielomian drugiego stopnia – odwrotna litera „U”). Idea klasycznej EKC polega na poszukiwaniu punktów zwrotnych (ekstremum funkcji). Punktem przełamania EKC jest taki poziom rozwoju gospodarczego, od którego następuje spadek zanieczyszczenia środowiska, więcej o EKC por. E. Antczak, *Aplikacja przestrzennych modeli panelowych do weryfikacji hipotezy środowiskowej krzywej Kuzneta na przykładzie Polski*, „Roczniki” Kolegium Analiz Ekonomicznych SGH, z. 27, Oficyna Wydawnicza SGH, Warszawa 2012, s. 113–130; E. Antczak, *Przestrzenno-czasowe modelowanie transgranicznego przemieszczania (się) odpadów w Europie*, „Roczniki” Kolegium Analiz Ekonomicznych SGH, z. 30, Oficyna Wydawnicza SGH, Warszawa 2013, s. 9–25.

Tabela 1. Miary i zakresy dotyczące zebranych danych statystycznych

	PKB	<i>Odp</i>	<i>lPKB</i>	$(lPKB)^2$	$(lPKB)^3$	<i>lOdp</i>
<i>max</i>	99 348	830	11,51	132,4	1523,4	6,7
<i>min</i>	500	200	6,2	38,6	240,0	5,3
<i>Ve</i>	86%	28%	11%	21%	29%	5%
<i>mediana</i>	17 300	465	9,8	95,2	929,3	6,1

Odp – ilość zebranych zmieszanych w ciągu roku odpadów komunalnych w kilogramach na mieszkańca, *PKB* – produkt krajowy brutto w standardzie siły nabywczej *per capita*, ceny stałe z 2000 r., *l* – logarytm zmiennej.

Źródło: opracowanie własne.

Poza celem głównym badania, sformułowano również cele szczegółowe, które dotyczyły: 1) weryfikacji wpływu powiązań międzyregionalnych na kształtowanie się wielkości zjawiska, 2) analizy heterogeniczności jednostek i uwzględnienia tego efektu w kształtowaniu się wielkości zebranych odpadów komunalnych, 3) porównania wyników uzyskanych z modelu klasycznego i modelu GWR.

2. Opis metody

Metodycznym problemem w aplikacji klasycznego modelu regresji jest założenie o stałości przebiegu procesu w przestrzeni (homogeniczności przestrzennej):

$$y_{it} = \alpha_0 + \sum_k \alpha_k x_{itk} + \varepsilon_{it}, \quad (1)$$

gdzie: y_{it} – wartości zmiennej zależnej w i -tej lokalizacji (punkcie, jednostce, obszarze w przestrzeni) i czasie t , x_{itk} – zbiór k -tych potencjalnych zmiennych wyjaśniających kształtowanie się wielkości zmiennej zależnej, α_0 – stała, α_k – parametry strukturalne modelu, ε_{it} – składnik losowy.

Homogeniczność (stacjonarność) przestrzenna zakłada istnienie identycznych uwarunkowań procesów w każdej części analizowanego obszaru. Relacja między zmiennymi niezależnymi a zmienną objaśnianą jest zatem stała w przestrzeni i jeżeli klasyczne założenia struktury stochastycznej są spełnione, to model (1) może być estymowany MNK. Istotność statystyczna szacowanych ocen parametrów globalnego modelu regresji nie jest w tym przypadku uzależniona od

struktury przestrzennej zjawiska, co może prowadzić do uzyskania pozornie poprawnych wyników, co z kolei skutkuje ich niewłaściwą interpretacją³.

Jednakże przy założeniu przestrzennej heterogeniczności zjawiska istnieje przesłanka zastosowania modelu regresji ważonej geograficznie. Umożliwia ona uchwycenie lokalnej zmienności współczynników regresji w przestrzeni w taki sposób, że parametry modelu są szacowane osobno dla każdej jednostki przestrzennej, dla której są znane wartości zmiennych⁴, a równanie (1) ma postać:

$$y_{it} = \alpha_0(u_i, v_i) + \sum_k \alpha_k(u_i, v_i) x_{itk} + \varepsilon_{it}, \quad (2)$$

gdzie: (u_i, v_i) – współrzędne i -tej lokalizacji, $\alpha_k(u_i, v_i)$ jest realizacją funkcji $\alpha_k(u, v)$ w i -tej lokalizacji i t -tej jednostce czasu. Dla każdej i -tej lokalizacji jest tworzona macierz wag \mathbf{W} (zmienna bądź stała) i stosowana jest ważona MNK:

$$\hat{\mathbf{a}}(u_i, v_i) = (\mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{Y}, \quad (3)$$

gdzie: $\hat{\mathbf{a}}$ – wektor k -elementów, $\mathbf{W}(u_i, v_i)$ – macierz diagonalna ($n \times n$), której niezerowe elementy diagonalne w_{ij} są wagami geograficznymi odnoszącymi się do otoczenia i -tej lokalizacji określonej współrzędnymi (u_i, v_i) i lokalizacją każdego punktu, w którym dokonano obserwacji, tak że $\mathbf{W}(u_i, v_i) = \text{elementydiag}(w_{i1}, w_{i2}, \dots, w_{in})$, czyli w_{ij} oznacza wagę j -tej obserwacji dla estymacji parametrów modelu w i -tej lokalizacji określonej współrzędnymi⁵ (u_i, v_i) .

Dla ogólnego modelu regresji (1) wektor ocen parametrów strukturalnych można zapisać:

$$\hat{\mathbf{a}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (4)$$

W metodzie GWR wybór stosowanych wag przestrzennych jest oparty na schematach ważenia (*weighting function*, *kernel function*). Jedną z możliwości zakłada zastosowanie wag otrzymanych w wyniku następujących założeń dotyczących przestrzeni geograficznej⁶:

³ M. Charlton, S. Fotheringham, *Geographically weighted regression*, National Centre for Geocomputation, Maynooth 2009.

⁴ B. Suchecki, *Ekonometria przestrzenna. Podstawowe metody i modele analizy danych przestrzennych*, C.H. Beck, Warszawa 2010, s. 263.

⁵ Ibidem.

⁶ Inne schematy ważenia por. np. A.S. Fotheringham, C. Brunson, M.E. Charlton, *Quantitative geography: perspectives on spatial data analysis*, Sage, London 2000.

$$v_{ij} = \begin{cases} [1 - (d_{ij}/b)^2]^2 & \text{dla } d_{ij} < b \\ 0 & \text{dla } d_{ij} \geq b \end{cases}, \quad (5)$$

gdzie: d_{ij} – odległość euklidesowa między lokalizacją i i j w przestrzeni geograficznej, b – zasięg przestrzenny (*kernel*), w terminologii nieparametrycznej nazywany „oknem”. Jest to parametr, który określa liczbę obserwacji włączonych do estymacji współczynników związanych z każdą i -tą obserwacją tak, że wartość wag zmierza do zera wraz z rosnącą odległością między punktem danych a punktem regresji, czyli wartość wag przyjmuje zero dla dystansu pomiędzy i i j równego wartości b lub większego od przyjętej wartości „okna”. Jeżeli b dąży do nieskończoności, to dla wszystkich par punktów wagi dążą do jedności. Oceny GWR stają się zatem ekwiwalentne do ocen MNK, a obciążenie estymatora wzrasta. Kiedy „okno” staje się mniejsze, oceny parametrów będą zależały coraz bardziej od obserwacji bliższych badanej i -tej obserwacji i będą miały rosnącą wariancję. Głównym problemem metodycznym regresji ważonej geograficznie jest wybór schematu ważenia oraz odpowiedniego „okna”, gdyż to b określa stopień wygładzenia danych oraz obciążenie i wariancję związanego z nim nieparametrycznego estymatora.

Wyboru wartości b można dokonać w tzw. procedurze walidacji krzyżowej. Ustalona wartość b prowadzi do minimalizacji następującego wyrażenia⁷:

$$CV = \sum_{i=1}^n [y_i - \hat{y}_{zi}(b)]^2, \quad (6)$$

gdzie: \hat{y}_{zi} jest wartością teoretyczną (estymowaną) obserwacji y_i ; jeżeli obserwacje związane są z i -tym punktem, to pomija się je w procesie kalibracji.

Efektom zastosowania GWR są oceny parametrów wyznaczonych globalnie i osobno dla każdej lokalizacji przestrzennej (oraz zbiór miar jakości regresji). Zróznicowanie wartości ocen parametrów (lokalna zmienność) wskazuje na przestrzenną heterogeniczność zjawiska. Weryfikacji hipotezy o istotności statystycznej różnic ocen parametrów dokonuje się na podstawie odpowiednich testów parametrycznych⁸.

⁷ W.S. Cleveland, *Robust Locally Weighted Regression and Smoothing Scatterplots*, „Journal of the American Statistical Association” 1979, vol. 74(368), s. 829–836.

⁸ M. Charlton, S. Fotheringham, op.cit.

3. Zastosowanie GWR w modelowaniu procesów gospodarczych, społecznych i ekologicznych

W 1996 r. ukazała się pierwsza publikacja, w której opisano metodę GWR⁹. Następnie sformalizowany opis regresji ważonej geograficznie znalazł się w publikacji A.S. Fotheringhama z 2002 r. Rozwój GWR umożliwił zastosowanie metody w wielu dziedzinach nauki, np. w analizach rynku nieruchomości¹⁰, a także w zakresie ochrony zdrowia¹¹, socjologii¹², użytkowania powierzchni i gruntów¹³, transportu¹⁴ czy rozwoju gospodarczego¹⁵. W geografii, ekologicznie zrównoważonym rozwoju i ochronie środowiska GWR po raz pierwszy zastosowano w 2003 r. – analizie poddano zależności pomiędzy ukształtowaniem terenu a erozją brzegu rzeki¹⁶. W Polsce w 2009 r. ukazał się artykuł opisujący wyniki aplikacji metody do modelowania wyspy ciepła we Wrocławiu¹⁷. GWR

⁹ C. Brunsdon, A.S. Fotheringham, M.E. Charlton, *GWR: A Method for Exploring Spatial Nonstationarity*, „Geographical Analysis” 1996, vol. 28(4), s. 281–298.

¹⁰ M. Chrzanowska, *Przestrzenna analiza warszawskiego (wtórnego) rynku mieszkaniowego*, „Journal of The Polish Real Estate Scientific Society” 2011, vol. 19, no. 3, s. 169–180; C. Bitter, G.F. Mulligan, S. Dall’erba, *Incorporating spatial variation in housing attribute prices: a comparison of geographically weighted regression and the spatial expansion method*, „Journal of Geographical Systems” 2007, vol. 9, s. 7–27.

¹¹ W. Kisiała, *Wykorzystanie geograficznie ważonej regresji do analizy czynników kształtujących zapotrzebowanie na świadczenia przedszpitalnego ratownictwa medycznego*, „Przegląd Geograficzny” 2013, t. 85, nr 2, s. 219–242; P. Congdon, *Modelling spatially varying impacts of socioeconomic predictors on mortality outcomes*, „Journal of Geographical Systems” 2003, vol. 5, s. 161–184.

¹² L.A. Waller, L. Zhu, C.A. Gotway, D.M. Gorman, P.J. Grunewald, *Quantifying geographic variations in associations between alcohol distribution and violence: a comparison of geographically weighted regression and spatially varying coefficient models*, „Stochastic Environmental Research and Risk Assessment” 2007, vol. 21, s. 573–588.

¹³ D. Ilnicki, K. Janc, M. Kryza, M. Szymanowski, *Cechy rozmieszczenia sklepów w przestrzeni wielkomiejskiej na przykładzie Wrocławia – zastosowanie regresji ważonej geograficznie*, „Folia Oeconomica” 2011, nr 253, s. 253–268; Y. Wang, K.M. Kockelman, X. Wang, *Anticipating land use change using geographically weighted regression models for discrete response*, „Transportation Research Record” 2011, no. 2245, s. 111–123.

¹⁴ A. Páez, *Exploring contextual variations in land use and transport analysis using a probit model with geographical weights*, „Transport Geography” 2006, vol. 14, s. 167–176.

¹⁵ R. Bivand, R. Brunstad, *Regional growth in Western Europe: detecting spatial misspecification using the R environment*, „Regional Science” 2006, vol. 85(2), s. 277–297.

¹⁶ P.M. Atkinson, S.E. German, D.A. Sear, M.J. Clark, *Exploring the relations between riverbank erosion and geomorphological controls using geographically weighted logistic regression*, „Geographical Analysis” 2003, vol. 35, s. 58–82.

¹⁷ M. Szymanowski, M. Kryza, *Zastosowanie regresji ważonej geograficznie do modelowania miejskiej wyspy ciepła we Wrocławiu*, „Archiwum Fotogrametrii, Kartografii i Teledetekcji” 2009, t. 20, s. 407–419.

stosowano również do szacowania relacji pomiędzy szeroko rozumianym zanieczyszczeniem (stanem) środowiska a rozwojem gospodarczym na podstawie funkcji środowiskowej krzywej Kuzneta, np. K. Tanaka i S. Matsuoka¹⁸ opublikowali artykuł, w którym weryfikowali tę relację w przypadku gospodarki Chin; D. Ciriaci i D. Palma¹⁹ w 2010 r. zamieścili rezultaty aplikacji EKC i GWR do modelowania wyżej opisanych zależności w przypadku Włoch, a J. Videras²⁰ w przypadku Stanów Zjednoczonych. Jak dotychczas w Polsce nie opublikowano wyników badań w tym zakresie.

4. Wyniki analizy

Jednym z warunków stosowalności modelu GWR jest spełnienie założenia o zależności i heterogeniczności przestrzennej²¹. Tym samym jest to przesłanka wprowadzenia do modelu macierzy wag przestrzennych (**W**) (zob. równanie 3). W tabeli 2 zaprezentowano wyniki analizy weryfikacji występowania autokorelacji przestrzennej składnika losowego modelu klasycznego²²:

$$IODP_{it} = \alpha_0 - \alpha_1 IPKB_{it} + \alpha_2 (IPKB_{it})^2 - \alpha_3 (IPKB_{it})^3 + \varepsilon_{it} \quad (7)$$

oraz dla zmiennej zależnej ($IODP_{it}$) i zmiennej niezależnej ($IPKB_{it}$).

¹⁸ K. Tanaka, S. Matsuoka, *Reconsidering the Environmental Kuznetes Curve: Geographically Weighted Regression Approach*, Discussion Paper Series, vol. 2007-8, UK.

¹⁹ D. Ciriaci, D. Palma, *Geography, environmental efficiency and Italian economic growth: a spatially-adapted EKC*, <http://mpira.ub.uni-muenchen.de/22899> (dostęp 27.03.2014).

²⁰ J. Videras, *Spatial Patterns of Carbon Emissions in the U.S.: A Geographically Weighted Regression Approach*, Hamilton College, January 2012.

²¹ A.S. Fotheringham, C. Brunson, M.E. Charlton, *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*, Wiley, Chichester 2002.

²² W niniejszym artykule uwagę skoncentrowano głównie na możliwości aplikacji modeli GWR do analiz opartych na teorii środowiskowej krzywej Kuzneta, natomiast szczegółowy opis EKC oraz wyników uzyskanych z estymacji przestrzennych modeli panelowych dla przyjętego zestawu danych opartych na funkcji EKC por. E. Antczak, *Przestrzenno-czasowe modelowanie...*, op.cit.

Tabela 2. Wartości Morana I dla składowych regresji nieprzestrzennej i lat

	Moran I	p -value	Moran I	p -value	Moran I	p -value
	zmienna Odp (I_{Odp})		zmienna PKB (I_{PKB})		składnik losowy (reszty)	
1990	-0,04	0,51	0,22	<0,01	-0,04	0,69
	0,13	0,58	0,34	<0,01		
1995	0,11	0,02	0,32	<0,01	-0,02	0,54
	0,19	0,05	0,43	<0,01		
2000	0,18	0,01	0,32	<0,01	0,05	0,23
	0,30	0,02	0,45	<0,01		
2005	0,14	0,01	0,51	<0,01	0,12	0,04
	0,26	0,03	0,58	<0,01		
2011	0,34	0,01	0,49	0,01	0,19	0,04
	0,36	0,01	0,54	0,01		
Wartości uśrednione	0,27	0,02	0,54	0,01	0,23	0,02
	0,28	0,02	0,61	0,01		

Poziom istotności $\alpha = 0,05$. Kursywą oznaczono wartości zmiennej transformowane do postaci logarytmów. Weryfikacja istotności statystyki opiera się na testach randomizacji, więcej np. B. Suchecki, *Ekometria przestrzenna. Podstawowe metody i modele analizy danych przestrzennych*, C.H. Beck, Warszawa 2010, s. 120.

Źródło: opracowanie własne w pakiecie OpenGeoDa.

W wybranych latach analizowanego okresu (od 1995 r.)²³ ilość wytwarzanych odpadów i PKB *per capita* w wybranych państwach Europy cechowały się istotną statystycznie dodatnią autokorelacją przestrzenną, co w przestrzeni oznacza grupowanie się krajów o podobnych poziomach zjawiska obok siebie. Ponadto, z danych zawartych w tabeli 2 wynika, iż siła istotnych statystycznie zależności przestrzennych w latach 1995–2011 wzrosła (wzrost wartości statystyki Morana I średnio o 36% w 2011 r. w odniesieniu do 1995 r.). Ilość odpadów w danym kraju ma zatem istotny wpływ na wielkości tego zjawiska w krajach z nim sąsiadujących (zgodnie z przyjętą macierzą wag przestrzennych). Dodatkowo, reszty estymowanych modeli dla wybranych lat charakteryzowała statystycznie istotna zależność przestrzenna.

Analizując zróżnicowanie wielkości zmiennych (I_e w tabeli 1) i wartości statystyk Morana I (tabela 2) w poszczególnych latach i dla danych uśrednionych (średnie z lat 1990–2011), należy stwierdzić, że istnieją przesłanki aplikacji modeli GWR, tj. uwzględniających zależności i heterogeniczność przestrzenną, tu opartych na środowiskowych krzywych Kuznetsa w postaci:

$$I_{Odp_{it}} = \alpha_0(u_i, v_i) - \alpha_1(u_i, v_i)I_{PKB_{it}} + \alpha_2(u_i, v_i)[I_{PKB_{it}}]^2 - \alpha_3(u_i, v_i)[I_{PKB_{it}}]^3 + \varepsilon_{it}. \quad (8)$$

²³ Przed 1995 r. zależności przestrzenne dla zmiennej Odp były statystycznie nieistotne na poziomie $\alpha = 0,05$.

W procedurze walidacji krzyżowej (wzór 6) wybrano zmienne macierze wag przestrzennych \mathbf{W} k -najbliższych sąsiadów (uwzględniającej od pięciu do ośmiu obszarów sąsiadujących)²⁴. W rezultacie przeprowadzonej analizy opartej na modelu GWR (równanie 8) otrzymano zbiór 32 równań regresji i ocen lokalnych. Uzyskane wyniki (dotyczące głównie jakości regresji) zestawiono i porównano z rezultatami modelu klasycznego, opisanego równaniem (7). Wykorzystano uśrednione po latach dane dotyczące ilości odpadów w 32 krajach Europy (tabela 3)²⁵.

Tabela 3. Statystyki modelu GWR i klasycznego – dane uśrednione

GWR: $IOd\hat{p}_s = \alpha_0(u_i, v_i) - \alpha_1(u_i, v_i)IPKB_s + \alpha_2(u_i, v_i)[IPKB_s]^2 - \alpha_3(u_i, v_i)[IPKB_s]^3 + \varepsilon_s$						
Wartości	α_0	α_1	α_2	α_3	Reszty	R^2
Min	88,1	-37,9	2,9	-0,2	-0,3	0,53
Maks	122,1	-27,4	4,1	-0,1	0,4	0,70
Mediana	100,5	-31,1	3,4	-0,1	0,01	0,66
Maks t_{ai} (p-value)	5,3(0,01)	-2,4(0,02)	4,3(0,02)	-2,6(0,02)	AIC = -9,2, $R^2 = 0,64$, Skor. $R^2 = 0,57$, Test Shapiro-Wilka = 0,97, $p = 0,42$	
Min t_{ai} (p-value)	2,9(<0,01)	-4,3(<0,01)	2,5(<0,01)	-4,3(<0,01)		
Mediana t_{ai} (p-value)	4,7(<0,01)	-3,8(<0,01)	3,8(<0,01)	-3,9(<0,01)		
Model klasyczny: $IOd\hat{p}_s = \alpha_0 - \alpha_1 IPKB_s + \alpha_2 (IPKB_s)^2 - \alpha_3 (IPKB_s)^3 + \varepsilon_s$						
Wartości	α_0	α_1	α_2	α_3	AIC = -4,6, $R^2 = 0,57$, Skor. $R^2 = 0,54$, Test Shapiro-Wilka = 0,96, $p = 0,41$	
t_{ai} (p-value)	4,2(0,02)	-4(<0,01)	4,1(<0,01)	-4,1(<0,01)		

s – dane uśrednione

Źródło: opracowanie własne.

Na podstawie wyników zawartych w tabeli 3 można stwierdzić, że model GWR jest efektywniejszy niż model klasyczny – wyższa wartość współczynnika

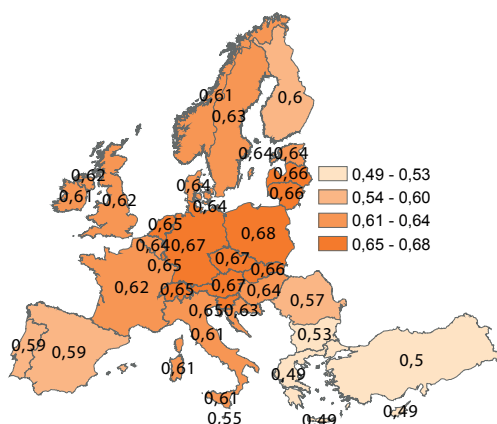
²⁴ Przeprowadzono również estymację z macierzami wag przestrzennych dla trzech i większej liczby najbliższych sąsiadów oraz z macierzą dystansu, jednakże wyniki niniejszych oszacowań z wykładniczo transformowanymi miarami odległości okazały się najbardziej efektywne.

²⁵ Problem aplikacji modelu GWR w przypadku próby panelowej GWPR (*Geographically Weighted Panel Regression*) w literaturze podmiotu nadal nie został rozwiązany, tj. są to wieloaspektowe trudności związane np. z poziomem zaawansowania procedur estymacyjnych modelu. Istnieją nieliczne opracowania naukowe na temat GWPR (D. Yu, F. Bruna, *Geographically Weighted Panel Regression*, 6th Seminar J. Paelinck, Universidad Autónoma de Madrid, 18–19 October 2013, Madrid), lecz nadal brakuje takich, w których kompleksowo usystematyzowano i udostępniono drogę oraz procedury estymacji modeli GWPR.

determinacji ($R^2_{sk.GWR} = 0,57$ v. $R^2_{sk} = 0,54$), niższa wartość kryterium AIC ($-9,2$ v. $-4,6$). Zarówno model GWR, jak i model globalnej regresji mają reszty charakteryzujące się rozkładem zbliżonym do normalnego (opisanego testem Shapiro–Wilka, na przyjętym poziomie istotności $\alpha = 0,05$). Zastosowanie modelu geograficznie ważonej regresji pozwoliło wyeliminować błędy w szacowaniu parametrów modelu wynikające z przestrzennej autokorelacji zmiennej losowej. Statystyka Morana dla reszt z GWR wynosiła 0,07 dla $p = 0,58$, wskazując na brak powiązania pomiędzy sąsiednimi obszarami.

Ponadto, dane zawarte w tabeli 3 potwierdziły, iż w analizie zależności pomiędzy rozwojem gospodarczym a wielkością odpadów komunalnych w Europie najwłaściwszą postacią funkcji EKC jest wielomian trzeciego stopnia (istotność statystyczna oszacowanych ocen parametrów strukturalnych). Własnością odwrotnych kubicznych funkcji EKC są dwa punkty przełamania. Na podstawie wartości ocen parametrów modelu klasycznego (wzór 7) wyznaczono dwa ekstrema dla wszystkich analizowanych krajów – 1212 PPS/capita i 22 027 PPS/capita (drugiego ekstremum nie przekroczyły np. Bułgaria, Cypr, Czechy, Estonia, Hiszpania, Grecja, Chorwacja, Polska, czyli rozwój gospodarczy tych krajów do 2011 r. generował wzrost produkcji odpadów).

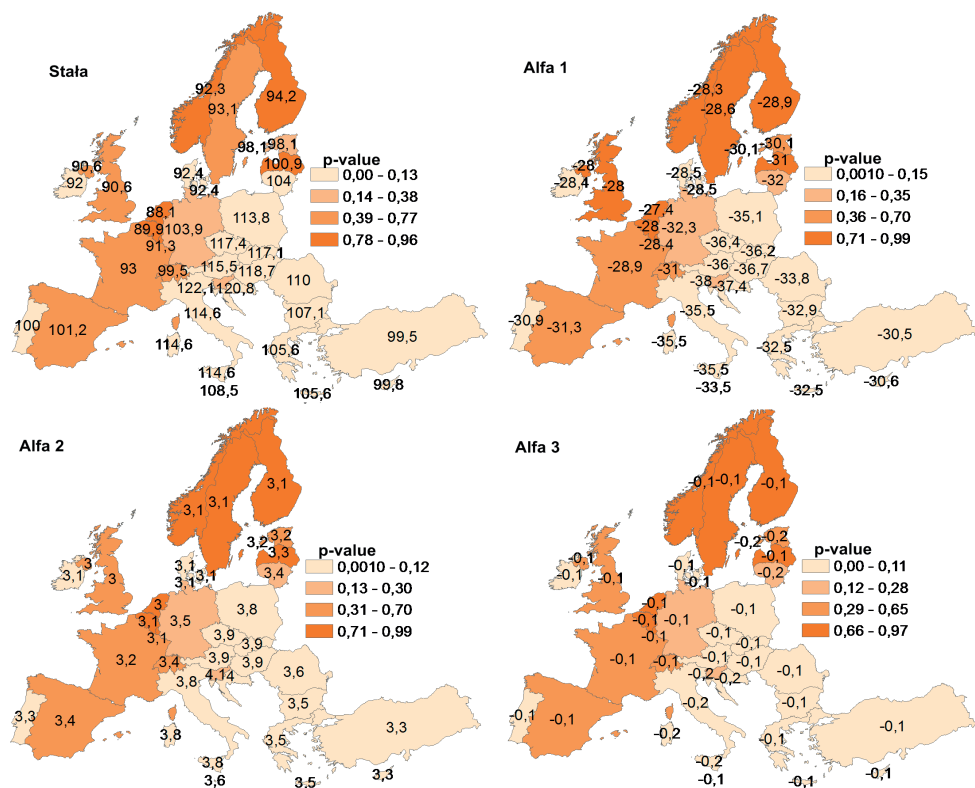
Co więcej, oszacowanie parametrów strukturalnych procedurą GWR umożliwiło wyznaczenie zbioru wartości lokalnych parametrów (dla każdego państwa osobno) – rysunki 1 i 2. Wartości lokalnych współczynników dopasowania mieszczą się w przedziale od 0,53 do 0,7 przy globalnej wartości R^2 wynoszącej 0,64 (tabela 3). Istnieją zatem takie kraje, w których zależność opisana funkcją EKC jest silna i dość dobrze wyjaśniona kształtowaniem się zmiennych niezależnych, wartość R^2 waha się od 0,65 do 0,68 (w krajach Europy Centralnej, w tym w Polsce) – rysunek 1.



Rysunek 1. Wartości lokalnych R^2 dla modelu GWR

Źródło: opracowanie własne.

Jak już wspomniano, estymacja modelu za pomocą GWR umożliwiła analizę zróżnicowania pozyskanych wyników lokalnie dla poszczególnych krajów (rysunek 2).



Na mapie dołączono liczbowe wartości ocen parametrów funkcji EKC, a skala barwna to poziom *p-value*.

Rysunek 2. Wartości lokalnych ocen parametrów modelu GWR i poziomy istotności

Źródło: opracowanie własne.

Oszacowane lokalne oceny parametrów pozwalają zatem na opis sytuacji każdego regionu osobno i weryfikację zależności przybliżonych funkcją EKC. I tak np. państwem, dla którego osiągnięto jedną z najwyższych wartości miary dopasowania $R^2 = 0,68$, była Polska (rysunek 1), a równanie EKC (8) przyjęło postać:

$$lOd\hat{p}_p = 113,8(u_i, v_i) - 35,1(u_i, v_i)IPKB_p + 3,8(u_i, v_i)[IPKB_p]^2 - 0,1(u_i, v_i)[IPKB_p]^3. \quad (9)$$

Oceny parametrów strukturalnych są istotne statystycznie na przyjętym poziomie istotności, a na podstawie ich wartości wyznaczono punkty przełamania: 1803 PPS/*capita* i 18 960 PPS/*capita*. Polska pierwszy punkt przełamania przekroczyła przed 1990 r. (i od tego momentu ilość zbieranych odpadów zależała od rozwoju gospodarczego). Natomiast wzrost dynamiki postępu technologicznego oraz wdrażanie idei równoważenia rozwoju gospodarczego przyczyniły się do przekroczenia w 2009 r. drugiego ekstremum, od którego spada ilość zbieranych corocznie odpadów.

Najniższym dopasowaniem funkcji do danych empirycznych w badanym okresie cechował się Cypr – $R^2 = 0,49$ (rysunek 1); dla jego rozwoju – po oszacowaniu ocen parametrów – krzywa EKC przyjęła postać:

$$Iod\hat{p}_c = 99,8(u_i, v_i) - 30,6(u_i, v_i)IPKB_c + 3,3(u_i, v_i)[IPKB_c]^2 - 0,1(u_i, v_i)[IPKB_c]^3. \quad (10)$$

Rozwój gospodarczy Cypru, podobnie jak Polski, już przed 1990 r. powodował wzrost ilości odpadów (5432 PPS/*capita*). Natomiast na przełomie lat 2007/2008 osiągnięto taki stopień nasycenia gospodarki (22 220 PPS/*capita*), że dalszy rozwój nie determinował wzrostu poziomu zmiennej zależnej.

Uzyskane z modelowania nieprzestrzennego i GWR wyniki dotyczące analizy relacji pomiędzy rozwojem gospodarczym a wielkością zebranych odpadów w wybranych krajach Europy w latach 1990–2011 wykazują znaczne różnice. Uzyskano dodatkowe informacje na temat prezentowanej relacji, a wyniki przestrzennej analizy ekonometrycznej nabrały sensu merytorycznego. Analogiczną analizę dotyczącą realizacji opisywanych zależności można przeprowadzić osobno dla każdego roku.

5. Podsumowanie i kierunki dalszych badań

Prowadzone badania wskazały na wyższość modelu GWR nad klasyczną funkcją regresji. Analizowano zależność pomiędzy rozwojem gospodarczym a poziomem zebranych odpadów komunalnych. Za wyższą jakością GWR przemawiają parametry stochastyczne (R^2 , AIC) oraz istotność statystyczna oszacowanych ocen parametrów (przy braku statystycznej istotności ocen parametrów modelu klasycznego, oceny lokalnych parametrów GWR wykazały istotność statystyczną dla wybranych krajów). Opisana metoda, poza weryfikacją analizowanej zależności ekonomiczno-ekologicznej, uwzględniła heterogeniczność

jednostek (oceny parametrów wyznaczonych globalnie i osobno dla każdej lokalizacji przestrzennej) oraz ich powiązania międzyregionalne (lokalizacja geograficzna, macierz wag przestrzennych). Istotnie statystycznie okazały się zatem lokalne zależności (pomimo braku istotności globalnych zależności w modelu klasycznym). Kontynuacją prowadzonych badań będą analizy ukierunkowane na rozwój metody GWR w stronę uwzględniającą charakter próby panelowej, a także na włączenie dodatkowych zmiennych niezależnych (określających również uwarunkowania polityczne i społeczne regionu) oraz aplikację przestrzennych modeli wielorównaniowych. Celem analiz pozostaną kwestie podniesienia poziomu świadomości ekologicznej w zakresie racjonalizacji konsumpcji i ograniczenia ilości zanieczyszczeń oraz skutecznej kontroli transgranicznego przemieszczania odpadów.

Bibliografia

1. Antczak E., *Aplikacja przestrzennych modeli panelowych do weryfikacji hipotezy środowiskowej krzywej Kuzneta na przykładzie Polski*, „Roczniki” Kolegium Analiz Ekonomicznych SGH, z. 27, Oficyna Wydawnicza SGH, Warszawa 2012, s. 113–130.
2. Antczak E., *Przestrzenno-czasowe modelowanie transgranicznego przemieszczania (się) odpadów w Europie*, „Roczniki” Kolegium Analiz Ekonomicznych SGH, z. 30, Oficyna Wydawnicza SGH, Warszawa 2013, s. 9–25.
3. Atkinson P.M., German S.E., Sear D.A., Clark M.J., *Exploring the relations between riverbank erosion and geomorphological controls using geographically weighted logistic regression*, „Geographical Analysis” 2003, vol. 35, s. 58–82.
4. Bitter C., Mulligan G.F., Dall’erba S., *Incorporating spatial variation in housing attribute prices: a comparison of geographically weighted regression and the spatial expansion method*, „Journal of Geographical Systems” 2007, vol. 9, s. 7–27.
5. Bivand R., Brunstad R., *Regional growth in Western Europe: detecting spatial misspecification using the R environment*, „Regional Science” 2006, vol. 85(2), s. 277–297.
6. Brunsdon C., Fotheringham A.S., Charlton M.E., *GWR: A Method for Exploring Spatial Nonstationarity*, „Geographical Analysis” 1996, vol. 28(4), s. 281–298.
7. Cai R., Yu D., Oppenheimer M., *Estimating the Effects of Weather Variations on Corn Yields using GWPR*, AAEA Meeting, Washington 2012.
8. Charlton M., Fotheringham S., *Geographically weighted regression*, National Centre for Geocomputation, Maynooth 2009.

9. Chrzanowska M., *Przestrzenna analiza warszawskiego (wtórnego) rynku mieszkaniowego*, „Journal of The Polish Real Estate Scientific Society” 2011, vol. 19, no. 3, s. 169–180.
10. Ciriaci D., Palma D., *Geography, environmental efficiency and Italian economic growth: a spatially-adapted EKC*, <http://mpr.ub.uni-muenchen.de/22899> (dostęp 27.03.2014).
11. Cleveland W.S., *Robust Locally Weighted Regression and Smoothing Scatterplots*, „Journal of the American Statistical Association” 1979, vol. 74(368), s. 829–836.
12. Congdon P., *Modelling spatially varying impacts of socioeconomic predictors on mortality outcomes*, „Journal of Geographical Systems” 2003, vol. 5, s. 161–184.
13. Fotheringham A.S., Brunsdon C., Charlton M.E., *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*, Wiley, Chichester 2002.
14. Fotheringham A.S., Brunsdon C., Charlton M.E., *Quantitative geography: perspectives on spatial data analysis*, Sage, London 2000.
15. Ilnicki D., Janc K., Kryza M., Szymanowski M., *Cechy rozmieszczenia sklepów w przestrzeni wielkomiejskiej na przykładzie Wrocławia – zastosowanie regresji ważonej geograficznie*, „Folia Oeconomica” 2011, nr 253, s. 253–268.
16. Kisiała W., *Wykorzystanie geograficznie ważonej regresji do analizy czynników kształtujących zapotrzebowanie na świadczenia przedszpitalnego ratownictwa medycznego*, „Przegląd Geograficzny” 2013, t. 85, nr 2, s. 219–242.
17. Páez A., *Exploring contextual variations in land use and transport analysis using a probit model with geographical weights*, „Transport Geography” 2006, vol. 14, s. 167–176.
18. Rada UE, *Odnowiona strategia UE dotycząca trwałego rozwoju*, Bruksela 2006.
19. Suchecki B., *Ekonometria przestrzenna. Podstawowe metody i modele analizy danych przestrzennych*, C.H. Beck, Warszawa 2010.
20. Szymanowski M., Kryza M., *Zastosowanie regresji ważonej geograficznie do modelowania miejskiej wyspy ciepła we Wrocławiu*, „Archiwum Fotogrametrii, Kartografii i Teledetekcji” 2009, t. 20, s. 407–419.
21. Tanaka K., Matsuoka S., *Reconsidering the Environmental Kuznetes Curve: Geographically Weighted Regression Approach*, Discussion Paper Series, vol. 2007-8, UK.
22. Videras J., *Spatial Patterns of Carbon Emissions in the U.S.: A Geographically Weighted Regression Approach*, Hamilton College, January 2012.
23. Waller L.A., Zhu L., Gotway C.A., Gorman D.M., Grunewald P.J., *Quantifying geographic variations in associations between alcohol distribution and violence: a comparison of geographically weighted regression and spatially varying coefficient models*, „Stochastic Environmental Research and Risk Assessment” 2007, vol. 21, s. 573–588.

24. Wang Y., Kockelman K.M., Wang X., *Anticipating land use change using geographically weighted regression models for discrete response*, „Transportation Research Record” 2011, no. 2245, s. 111–123.
25. Yu D., Bruna F., *Geographically Weighted Panel Regression*, 6th Seminar J. Paelinck, Universidad Autónoma de Madrid, 18–19 October 2013, Madrid.

* * *

Estimation of spatio-temporal environmental Kuznets curve using geographically weighted regression

Summary

The aim of this article is to present the possibility of using Geographically Weighted Regression to verify eco-economic dependences (described by the Environmental Kuznets Curve). GWR advantage over classical regression models is the ability to take into account the spatial heterogeneity in the relationship between the dependent variable (here the amount of collected municipal waste in kg/capita) and the independent variables (here, GDP/capita in PPS, constant prices, multiplied-representing Kuznets Curve function) for each observation (selected countries of Europe). In the model there were used different spatial weights matrices. The statistical significance values of local parameters estimated for each unit separately evidence the EKC hypothesis. Results depended on local factor and interregional links. The analysis was performed for the years 1990–2011 (average of data).

Keywords: Geographically Weighted Regression, spatial heterogeneity, EKC