

Wykorzystanie geograficznie ważonej regresji do analizy czynników kształtujących zapotrzebowanie na świadczenia przedszpitalnego ratownictwa medycznego

*Application of geographically weighted regression in the analysis
of factors affecting demand for emergency pre-hospital care*

WOJCIECH KISIAŁA

Katedra Ekonomiki Przestrzennej i Środowiskowej, Uniwersytet Ekonomiczny w Poznaniu,
61-875 Poznań, al. Niepodległości 10; wojciech.kisiala@ue.poznan.pl

Zarys treści. Celem artykułu jest identyfikacja czynników wpływających na korzystanie ze świadczeń przedszpitalnego ratownictwa medycznego za pomocą narzędzi statystyki przestrzennej, do których należy geograficznie ważona regresja (GWR). Rozpoczęto od sformułowania, na podstawie literatury, hipotez badawczych. Następnie przeprowadzono analizę globalnych zależności na podstawie klasycznego modelu regresji. W kolejnym kroku dokonano oceny autokorelacji przestrzennej, aby w finalnym etapie, biorąc pod uwagę heterogeniczność przestrzenną modelowanego zjawiska, opracować lokalne modele GWR.

Badanie pozwoliło pozytywnie zweryfikować hipotezy zakładające, że zapotrzebowanie na usługi świadczone przez zespoły ratownictwa medycznego związane jest ze strukturą wiekową oraz nadwyżką ludności przebywającej na danym obszarze w stosunku do ludności zamieszkującej ten obszar. Nie wykazano natomiast wpływu takich czynników jak dostępność ochrony zdrowia w pozostałych formach, poziom urbanizacji czy też sytuacja społeczno-ekonomiczna ludności.

Słowa kluczowe: czynniki wezwań ratunkowych, geograficznie ważona regresja, geografia ochrony zdrowia, ratownictwo medyczne, Polska.

Wprowadzenie

Problematyka poruszana w niniejszej pracy wpisuje się w nurt geograficznych badań dotyczących zdrowia i jego ochrony. Badania tego typu stanowią jedno z pól zainteresowań geografii medycznej – stale rozwijającej się subdyscypliny w ramach geografii człowieka (Joseph i Phillips, 1984; Mayer, 1990; Mazurkiewicz, 1994). Do najczęściej rozpatrywanych społecznych zagadnień geografii medycznej zalicza się charakterystykę ludności korzystającej z usług medycznych

oraz związane z tym analizy popytu na świadczenia ochrony zdrowia (Mazurkiewicz i Wróbel, 1990).

Obok badań dotyczących leczenia szpitalnego i ambulatoryjnej opieki zdrowotnej, wspomniane analizy geograficzno-medyczne prowadzone są także w odniesieniu do usług ratownictwa medycznego. Istotą działalności systemów ratownictwa medycznego jest pomoc w przypadkach nagłego zagrożenia życia lub zdrowia (Poździoch i Guła, 2008). Rozpoznanie czynników kształtujących zapotrzebowanie na usługi ratownictwa medycznego może znacznie usprawnić działania mające na celu zabezpieczenie medyczne ludności.

Praca służy realizacji dwu celów: poznawczego i metodologicznego. Celem poznawczym artykułu jest identyfikacja społeczno-ekonomicznych czynników warunkujących korzystanie ze świadczeń przedszpitalnego ratownictwa medycznego¹. Na potrzeby prowadzonych badań przyjęto za Z. Chojnickim i T. Czyż (1978, s. 11), że czynnikami są „pewne wielkości istotne dla kształtowania się innych wielkości, zarówno o charakterze klasyfikującym, jak i porządkującym”. Realizacja celu poznawczego polegała zatem na analizie wpływu cech o charakterze społeczno-ekonomicznym na natężenie wyjazdów zespołów ratownictwa medycznego (ZRM).

Celem metodologicznym pracy jest przedstawienie możliwości zastosowania geograficznie ważonej regresji (GWR) w badaniach przestrzennych aspektów użytkowania usług ratunkowo-medycznych. Przewaga GWR nad klasycznymi modelami regresyjnymi polega na możliwości uwzględnienia zróżnicowania przestrzennego relacji pomiędzy zmienną zależną a zmiennymi niezależnymi w poszczególnych punktach obserwacji. Model GWR ma ponadto walor praktyczny, gdyż wskazuje, które parametry są istotne w różnych lokalizacjach, co może mieć znaczenie przy prowadzeniu szeroko rozumianej polityki zdrowotnej.

Badaniami objęto Polskę w układzie powiatów, przyjmując do celów analitycznych założenie, że miasta na prawach powiatów będą traktowane łącznie z odpowiadającymi im powiatami ziemskimi². W ten sposób powstał zbiór 335 jednostek przestrzennych, które scharakteryzowano za pomocą wskaźników stanowiących podstawę do analizy przestrzennej czynników wezwań ratunkowych. Zakres czasowy opracowania ograniczono do roku 2008.

¹ W polskim systemie ratownictwa medycznego świadczenia przedszpitalne udzielane są przez ruchome jednostki systemu nazwane zespołami ratownictwa medycznego – art. 32 pkt 2 Ustawy z dnia 8 września 2006 r. o Państwowym Ratownictwie Medycznym (Dz.U.2006.191.1410 z późn. zm.).

² Wybór szczebla podziału administracyjnego, na którym prowadzono analizy, wynikał ze sposobu organizacji i funkcjonowania systemu ratownictwa medycznego w Polsce. Obszary działania poszczególnych jednostek systemu najczęściej nie pokrywały się z granicami gmin, a domykały się w granicach powiatów. Był to zatem najniższy szczebel organizacji terytorialnej z dostępnymi danymi statystycznymi dotyczącymi wyjazdów zespołów ratownictwa medycznego. Z kolei łączenia powiatów grodzkich z odpowiadającymi im powiatami ziemskimi dokonywano w sytuacji, w której siedzibą powiatu ziemskiego było miasto-powiat grodzki. Wynikało to z faktu, że na dużej części terenów powiatów ziemskich działały zespoły ratownictwa medycznego stacjonujące w miastach centralnych (powiatach grodzkich).

Układ pracy odpowiada schematowi przyjętego postępowania badawczego, które rozpoczęto od przeglądu literatury przedmiotu oraz sformułowania, na tej podstawie, hipotez badawczych. Następnie, zgodnie z procedurą stosowaną przy konstruowaniu modeli GWR, przeprowadzono analizę globalnych zależności wykorzystując klasyczny model regresji. W kolejnym kroku dokonano oceny autokorelacji przestrzennej, a w finalnym etapie, biorąc pod uwagę heterogeniczność przestrzenną modelowanego zjawiska, opracowano lokalne modele regresji, bazujące na macierzy sąsiedztwa (por. Charlton i Fotheringham, 2009).

Spółeczno-ekonomiczne determinanty korzystania ze świadczeń pomocy doraźnej

Czynniki wpływające na korzystanie ze świadczeń ochrony zdrowia od wielu lat stanowią przedmiot badań prowadzonych na gruncie nauk przede wszystkim medycznych, ale również socjologicznych, ekonomicznych czy wreszcie geograficznych.

W dostępnej literaturze studia empiryczne najczęściej koncentrują się na badaniu związków pomiędzy cechami demograficznymi ludności zamieszkującej dany obszar a użytkowaniem usług opieki zdrowotnej. J. Malczewski (1989, s. 34) stwierdza, że „wiek i płeć są czynnikami różnicującymi populację pod względem zapotrzebowania na ochronę zdrowia”. Podobnych wniosków dostarczają m.in. prace J. Eylesa i K.J. Woodsa (1983), A.E. Josepha i D.R. Phillipsa (1984), H. Powęskiej (1990), L. Roováli i R.A. Kiiveta (2006) oraz M. Widmera i innych (2009).

Do demograficznych czynników wezwań ratunkowych z pewnością zaliczyć można strukturę wiekową populacji, dla której świadczone są usługi wyjazdowej pomocy doraźnej. Liczne badania dowodzą (m.in. Cadigan i Bugarin, 1989; Rucker i inni, 1997; McConnel i Wilson, 1998; Clark i inni, 1999; Shah i inni, 2003; Ruger i inni, 2006), że wśród ludzi z najstarszych grup wiekowych występuje wyraźnie zwiększone zapotrzebowanie na tego rodzaju świadczenia. Z kolei grupa dzieci i młodzieży, ciesząc się dobrym zdrowiem lub zaspokajając potrzeby w innych formach świadczenia opieki medycznej, tylko w niewielkim stopniu korzysta z działalności przedszpitalnego ratownictwa medycznego.

Trudno natomiast stwierdzić współzależność pomiędzy liczbą wezwań a płcią pacjentów (por. Rucker i inni, 1997; Clark i inni, 1999; Shah i inni, 2003). Z jednej strony mężczyźni częściej ulegają wypadkom w pracy oraz w ruchu komunikacyjnym, z drugiej jednak strony najwięcej wyjazdów ratunkowych kierowanych jest do ludności w podeszłym wieku, wśród której zdecydowaną przewagę mają kobiety.

Istotne znaczenie w analizie czynników korzystania z ochrony zdrowia ma status społeczny oraz warunki ekonomiczne potencjalnych pacjentów. Dostępna literatura opisuje wpływ takich cech jak stan cywilny, sytuacja rodzinna, przynależność etniczna, wierzenia, pozycja zawodowa, wykształcenie, wielkość dochodów, a także poziom i warunki życia, na zachorowalność oraz potrzeby

zdrowotne ludności (Eyles i Woods, 1983; Joseph i Phillips, 1984; Picheral, 1987; Grochowski, 1988; Powęska, 1990). Na ogół częstość użytkowania świadczeń medycznych zwiększa się wraz z poprawą warunków społecznych i ekonomicznych życia. Gorzej sytuowane osoby (słabiej wykształcone, mniej zamożne itd.) odczuwają trudności w dotarciu do placówek opieki medycznej oraz niechęć do uświadamiania sobie ryzyka chorobowego. Przeprowadzone badania dowodzą, że istnieje „ścisły związek pomiędzy stopniem ubóstwa a podatnością na choroby zakaźne, zwiększoną śmiertelnością, niedowagą dzieci czy rozwojem schorzeń psychicznych” (Grochowski i Kowalczyk, 1987, s. 9).

W przypadku usług z zakresu ratownictwa medycznego zakłada się występowanie odwrotnych relacji (Klingbeil, 1987; Cadigan i Bugarin, 1989; Rucker i inni, 1997; Lowthian i inni, 2011a). Wśród osób o niskiej pozycji społecznej i ekonomicznej poprzez ograniczenie profilaktyki i bieżących kontaktów z lekarzem następuje znaczny wzrost zapotrzebowania na świadczenia pomocy doraźnej. Z kolei świadoma ryzyka chorobowego ludność o wysokim statusie społeczno-ekonomicznym, rzadziej zaniedbuje stan zdrowia i podejmuje leczenie w przychodniach, ośrodkach zdrowia, szpitalach, czy też sanatoriach, często korzystając również z usług prywatnego (płatnego) sektora opieki medycznej.

Generalizując powyżej opisane zależności można dojść do wniosku, że jednym z czynników wezwań ratunkowych są niezaspokojone potrzeby zdrowotne, szczególnie w zakresie leczenia na poziomie podstawowym (Lang i inni, 1997; Toloo i inni, 2011). Często przyjmuje się założenie, że sprawne działanie sektora podstawowej opieki zdrowotnej prowadzi do redukcji kolejek do lekarzy specjalistów, a także zapotrzebowania na świadczenia ratownictwa medycznego. Wprawdzie badania D. Oterino de la Fuente i innych (2007) nie potwierdzają występowania tego typu relacji³, jednak wielu autorów dowodzi, że w polskich warunkach pogotowie ratunkowe często wykorzystywane jest w sposób nieuprawniony, wypełniając w ten sposób głównie zadania lekarzy rodzinnych (Włodarczyk, 1998; Głębocki i inni, 2000; Ryś, 2002; Leki, 2006). Działania organizacyjne regulujące zakres świadczeń udzielanych w ramach podstawowej opieki zdrowotnej w założeniu mają ograniczyć liczbę nieuzasadnionych wyjazdów zespołów ratownictwa medycznego. Zatem dostęp do tzw. leczenia otwartego (ale również zamkniętego) może stanowić ważny czynnik wezwań ratunkowych (por. Lowthian i inni, 2011a).

Osobną grupę uwarunkowań stanowią „kompleksy patogenne” związane z urbanizacją, industrializacją i życiem miejskim (Picheral, 1987; Malczewski, 1989; Peacock i Peacock, 2006). W miastach występuje podwyższona zapadalność na choroby cywilizacyjno-społeczne, w tym wywołane różnego rodzaju urazami i stresem. Dlatego ludność miejska jest szczególnie narażona na sytuacje

³ Autorzy w konkluzji stwierdzają, że większemu wykorzystaniu usług lekarskich podstawowej opieki zdrowotnej nie towarzyszy spadek zapotrzebowania na świadczenia udzielane w szpitalnych oddziałach ratunkowych.

nagłego zagrożenia zdrowotnego, a tym samym predestynowana do korzystania z usług ratownictwa medycznego.

W analizach użytkowania przedszpitalnego ratownictwa medycznego często zwraca się uwagę na osoby niemieszkające na obszarach działania poszczególnych jednostek ratunkowych. Konieczność obsługi ratunkowo-medycznej zwiększonej populacji dotyczy szczególnie zespołów ratownictwa medycznego działających w regionach turystycznych czy w okolicach głównych szlaków i węzłów komunikacyjnych⁴. Zatem nadwyżka ludności przebywającej na danym terenie w stosunku do ludności go zamieszkującej może być czynnikiem ponadproporcjonalnego zapotrzebowania na świadczenia wyjazdowej pomocy doraźnej.

Na zakończenie należy dodać, że w literaturze często spotyka się ostrzeżenia przed nadmiernym determinizmem w badaniach nad zachorowalnością i użytkowaniem świadczeń zdrowotnych. Zdrowie populacji nie jest prostym i bezpośrednim odbiciem warunków społecznych i ekonomicznych, a na zapotrzebowanie na opiekę medyczną wpływają również trudno kwantyfikowalne czynniki związane z przyzwyczajeniami, tradycją czy kulturą (por. Eyles i Woods, 1983; Joseph i Phillips, 1984; Wysocki i Miller, 2003). Specyfika działalności ratownictwa medycznego dodatkowo komplikuje analizy, gdyż o wezwaniu pomocy ratunkowej często decyduje element losowy (przewidywalne stany chorobowe powinny być leczone w ramach innych form opieki medycznej). I choć opisanym w tej części współzależnościom trudno zarzucić nielogiczność, to podczas konstruowania modeli przyczynowo-skutkowych nie należy oczekiwać wysokich wartości współczynników determinacji (por. Mayer, 1982).

Hipotezy badawcze, charakterystyka zmiennych i ich wskaźników

Badanie społeczno-ekonomicznych czynników wpływających na korzystanie ze świadczeń przedszpitalnego ratownictwa medycznego rozpoczęto od sformułowania, na podstawie studiów literaturowych, następujących hipotez badawczych.

- H1: Zapotrzebowanie na usługi świadczone przez ZRM związane jest ze strukturą wiekową ludności;
- H2: Zapotrzebowanie na usługi świadczone przez ZRM związane jest z dostępnością opieki medycznej świadczonej w pozostałych formach;
- H3: Zapotrzebowanie na usługi świadczone przez ZRM związane jest z poziomem urbanizacji;
- H4: Zapotrzebowanie na usługi świadczone przez ZRM związane jest z sytuacją ekonomiczną ludności;
- H5: Zapotrzebowanie na usługi świadczone przez ZRM związane jest z poziomem wykształcenia ludności;

⁴ por. m.in. uwagi prezydium Naczelnej Izby Lekarskiej do projektu rozporządzenia ministra zdrowia w sprawie algorytmu podziału środków na finansowanie zadań zespołów ratownictwa medycznego pomiędzy poszczególne województwa (Gazeta Lekarska, nr 7-8, 2007, s. 14).

H6: Zapotrzebowanie na usługi świadczone przez ZRM związane jest z nadwyżką ludności przebywającej na danym obszarze w stosunku do ludności zamieszkującej ten obszar (np. w związku z natężeniem ruchu turystycznego).

W celu weryfikacji powyższych hipotez posłużono się analizą regresji i korelacji, za pomocą których „można potwierdzić fakt występowania lub niewystępowania związku między badanymi elementami”, a także „określić charakter tego związku, jego siłę i istotność” (Parysek i Wojtasiewicz, 1979, s. 51). Istotnym etapem badania było wyznaczenie poprzez analizę korelacyjną modeli regresyjnych, które pozwoliłyby odpowiedzieć na pytania, czy i w jakim stopniu wybrane cechy społeczno-ekonomiczne wpływają na wielkość potrzeb w zakresie przedszpitalnego ratownictwa medycznego.

Za zmienną zależną (skutkową, podlegającą wpływom) przyjęto liczbę wyjazdów ZRM na 1000 mieszkańców (WYJ), jako wskaźnik empiryczny najlepiej obrazujący zapotrzebowanie na usługi świadczone przez ZRM. Następnie wybrano wskaźniki charakteryzujące poszczególne powiaty w kategoriach określonych w hipotezach. W ten sposób powstała lista 17 potencjalnych zmiennych przyczynowych (niezależnych, objaśniających), a więc takich, które na początku badań zostały przyjęte warunkowo, a o ich ostatecznej akceptacji bądź odrzuceniu decydował stopień istotności dla dalszego trybu postępowania.

Na tym etapie postępowania badawczego starano się uwzględnić jak najwięcej cech (wskaźników), zdając sobie sprawę, że część z nich może nie wykazać związku z badanym zjawiskiem (a tym samym umożliwić odrzucenie zakładanych hipotez) lub wносить do analizy podobne informacje (tak jak silnie skorelowane wskaźniki gęstości zaludnienia i odsetka terenów zurbanizowanych w strukturze użytkowania terenu). Wykaz oraz podstawowe statystyki analizowanych wskaźników reprezentujących zmienną zależną i potencjalne zmienne niezależne przedstawiono w tabeli 1.

WYJ – liczba wyjazdów ZRM na 1000 ludności / number of ambulance calls per 1000 head of population;

DEM1 – % ludności w wieku 0-19 lat / percentage of population at ages 0-19;

DEM2 – % ludności w wieku 60+ / percentage of population 60+;

DEM3 – % ludności w wieku 45+ / percentage of population 45+;

ZDR1 – liczba porad udzielonych w POZ per capita / number of consultations provided in primary medical care per capita;

ZDR2 – liczba lekarzy na 10 000 ludności / number of doctors per 10,000 head of population;

ZDR3 – liczba łóżek w szpitalach ogólnych na 10 000 ludności / number of beds in general hospitals per 10,000 head of population;

URB1 – gęstość zaludnienia (osoby na km²) / population density (persons per km²);

URB2 – % terenów zurbanizowanych w strukturze użytkowania terenu / percentage in land use structure accounted for by urbanized areas;

URB3 – % ludności zatrudnionej w przemyśle / percentage of population employed in industry;

URB4 – % ludności zatrudnionej w usługach / percentage of population employed in services;

EKO1 – przeciętne miesięczne wynagrodzenia brutto / average monthly gross wages and salaries;

EKO2 – dochody budżetów gmin i miast na prawach powiatu z PIT per capita / budget revenue of gminas and cities enjoying powiat rights expressed as per capita personal income tax per;

Tabela 1. Podstawowe statystyki wskaźników reprezentujących zmienną zależną oraz potencjalne zmienne niezależne (N=335)

Summary statistics of the indexes representing the dependent variable and independent variables (N=335)

Potencjalne czynniki związane z: <i>Potential factors related to:</i>	Wskaźnik <i>Variable</i>	Średnia <i>Mean</i>	Mediana <i>Median</i>	Odch. stand. <i>Std. deviation</i>	Minimum <i>Minimum</i>	Maksimum <i>Maximum</i>
	WYJ	81,11	75,10	22,93	25,57	208,39
sytuacją demograficzną <i>demographic situation</i>	DEM1	22,16	23,59	2,28	14,74	30,46
	DEM2	18,56	17,79	2,25	11,76	27,63
	DEM3	40,63	39,90	2,80	31,63	50,52
dostępnością ochrony zdrowia <i>access to health care</i>	ZDR1	3,96	3,99	0,61	2,22	6,67
	ZDR2	20,48	13,52	6,85	3,37	52,16
	ZDR3	48,10	38,88	19,24	0,00	119,50
poziomem urbanizacji <i>urbanization</i>	URB1	121,96	89,71	509,17	19,33	4 181,54
	URB2	4,00	3,45	10,60	0,39	73,16
	URB3	29,61	29,98	11,97	1,74	73,39
	URB4	50,50	39,82	12,45	18,97	83,31
sytuacją ekonomiczną ludności <i>people's economic status</i>	EKO1	3 158,48	2 537,65	400,66	1 992,51	5 432,42
	EKO2	644,92	383,43	235,32	196,68	2 055,51
	EKO3	13,15	13,51	10,06	0,91	61,03
	EKO4	52,06	53,08	23,41	19,47	166,45
poziomem wykształcenia <i>level of education</i>	EDU1	8,38	5,35	2,57	3,26	21,54
ruchem turystycznym <i>tourist movement</i>	TUR1	512,80	219,88	784,13	0,00	7 363,77
	TUR2	148,54	49,78	418,13	0,00	3 985,79

EKO3 – liczba bezrobotnych na 1000 ludności / number of unemployed persons per 1000 head of population;

EKO4 – wydatki gmin i miast na prawach powiatu na zasiłki i inne świadczenia opieki społecznej per capita / expenditure from the budgets of gminas and cities enjoying powiat rights going on social welfare benefits expressed per capita;

EDU1 – % ludności z wykształceniem wyższym (dane za 2002 r.) / percentage of population with higher education (2002);

TUR1 – liczba korzystających z noclegów na 1000 ludności / number of tourists accommodated per 1000 head of population;

TUR2 – liczba udzielonych noclegów na 100 ludności / accommodation provided per 100 head of population.

Obliczenia własne na podstawie danych Ministerstwa Zdrowia (WYJ) oraz GUS (pozostałe).

Own elaboration based on data from the Ministry of Health (WYJ variable) and the Central Statistical Office of Poland (other variables).

Następnie wykorzystano analizę korelacyjną do redukcji pierwotnie uwzględnionych (potencjalnych) zmiennych niezależnych. W tym celu obliczono współczynniki korelacji pomiędzy wszystkimi zmiennymi, a z uzyskanych wyników skonstruowano macierz korelacyjną (tab. 2).

Przeprowadzona analiza pozwoliła w pierwszej kolejności wyeliminować z dalszych badań zmienne ZDR1, ZDR3, URB3, EKO3 i EKO4, jako nieistotne statystycznie w relacji ze zmienną zależną WYJ (przy założonym wysokim poziomie istotności $p = 0,001$). Dalsza redukcja związana była z identyfikacją zmiennych niezależnych wzajemnie skorelowanych i wykluczeniu tych, które dostarczały najmniej unikatowej informacji. Założono, że o wzajemnym skorelowaniu zmiennych świadczył współczynnik korelacji $r > 0,7$. W ten sposób wyeliminowano zmienne DEM1, DEM2, URB2, EKO1, EDU1 oraz TUR2, a do kolejnego etapu analizy pozostała następująca lista zmiennych:

- 1) % ludności w wieku 45 lat i więcej (DEM3) – jako wskaźnik struktury wiekowej ludności;
- 2) liczba lekarzy na 10000 ludności (ZDR2) – jako wskaźnik dostępności opieki medycznej;
- 3) gęstość zaludnienia (URB1) oraz
- 4) % ludności zatrudnionej w usługach (URB4) – jako wskaźniki poziomu urbanizacji;
- 5) dochody budżetów miast i gmin na prawach powiatu z PIT *per capita* (EKO2) – jako wskaźnik sytuacji ekonomicznej ludności;
- 6) liczba korzystających z noclegów na 1000 ludności (TUR1) – jako wskaźnik nadwyżki ludności przebywającej na danym obszarze w stosunku do ludności zamieszkującej ten obszar.

Ze względu na wyeliminowanie zmiennej EDU1 (z powodu dużego stopnia korelacji ze zmiennymi ZDR2, URB4 oraz EKO2) nie potwierdzono prawdziwości hipotezy H_5 , choć współczynnik korelacji pomiędzy tą zmienną a zmienną skutkową WYJ wynoszący 0,29 należał do największych w badanym zbiorze. Wskazywał jednak na odwrotny kierunek wpływu w stosunku do założeń wynikających ze studiów literaturowych.

Analiza czynników wezwań ratunkowych za pomocą modelu klasycznej regresji wielokrotnej

Globalny (klasyczny) model regresji⁵ umożliwiający określenie statystycznego związku o charakterze liniowym pomiędzy zmienną zależną a większą liczbą zmiennych niezależnych może zostać zapisany z postaci:

⁵ Szczegółowe informacje na temat metodologicznych podstaw analizy regresji wraz z opisem procedury postępowania w celu jej zastosowania i wyliczenia modeli zawierają publikacje m.in. E. Nowosielskiej (1977), H. Rogackiego (1980), E. Malca (1980), A.S. Fotheringhama i innych (2002) oraz M. Charltona i A.S. Fotheringhama (2009).

Tabela 2. Macierz współczynników korelacji zmiennej zależnej oraz zmiennych niezależnych
Correlation matrix for variables

	WYJ	DEM1	DEM2	DEM3	ZDR1	ZDR2	ZDR3	URB1	URB2	URB3	URB4	EKO1	EKO2	EKO3	EKO4	EDU1	TUR1	TUR2
WYJ	1,00	-0,45	0,28	0,47	0,17	0,27	0,16	0,21	0,21	0,03	0,31	0,22	0,26	-0,03	0,06	0,29	0,21	0,18
DEM1	-0,45	1,00	-0,64	-0,87	-0,10	-0,57	-0,33	-0,50	-0,57	-0,17	-0,51	-0,44	-0,60	0,26	0,10	-0,60	-0,10	-0,06
DEM2	0,28	-0,64	1,00	0,85	0,18	0,37	0,30	0,28	0,30	-0,36	-0,02	0,14	0,16	0,03	-0,13	0,28	-0,02	-0,04
DEM3	0,47	-0,87	0,85	1,00	0,23	0,42	0,32	0,35	0,40	-0,09	0,24	0,24	0,32	-0,05	0,00	0,37	0,07	0,07
ZDR1	0,17	-0,10	0,18	0,23	1,00	0,04	0,04	-0,02	-0,03	0,00	-0,11	-0,03	-0,11	0,11	0,23	-0,08	-0,03	0,00
ZDR2	0,27	-0,57	0,37	0,42	0,04	1,00	0,68	0,42	0,45	0,01	0,58	0,47	0,58	-0,22	-0,16	0,73	0,19	0,11
ZDR3	0,16	-0,33	0,30	0,32	0,04	0,68	1,00	0,27	0,27	-0,09	0,30	0,18	0,23	-0,08	0,01	0,31	0,21	0,13
URB1	0,21	-0,50	0,28	0,35	-0,02	0,42	0,27	1,00	0,97	0,19	0,46	0,38	0,63	-0,29	-0,06	0,44	0,02	-0,01
URB2	0,21	-0,57	0,30	0,40	-0,03	0,45	0,27	0,97	1,00	0,26	0,48	0,43	0,68	-0,33	-0,13	0,46	0,00	-0,04
URB3	0,03	-0,17	-0,36	-0,09	0,00	0,01	-0,09	0,19	0,26	1,00	0,19	0,23	0,34	-0,44	-0,06	0,09	-0,11	-0,12
URB4	0,31	-0,51	-0,02	0,24	-0,11	0,58	0,30	0,46	0,48	0,19	1,00	0,41	0,69	-0,27	0,02	0,72	0,43	0,34
EKO1	0,22	-0,44	0,14	0,24	-0,03	0,47	0,18	0,38	0,43	0,23	0,41	1,00	0,70	-0,32	-0,22	0,58	0,06	-0,01
EKO2	0,26	-0,60	0,16	0,32	-0,11	0,58	0,23	0,63	0,68	0,34	0,69	0,70	1,00	-0,50	-0,22	0,84	0,14	0,05
EKO3	-0,03	0,26	0,03	-0,05	0,11	-0,22	-0,08	-0,29	-0,33	-0,44	-0,27	-0,32	-0,50	1,00	0,29	-0,34	-0,07	0,00
EKO4	0,06	0,10	-0,13	0,00	0,23	-0,16	0,01	-0,06	-0,13	-0,06	0,02	-0,22	-0,22	0,29	1,00	-0,22	0,03	0,05
EDU1	0,29	-0,60	0,28	0,37	-0,08	0,73	0,31	0,44	0,46	0,09	0,72	0,58	0,84	-0,34	-0,22	1,00	0,23	0,12
TUR1	0,21	-0,10	-0,02	0,07	-0,03	0,19	0,21	0,02	0,00	-0,11	0,43	0,06	0,14	-0,07	0,03	0,23	1,00	0,88
TUR2	0,18	-0,06	-0,04	0,07	0,00	0,11	0,13	-0,01	-0,04	-0,12	0,34	-0,01	0,05	0,00	0,05	0,12	0,88	1,00

Na szarym tle oznaczono istotne statystycznie wartości współczynników korelacji przy założonym poziomie istotności $p=0,001$, pogrubioną czcionką zaś wyróżniono współczynniki korelacji większe lub równe 0,7. Objasnienia zmiennych jak w tabeli 1.

The gray area represents statistical significance values for correlations coefficients with the assumed level of statistical significance set at $p=0.001$, while correlation coefficients >0.7 are bolded. Explanations of variables as in Table 1.

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad (\text{dla } i = 1, \dots, n),$$

gdzie y_i oznacza wartość zmiennej zależnej dla i -tej obserwacji (lokalizacji), x_{1i} , x_{2i} , ..., x_{ki} – wartości zmiennych niezależnych dla tej samej obserwacji (lokalizacji), β_0 – wyraz wolny, natomiast β_1 , β_2 , ..., β_k oznaczają współczynniki regresji (parametry funkcji), które wskazują o ile średnio zmieni się zmienna zależna, gdy zmienna niezależna wzrośnie o jednostkę. Z kolei ε_i to tzw. składnik losowy nazywany błędem modelu.

Ponieważ błąd modelu jest nieobserwowalny, jego oszacowanie stanowi reszta z regresji, czyli różnica między obserwowanymi (empirycznymi) wielkościami zmiennej zależnej y_i a wyliczonymi z uzyskanego równania regresji oznaczanymi przez \hat{y}_i (por. Nowosielska, 1977; Parysek i Wojtasiewicz, 1979; Charlton i Fotheringham, 2009).

Estymacja parametrów funkcji regresyjnej odbywa się najczęściej metodą najmniejszych kwadratów, zgodnie z którą minimalizowana jest wartość sumy kwadratów różnic pomiędzy rzeczywistymi wartościami zmiennej zależnej y_i i jej estymatorem \hat{y}_i .

Na potrzeby niniejszego badania wykorzystano metodę regresji krokowej, dzięki której możliwa była identyfikacja tylko tych zmiennych, które najbardziej wpływały na zmienną zależną (WYJ). Zastosowano eliminację zmiennych *a posteriori*, zgodnie z którą w pierwszym etapie do modelu regresji przyjęto wszystkie potencjalne zmienne objaśniające, a następnie wykluczono z niego te, które nie spełniały kryteriów istotności statystycznej (por. Nowosielska, 1977). Ze względu na złożoność obliczeń regresji krokowej modelowanie przeprowadzono przy użyciu komputerowego pakietu statystycznego STATISTICA.

Z początkowo uwzględnionych sześciu zmiennych niezależnych (DEM3, ZDR2, URB1, URB4, EKO2 oraz TUR1), po kolejnych krokach wstecznej eliminacji, w ostatecznej wersji modelu pozostały dwie (DEM3 oraz TUR1), a poszukiwane równanie zależności między zmiennymi przybrało postać:

$$\hat{y} = -72,74 + 3,71 \times \text{DEM3} + 0,005 \times \text{TUR1}.$$

Parametry funkcji regresji wykazywały istotność statystyczną (na poziomie $p < 0,001$), a współczynnik determinacji R^2 wynosił 0,25. Oznacza to, że skonstruowany model wyjaśniał 25% zmian zmiennej objaśnianej. Wartość skorygowanego R^2 (uwzględniającego liczbę zmiennych niezależnych w modelu) nie odbiegała znacząco od ogólnego współczynnika. Podstawowe informacje o oszacowanym modelu regresji zawarto w tabeli 3.

Z modelu regresyjnego wynika, że na wyjaśnianą część zmienności liczby wyjazdów ZRM na 1000 mieszkańców (zmienna zależna WYJ) największy wpływ miała struktura wiekowa ludności. Równanie regresji wskazuje, że im więcej ludzi starszych zamieszkuje daną jednostkę przestrzenną (w wieku 45 lat i więcej – zmienna DEM3), tym większe zapotrzebowanie na usługi przedszpitalnego ratownictwa medycznego. Dodatkowo, choć w dużo mniejszym stopniu,

zmienna objaśniana uwarunkowana była liczbą korzystających z noclegów na 1000 mieszkańców (zmienna TUR1). Zmienna ta wykazywała również charakter stymulanty w odniesieniu do zmiennej zależnej. Związane to było w głównej mierze z użytkowaniem wyjazdowej pomocy doraźnej przez osoby goszczące w atrakcyjnych turystycznie miejscowościach wypoczynkowych.

Tabela 3. Podstawowe statystyki modelu regresji wielokrotnej krokowej wstecznej
Summary statistics for the multivariate stepwise regression model with backward elimination

N = 335	$R^2 = 0,249$; Skorygowany / <i>Adjusted</i> $R^2 = 0,244$; Stopnie swobody / <i>Degrees of freedom</i> : 332; Błąd standardowy estymacji / <i>Standard error of estimation</i> : 19,935; Kryterium Informacyjne Akaike / <i>Akaike's Information Criterion (AIC)</i> : 2958,65			
	Współczynnik <i>Coefficient</i> $\hat{\beta}$	Błąd standardowy <i>Standard error of</i> $\hat{\beta}$	Statystyka <i>t</i> <i>t-Statistics</i>	Prawdopodobieństwo <i>Probability</i>
Wyraz wolny <i>Intercept</i>	-72,7393	15,64393	-4,64968	0,000005*
DEM3	3,7107	0,39118	9,48585	0,000000*
TUR1	0,0052	0,00139	3,76273	0,000199*

* istotne statystycznie na poziomie $p=0,001$ / statistically significant at the 0.001 level.

Obliczenia własne. / Own elaboration.

Przeprowadzona analiza klasycznej regresji wielokrotnej pozwoliła pozytywnie zweryfikować sformułowane na początku badań hipotezy H1 oraz H6. Eliminacja zdecydowanej większości potencjalnych zmiennych niezależnych związana z brakiem statystycznie potwierdzonej zależności lub istotności powiązań uniemożliwiła natomiast konfirmację pozostałych hipotez (H2, H3, H4 i H5). Należy przypuszczać, że w początkowej fazie funkcjonowania systemu ratownictwa medycznego w Polsce⁶ struktura wyjazdów nie odzwierciedlała uzasadnionego zapotrzebowania na usługi ratownictwa medycznego, stąd słaba moc wyjaśniająca konstruowanych modeli, a co za tym idzie trudności w weryfikacji hipotez. W miarę kształtowania się racjonalnych postaw wobec korzystania z usług ZRM, czynniki wyróżnione w przedstawionych hipotezach powinny nabierać większego znaczenia, a badania prowadzone w kolejnych latach dostarczać interesujących wniosków.

⁶ Obecnie funkcjonujący w Polsce system Państwowego Ratownictwa Medycznego działa od początku 2007 r.

Autokorelacja przestrzenna zmiennej zależnej

W klasycznych modelach regresji przyjmowane jest założenie, że w każdej uwzględnionej w badaniach lokalizacji (w każdym i -tym punkcie obserwacji) występują stałe (takie same) relacje pomiędzy zmienną zależną a zmiennymi niezależnymi. Założenie to sprawdza się wyłącznie w sytuacji, gdy obserwacje w poszczególnych lokalizacjach są od siebie niezależne, co w statystyce określa się brakiem autokorelacji przestrzennej. Tymczasem, zgodnie z regułą Toblera, pomiędzy obiektami w przestrzeni (jednostkami obserwacji) występują interakcje, a ich siła jest tym większa, im bliżej siebie są położone (por. Longley i inni, 2008). Zatem prawidłowe zbadanie rzeczywistych współzależności wymaga uprzedniej oceny autokorelacji przestrzennej analizowanego zjawiska.

Jedną z najczęściej stosowanych miar autokorelacji przestrzennej jest statystyka I -Morana⁷. Wskaźnik ten przyjmuje wartości: (1) dodatnie, w sytuacji gdy istnieje podobieństwo w zakresie analizowanej cechy pomiędzy sąsiadującymi ze sobą obiektami (występują skupienia zbliżonych wartości danej cechy), (2) ujemne, w przypadku braku takiego podobieństwa (wysokie wartości cechy sąsiadują z niskimi) oraz (3) bliskie zeru, kiedy wartości cechy rozmieszczone są losowo i niezależnie w przestrzeni (brak autokorelacji).


Analizę potencjalnej autokorelacji przestrzennej zmiennej zależnej WYJ (liczba wyjazdów ZRM na 1000 ludności) przeprowadzono na podstawie statystyki I -Morana, wykorzystując do obliczeń program CrimeStatIII⁸. Globalny indeks I -Morana wyniósł 0,26, co wskazywało na wysoką dodatnią autokorelację przestrzenną zmiennej, a prawdopodobieństwo, że była ona wynikiem przypadku, nie przekraczało 0,1% ($p < 0,001$).

W celu oceny zasięgu autokorelacji wykreślono korelogramy przedstawiające wartości wskaźnika I -Morana dla określonych przedziałów odległości pomiędzy porównywanymi lokalizacjami. Korelogram sporządzono zarówno dla skumulowanych, jak i indywidualnych przedziałów odległości (por. ryc. 1 i 2).

Korelogram I -Morana wyliczony dla skumulowanych odstępów (ryc. 1) przyjmował wyłącznie wartości dodatnie. Szczególnie wysokie wartości ($I > 0,3$) wykazywał dla małych odległości, wskazując na bardzo wysoką dodatnią autokorelację. Zwraca uwagę fakt, że w prawie całym analizowanym przedziale odległości (oprócz odcinka między 40 a 100 km) wykres funkcji I mieścił się poniżej maksymalnej symulowanej wartości. Prawdopodobieństwo, że taki układ jest przypadkowy było w prawie całym przedziale odległości nie większe od 1%.

⁷ Szczegółowe charakterystyki wskaźników wykorzystywanych do testowania autokorelacji przestrzennej, w tym statystyki I -Morana, wraz ze sposobami ich obliczania przedstawione są w pracy pod redakcją B. Sucheckiego (2010).

⁸ Program CrimeStat wraz z dokumentacją teoretyczną i techniczną dostępny jest na stronach internetowych ICPSR (Inter-University Consortium for Political and Social Research) – <http://www.icpsr.umich.edu/CrimeStat/> (30.09.2012).




Ryc. 1. Korelogram I -Morana obliczony dla skumulowanych 40 odstępów w całym zakresie odległości między analizowanymi lokalizacjami

Górny wykres reprezentuje wyłącznie korelogram empiryczny (z danych), dolny zawiera także przybliżone przedziały ufności I wyliczone z 500 symulacji (permutacji wykonanych metodą Monte Carlo). Zakres wyznaczony kolorem zielonym obejmuje przedział między minimalnym i maksymalnym I , jasnożółtym – 99% przedział ufności (pomiędzy $I_{0,005}$ a $I_{0,995}$), natomiast ciemnożółtym – 95% przedział ufności (pomiędzy $I_{0,025}$ a $I_{0,975}$). Ponieważ ekstremalne wartości symulowanego I były bardzo duże lub małe, aby zachować czytelność wykresu, zostały one ograniczone do zakresu $\{-0,5 - 0,5\}$.

Moran's I correlogram for the aggregated 40 lags in the whole range of distances between the analysed locations

The upper graph represents only the empirical correlogram (based on the data) while the lower graph also includes the rough confidence intervals I , calculated on the basis of 500 simulations (Monte Carlo permutation). The range marked in green includes that between the minimal and maximal I , while the light yellow colour represents the 99% confidence interval (between $I_{0,005}$ and $I_{0,995}$), and the dark green colour the 95% confidence interval (between $I_{0,025}$ and $I_{0,975}$). Because the extreme values of the simulated I were either too high or too low, these had to be limited to the range $\{-0.5 - 0.5\}$ in order to ensure clarity of the graph.



Ryc. 2. Korelogram I -Morana obliczony dla indywidualnych 40 odstępów w całym zakresie odległości między analizowanymi lokalizacjami. Objasnienia jak na rycinie 1
 Moran's I correlogram for the separate 40 lags in the whole range of distances between the analysed locations. Explanation as in Fig. 1

Z kolei obliczenia I dla indywidualnych przedziałów odległości (ryc. 2) wskazywały, że autokorelacja przestrzenna zmiennej WYJ w zasadzie nie sięgała dalej niż do 100 km, a tylko w przedziale 40–80 km prawdopodobieństwo przypadkowości wyniku było mniejsze niż 5%. Dla odległości większych niż 620 km wyliczone wartości I były mało wiarygodne, co wynikało z małej liczby punktów (powiatów), które dzielił tak znaczny dystans.

Przeprowadzone testowanie jednoznacznie wykazało autokorelację przestrzenną zmiennej objaśnianej. Oznacza to, że w tym przypadku klasyczne modele regresyjne nie powinny znajdować zastosowania, gdyż występowanie autokorelacji przestrzennej powoduje zmiany własności estymatorów wypro-

wadzanych metodą najmniejszych kwadratów. Wskutek tego oceny parametrów mogą być niedokładne, a istotność statystyczna testów siły i kierunków powiązań niewielka (Anselin, 1988; Longley i inni, 2008). Bardziej adekwatne jest natomiast wykorzystanie modeli przestrzennych, do których należy m.in. regresja z wagowaniem geograficznym.

Regresja ważona geograficznie jako narzędzie analizy czynników wezwań ratunkowych

Autokorelacja przestrzenna zmiennej zależnej nie jest jedynym zjawiskiem osłabiającym moc wyjaśniającą klasycznych modeli regresji i sugerującym użyteczność modeli regresji przestrzennej. Interakcje przestrzenne mogą dotyczyć również zmiennych objaśniających, a także składnika losowego. Struktura interakcji przestrzennych determinuje rodzaj modelu, którego zastosowanie w danej sytuacji pozwoli uzyskać największą poprawność wyników (Suchecki, 2010).

Model regresji ważonej geograficznie (GWR) należy do grupy modeli heterogeniczności przestrzennej, przejawiającej się niestabilnością parametrów strukturalnych. Metoda regresji z wagowaniem geograficznym „pozwała na uchwycenie dla każdej obserwacji zmienności współczynników regresji w przestrzeni” (Suchecki, 2010, s. 264). Zgodnie z tym założeniem parametry modelu szacowane są osobno dla każdego punktu w przestrzeni, dla którego znane są wartości zmiennych objaśnianej i objaśniających. Estymacja parametrów lokalnych modeli regresji dokonywana jest z uwzględnianiem charakterystyk (zmiennych objaśniających) pochodzących przede wszystkim z obserwacji sąsiednich, z malejącym wraz z odległością znaczeniem kolejnych obserwacji.

Zgodnie z powyższym parametry modelu GWR związane są z lokalizacją, a równanie typowego modelu w przypadku większej liczby zmiennych objaśniających można zapisać w postaci:

$$y_i = \beta_0(x_i, y_i) + \beta_1(x_i, y_i)x_{1i} + \beta_2(x_i, y_i)x_{2i} + \dots + \beta_k(x_i, y_i)x_{ki} + \varepsilon_i$$

(dla $i = 1, \dots, n$),

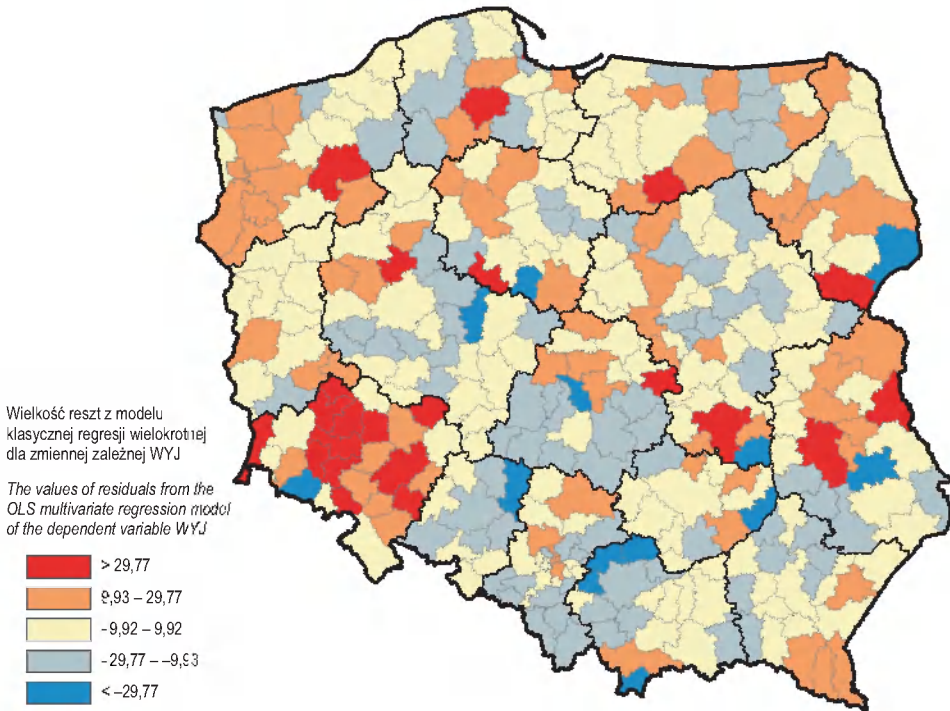
gdzie (x_i, y_i) – to współrzędne i -tej lokalizacji, a pozostałe oznaczenia wyjaśnione zostały przy omawianiu równania klasycznej regresji wielokrotnej.

Wyznaczanie parametrów lokalnych równań regresji wraz z wyprowadzeniem i interpretacją odpowiednich wzorów opisane zostało szczegółowo m.in. w publikacjach A.S. Fotheringhama i innych (2002), M. Charltona i A.S. Fotheringhama (2009) oraz B. Sucheckiego (2010). Na potrzeby prowadzonych badań wykorzystano pakiet oprogramowania ArcGIS, w ramach którego dostępne są narzędzia statystyki przestrzennej (*Spatial Statistics Tools*), w tym analiza geograficznie ważonej regresji.

Modele GWR stosowane są w sytuacji, gdy istnieje autokorelacja przestrzenna składnika losowego modelu klasycznej regresji (Fotheringham i inni, 2002).

Wykorzystując wyniki uzyskane z modelu klasycznej analizy regresji wielokrotnej stwierdzono występowanie tego typu interakcji o czym świadczyła wartość wskaźnika I -Morana ($I = 0,16$), wyliczonego dla reszt z regresji w poszczególnych lokalizacjach (obserwacjach $i = 1, \dots, n$).

Na rycinie 3 przedstawiono zróżnicowanie wartości reszt z klasycznego modelu regresji na analizowanym obszarze. Skupienia zbliżonych wartości potwierdzają autokorelację przestrzenną składnika losowego.



Ryc. 3. Zróżnicowanie przestrzenne reszt z klasycznego modelu regresji wielokrotnej (skupienia zbliżonych wartości dowodzą występowania autokorelacji przestrzennej składnika losowego, $I = 0,16$). Klasyfikacja na podstawie średniej i 1/2 odchylenia standardowego

Spatial diversification of residuals from the OLS multivariate regression model (concentrations of rough values attest to the spatial autocorrelation of the error term, $I = 0.16$). Classification based on mean and 1/2 standard deviation

Opracowanie własne. / Own elaboration.

W następstwie stwierdzonych relacji przestrzennych skonstruowano model GWR, w którym – analogicznie jak w przypadku klasycznej regresji – zmienna WYJ objaśniana była przez zmienne objaśniające DEM3 i TUR1. W rezultacie otrzymano zbiór 335 równań regresji oraz ocen lokalnych (takich jak lokalne R^2)

dotyczących poszczególnych lokalizacji. Podstawowe statystyki przeprowadzonej analizy GWR przedstawiono w tabeli 4.

Zastosowanie modelu geograficznie ważonej regresji pozwoliło wyeliminować błędy w szacowaniu parametrów funkcji regresji wynikające z autokorelacji zmiennej losowej. Statystyka *I*-Morana dla reszt z modelu GWR wynosiła $-0,01$, wskazując na niemal zupełny brak powiązania pomiędzy sąsiadującymi elementami (por. ryc. 4).

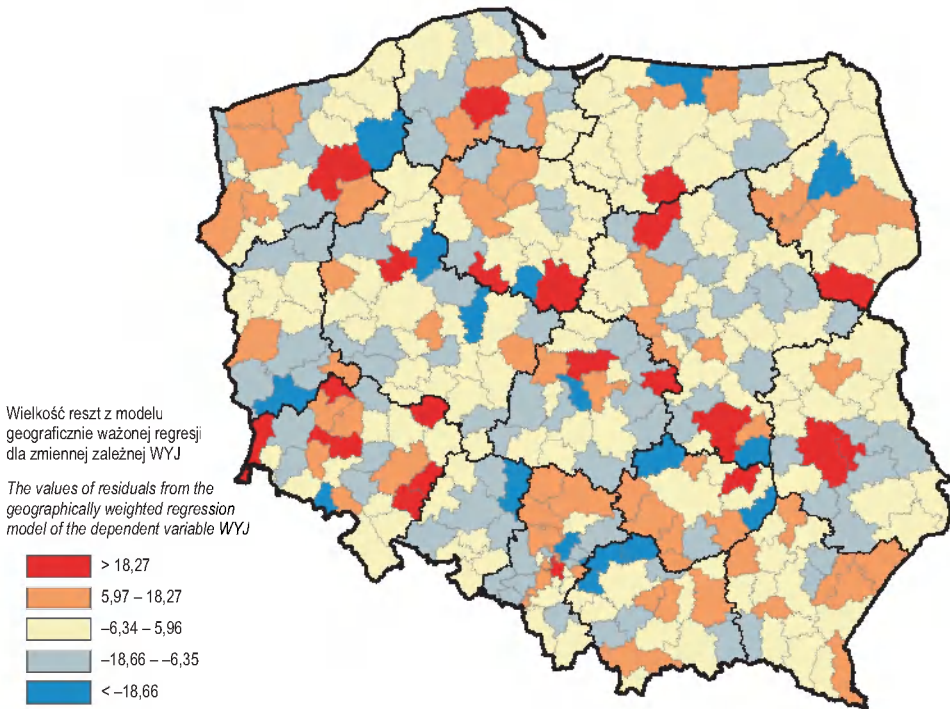
Tabela 4. Podstawowe statystyki modelu geograficznie ważonej regresji
Summary statistics of the geographically weighted regression model

N = 335	$R^2 = 0,897$; Skorygowany / <i>Adjusted</i> $R^2 = 0,811$; <i>Bandwidth</i> : 42236,31; Kwadraty reszt regresji / <i>Residual squares</i> : 2704,653256; Kryterium Informacyjne Akaike / <i>Akaike's Information Criterion (AIC)</i> : 202,69				
	β_0 (W. wolny <i>Intercept</i>)	β_1 (DEM3)	β_2 (TUR1)	Reszty regresji <i>Residuals</i>	Lokalne <i>Local</i> R^2
Minimum <i>Min</i>	-521,89452	-5,82922	-0,07172	-36,34149	0,00059
Maksimum <i>Max</i>	313,72712	15,51961	0,09767	63,25060	0,89085
Mediana <i>Median</i>	-81,44129	3,90976	0,00424	-0,82643	0,42685
Średnia <i>Mean</i>	-82,13522	3,93449	0,00745	-0,19563	0,43023

W związku z tym istotnie zwiększyła się moc wyjaśniająca analizy. Współczynnik determinacji GWR wynosił aż 0,89 i znacznie przekraczał wartość wyliczoną dla klasycznego modelu ($R^2 = 0,25$). Podobnie rzecz się miała w przypadku kryterium informacyjnego Akaike (*AIC*). Kryterium to, w odróżnieniu od współczynnika determinacji, nie jest miarą absolutną, lecz relatywną, umożliwiającą porównywanie różnych modeli z tymi samymi zmiennymi. Generalnie modele, które charakteryzuje mniejsza wartość *AIC* są lepiej dopasowane do rzeczywistości niż takie, w których *AIC* przybiera większe wartości. W analizowanych przypadkach kryterium *AIC* wynosiło 2958,65 dla modelu klasycznej regresji wielokrotnej oraz 202,69 dla modelu GWR (por. tab. 3 i 4). Zatem na podstawie kryterium informacyjnego Akaike potwierdzono, że zastosowanie metody GWR znacznie poprawiło stopień dopasowania modelu do danych obserwowalnych.

Analiza lokalnych współczynników GWR wskazywała na duże zróżnicowanie przestrzenne znaczenia poszczególnych zmiennych niezależnych. Pełen obraz zmienności lokalnych współczynników GWR odnoszących się do zmiennych DEM3 oraz TUR1 zilustrowano na rycinach 5 i 6.

Wartość parametru β_1 (odnoszącego się do zmiennej DEM3 – % ludności w wieku 45+) wahała się od $-5,83$ do $15,92$ (w przypadku klasycznego modelu było to $3,71$). Struktura wiekowa populacji wpływała najbardziej stymulująco na zapotrzebowanie na świadczenia przedszpitalnego ratownictwa medycznego w północnej części województwa dolnośląskiego, południowo-zachodniej – wielkopolskiego, południowej – opolskiego, południowo-wschodnich krańcach pod-



Ryc. 4. Zróżnicowanie przestrzenne reszt z modelu geograficznie ważonej regresji (mapa przedstawia brak autokorelacji przestrzennej składnika losowego, $I = -0,01$).

Klasyfikacja na podstawie średniej i 1/2 odchylenia standardowego

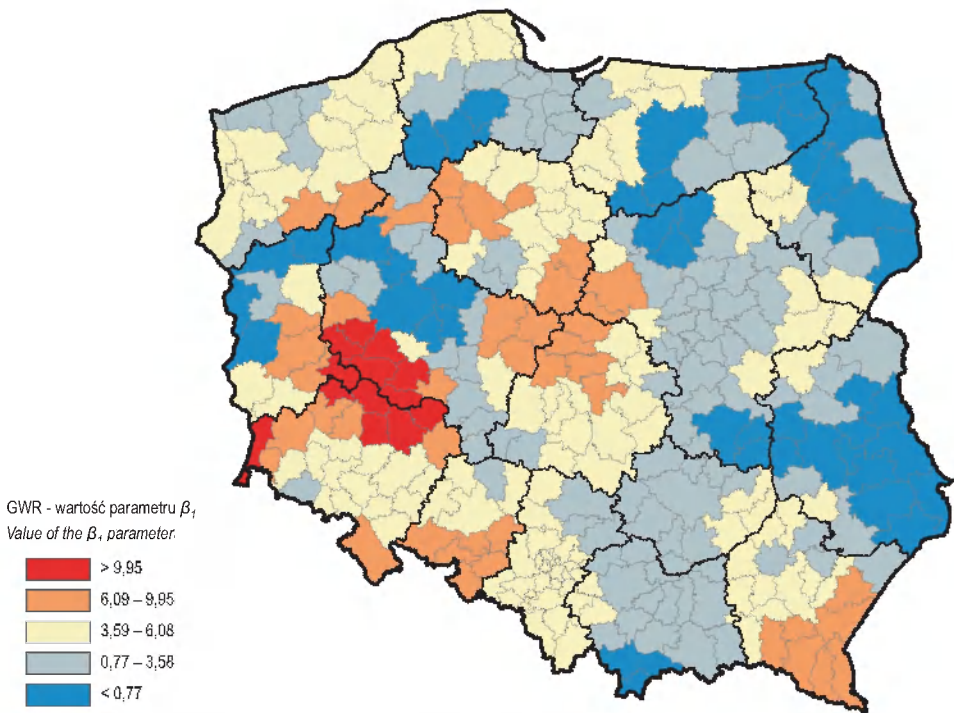
Spatial diversification of the residuals from the geographically weighted regression model (the map indicates the lack of the spatial autocorrelation of the error term, $I = -0.01$).

Classification based on mean and 1/2 standard deviation

Opracowanie własne. / Own elaboration.

karpackiego oraz powiatach centralnej Polski (w okolicach styku województw kujawsko-pomorskiego, mazowieckiego, łódzkiego i wielkopolskiego). W tych miejscach planowanie organizacji przestrzennej zespołów ratownictwa medycznego powinno być prowadzone głównie w odniesieniu do rozmieszczenia ludności ze starszych grup wiekowych. Dużo mniejsze znaczenie czynnika związanego ze strukturą wiekową ludności zidentyfikowano we wschodniej Polsce (z wyjąt-

kiem województwa podkarpackiego) oraz w dużej części województwa pomorskiego, centralnych terenach wielkopolskiego, północno-zachodnich obszarach lubuskiego oraz północnej części zachodniopomorskiego. Uwagę zwraca fakt, że na tych terenach występowały miejsca (33 powiaty), w których zmienna demograficzna oddziaływała obniżająco na zapotrzebowanie na usługi ZRM (w przypadkach gdy $\beta_1 < 0$).



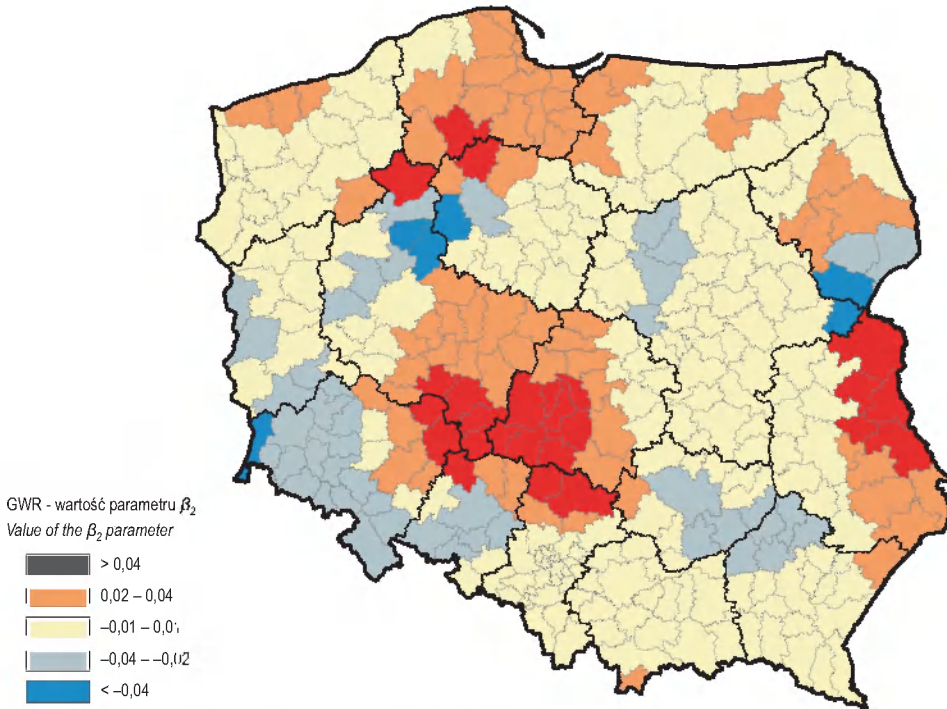
Ryc. 5. Zróżnicowanie przestrzenne wartości parametru β_1 (zmienna DEM3) według modelu GWR. Klasyfikacja na podstawie podziału naturalnego

Spatial diversification of the β_1 parameter (variable DEM3) in line with the GWR model.
Classification based on natural breaks

Opracowanie własne. / Own elaboration.

Z kolei lokalne współczynniki β_2 (przy zmiennej TUR1 – liczba korzystających z noclegów na 1000 mieszkańców) przyjmowały wartości od $-0,07$ do $0,09$ (podczas gdy w klasycznym modelu $0,005$), wykazując w pewnych obszarach charakter stymulacyjny (dla 244 powiatów $\beta_2 > 0$) a w innych destymulacyjny (dla pozostałych 91 powiatów $\beta_2 < 0$). Na wzrost zapotrzebowania na świadczenia zespołów ratownictwa medycznego czynnik związany z ruchem turystycznym najbardziej oddziaływał w centralnej Polsce, w województwie pomorskim oraz

wschodnich krańcach lubelskiego i centralnej części podlaskiego. Dodatkowo zaobserwowano stymulujący wpływ omawianego czynnika na obszarach atrakcyjnych turystycznie, takich jak zachodnie wybrzeże Bałtyku, powiat tatrzański, czy też Pojezierze Mazurskie i Pomorskie. Niskie wartości parametrów przy zmiennej turystycznej oznaczały jednak, że jej wpływ na zmienną zależną był w całym obszarze badań niewielki (choć istotny statystycznie).



Ryc. 6. Zróżnicowanie przestrzenne wartości parametru β_2 (zmienna TUR1) według modelu GWR. Klasyfikacja na podstawie podziału naturalnego

Spatial diversification of the β_2 parameter (variable TUR1) in line with the GWR model.
Classification based on natural breaks

Opracowanie własne. / Own elaboration.

Podsumowanie

W świetle przeprowadzonych badań stwierdzono, że do czynników w największym stopniu wpływających na wielkość zapotrzebowania na świadczenia przedszpitalnego ratownictwa medycznego należą: (1) odsetek ludności w wieku 45 lat i więcej oraz (2) liczba korzystających z noclegów na 1000 ludności. Tym samym pozytywnie zweryfikowano hipotezy zakładające, że zapotrzebowanie na usługi

świadczone przez ZRM związane jest ze strukturą wiekową oraz nadwyżką ludności przebywającej na danym obszarze w stosunku do ludności zamieszkującej ten obszar. Nie wykazano natomiast istotnego statystycznie wpływu takich czynników jak dostępność ochrony zdrowia w pozostałych formach, poziom urbanizacji czy też sytuacja społeczno-ekonomiczna ludności. Ostateczna weryfikacja hipotez odnoszących się do tych czynników wymagałaby jednak prowadzenia bardziej wnikliwych badań na poziomie lokalnym.

Ustalenia dotyczące wpływu struktury wiekowej ludności na zapotrzebowanie w zakresie przedszpitalnego ratownictwa medycznego mają szczególne znaczenie w kontekście bieżących trendów demograficznych związanych z wydłużaniem się trwania życia, malejącą liczbą urodzeń, a co za tym idzie starzeniem się społeczeństwa. Doświadczenia wielu wysokorozwiniętych państw świata wskazują, że postępującej starości demograficznej towarzyszy zwiększone użytkowanie usług ratunkowo-medycznych (por. McConnel i Wilson, 1998; Clark i FitzGerald, 1999; Victor i inni, 1999; Lowthian i inni, 2011b). Przy rosnącym zapotrzebowaniu na usługi ratunkowo-medyczne ważną staje się optymalizacja rozwiązań organizacyjno-przestrzennych w systemie pomocy doraźnej. Jak wynika z rozważań J.D. Mayera (1982), planowanie takich systemów powinno być prowadzone głównie w odniesieniu do ludności najbardziej narażonej na zagrożenia zdrowotne. W związku z tym, optymalizując struktury terytorialne ruchomych jednostek systemu ratownictwa medycznego w Polsce, należy przede wszystkim uwzględniać rozmieszczenie ludności ze starszych grup wiekowych.

Przeprowadzona analiza dowiodła, że zastosowanie modelu GWR pozwala precyzyjnie zidentyfikować zmienność przestrzenną czynników kształtujących zapotrzebowanie na świadczenia przedszpitalnego ratownictwa medycznego. Wyniki GWR mogą zatem stanowić źródło informacji cenne z punktu widzenia szeroko rozumianej polityki zdrowotnej, głównie w kontekście opracowywania planów zabezpieczenia ratunkowo-medycznego ludności oraz podejmowania decyzji o lokalizacji jednostek systemu ratownictwa medycznego.

Piśmiennictwo

- Anselin L., 1988, *Spatial Econometrics: Methods and Models*, Kluwer Academic Publishers, Dordrecht.
- Cadigan R.T., Bugarin C.E., 1989, *Predicting demand for emergency ambulance service*, *Annals of Emergency Medicine*, 18, 6, s. 618–621.
- Charlton M., Fotheringham A.S., 2009, *Geographically Weighted Regression: White Paper*, Maynooth, http://ncg.nuim.ie/ncg/GWR/GWR_WhitePaper.pdf (15.06.2012).
- Chojnicki Z., Czyż T., 1978, Analiza zmienności zróżnicowania przestrzeni społeczno-ekonomicznej Polski, [w:] Z. Chojnicki, T. Czyż, J.J. Parysek, W. Ratajczak (red.), *Badania przestrzennej struktury społeczno-ekonomicznej Polski metodami czynnikowymi*, PWN, Warszawa-Poznań.
- Clark M.J., FitzGerald G., 1999, *Older people's use of ambulance services: a population based analysis*, *Journal of Accident and Emergency Medicine*, 16, s. 108–111.

- Clark M.J., Purdie J., FitzGerald G.J., Bischoff N.G., O'Rourke P.K., 1999, *Predictors of demand for emergency prehospital care: an Australian study*, *Prehospital and Disaster Medicine*, 14, 3, s. 167–173.
- Eyles J., Woods K.J., 1983, *The Social Geography of Medicine and Health*, Croom Helm, London.
- Fotheringham A.S., Brunsdon C., Charlton M., 2002, *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*, Wiley, Chichester.
- Głębocki J.T., Gaca M., Konieczny J., 2000, *Przegląd rozwiązań organizacyjnych ratownictwa medycznego w wybranych krajach Europy i w Stanach Zjednoczonych*, [w:] J. Konieczny, M. Gaca (red.), *Zarządzanie w sytuacjach kryzysowych: ratownictwo medyczne: materiały przedstawione podczas sesji naukowej V Forum Ratownictwa w Inowrocławiu*, Akademia Medyczna im. K. Marcinkowskiego w Poznaniu, Inowrocław, s. 47–64.
- Grochowski M., 1988, *Rejonizacja służby zdrowia a dostępność usług medycznych*, *Rozwój Regionalny, Rozwój Lokalny, Samorząd Terytorialny*, 15, Warszawa.
- Grochowski M., Kowalczyk A., 1987, *Spoleczna geografia medyczna – nowy kierunek w badaniach geograficzno-medycznych*, [w:] M. Grochowski, A. Kowalczyk (red.), *Spoleczna geografia medyczna*, *Przegląd Zagranicznej Literatury Geograficznej*, 1, Warszawa, s. 5–25.
- Joseph A.E., Phillips D.R., 1984, *Accessibility and Utilization. Geographical Perspectives on Health Care Delivery*, Harper and Row, London.
- Klingbeil S., 1987, *Teoretyczne aspekty popytu i podaży w dziedzinie ochrony zdrowia*, [w:] M. Grochowski, A. Kowalczyk (red.), *Spoleczna geografia medyczna*, *Przegląd Zagranicznej Literatury Geograficznej*, 1, Warszawa, s. 105–120.
- Leki K., 2006, *Pomoc doraźna w świetle ustawy o Państwowym Ratownictwie Medycznym*, [w:] V. Korporowicz (red.), *Zdrowie i jego ochrona: między teorią a praktyką*, Oficyna Wydawnicza SGH, Warszawa, s. 187–199.
- Lang T., Davido A., Diakite B., Agay E., Viel J.F., Flicoteaux B., 1997, *Using the hospital emergency department as a regular source of care*, *European Journal of Epidemiology*, 13, 2, s. 223–228.
- Longley P., Goodchild M.F., Maguire D.J., Rhind D.W., 2008, *GIS. Teoria i praktyka*, PWN, Warszawa.
- Lowthian J.A., Cameron P.A., Stoelwinder J.U., Curtis A., Currell A., Cooke M.W., McNeil J.J., 2011a, *Increasing utilisation of emergency ambulances*, *Australian Health Review*, 35, 1, s. 63–69.
- Lowthian J.A., Jolley D.J., Curtis A.J., Currell A., Cameron P.A., Stoelwinder J.U., McNeil J.J., 2011b, *The challenges of population ageing: accelerating demand for emergency ambulance services by older patients, 1995–2015*, *Medical Journal of Australia*, 194, 11, s. 574–578.
- Malczewski J., 1989, *Przestrzenna organizacja systemu placówek podstawowej ochrony zdrowia (na przykładzie dzielnicy Warszawa-Wola)*, Dokumentacja Geograficzna, 1.
- Malec E., 1980, *Wybrane zagadnienia analizy regresji*, [w:] Z. Chojnicki (red.), *Analiza regresji w geografii*, PWN, Warszawa-Poznań, s. 7–14.
- Mayer J.D., 1982, *Relations between two traditions of medical geography: health systems planning and geographical epidemiology*, *Progress in Human Geography*, 6, 2, s. 216–230.
- Mayer J.D., 1990, *The centrality of medical geography to human geography: the traditions of geographical and medical geographical thought*, *Norsk Geografisk Tidsskrift – Norwegian Journal of Geography*, 44, 4, s. 175–187.

- Mazurkiewicz L., 1994, *Czy geografia człowieka powinna zajmować się problematyką zdrowia?*, Przegląd Geograficzny, 66, 1-2, s. 191–194.
- Mazurkiewicz L., Wróbel A., 1990, *Problematyka badawcza geografii medycznej. Stan współczesny i perspektywy*, [w:] L. Mazurkiewicz, A. Wróbel (red.), *Przestrzenne problemy zdrowotności*, Conference Papers, IGiPZ PAN, 9, Warszawa, s. 7–18.
- McConnel C.E., Wilson R.W., 1998, *The demand for prehospital emergency services in an aging society*, Social Science and Medicine, 46, 8, s. 1027–1031.
- Nowosielska E., 1977, *Analiza regresji w badaniach geograficznych*, [w:] Z. Chojnicki (red.), *Metody ilościowe i modele w geografii*, PWN, Warszawa, s. 16–45.
- Oterino de la Fuente D., Baños Pino J.F., Blanco V.F., Álvarez A.R., 2007, *Does better access to primary care reduce utilization of hospital accident and emergency departments? A time-series analysis*, European Journal of Public Health, 17, 2, s. 186–192.
- Parysek J.J., Wojtasiewicz L., 1979, *Metody analizy regionalnej i metody planowania regionalnego*, Studia KPZK PAN, 69, Warszawa.
- Peacock P.J., Peacock J.L., 2006, *Emergency call work-load, deprivation and population density: an investigation into ambulance services across England*, Journal of Public Health, 28, 2, s. 111–115.
- Picheral H., 1987, *Geografia medyczna, geografia chorób, geografia zdrowia*, [w:] M. Grochowski, A. Kowalczyk (red.), *Spoleczna geografia medyczna*, Przegląd Zagranicznej Literatury Geograficznej, 1, Warszawa, s. 49–79.
- Powęska H., 1990, *Dostępność przestrzenna usług medycznych a zachowania medyczne ludności*, Biuletyn Informacyjny, IGiPZ PAN, 61, Warszawa.
- Póździej S., Guła P. (red.), 2008, *Ustawa o Państwowym Ratownictwie Medycznym. Komentarz*, Wolters Kluwer Polska, Warszawa.
- Rogacki H., 1980, *Zastosowanie analizy regresji wielokrotnej w geografii*, [w:] Z. Chojnicki (red.), *Analiza regresji w geografii*, PWN, Warszawa-Poznań, s. 15–22.
- Roovali L., Kiiwet R.A., 2006, *Geographical variations in hospital use in Estonia*, Health and Place, 12, 2, s. 195–202.
- Rucker D.W., Edwards R.A., Burstin H.R., O'Neil A.C., Brennan T.A., 1997, *Patient-specific predictors of ambulance use*, Annals of Emergency Medicine, 29, 4, s. 484–491.
- Ruger J.P., Richter C.J., Lewis L.M., 2006, *Clinical and Economic Factors Associated With Ambulance Use to the Emergency Department*, Academic Emergency Medicine, 13, 8, s. 879–885.
- Ryś A., 2002, *Czy ratownictwo medyczne jest potrzebne?* [w:] J. Jakubaszko, A. Ryś (red.), *Ratownictwo medyczne w Polsce – ustawa o państwowym ratownictwie medycznym*, Zdrowie i Zarządzanie, Kraków, s. 15–32.
- Shah M.N., Glushak C., Karrison T.G., Mulliken R., Walter J., Friedmann P.D., Hayley D.C., Chin M.H., 2003, *Predictors of emergency medical services utilization by elders*, Academic Emergency Medicine, 10, 1, s. 52–58.
- Suhecki B. (red.), 2010, *Ekonometria przestrzenna. Metody i modele analizy danych przestrzennych*, Wydawnictwo C.H. Beck, Warszawa.
- Toloo S., FitzGerald G., Aitken P., Ting J., Tippet V., Chu K., 2011, *Emergency Health Services: Demand and Service Delivery Models. Monograph 1: Literature Review and Activity Trends*, Queensland University of Technology, Brisbane.
- Victor C.R., Peacock J.L., Chazot C., Walsh S., Holmes D., 1999, *Who calls 999 and why? A survey of the emergency workload of the London Ambulance Service*, Journal of Accident and Emergency Medicine, 16, 3, s. 174–178.
- Widmer M., Matter P., Staub L., Schoeni-Affolter F., Busato A., 2009, *Regional variation in orthopedic surgery in Switzerland*, Health and Place, 15, 3, s. 761–768.

- Włodarczyk W.C., 1998, *Reforma opieki zdrowotnej w Polsce. Studium polityki zdrowotnej*, Vesalius, Kraków.
- Wysocki M.J., Miller M., 2003, *Paradygmat Lalonde'a, Światowa Organizacja Zdrowia i Nowe Zdrowie Publiczne*, Przegląd Epidemiologiczny, 57, 3, s. 505–512.

[Wpłynęło: luty; poprawiono: kwiecień 2013 r.]

WOJCIECH KISIAŁA

APPLICATION OF GEOGRAPHICALLY WEIGHTED REGRESSION IN THE ANALYSIS OF FACTORS AFFECTING DEMAND FOR EMERGENCY PRE-HOSPITAL CARE

The article details work that exemplifies the geographical study of healthcare. The aim was to identify factors affecting emergency calls using the method from spatial statistics known as geographically weighted regression (GWR). Following a formulation of hypotheses in line with the available literature global correlations were analysed in regard to the OLS regression model, in line with GWR procedures. Spatial autocorrelation was then performed with a view to local GWR models being formulated. The research took account of the spatial heterogeneity to the phenomenon under study.

The work allowed for the verification of a hypothesis contending that societal demand for emergency ambulance services depends on an area's population age structure, as well as the surplus in relation to the area's resident population. However, no effect could be demonstrated definitively when it came to such factors as other forms of access to healthcare, level of urbanization or socio-economic status of the population and use of pre-hospital emergency services.

Application of geographically weighted regression allowed for the elimination of misstatements in estimating parameters of global OLS regression as these result from spatial autocorrelation of the model's error term. This led to improved goodness of fit for the model. The estimated coefficient of determination R^2 of the GWR model reached 0.89, a value greatly exceeding that obtained for the global OLS model ($R^2=0.25$). Similarly, reference to the Akaike Information Criterion (AIC) showed that the application of GWR yielded a marked improvement in the fit of the model to the data.

Analysis of local GWR coefficients revealed marked spatial diversification of the independent variables tested. Values for the variable describing age structure of the population (percentage of population aged 45+) ranged between -5.83 and 15.92 (the value estimated for the global model was 3.71). Moreover, local coefficients for the variable representing surplus of the population (number of tourists accommodated per 1000 citizens) ranged between -0.07 and 0.09 (0.005 for the global model).

In the light of performed research, the method of geographically weighted regression can be said to have proved extremely useful where analysing of the factors underpinning emergency calls is concerned. The GWR model responsible for identifying spatial variability to factors influencing demand for the pre-hospital care offered by emergency medical services may prove an extremely valuable source of information in the context of practical activities, and may be of particular importance where global healthcare policy is concerned.