

Analiza korelacji kanonicznych

Mirosław Krzyśko, Łukasz Waszak

Wydział Matematyki i Informatyki
Uniwersytet im. Adama Mickiewicza

Wielowymiarowe metody statystyczne
Poznań 09.01.2013

W klasycznej analizie korelacji kanonicznych (CCA) interesuje nas zależność między dwoma wektorami losowymi \mathbf{Y} i \mathbf{X} . Poszukujemy wektorów wag \mathbf{l} i \mathbf{m} takich, żeby kombinacje liniowe $\mathbf{l}'\mathbf{Y}$ i $\mathbf{m}'\mathbf{X}$, zwane zmiennymi kanonicznymi, były ze sobą maksymalnie skorelowane.

- Współczynnik korelacji Pearsona

$$(Y, X) \rightarrow \rho = \frac{\text{Cov}(Y, X)}{\sqrt{\text{Var}(Y)\text{Var}(X)}} \in [-1, 1]$$

- Współczynnik korelacji wielokrotnej (wielorakiej)

$$(Y, \mathbf{X}) \rightarrow \rho = \max_{\mathbf{m} \in \mathbb{R}^q} \frac{\text{Cov}(Y, \mathbf{m}'\mathbf{X})}{\sqrt{\text{Var}(Y)\text{Var}(\mathbf{m}'\mathbf{X})}} \in [0, 1]$$

Niech

$$\text{Var} \begin{pmatrix} Y \\ \mathbf{X} \end{pmatrix} = \begin{bmatrix} \sigma_Y^2 & \sigma'_{Y\mathbf{X}} \\ \sigma_{Y\mathbf{X}} & \Sigma \end{bmatrix}, \quad \sigma_{Y\mathbf{X}} = \begin{bmatrix} \text{Cov}(Y, X_1) \\ \dots \\ \text{Cov}(Y, X_q) \end{bmatrix}.$$

Stąd

$$\rho = \left(\frac{\sigma'_{Y\mathbf{X}} \Sigma^{-1} \sigma_{Y\mathbf{X}}}{\sigma_Y^2} \right)^{\frac{1}{2}}$$

- Współczynnik korelacji kanonicznej

$$(\mathbf{Y}, \mathbf{X}) \longrightarrow \rho = \max_{\mathbf{l} \in \mathbb{R}^p, \mathbf{m} \in \mathbb{R}^q} \frac{\text{Cov}(\mathbf{l}'\mathbf{Y}, \mathbf{m}'\mathbf{X})}{\sqrt{\text{Var}(\mathbf{l}'\mathbf{Y})\text{Var}(\mathbf{m}'\mathbf{X})}} \in (0, 1]$$

Niech

$$\text{Var} \begin{pmatrix} \mathbf{Y} \\ \mathbf{X} \end{pmatrix} = \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}'_{12} & \boldsymbol{\Sigma}_{22} \end{bmatrix}.$$

Założmy, że $p \leq q$ oraz $\text{rz}\boldsymbol{\Sigma}_{12} = s \leq p$.

Niech

$$U = \mathbf{l}'\mathbf{Y} = l_1 Y_1 + l_2 Y_2 + l_p Y_p,$$

$$V = \mathbf{m}'\mathbf{X} = m_1 X_1 + m_2 X_2 + m_q X_q.$$

Wówczas

$$\text{Var}(U) = \mathbf{l}'\boldsymbol{\Sigma}_{11}\mathbf{l}, \quad \text{Var}(V) = \mathbf{m}'\boldsymbol{\Sigma}_{22}\mathbf{m},$$

$$\text{cov}(U, V) = \mathbf{l}'\boldsymbol{\Sigma}_{12}\mathbf{m}$$

oraz

$$\rho = \max_{\mathbf{l} \in \mathbb{R}^p, \mathbf{m} \in \mathbb{R}^q} \frac{\mathbf{l}'\boldsymbol{\Sigma}_{12}\mathbf{m}}{\sqrt{\mathbf{l}'\boldsymbol{\Sigma}_{11}\mathbf{l} \mathbf{m}'\boldsymbol{\Sigma}_{22}\mathbf{m}}}.$$

Ponieważ $\text{Corr}(U, V) = \text{Corr}(c_1 U, c_2 V)$, gdzie $c_1, c_2 \in \mathbb{R}$, to wektory \mathbf{l} i \mathbf{m} unormujemy tak, by $\text{Var}(\mathbf{l}'\mathbf{Y}) = \mathbf{l}'\boldsymbol{\Sigma}_{11}\mathbf{l} = 1$ i $\text{Var}(\mathbf{m}'\mathbf{X}) = \mathbf{m}'\boldsymbol{\Sigma}_{22}\mathbf{m} = 1$. Wówczas

$$\rho = \max_{\mathbf{l} \in \mathbb{R}^p, \mathbf{m} \in \mathbb{R}^q} \mathbf{l}'\boldsymbol{\Sigma}_{12}\mathbf{m},$$

przy warunku ograniczającym $\mathbf{l}'\boldsymbol{\Sigma}_{11}\mathbf{l} = 1$ i $\mathbf{m}'\boldsymbol{\Sigma}_{22}\mathbf{m} = 1$. Stosując metodę mnożników Lagrange'a otrzymujemy:

$$\begin{cases} -\rho\boldsymbol{\Sigma}_{11}\mathbf{l} + \boldsymbol{\Sigma}_{12}\mathbf{m} = 0 \\ \boldsymbol{\Sigma}_{21}\mathbf{l} - \rho\boldsymbol{\Sigma}_{22}\mathbf{m} = 0 \end{cases}$$

Po przekształceniu otrzymujemy dwa układy równań jednorodnych:

$$(\boldsymbol{\Sigma}_{11}^{-1}\boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21} - \rho_k^2 \mathbf{I}_p)\mathbf{l} = \mathbf{0}, \quad (\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}\boldsymbol{\Sigma}_{12} - \rho_k^2 \mathbf{I}_q)\mathbf{m} = \mathbf{0},$$

Zajmiemy się tylko układem $(\Sigma_{11}^{-1}\Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} - \rho_k^2 I_p)l = \mathbf{0}$. Warunkiem koniecznym i dostatecznym na to, by istniało niezerowe rozwiązanie tego układu jest warunek:

$$|\Sigma_{11}^{-1}\Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} - \rho_k^2 I_p| = 0.$$

Równanie to ma s niezerowych rozwiązań:

$$\rho_1^2 \geq \rho_2^2 \geq \dots \geq \rho_s^2, \quad s = rz \Sigma_{12}.$$

Rozwiązaniom tym odpowiada s wektorów własnych:

$$l_1, l_2, \dots, l_s.$$

Wtedy wektory własne m_1, m_2, \dots, m_s otrzymujemy z równości:

$$m_i = \rho_i^{-1} \Sigma_{22}^{-1} \Sigma_{21} l_i, \quad i = 1, 2, \dots, s.$$

- Niezerowe wartości $\rho_1 \geq \rho_2 \geq \dots \geq \rho_s$ nazywane są współczynnikami korelacji kanonicznej.
- Zmienne $U_i = \mathbf{l}'_i \mathbf{Y}$ nazywane są zmiennymi kanonicznymi przestrzeni \mathbf{Y} , natomiast zmienne $V_i = \mathbf{m}'_i \mathbf{X}$ nazywane są zmiennymi kanonicznymi przestrzeni \mathbf{X} .

Zachodzą następujące związki:

$$\text{Corr}(U_i, V_j) = \begin{cases} \rho_i, & \text{jeżeli } i = j, \\ 0, & \text{jeżeli } i \neq j, \end{cases}$$

$$\text{Corr}(U_i, U_j) = 0, \quad \text{Corr}(V_i, V_j) = 0, \text{ jeżeli } i \neq j.$$

Zatem pierwsze zmienne kanoniczne U_1 i V_1 są kombinacjami liniowymi składowych wektorów \mathbf{Y} i \mathbf{X} , maksymalnie ze sobą skorelowanymi (współczynnik korelacji jest równy ρ_1) i mającymi jednostkowe wariancje. Druga para zmiennych kanonicznych (U_2, V_2) jest tą parą, spośród wszystkich kombinacji liniowych składowych wektorów \mathbf{Y} i \mathbf{X} , która nie jest skorelowana z parą (U_1, V_1) , posiada współczynnik korelacji ρ_2 oraz posiada jednostkowe wariancje.

Jeżeli zmienne Y_1, Y_2, \dots, Y_p oraz X_1, X_2, \dots, X_q zestandaryzujemy, to wówczas macierzom kowariancji $\mathbf{\Sigma}_{11}, \mathbf{\Sigma}_{22}, \mathbf{\Sigma}_{12}$ odpowiadać będą macierze korelacji $\mathbf{R}_{11}, \mathbf{R}_{22}, \mathbf{R}_{12}$. Po standaryzacji, współczynniki korelacji kanonicznej nie ulegną zmianie, a wektory własne dla danych standaryzowanych wyrażą się za pomocą wektorów niestandaryzowanych następująco:

$$\tilde{\mathbf{l}}_i = (\text{diag} \mathbf{\Sigma}_{11})^{\frac{1}{2}} \mathbf{l}_i, \quad \tilde{\mathbf{m}}_i = (\text{diag} \mathbf{\Sigma}_{22})^{\frac{1}{2}} \mathbf{m}_i, \quad i = 1, 2, \dots, s.$$

Przykład 1.

Przykład pochodzi z książki *W. Härdle, L.Simar, Applied Multivariate Statistical Analysis, Springer 2007*. Dane są uśrednioną oceną 24 marek samochodów ($N = 24$) uzyskaną na podstawie ankiety 40 osób. Każda z cech została oceniona w skali od 1 (bardzo dobra) do 6 (bardzo zła).

Dane zostały podzielone na dwa zbiory zmiennych:


X – *Cena, Stabilność wartości*

Y – *Ekonomiczność, Serwis, Konstrukcja, Charakter sportowy, Bezpieczeństwo, Łatwość obsługi*

Klasyczna analiza korelacji kanonicznych

Współczynniki korelacji: **0.979197**, 0.885122

Rysunek: Rzut na przestrzeń 2 pierwszych zmiennych kanonicznych



Odwzorowujemy przestrzeń \mathbb{R}^p do przestrzeni Hilberta z jądrem reprodukującym $H(k_y)$, $\varphi : \mathbb{R}^p \rightarrow H(k_y)$, a przestrzeń \mathbb{R}^q do przestrzeni Hilberta z jądrem reprodukującym $H(k_x)$, $\psi : \mathbb{R}^q \rightarrow H(k_x)$.

Założmy, że $\tilde{\mathbf{K}}$ jest macierzą jądrową dla danych niescentrowanych. Wówczas macierz jądrowa dla danych scentrowanych jest postaci:

$$\mathbf{K} = \mathbf{P}\tilde{\mathbf{K}}\mathbf{P},$$

gdzie $\mathbf{P} = \mathbf{I} - \frac{1}{n}\mathbf{1}_n\mathbf{1}_n^T$, $\mathbf{1}_n$ jest n -wymiarowym wektorem złożonym z samych jedynek.

Formułujemy nowe zagadnienie CCA na zbiorach $\varphi(\mathbf{Y})$ oraz $\psi(\mathbf{X})$ (KCCA) i korzystamy z twierdzenia Moore'a-Aronszajna.

Ocnom macierzy kowariancji Σ_{11} , Σ_{22} , Σ_{12} odpowiadają następujące macierze w wersji jądrowej:

$$\hat{\Sigma}_{11} \rightarrow \mathbf{K}_y \mathbf{K}_y = \mathbf{K}_y^2$$

$$\hat{\Sigma}_{22} \rightarrow \mathbf{K}_x \mathbf{K}_x = \mathbf{K}_x^2$$

$$\hat{\Sigma}_{12} \rightarrow \mathbf{K}_y \mathbf{K}_x$$

Stosując metodę mnożników Lagrange'a otrzymujemy:

$$\begin{cases} -\rho \mathbf{K}_y^2 \mathbf{a} + \mathbf{K}_y \mathbf{K}_x \mathbf{b} = 0 \\ \mathbf{K}_x \mathbf{K}_y \mathbf{a} - \rho \mathbf{K}_x^2 \mathbf{b} = 0 \end{cases}$$

Powyższe uogólnione zagadnienie własne można zapisać w postaci macierzowej:

$$\mathbf{K}_1 \mathbf{c} = \rho \mathbf{K}_2 \mathbf{c}, \quad (1)$$

$$\mathbf{K}_1 = \begin{bmatrix} \mathbf{0} & \mathbf{K}_x \mathbf{K}_y \\ \mathbf{K}_y \mathbf{K}_x & \mathbf{0} \end{bmatrix}, \mathbf{K}_2 = \begin{bmatrix} \mathbf{K}_x^2 & \mathbf{0} \\ \mathbf{0} & \mathbf{K}_y^2 \end{bmatrix}, \mathbf{c} = \begin{bmatrix} \mathbf{a} = \boldsymbol{\alpha}^T \boldsymbol{\varphi}(\mathbf{X}) \\ \mathbf{b} = \boldsymbol{\beta}^T \boldsymbol{\psi}(\mathbf{Y}) \end{bmatrix},$$

gdzie $\mathbf{K}_y = (k_y(y_i, y_j))$ oraz $\mathbf{K}_x = (k_x(x_i, x_j))$, $i, j = 1, \dots, N$, są macierzami jądrowymi, których elementami są funkcje jądrowe.

Macierz \mathbf{K}_2 jest nieujemnie określona, mogą pojawić się więc osobliwości. Najprostrzym sposobem (wykorzystywanym również przy konstrukcji jądrowych zmiennych dyskryminacyjnych) jest regularyzacja macierzy \mathbf{K}_2 :

$$\mathbf{K}_2 \mapsto \mathbf{K}_2 + \epsilon \mathbf{I},$$

$$\epsilon = 10^{-5}.$$

i -ta wartość własna ρ_i macierzy $\mathbf{K}_1(\mathbf{K}_2 + \epsilon \mathbf{I})^{-1}$ wyznacza i -ty **jądrowy współczynnik korelacji kanonicznej**, a odpowiadający jej wektor własny \mathbf{c} i -tą parę **jądrowych zmiennych kanonicznych**.

Przykład 1.

Przykład pochodzi z książki *W. Härdle, L.Simar, Applied Multivariate Statistical Analysis, Springer 2007*. Dane są uśrednioną oceną 24 marek samochodów ($N = 24$) uzyskaną na podstawie ankiety 40 osób. Każda z cech została oceniona w skali od 1 (bardzo dobra) do 6 (bardzo zła).


Dane zostały podzielone na dwa zbiory zmiennych:

X – *Cena, Stabilność wartości*

Y – *Ekonomiczność, Serwis, Konstrukcja, Charakter sportowy, Bezpieczeństwo, Łatwość obsługi*

0.979197 0.885122


Rysunek: Rzut na przestrzeń 2 pierwszych klasycznych zmiennych kanonicznych




Jądrowe korelacje kanoniczne

1.000000 0.999998 0.999980 0.999385 0.998763 0.000002

Rysunek: Rzut na przestrzeń 2 pierwszych jądrowych zmiennych kanonicznych (KCCA)




Rysunek: Rzut na przestrzeń 2 pierwszych jądrowych zmiennych kanonicznych (KCCA) - górna prawa część wykresu



Innym podejściem jest odwzorowanie tylko przestrzeni \mathbb{R}^q do przestrzeni Hilberta z jądrem reprodukcującym. Pozostałe rozważania pozostają bez zmian (Zheng et al (2006)) (Q-KCCA).

0.99995 0.99935

Rysunek: Rzut na przestrzeń 2 pierwszych jądrowych zmiennych kanonicznych (Q-KCCA)



W przypadku funkcjonalnym (FCCA), interesuje nas zależność między dwoma procesami losowymi $Y(t)$ i $X(t)$. Poszukujemy funkcji wagowych $u(t)$ i $v(t)$ takich, by $\int uY$ i $\int vX$ były ze sobą maksymalnie skorelowane. Problematyka ta została zapoczątkowana pracą Leurgansa, Moyeeda i Silvermana (1993), a w bardziej dojrzałej formie została przedstawiona w monografii Ramsay'a i Silvermana (2005).

Przedstawimy nową metodę konstrukcji funkcjonalnych zmiennych kanonicznych odmienną od metody Ramsay'a i Silvermana.

Niech $\{y_{ij}, x_{ij}\}$ oznacza zaobserwowaną wartość pary cech statystycznych Y i X na i -tej jednostce doświadczalnej w j -tym momencie czasowym, gdzie $i = 1, 2, \dots, N$, $j = 1, 2, \dots, J_i$. Wówczas nasze dane składają się z N trójek $\{t_{ij}, y_{ij}, x_{ij}\}$, gdzie $t_{ij} \in [0, T]$, $i = 1, 2, \dots, N$, $j = 1, 2, \dots, J_i$.

Jednakże w wielu przypadkach wygodniej jest posługiwać się ciągłymi funkcjami czasu $y(t)$ i $x(t)$, $t \in [0, T]$, tj. **danymi funkcjonalnymi**. W takim przypadku dane dyskretne $\{t_{ij}, y_{ij}, x_{ij}\}$ przekształcamy na dane funkcjonalne $\{y_i(t), x_i(t), t \in [0, T]\}$.

Proces przekształcania danych jest identyczny dla wszystkich $y_i(t)$ oraz $x_i(t)$, stąd nasze dalsze rozważania dotyczyć będą pojedynczych funkcji $y(t)$ oraz $x(t)$, $t \in [0, T]$.

Jednym ze sposobów wygładzania (Ramsay i Silverman (2005)) jest przedstawienie odpowiednio funkcji $y(t)$ oraz $x(t)$ jako kombinacji liniowych odpowiednio $K_1 + 1$ ortonormalnych funkcji bazowych φ_k oraz $K_2 + 1$ ortonormalnych funkcji bazowych ψ_k :

$$y(t) = \sum_{k=0}^{K_1} \alpha_k \varphi_k(t), \quad t \in [0, T_1], \quad x(t) = \sum_{l=0}^{K_2} \beta_l \psi_l(t), \quad t \in [0, T_2].$$

Współczynniki tych kombinacji liniowych dobrane metodą najmniejszych kwadratów są postaci:

$$\hat{\alpha} = (\Phi' \Phi)^{-1} \Phi' \mathbf{y}, \quad \hat{\beta} = (\Psi' \Psi)^{-1} \Psi' \mathbf{x}.$$

gdzie $\mathbf{y} = (y_1, y_2, \dots, y_{J_1})'$, $\mathbf{x} = (x_1, x_2, \dots, x_{J_2})'$, $\alpha = (\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_{K_1})'$, $\beta = (\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_{K_2})'$ oraz Φ jest macierzą wymiaru $J_1 \times (K_1 + 1)$ zawierającą wartości $\varphi_k(t_j)$, a Ψ jest macierzą wymiaru $J_2 \times (K_2 + 1)$ zawierającą wartości $\psi_l(t_j)$.

Stopień gładkości funkcji $y(t)$ zależy od K_1 (małe K_1 powodują większe wygładzenie krzywych). Optymalną wartość K_1 wybieramy dla każdej funkcji $y_i(t)$ za pomocą bayesowskiego kryterium informacyjnego (BIC, patrz Shmueli(2010)), a następnie z wartości K_1 odpowiadającym wszystkim funkcjom wybierana jest wartość modalna (wspólna dla wszystkich $y_i(t)$).

Wartość BIC dla funkcji $y(t)$ wyraża się wzorem:

$$BIC(y(t)) = \ln \left(\frac{\mathbf{e}'\mathbf{e}}{2} \right) + (K_1 + 1) \left(\frac{\ln J}{J} \right),$$

gdzie $\mathbf{e} = (e_1, \dots, e_J)'$, $e_j = y_j - \sum_{k=0}^{K_1} \hat{\alpha}_k \varphi_k(t_j)$, $j = 1, 2, \dots, J$.
Analogicznie wyliczamy BIC dla funkcji $x(t)$.

Założmy, że obserwujemy realizacje dwuwymiarowego procesu losowego (Y, X) , gdzie $Y(t) \in L_2(I_1)$, $X(t) \in L_2(I_2)$. Tutaj $L_2(I_1)$ oraz $L_2(I_2)$ są przestrzeniami funkcji całkowalnych z kwadratem na przedziale odpowiednio I_1 oraz I_2 z iloczynem skalarnym

$$\langle u, v \rangle = \int u(t)v(t)dt.$$

Zakładamy również, że

$$E(\langle Z, Z \rangle) = E \left[\int (Z(t))^2 dt \right] < \infty,$$

gdzie $Z = Y$ lub $Z = X$.

Korelacje kanoniczne dla skończonego wymiarowych wektorów losowych $\mathbf{Y} \in \mathbb{R}^{K_1+1}$, $\mathbf{X} \in \mathbb{R}^{K_2+1}$ i procesów stochastycznych $Y(t) \in L_2(I_1)$, $X(t) \in L_2(I_2)$, definiujemy następująco. Niech $H_i = \mathbb{R}^{K_i+1}$ w przypadku wektorowym oraz $H_i = L_2(I_i)$ w przypadku funkcjonalnym.

Wówczas pierwsza korelacja kanoniczna ρ_1 i związane z nią wektory u_1 i v_1 lub funkcje wagowe $u_1(t)$ i $v_1(t)$ jest definiowana następująco:

$$\rho_1 = \sup_{u \in H_1, v \in H_2} \text{Cov}(\langle u, Y \rangle, \langle v, X \rangle) = \text{Cov}(\langle u_1, Y \rangle, \langle v_1, X \rangle)$$

przy czym

$$\text{Var}(\langle u, Y \rangle) = 1, \quad \text{Var}(\langle v, X \rangle) = 1.$$

Ogólnie k -ta korelacja kanoniczna ρ_k i związane z nią wektory u_k i v_k lub funkcje wagowe $u_k(t)$ i $v_k(t)$ jest definiowana następująco:

$$\rho_k = \sup_{u \in H_1, v \in H_2} \text{Cov}(\langle u, Y \rangle, \langle v, X \rangle) = \text{Cov}(\langle u_k, Y \rangle, \langle v_k, X \rangle)$$

przy czym $\text{Var}(\langle u, Y \rangle) = 1$, $\text{Var}(\langle v, X \rangle) = 1$ oraz k -ta para zmiennych kanonicznych (U_k, V_k) nie jest skorelowana z $k - 1$ pierwszymi parami $\{(U_i, V_i), i = 1, 2, \dots, k - 1\}$, gdzie

$$U_k = \langle u_k, Y \rangle, \quad V_k = \langle v_k, X \rangle.$$

Wyrażenie (ρ_k, u_k, v_k) nazywać będziemy **k -tą składową kanoniczną**.

Rozpatrując przypadek, gdy X i Y są procesami stochastycznymi, zakładając będziemy, że X i Y mogą być reprezentowane przez skończoną liczbę ortonormalnych funkcji bazowych, tj. można je zapisać w postaci:

$$Y(t) = \sum_{k=0}^{K_1} \alpha_k \varphi_k(t), \quad t \in I_1, \quad X(t) = \sum_{l=0}^{K_2} \beta_l \psi_l(t), \quad t \in I_2,$$

gdzie $\{\varphi_k\}$ i $\{\psi_k\}$ są $(K_i + 1)$ pierwszymi elementami baz przestrzeni $L_2(I_i)$ oraz $\{\alpha_k\}$ i $\{\beta_k\}$ są zmiennymi losowymi z zerowymi wartościami oczekiwanymi oraz skończonymi wariancjami.

Funkcjonalna analiza kanoniczna jest równoważna zwykłej analizie kanonicznej dla wektorów losowych złożonych ze współczynników α_k i β_k .

Niech:

$$\varphi(t) = (\varphi_0(t), \varphi_1(t), \dots, \varphi_{K_1}(t))', \quad \psi(t) = (\psi_0(t), \psi_1(t), \dots, \psi_{K_2}(t))',$$

$$\alpha = (\alpha_0, \alpha_1, \dots, \alpha_{K_1})', \quad \beta = (\beta_0, \beta_1, \dots, \beta_{K_2})',$$

gdzie

$$E(\alpha) = \mathbf{0}, \quad E(\beta) = \mathbf{0},$$

$$\text{Var}(\alpha) = \mathbf{\Sigma}_{11}, \quad \text{Var}(\beta) = \mathbf{\Sigma}_{22}, \quad \text{Cov}(\alpha, \beta) = E(\alpha\beta') = \mathbf{\Sigma}_{12}.$$

Wówczas procesy $Y(t)$ $X(t)$ możemy zapisać w postaci:

$$Y(t) = \alpha' \varphi(t), \quad X(t) = \beta' \psi(t).$$

Twierdzenie

k -ta składowa kanoniczna $(\rho_k, \mathbf{u}_k, \mathbf{v}_k)$ pary wektorów losowych $(\boldsymbol{\alpha}, \boldsymbol{\beta})$ związana jest z k -tą składową kanoniczną $(\gamma_k, u_k(t), v_k(t))$ pary procesów losowych $(X(t), Y(t))$ zależnościami:

$$\gamma_k = \rho_k, \quad u_k(t) = \mathbf{u}'_k \boldsymbol{\varphi}(t), \quad v_k(t) = \mathbf{v}'_k \boldsymbol{\psi}(t).$$

Niezerowe wartości własne ρ_k^2 oraz odpowiadające im wektory charakterystyczne \mathbf{u}_k wyznaczamy z równania:

$$(\boldsymbol{\Sigma}_{11}^{-1} \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^{-1} \boldsymbol{\Sigma}_{21} - \rho_k^2 \mathbf{I}_{p_1}) \mathbf{u}_k = \mathbf{0},$$

przy czym $1 \leq k \leq \min(K_1 + 1, K_2 + 1)$. Natomiast wektory \mathbf{v}_k wyznaczamy z równości:

$$\mathbf{v}_k = \rho_k^{-1} \boldsymbol{\Sigma}_{22}^{-1} \boldsymbol{\Sigma}_{21} \mathbf{u}_k, \quad i = 1, 2, \dots, s,$$

(Krzyśko (2009)).

Analiza korelacji kanonicznych dla wektorów losowych α i β bazuje na macierzach Σ_{11} , Σ_{22} i Σ_{12} . W praktyce macierze te nie są znane. Oceniamy je na podstawie N niezależnych realizacji tych wektorów. Mając wyznaczone wektory własne \hat{u}_k i \hat{v}_k wyznaczamy funkcje wagowe

$$\hat{u}_k(t) = \hat{u}'_k \varphi(t), \quad \hat{v}_k(t) = \hat{v}'_k \psi(t), \quad t \in [0, T].$$

Stąd współrzędna rzutu i -tej realizacji $y_i(t)$ procesu $Y(t)$ na j -tą funkcjonalną zmienną kanoniczną jest równa

$$\hat{U}_{ij} = \langle \hat{u}_j(t), y_i(t) \rangle = \int \hat{u}_j(t) y_i(t) dt = \sum_{k=0}^{K_1} \hat{\alpha}_{ik} \hat{u}_{jk} = \hat{\alpha}'_i \hat{\mathbf{u}}_j,$$

gdzie $i = 1, 2, \dots, N$, $j = 1, \dots, \min(K_1 + 1, K_2 + 1)$. Analogicznie współrzędna rzutu i -tej realizacji $x_i(t)$ procesu $X(t)$ na j -tą funkcjonalną zmienną kanoniczną jest równa


$$\hat{V}_{ij} = \hat{\beta}'_i \hat{\mathbf{v}}_j.$$

Dane pochodzą z internetowej bazy danych Banku Światowego (<http://data.worldbank.org/>).

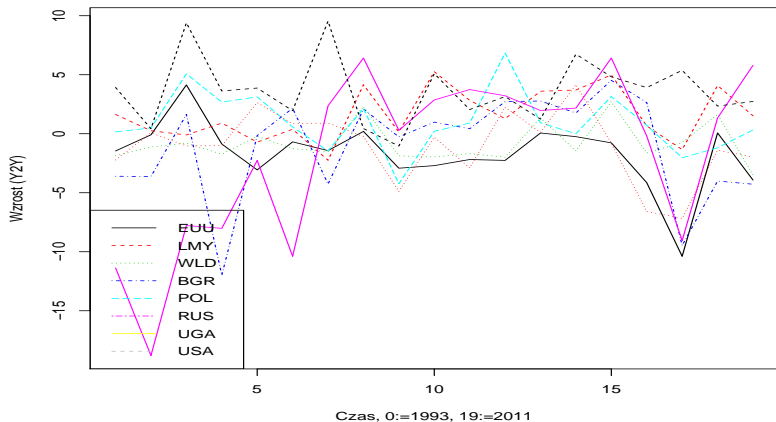
Do analizy wybrano 8 obszarów świata ($n = 8$) (Unia Europejska (EUU), Kraje o niskich i średnich dochodach (LMY), Cały Świat (WLD), Bułgaria (BGR), Polska (POL), Rosja (RUS), Uganda (UGA), Stany Zjednoczone (USA)) scharakteryzowanych dwiema zmiennymi - **Wzrost PKB** (Y) oraz **Stopa wzrostu bezpośrednich inwestycji zagranicznych** (X) badanymi w latach 1993-2011 ($J = 19$).

Szeregi zostały scentrowane, a do obliczeń użyta została baza Legendre'a w $L_2([-1, 1])$. Optymalne wartości K_1 oraz K_2 wybrane za pomocą kryterium BIC wynoszą dla obu szeregów 2 ($K_1 = 2 = K_2$).

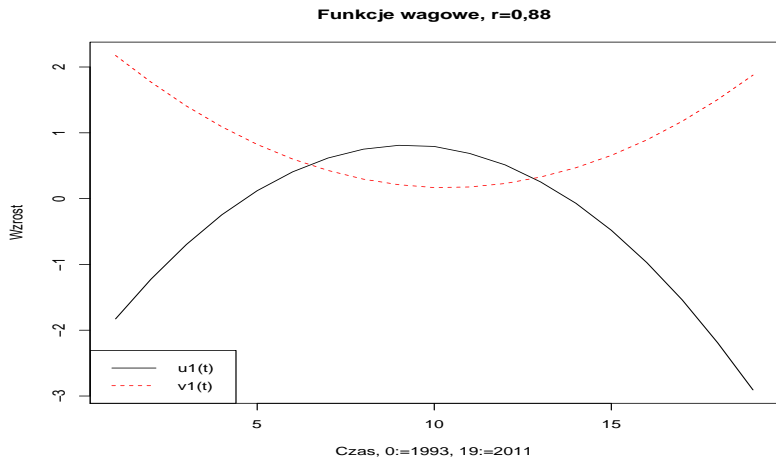
Rysunek: Szereg czasowy wzrostu PKB (Y)



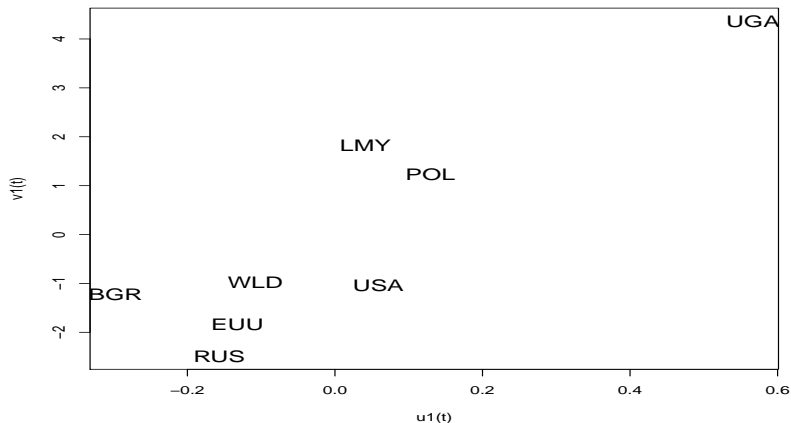
Rysunek: Szereg czasowy stóp wzrostu bezpośrednich inwestycji zagranicznych (X)



Rysunek: Funkcje wagowe ($u_1(t)$, $v_1(t)$)



Rysunek: Rzut 8 obszarów świata na płaszczyznę $(u_1(t), v_1(t))$



-  Krzyśko, M. (2009): Podstawy wielowymiarowego wnioskowania statystycznego, Wydawnictwo Naukowe UAM, Poznań.
-  Krzyśko, M., Waszak., Ł. (2012): Methods of representation for kernel canonical correlation analysis. STATISTICS IN TRANSITION new series - An International Journal of the Polish Statistical Association, Volume 13, Number 2, Summer 2012, 301-311
-  Leurgans, S.E., Moyeed, R.A. and Silverman B.W. (1993): Canonical correlation analysis when the data are curves, Journal of the Royal Statistical Society B 55, No. 3, 725-740.
-  Ramsay, J.O. and Silverman, B.W.: Functional Data Analysis, Second Edition, Springer 2005.
-  Zheng, W., Zhou, X., Zou, C., Zhao, L. (2006): Facial Expression Recognition Using Kernel Canonical Correlation Analysis, IEEE Transaction on Neural Networks 17(1), 233