

Možnosti jednorozměrné statistické analýzy kompozičních dat

K. Hron¹, P. Filzmoser², E. Fišerová¹, P. de Caritat³,
A. Gardlo¹

¹Katedra matematické analýzy a aplikací matematiky - Univerzita Palackého

²Institut für Stochastik und Wirtschaftsmathematik - Technische Universität
Wien, Österreich

³Geoscience Australia

Robust 2016, 12. září 2016

Kompoziční data

- = *D-složkové vektory, popisující kvantitativně části nějakého celku, nesoucí relativní informaci o složkách* (Aitchison, 1986; Pawlowsky-Glahn a kol., 2015)

Kompoziční data

- = *D-složkové vektory, popisující kvantitativně části nějakého celku, nesoucí relativní informaci o složkách* (Aitchison, 1986; Pawlowsky-Glahn a kol., 2015)
- **obvyklé jednotky měření:** procenta, mg/kg (*konstantní součet složek*), mg/l (*konstantní součet se nevyskytuje*)

Kompoziční data

- = *D-složkové vektory, popisující kvantitativně části nějakého celku, nesoucí relativní informaci o složkách* (Aitchison, 1986; Pawlowsky-Glahn a kol., 2015)
- **obvyklé jednotky měření:** procenta, mg/kg (*konstantní součet složek*), mg/l (*konstantní součet se nevyskytuje*)
- **příklady:** geochemická data - proporce minerálů v hornině; koncentrace fenolických kyselin ve víně (mg/l); výdaje domácností na různé položky (jídlo, bydlení, ošacení) apod.

Kompoziční data

- = *D-složkové vektory, popisující kvantitativně části nějakého celku, nesoucí relativní informaci o složkách* (Aitchison, 1986; Pawlowsky-Glahn a kol., 2015)
- **obvyklé jednotky měření:** procenta, mg/kg (*konstantní součet složek*), mg/l (*konstantní součet se nevyskytuje*)
- **příklady:** geochemická data - proporce minerálů v hornině; koncentrace fenolických kyselin ve víně (mg/l); výdaje domácností na různé položky (jídlo, bydlení, ošacení) apod.
- konstantní součet složek (1, 100) = *vhodná reprezentace kompozic*

Geometrické aspekty analýzy kompozičních dat

- požadavky na relevantní analýzu kompozic: *invariance na změnu měřítka, podkompoziční soudržnost, zachování relativního měřítka* \Rightarrow **Aitchisonova geometrie** (AG; EVP dimenze $D - 1$)
- většina statistických metod se opírá o předpoklad euklidovské geometrie (Eaton, 1983)

Geometrické aspekty analýzy kompozičních dat

- požadavky na relevantní analýzu kompozic: *invariance na změnu měřítka, podkompoziční soudržnost, zachování relativního měřítka* \Rightarrow **Aitchisonova geometrie** (AG; EVP dimenze $D - 1$)
 - většina statistických metod se opírá o předpoklad euklidovské geometrie (Eaton, 1983)
- \Rightarrow vyjádřit kompoziční data v souřadnicích vzhledem k ortonormální bázi na simplexu (Egozcue a kol., 2003) \rightarrow statistická analýza, interpretace (*bilance, absence standardních (kartézských) souřadnic*)
- **log-podílová (log-ratio) analýza** kompozičních dat (Aitchison, 1986)

Problém

- **výchozí pozice:** kompoziční data jsou z definice mnohorozměrná, libovolná složka kompozice nemůže být uvažována nezávisle na ostatních (veškerá relevantní informace je obsažena v podílech mezi složkami)
- **dáno:** D -složková kompozice $\mathbf{x} = (x_1, \dots, x_D)'$, vyjádřená v $D - 1$ ortonormálních souřadnicích vzhledem k AG

Problém

- **výchozí pozice:** kompoziční data jsou z definice mnohorozměrná, libovolná složka kompozice nemůže být uvažována nezávisle na ostatních (veškerá relevantní informace je obsažena v podílech mezi složkami)
- **dáno:** D -složková kompozice $\mathbf{x} = (x_1, \dots, x_D)'$, vyjádřená v $D - 1$ ortonormálních souřadnicích vzhledem k AG
- **cíl:** zachytit relativní informaci o **konkrétní složce**, řekněme x_1 , pomocí jedné ze souřadnic

Problém

- **výchozí pozice:** kompoziční data jsou z definice mnohorozměrná, libovolná složka kompozice nemůže být uvažována nezávisle na ostatních (veškerá relevantní informace je obsažena v podílech mezi složkami)
- **dáno:** D -složková kompozice $\mathbf{x} = (x_1, \dots, x_D)'$, vyjádřená v $D - 1$ ortonormálních souřadnicích vzhledem k AG
- **cíl:** zachytit relativní informaci o **konkrétní složce**, řekněme x_1 , pomocí jedné ze souřadnic
- **otázka:** které složky musíme uvažovat, např. při tvorbě geochemické mapy pro složku x_1 ?

Problém

- **výchozí pozice:** kompoziční data jsou z definice mnohorozměrná, libovolná složka kompozice nemůže být uvažována nezávisle na ostatních (veškerá relevantní informace je obsažena v podílech mezi složkami)
- **dáno:** D -složková kompozice $\mathbf{x} = (x_1, \dots, x_D)'$, vyjádřená v $D - 1$ ortonormálních souřadnicích vzhledem k AG
- **cíl:** zachytit relativní informaci o **konkrétní složce**, řekněme x_1 , pomocí jedné ze souřadnic
- **otázka:** které složky musíme uvažovat, např. při tvorbě geochemické mapy pro složku x_1 ?
- **problém:** některé složky mohou být zatíženy chybou měření, což může ovlivnit relativní informaci o x_1

Souřadnicová reprezentace

- **veškerá relativní informace** o složce x_1 může být reprezentována souřadnicí z_1 , lze zkonstruovat ortonormální souřadnice (pivotové bilance) $\mathbf{z} = (z_1, \dots, z_{D-1})'$ k x_1 jako

$$z_i = \sqrt{\frac{D-i}{D-i+1}} \ln \frac{x_i}{\sqrt[D-i]{\prod_{k=i+1}^D x_k}}, \quad i = 1, \dots, D-1$$

(Fišerová a Hron, 2011)

- složka x_1 je obsažena pouze v z_1 , která může být také vyjádřena jako normovaný součet $\ln(x_1/x_2) + \dots + \ln(x_1/x_D)$
- zbývající souřadnice (z_2, \dots, z_{D-1}) reprezentují podkompozici o složkách x_2, \dots, x_D

Vážené pivotové bilance

- **vážený protějšek k z_1** (Filzmoser a Hron, 2015): vezmeme vážený součet párových log-podílů k x_1 :

$$\alpha_2 \ln \frac{x_1}{x_2} + \dots + \alpha_D \ln \frac{x_1}{x_D}, \quad \alpha_k > 0, \quad k = 1, \dots, D; \quad \alpha_2 + \dots + \alpha_D = 1$$

- s normující konstantou (pro dosažení ortonormality) obdržíme souřadnici

$$w_1 = \frac{1}{\sqrt{1 + \sum_{k=2}^D \alpha_k^2}} \ln \frac{x_1}{\prod_{k=2}^D x_k^{\alpha_k}}$$

- zbývajících $D - 2$ souřadnic získáme řešením posloupnosti vhodně zvolených lineárních homogenních systémů

Vážené pivotové bilance: konstrukce

- 1) vyjádříme váženou pivotovou bilanci jako vektor logkontrastových koeficientů, $w_1 = \mathbf{w}'_1 \ln \mathbf{x}$

$$\mathbf{w}_1 = \frac{1}{\sqrt{1 + \sum_{k=2}^D \alpha_k^2}} (1, -\alpha_2, \dots, -\alpha_D)'$$

- 2) vektory koeficientů $\mathbf{w}_2, \dots, \mathbf{w}_{D-1}$ získáme postupně při dodržení požadavku ortonormality $\mathbf{w}'_i \mathbf{w}_j = \delta_{ij}$,
 $i, j = 1, \dots, D-1$ a logkontrastové podmínky $\mathbf{w}'_i \mathbf{1} = 0$
- 3) volné parametry v lineárních systémech jsou užity pro zajištění toho, že je informace o x_1 obsažena pouze v w_1 a w_{D-1}

Vážené pivotové bilance: konstrukce

- 1) vyjádříme váženou pivotovou bilanci jako vektor logkontrastových koeficientů, $w_1 = \mathbf{w}'_1 \ln \mathbf{x}$

$$\mathbf{w}_1 = \frac{1}{\sqrt{1 + \sum_{k=2}^D \alpha_k^2}} (1, -\alpha_2, \dots, -\alpha_D)'$$

- 2) vektory koeficientů $\mathbf{w}_2, \dots, \mathbf{w}_{D-1}$ získáme postupně při dodržení požadavku ortonormality $\mathbf{w}'_i \mathbf{w}_j = \delta_{ij}$,
 $i, j = 1, \dots, D-1$ a logkontrastové podmínky $\mathbf{w}'_i \mathbf{1} = 0$
- 3) volné parametry v lineárních systémech jsou užity pro zajištění toho, že je informace o x_1 obsažena pouze v w_1 a w_{D-1}
- ⇒ lze předpokládat, w_1 obsahuje relevantní relativní informaci o x_1 a w_{D-1} tu zbývající (redundantní)

Vážené pivotové bilance: obecné vztahy

- $\mathbf{w}_2 = (\underbrace{0, \dots, 0}_{D-3}, \alpha_{D-1} - \alpha_D, \alpha_D - \alpha_{D-2}, \alpha_{D-2} - \alpha_D)',$
- $\mathbf{w}_p = (\underbrace{0, \dots, 0}_{D-p-1}, w_{p,D-p}, w_{p,D-p+1}, \dots, w_{p,D})',$
 $p = 3, \dots, D-2:$

$$w_{p,D-p} = 2 \sum_{i=D-p+1}^{D-1} \sum_{j=i+1}^D \alpha_i \alpha_j - (p-1) \sum_{i=D-p+1}^D \alpha_i^2,$$

$$w_{p,k} = \sum_{\substack{i=D-p+1 \\ i \neq k}}^D \alpha_i^2 - (\alpha_{D-p} + \alpha_k) \sum_{\substack{i=D-p+1 \\ i \neq k}}^D \alpha_i + (p-1) \alpha_k \alpha_{(D-p)},$$

$$k = D-p+1, D-p+2, \dots, D$$

Vážené pivotové bilance: obecné vztahy

- pro $\mathbf{w}_{D-1} = (w_{D-1,1}, w_{D-1,2}, \dots, w_{D-1,D})'$ obdržíme následující koeficienty

$$w_{D-1,1} = 2 \sum_{i=2}^{D-1} \sum_{j=i+1}^D \alpha_i \alpha_j - (D-2) \sum_{i=2}^D \alpha_i^2,$$

$$w_{D-1,k} = (D-2) \sum_{\substack{i=2 \\ i \neq k}}^D \alpha_i^2 + (1-\alpha_k) \sum_{\substack{i=2 \\ i \neq k}}^D \alpha_i - (D-2)\alpha_k, \quad k = 2, \dots, D$$

- specifická role x_1 v souřadnici w_{D-1} je zřejmá
- následně lze určit normující konstanty (pro obdržení ortonormálních souřadnic)

Vážené pivotové bilance: případ $D = 3$

- **případ $D = 3$:**

$$w_1 = \frac{1}{\sqrt{2(1 - \alpha_2\alpha_3)}} \ln \frac{x_1}{x_2^{\alpha_2} x_3^{\alpha_3}}$$

$$w_2 = \frac{1}{\sqrt{6(1 - \alpha_2\alpha_3)}} \ln x_1^{\alpha_3 - \alpha_2} x_2^{-(1 + \alpha_3)} x_3^{1 + \alpha_2}$$

- poznamenejme, že v závislosti na α_2 a α_3 souřadnice w_2 taktéž obsahuje relativní informaci o x_1 ; **speciální případ:** $\alpha_2 = \alpha_3 = \frac{1}{2}$:

$$w_1 = z_1 = \sqrt{\frac{2}{3}} \ln \frac{x_1}{\sqrt{x_2 x_3}} \quad \text{and} \quad w_2 = z_2 = \frac{1}{\sqrt{2}} \ln \frac{x_2}{x_3}$$

Volba vah

- variační(!) matice je základní charakteristikou kompoziční variability pro $\mathbf{x} = (x_1, \dots, x_D)'$:

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

- předpokládejme, že složka, která nás zajímá, je x_1 , tedy uvažujeme první řádek (sloupec) matice \mathbf{T} :

$$\mathbf{t}_1 = (t_{11}, \dots, t_{1D}) = \left(\text{var} \left(\ln \frac{x_1}{x_1} \right), \text{var} \left(\ln \frac{x_1}{x_2} \right), \dots, \text{var} \left(\ln \frac{x_1}{x_D} \right) \right)$$

- definujeme váhy: $\tilde{\alpha}_i = \frac{1}{t_{1i}^2}$, pro $i = 2, \dots, D$, které přiřazují převrácené čtvercové hodnoty rozptylů párových log-podílů s x_1 (dále normované pro získání $\alpha_2, \dots, \alpha_D$)


Koncentrace prvků v sedimentech (National Geochemical Survey of Australia)

- projekt National Geochemical Survey of Australia (NGSA) shromáždil 1315 vzorků pokrývajících přes 80 % Austrálie (Caritat a Cooper, 2011)
- výsledek rozsáhlého geochemického výzkumu pokrývajícího přes 6 million km², provedeného Geoscience Australia a geologickými službami jednotlivých států Austrálie
- pro analýzu bylo vybráno 49 proměnných (koncentrací chemických prvků)

NGSA data: výsledky

- simulační studie (se všemi složkami): ukázalo se, že vážené bilance jsou efektivním prostředkem k zachycení jednorozměrné (relativní) informace v geochemických mapách díky potlačení „redundantních“ log-podílů skrze vhodnou volbu vah


NSGA data: simulace



NGSA data: výsledky

- simulační studie (se všemi složkami): ukázalo se, že vážené bilance jsou efektivním prostředkem k zachycení jednorozměrné (relativní) informace v geochemických mapách díky potlačení „redundantních“ log-podílů skrze vhodnou volbu vah
- eliminace tzv. **pobřežního efektu** (v oblastech jeho výskytu), zejména pro stopové prvky
 - demonstrováno pro případ cesia (Cs)

NSGA data: srovnání pro Cs



Závěry

- vážené pivotové bilance představují alternativu k „automatické“ konstrukci pivotových bilancí

Závěry

- vážené pivotové bilance představují alternativu k „automatické“ konstrukci pivotových bilancí
- získané ortonormální souřadnice mohou být následně využity pro statistickou analýzu (korelační analýza v souřadnicích, regresní analýza)

Závěry

- vážené pivotové bilance představují alternativu k „automatické“ konstrukci pivotových bilancí
- získané ortonormální souřadnice mohou být následně využity pro statistickou analýzu (korelační analýza v souřadnicích, regresní analýza)
- w_1 a w_{D-1} jsou konstruovány tak, že obsahují veškerou relativní informaci o vybrané složce; w_1 obsahuje „relevantní“ informaci, w_{D-1} obsahuje zbývající informaci

Závěry

- vážené pivotové bilance představují alternativu k „automatické“ konstrukci pivotových bilancí
- získané ortonormální souřadnice mohou být následně využity pro statistickou analýzu (korelační analýza v souřadnicích, regresní analýza)
- w_1 a w_{D-1} jsou konstruovány tak, že obsahují veškerou relativní informaci o vybrané složce; w_1 obsahuje „relevantní“ informaci, w_{D-1} obsahuje zbývající informaci
- váhy mohou být určeny pomocí variační matice, nebo na základě expertní znalosti (např. kvality měření)

Literatura

-  Aitchison, J. : *The statistical analysis of compositional data.* Chapman and Hall, London, 1986.
-  Caritat, P. de, Cooper, M.: *National Geochemical Survey of Australia: The Geochemical Atlas of Australia.* Geoscience Australia Record, 2011/20 (2 Volumes)
-  Eaton, M.L.: *Multivariate statistics: A vector space approach.* Wiley, New York, 1983.
-  Egozcue, J.J., Pawlowsky-Glahn, V.: *Groups of parts and their balances in compositional data analysis.* Mathematical Geology 37, 795-828, 2005.
-  Filzmoser, P., Hron, K.: *Robust coordinates for compositional data using weighted balances.* In Nordhausen, K., Taskinen, S., editors, *Modern nonparametric, robust and multivariate methods.* Springer, Heidelberg, 2015.
-  Fišerová, E., Hron, K.: *On interpretation of orthonormal coordinates for compositional data.* Mathematical Geosciences 43, 455-468, 2011.
-  Pawlowsky-Glahn, V., Egozcue, J.J., Tolosana-Delgado, R.: *Modeling and analysis of compositional data.* Wiley, Chichester, 2015.

Prezentace je k dispozici na <http://compositions.sweb.cz/>.