



Tom 25/2017, ss. 49–65  
ISSN 1644-888X  
e-ISSN 2449-7975  
DOI: 10.19251/ne/2017.25(3)  
www.ne.pwspzlock.pl

---

**Paweł Kaczmarczyk**

Państwowa Wyższa Szkoła Zawodowa w Płocku

## **ZASTOSOWANIE METOD PORZĄDKOWANIA LINIOWEGO W BADANIU WOJEWÓDZTW POD WZGLĘDEM STOPNIA WYKORZYSTANIA ICT W PRZEDSIĘBIORSTWACH**

APPLICATION OF THE LINEAR ORDERING METHODS IN THE  
VOIVODESHIPS RESEARCH IN TERMS OF THE ICT USAGE IN  
ENTERPRISES

### **Streszczenie**

Celem opracowania jest analiza stopnia wykorzystania ICT przez polskie przedsiębiorstwa w podziale na województwa. W części teoretycznej przedstawiono problematykę roli ICT w gospodarce postindustrialnej, a zwłaszcza znaczenie poziomu nakładów na ICT w kontekście wzrostu gospodarczego. Zaprezentowano również metodykę zrealizowanych badań własnych. W części empirycznej przedstawiono wyniki analiz, których celem było uporządkowanie województw pod względem wykorzystania

### **Summary**

The aim of the study is to analyze the degree of ICT usage in Polish enterprises in the particular voivodeships. The theoretical part presents the issue of ICT role in the post-industrial economy, especially the importance of expenditure on ICT with regard to the economic growth. The methodology of own research was also presented. The empirical part presents the results of the research which was carried out to obtain rankings of voivodeships in terms of the ICT usage in enterprises. Seventeen potential diagnostic variables

ICT przez przedsiębiorstwa. W oparciu o dane z publikacji GUS zdefiniowano siedemnaście potencjalnych zmiennych diagnostycznych. Ostatecznie wykorzystano jedenaście zmiennych mających najwyższe możliwości dyskryminacyjne. Rankingi utworzono z wykorzystaniem trzech metod porządkowania. We wszystkich uzyskanych rankingach pierwsze trzy miejsca zajmują odpowiednio województwa: mazowieckie, małopolskie, dolnośląskie.

**Słowa kluczowe:** ICT, wzrost gospodarczy, województwa, porządkowanie liniowe.

## Wprowadzenie

Na przełomie XX i XXI wieku rzeczywistość gospodarczą zaczęto określać jako gospodarka postindustrialna. Jedną z cech gospodarki postindustrialnej jest to, że odchodzi się w niej od dominacji wielkiego przemysłu na rzecz przewagi sektora usługowego. Inną cechą tej gospodarki jest wskazywanie wiedzy jako istotnego czynnika wzrostu gospodarczego. Gospodarka postindustrialna jest więc określana również gospodarką opartą na wiedzy.

Niezwykle ważne znaczenie mają w tym kontekście technologie informacyjno-komunikacyjne (ICT). W literaturze, obejmującej zagadnienia gospodarki opartej na wiedzy, zwraca się uwagę na fakt, iż przedsiębiorstwa postindustrialne to przedsiębiorstwa, które swoje funkcjonowanie w dużym stopniu opierają o nowoczesne technologie teleinformatyczne. Dostęp do Internetu w wyraźny sposób podnosi konkurencyjność przedsiębiorstw [Paszta, 2010, s. 362-369]. Wykazywany jest również istotny związek pomiędzy nakładami na ICT a wzrostem produktywności [Picot i Wernick, 2007, s. 660-674].

Celem niniejszego opracowania jest analiza rozwoju województw pod względem stopnia wykorzystania ICT. Wykorzystanie ICT jest rozumiane m.in. jako odsetek przedsiębiorstw, w których: pracownicy wykorzystują komputery, pracownicy wykorzystują komputery z dostępem do Internetu, wykorzystywane jest przynajmniej jedno z mediów społecznościowych, wykorzystywane są sieci komputerowe do składania lub otrzymywania zamówień.

were defined. These variables were based on data from the publications of the Central Statistical Office. Finally, eleven variables with the highest discriminatory potential were used. The rankings were created with the use of three ordering methods. In all obtained rankings, the first three places are occupied by the following voivodeships: mazowieckie, małopolskie, dolnośląskie.

**Keywords:** ICT, economic growth, voivodeships, linear ordering.

W przeprowadzonych analizach zastosowano metody porządkowania obiektów (województw) oparte na wzorcu rozwoju i bezwzorcowe. Wyniki badań są podstawą formułowania rankingów pod względem analizowanych cech i dostarczają wiedzy na temat potencjału rozwoju społeczno-gospodarczego poszczególnych województw.

## 1. Rola ICT w gospodarce postindustrialnej

Współcześnie znany jest wpływ ICT na produktywność i na PKB. W związku z tym w literaturze pojawiły się modele wzrostu obejmujące nakłady na te technologie. Model wzrostu uwzględniający oddziaływanie ICT wykorzystuje funkcję produkcji Cobba-Douglasa. Zatem zmienna objaśniana tj. PKB ( $Y$ ) zależy w sposób potęgowy od kapitału wydatkowanego na ICT, pozostałego kapitału ( $N_{ICT}$ ) oraz zatrudnienia mierzonego liczbą godzin pracy ( $L$ ). Jedyna liniowa zależność związana jest z ogólnym poziomem technologii ( $A$ ):

$$Y = AL^{\alpha}N_{ICT}^{\beta}ICT^{\gamma}$$

Podobna zależność została sformułowana dla produktywności pracy ( $Y/L$ ):

$$Y/L = AL^{\alpha-1}N_{ICT}^{\beta}ICT^{\gamma}$$

Inwestycje w ICT w obecnej fali innowacyjnej stanowią więc istotną rolę w rozwoju społeczno-gospodarczym. W krajach wysoko rozwiniętych i niektórych nowo uprzemysłowionych nakłady na ICT stymulują wzrost gospodarczy, natomiast w krajach słabiej rozwiniętych to zazwyczaj wysoki wzrost gospodarczy powoduje zwiększenie aktywności inwestycyjnej w zakresie ICT. Nadal są kraje, gdzie głównymi źródłami wzrostu są kapitał fizyczny lub tradycyjne technologie, jednak inwestycje w te zasoby są przyczyną znacznej części luki rozwojowej [Zielińska-Głębocka, 2012, s. 48-49].

W literaturze przedmiotu znajdują się opisy wyników badań związanych z estymacją modeli Cobba-Douglasa posiadającymi wśród zmiennych niezależnych zmienną reprezentującą sektor informacyjny. Analizę wpływu sektora informacyjnego na PKB dokonali R. Hayes i H. Borko na podstawie gospodarki USA. Wykorzystane przez nich zmienne objaśniające dotyczyły: kapitału podstawowego określonej gałęzi ( $K$ ), zatrudnienia w danej gałęzi ( $L$ ), wydatków danej gałęzi na informacje (sektor informacji -  $I$ ) oraz wydatków danej gałęzi na surowce i półfabrykaty ( $X$ ). Każda zmienna zawierała obserwacje pochodzące z pięćdziesięciu jeden gałęzi produkcji przemysłowej. W analizach przyjęto następującą funkcję:

$$\log(Y) = \log(a) + d \log(L) + b \log(I) + c \log(K) + e \log(X)$$

Otrzymane wartości współczynników determinacji ( $R^2$ ) dla okresów rocznych przekraczały poziom 0,98.

Estymacją modeli Cobba-Douglasa dla danych USA zajmował się również H. Engelbrecht, który w swoich analizach uwzględniał wpływ innych czynników, związanych z popytem na informacje, na przykład w rozwoju naukowo-technicznym.

Z kolei C. Simon i C. Nardinelli zajmowali się teorią rozwoju miast. Głównym celem ich badań była ocena zależności pomiędzy wzrostem populacji miast a poziomem kapitału ludzkiego. Badaniami objęli siedemdziesiąt dziewięć miast angielskich i walijskich z okresu stu lat. Zgodnie z funkcją produkcji Cobba-Douglasa przyjęli, że produkcja dóbr przemysłowych ( $Mt$ ) zależy od zatrudnienia ( $LMt$ ), ilości ziemi ( $T$ ), ilości usług informacyjnych (wyodrębnionych z sektora usług) w czasie  $t$  ( $It$ ):

$$Mt = f(LMt, T, It).$$

Zmienna  $It$  jest funkcją: bieżącego zasobu specyficznej wiedzy miasta ( $Kt$ ), poszczególnych  $n$  typów usług informacyjnych ( $nt$ ), produkcji każdego z komponentów  $nt$  ( $St$ ):

$$It = g(Kt, St, nt).$$

Badacze przyjęli, że stopa wzrostu miasta (tj. specyficzna wiedza) zależy od liczby zatrudnionych w sektorze informacyjnym ( $Lst$ ) oraz różnorodności usług informacyjnych ( $nt$ ):

$$Kt + \frac{I}{Kt} = h(Lst, nt).$$

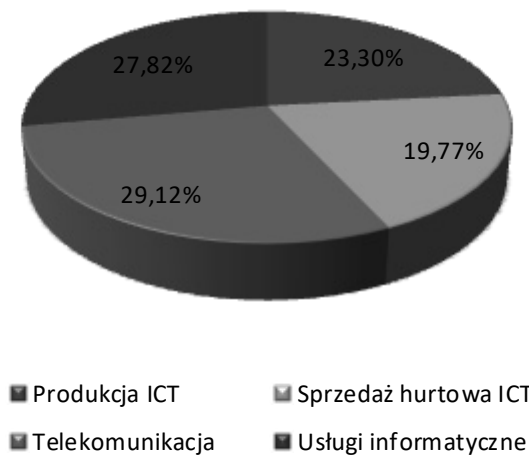
Na podstawie wyników badań dowiedziono, że miasta posiadające większą koncentrację kapitału ludzkiego (wyrażającą się wyższymi wartościami  $Lst$  i  $nt$ ) wyróżniają się szybszym rozwojem.

Wyniki, które były otrzymywane przez wymienionych powyżej autorów, potwierdzały niezaprzeczalną rolę sektora informacyjnego w rozwoju gospodarczym (uzyskiwane wartości  $R^2$  wynosiły niejednokrotnie nawet powyżej 0,98) [Dziuba, 2007, s. 126-130].

Istnieją również wyniki badań wpływu przyrostu linii szerokopasmowych na wzrost gospodarczy. L. Roller i L. Waverman potwierdzili w tym zakresie istotną korelację (na podstawie ponad dwudziestoletniego okresu)

dla 21 krajów OECD. Przy czym według ich analiz wpływ przyrostu sieci szerokopasmowych na wzrost gospodarczy jest znaczący dopiero po osiągnięciu przez infrastrukturę telekomunikacyjną odpowiedniej masy krytycznej. Podobne wyniki uzyskali A. Datta i S. Agarwal dla 22 krajów OECD. Następnie S. Koutroumpis (na podstawie 15 krajów UE) wykazał że przyrost sieci szerokopasmowych w latach 2002-2007 skutkował wzrostem gospodarczym, który stanowił 16,92% całkowitego wzrostu w tym okresie. Z kolei S. Greenstein i P. McDevitt oszacowali, że infrastruktura szerokopasmowa w USA kreuje w przybliżeniu od 8,3 do 10,6 bilionów dolarów PKB. [Cambini i Jiang, 2009, s. 559-560].

Coraz szersze zastosowanie technologii informacyjnych w procesach gospodarczych spowodowało, że jednym z ważniejszych wskaźników rozwoju gospodarczego kraju jest poziom dochodu generowany w sektorze wysokich technologii. W polskim sektorze ICT przychody netto ze sprzedaży charakteryzują się tendencją rosnącą i w 2015 r. wyniosły 138813 mln zł. Strukturę przychodów netto ze sprzedaży w 2015 r. przedstawiono na wykresie 1.



**Wykres 1. Struktura przychodów netto ze sprzedaży w sektorze ICT w 2015 r.**

Źródło: Opracowanie własne na podstawie [GUS, 2016, s. 21].

Zarówno w 2015 r. jak i w poprzednich latach dominujący udział w przychodach netto ze sprzedaży zajmowała telekomunikacja, co wynikało z odpowiednio prowadzonej polityki telekomunikacyjnej, która zakładała m.in. obniżenie cen, stymulowanie konkurencji, zapewnienie odpowiedniego poziomu jakości usług [Kaczmarczyk, 2015, s. 79-94].

Ze względu na to, że do opisu obecnej rzeczywistości gospodarczej wykorzystywane jest pojęcie gospodarki postindustrialnej, to współczesne przedsiębiorstwa nazywane są przedsiębiorstwami postindustrialnymi. Jedną z cech charakteryzującą firmę postindustrialną jest to, że wykorzystuje technologię informacyjno-komunikacyjną dla potrzeb zarządzania i organizowania swoich działań. Wraz z rozwojem technologii informacyjno-komunikacyjnych pojawiły się nowe koncepcje zarządzania, których idea bazuje na tych technologiach. Jednocześnie zauważalne jest zjawisko odchodzenia od dotychczasowych form prowadzenia biznesu. Istnieją już nawet firmy, których funkcjonowanie całkowicie uzależnione jest od Internetu i sieci z nim powiązanych [Gonciarski, 2009, s. 25-41].

## 2. Metodyka badań

W procedurze porządkowania liniowego obiektów wielocechowych wykorzystuje się miary syntetyczne (inaczej zmienne agregatowe). Porządkowanie polega na stworzeniu rankingu porównywanych obiektów tzn. ułożeniu ich od *najlepszego* do *najgorszego* w analizowanym kontekście badawczym.

Wśród metod wyznaczania miernika syntetycznego wyróżnia się metody wzorcowe i bezwzorcowe [Walesiak, 2004, s. 351-368; Panek i Zwierzchowski, 2013, s. 57-97]. W części empirycznej niniejszego opracowania zastosowano obydwie rodzaje tych metod, co stanowiło szerszą podstawę do formułowania wniosków. W metodach bezwzorcowych syntetyczny miernik oblicza się z wykorzystaniem funkcji przekształconych (znormalizowanych) cech zbioru wyjściowego. Natomiast do sposobów przekształcania cech (nazywanych ogólnie normalizacją) zalicza się np.: standaryzację, unitaryzację lub normalizację. Zatem w przeprowadzonych badaniach zastosowano następujące miary syntetyczne:

1. Średnia arytmetyczna zunitaryzowanych cech:

$$s_i = \frac{1}{p} \sum_{j=1}^p x_{ij} \quad \text{dla } i = 1, \dots, n,$$

gdzie:

$$x_{ij} := \frac{x_{ij} - \min_i x_{ij}}{\max_i x_{ij} - \min_i x_{ij}}$$

Zunitaryzowane wartości  $x_{ij}$  mieszczą się w przedziale  $[0, 1]$  i zachowują zróżnicowane wartości wariancji.

2. Średnia arytmetyczna znormalizowanych cech:

$$h_i = \frac{1}{p} \sum_{j=1}^p x_{ij} \quad \text{dla } i = 1, \dots, n,$$

gdzie:

$$x_{ij} := \frac{x_{ij}}{\max_i x_{ij}}$$

Powyższe przekształcenie charakteryzuje się tym, że cechy zachowują zróżnicowane wariancje i proporcje pomiędzy wartościami znormalizowanymi a pierwotnymi, co jest niewątpliwą zaletą tego sposobu przekształcenia cech.

W metodach wzorcowych wybiera się tzw. obiekt wzorcowy (inaczej biegun górny zbioru obiektów). Wybrany wzorzec to obiekt o najkorzystniejszych wartościach cech. Następnie oblicza się odległości taksonomiczne badanych obiektów do obiektu wzorcowego. Obliczone odległości stanowią zazwyczaj wartości zmiennej syntetycznej. Analogiczne postępowanie można przeprowadzić z wykorzystaniem obiektu-antywzorca (bieguna dolnego zbioru obiektów). Oczywiście jest wówczas konieczność odwrotnego porządkowania badanych obiektów, tzn. obiekt najbardziej oddalony od antywzorca staje się liderem.

Z grupy metod wzorcowych zastosowano metodę Hellwiga. Macierz danych przekształcono zgodnie z poniższą formułą (tj. przeprowadzono standaryzację):

$$x_{ij} := \frac{x_{ij} - \bar{x}_j}{s_j}$$

Po standaryzacji zmienne mają wariancję 1 oraz średnią 0. Następnie znaleziono obiekt wzorcowy  $P_0$ , którego geometryczną reprezentacją jest punkt:

$$X_0 = (x_{01}, x_{02}, \dots, x_{0p}).$$

Współrzędne obiektu-wzorca wyznaczane są następujący sposób:

$$x_{0k} = \begin{cases} \max_i x_{ij} & \text{dla } j \in S \\ \min_i x_{ij} & \text{dla } j \notin S \end{cases}$$

gdzie:

$S$  – zbiór standaryzowanych stymulant.

W przeprowadzonych badaniach wszystkie zmienne miały charakter stymulant, zatem współrzędne wzorca wybrano w oparciu o pierwszy z wymienionych wariantów.

Syntetyczna miara Hellwiga jest następująca:

$$d_i = 1 - \frac{d_{i0}}{d_0} \quad i = 1, 2, \dots, n$$

gdzie:

$$d_{i0} = d(x_i, x_0) = \sqrt{\sum_{j=1}^p (x_{ij} - x_{0j})^2}$$

$$d_0 = \bar{d}_0 + 2s_d$$

Wartości  $\bar{d}_0$  oraz  $s_d$  obliczane są następująco:

$$\bar{d}_0 = \frac{1}{n} \sum_{i=1}^n d_{i0}$$

$$s_d = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_{i0} - \bar{d}_0)^2}$$

Im wartości miary  $d_i$  są bliższe jedności tym mniejsza jest odległość od wzorca.

Wartości miar syntetycznych umożliwiają przeprowadzenie procedury klasyfikacji obiektów. Klasyfikacja realizowana jest wówczas w oparciu o jedną cechę – zmienną syntetyczną. Jednak z uwagi na cel niniejszego opracowania, część metodologiczną oraz badania empiryczne ograniczono do kwestii związanych z porządkiem województw. Wychodząc poza wykorzystany w badaniu zakres metodologiczny, wśród metod porządkowania obiektów można wskazać również metodę UTA [Becker, 2011, s. 477-485].

W celu otrzymania wiarygodnych wyników warto jest przygotować kilka rankingów, opartych na różnych metodach i różnych założeniach, a następnie zbadać je pod względem zgodności otrzymanych wyników [Olszewska i Gudanowska, 2014, s. 91-100]. Zatem do porównania otrzymanych rankingów z wykorzystaniem opisanych miar syntetycznych wykorzystano



współczynnik korelacji rangowej Spearmana oraz współczynnik korelacji rangowej Kendalla [Wawrzynek i in., 1998, s. 30-129].

W obu metodach przyjmuje się, że każda para porównywanych zmiennych syntetycznych to dwuwymiarowa zmienna losowa  $(X, Y)$ , natomiast  $(X_1, Y_1), \dots, (X_n, Y_n)$  jest próbą losową tej zmiennej. Wartości obu współczynników mieszczą się przedziale  $[-1; 1]$ . Im wyższa jest wartość bezwzględna, tym silniejsza jest zależność badanych zmiennych. W celu wyznaczenia współczynnika korelacji rangowej Spearmana, elementy  $X_i$  porządkowane są rosnąco lub malejąco, a następnie nadawane są im rangi  $r(X_i)$ . Z kolei elementom  $Y_i$  nadawane są rangi  $r(Y_i)$ . Rangami są kolejne liczby naturalne. Konieczne jest przyjęcie takiego samego sposobu rangowania wartości obu zmiennych rozpatrywanej zmiennej dwuwymiarowej. W przypadku powtarzających się uporządkowanych wartości zmiennej, przypisywane są im średnie arytmetyczne odpowiadającym im rang. Współczynnik korelacji rangowej Spearmana oblicza się następująco:

$$\rho_n = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)},$$

gdzie:

$$d_i = r(X_i) - r(Y_i).$$

Wartość krytyczną  $r_n(\alpha)$  współczynnika korelacji rangowej Spearmana (dla dużych prób) wyznacza się według formuły:

$$r_n(\alpha) \approx \frac{x_{1-\alpha}}{\sqrt{n-1}} \left\{ 1 - \frac{0,19}{n-1} (x_{1-\alpha}^2 - 3) \right\},$$

gdzie  $x_{1-\alpha}$  oznacza kwantyl rzędu  $1 - \alpha$  rozkładu normalnego  $N(0,1)$ .

Prawdopodobieństwo, że empiryczna wartość współczynnika jest większa od wartości krytycznej (a więc prawdopodobieństwo zależności zmiennych) możemy zapisać w poniższy sposób:

$$P\{\rho_n > r_n(\alpha)\} \leq \alpha.$$

W celu wyznaczenia współczynnika korelacji rangowej Kendalla realizacje dwuwymiarowej zmiennej  $(X, Y)$  porządkowane są według rosnących  $X_i$  (czyli przeprowadzane jest rangowanie). Otrzymujemy zatem ciąg par wartości:

$$(X_{1:n}, Y_1^*), (X_{2:n}, Y_2^*), \dots, (X_{n:n}, Y_n^*)$$

W odniesieniu do wartości zmiennej  $X$  spełniona jest relacja:

$$X_{1:n} < X_{2:n} < \dots < X_{n:n}$$

Wartość współczynnika korelacji rangowej Kendalla uzyskiwana jest z wykorzystaniem poniższej formuły:

$$\tau_n = \frac{4 \sum_{i=1}^n S_i}{n(n-1)} - 1,$$

gdzie  $S_i$  oznacza liczbę takich par  $(X_{j:n}, Y_j^*)$ ,  $j > i$ , w których  $Y_j^* > Y_i^*$ .

Wartość krytyczną  $t_n(\alpha)$  współczynnika korelacji rangowej Kendalla (dla dużych prób) wyznacza się według formuły:

$$t_n(\alpha) \approx \frac{2}{3} \sqrt{\frac{n+2,5}{n(n-1)}} \cdot x_{1-\alpha} + \frac{2}{n(n-1)},$$

gdzie  $x_{1-\alpha}$  oznacza kwantyl rzędu  $1 - \alpha$  rozkładu normalnego  $N(0,1)$ .

Wykorzystywana w przeprowadzonych analizach relacja:

$$P\{\tau_n > t_n(\alpha)\} \leq \alpha$$

określa prawdopodobieństwo, że empiryczna wartość współczynnika jest większa od wartości krytycznej (czyli prawdopodobieństwo zależności zmiennych).

### 3. Wyniki badań

Badania przeprowadzono w oparciu o dane pochodzące z 2015 r. Porządkowanymi obiektami były województwa ( $i = 1, 2, \dots, 16$ ). Wytypowano wstępnie siedemnaście zmiennych diagnostycznych ( $j = 1, 2, \dots, 17$ ). Zmiennymi diagnostycznymi opisującymi porządkowane obiekty były wskaźniki struktury odnoszące się do przedsiębiorstw lub pracowników korzystających z określonego rodzaju ICT. Zestawiono następujące zmienne:

1. Przedsiębiorstwa wykorzystujące komputery ( $X_1$ ).
2. Przedsiębiorstwa posiadające dostęp do Internetu ( $X_2$ ).
3. Przedsiębiorstwa z szerokopasmowym dostępem do Internetu ( $X_3$ ).
4. Przedsiębiorstwa posiadające szerokopasmowy dostęp do Internetu z wykorzystaniem łącza DSL lub innego stałego łącza szerokopasmowego np. ADSL, SDSL, VDSL, sieć światłowodowa, sieć telewizji kablowej ( $X_4$ ).

5. Przedsiębiorstwa posiadające szerokopasmowy dostęp do Internetu z wykorzystaniem komputera z modemem 3G ( $X_5$ ).
6. Przedsiębiorstwa posiadające szerokopasmowy dostęp do Internetu z wykorzystaniem telefonu w technologii 3G np. smartfon ( $X_6$ ).
7. Pracownicy wykorzystujący komputery w przedsiębiorstwach ( $X_7$ ).
8. Pracownicy wykorzystujący komputery z dostępem do Internetu ( $X_8$ ).
9. Przedsiębiorstwa wykorzystujące przynajmniej jedno z mediów społecznościowych ( $X_9$ ).
10. Przedsiębiorstwa wykorzystujące serwisy społecznościowe ( $X_{10}$ ).
11. Przedsiębiorstwa prowadzące blogi i mikroblogi ( $X_{11}$ ).
12. Przedsiębiorstwa wykorzystujące portale umożliwiające udostępnianie multimediów ( $X_{12}$ ).
13. Przedsiębiorstwa wykorzystujące narzędzia Wiki ( $X_{13}$ ).
14. Przedsiębiorstwa składające zamówienia przez sieci komputerowe ( $X_{14}$ ).
15. Przedsiębiorstwa otrzymujące zamówienia przez sieci komputerowe ( $X_{15}$ ).
16. Przedsiębiorstwa korzystające z e-administracji ( $X_{16}$ ).
17. Przedsiębiorstwa przeprowadzające analizy big data ( $X_{17}$ ).

Analizy rozpoczęto od wyznaczenia wartości minimalnej ( $x_{\min}$ ), maksymalnej ( $x_{\max}$ ), rozpiętości ( $R$ ), średniej ( $\bar{x}$ ), odchylenia standardowego ( $s$ ), współczynnika zmienności ( $V$ ) oraz współczynnika skośności ( $A$ ). Wartości statystyk opisowych przedstawiono w tabeli poniżej.

**Tabela 1. Parametry statystyczne badanych zmiennych**

Zmienna	$x_{\min}$	$x_{\max}$	$R$	$\bar{x}$	$s$	$V$	$A$
$X_1$	89,3	97,4	8,1	93,6688	1,9754	2,11	-0,2934
$X_2$	86,7	95,7	9,0	92,2313	2,2768	2,47	-0,7016
$X_3$	83,8	95,5	11,7	91,3125	3,2473	3,56	-0,8863
$X_4$	76,0	92,5	16,5	85,6313	4,2719	4,99	-0,4680
$X_5$	42,7	67,7	25,0	51,0563	6,0588	11,87	1,2469
$X_6$	40,0	62,3	22,3	46,2000	5,6441	12,22	1,4982
$X_7$	28,2	58,0	29,8	38,1313	6,9060	18,11	1,5634
$X_8$	24,9	53,6	28,7	33,2125	6,8601	20,66	1,8079
$X_9$	15,2	28,9	13,7	20,5375	3,3508	16,32	0,5984
$X_{10}$	12,8	27,1	14,3	18,6000	3,4215	18,40	0,5305
$X_{11}$	1,8	7,0	5,2	3,4438	1,4656	42,56	1,3560
$X_{12}$	4,9	10,9	6,0	7,1875	1,5671	21,80	0,7278

Zmienna	$x_{\min}$	$x_{\max}$	$R$	$\bar{x}$	$s$	$V$	$A$
$X_{13}$	0,5	4,8	4,3	2,2375	0,9722	43,45	0,9055
$X_{14}$	29,9	42,4	12,5	34,1313	3,1400	9,20	1,2009
$X_{15}$	5,7	17,5	11,8	11,4438	2,9875	26,11	0,3766
$X_{16}$	91,0	95,3	4,3	93,5625	1,2463	1,33	-0,8169
$X_{17}$	3,4	8,4	5,0	5,5563	1,3890	25,00	0,4335

Źródło: Obliczenia własne na podstawie [GUS, 2016].

Najniższą wartość obserwacji odnotowano dla zmiennej  $X_{13}$  (przedsiębiorstwa wykorzystujące narzędzia Wiki), a największą dla  $X_1$  (przedsiębiorstwa wykorzystujące komputery). Wyniki te opowiadają uzyskanym średnim poziomom zmiennych. Zmienną, której odpowiada najniższa przeciętna wartość była zmienna  $X_{13}$ . Natomiast zmienną o najwyższej średniej wartości była zmienna  $X_1$ . Najwyższe względne zróżnicowanie odnotowano dla zmiennej  $X_{13}$ , a najniższe dla zmiennej  $X_{16}$  (przedsiębiorstwa korzystające z e-administracji). Większość zmiennych (jedenaście) charakteryzuje się istotnym statystycznie zróżnicowaniem ( $V > 10\%$ ). Przeważają również zmienne (dwanaście) o asymetrii prawostronnej. Do dalszych badań przyjęto te zmienne, dla których współczynnik zmienności przekroczył progową wartość 10%. Zmienne diagnostyczne dobrze dyskryminują badane obiekty jeżeli zróżnicowanie tych zmiennych jest statystycznie istotne.

W efekcie zastosowania bezwzorcowych metod porządkowania uzyskano dwa rankingi województw. Pozycje województw i odpowiadające im wartości miar syntetycznych przedstawiono w tabeli 2.

**Tabela 2. Rankingi województw uzyskane w wyniku zastosowania bezwzorcowych metod porządkowania**

Miara $s_i$			Miara $h_i$		
Pozycja	Województwo	Wartość miary	Pozycja	Województwo	Wartość miary
1	Mazowieckie	1,000000	1	Mazowieckie	1,000000
2	Małopolskie	0,516122	2	Małopolskie	0,736878
3	Dolnośląskie	0,475393	3	Dolnośląskie	0,704893
4	Śląskie	0,444630	4	Śląskie	0,680084
5	Wielkopolskie	0,432156	5	Wielkopolskie	0,676749
6	Pomorskie	0,429213	6	Pomorskie	0,673048
7	Łódzkie	0,390048	7	Łódzkie	0,653784
8	Kujawsko-pomorskie	0,348109	8	Kujawsko-pomorskie	0,639713
9	Zachodniopomorskie	0,336112	9	Zachodniopomorskie	0,623149

Miara $s_i$			Miara $h_i$		
Pozycja	Województwo	Wartość miary	Pozycja	Województwo	Wartość miary
10	Podlaskie	0,272819	10	Podlaskie	0,594414
11	Opolskie	0,271971	11	Opolskie	0,592380
12	Lubelskie	0,268788	12	Lubelskie	0,586308
13	Podkarpackie	0,204321	13	Podkarpackie	0,560375
14	Warmińsko-mazurskie	0,177488	14	Warmińsko-mazurskie	0,542015
15	Lubuskie	0,172731	15	Świętokrzyskie	0,538139
16	Świętokrzyskie	0,150721	16	Lubuskie	0,529251

Źródło: Obliczenia własne na podstawie [GUS, 2016].

Graficzną prezentację uzyskanych wyników (która umożliwi analizę dystansu obiektów w kontekście analizowanego zakresu rozwoju) przedstawiono na wykresie 2.



**Wykres 2. Wartości miar syntetycznych wyznaczone metodami bezwzorcowymi**

Źródło: Obliczenia własne na podstawie [GUS, 2016].


Wyniki uzyskane z wykorzystaniem metody wzorcowej przedstawiono w tabeli 3 oraz na wykresie 3.

**Tabela 3. Ranking województw uzyskany w wyniku zastosowania wzorcowej metody porządkowania**

Miara $d_i$		
Pozycja	Województwo	Wartość miary
1	Mazowieckie	1,000000
2	Małopolskie	0,519969

Miara $d_i$		
Pozycja	Województwo	Wartość miary
3	Dolnośląskie	0,507315
4	Śląskie	0,474298
5	Pomorskie	0,458602
6	Wielkopolskie	0,453884
7	Łódzkie	0,407487
8	Zachodniopomorskie	0,365351
9	Kujawsko-pomorskie	0,365017
10	Opolskie	0,315159
11	Lubelskie	0,304986
12	Podlaskie	0,282408
13	Podkarpackie	0,240703
14	Warmińsko-mazurskie	0,221286
15	Świętokrzyskie	0,189696
16	Lubuskie	0,180966

Źródło: Obliczenia własne na podstawie [GUS, 2016].



**Wykres 3. Wartości miary syntetycznej wyznaczone metodą wzorcową**

Źródło: Obliczenia własne na podstawie [GUS, 2016].

W celu ustalenia stopnia podobieństwa otrzymanych rankingów województw zastosowano współczynnik korelacji rangowej Kendalla i współczynnik korelacji rangowej Spearmana. Wartości korelacji z wykorzystaniem obu współczynników przedstawiono poniżej.

Tabela 4. Wartości współczynników korelacji Kendalla oraz Spearmana

$\rho_n$				$\tau_n$			
	$S_i$	$h_i$	$d_i$		$S_i$	$h_i$	$d_i$
$S_i$	–	0,997059 p=0,0000	0,982353 p=0,0000		–	0,983333 p=0,0000	0,916667 p=0,0000
$h_i$	0,997059 p=0,0000	–	0,985294 p=0,0000		0,983333 p=0,0000	–	0,933333 p=0,0000
$d_i$	0,982353 p=0,0000	0,985294 p=0,0000	–		0,916667 p=0,0000	0,933333 p=0,0000	–

Źródło: Obliczenia własne na podstawie [GUS, 2016].

Wszystkie współczynniki są statystycznie istotne (przy  $p = 0,05$ ). Największe podobieństwo odnotowano w parze rankingów dokonanych z wykorzystaniem miar  $s_i$  oraz  $h_i$ . Zauważalne jest nieco mniejsze podobieństwo w parach z udziałem rankingu stworzonego na podstawie zmiennej  $d_i$ . Ze względu na wysokie wartości współczynników korelacji, otrzymane rankingi województw należy uznać za zgodne. We wszystkich trzech uporządkowaniach pierwsze cztery miejsca zajmują województwa: mazowieckie, małopolskie, dolnośląskie i śląskie. Na podobnym poziomie znajdują się województwa: wielkopolskie i pomorskie. W miarach bezwzorcowych województwo wielkopolskie uplasowało się na piątej pozycji (przed województwem pomorskim), a przy pomocy miary wzorcowej znalazło się na miejscu szóstym (tzn. po województwie pomorskim). Kolejne miejsca wg porządku opartego na miarach bezwzorcowych zajmują województwa: łódzkie, kujawsko-pomorskie, zachodniopomorskie, podlaskie, opolskie, lubelskie, podkarpackie, warmińsko-mazurskie. Różnica pojawiająca się w rankingu sformułowanym przy pomocy miary wzorcowej polega na tym, że na miejscu ósmym uplasowało się województwo zachodniopomorskie i bezpośrednio poprzedziło województwo kujawsko-pomorskie. Kolejna różnica polega na tym, że na miejscu dziesiątym pojawiło się województwo opolskie (przed następującym po nim województwem lubelskim i podlaskim). Rankingi zbudowane z wykorzystaniem miar  $s_i$  oraz  $h_i$  różnią się pozycjami województwa lubuskiego i świętokrzyskiego. W pierwszym rankingu województwo lubuskie wyprzedza świętokrzyskie, a w drugim powyższe województwa uszeregowane zostały odwrotnie. W rankingu zrealizowanym według miary  $d_i$  pozycje, które zajmują te województwa są takie jak w rankingu według  $d_i$ .

## Podsumowanie

Wszystkie sformułowane rankingi świadczą o dominującej pozycji województwa mazowieckiego pod względem stopnia wykorzystania ICT przez przedsiębiorstwa w 2015 r. Drugie i trzecie miejsca (we wszystkich stworzonych rankingach) zajmują odpowiednio województwo: małopolskie i dolnośląskie. Jednak dystans w rozwoju województwa mazowieckiego (w analizowanym zakresie) do następnego w kolejności województwa jest największy z spośród wszystkich różnic pomiędzy następującymi po sobie w rankingu województwami. Wiarygodność uzyskanych wyników potwierdzają statystycznie istotne i wysokie wartości współczynnika korelacji rangowej Kendalla i współczynnika korelacji rangowej Spearmana. Współczynniki te zostały wyznaczone dla wartości miar syntetycznych wykorzystanych w badaniu.

## Literatura

- Becker Aneta. 2011. „Ranking województw pod względem stopnia wykorzystania technologii ICT w przedsiębiorstwach z zastosowaniem metody UTA”. *Taksonomia 18. Klasyfikacja i analiza danych – teoria i zastosowanie. Prace naukowe Uniwersytetu Ekonomicznego we Wrocławiu* nr 176.
- Cambini Carlo, Jiang Yanyan. 2009. “Broadband investment and regulation: A literature review”. *Telecommunications Policy. The International Journal on Knowledge Infrastructure Development, Management and Regulation* vol. 33.
- Dziuba Dariusz. 2007. *Metody ekonomiki sektora informacyjnego*. Warszawa: Difin.
- Gonciarski Wiesław. 2009. Nowoczesne koncepcje i metody zarządzania stosowane w przedsiębiorstwach postindustrialnych. W *Zarządzanie w gospodarce postindustrialnej*, red. Kazimierz Piotrowski, Marek Świątkowski, 25-41. Warszawa: Almamery Wyższa Szkoła Ekonomiczna.
- GUS. 2016. *Spółeczeństwo informacyjne w Polsce. Wyniki badań statystycznych z lat 2012-2016*. Warszawa.
- Kaczmarczyk Paweł. 2015. „Ocena stopnia realizacji polityki telekomunikacyjnej w zakresie Strategii regulacyjnej do roku 2015”. *Studia z Polityki Publicznej* nr 2(6)/2015.
- Olszewska Anna, Gudanowska Alicja. 2014. „Wykorzystanie wybranych metod porządkowania obiektów do klasyfikacji województw pod kątem ich potencjału innowacyjnego”. *Metody Ilościowe w Badaniach Ekonomicznych* tom XV/4.



Panek Tomasz, Zwierzchowski Jan. 2013. *Statystyczne metody wielowymiarowej analizy porównawczej*. Teoria i zastosowania. Warszawa: Szkoła Główna Handlowa.

Paszta Ewa. 2010. Internet w działalności informacyjnej i komunikacyjnej przedsiębiorstw. W *Zarządzanie zasobami informacyjnymi w warunkach nowej gospodarki*, red. Ryszard Borowiecki, Janusz Czekaj, 362-369. Warszawa: Difin.

Picot Arnold, Wernick Christian. 2007. "The role of government in broadband access", *Telecommunications Policy. The International Journal on Knowledge Infrastructure Development, Management and Regulation* vol. 31.

Walesiak Marek. 2004. Metody porządkowania liniowego. W *Metody statystycznej analizy wielowymiarowej w badaniach marketingowych*, red. Marek Walesiak, Eugeniusz Gatnar, 351-368. Wrocław: Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu.

Wawrzynek Jerzy, Bukietyńska Agnieszka, Rusnak Zofia, Siedlecka Urszula, Heilpern Stanisław. 1998. Opisowa analiza danych. W *Statystyczne metody analizy danych*, red. Walenty Ostasiewicz, 30-129. Wrocław: Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu.

Zielińska-Głębocka Anna. 2012. *Współczesna gospodarka światowa. Przemiany, innowacje, kryzysy, rozwiązania regionalne*. Warszawa: Wolters Kluwer business.