

Výběr proměnných v kompozičních datech

S. Donevska E. Fišerová P. Filzmoser K. Hron

ROBUST 2014

Kompoziční data (CoDa) = kvantitativní popis časti nějakého celku, tudíž data nesoucí pouze **relativní informaci**.

- Simplex s Aitchisonovou geometrií = výběrový prostor CoDa,

$$\mathcal{S}^D = \{\mathbf{x} = (x_1, \dots, x_D)', x_i > 0, \sum_{i=1}^D x_i = \kappa\}.$$

- Aitchisonova geometrie není úplně vhodná pro provádění standardních statistických metod.
 - ⇒ Potřeba najít vhodnou reprezentaci CoDa v reálném prostoru.
- Navrženy transformace logaritmu podílů (logratio): aditivní logratio (alr) transformace, centrovaná logratio (clr) transformace a i izometrická logratio (ilr) transformace.
- CoDa se reprezentují pomocí podílu složek.

Clr transformace

Clr transformace je izometrické zobrazení mezi S^D a nadrovinou v \mathbb{R}^D ,

$$\mathbf{y} = \text{clr}(\mathbf{x}) = (y_1, y_2, \dots, y_D)' = \left(\ln \frac{x_1}{\sqrt[D]{\prod_{i=1}^D x_i}}, \dots, \ln \frac{x_D}{\sqrt[D]{\prod_{i=1}^D x_i}} \right)'. \quad (1)$$

- Nevýhody clr proměnných:

- nejsou souřadnice vzhledem k bázi na simplexu,
- vedou k singulární varianční matici ($y_1 + \dots + y_D = 0$),
- nejsou subkompozičně soudržné.

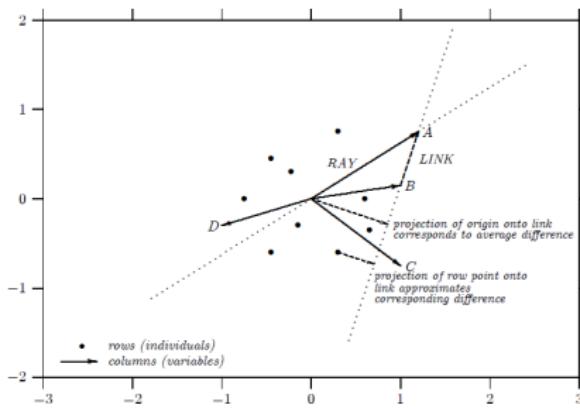
- Výhody clr proměnných:

- Převádí operace perturbace a mocninné transformace CoDa do obyčejného součtu a násobení skalárem CLR koeficientů,
- Euklidovská vzdálenost mezi vektory CLR proměnných = Aitchisonova vzdálenost jejich příslušných kompozic.
Platí i pro skalární součin a normu.

Interpretace CoDa biplotu

Kompoziční biplot je získaný jako standardní biplot pro clr transformovaná data.

- ① Vzdálenost mezi vrcholy šipek jsou úměrné směrodatné odchylce logaritmu podílu příslušných složek.
- ② Šipky představují clr proměnné.
- ③ Délka šipky je úměrná směrodatné odchylce clr proměnné.
- ④ Kosinus úhlu mezi dvěma vrcholy šipek dává hodnotu korelačního koeficientu mezi odpovídajícími logaritmami podílu.



Základní míra variability náhodné kompozice $\mathbf{x} = (x_1, \dots, x_D)'$ je **variační matice** definovaná jako

$$\mathbf{T} = \left\{ \text{var} \left(\ln \frac{x_i}{x_j} \right) \right\}_{i,j=1}^D.$$

- **T** je symetrická matice, která má na hlavní diagonále 0.
- Prvky matice **T** popisují variabilitu logaritmu podílu složek x_i a x_j .

(Normovaný) součet prvků variační matice **T** se nazývá **celková variance**,

$$\text{totvar}(\mathbf{x}) = \frac{1}{2D} \sum_{i=1}^D \sum_{j=1}^D \text{var} \left(\ln \frac{x_i}{x_j} \right),$$

vyjadřuje celkovou variabilitu v kompozičním datovém souboru.

Miry variability

- Platí, že $\text{totvar}(\mathbf{x}) = \sum_{i=1}^D \text{var}(y_i)$, kde

$$\text{var}(y_i) = \frac{D-1}{D^2} \sum_{j=1}^D \text{var}\left(\ln \frac{x_j}{x_i}\right) - \frac{1}{2D^2} \sum_{\substack{j=1 \\ j \neq i}}^D \sum_{\substack{l=1 \\ l \neq i}}^D \text{var}\left(\ln \frac{x_j}{x_l}\right),$$

- ⇒ Existuje celkem silný vztah mezi $\text{var}(y_i)$ a součtem prvků v i -tého řádku (sloupce) příslušné variační matici \mathbf{T} .

Věta

Nechť jsou dány CLR proměnné y_i a y_j , $i \neq j$, $i, j = 1, \dots, D$. Potom, $\text{var}(y_i) \geq \text{var}(y_j)$, právě tehdy, když

$$\sum_{p=1}^D \text{var}\left(\ln \frac{x_i}{x_p}\right) \geq \sum_{p=1}^D \text{var}\left(\ln \frac{x_j}{x_p}\right).$$

Navržená kroková procedura

Uvažujme kompozici $\mathbf{x} = (x_1, \dots, x_D)'$, takovou, že

$$\text{var}(y_1) \geq \dots \geq \text{var}(y_D) \quad (2)$$

\Leftrightarrow

$$\sum_{p=1}^D \text{var}\left(\ln \frac{x_1}{x_p}\right) \geq \sum_{p=1}^D \text{var}\left(\ln \frac{x_2}{x_p}\right) \geq \dots \geq \sum_{p=1}^D \text{var}\left(\ln \frac{x_D}{x_p}\right). \quad (3)$$

Algoritmus:

- 1 Vynecháme složku x_D , jejíž rozptyl odpovídající CLR proměnné je nejmenší.

Uvažujeme tedy podkompozici $\mathbf{x}_1 = (x_1, \dots, x_{D-1})'$ a provedeme CLR transformaci na \mathbf{x}_1 .

Vypočítáme rozptyly CLR transformovaných proměnných z \mathbf{x}_1 .

- 2 Opakujeme krok 1.
- 3 STOP nejpozději po $D - 2$ krocích.

Navržená kroková procedura

- Bude dodrženo pořadí variancí clr proměnných při přechodu z D -složkové k $D - 1$ - složkové podkompozici?
- ⇒ Ano, ale jen za splnění předpokladu

$$\text{var} \left(\ln \frac{x_1}{x_D} \right) \geq \text{var} \left(\ln \frac{x_2}{x_D} \right) \geq \cdots \geq \text{var} \left(\ln \frac{x_{D-1}}{x_D} \right).$$

- Kdy máme skončit s výběrem kompozičních složek?
- ⇒ Poté co použijeme stop kritérium, které porovnává celkovou varianci podkompozici \mathbf{x}_i , získanou v i -tém kroku algoritmu $i = 1, \dots, D - 2$, s celkovou variancí podkompozici \mathbf{x}_{i-1} z předchozího kroku.

Navržená kroková procedura – STOP kritérium

$$H_0 : \text{totvar}(\mathbf{x}_i) = \text{totvar}(\mathbf{x}_{i-1}) \text{ v.s. } H_A : \text{totvar}(\mathbf{x}_i) < \text{totvar}(\mathbf{x}_{i-1})$$

- Za předpokladu platnosti nulové hypotézy

$$U_i^+ = \frac{\widehat{\text{totvar}}(\mathbf{x}_i) - \text{totvar}(\mathbf{x}_{i-1})}{\sqrt{\frac{2}{n-1} \text{tr} \left(\widehat{\boldsymbol{\Sigma}}_i^2 \right)}} \sim N(0, 1), \text{ pro } i \rightarrow \infty,$$

kde $\widehat{\boldsymbol{\Sigma}}_i$ je výběrová varianční matice kompozice \mathbf{x}_i v (libovolných) ilr souřadnicích.

- H_0 se zamítá na hladině významnosti α jestliže

$$u_i^+ \in W = (-\infty, u_\alpha),$$

kde u_i^+ je realizace U_i^+ a u_α je α - kvantil normovaného normálního rozdělení.

- V každém kroku spočítáme U_i^+ proceduru ukončíme když $u_i^+ \in W$.

Datový soubor Kola je výsledkem velkého geochemického projektu, který byl prováděný od 1992 do 1998 Geologickým průzkumným ústavem Finska a Norska, Centrální Kola expedicí, Rusko.

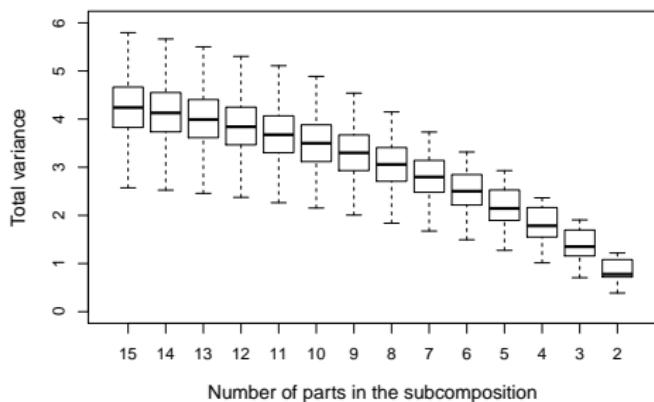
- Zkoumaná oblast: 188 000 km^2 na poloostrově Kola v Severní Evropě.
- Celkem je odebráno cca 600 vzorků ze 4 různých půdních horizontů (horizont O, horizont A, horizont B, horizont C).
- Analyzovaný jsou více než 50 chemických prvků v půdních horizontech.
- Data jsou dostupná v balíčku StatDA softwaru R (R Development Core Team, 2012).

Příklad – Data Kola – I. Experiment

- Náhodně vybereme 15 proměnných z 30 prvků z horizontu O.
- Algoritmus je aplikovaný dokud nedocílíme 2-složkovou podkompozici.
- V každém kroku je vypočítaná celková variance.
- Celá procedura je opakovaná 1000 krát.

Příklad – Data Kola – I. Experiment

- Náhodně vybereme 15 proměnných z 30 prvků z horizontu O.
- Algoritmus je aplikovaný dokud nedocílíme 2-složkovou podkompozici.
- V každém kroku je vypočítaná celková variance.
- Celá procedura je opakovaná 1000 krát.



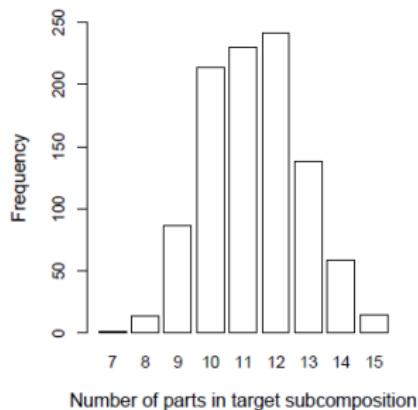
Obr: Celková variance podkompozic obdržená z postupné krokové procedury.

Příklad – Data Kola – II. experiment

- Znovu vybíráme náhodně 15 proměnných z 30 prvků z horizontu O.
- Postupná procedura je aplikovaná dokud testová statistika nenavrhne zastavení procesu.
- Celá procedura je opakovaná 1000 krát.

Příklad – Data Kola – II. experiment

- Znovu vybíráme náhodně 15 proměnných z 30 prvků z horizontu O.
- Postupná procedura je aplikovaná dokud testová statistika nenavrhne zastavení procesu.
- Celá procedura je opakovaná 1000 krát.



Obr: Sloupcový graf počtu složek výsledných podkompozic z postupné krokové procedury užitím STOP kritéria.

Příklad – Data Kola – II. experiment

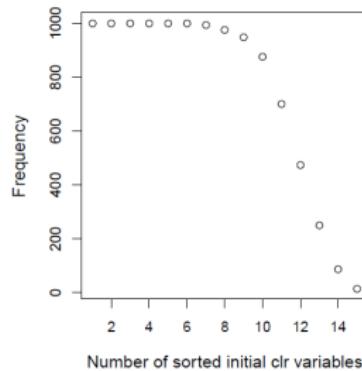
Obsahuje výsledná kompozice složky, které měly vysokou clr varianci v původní D-složkové kompozici?

- Složky ze všech 1000 počátečních podkompozic jsou vybrané dle jejich klesajících hodnot clr variancí.
- Počítáme, jak často jsou top k clr proměnné zahrnuty do výsledné kompozice, kde $k = 1, \dots, 15$.

Příklad – Data Kola – II. experiment

Obsahuje výsledná kompozice složky, které měly vysokou clr varianci v původní D-složkové kompozici?

- Složky ze všech 1000 počátečních podkompozic jsou vybrané dle jejich klesajících hodnot clr variancí.
- Počítáme, jak často jsou top k clr proměnné zahrnuty do výsledné kompozice, kde $k = 1, \dots, 15$.



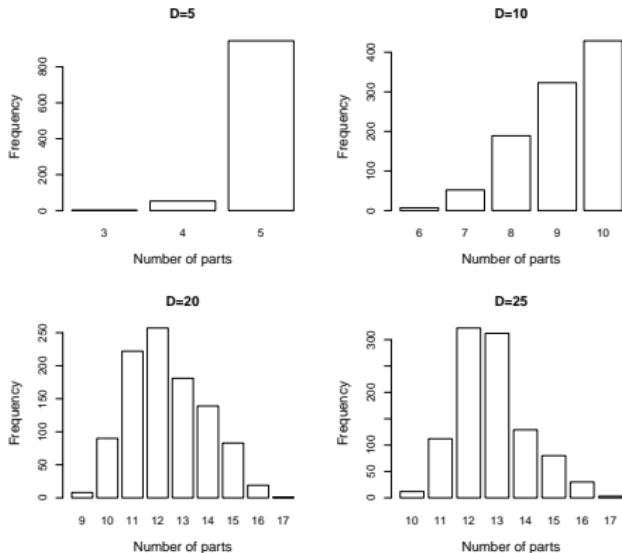
Obr: Clr proměnné z původní kompozice uspořádané dle klesajících variancí, vs. počet, kolikrát příslušné kompoziční složky byly zahrnuty ve výsledné podkompozici.

Příklad – Data Kola – III. experiment

- Použijeme stejné simulační nastavení jako před tím, ale vybereme 5, 10, 20 a 25 - složkové počáteční kompozice z datového souboru Kola.
- Cela procedura je opakovaná 1000 krát.

Příklad – Data Kola – III. experiment

- Použijeme stejné simulační nastavení jako před tím, ale vybereme 5, 10, 20 a 25 - složkové počáteční kompozice z datového souboru Kola.
- Cela procedura je opakovaná 1000 krát.



Obr: Sloupcové grafy počtů složek výsledné podkompozice z krokové procedury užitím STOP – kritéria.

Příklad – Baltický průzkum půdy

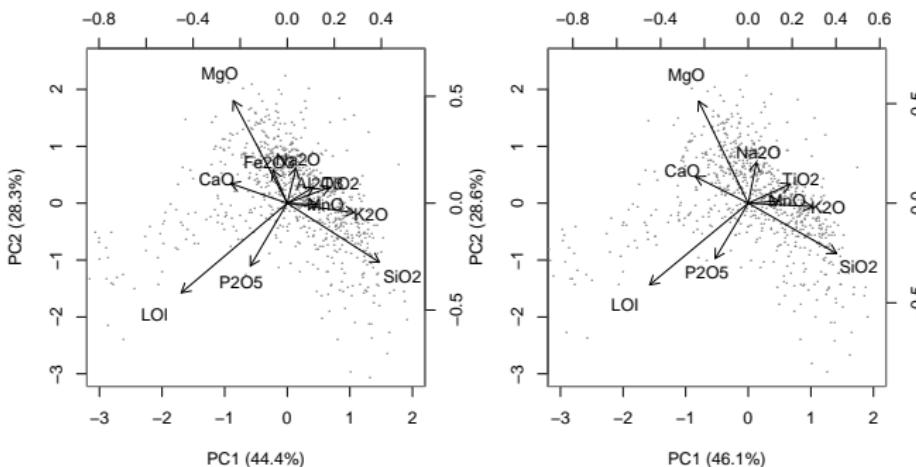
BSS datový soubor (Reimann et al., 2003), je získány z rozsáhlého geochemického projektu který, je realizovaný v Severní Evropě v oblasti rozsahu cca 1 800 000 km².

- 769 vzorků zemědělské půdy.
- Vzorky pocházejí ze dvou vrstev: horní vrstva (0-25cm) a spodní vrstva (50-75 cm).
- U všech vzorku je analyzovaná koncentrace z více než 40 chemických sloučenin.
- Používáme významné sloučeniny (Al_2O_3 , Fe_2O_3 , K_2O , MgO , MnO , CaO , TiO_2 , Na_2O , P_2O_5 a SiO_2), plus LOI (Loss on ignition) z horní vrstvě tj., 11-ti složkovou CoDa.
- Datový soubor z horní a dolní vrstvy půdy je přístupny v balíčku `mvoutlier` v R.

Příklad – Baltický průzkum půdy

Vliv postupné procedury je zobrazen pomocí CoDa biplotu na BSS datech.

- Při použití testového kritéria pro $\alpha = 0.05$ jsme získali 9-složkovou podkompozici (Al_2O_3 a Fe_2O_3 jsou vyloučené).



Obr: Biplot pro BSS data pro všechny významné sloučeniny (vlevo) a po odstranění Al_2O_3 a Fe_2O_3 (vpravo).

Literatura

-  Aitchison J (1986) The statistical analysis of compositional data. Chapman and Hall, London.
-  Egozcue JJ (2009) Reply to "On the Harker Variation Diagrams; ..." by J. A. Cortés. *Math Geosci* 41:829–834.
-  Filzmoser P, Hron K, Reimann C (2012) Interpretation of multivariate outliers for compositional data. *Computers & Geosciences* 39: 77–85.
-  Hron K, Filzmoser P, Donevska S, Fišerová E (2013) Covariance based variable selection for compositional data. *Mathematical geosciences* 45:487–498.
-  Hron K, Kubáček L (2011) Statistical properties of the total variation estimator for compositional data. *Metrika* 74: 221–230.