

WIELOWYMIAROWA ANALIZA PORÓWNAWCZA W UJĘCIU DYNAMICZNYM NA PRZYKŁADZIE WYBRANYCH CHARAKTERYSTYK EKONOMICZNYCH

Adrianna Mastalerz-Kodzis, Ewa Pośpiech

Katedra Matematyki, Uniwersytet Ekonomiczny w Katowicach
e-mail: adrianna.mastalerz-kodzis@ue.katowice.pl, ewa.pospiech@ue.katowice.pl

Streszczenie: Celem artykułu jest wskazanie kierunku i siły zmian demograficznych oraz wybranych charakterystyk ekonomicznych zachodzących w Polsce, konstrukcja mierników syntetycznych oraz ich prognoz, a także sporządzenie rankingu województw i porównanie różnych metod prognozowania mierników syntetycznych. Artykuł składa się z dwóch części. Pierwsza z nich dotyczy metod badawczych, zaś druga część to analiza empiryczna wybranych charakterystyk demograficznych i ekonomicznych, konstrukcja mierników syntetycznych z uwzględnieniem dynamiki zmiennych oraz wnioski.

Słowa kluczowe: dynamika ekonomiczna, wielowymiarowa analiza porównawcza w ujęciu dynamicznym, dynamiczna bezwzorcowa miara syntetyczna, demografia

WPROWADZENIE

Proces starzenia się ludności w Polsce jest widoczny już nie tylko w analizach statystycznych, ale także w otaczającym nas świecie. Proces ten nie dotyczy tylko społeczeństwa polskiego, dotyka wiele gospodarek europejskich, jednak w niniejszym artykule rozważania ograniczymy do danych dotyczących Polski zaczerpniętych z Banku Danych Lokalnych Głównego Urzędu Statystycznego (BDL GUS).

Zachodzące na przełomie XX i XXI wieku zmiany w strukturze demograficznej społeczeństwa, między innymi bardzo niski przyrost naturalny oraz wzrost odsetka osób w podeszłym wieku implikują zarówno pozytywne jak i negatywne zjawiska gospodarcze. Cytując za Kurkiewicz i in. [1991] „Podstawową hipotezą jest stwierdzenie, że jakkolwiek procesy demograficzne

rzędzą się swoistymi prawami, to jednak istnieje wzajemny wpływ/ relacja/ zjawisk demograficznych i poziomu rozwoju społeczno-gospodarczego. Na pozór ten związek nie jest oczywisty, zwłaszcza jeśli wziąć pod uwagę wyniki badań empirycznych, które - co prawda rzadko - przeprowadzane były w ujęciu statycznym i dynamicznym.”

Rzeczywistość ekonomiczna zmienia się dynamicznie. Dynamiką także cechują się zmiany w strukturze wiekowej społeczeństwa polskiego. Analiza statyczna zatem nie odzwierciedla w pełni badanego zjawiska, istnieje potrzeba stosowania metod uwzględniających upływ czasu [Duncan 1998, Fidel i in. 2012, Holzer 2003].

W badaniach do analiz posłużyły wybrane zmienne demograficzne oraz zmienne ogólnoeconomiczne. Okresem badawczym były lata 2005-2014, analizowano zmienne czasowo-przestrzenne o częstotliwości rocznej w przekroju województw. Artykuł składa się z dwóch części. W pierwszej omówiono dynamiczne ujęcie WAP, część druga ma charakter empiryczny.

UWAGI O METODYCE BADAŃ

W analizach zastosowano wybrane metody dynamicznej wielowymiarowej analizy porównawczej (WAP) dla danych przekrojowo-czasowych [Kurkiewicz i in. 1991, Suchecki 2010, Rencher 2002, Ostasiewicz, 1999, Panek 2009, Giri i in. 2004), Tarczyński 2004]. Główną ideą WAP jest uporządkowanie zbioru obiektów w celu podjęcia decyzji dotyczących wyboru obiektu według z góry ustalonego kryterium. Celem WAP jest konstrukcja zagregowanego wskaźnika, tzw. zmiennej syntetycznej, który stanowi podstawę hierarchizacji badanych obiektów ze względu na poziom zjawiska opisywanego przez wiele cech.

Analiza dynamiki rozważanych zmiennych demograficznych oraz ekonomicznych pokazała, że szeregi czasowe tych zmiennych nie są stałe w czasie, a w wielu przypadkach zmieniają się w sposób liniowy. Zatem miary syntetyczne konstruowane na podstawie tych szeregów także powinny uwzględniać parametr czasu, a nie uśredniać wielkości zmiennych diagnostycznych. Zmiany w czasie mogą wpływać na pozycję w rankingu analizowanych obiektów, stąd istnieje potrzeba podejścia dynamicznego do konstrukcji wskaźników zagregowanych.

Mierniki syntetyczne konstruuje się, między innymi, w celu wyłonienia z badanej grupy obiektów tych, które wg badanych cech znajdują się na najwyższych lub najniższych pozycjach. Analiza dynamiczna mierników pozwala na wskazanie tych obiektów, które pod wpływem czasu zmieniają swoje pozycje, wskazuje kierunek zmian (pozytywny, negatywny).

W literaturze można znaleźć różne metody wyznaczania mierników syntetycznych, między innymi metodę opartą na wzorcu i metodę bezwzorcową. W zależności od zastosowanej metody uzyskuje różne wyniki. Zatem naturalnym wydaje się być porównanie tych metod. Ponadto, analiza danych historycznych wprowadza pewien porządek w zbiorze analizowanych obiektów. Pytanie, jak

wobec dynamicznej natury zmiennych diagnostycznych porządek ten będzie się zmieniał w przyszłości. Uwzględniając dynamiczny charakter zmiennych diagnostycznych nie uśrednia się ich wielkości historycznych. Można jednak zadać pytanie: czy należy modelować zmienne diagnostyczne i na podstawie ich prognoz konstruować prognozy miary syntetycznej, czy też prognozować zmienną syntetyczną na podstawie jej historycznych wartości? Czy otrzymane wyniki wprowadzają ten sam porządek w zbiorze obiektów? Czy istnieje zależność pomiędzy omawianymi metodami?

Dynamiczne ujęcie taksonomicznej miary wzorcowej

Konstruując syntetyczny miernik wzorcowy w WAP należy uwzględnić dynamikę zmiennych diagnostycznych. Zmienna syntetyczna $z_i(t)$ odpowiadająca i -temu obiektowi w roku t jest wartością funkcji wielu zmiennych postaci $f(X(t)) = z_i(t)$, gdzie $X(t)$ jest ciągiem macierzy danych historycznych (w którym destymulanty zamieniono na stymulanty) przedstawiającym wartości cech diagnostycznych

$$X(t) = [x_{ij}(t)]_{i=1, \dots, n; j=1, \dots, m}. \quad (1)$$

Dla $\bar{x}_j(t)$ średniej arytmetycznej i $s_j(t)$ odchylenia standardowego cechy j w momencie czasowym t normalizuje się zmienne zgodnie ze wzorem:

$$y_{ij}(t) = \frac{x_{ij}(t) - \bar{x}_j(t)}{s_j(t)} \quad (2)$$

Macierze zmiennych znormalizowanych oznacza się jako:

$$Y(t) = [y_{ij}]_{i=1, \dots, n; j=1, \dots, m}. \quad (3)$$

Z ciągu macierzy (3) dla każdej zmiennej wybiera się wartość największą - wzorzec y_{0j} . Wzorzec nie jest zależny od czasu, nie zmienia się punkt odniesienia w całym analizowanym przedziale czasowym. Odległość obiektu od wzorca wyznacza się zgodnie ze wzorem:

$$d_i(t) = \sqrt{\frac{\sum_{j=1}^m (y_{ij}(t) - y_{0j})^2}{m}} \quad (4)$$

Mniejsza odległość obiektu od wzorca implikuje mniejszą wartość $d_i(t)$.

Wielkość $d_i(t)$ normalizuje się za pomocą wzoru:

$$z_i(t) = 1 - \frac{d_i(t)}{d_0} \quad (5)$$

gdzie $z_i(t)$ oznacza taksonomiczny miernik rozwoju i -tego obiektu w roku t , $d_i(t)$ jest odległością i -tego obiektu od wzorca, d_0 jest normą. Zmienna $z_i(t)$ przyjmie wartości z przedziału $[0, 1]$. Im wartość zmiennej syntetycznej $z_i(t)$ bliższa 1, tym obiekt ma wyższą pozycję w rankingu.

W artykule, w podejściu 1, prognozowano wartości zmiennych diagnostycznych i na podstawie prognoz obliczano wartości zmiennej syntetycznej. W podejściu 2 prognozowano zmienną syntetyczną na podstawie jej wartości historycznych $z_i(t)$. Porównano otrzymane podejścia.

Bezwzorcowa miara syntetyczna w ujęciu dynamicznym

W niniejszej pracy miarę BMS obliczano w następujący sposób

$$\overline{\text{BMS}}_i(t) = \frac{1}{n} \sum_{j=1}^n y_{ij}(t) \quad (6)$$

gdzie wartości $y_{ij}(t)$ są elementami macierzy (3). Im wyższa pozycja obiektu w rankingu, tym wartość miary $\overline{\text{BMS}}_i(t)$ jest większa. W analizie dynamicznej zamiast średniej posłużono się także prognozami zmiennych diagnostycznych i na ich podstawie skonstruowano prognozy miernika syntetycznego (podejście 3) oraz prognozowano $\overline{\text{BMS}}_i(t)$ na lata 2015 i 2016 na podstawie historycznych wartości $\overline{\text{BMS}}_i(t)$ (podejście 4). Wyniki analiz zaprezentowano poniżej.

ZASTOSOWANIE METODYKI WAP W UJĘCIU DYNAMICZNYM DO ANALIZ EKONOMICZNYCH

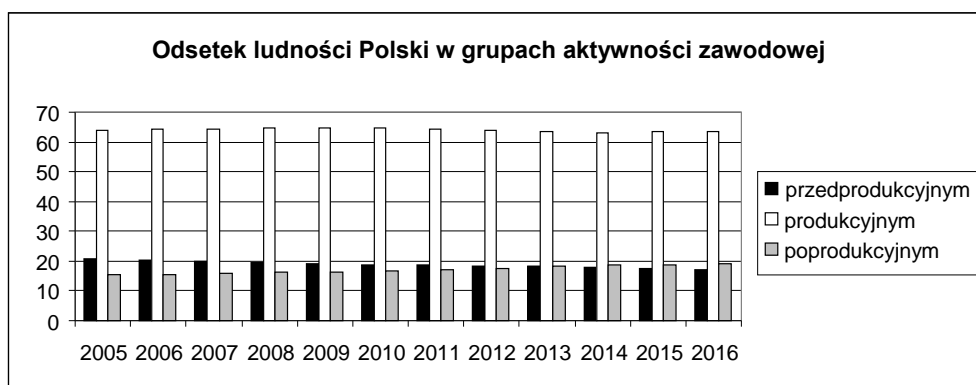
Analizę empiryczną prowadzono w oparciu o wielkości wybranych charakterystyk demograficznych i ekonomicznych w latach 2005-2014 w przekroju województw. Do analiz posłużyły zmienne zaczerpnięte z BDL GUS:

- urodzenia żywe na 1000 ludności,
- przyrost naturalny na 1000 ludności,
- wskaźnik obciążenia demograficznego,
- wskaźnik zagrożenia ubóstwem,
- odsetek ludności w wieku przedprodukcyjnym,
- odsetek ludności w wieku produkcyjnym, ,
- odsetek ludności w wieku poprodukcyjnym,
- przeciętna emerytura i renta poza rolnictwem,
- przeciętna emerytura i renta w rolnictwie,
- przeciętnie miesięczne wynagrodzenie brutto w gospodarce narodowej (GN),
- stopa bezrobocia,

- wskaźnik aktywności zawodowej kobiet i mężczyzn,
- zasoby mieszkaniowe (w m² powierzchni użytkowej na 1 mieszkańca),
- nakłady inwestycyjne na 1 mieszkańca.

Wśród ww zmiennych diagnostycznych znajdują się zmienne demograficzne zmienne oraz ekonomiczne świadczące o poziomie wynagrodzeń oraz o standardzie życia. Charakteryzując dynamikę rozwoju województw można uznać, że struktura demograficzna oraz poziom wynagrodzeń i standard życia mają znaczący wpływ na jakość życia, a także na rozwój województwa.

Rysunek 1. Struktura wieku ludności w Polsce w latach 2005-2014 wraz z prognozą GUS na lata 2015, 2016



Źródło: opracowanie własne

Na Rysunku 1 przedstawiono udział ludności w wieku przedprodukcyjnym, produkcyjnym i poprodukcyjnym w Polsce w latach 2005-2014 wraz z prognozami na lata 2015 i 2016. Udział ludności w wieku przedprodukcyjnym w latach 2005-2014 zmalał o prawie 3%, zaś udział osób w wieku poprodukcyjnym wzrósł o około 3,6%. Prognozując metodą trendu liniowego uzyskano odsetek ludności w wybranych grupach na lata 2015, 2016 (prognozy odsetka ludności w wieku przedprodukcyjnym, produkcyjnym i poprodukcyjnym na lata 2015 i 2016 skorygowano, aby sumowały się do 100). Dla grupy ludności w wieku przedprodukcyjnym prognozy wynoszą odpowiednio: 17,4% i 17,1%, zaś dla grupy poprodukcyjnej 18,9 i 19,3%. Stopień dopasowania linii trendu do danych za lata 2005-2014 w obydwu przypadkach jest na poziomie 0,96. Zatem na podstawie prognoz można stwierdzić, że w kolejnych latach będzie następować dalsze starzenie się społeczeństwa polskiego.

Analizując pozostałe zmienne można zauważyć także wyraźne liniowe trendy, w roku 2014 w porównaniu z rokiem 2005:

- wskaźnik obciążenia demograficznego wzrósł o ok. 1,7%,
- wskaźnik zagrożenia ubóstwem zmalał o ok. 6,8%,
- przeciętna emerytura i renta wzrosła o ok. 51%,

- przeciętne miesięczne wynagrodzenie brutto w GN wzrosło o ok. 62%,
- stopa bezrobocia zmalała o ok. 8,3%,
- wskaźnik aktywności zawodowej osób w wieku 55-64 wzrósł o ok. 12%,
- zasoby mieszkaniowe wzrosły o ok. 15%,
- nakłady inwestycyjne na 1 mieszkańca wzrosły o ok. 109%.

Analizując powyższe wielkości, można rozważać zmiany o charakterze pozytywnym: malejący wskaźnik zagrożenia ubóstwem, malejąca stopa bezrobocia, a także wzrost dochodów i aktywności zawodowej ludności, wzrost zasobów mieszkaniowych i nakładów inwestycyjnych oraz zmiany negatywne - wzrost obciążenia demograficznego społeczeństwa polskiego.

Sporządzono ranking województw stosując metodykę WAP dla danych historycznych, uśredniając wielkości, nie uwzględniając dynamiki zmian (Tabela 1, kolumna 2 - wartości miary taksonomicznej oraz pozycja w rankingu). Następnie, uwzględniając dane historyczne za lata 2005-2014 dla każdej zmiennej i dla każdego województwa wyznaczono prognozy zmiennych diagnostycznych na lata 2015, 2016 metodą trendu liniowego. Stopień dopasowania funkcji trendu był zależny od charakteru zmiennych i wahał się w przedziale 0,3-0,9.

Tabela 1. Historyczne i prognozowane wartości miary syntetycznej $z_i(t)$ oraz pozycja w rankingu województw zgodnie z podejściem 1 i 2

Województwo	Średnia $z_i(t)$ za lata 2005-2014	Prognoza $z_i(2015)$ podejście 1	Prognoza $z_i(2016)$ podejście 1	Prognoza $z_i(2015)$ podejście 2	Prognoza $z_i(2016)$ podejście 2
DOLNOŚLĄSKIE	0,260 (6)	0,313 (5)	0,297 (7)	0,212 (8)	0,203 (8)
KUJAWSKO-POMORSKIE	0,272 (5)	0,265 (8)	0,265 (8)	0,338 (4)	0,351 (4)
LUBELSKIE	0,216 (8)	0,195 (12)	0,195 (12)	0,199 (9)	0,196 (9)
LUBUSKIE	0,182 (12)	0,212 (11)	0,202 (11)	0,171 (10)	0,169 (10)
ŁÓDZKIE	0,184 (11)	0,300 (6)	0,311 (5)	0,126 (12)	0,115 (12)
MAŁOPOLSKIE	0,361 (2)	0,408 (3)	0,405 (3)	0,403 (2)	0,411 (2)
MAZOWIECKIE	0,306 (4)	0,492 (1)	0,481 (2)	0,123 (13)	0,089 (13)
OPOLSKIE	0,184 (11)	0,190 (14)	0,192 (13)	0,150 (11)	0,144 (11)
PODKARPACKIE	0,239 (7)	0,298 (7)	0,306 (6)	0,375 (3)	0,400 (3)
PODLASKIE	0,215 (9)	0,194 (13)	0,189 (14)	0,240 (6)	0,244 (6)
POMORSKIE	0,327 (3)	0,351 (4)	0,338 (4)	0,332 (5)	0,333 (5)
ŚLĄSKIE	0,056 (15)	0,232 (10)	0,241 (10)	0,044 (16)	0,042 (16)
ŚWIĘTOKRZYSKIE	0,214 (10)	0,234 (9)	0,245 (9)	0,222 (7)	0,224 (7)
WARMIŃSKO-MAZURSKIE	0,065 (14)	0,051 (16)	0,054 (16)	0,051 (15)	0,049 (15)
WIELKOPOLSKIE	0,428 (1)	0,454 (2)	0,447 (1)	0,425 (1)	0,425 (1)
ZACHODNIO-POMORSKIE	0,128 (13)	0,085 (15)	0,076 (15)	0,070 (14)	0,059 (14)

Źródło: obliczenia własne

Na podstawie tych prognoz wyznaczono wartości zmiennej syntetycznej $z_i(t)$ na lata 2015, 2016 - podejście 1 (Tabela 1, kolumna 3 i 4). W podejściu 2 (kolumna 5 i 6 w Tabeli 1) na podstawie ciągu historycznych wartości $z_i(t)$

w poszczególnych latach prognozowano za pomocą regresji liniowej wartości miary syntetycznej na lata 2015 oraz 2016.

Analizując wyniki zawarte w Tabeli 1 można stwierdzić, że dla danych historycznych pod względem badanych cech najlepsza sytuacja jest w województwach kolejno: wielkopolskim, małopolskim i pomorskim, zaś najbardziej niepokojąca w województwach śląskim, warmińsko-mazurskim i zachodnio-pomorskim. Najwyżej w rankingu są województwa o wysokim wskaźniku aktywności zawodowej, a tym samym niskiej stopie bezrobocia, najwyższych dochodach ludności. W tych województwach jest także największy odsetek ludności w wieku produkcyjnym.

W przypadku dwóch różnych podejść do wyznaczenia wartości miar syntetycznych w latach 2015, 2016 uzyskano różne wyniki. Wg prognoz na lata 2015, 2016 zgodnie z podejściem 1 na czołowych pozycjach są województwa: mazowieckie, wielkopolskie i małopolskie, zaś na końcu rankingu znajdują się: warmińsko-mazurskie, zachodnio-pomorskie, opolskie i podlaskie. Natomiast podejście drugie wyłoniło na najwyższe pozycje województwa: wielkopolskie, małopolskie i podkarpackie, zaś na ostatnich można zanotować województwa: śląskie, warmińsko-mazurskie i zachodnio-pomorskie. Rankingi dla podejścia 1 w latach 2015-2016 nieznacznie różnią się między sobą, natomiast dla podejścia drugiego są tożsame, pomimo różnych wartości miar syntetycznych.

W Tabeli 2 pokazano wyniki analiz dla bezwzorcowej miary $\overline{BMS}_i(t)$. W kolumnie drugiej zamieszczono klasyfikacje dla danych historycznych, w kolumnie 3 prognozy miernika na rok 2015 zgodnie z podejściem 3 i 4 (prognozowanymi zmiennymi diagnostycznymi oraz prognozowania zmiennej diagnostycznej na podstawie jej wartości historycznych), natomiast w kolumnie 4 wyniki analiz dla roku 2016 dla podejścia 3 i 4.

Zgodnie z wartościami miernika syntetycznego $\overline{BMS}_i(t)$ w latach 2015-2016 najlepiej pod względem demograficzno-ekonomicznym mieszkańcy będą w województwach mazowieckim, wielkopolskim, małopolskim i łódzkim. Najniższe wartości mierników mają województwa warmińsko-mazurskie i zachodniopomorskie. Można także zauważyć, że pozycje w rankingu kilku województw znacząco zmieniły się po uwzględnieniu prognoz na lata 2015, 2016. Można zauważyć niekorzystny trend zmian demograficzno-ekonomicznych dla województwa lubuskiego i pomorskiego. Pozytywny trend zmian zanotowano w województwach podkarpackim, podlaskim i łódzkim.

Tabela 2. Historyczne i prognozowane wartości miary syntetycznej $\overline{BMS}_i(t)$ oraz pozycja w rankingu województw zgodnie z podejściem 3 i 4

Województwo	Średnia \overline{BMS}_i 2005-2014	Prognoza $\overline{BMS}_i(2015)$ podejście 3, 4	Prognoza $\overline{BMS}_i(2016)$ podejście 3, 4
DOLNOŚLĄSKIE	0,101 (5)	0,589 (5)	0,678 (5)
KUJAWSKO-POMORSKIE	-0,132 (11)	0,255 (12)	0,326 (13)
LUBELSKIE	-0,135 (12)	0,286 (11)	0,362 (11)
LUBUSKIE	-0,069 (8)	0,247 (14)	0,304 (14)
ŁÓDZKIE	0,049 (6)	0,633 (4)	0,739 (4)
MAŁOPOLSKIE	0,176 (4)	0,682 (3)	0,775 (3)
MAZOWIECKIE	0,704 (1)	1,347 (1)	1,464 (1)
OPOLSKIE	-0,009 (7)	0,414 (8)	0,491 (8)
PODKARPACKIE	-0,178 (13)	0,384 (9)	0,486 (9)
PODLASKIE	-0,099 (9)	0,409 (7)	0,502 (7)
POMORSKIE	0,201 (3)	0,563 (6)	0,629 (6)
ŚLĄSKIE	-0,115 (10)	0,380 (10)	0,470 (10)
ŚWIĘTOKRZYSKIE	-0,221 (14)	0,248 (13)	0,333 (12)
WARMIŃSKO-MAZURSKIE	-0,483 (16)	-0,300 (16)	-0,266 (16)
WIELKOPOLSKIE	0,447 (2)	0,851 (2)	0,924 (2)
ZACHODNIO-POMORSKIE	-0,238 (15)	0,053 (15)	0,106 (15)

Źródło: obliczenia własne

Obliczono współczynnik korelacji rang Spearmana pomiędzy poszczególnymi rankingami. Wyniki przedstawiono poniżej:

- 0,69 (średnia $z_i(t)$ i średnia \overline{BMS}_i za lata 2005-2014).
Zatem istnieje umiarkowana zależność pomiędzy otrzymanymi rankingami dla wartości historycznych uzyskanych różnymi metodami.
- 0,82 (średnia $z_i(t)$ za lata 2005-2014 i $z_i(2015)$, podejście 1).
Znacząca zależność występuje pomiędzy rankingami mierników syntetycznych uzyskanych dla danych historycznych a rankingiem dla prognoz obliczonych zgodnie z podejściem 2.
- 0,985 (prognoza $z_i(2015)$ i prognoza $z_i(2016)$, podejście 1).
Uzyskany wynik świadczy o bardzo silnej zależności pomiędzy uzyskanymi rankingami. Można przypuszczać, że w kolejnych latach pozycje województw nie ulegną istotnym zmianom.
- 1 (prognoza $z_i(2015)$ i prognoza $z_i(2016)$, podejście 2).
Podejście 2 wprowadza ten sam porządek w zbiorze obiektów (pomimo różnych wartości zmiennych syntetycznych).
- 0,997 (prognoza $\overline{BMS}_i(2015)$ i prognoza $\overline{BMS}_i(2016)$, podejście 3 i 4).
Istnieje bardzo silna, dodatnia zależność między rankingami, analogicznie jak dla podejścia 2 pozycje województw w rankingach nie ulegają zmianie w czasie (bądź w bardzo małym stopniu się zmieniają).

W przypadku wyznaczenia współczynnika korelacji liniowej Pearsona pomiędzy wartościami mierników syntetycznych uzyskano następujące wielkości:

- 0,73 (średnia $z_i(t)$ i średnia \overline{BMS}_i za lata 2005-2014).

Zatem istnieje znacząca, istotna statystycznie (dla poziomu ufności 0,05) zależność pomiędzy otrzymanymi wielkościami miar syntetycznych dla wartości historycznych uzyskanych różnymi metodami.

- 0,58 (prognoza $z_i(2015)$ i prognoza $z_i(2015)$, podejście 1 i 2).
- 0,54 (prognoza $z_i(2016)$ i prognoza $z_i(2016)$, podejście 1 i 2).

Istnieje umiarkowana zależność pomiędzy sposobem porządkowania obiektów województw. Na poziomie ufności 0,05 zależności powyższe są statystycznie istotne.

- 0,999 (prognoza $\overline{BMS}_i(2015)$, prognoza $\overline{BMS}_i(2016)$),
- 0,96 (średnia \overline{BMS}_i 2005-2014, prognoza $\overline{BMS}_i(2015)$),
- 0,95 (średnia \overline{BMS}_i 2005-2014, prognoza $\overline{BMS}_i(2016)$),

Wszystkie powyższe zależności są bardzo silne, istotne statystycznie (0,05). Kolejność województw w znacznym stopniu nie ulega zmianie. Jest to wynik zastosowania funkcji regresji do modelowania zmiennych diagnostycznych i miernika syntetycznego.

Zatem można stwierdzić, że wartości zmiennej syntetycznej różnią się w zależności od zastosowanej metodologii. Można jednak zauważyć, że wiodące województwa wg Tabeli 1 są także na najwyższych pozycjach w rankingu w Tabeli 2 zarówno dla danych historycznych, jak i w roku 2015 oraz 2016. Uwzględnienie dynamiki, czy to zmiennych diagnostycznych, czy też wartości miernika syntetycznego daje porównywalne, ale nie tożsame rezultaty.

PODSUMOWANIE

Wartości zmiennej syntetycznej różnią się w zależności od zastosowanej metodologii w przypadku podejścia 1 i 2, sposób obliczania miernika syntetycznego nie wpływa na jego wartość dla podejścia 3 i 4. Uwzględnienie dynamiki, zarówno zmiennych diagnostycznych, jak i wartości miernika syntetycznego daje zbliżone, ale nie takie same wyniki w przypadku miary wzorcowej i bezwzorcowej. Pozycja obiektu w rankingu nieznacznie zmienia się w zależności od zastosowanej metody prognozowania przyszłej wartości miary syntetycznej.

Rzeczywistość, nie tylko ekonomiczna, otaczającego świata zmienia się w sposób dynamiczny. Do opisu tych zmian można używać metod wielowymiarowych uwzględniając jednak dynamikę zmiennych. Analiza wybranych wielkości demograficznych z uwzględnieniem zmiennych ogólnoeconomicznych pozwala na skonstruowanie mierników syntetycznych umożliwiających budowę rankingów

regionów/województw ze względu na badane wielkości i wskazanie tych regionów, w których sytuacja jest najlepsza oraz pokazanie tych, dla których mierniki syntetyczne przyjmują najmniejsze wartości.

BIBLIOGRAFIA

- Duncan C. J. and Scott S. (1998) *Human Demography and Disease*, UK Cambridge, University Press, pp. 103-110.
- Fihel A., Okólski M. (2012) *Demografia. Współczesne zjawiska i teorie*, Wydawnictwo Naukowe Scholar, Warszawa.
- Giri Narayan C. (2004) *Multivariate Statistical Analysis*, USA Marcel Dekker, pp. 435-526.
- Holzer J. Z. (2003) *Demografia*, PWE, Warszawa.
- Ostasiewicz W. (red.) (1999) *Statystyczne metody analizy danych*. Wydawnictwo Akademii Ekonomicznej we Wrocławiu, Wrocław.
- Panek T. (2009) *Statystyczne metody wielowymiarowej analizy porównawczej*. SGH, Warszawa.
- Rencher A. C. (2002) *Methods of Multivariate Analysis*, USA, John Wiley & Sons.
- Kurkiewicz J., Pocięcha J., Zając K. (1991) *Metody wielowymiarowej analizy porównawczej w badaniach rozwoju demograficznego*, SGH, Monografie i Opracowania nr 336, Warszawa.
- Suchecki B. (red) (2010) *Ekonometria przestrzenna. Metody i modele analizy danych przestrzennych*, Warszawa.
- Tarczyński W. (2004) *Dynamiczne ujęcie taksonomicznej miary atrakcyjności inwestowania na przykładzie wybranych spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie*, [w:] *Metody Ilościowe w Ekonomii, cz I, Zeszyty Naukowe Uniwersytetu Szczecińskiego nr 394, Prace Katedry Ekonometrii i Statystyki nr 15*, Wydawnictwo Uniwersytetu Szczecińskiego, Szczecin.
- www.bdl.gus.pl (dostęp dnia 1.06.2015)

DYNAMIC MULTIVARIATE COMPARATIVE ANALYSIS FOR CHOSEN DEMOGRAPHIC CHARACTERISTICS

Summary: The aim of the paper is to analyze the dynamic demographic and economic changes that are observed in Poland from 2005 to 2014. General tendencies in Polish population age structure were shown. Besides, some dependences between demographic variables and chosen economic indicators were presented. By means of selected dynamic multivariate comparative analysis tools the regions of Poland were characterized and compared.

Keywords: dynamic economics, dynamic approach of multivariate comparative analysis, dynamic non-proof synthetic measure, demography