

# Rozwój gospodarczy województw Polski w latach 2010–2021 w świetle analizy danych funkcjonalnych

Marcin Szymkowiak<sup>1,2</sup>, Mirosław Krzyśko<sup>3</sup>,  
Waldemar Wołyński<sup>4</sup>

<sup>1</sup>Uniwersytet Ekonomiczny w Poznaniu

<sup>2</sup>Urząd Statystyczny w Poznaniu

<sup>3</sup> Akademia Kaliska im. Prezydenta Stanisława Wojciechowskiego

<sup>4</sup>Uniwersytet im. Adama Mickiewicza w Poznaniu

03.07.2023

- 1 Cel prezentacji
- 2 Rozwój gospodarczy
- 3 Dane funkcjonalne
- 4 Funkcjonalna analiza składowych głównych
- 5 Wybrane wyniki
- 6 Podsumowanie
- 7 Literatura

# Cel prezentacji

- Głównym celem prezentacji jest ocena województw w Polsce z punktu widzenia ich rozwoju gospodarczego z wykorzystaniem aparatu jaki oferuje **analiza danych funkcjonalnych**.
- Na potrzeby realizacji tak postawionego celu autorzy wykorzystali **funkcjonalną analizę składowych głównych** i **analizę skupień**.

# Rozwój gospodarczy

- **Rozwój gospodarczy** – długofalowy proces przemian dokonujących się w gospodarce.
- **Rozwój gospodarczy** wyraża się w ilościowym i jakościowym wzroście dóbr i usług konsumpcyjnych oraz produkcyjnych.
- Dotychczas nie wypracowano jednoznacznego i powszechnie stosowanego miernika **rozwoju gospodarczego**.
- **Rozwój gospodarczy** bywa najczęściej wąsko analizowany poprzez wzrost wolumenu produkcji mierzonego za pomocą PKB lub dochodu narodowego per capita i jego struktury.

# Rozwój gospodarczy

Wśród czynników rozwoju regionalnego można wyodrębnić trzy grupy:

- **infrastrukturę techniczną** – obejmującą dostęp do urządzeń i sieci: wodno-kanalizacyjnej, energetycznej, gazowej, centralnego ogrzewania, telekomunikacyjnej, komputerowej, transportowej;
- **kapitał ludzki** – tworzony przez zasoby wykwalifikowanej i wykształconej siły roboczej, rozumiany także jako dostęp do oferty edukacyjnej;
- **czynniki miękkie** - w tym kapitał społeczny i innowacyjność – stworzenie warunków do budowania gospodarki opartej na wiedzy, dostęp do nowych technologii, itp.

# Dane funkcjonalne

- W ostatnich latach można zaobserwować w obszarze statystyki coraz większe znaczenie reprezentacji danych za pomocą funkcji powierzchni lub krzywych.
- Szczególną rolę odgrywa **funkcjonalna analiza danych**, która zajmuje się analizą informacji zawartych w obiektach ciągłych, takich jak funkcje, powierzchnie, krzywe, etc.

# Dane funkcjonalne

- Obiekty będące przedmiotem analizy określa się jako **dane funkcjonalne**.
- **Dane funkcjonalne** charakteryzują się pewną ciągłością, np. względem czasu. Ponieważ w praktyce dane o charakterze ciągłym występują stosunkowo rzadko zachodzi potrzeba zamiany danych obserwowanych w dyskretnych momentach czasu do danych funkcjonalnych o charakterze ciągłym.
- **Analiza danych funkcjonalnych** ma obecnie bardzo szerokie zastosowanie m.in. w chemometrii, klimatologii, biologii, medycynie oraz ekonomii.

# Funkcjonalna analiza składowych głównych

- Z kolei za pomocą **funkcjonalnej analizy składowych głównych** (FPCA, ang. **Functional Principal Components Analysis**) możemy dokonać rzutu wysokowymiarowych danych na przestrzeń o dużo mniejszym wymiarze, jednocześnie zachowując maksymalnie dużo informacji.
- Główna idea metody polega na znalezieniu takich funkcji, których iloczyn skalarny z danymi pozwala otrzymać maksymalną zmienność.



# Funkcjonalna analiza składowych głównych

- Pierwsza składowa wyjaśnia najwięcej zmienności, druga jest prostopadła do pierwszej i wyjaśnia maksymalnie dużo z tego, co zostało itd.
- Wkład każdej kolejnej składowej w ogólną zmienność początkowych zmiennych jest nie tylko znany, ale i coraz mniejszy, od pewnego momentu składowe będą wyjaśniać znikomy zakres zmienności.
- Większość zmienności zachowana jest zazwyczaj przez kilka pierwszych funkcjonalnych składowych głównych.

## Funkcjonalna analiza składowych głównych

Założmy, że obserwujemy  $p$ -wymiarowy losowy proces z ciągłym parametrem czasu  $t$ :  $\mathbf{X}(t) = (X_1(t), X_2(t), \dots, X_p(t))^T$  takim, że  $E(\mathbf{X}(t)) = \mathbf{0}$ , oraz  $\mathbf{X}(t) \in L_2^p(I)$ , gdzie  $L_2^p(I)$  jest przestrzenią Hilberta funkcji całkowalnych z kwadratem na przedziale  $I$  z iloczynem skalarnym postaci:

$$\langle \mathbf{u}(t), \mathbf{v}(t) \rangle = \int_I \mathbf{u}^T(t) \mathbf{v}(t) dt. \quad (1)$$

## Funkcjonalna analiza składowych głównych

Zakładamy ponadto, że  $k$ -ta składowa tego procesu  $\mathbf{X}(t)$  jest reprezentowana przez skończoną liczbę ortonormalnych funkcji bazowych  $\phi_b$ :

$$X_k(t) = \sum_{b=0}^{B_k} c_{kb} \phi_b(t), \quad t \in I, \quad (2)$$

gdzie  $\mathbf{c}_k = (c_{k0}, c_{k1}, \dots, c_{kB_k})^\top$ , są zmiennymi losowymi takimi, że  $E(c_{kb}) = 0$ ,  $\text{Var}(c_{kb}) < \infty$ ,  $k = 1, 2, \dots, p$ ,  $b = 0, 1, \dots, B_k$ .

## Funkcjonalna analiza składowych głównych

Niech  $\mathbf{c} = (\mathbf{c}_1^\top, \mathbf{c}_2^\top, \dots, \mathbf{c}_p^\top)^\top$  oraz ortonormalna macierz  $\Phi(t)$

$$\Phi(t) = \begin{bmatrix} \phi_1^\top(t) & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \phi_2^\top(t) & \dots & \mathbf{0} \\ \dots & \dots & \dots & \dots \\ \mathbf{0} & \mathbf{0} & \dots & \phi_p^\top(t) \end{bmatrix}, \quad (3)$$

gdzie  $\phi_k(t) = (\phi_0(t), \phi_1(t), \dots, \phi_{B_k}(t))^\top$ ,  $k = 1, 2, \dots, p$ .

W notacji macierzowej, proces  $\mathbf{X}(t)$  można przedstawić w następujący sposób:

$$\mathbf{X}(t) = \Phi(t)\mathbf{c}, \quad t \in I, \quad E(\mathbf{c}) = \mathbf{0}, \quad \text{Var}(\mathbf{c}) = \Sigma_{\mathbf{c}}, \quad (4)$$

$$\mathbf{c} \in \mathbb{R}^{K+p}, \quad \Phi(t) \in \mathbb{R}^{p \times (K+p)}, \quad K = B_1 + B_2 + \dots + B_p.$$

# Funkcjonalna analiza składowych głównych

Definiujemy funkcjonalną składową główną jako:

$$U = \langle \mathbf{u}(t), \mathbf{X}(t) \rangle = \int_I \mathbf{u}^\top(t) \mathbf{X}(t) dt \quad (5)$$

mającą maksymalną wariancję dla wszystkich wektorów funkcji wagowych  $\mathbf{u}(t) \in L_2^p(I)$  takich, że  $\langle \mathbf{u}(t), \mathbf{u}(t) \rangle = 1$

Dalej zakładamy, że wektor funkcji wagowych  $\mathbf{u}(t)$  oraz proces losowy  $\mathbf{X}(t)$  należą do tej samej przestrzeni, tj. funkcja  $\mathbf{u}(t)$  jest wyrażana jako:

$$\mathbf{u}(t) = \Phi(t)\mathbf{u}, \quad (6)$$

gdzie  $\mathbf{u} \in \mathbb{R}^{K+p}$ ,  $K = B_1 + \dots + B_p$ .

## Funkcjonalna analiza składowych głównych

Wówczas

$$\langle \mathbf{u}(t), \mathbf{X}(t) \rangle = \langle \Phi(t)\mathbf{u}, \Phi(t)\mathbf{c} \rangle = \mathbf{u}^\top \mathbf{c} \quad (7)$$

$$E(\langle \mathbf{u}(t), \mathbf{X}(t) \rangle) = \mathbf{u}^\top E(\mathbf{c}) = \mathbf{u}^\top E(\mathbf{0}) = 0, \quad (8)$$

$$\text{Var}(\langle \mathbf{u}(t), \mathbf{X}(t) \rangle) = \mathbf{u}^\top \Sigma_c \mathbf{u}, \text{ gdzie } \Sigma_c = E(\mathbf{c}\mathbf{c}^\top). \quad (9)$$

Niech

$$\lambda_1 = \sup_{\mathbf{u}(t) \in L_2^p(I)} \text{Var}(\langle \mathbf{u}(t), \mathbf{X}(t) \rangle) = \text{Var}(\langle \mathbf{u}_1(t), \mathbf{X}(t) \rangle) = \mathbf{u}_1^\top \Sigma_c \mathbf{u}_1, \quad (10)$$

gdzie

$$\langle \mathbf{u}_1(t), \mathbf{u}_1(t) \rangle = \mathbf{u}_1^\top \mathbf{u}_1 = 1. \quad (11)$$

$\mathbf{U}_1$  jest pierwszą funkcjonalną składową główną, a wektor  $\mathbf{u}_1(t)$  pierwszym wektorem funkcji wagowych.

# Funkcjonalna analiza składowych głównych

Następnie poszukujemy drugiej funkcjonalnej składowej głównej

$$U_2 = \langle \mathbf{u}_2(t), \mathbf{X}(t) \rangle = \mathbf{u}_2^\top \mathbf{c} \quad (12)$$

maksymalizując wariancję:

$$\text{Var}(\langle \mathbf{u}(t), \mathbf{X}(t) \rangle) = \mathbf{u}^\top \Sigma_c \mathbf{u}, \quad (13)$$

w taki sposób, że

$$\langle \mathbf{u}_2(t), \mathbf{u}_2(t) \rangle = \mathbf{u}_2^\top \mathbf{u}_2 = 1 \quad (14)$$

i jest ona nieskorelowana z pierwszą funkcjonalną składową główną  $U_1$ , tj. spełniony jest warunek:

$$\langle \mathbf{u}_1(t), \mathbf{u}_2(t) \rangle = \mathbf{u}_1^\top \mathbf{u}_2 = 0. \quad (15)$$

## Funkcjonalna analiza składowych głównych

W ogólności  $k$ -ta funkcjonalna składowa główna

$$U_k = \langle \mathbf{u}_k(t), \mathbf{X}(t) \rangle = \mathbf{u}_k^\top \mathbf{c} \quad (16)$$

spełnia następujące warunki:

$$\lambda_k = \sup_{\mathbf{u}(t) \in L_2^p(I)} \text{Var}(\langle \mathbf{u}(t), \mathbf{X}(t) \rangle) = \mathbf{u}_k^\top \boldsymbol{\Sigma}_c \mathbf{u}_k, \quad (17)$$

$$\langle \mathbf{u}_{k_1}(t), \mathbf{u}_{k_2}(t) \rangle = \delta_{k_1, k_2}, \quad k_1, k_2 = 1, 2, \dots, k. \quad (18)$$

Parę  $(\lambda_k, \mathbf{u}_k(t))$  nazywamy  $k$ -tym układem składowych głównych procesu stochastycznego  $\mathbf{X}(t)$ .



## Funkcjonalna analiza składowych głównych

Rozważmy teraz klasyczny problem składowych głównych dla losowego wektora  $\mathbf{c}$ .  $k$ -ta składowa główna takiego wektora spełnia warunek:

$$\gamma_k = \sup_{\mathbf{u} \in \mathbb{R}^{K+p}} \text{Var}(\langle \mathbf{u}, \mathbf{c} \rangle) = \mathbf{u}_k^\top \boldsymbol{\Sigma}_c \mathbf{u}_k, \quad (19)$$

$$\langle \mathbf{u}_{k1}, \mathbf{u}_{k2} \rangle = \delta_{k_1, k_2}, \quad (20)$$

gdzie  $k_1, k_2 = 1, 2, \dots, k$ ,  $K = B_1 + B_2 + \dots + B_p$ .

Parę  $(\gamma_k, \mathbf{u}_k)$  nazywamy  $k$ -tą składową główną dla wektora  $\mathbf{c}$ .

# Funkcjonalna analiza składowych głównych

Znalezienie  $k$ -tej składowej głównej dla wektora  $\mathbf{c}$  jest równoważne ze znalezieniem wartości własnych i odpowiadającym im wektorów własnych macierzy kowariancji  $\Sigma_{\mathbf{c}}$   $\mathbf{u}_{k1}^T \mathbf{u}_{k2} = \delta_{k1,k2}$ .

W związku z powyższym otrzymujemy, że  $k$ -ta składowa główna procesu losowego  $\mathbf{X}(t)$  jest powiązana z  $k$ -tą składową główną wektora losowego  $\mathbf{c}$  w następujący sposób:

$$\lambda_k = \gamma_k, \mathbf{u}_k(t) = \Phi(t)\mathbf{u}_k, t \in I, \quad (21)$$

gdzie  $k = 1, 2, \dots, K + p$ ,  $K = B_1 + B_2 + \dots + B_p$ .

Analiza składowych głównych dla losowego wektora  $\mathbf{c}$  bazuje na macierzy kowariancji  $\Sigma_{\mathbf{c}}$ , która w praktyce zazwyczaj jest nieznana.

# Funkcjonalna analiza składowych głównych

Estymujemy elementy macierzy kowariancji  $\Sigma_c$  na bazie  $n$  niezależnych realizacji wektora  $\mathbf{x}_1(t), \mathbf{x}_2(t), \dots, \mathbf{x}_n(t)$  procesu losowego  $\mathbf{X}(t)$ .

W większości przypadków dane wyrażane są jako dyskretne momenty w czasie.

Niech  $x_{ikj}$  oznacza wartość  $i$ -tej realizacji  $k$ -tej zmiennej w czasie  $t_j$  procesu  $\mathbf{X}(t)$ ,  $i = 1, 2, \dots, n$ ,  $k = 1, 2, \dots, p$ ,  $j = 1, 2, \dots, J$ ,  $t_j \in I$ .

## Funkcjonalna analiza składowych głównych

Niech

$$\mathbf{x}_{ik} = (x_{ik1}, x_{ik2}, \dots, x_{ikJ})^T, \quad \mathbf{c}_{ik} = (c_{ik0}, x_{ik1}, \dots, x_{ikB_k})^T \quad (22)$$

oraz

$$\boldsymbol{\Psi}_k(t) = (\phi_b(t_j)) \quad (23)$$

będzie macierzą o wymiarach  $J \times (B_k + 1)$  z elementami  $\phi_b(t_j)$ ,  $b = 0, 1, \dots, B_k$ ,  $k = 1, 2, \dots, p$ ,  $j = 1, 2, \dots, J$ ,  $i = 1, 2, \dots, n$ .

## Funkcjonalna analiza składowych głównych

Wówczas estymator uzyskany metodą najmniejszych kwadratów wektora  $\mathbf{c}_{ik}$  ma postać:

$$\hat{\mathbf{c}}_{ik} = (\boldsymbol{\Psi}_k^\top(t)\boldsymbol{\Psi}_k(t))^{-1}\boldsymbol{\Psi}_k^\top(t)\mathbf{x}_{ik}, \quad (24)$$

$i = 1, 2, \dots, n, k = 1, 2, \dots, p.$

Niech  $\hat{\mathbf{c}}_i = (\mathbf{c}_{i1}^\top, \mathbf{c}_{i2}^\top, \dots, \mathbf{c}_{ip}^\top)^\top$ ,  $i = 1, 2, \dots, n$ , będzie wektorem scentrowanym oraz niech

$$\hat{\mathbf{C}} = (\hat{\mathbf{c}}_1, \hat{\mathbf{c}}_2, \dots, \hat{\mathbf{c}}_n). \quad (25)$$

Wówczas

$$\hat{\boldsymbol{\Sigma}}_c = \frac{1}{n}\hat{\mathbf{C}}\hat{\mathbf{C}}^\top. \quad (26)$$

# Funkcjonalna analiza składowych głównych

Niech  $\hat{\gamma}_1 \geq \hat{\gamma}_2 \geq \dots \geq \hat{\gamma}_s$  będą niezerowymi wartościami własnymi macierzy wariancji  $\hat{\Sigma}_c$  oraz niech  $\hat{\mathbf{u}}_1, \hat{\mathbf{u}}_2, \dots, \hat{\mathbf{u}}_s$  będzie odpowiadającym im wektorami własnymi, gdzie  $s = \text{rank}(\hat{\Sigma}_c)$ .

Współrzędne  $i$ -tej realizacji  $\mathbf{x}_i(t)$  procesu  $\mathbf{X}(t)$  na  $k$ -tej funkcjonalnej składowej głównej są postaci

$$\hat{U}_{ik} = \langle \hat{\mathbf{u}}_k(t), \mathbf{x}_i(t) \rangle = \langle \Phi(t)\hat{\mathbf{u}}_k, \Phi(t)\hat{\mathbf{c}}_i \rangle = \hat{\mathbf{u}}_k^\top \hat{\mathbf{c}}_i, \quad (27)$$

dla  $i = 1, 2, \dots, n$ ,  $k = 1, 2, \dots, s$ .

# Funkcjonalna analiza składowych głównych

W przypadku klasycznej analizy składowych głównych wkład poszczególnych cech w konstrukcję danej składowej głównej jest wyznaczany na bazie modułów współczynników każdej cechy.

W przypadku funkcjonalnej analizy składowych głównych odpowiednikami współczynników cech są funkcje wagowe powiązane z danym procesem.

# Funkcjonalna analiza składowych głównych

Funkcjonalna składowa główna  $U_j$  jest określona przez wektor wag funkcyjnych  $\mathbf{u}_j(t) = (u_{j1}(t), u_{j2}(t), \dots, u_{jp}(t))^T$ ,  $j = 1, 2, \dots, s$ .

Składowa  $X_k(t)$  wektora  $\mathbf{X}(t) = (X_1(t), X_2(t), \dots, X_p(t))^T$  procesu losowego ma największy wkład w konstrukcję funkcjonalnej składowej głównej  $U_j$  w momencie  $t$  jeśli:

$$|u_{jk}(t)| = \max_{1 \leq i \leq p} |u_{ji}(t)|, \quad j = 1, 2, \dots, s, \quad k = 1, 2, \dots, p. \quad (28)$$



## Funkcjonalna analiza składowych głównych

Niech  $A_{jk}$  oznacza pole powierzchni pod modułem składowej  $u_{jk}(t)$  wektora funkcji wagowych, dla  $t \in I$ , i niech

$$A_{ik}^* = \frac{A_{jk}}{\sum_{k=1}^p A_{jk}}, \quad j = 1, 2, \dots, s, \quad k = 1, 2, \dots, p. \quad (29)$$

Składowa  $X_k(t)$  wektora  $\mathbf{X}(t) = (X_1(t), X_2(t), \dots, X_p(t))^T$  procesu losowego ma największy wkład w konstrukcję funkcjonalnej składowej głównej  $U_j$ , dla wszystkich  $t \in I$ , jeśli

$$A_{jk}^* = \max_{1 \leq i \leq p} |A_{jk}^*|, \quad j = 1, 2, \dots, s, \quad k = 1, 2, \dots, p. \quad (30)$$

# Założenia

- Wykorzystano dane opisujące województwa w Polsce z punktu widzenia determinant rozwoju gospodarczego za lata 2010–2021 (BDL):  $p = 12$  zmiennych diagnostycznych.
- Dane poddano unitaryzacji zerowanej.
- Funkcje bazowe  $\varphi$  zostały określone na przedziale  $I = [0, T] = [0, 12]$ .
- Poszczególnym latom (punktom czasu) przypisano następujące wartości:  $t_1 = 0.5(2010)$ ,  $t_2 = 1.5(2011)$ ,  $\dots$ ,  $t_{12} = 11.5(2021)$ .
- Przyjęto, że  $B_1 = \dots = B_{12} = 4$ ,  $K = B_1 + B_2 + \dots, B_{12} = 48$   
 $K + p = 48 + 12 = 60$ . Zatem  $\mathbf{c} \in \mathbb{R}^{60}$  oraz  $\Phi \in \mathbb{R}^{12 \times 60}$ .

# Założenia

- W charakterze bazy ortonormalnej wykorzystano bazę Fouriera:


$$\phi_0(t) = \frac{1}{\sqrt{T}}, \phi_{2k-1}(t) = \sqrt{\frac{2}{T}} \sin \frac{2\pi kt}{T}, \phi_{2k}(t) = \sqrt{\frac{2}{T}} \cos \frac{2\pi kt}{T},$$

gdzie  $k = 1, 2, \dots, t \in [0, T]$

- Dokonano zamiany danych obserwowanych w dyskretnych momentach czasu do danych funkcjonalnych o charakterze ciągłym.
- Bazując na macierzy wariancji  $\hat{\Sigma}_c$ ,  $s = 15$  funkcjonalnych składowych głównych zostało skonstruowanych, gdzie  $s = \text{rank}(\hat{\Sigma}_c)$ .

## Zmienne

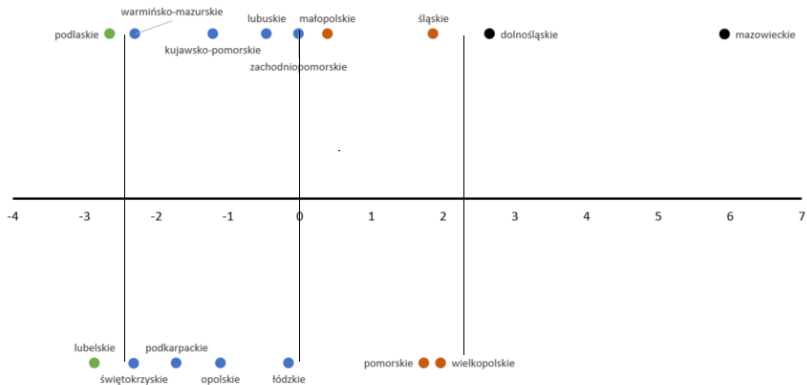
Cecha	Opis
1	produkt krajowy brutto na 1 mieszkańca
2	przeciętne miesięczne wynagrodzenia brutto
3	liczba podmiotów gospodarczych na 1000 osób w wieku produkcyjnym
4	liczba nowo utworzonych miejsc pracy na 1000 osób w wieku produkcyjnym
5	nakłady inwestycyjne w przedsiębiorstwach na 1 mieszkańca
6	produkcja sprzedana przemysłu ogółem na 1 mieszkańca
7	dochody własne budżetów samorządów lokalnych per capita w zł
8	udział mieszkańców korzystających z wodociągu (w %)
9	udział mieszkańców korzystających z kanalizacji (w %)
10	udział mieszkańców korzystających z gazu (w %)
11	drogi o twardej nawierzchni w km na 100 km <sup>2</sup>
12	nowe budynki mieszkalne na 1000 osób

Wartości własne macierzy wariancji  $\hat{\Sigma}_c$ 


# Miary jakości

<b>FPCA</b>	<b>% zmienności</b>	<b>Skumulowany % zmienności</b>
1	50.91	50.91
2	20.29	71.20
3	9.06	80.26

## Rzut województw na 1 funkcjonalną składową główną



# Skupienia województw podobnych – 1 FPCA

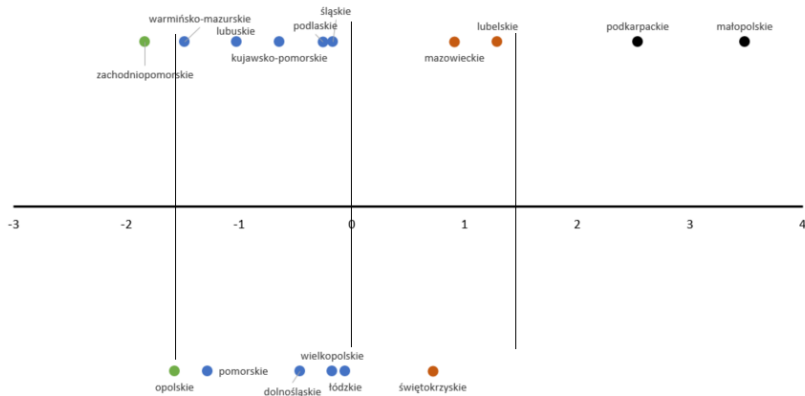





## Wkład poszczególnych zmiennych w FPCA

Zmienna	1 FPCA		2 FPCA		3 FPCA	
	Area	Cum(%)	Area	Cum (%)	Area	Cum (%)
	$A_{jk}$	$A_{jk}^*$	$A_{jk}$	$A_{jk}^*$	$A_{jk}$	$A_{jk}^*$
1.	1.25	11.28	0.09	1.00	0.65	7.88
2.	1.15	10.39	0.22	2.53	0.66	8.02
3.	1.28	11.56	0.46	5.30	0.16	1.98
4.	1.04	9.42	0.38	4.33	0.32	3.92
5.	1.09	9.80	0.14	1.58	0.28	3.35
6.	1.47	13.28	0.28	3.26	0.12	1.43
7.	1.21	10.88	0.13	1.54	0.46	5.61
8.	0.33	2.99	2.41	27.71	0.38	4.62
9.	0.60	5.41	1.36	15.65	1.96	23.73
10.	0.59	5.33	0.74	8.55	2.51	30.40
11.	0.42	3.80	1.29	14.80	0.25	3.00
12.	0.65	5.88	1.20	13.77	0.50	6.06

## Rzut województw na 2 funkcjonalną składową główną



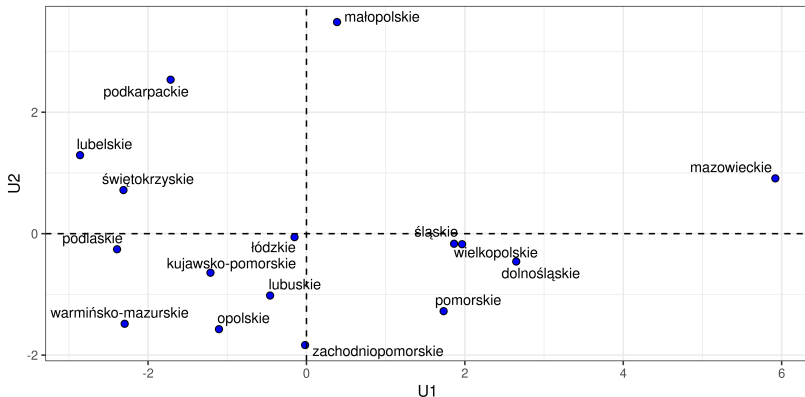
## Skupienia województw podobnych – 2 FPCA




# Wkład poszczególnych zmiennych w FPCA

Zmienna	1 FPCA		2 FPCA		3 FPCA	
	Area	Cum(%)	Area	Cum (%)	Area	Cum (%)
	$A_{jk}$	$A_{jk}^*$	$A_{jk}$	$A_{jk}^*$	$A_{jk}$	$A_{jk}^*$
1.	1.25	11.28	0.09	1.00	0.65	7.88
2.	1.15	10.39	0.22	2.53	0.66	8.02
3.	1.28	11.56	0.46	5.30	0.16	1.98
4.	1.04	9.42	0.38	4.33	0.32	3.92
5.	1.09	9.80	0.14	1.58	0.28	3.35
6.	1.47	13.28	0.28	3.26	0.12	1.43
7.	1.21	10.88	0.13	1.54	0.46	5.61
8.	0.33	2.99	2.41	27.71	0.38	4.62
9.	0.60	5.41	1.36	15.65	1.96	23.73
10.	0.59	5.33	0.74	8.55	2.51	30.40
11.	0.42	3.80	1.29	14.80	0.25	3.00
12.	0.65	5.88	1.20	13.77	0.50	6.06

## Rzut województw na 1 i 2 funkcjonalną składową główną



# Skupienia województw podobnych – 1 i 2 FPCA



# Podsumowanie

- Zaproponowano wykorzystanie funkcjonalnej analizy składowych głównych w ocenie rozwoju gospodarczego województw w Polsce za lata 2010–2021.
- Uzyskane wyniki są bardzo ważne z punktu widzenia prowadzenia odpowiedniej polityki gospodarczej.

# Literatura

Goswami, S., Das, A. K., Chakrabarti, A., Chakraborty, B. (2017), *A feature cluster taxonomy based feature selection technique*. Expert Systems with Applications, 79, 76–89.

Miao, J., Ping, Y., Chen, Z., Jin, X. B., Li, P., Niu, L. (2021), *Unsupervised feature selection by non-convex regularized self-representation*. Expert Systems with Applications, 173, 114643.

Schmutz, A., Jacques, J., Bouveyron, C., Cheze, L., Martin, P. (2020), *Clustering multivariate functional data in group-specific functional subspaces*. Computational Statistics, 1–31.



# Literatura

Wu, R., Wang, B., Xu, A. (2021), *Functional data clustering using principal curve methods*. Communications in Statistics-Theory and Methods, 1–34.

Dziękujemy za uwagę!