

Aplikace \mathcal{T} -prostorů při modelování kompozičních časových řad

P. Kynčlová^{1,3}
P. Filzmoser¹, K. Hron^{2,3}

¹Department of Statistics and Probability Theory
Vienna University of Technology

²Katedra matematické analýzy a aplikací matematiky
Univerzita Palackého v Olomouci

³Katedra geoinformatiky
Univerzita Palackého v Olomouci

ROBUST 2014, 23. ledna 2014

Obsah

Kompoziční časové řady

VAR model

\mathcal{T} -prostory

Praktický příklad

Kompoziční data

- ▶ data nesoucí výhradně **relativní** informaci, jejichž výběrovým prostorem je simplex \mathcal{S}^D

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

- ▶ **Aitchisonova geometrie na simplexu**

⇒ logratio transformace ze simplexu do reálného prostoru

- ▶ **izometrická logratio transformace:** $\text{ilr}(\mathbf{x}) = (z_1, \dots, z_{D-1})'$

$$z_j = \sqrt{\frac{D-j}{D-j+1}} \ln \frac{x_j}{\sqrt[D-j]{\prod_{l=j+1}^D x_l}}, \quad j = 1, \dots, D-1 \quad (1)$$

⇒ souřadnice z_1 obsahuje veškerou relativní informaci o x_1 vzhledem k ostatním složkám x_2, \dots, x_D

Kompoziční časové řady

Definice

- ▶ mnohorozměrné časové řady pro kompoziční data

$$\{\mathbf{x}_t : t = 1, \dots, n\}, \quad \mathbf{x}_t = (x_{1t}, \dots, x_{Dt})' \in \mathcal{S}^D$$

- ▶ časové řady s kladnými reálnými prvky

$$x_{1t}, \dots, x_{Dt} > 0$$

- ▶ **problém:** konstatní součet v každém čase $t \iff$ často roven 1 (proporcionální data)
- ▶ **řešení:** logratio transformace ze simplexu do prostoru souřadnic ($\mathcal{S}^D \rightarrow \mathbb{R}^{D-1}$)

Kompoziční časové řady

Princip modelování kompozičních časových řad

- ▶ transformace do prostoru souřadnic:
izometrická logratio (ilr) transformace (1)
⇒ výhodné interpretační vlastnosti
- ▶ aplikace standardních metod pro analýzu mnohorozměrných časových řad v prostoru souřadnic
- ▶ návrat zpět na simplex ⇒ inverzní ilr transformace

Vektorový autoregresní proces VAR(p)

Definice

- ▶ **VAR(p) model** v redukovaném tvaru

$$\mathbf{z}_t = \mathbf{c} + \mathbf{A}_{\mathbf{V}}^{(1)} \mathbf{z}_{t-1} + \mathbf{A}_{\mathbf{V}}^{(2)} \mathbf{z}_{t-2} + \cdots + \mathbf{A}_{\mathbf{V}}^{(p)} \mathbf{z}_{t-p} + \boldsymbol{\epsilon}_t, \quad (2)$$

kde $\mathbf{B} = [\mathbf{c}_{\mathbf{V}}, \mathbf{A}_{\mathbf{V}}^{(1)}, \dots, \mathbf{A}_{\mathbf{V}}^{(p)}]$ jsou parametry a $\boldsymbol{\epsilon}_t$ chybová složka, $\boldsymbol{\epsilon}_t \sim \mathcal{WN}(\mathbf{0}, \boldsymbol{\Sigma}_{\boldsymbol{\epsilon}})$

- ▶ p se nazývá řád modelu
- ▶ pozorování \mathbf{z}_t je modelováno pomocí p předchozích pozorování $\mathbf{z}_{t-1}, \dots, \mathbf{z}_{t-p}$.

- ▶ $\mathbf{z}_t = \text{ilr}_{\mathbf{V}}(\mathbf{x}_t)$ jsou ilr souřadnice kompozice $\mathbf{x}_t \in \mathcal{S}^D$ dané maticí \mathbf{V} a $\mathbf{z}_t^* = \text{ilr}_{\mathbf{V}^*}(\mathbf{x}_t)$ ilr souřadnice dané maticí \mathbf{V}^*
- ▶ VAR(p) modely jsou kompozičně ekvivalentní při použití libovolné ilr transformace

$$\mathbf{z}_t = \mathbf{c}_{\mathbf{V}} + \mathbf{A}_{\mathbf{V}}^{(1)} \mathbf{z}_{t-1} + \mathbf{A}_{\mathbf{V}}^{(2)} \mathbf{z}_{t-2} + \dots + \mathbf{A}_{\mathbf{V}}^{(p)} \mathbf{z}_{t-p},$$
$$\mathbf{z}_t^* = \mathbf{c}_{\mathbf{V}^*} + \mathbf{A}_{\mathbf{V}^*}^{(1)} \mathbf{z}_{t-1}^* + \mathbf{A}_{\mathbf{V}^*}^{(2)} \mathbf{z}_{t-2}^* + \dots + \mathbf{A}_{\mathbf{V}^*}^{(p)} \mathbf{z}_{t-p}^*.$$

Vektorový autoregresní proces VAR(p)

Endomorfismus na simplexu \mathcal{S}^D

$$\mathbf{A} \square \mathbf{x} = \mathcal{C} \left(\prod_{j=1}^D x_j^{a_{1j}}, \dots, \prod_{j=1}^D x_j^{a_{Dj}} \right)^\top \quad \mathbf{A} \in \mathbb{R}_{D \times D}, \mathbf{x} \in \mathcal{S}^D$$

- ▶ představuje **lineární transformaci** vzhledem k Aitchisonově geometrii
 - ▶ za podmínky $\mathbf{A}\mathbf{1}_D = \mathbf{0}_D$ (jinak $\mathbf{A} \square \mathbf{x} \neq \mathbf{A} \square (k\mathbf{x})$)
- ▶ pokud navíc platí $\mathbf{A}^\top \mathbf{1}_D = \mathbf{0}_D$, pak funkce $\mathbf{x} \rightarrow \mathbf{A} \square \mathbf{x}$ se nazývá **endomorfismus** na simplexu \mathcal{S}^D
- ▶ máme-li endomorfismus $\mathbf{y} = \mathbf{A} \square \mathbf{x}$ na simplexu, pak ho můžeme též vyjádřit i v prostoru souřadnic
 - ▶ $\text{clr}(\mathbf{y}) = \mathbf{A} \cdot \text{clr}(\mathbf{x})$
 - ▶ $\text{ilr}_{\mathbf{V}}(\mathbf{y}) = \mathbf{A}_{\mathbf{V}} \cdot \text{ilr}_{\mathbf{V}}(\mathbf{x}) \Leftrightarrow \text{ilr}(\mathbf{y}) = \mathbf{V}^\top \mathbf{A} \mathbf{V} \cdot \text{ilr}(\mathbf{x})$

Vektorový autoregresní proces VAR(p)

VAR(p) na simplexu S^D

- ▶ výsledný VAR model na simplexu **nezávisí** na volbě konkrétní transformace

$$\mathbf{x}_t = \mathbf{b} \oplus \left(\mathbf{A}^{(1)} \square \mathbf{x}_{t-1} \right) \oplus \cdots \oplus \left(\mathbf{A}^{(p)} \square \mathbf{x}_{t-p} \right) \oplus \mathbf{w}_t$$

- ▶ modelování kompozičních časových řad přímo na simplexu
 \implies Barcelo-Vidal et al.(2011)

Vektorový autoregresní proces VAR(p)

Odhad parametrů

- ▶ stacionární VAR(p) model lze rovněž zapsat v maticovém tvaru

$$\mathbf{Y} = \mathbf{Z}\mathbf{B} + \mathbf{E}$$

kde $\mathbf{Y} = (\mathbf{z}_1, \dots, \mathbf{z}_n)'$, $\mathbf{Z}_t = (1, \mathbf{z}'_{t-1}, \dots, \mathbf{z}'_{t-p})'$ je t -tý řádek matice $\mathbf{Z} \in \mathbb{R}^{n \times [(D-1)p+1]}$

- ▶ parametry \mathbf{B} lze odhadnout pomocí MNČ pro každou rovnici zvlášť na základě
 - ▶ "sample" $\rightarrow \mathbf{z}_1, \dots, \mathbf{z}_n$
 - ▶ "presample" $\rightarrow \mathbf{z}_{-p+1}, \dots, \mathbf{z}_0$

Vektorový autoregresní proces VAR(p)

Testování hypotéz: Grangerova kauzalita

- ▶ testování kauzality založené na predikci
- ▶ x_1 „Granger causes“ x_2
 \implies minulé (zpozděné) hodnoty x_1 obsahují statisticky významnou informaci o budoucích hodnotách x_2
- ▶ test hypotézy $H_0 : \mathbf{R}\hat{\beta} = \mathbf{r}$
- ▶ **Waldova statistika**

$$(\mathbf{R}\hat{\beta} - \mathbf{r})' \left\{ \mathbf{R} [\widehat{avar}(\hat{\beta})] \mathbf{R}' \right\}^{-1} (\mathbf{R}\hat{\beta} - \mathbf{r}) \sim F(q, n - (D-1)p - 1)$$

q ... hodnota matice \mathbf{R}

Teorie \mathcal{T} -prostorů

- ▶ **kompoziční data** = data nesoucí výhradně **relativní** informaci → v podílech mezi složkami
- ▶ **kompoziční časové řady** → zajímá nás též **absolutní** informace o celkovém množství v čase t (např. při predikci budoucích hodnot)
- ▶ teorie \mathcal{T} -prostorů definuje rozšířený vektorový prostor $\mathcal{T} = \mathbb{R}_+^D \times \mathcal{S}^D \implies$ umožňuje modelovat podíly mezi jednotlivými složkami s úhrnnými hodnotami těchto složek současně v jednom modelu

Teorie \mathcal{T} -prostorů

Aplikace teorie \mathcal{T} -prostorů na časové řady

- ▶ vektor $\tilde{\mathbf{x}} = [t(\mathbf{x}), \mathcal{C}(\mathbf{x})] = [t_x, \tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_D]$ je prvkem prostoru $\mathcal{T} = \mathbb{R}_+^D \times \mathcal{S}^D$
 - ▶ $\mathcal{C}(\mathbf{x})$ kompozice, $\mathbf{x} \in \mathcal{S}^D$
 - ▶ $t(\mathbf{x})$ celkový součet hodnot složek kompozice v daném okamžiku t

$$t(\mathbf{x}) = \sum_{i=1}^D x_i$$

- ▶ kompozice \mathbf{x} jsou modelovány pomocí logratio transformací
- ▶ úhrnné hodnoty $t(\mathbf{x})$ jsou uvažovány v jejich zlogaritmované podobě

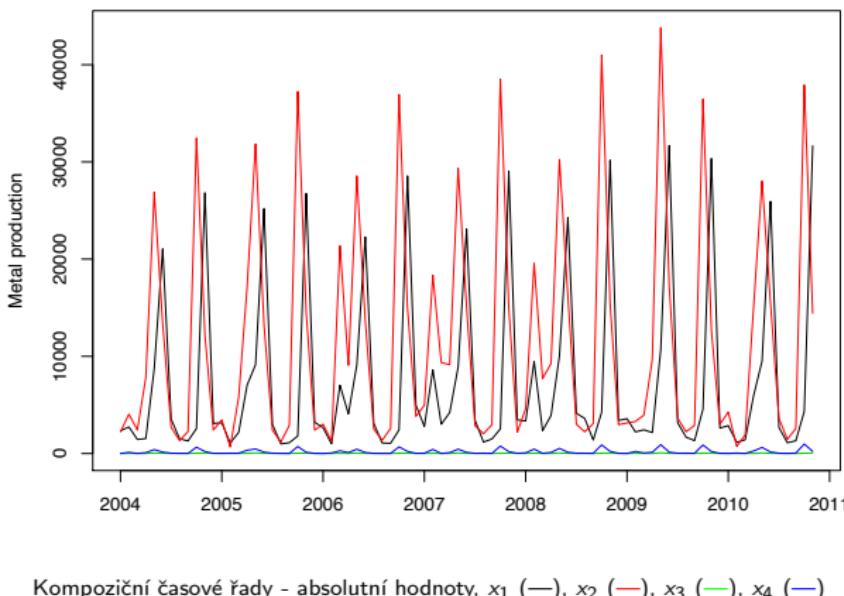
Praktický příklad

Hrubé bonusy k příjmům zaměstnanců

- ▶ hrubé bonusy k příjmům zaměstnanců v odvětví zpracovávání kovů v Rakousku (v tisících eurech) \Rightarrow leden 2004 - listopad 2011
 - ▶ $x_1 \dots$ tzv. „bílé límečky“
 - ▶ $x_2 \dots$ dělníci
 - ▶ $x_3 \dots$ učni v komerční sféře
 - ▶ $x_4 \dots$ učni v industriální sféře
 - ▶ $X_t \dots$ celkový úhrn hodnot v čase $t \rightarrow x_1 + x_2 + x_3 + x_4$

	x1	x2	x3	x4	Xt
1	1494.70	610.50	2.00	19.40	2126.60
2	723.40	785.20	3.70	14.50	1526.80
3	2168.10	1171.90	3.00	9.90	3352.90
4	2293.70	3173.30	4.80	60.60	5532.40
5	12497.20	12782.20	21.10	97.80	25398.30
6	13851.50	23369.40	176.00	380.30	37777.20

Praktický příklad



Praktický příklad

Volba modelu

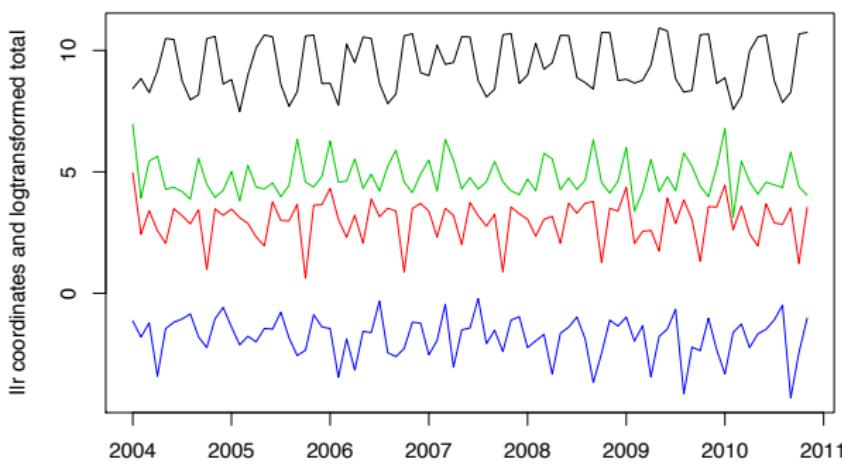
Dva přístupy:

- ▶ aplikace VAR modelu standardním způsobem na proměnné x_1, x_2, x_3, x_4
- ▶ s využitím teorie \mathcal{T} -prostorů byly proměnné transformovány pomocí ilr transformace a zlogaritmovaný celkový úhrn hodnot $\log(X_t)$ byl zahrnut do modelu jako další proměnná

Přístup	AIC(p)	HQ(p)	SC(p)	FPE(p)
standardní	10	1	1	2
kompoziční	10	1	1	1

⇒ **VAR(1) model**

Praktický příklad



Ilr souřadnice pro kompoziční časové řady (z_1 (—), z_2 (—), z_3 (—))

a celkový úhrn hodnot složek X_t po zlogaritmování.

Praktický příklad

Testování Grangerovy kauzality

- ▶ na rozdíl od standardního přístupu nám použití ilr transformace a teorie \mathcal{T} -prostorů umožňuje testovat kauzalitu nejen mezi proměnnými, ale i mezi úhrnnými hodnotami složek
- ▶ vzhledem k výhodným interpretačním vlastnostem dané ilr transformace lze otestovat nulovou hypotézu

„ z_1 nemá signifikantní vliv na $z_2, z_3, \log(X_t)$ “

- ▶ testování Grangerovy kauzality kompozičním přístupem je **nesrovnatelné** s aplikací VAR modelu klasickým způsobem
 - ▶ samotné testování probíhá **v prostoru ortonormálních souřadnic**
 - ▶ celkové úhrnné hodnoty jsou zahrnuty do modelu jako **další proměnná**

Praktický příklad

Testování Grangerovy kauzality

nulová hypotéza	p-hodnota
z_1 nemá vliv na $z_2, z_3, \log(X_t)$	
$z_1 =$ rel. informace o x_1 vzhledem k x_2, x_3, x_4	0.526
$z_1 =$ rel. informace o x_2 vzhledem k x_1, x_3, x_4	0.852
$z_1 =$ rel. informace o x_3 vzhledem k x_1, x_2, x_4	0.659
$z_1 =$ rel. informace o x_4 vzhledem k x_1, x_2, x_3	0.043
$\log(X_t)$ nemá vliv na z_1, z_2, z_3	0.279

⇒ relativní informace obsažená v x_4 má dle testu významný vliv na předpověď budoucích hodnot složek x_1, x_2, x_3 i celkových úhrnných hodnot X_t

Závěr

- ▶ určení předpovědí **nezávisí** na typu zvolené logratio transformace
- ▶ výběr ilr transformace usnadňuje možnost **interpretace** (např. testování hypotéz)
- ▶ teorie \mathcal{T} -prostorů umožňuje modelovat nejen proporcionální strukturu dat, ale i celkové absolutní hodnoty **v jednom modelu**
- ▶ použití \mathcal{T} -prostorů poskytuje **nové možnosti testování** Grangerovy kauzality (testování kauzálních vztahů i mezi kompozicemi a úhrnnými hodnotami)
- ▶ kompoziční přístup ukázal vyšší přesnost předpovědí na základě RMSEP

Reference

-  Barceló-Vidal, C., Aguilar, L., Martín-Fernández, J. A. (2011)
Compositional VARIMA time series. In V. Pawlowsky-Glahn and
A. Buccianti, eds.,
Compositional Data Analysis. Theory and Applications.
John Wiley & Sons, Chichester, pp. 87–103.
-  Fišerová, E., Hron, K. (2012).
On interpretation of orthonormal coordinates for compositional data.
Mathematical Geosciences 43(4), 455–468.
-  Pawlowsky-Glahn, V., Egozcue, J.J., Lovell, D. (2013).
The product space \mathcal{T} (tools for compositional data with a total). In
K. Hron, P. Filzmoser and M. Templ, editors,
*Proceedings of CoDaWork'13, The 5th Compositional Data Analysis
Workshop.* Vorau, Austria.

Reference

-  Aitchison, J. (1986).
The Statistical Analysis of Compositional Data.
Chapman and Hall Ltd., London, UK.
-  Lütkepohl, L. (2005).
New Introduction to Multiple Time Series Analysis.
Springer, Berlin.
-  Pawlowsky-Glahn, V., Buccianti, A., eds. (2011).
Compositional Data Analysis: Theory and Applications.
Wiley, Chichester.

$$\hat{\beta} = \text{vec}(\hat{\mathbf{B}}) = \begin{pmatrix} \hat{\boldsymbol{\epsilon}}^\top \\ (\hat{\mathbf{A}}^{(1)})^\top \\ \vdots \\ (\hat{\mathbf{A}}^{(p)})^\top \end{pmatrix} \quad \widehat{avar}(\hat{\beta}) = \hat{\Sigma}_\epsilon \otimes (\mathbf{Z}\mathbf{Z}^\top)^{-1}$$

$$\hat{\Sigma}_\epsilon = \frac{1}{n - (D - 1)p - 1} \sum_{t=1}^n (\mathbf{z}_t - \mathbf{Z}\hat{\mathbf{B}})(\mathbf{z}_t - \mathbf{Z}\hat{\mathbf{B}})^\top.$$

Testování Grangerovy kauzality ve standardním VAR modelu

nulová hypotéza	p-hodnota
x_1 nemá vliv na x_2, x_3, x_4	0.749
x_2 nemá vliv na x_1, x_3, x_4	0.190
x_3 nemá vliv na x_1, x_2, x_4	0.085
x_4 nemá vliv na x_1, x_2, x_3	$6.158 \cdot 10^{-6}$

⇒ i standardně docházíme k výsledku, že x_4 má signifikantní vliv na x_1, x_2, x_3 , a tedy minulé hodnoty x_4 mají významný efekt na odhad budoucích hodnot ostatních proměnných

Přesnost předpovědí pro použité modely

Root mean squared error of prediction (RMSEP)

$$\text{RMSEP} = \sqrt{\frac{1}{m} \sum_{i=1}^m \|\mathbf{x}_t - \hat{\mathbf{x}}_t\|^2},$$

kde m je počet predikovaných hodnot.

přístup	RMSEP
standardní	170.94
kompoziční	167.02