

# Zastosowanie statystyki przestrzennej do analizy wynagrodzeń na poziomie powiatów

Marek Ręklewski<sup>a</sup>

**Streszczenie.** Zróżnicowanie przestrzenne wynagrodzeń stanowi przedmiot wielu badań naukowych zarówno w ujęciu teoretycznym, jak i empirycznym. Czynniki determinującymi wysokość wynagrodzeń w Polsce są m.in. struktura i rodzaj działalności prowadzonej przez przedsiębiorstwa, specyficzne dla danego regionu i zależne od jego lokalizacji. Celem badania omawianego w artykule jest identyfikacja zależności przestrzennych zachodzących pomiędzy powiatami pod względem poziomu przeciętnych miesięcznych wynagrodzeń brutto z zastosowaniem statystycznych metod autokorelacji przestrzennej. Analizowano dane statystyczne za lata 2010–2019 zaczerpnięte z Banku Danych Lokalnych GUS. Wykorzystano miary globalne i lokalne. Do obliczenia globalnych parametrów autokorelacji przestrzennej posłużyły statystyki *I* Morana i *C* Geary'ego, a do identyfikacji autokorelacji lokalnej – statystyka *I* Morana, należąca do lokalnych wskaźników przestrzennych z grupy LISA (Local Indicators of Spatial Association). Istotność statystyczną statystyk globalnych zweryfikowano przy wykorzystaniu podejścia randomizacyjnego opierającego się na momentach teoretycznych.

Z globalnych statystyk *I* Morana i *C* Geary'ego wynika, że w badanym okresie pomiędzy powiatami występowała istotna (bardzo słaba lub słaba) dodatnia autokorelacja przestrzenna pod względem poziomu przeciętnych miesięcznych wynagrodzeń brutto. Świadczy ona o tym, że istnieją przestrzenne struktury powiatów o podobnych wartościach, a więc klastry charakteryzujące się wysokimi lub niskimi wartościami przeciętnej płacy. Wzrost wartości statystyki *I* Morana oraz spadek *C* Geary'ego w analizowanych latach wskazuje na zmniejszenie się zróżnicowania przeciętnych miesięcznych wynagrodzeń pomiędzy powiatami, a tym samym na wzrost autokorelacji przestrzennej. Analiza otrzymanych statystyk lokalnych pozwoliła na wyróżnienie klastrów podobnych powiatów: mazowieckiego, pomorskiego i śląskiego, a także wskazała na występowanie powiatów odstających (ang. *outliers*).

**Słowa kluczowe:** wynagrodzenia, rynek pracy, statystyka przestrzenna, autokorelacja przestrzenna

**JEL:** C10, J30

## The use of spatial statistics in the analysis of salaries at poviast level in Poland

**Abstract.** The spatial differentiation of salaries is the subject of many scientific studies, both theoretical and empirical. One of the factors determining remuneration in Poland is the structure and type of business activity, specific for a given region and depending on its

<sup>a</sup> Państwowa Uczelnia Zawodowa we Włocławku, Instytut Nauk Społecznych i Technicznych, Polska / State Vocational University in Włocławek, Institute of Social and Technical Sciences, Poland.  
ORCID: <https://orcid.org/0000-0001-6036-3370>. E-mail: [marek.reklewski@puz.wloclawek.pl](mailto:marek.reklewski@puz.wloclawek.pl).

poviats (counties) in terms of the level of the average gross monthly salary by means of spatial autocorrelation statistical methods. The analysed statistical data for 2010–2019 come from the Local Data Bank (Bank Danych Lokalnych – BDL) of Statistics Poland. Global and local measures were used in the analysis. The calculation of the global parameters of spatial autocorrelation was based on the *I* Moran and *C* Geary statistics, while the *I* Moran statistic, which belongs to local spatial indicators from the LISA group (Local Indicators of Spatial Association), was used to identify the local autocorrelation. The statistical significance of the global statistics was verified by means of a randomisation approach based on theoretical moments.

The *I* Moran and *C* Geary global statistics indicated a significant (very weak or weak) and positive spatial autocorrelation between poviats in terms of the level of average gross monthly salaries in 2010–2019, which shows the existence of spatial poviat structures of similar values, i.e. clusters with high or low values of average salaries. The increase in *I* Moran's statistics and the growth of the *C* Geary in the analysed period indicate a decrease in the differentiation of average monthly salaries between poviats, thus signifying an increase in the dependence of spatial autocorrelation. The analysis of the results of the obtained local statistics allowed the determination of clusters of similar poviats in Poland, e.g. Mazowiecki, Pomorski and Śląski. Furthermore, the results of the analysis indicated the presence of outlier poviats.

**Keywords:** salary, labour market, spatial statistics, spatial autocorrelation

## 1. Wprowadzenie

Wynagrodzenia są ważną kategorią ekonomiczną, ponieważ pełnią różnorodne funkcje: dochodową (konsumpcyjną), motywacyjną, kosztową i społeczną. Wynagrodzenie za pracę może być rozpatrywane jako suma dochodów otrzymywanych przez pracownika ze stosunku pracy lub jako część dochodów związana bezpośrednio z charakterem, rodzajem i efektywnością świadczonej pracy (Jarmołowicz i Knapińska, 2013, s. 10). Dla większości społeczeństwa wynagrodzenie za pracę stanowi podstawowe źródło dochodu, a jego wysokość określa poziom życia osób pracujących oraz ich status społeczny.

Na zróżnicowanie wynagrodzeń wpływa wiele różnorodnych czynników ekonomicznych i społeczno-demograficznych. Do czynników ekonomicznych należą m.in. poziom rozwoju gospodarczego danego regionu i sytuacja na lokalnym rynku pracy. Do najważniejszych społeczno-demograficznych determinant zróżnicowania wynagrodzeń można zaliczyć strukturę wieku, płeć i wykształcenie pracowników (Antoszek, 2010, s. 105–114). Przestrzenne zróżnicowanie wynagrodzeń jest związane ze strukturą działalności gospodarczej. Wynagrodzenia w poszczególnych sekcjach Polskiej Klasyfikacji Działalności (PKD) znacząco się różnią (Zieliński, 2011, s. 73).

W badaniach ekonomicznych często prowadzi się analizy z zakresu przestrzennego zróżnicowania wynagrodzeń w Polsce. Jest to niezwykle ważne, ponieważ na tej podstawie można wskazać regiony o bardziej lub mniej atrakcyjnym rynku pracy oraz określić istniejące nierówności. Regiony bardziej rozwinięte pod względem społeczno-gospodarczym przyciągają siłę roboczą z regionów słabiej rozwiniętych dzięki oferowaniu wyższych zarobków (Czarnecki, 2013, s. 166).

Zróżnicowanie wynagrodzeń jest rozpatrywane również w ujęciu demograficznym. Przestrzenne różnice w poziomie wynagrodzeń mogą stanowić istotną prze-

słankę do emigracji zarobkowej. Mobilność pracownicza często jest pochodną struktury wynagrodzeń na danym rynku pracy, a teorie rynku pracy wyjaśniają niektóre przyczyny mobilności (przestrzennej, społecznej, zawodowej) i przepływów pracowników (Jarmołowicz i Knapieńska, 2011, s. 124). Ważne, aby badania regionalne nad zróżnicowaniem wynagrodzeń były – ze względu na złożoność zjawiska – realizowane na jak najniższym poziomie administracyjnym, ponieważ umożliwia to lepsze zrozumienie istoty przestrzennego kształtowania się wynagrodzeń w Polsce.

Celem badania omawianego w artykule jest identyfikacja zależności przestrzennych zachodzących pomiędzy powiatami pod względem poziomu przeciętnych miesięcznych wynagrodzeń brutto z zastosowaniem statystycznych metod autokorelacji przestrzennej. Badanie tego rodzaju pozwala określić wpływ przestrzennego efektu aglomeracyjnego na wysokość wynagrodzeń według powiatów, a także umożliwia identyfikację jednorodnych skupisk powiatów podobnych i różniących się wewnętrznie pod względem przeciętnych wynagrodzeń.

Badania regionalne z wykorzystaniem narzędzi statystyki przestrzennej mają szerokie zastosowanie i są podejmowane przez wielu autorów. Spektrum poruszanej problematyki jest bardzo bogate – od badań związanych z obciążeniem demograficznym, dochodami czy rynkiem pracy aż do zagadnień dotyczących infrastruktury gospodarstw rolnych. Wyniki tego typu prac opublikowali m.in.: Kołodziejczak i Kossowski (2016), Müller-Frączek i Pietrzak (2008), Pośpiech (2015), Pośpiech i Mastalerz-Kodzis (2018), Sikora (2009), Szczuciński (2019) oraz Wilk i in. (2015).

## 2. Metoda badania

Przedmiotem omawianej analizy statystycznej są przeciętne wynagrodzenia brutto w ujęciu regionalnym w Polsce, a badaną jednostką administracyjną jest powiat. Za zmienną opisującą poziom wynagrodzeń w powiatach przyjęto przeciętne miesięczne wynagrodzenie brutto w przeliczeniu na zatrudnionego<sup>1</sup>. Przeciętne miesięczne wynagrodzenie brutto stanowi należność za wykonywaną pracę wynikającą ze stosunku pracy i prezentowane jest w ujęciu nominalnym (GUS, 2020, s. 84). Dane wykorzystane w analizie dotyczą lat 2010–2019 i pochodzą z zasobów Banku Danych Lokalnych (BDL) GUS.

---

<sup>1</sup> Przeciętne miesięczne wynagrodzenie brutto to stosunek sumy wynagrodzeń osobowych brutto, honorariów wypłaconych niektórym grupom pracowników za prace wynikające z umowy o pracę, wypłat z tytułu udziału w zysku lub w nadwyżce bilansowej w spółdzielniach oraz dodatkowych wynagrodzeń rocznych dla pracowników jednostek sfery budżetowej do przeciętnej liczby zatrudnionych w danym okresie. Nie uwzględnia się osób wykonujących pracę nakładczą i zatrudnionych za granicą (Główny Urząd Statystyczny [GUS], 2020, s. 79–80).

Dane o wynagrodzeniach podaje się w ujęciu brutto, tj. łącznie z zaliczkami na poczet podatku dochodowego od osób fizycznych oraz od 1999 r. ze składkami na obowiązkowe ubezpieczenia społeczne (emerytalne, rentowe i chorobowe) płaconymi przez ubezpieczonego pracownika. Dane o świadczeniach społecznych podaje się w ujęciu brutto, tj. łącznie z zaliczkami na poczet podatku dochodowego od osób fizycznych. Nie dotyczy to podmiotów gospodarczych o liczbie pracujących do dziewięciu osób (GUS, b.r.).

Aby zrealizować założony cel, zastosowano metody przestrzenne, umożliwiające dokonanie wszechstronnych analiz regionalnych, w których lokalizacja odgrywa kluczową rolę w identyfikacji zależności pomiędzy daną jednostką a jej sąsiadami. Statystyki autokorelacji przestrzennej oprócz wielu zalet mają również pewne wady, np. w macierzy wag wszystkim jednostkom przestrzennym powiązanim z sąsiadami przypisuje się tę samą wagę, choć w rzeczywistości siła zależności pomiędzy nimi jest różna (Cliff i Ord, 1973, 1981). Należy także zwrócić uwagę na trudności z testowaniem statystyk globalnych i lokalnych wynikające z braku znajomości własności rozkładów (Suchecki, 2010, s. 122).

W celu zidentyfikowania zależności przestrzennych zastosowano dwie najpopularniejsze statystyki globalne: *I* Morana i *C* Geary'ego. Interakcje między danym powiatem a najbliższym otoczeniem określono za pomocą lokalnej statystyki Morana, należącej do grupy lokalnych wskaźników przestrzennych LISA (Local Indicators of Spatial Association; Anselin, 1995, s. 95–97). Istotność globalnych wskaźników autokorelacji przestrzennej zweryfikowano na podstawie ujęcia randomizacyjnego.

Statystykę *I* Morana (Moran, 1948) wykorzystuje się do określenia stopnia skorelowania, a więc siły związku pomiędzy zmienną *X* a lokalizacją badanych jednostek przestrzennych. Ogólną postać statystyki globalnej *I* Morana można przedstawić według wzoru (Moran, 1950):

$$I = \frac{1}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \cdot \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{S^2} = \frac{n}{W_0} \cdot \frac{\mathbf{z}^T \mathbf{W} \mathbf{z}}{\mathbf{z}^T \mathbf{z}}, \quad (1)$$

gdzie:

$$S^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n},$$

*n* – liczba analizowanych jednostek przestrzennych,

$x_i, x_j$  – wartości badanej zmiennej w jednostkach przestrzennych *i* i *j*,

$\bar{x}$  – średnia arytmetyczna badanej zmiennej,

*z* – wektor kolumnowy o elementach:  $z_i = x_i - \bar{x}$ ,

**W** – macierz wag przestrzennych według kryterium wspólnej granicy;  $\mathbf{W} = [w_{ij}]$ ,  
 $w_{ij} = 1$ , gdy *i* ≠ *j* oraz *i* sąsiaduje z *j*;  $w_{ij} = 0$  w pozostałych przypadkach,

$W_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}$  – suma elementów przestrzennej macierzy wag.

Statystykę *I* interpretuje się podobnie jak współczynnik determinacji obliczony na podstawie współczynnika korelacji liniowej (Kopczewska, 2020, s. 270). Wskazuje on, jaki odsetek zmienności badanej zmiennej *X* w danej jednostce został wyjaśniony przez położenie geograficzne (czyli lokalizację) tej jednostki (Kopczewska, 2011, s. 81).

Interpretacja statystyki globalnej  $I$  Morana jest następująca (Kopczewska, 2020, s. 266):

- dodatnia autokorelacja przestrzenna ( $I > 0$ ) świadczy o tym, że wartości badanej zmiennej dla jednostek przestrzennych w utworzonych klastrach charakteryzują się podobnymi wartościami;
- ujemna autokorelacja przestrzenna ( $I < 0$ ) zachodzi wtedy, gdy jednostki w zidentyfikowanych klastrach charakteryzują się różnymi wartościami pod względem zmiennej (typu *hot spots*);
- w sytuacji gdy  $I = 0$ , mamy do czynienia z brakiem autokorelacji przestrzennej.

Rozkład wartości badanej zmiennej w jednostkach przestrzennych ma charakter losowy (Suchecki, 2010, s. 114).

Aby obliczyć globalne statystyki autokorelacji, posłużono się najczęściej stosowaną macierzą sąsiedztwa typu  $\mathbf{W} = [w_{ij}]$  (Suchecka, 2014, s. 169). Jest to macierz sąsiedztwa pierwszego rzędu tworzona według kryterium wspólnej granicy o wymiarach  $n \times n$ . Macierz  $\mathbf{W}$  jest kwadratowa i symetryczna z zerami po przekątnej. Dodatkowo poddaje się ją standaryzacji wierszami ( $1/N$ ). W ten sposób uzyskuje się sumę wag dla poszczególnych jednostek przestrzennych dla rzędów równą 1, tj.  $\sum_j w_{ij} = 1$  (tabl. 1). Przypisanie wartości zero-jedynkowych w macierzy  $\mathbf{W}$ , obrazującej przestrzenne położenie badanych jednostek względem siebie, odbywa się według następującej zasady:

$$w_{ij} = \begin{cases} 1, & \text{kiedy jednostka } i \text{ graniczy z jednostką } j \text{ (są sąsiadami),} \\ 0 & \text{we wszystkich pozostałych przypadkach (nie są sąsiadami),} \\ 0 & \text{dla elementów diagonalnych macierzy.} \end{cases}$$

**Tabl. 1.** Zstandaryzowana wierszami macierz sąsiedztwa  $\mathbf{W}$  według kryterium wspólnej granicy na przykładzie powiatów województwa opolskiego

Powiaty $n_j$	Wagi dla powiatów $w_{ij}$											Liczba sąsiadów $N$	Suma wag $w_{ij}$	
	brzeski	głubczycki	kędzierzyńsko-kozielski	kluczborski	krapkowicki	namysłowski	nyski	oleski	opolski	prudnicki	strzelecki			m. Opole
Brzeski .....	0	0	0	0	0	1/3	1/3	0	1/3	0	0	0	3	1
Głubczycki .....	0	0	1/2	0	0	0	0	0	0	1/2	0	0	2	1
Kędzierzyńsko-kozielski .....	0	1/4	0	0	1/4	0	0	0	0	1/4	1/4	0	4	1
Kluczborski .....	0	0	0	0	0	1/3	0	1/3	1/3	0	0	0	3	1
Krapkowicki .....	0	0	1/4	0	0	0	0	0	1/4	1/4	1/4	0	4	1
Namysłowski .....	1/3	0	0	1/3	0	0	0	0	1/3	0	0	0	3	1
Nyski .....	1/3	0	0	0	0	0	0	0	1/3	1/3	0	0	3	1
Oleski .....	0	0	0	1/3	0	0	0	0	1/3	0	1/3	0	3	1
Opolski .....	1/9	0	0	1/9	1/9	1/9	1/9	1/9	0	1/9	1/9	1/9	9	1
Prudnicki .....	0	1/5	1/5	0	1/5	0	1/5	0	1/5	0	0	0	5	1
Strzelecki .....	0	0	1/4	0	1/4	0	0	1/4	1/4	0	0	0	4	1
M. Opole .....	0	0	0	0	0	0	0	0	1	0	0	0	1	1

Źródło: opracowanie własne na podstawie: Suchecka (2014, s. 164).

Narzędziem najczęściej wykorzystywanym do wizualizacji wyników i identyfikacji globalnej autokorelacji przestrzennej wśród badanych jednostek jest wykres rozrzutu, czyli wykres punktowy Morana (Kopczewska, 2020, s. 271). W prostokątnym układzie współrzędnych na osi  $X$  przedstawiona jest zmienna zestandaryzowana, a na osi  $Y$  – opóźnienie przestrzenne tej zmiennej. Wykres umożliwia zobrazowanie zależności pomiędzy wartością zmiennej  $X$  w danym regionie w porównaniu z wartością analizowanej zmiennej w sąsiednich regionach. Na wykresie rozproszenia znajduje się liniowa funkcja regresji, której współczynnikiem kierunkowym jest wartość globalnej statystyki  $I$  Morana. W ćwiartkach I i III występuje skupienie punktów, które świadczą o dodatniej autokorelacji przestrzennej. Mieszczą się tutaj regiony o podobnych wartościach zmiennej  $X$ , tzn. klastry o wysokich i niskich wartościach. Ćwiartki II i IV skupiają jednostki nietypowe; jeśli ich wartości są istotne statystycznie, to mamy do czynienia z obserwacjami odstającymi (ang. *outliers*). Punkty zlokalizowane w ćwiartkach II i IV oznaczają, że występuje ujemna autokorelacja przestrzenna. Wysokim wartościom zmiennej  $X$  przyporządkowane są niskie wartości charakteryzujące sąsiednie regiony, a niskim wartościom – wartości wysokie. Testowanie istotności globalnych wskaźników autokorelacji przestrzennej zostało przeprowadzone przy wykorzystaniu ujęcia randomizacyjnego.

W badaniach nad identyfikacją autokorelacji przestrzennej oprócz statystyki globalnej  $I$  Morana bardzo często stosuje się statystykę  $C$  Geary'ego. Można ją zapisać wzorem (Geary, 1954, s. 116):

$$C = \frac{(n-1)n-1 \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - x_j)^2}{2 \sum_{i=1}^n \sum_{j=1}^n w_{ij} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}. \quad (2)$$

Wartości statystyki  $C$  Geary'ego dla poszczególnych jednostek przestrzennych są dodatnie i zestandaryzowane w przedziale  $[0, 2]$ . Statystykę  $C$  Geary'ego interpretuje się następująco (Suchecki, 2010, s. 115):

- $0 < C < 1$  – autokorelacja dodatnia;
- $1 < C < 2$  – autokorelacja ujemna;
- $C \approx 1$  i  $Z_c \approx 0$  (gdzie  $Z_c$  to zestandaryzowana statystyka  $C$  Geary'ego) – brak autokorelacji.

W badaniach przestrzennych oprócz globalnej autokorelacji bada się także lokalne zależności umożliwiające uchwycenie przestrzennych efektów aglomeracyjnych (Kopczewska, 2020, s. 283) i najczęściej stosuje się statystykę lokalną  $I_i$  Morana lub statystykę  $G_i$  Getisa-Orda (Ord i Getis, 1995, s. 286–306). W niniejszym artykule zastosowano statystykę lokalną  $I_i$  Morana, która dla wartości niestandardyzowanej zmiennej  $X$  w  $i$ -tej lokalizacji ( $i = 1, 2, \dots, n$ , gdzie  $n$  to liczba rozpatrywanych jednostek przestrzennych) i standaryzowanej wierszami macierzy wag przyjmuje postać (Anselin, 1995 s. 98):

$$I_i = \frac{(x_i - \bar{x}) \sum_{j=1}^n w_{ij}^* (x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})} = \frac{z_i \sum_{j=1}^n w_{ij}^* z_j}{\sum_{i=1}^n z_i^2}. \quad (3)$$

Interpretacja statystyki lokalnej  $I_i$  Morana przedstawia się następująco (Kopczewska, 2011, s. 90–91):

- $I_i > 0$  i  $p$ -value  $< 0,05$  – autokorelacja dodatnia;
- $I_i < 0$  i  $p$ -value  $> 0,95$  – autokorelacja ujemna.

Statystyki lokalne  $I_i$  Morana umożliwiają identyfikację jednorodnych klastrów o wysokich lub niskich wartościach badanej zmiennej  $X$  (korelacja dodatnia) oraz wskazują regiony nietypowe typu *outlier* (*hot spots* – gdzie obiekt  $i$  o wysokiej wartości zmiennej otoczony jest obszarami o niskich wartościach zmiennej, *cold spots* – gdzie obiekt  $i$  o niskiej wartości zmiennej otoczony jest obszarami o wysokich poziomach zmiennej), otoczone regionami o różniących się wartościach zmiennej  $X$  (korelacja ujemna).

Testowanie istotności przestrzennej statystyki lokalnej  $I_i$  Morana, przy założeniu asymptotycznego rozkładu normalnego, odbywa się za pomocą testu  $Z_{I_i}$  (Suchecky, 2010, s. 124):

$$Z_{I_i} = \frac{I_i - E(I_i)}{\sqrt{\text{Var}(I_i)}} \sim N(0,1), \quad (4)$$

gdzie:

$E(I_i)$  – wartość oczekiwana,

$\text{Var}(I_i)$  – wariancja.

Powyższy test umożliwia weryfikację hipotezy  $H_0$ , zakładającej brak występowania skupisk podobnych (o wysokich lub niskich wartościach zmiennej  $X$ ) w otoczeniu  $i$ -tego obiektu.

### 3. Poziom i dynamika wynagrodzeń w latach 2010–2019

Wynagrodzenia brutto w Polsce w latach 2010–2019 stopniowo wzrastały. Przeciętne miesięczne wynagrodzenie brutto w 2019 r. wynosiło 5181,63 zł i było o 1746,63 zł wyższe od wynagrodzenia z 2010 r. (tabl. 2). W ujęciu dynamicznym, przy założeniu 2010 = 100, przeciętne miesięczne wynagrodzenia brutto rosły w przedziale zmienności od 5,5% do 50,9%. W latach 2010–2019 średnie roczne tempo wzrostu wynagrodzeń wyniosło 4,7%.

**Tabl. 2.** Indeksy dynamiki przeciętnego miesięcznego wynagrodzenia brutto na zatrudnionego w Polsce

L a t a	Przeciętne miesięczne wynagrodzenie brutto w zł	Indeksy dynamiki	
		jednopodstawowe (2010 = 100)	łańcuchowe (rok poprzedni = 100)
		w %	
2010 .....	3435,00	100,0	.
2011 .....	3625,21	105,5	105,5
2012 .....	3744,38	109,0	103,3
2013 .....	3877,43	112,9	103,6
2014 .....	4003,99	116,6	103,3
2015 .....	4150,86	120,8	103,7
2016 .....	4290,52	124,9	103,4
2017 .....	4527,89	131,8	105,5
2018 .....	4834,76	140,8	106,8
2019 .....	5181,63	150,9	107,2

Źródło: opracowanie własne na podstawie danych z BDL GUS.

Analizując łańcuchowe indeksy dynamiki, można stwierdzić, że najwyższe zaobserwowane zmiany w wysokości przeciętnego wynagrodzenia brutto w porównaniu z poprzednim rokiem wystąpiły w latach 2018–2019. W tym okresie wzrosło ono odpowiednio o 6,8% i 7,2%.

Dane z tabl. 3 pokazują tendencję do zwiększania się dysproporcji w wynagrodzeniach skrajnych, tzn. pomiędzy powiatami charakteryzującymi się najniższą i najwyższą płacą. Ta różnica (czyli rozstęp) w przeciętnych wynagrodzeniach zatrudnionych w 2010 r. wynosiła 3906,11 zł, a w 2019 r. była o niemal 1000 zł wyższa (4905,67 zł).

Najniższe przeciętne wynagrodzenie brutto w latach 2010–2019 odnotowano w powiecie kępińskim (woj. wielkopolskie). Z kolei najwyższe przeciętne wynagrodzenie otrzymywali pracownicy zatrudnieni w powiecie lubińskim (woj. dolnośląskie) oraz Jastrzębiu-Zdroju (woj. śląskie).

**Tabl. 3.** Wartości minimalnych i maksymalnych przeciętnych miesięcznych wynagrodzeń brutto w powiatach

Wyszczególnienie	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
	w zł na zatrudnionego									
Minimum <sup>a</sup> ...	2106,84	2224,07	2349,11	2456,46	2544,18	2568,52	2658,47	2960,24	3183,34	3537,58
Maksimum <sup>b</sup>	6012,95	6324,79	6541,95	6641,40	6807,05	6955,85	7170,21	7515,99	8121,08	8443,25
Rozstęp .....	3906,11	4100,72	4192,84	4184,94	4262,87	4387,33	4511,74	4555,75	4937,74	4905,67

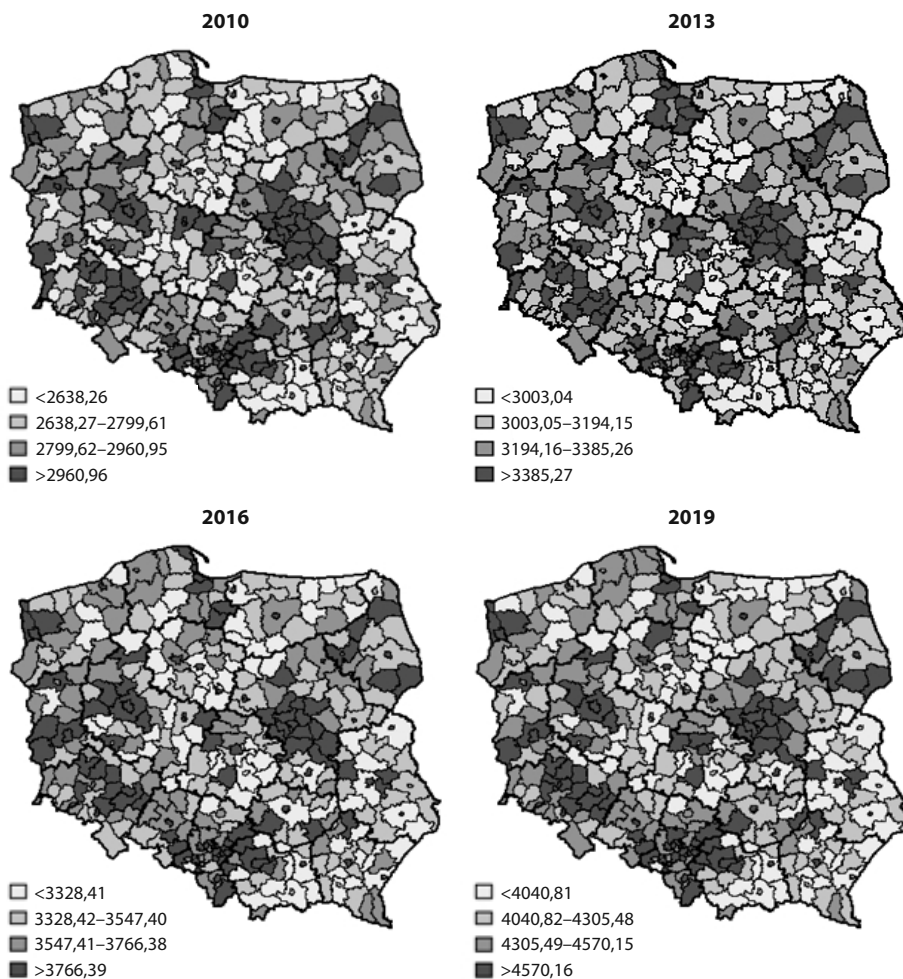
a Powiat kępiński. b Powiat lubiński w latach 2010 i 2012–2017, m. Jastrzębie-Zdrój w latach 2011 i 2018–2019.

Źródło: opracowanie własne na podstawie danych z BDL GUS.



Na mapie 1 przedstawiono zróżnicowanie przeciętnych miesięcznych wynagrodzeń brutto na poziomie powiatów w Polsce. Można tu zauważyć silną koncentrację powiatów charakteryzujących się wysokimi wynagrodzeniami w województwach mazowieckim i śląskim, gdzie występuje duża liczba aglomeracji miejskich. Powiaty o relatywnie wysokich wynagrodzeniach skupione są w sąsiedztwie takich miast, jak Poznań, Wrocław i Szczecin. W tego rodzaju skupiskach miasta odgrywają rolę najważniejszych ośrodków rozwoju społeczno-gospodarczego w danym województwie.

**Mapa 1.** Przestrzenne zróżnicowanie przeciętnych wynagrodzeń brutto na poziomie powiatów w zł



Uwaga. Przedziały wynagrodzeń wyznaczono według statystyk pozycyjnych, korzystając z mediany i medianowego odchylenia bezwzględnego.

Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

#### 4. Autokorelacja przestrzenna wynagrodzeń

Analizę rozpoczęto od obliczenia wartości globalnych statystyk autokorelacji przeciętnych miesięcznych wynagrodzeń brutto według *I* Morana i *C* Geary'ego w latach 2010–2019. Istotność statystyczną statystyk globalnych zweryfikowano poprzez zastosowanie podejścia randomizacyjnego opierającego się na momentach teoretycznych (tabl. 4). Miary obliczone na podstawie danych powiatowych dla badanych lat są większe od 0 ( $I > 0$ ) i istotne statystycznie, tak więc hipoteza  $H_0$ , wskazująca na brak autokorelacji przestrzennej, została odrzucona na korzyść hipotezy alternatywnej  $H_1$  o występowaniu autokorelacji przestrzennej. Obliczone statystyki kształtują się w następujących przedziałach: 0,1563–0,2458 w przypadku statystyki *I* Morana oraz 0,7175–0,7839 dla *C* Geary'ego. Dodatkowo wartości otrzymanych statystyk globalnych wskazują na występowanie dodatniej autokorelacji przestrzennej przeciętnych wynagrodzeń w ujęciu powiatowym.

**Tabl. 4.** Statystyki globalne wynagrodzeń i testowanie ich istotności przy wykorzystaniu podejścia randomizacyjnego z uwzględnieniem powiatów

Lata	<i>I</i> Morana		<i>C</i> Geary'ego	
		<i>p</i> -value		<i>p</i> -value
2010 .....	0,1649	2,550e-07	0,7650	0,0002
2011 .....	0,1563	8,975e-07	0,7839	0,0009
2012 .....	0,1589	6,319e-07	0,7732	0,0004
2013 .....	0,1942	1,955e-09	0,7767	0,0003
2014 .....	0,2076	1,685e-10	0,7590	6,971e-05
2015 .....	0,2138	5,752e-11	0,7510	1,387e-05
2016 .....	0,2216	1,268e-11	0,7404	4,532e-06
2017 .....	0,2188	2,232e-11	0,7451	5,862e-06
2018 .....	0,2304	1,697e-12	0,7371	1,489e-05
2019 .....	0,2458	6,608e-14	0,7175	1,602e-06

Uwaga. Test istotności został przeprowadzony metodą momentów teoretycznych.

Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

Oznacza to, że wynagrodzenia w powiatach sąsiadujących są podobne, tzn. mają wartości wysokie lub niskie. Wyniki obliczeń statystyk *I* Morana wskazują na występowanie bardzo słabej (2010–2013) lub słabej (2014–2019) autokorelacji przestrzennej pomiędzy poziomem wynagrodzeń a czynnikiem przestrzennym. Wzrost warto-

ści statystyk  $I$  Morana oraz spadek  $C$  Geary'ego można zinterpretować jako zmniejszenie się zróżnicowania przeciętnych miesięcznych wynagrodzeń pomiędzy powiatami, wskazujące tym samym na zwiększenie się zależności autokorelacji przestrzennej.

W tabl. 5 zaprezentowano zmiany autokorelacji przestrzennej dla przeciętnych miesięcznych wynagrodzeń brutto z uwzględnieniem 6. rzędu opóźnienia przestrzennego. W latach 2010, 2013 i 2016 dwa pierwsze opóźnienia są statystycznie istotne, co świadczy o tym, że autokorelacja przestrzenna występuje nie tylko z najbliższymi sąsiadami – zlokalizowanymi przy wspólnej granicy, lecz także z sąsiadami 2. rzędu. Z kolei w 2019 r. autokorelacja przestrzenna występuje do rzędu 3.

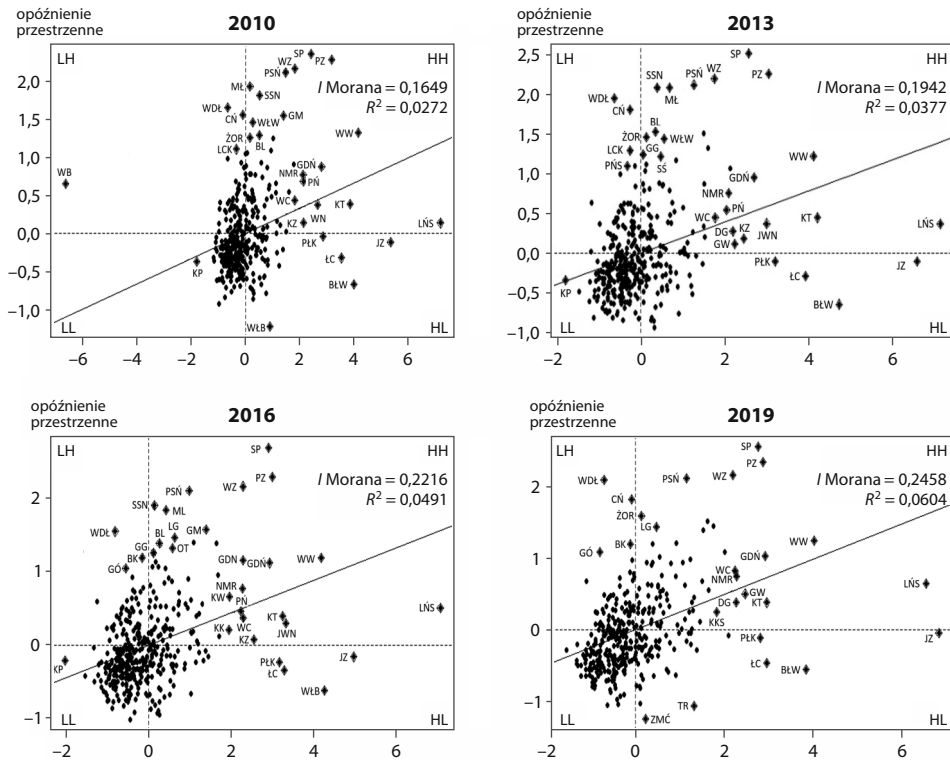
**Tabl. 5.** Opóźnienia przestrzenne statystyk globalnych  $I$  Morana

Rząd opóźnień	2010		2013		2016		2019	
	$I$ Morana	$p$ -value	$I$ Morana	$p$ -value	$I$ Morana	$p$ -value	$I$ Morana	$p$ -value
1 .....	0,1649	5,11e-07***	0,1942	3,90e-09***	0,2216	2,53e-11***	0,2458	1,32e-13***
2 .....	0,0537	0,00696**	0,0571	0,00432**	0,0740	0,00027***	0,0989	1,31e-06***
3 .....	0,0144	0,30772	0,0151	0,29120	0,0167	0,25094	0,0355	0,02331
4 .....	-0,0142	0,42855	-0,0120	0,51889	-0,0100	0,61282	0,0023	0,73446
5 .....	-0,0050	0,85646	-0,0201	0,18284	-0,0208	0,17040	-0,0217	0,14823
6 .....	-0,0426	0,00112**	-0,0534	3,65e-05***	-0,0631	9,93e-07***	-0,0617	1,69e-06***

Uwaga. Poziom istotności: \*\*\* – 0,001; \*\* – 0,01; \* – 0,05.

Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

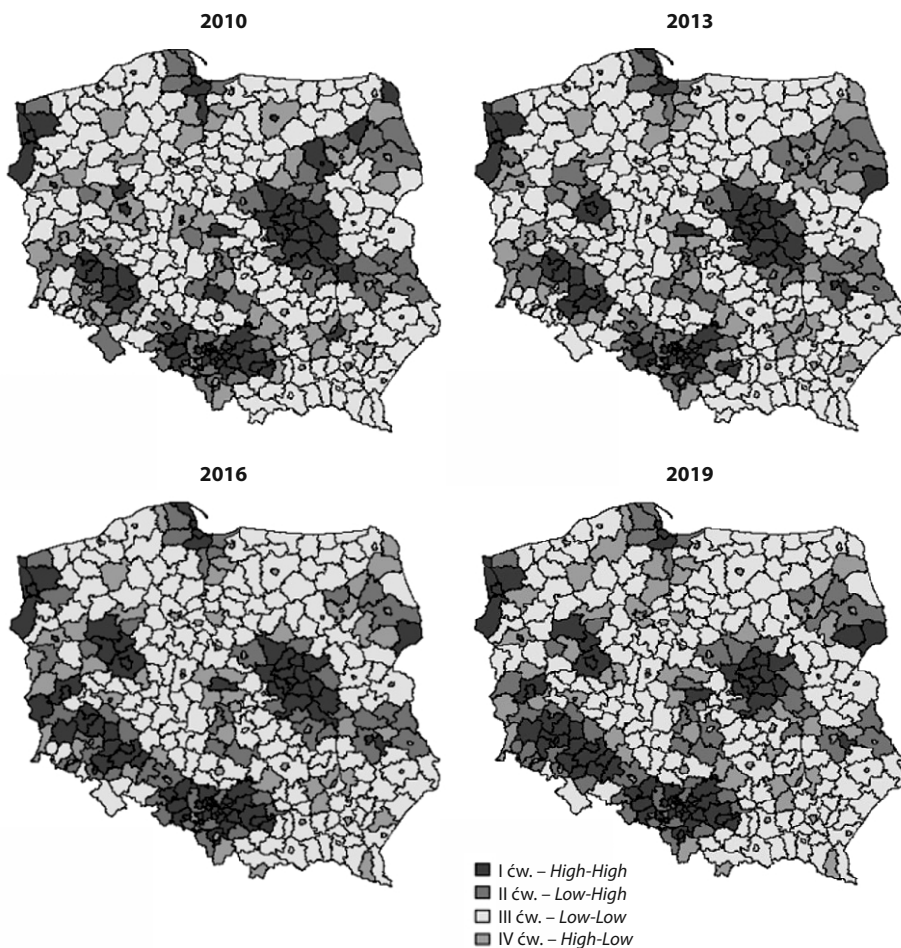
Graficzną prezentację wyników globalnych statystyk  $I$  Morana przedstawiono na wykresach punktowych (wykres). Dzięki linii regresji, określającej średni poziom wynagrodzeń, można zidentyfikować powiaty, w których wynagrodzenia są relatywnie wyższe i niższe. Powiaty charakteryzujące się niższymi przeciętnymi wynagrodzeniami znajdują się pod linią regresji, z kolei powiaty charakteryzujące się wyższymi wynagrodzeniami – nad tą linią. Na wykresach rozproszenia można zauważyć jednostki odstające od wartości średniej, oznaczone rombem. Do tej grupy należą m.in. powiaty miejskie: Warszawa, Płock, Gdańsk, Sopot, Poznań i Katowice oraz ziemskie, np.: łączyński, bełchatowski, warszawski zachodni, pruszkowski i lubiński. Powiaty zlokalizowane nad punktem 0 osi  $Y$  charakteryzują się wysokimi wynagrodzeniami w porównaniu ze wszystkimi analizowanymi powiatami, a nie tylko w stosunku do swoich sąsiadów.

**Wykres 1.** Wykresy rozproszenia Morana dla przeciętnych miesięcznych wynagrodzeń brutto (zmienna zestandaryzowana) na poziomie powiatów

Uwaga. HH – High-High, LH – Low-High, LL – Low-Low, HL – High-Low. BŁW – bełchatowski, BK – będziński, BL – bieruńsko-lęczyński, CN – cieszyński, DG – m. Dąbrowa Górnicza, GDN – m. Gdańsk, GDN – m. Gdynia, GG – głogowski, GM – grodziski, GW – m. Gliwice, GÓ – górowski, JWN – m. Jaworzno, JZ – m. Jastrzębie-Zdrój, KP – kępiński, KK – kędzierzyńsko-kozielski, KT – m. Katowice, KKS – krakowski, KW – m. Kraków, KZ – kozielnicki, LCK – legnicki, LG – legionowski, LNS – lubiński, ŁC – łęczyński, ML – milicki, MŁ – m. Mysłowice, NMR – nowodworski, OT – Otwock, PŁK – m. Płock, PN – przasnyski, PŃ – m. Poznań, PSN – piaseczyński, PŃS – pszczyński, PZ – pruszkowski, SP – m. Sopot, SSN – m. Sosnowiec, SŚ – m. Siemianowice Śląskie, TR – czarnkowsko-trzcianecki, WB – m. Wałbrzych, WC – m. Wrocław, WDŁ – wodzisławski, WŁB – wałbrzyski, WŁW – wołowski, WW – m. Warszawa, WZ – warszawski zachodni, ZMC – m. Zamość, ŻOR – m. Żory.

Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

Związki zachodzące pomiędzy powiatami pod względem poziomu wynagrodzeń a czynnikiem przestrzennym wyraźniej widać na mapach konturowych, które odwzorowują nie tylko położenie powiatów należących do poszczególnych ćwiartek z wykresu punktowego, lecz także wskazują położenie geograficzne danego powiatu w odniesieniu do pozostałych powiatów (mapa 2).

**Mapa 2.** Autokorelacja przestrzenna przeciętnych wynagrodzeń brutto na poziomie powiatów

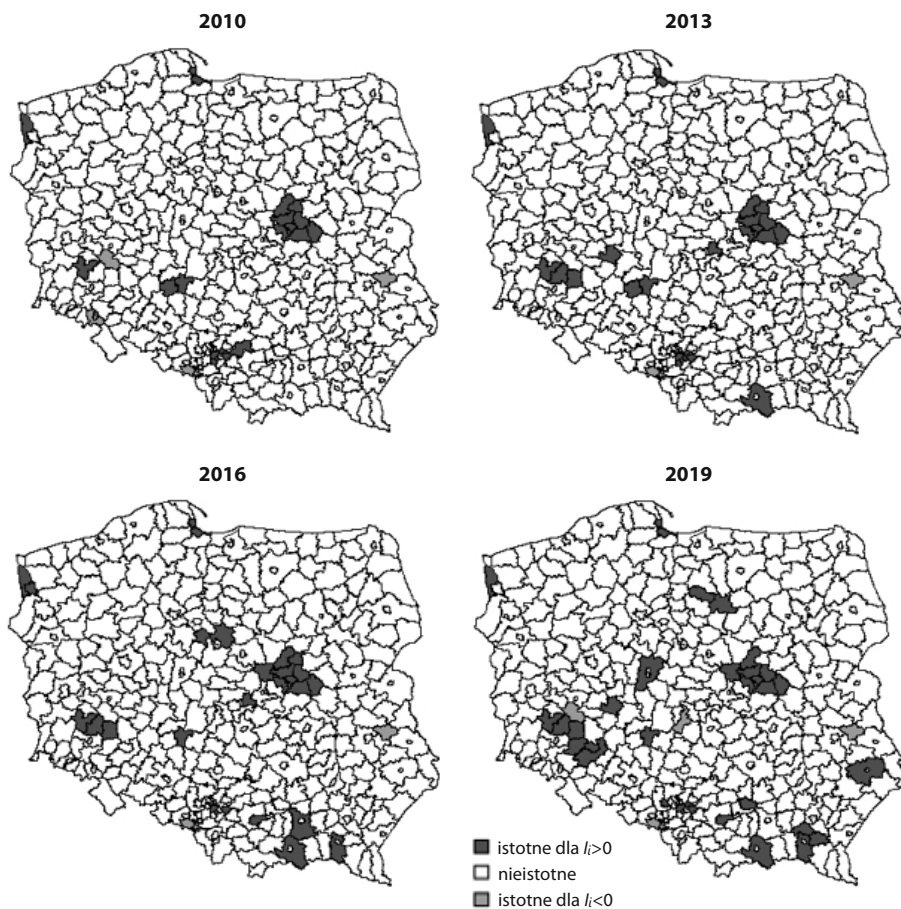
Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

Przestrzenny rozkład lokalnych statystyk  $I_i$  Morana na poziomie powiatów przedstawiono na mapie 3. Zwykle istotne lokalne statystyki Morana występują w regionach, w których zachodzi istotna autokorelacja globalna. Kolorami ciemno- i jasno-szarym oznaczono powiaty, w których obliczone lokalne statystyki Morana są istotne statystycznie, biorąc pod uwagę  $p$ -value  $< 0,05$  (dla  $I_i > 0$  – klastry powiatów podobnych) i  $p$ -value  $> 0,95$  (dla  $I_i < 0$  – obiekty typu *outlier*).

Na podstawie otrzymanych rezultatów można stwierdzić, że w 2010 r. największy – składający się z ośmiu jednostek – klastrowy powiatów, w których przeciętne wynagrodzenia brutto są relatywnie wysokie, zidentyfikowano w woj. mazowieckim

(tabl. 6). Klaster mazowiecki odznacza się istotnymi i wysokimi wartościami statystyk  $I_i$ . Stanowi on bardzo ważny region z punktu widzenia rynku pracy. Drugi, znacznie mniejszy klaster powiatów charakteryzujących się wysokimi wynagrodzeniami znajduje się w woj. pomorskim. W jego skład wchodzi wyłącznie miasta na prawach powiatu: Gdańsk, Gdynia i Sopot. Trzeci klaster skupiający powiaty, gdzie płace są relatywnie wysokie, jest zlokalizowany na granicy województw śląskiego i małopolskiego. Znalazło się w nim pięć powiatów: olkuski, Jaworzno, Katowice, Sosnowiec i Tychy. Wartości lokalnych statystyk  $I_i$  w tym skupieniu są istotne, ale dużo niższe niż w przypadku klastrów mazowieckiego i pomorskiego. W tabl. 6 i 7 nie uwzględniono skupisk jedno- i dwuelementowych.

**Mapa 3.** Rozkład przestrzenny istotnych i nieistotnych statystyk lokalnych  $I_i$  Morana na poziomie powiatów



**Tabl. 6.** Klustry powiatów podobnych pod względem przeciętnych miesięcznych wynagrodzeń brutto w 2010 r.

Powiaty	$I_i > 0$	$Var(I_i)$	$Z(I_i)$	$p$ -value
<b>Klaster mazowiecki</b>				
Grodziski .....	2,0446134	0,1571691	5,164017	1,208527e-07
Legionowski .....	1,1648671	0,1571691	2,944933	1,615125e-03
Nowodworski .....	1,4719960	0,1890845	3,391224	3,479064e-04
Otwocki .....	1,1712086	0,1890845	2,699502	3,472170e-03
Piaseczyński .....	2,9909493	0,1890845	6,884368	2,902240e-12
Pruszkowski .....	6,9669710	0,2369575	14,317698	8,482537e-47
Warszawski zachodni .....	3,7701745	0,1571691	9,516597	8,947160e-22
M.st. Warszawa .....	5,1799848	0,1343724	14,138214	1,104084e-45
<b>Klaster pomorski</b>				
M. Gdańsk .....	2,2483541	0,1890845	5,176618	1,129720e-07
M. Gdynia .....	1,4868838	0,1890845	3,425461	3,068783e-04
M. Sopot .....	5,4933348	0,4763228	7,963316	8,374453e-16
<b>Klaster śląski<sup>a</sup></b>				
Olkuski .....	0,6286053	0,1343724	1,722035	4,253155e-02
M. Jaworzno .....	0,8318101	0,1343724	2,276379	1,141167e-02
M. Katowice .....	1,2370418	0,1039768	3,844513	6,039592e-05
M. Sosnowiec .....	0,8832643	0,1890845	2,037315	2,080925e-02
M. Tychy .....	0,9387289	0,2369575	1,933855	2,656547e-02

a Nazwa klastra została ustalona ze względu na przeważającą liczbę powiatów woj. śląskiego.

Uwaga.  $I_i$  – statystyka lokalna Morana,  $Var(I_i)$  – wariancja,  $Z(I_i)$  – test istotności statystyki lokalnej Morana. Wartość oczekiwana –  $E(I_i)$  – wynosi  $-0,00263852$ .

Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

Przykładem jednostek typu odstającego w 2010 r. są powiaty górowski (woj. dolnośląskie;  $I_{2010} = -0,614$ ,  $p$ -value = 0,9523) i łączyński (woj. lubelskie;  $I_{2010} = -1,351$ ,  $p$ -value = 0,9997). Pierwszy z nich charakteryzuje się niską wartością przeciętnego wynagrodzenia, ale otoczony jest powiatami o relatywnie wyższych wartościach przeciętnej płacy, natomiast drugi odznacza się wysoką wartością przeciętnego wynagrodzenia, ale otoczony jest powiatami o relatywnie niskich wartościach analizowanej zmiennej. Na podstawie statystyk lokalnych  $I_i$  Morana w 2019 r. powiatami typu *outlier* były m.in. łącki (woj. łódzkie;  $I_{2019} = -0,6601$ ,  $p$ -value = 0,9505) i wodzisławski (woj. śląskie;  $I_{2019} = -1,4047$ ,  $p$ -value = 0,9979). Obydwa charakteryzują się niskimi wynagrodzeniami i są otoczone powiatami, w których wynagrodzenia są wyższe. W 2019 r. uwypukliły się jeszcze dwa klustry (tabl. 7): dolnośląski (klaster wysokich wynagrodzeń) i podkarpacki (klaster niskich wynagrodzeń).

**Tabl. 7.** Klustry powiatów podobnych pod względem przeciętnych miesięcznych wynagrodzeń brutto w 2019 r.

Powiaty	$I_i > 0$	$Var(I_i)$	$Z(I_i)$	$p$ -value
<b>Klaster dolnośląski</b>				
Lubiński .....	3,6985065	0,1911438	8,465566	1,274561e-17
Polkowicki .....	2,0044067	0,1911438	4,590680	2,209020e-06
Średzki .....	0,9118064	0,1358275	2,481211	6,546836e-03
Wołowski .....	2,4013518	0,1911438	5,498606	1,914027e-08
Wrocławski .....	0,8937316	0,1185411	2,603472	4,614245e-03
M. Wrocław .....	1,6637939	0,3202153	2,944874	1,615432e-03
<b>Klaster mazowiecki</b>				
Grodziski .....	2,3209193	0,1588759	5,829407	2,781227e-09
Nowodworski .....	1,5249456	0,1911438	3,494017	2,379053e-04
Otwocki .....	1,0429646	0,1911438	2,391590	8,387783e-03
Piaseczyński .....	2,3480531	0,1911438	5,376697	3,793241e-08
Pruszkowski .....	6,4662169	0,2395456	13,217014	3,499382e-40
Sochaczewski .....	0,6108344	0,1050962	1,892350	2,922204e-02
Warszawski zachodni .....	4,5468024	0,1588759	11,413766	1,784672e-30
M.st. Warszawa .....	4,6619009	0,1358275	12,656539	5,146927e-37
<b>Klaster podkarpacki</b>				
Brzozowski .....	0,7646822	0,1911438	1,755080	3,962285e-02
Krośnieński .....	0,8048097	0,1911438	1,846863	3,238353e-04
Strzyżowski .....	0,7379849	0,1588759	1,858097	3,157763e-03
<b>Klaster pomorski</b>				
M. Gdańsk .....	2,7554106	0,1911438	6,308439	1,409322e-10
M. Gdynia .....	2,0331716	0,1911438	4,656474	1,608356e-06
M. Sopot .....	6,8344193	0,4815540	9,852501	3,342948e-23
<b>Klaster śląski</b>				
M. Jaworzno .....	0,6183339	0,1358275	1,684917	4,600230e-02
M. Katowice .....	0,8870211	0,1050962	2,744293	3,032073e-03
M. Sosnowiec .....	0,8009170	0,1911438	1,837959	3,303424e-02

Uwaga. Jak przy tabl. 6.

Źródło: opracowanie własne na podstawie danych z BDL GUS z wykorzystaniem programu R-CRAN.

Obliczone globalne statystyki Morana przeciętnych miesięcznych wynagrodzeń są zbieżne z wynikami badań innych autorów, pomimo niewielkich różnic w otrzymanych wartościach. Pośpiech i Mastalerz-Kodzis (2015) wykazały istotną (bardzo słabą) dodatnią autokorelację przestrzenną wynagrodzeń w ujęciu powiatów w latach 2005–2013. Efektem ich badania było wyróżnienie kilku mniejszych podobnych klastrów i największego klastra wysokich wynagrodzeń w woj. mazowieckim, skupia-



jącego powiaty skoncentrowane wokół Warszawy. Podobne rezultaty otrzymała Lewandowska-Gwarda (2014). Z przeprowadzonego przez nią badania wynika, że wynagrodzenia w powiatach w okresie 2009–2012 charakteryzowały się dodatnią i bardzo słabą autokorelacją. Autorka wykazała m.in. koncentrację wysokich wynagrodzeń w powiatach w okolicach Warszawy. Wysokie wartości statystyk lokalnych Morana uzyskane w badaniu omawianym w niniejszym artykule potwierdzają ten wniosek.

## 5. Podsumowanie

Badanie związków przestrzennych z wykorzystaniem statystyk autokorelacji w Polsce na poziomie powiatu czy gminy jest zasadne. Przeprowadzona analiza statystyczna w ujęciu powiatowym wykazała homogenicznie spójne struktury przestrzenne pod względem wysokości przeciętnych miesięcznych wynagrodzeń. Poziom wynagrodzenia w danym powiecie jest uwarunkowany nie tylko wewnętrznym oddziaływaniem różnorodnych czynników, lecz także jego lokalizacją w powiązaniu z sąsiednimi powiatami.

Na podstawie analizy przeciętnych wynagrodzeń brutto w przeliczeniu na zatrudnionego w ujęciu powiatowym w latach 2010–2019 można stwierdzić, że wartości statystyk globalnych  $I$  Morana (0,1563–0,2458) i  $C$  Geary’ego (0,7175–0,7839) wskazują na występowanie istotnej dodatniej autokorelacji przestrzennej ze względu na wartości przeciętnych wynagrodzeń brutto w ujęciu powiatowym. Mimo że siła związku jest bardzo słaba lub słaba, zauważalny jest stopniowy – z roku na rok – wzrost zależności autokorelacyjnej, a więc wpływu czynnika przestrzennego na poziom wynagrodzeń w Polsce. Wzrost statystyk  $I$  Morana oraz spadek  $C$  Geary’ego może wskazywać na zmniejszenie się zróżnicowania regionalnego pod względem przeciętnego miesięcznego wynagrodzenia brutto pomiędzy powiatami i tym samym na zwiększenie zależności autokorelacji przestrzennej. W takiej sytuacji można przypuszczać, że w wyróżnionych jednorodnych klastrach powiaty, w których przeciętne wynagrodzenia brutto kształtują się na relatywnie wysokim poziomie, są otoczone jednostkami o wysokich wartościach wynagrodzeń, a powiaty, w których poziom wynagrodzeń jest relatywnie niski – jednostkami o niskich wartościach wynagrodzeń.

Na podstawie statystyk lokalnych autokorelacji zidentyfikowano istotne klastry powiatów podobnych pod względem przeciętnych wynagrodzeń oraz powiatów nietypowych (typu *outlier*), różniących się od przyjętego wzorca przestrzennego, do których w 2019 r. należały jednostki o niskich wartościach wynagrodzeń: łącki i wodzisławski, otoczone powiatami, w których wynagrodzenia były relatywnie wysokie. Do najważniejszych wyróżnionych klastrów zaliczają się mazowiecki, pomorski

i śląski, które skupiają powiaty o wysokich wartościach badanej zmiennej i charakteryzują się dobrą sytuacją na rynku pracy ze względu na kształtowanie się przeciętnych wynagrodzeń brutto.

Statystyczne metody autokorelacji przestrzennej dają dodatkowe możliwości w zakresie eksploracji danych statystycznych w celu zidentyfikowania związków przestrzennych w wybranym układzie regionalnym. Czyni to z nich ciekawą propozycję do wykorzystania – w powiązaniu z innymi metodami – w pomiarze zróżnicowania wynagrodzeń. Analiza przestrzennej zależności wynagrodzeń stanowi istotny element oceny sytuacji społeczno-gospodarczej kraju. Znajomość przestrzennego zróżnicowania przeciętnych wynagrodzeń brutto może zostać wykorzystana do tworzenia instrumentów polityki regionalnej, np. strategii rozwoju powiatu.

## Bibliografia

- Anselin, L. (1995). Local Indicators of Spatial Association—LISA. *Geographical Analysis*, 27(2), 93–115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>.
- Antoszek, P. (2010). *Regionalne różnice płac w Polsce i ich społeczno-ekonomiczne determinanty /W latach 1994–2004/* [rozprawa doktorska, Uniwersytet Ekonomiczny w Poznaniu]. <https://www.wbc.poznan.pl/publication/141521>.
- Cliff, A. D., Ord, J. K. (1973). *Spatial Autocorrelation*. Pion.
- Cliff, A. D., Ord, J. K. (1981). *Spatial Process. Models and Applications*. Pion.
- Czarnecki, A. (2013). Atrakcyjność rynków pracy małych miast w Polsce (dla ludności miejscowej i dojeżdżających). *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, (144), 165–187. [https://www.ue.katowice.pl/fileadmin/\\_migrated/content\\_uploads/11\\_A.Czarnecki\\_Atrakcyjnosc\\_rynkow\\_pracy....pdf](https://www.ue.katowice.pl/fileadmin/_migrated/content_uploads/11_A.Czarnecki_Atrakcyjnosc_rynkow_pracy....pdf).
- Geary, R. C. (1954). The Contiguity Ratio and Statistical Mapping. *The Incorporated Statistician*, 5(3), 115–146. <https://doi.org/10.2307/2986645>.
- Główny Urząd Statystyczny. (b.r.). *Przeciętne miesięczne wynagrodzenia brutto* [zbiór danych]. Pobrane 1 sierpnia 2021 r. z <https://bdl.stat.gov.pl/BDL/dane/podgrup/temat>.
- Główny Urząd Statystyczny. (2020). *Zeszyt metodologiczny. Statystyka rynku pracy i wynagrodzeń*. <https://stat.gov.pl/obszary-tematyczne/rynek-pracy/zasady-metodyczne-rocznik-pracy/zeszyt-metodologiczny-statystyka-ryнку-pracy-i-wynagrodzen,1,3.html>.
- Jarmołowicz, W., Knapińska, M. (2011). Współczesne teorie rynku pracy a mobilność i przepływy pracowników w dobie globalizacji. *Zeszyty Naukowe Polskiego Towarzystwa Ekonomicznego*, (9), 123–144. [http://www.pte.pl/pliki/1/1144/ZN-9\\_Jarmolowicz\\_Knapińska.pdf](http://www.pte.pl/pliki/1/1144/ZN-9_Jarmolowicz_Knapińska.pdf).
- Jarmołowicz, W., Knapińska, M. (2013). Polityka gospodarcza wobec zatrudniania i wynagradzania pracowników – aspekty teoretyczne i realizacyjne. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, (160), 9–21.
- Kołodziejczak, A., Kossowski, T. (2016). Wykorzystanie metody autokorelacji przestrzennej do analizy ubóstwa na obszarach wiejskich. *Wiadomości Statystyczne*, 61(10), 22–32. <https://doi.org/10.5604/01.3001.0014.1107>.

- Kopczewska, K. (2011). *Ekonometria i statystyka przestrzenna z wykorzystaniem programu R Cran. CeDeWu*.
- Kopczewska, K. (red.). (2020). *Przestrzenne metody ilościowe w R*. CeDeWu.
- Lewandowska-Gwarda, K. (2014). Analiza przestrzennego zróżnicowania wynagrodzeń w Polsce w latach 2009–2012. *Roczniki Kolegium Analiz Ekonomicznych*, (34), 27–41.
- Moran, P. A. P. (1948). The Interpretation of Statistical Maps. *Journal of the Royal Statistical Society*, 10(2), 243–251. <https://doi.org/10.1111/j.2517-6161.1948.tb00012.x>.
- Moran, P. A. P. (1950). Notes on continuous stochastic phenomena. *Biometrika*, 37(1–2), 17–23. <https://doi.org/10.2307/2332142>.
- Müller-Frączek, I., Pietrzak, M. B. (2008). Wykorzystanie narzędzi statystyki przestrzennej do identyfikacji kluczowych ośrodków rozwoju województwa kujawsko-pomorskiego. *Acta Universitatis Nicolai Copernici*, (388), 229–238. [http://dx.doi.org/10.12775/AUNC\\_ECON.2008.016](http://dx.doi.org/10.12775/AUNC_ECON.2008.016).
- Ord, J. K., Getis, A. (1995). Local Spatial Autocorrelation Statistics: Distributional Issues and an Application. *Geographical Analysis*, 27(4), 286–306. <https://doi.org/10.1111/j.1538-4632.1995.tb00912.x>.
- Pośpiech, E. (2015). Analiza przestrzenna bezrobocia w Polsce. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, (227), 59–74. [https://www.ue.katowice.pl/fileadmin/\\_migrated/content\\_uploads/05\\_30.pdf](https://www.ue.katowice.pl/fileadmin/_migrated/content_uploads/05_30.pdf).
- Pośpiech, E., Mastalerz-Kodzis, A. (2015). Autokorelacja przestrzenna wybranych charakterystyk społeczno-ekonomicznych. *Metody Ilościowe w Badaniach Ekonomicznych*, 16(4), 85–94. [http://qme.sggw.pl/pdf/MIBE\\_T16\\_z4\\_08.pdf](http://qme.sggw.pl/pdf/MIBE_T16_z4_08.pdf).
- Pośpiech, E., Mastalerz-Kodzis, A. (2018). Analiza przestrzenna rozwoju społeczeństwa informacyjnego w Polsce. *Nierówności Społeczne a Wzrost Gospodarczy*, 53(1), 286–296. <https://repozytorium.ur.edu.pl/handle/item/3718>.
- Sikora, J. (2009). Określenie siły i charakteru autokorelacji przestrzennej na podstawie globalnej statystyki I Morana infrastruktury rolniczej Polski południowej i południowo-wschodniej. *Infrastruktura i Ekologia Terenów Wiejskich*, (9), 217–227.
- Suchecka, J. (red.). (2014). *Statystyka przestrzenna. Metody analiz struktur przestrzennych*. C. H. Beck.
- Suchecky, B. (red.). (2010). *Ekonometria przestrzenna. Metody i modele analizy danych przestrzennych*. C. H. Beck.
- Szczuciński, P. (2019). Autokorelacja przestrzenna wybranych cech rozwoju gmin w województwie lubuskim. *Optimum. Economic Studies*, 3(97), 164–176. [https://repozytorium.uwb.edu.pl/jspui/bitstream/11320/8124/1/Optimum\\_3\\_2019\\_P\\_Szczucinski\\_Autokorelacja\\_przestrzenna.pdf](https://repozytorium.uwb.edu.pl/jspui/bitstream/11320/8124/1/Optimum_3_2019_P_Szczucinski_Autokorelacja_przestrzenna.pdf).
- Wilk, J., Pietrzak, M. B., Bivand, R. S., Kossowski, T. (2015). Wpływ wyboru metody klasyfikacji na identyfikację zależności przestrzennych – zastosowanie testu join-count. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu / Research Papers of Wrocław University of Economics*, (384), 296–304. <https://doi.org/10.15611/pn.2015.384.32>.
- Zieliński, K. (2011). Regionalne zróżnicowanie płac w Polsce – kierunki zmian. *Zeszyty Naukowe Uniwersytetu Ekonomicznego w Krakowie*, (863), 69–83. <https://r.uek.krakow.pl/bitstream/123456789/1059/1/171192067.pdf>.