

# Analýza prostorově závislých funkcionálních dat


V. Římalová, A. Menafoglio, A. Pini, E. Fišerová

Robust 2018

25. ledna 2018

# Motivace – Data a náhled lokace

- Měsíční měření (březen-říjen 2015 a 2016) 5 chemických ukazatelů
- 5 lokací (transektů) v okolí obce Křtiny na Brněnsku
- V transektu se nachází 11 odběrných míst umístěných v přímce za sebou, vzdálenost sousedících OM je 3 metry.
- Uprostřed ležící odběrné místo, ekoton, rozděluje lokaci na polní a lesní část.




- Ověřit, zda se naměřené hodnoty chemických ukazatelů liší v závislosti na typu půdy a vzdálenosti od ekotonu.
- V příspěvku prezentujeme výsledky pro pH chlornanu draselného naměřeného v transektu 1 v hloubce 5 cm.

- Nechť  $(\Omega, \mathcal{F}, \mathbb{P})$  je pravděpodobnostní prostor a  $\mathcal{H}$  je Hilbertův prostor, na němž je definovaný skalární součin  $\langle ., . \rangle$  indukující normu  $\|.\|$ .
- Funkcionální náhodnou proměnnou nazveme měřitelnou funkci  $\mathcal{X} : \Omega \rightarrow H$
- Množina  $\{\mathcal{X}_s, s \in D \subset \mathbb{R}^d\}$  je funkcionální náhodné pole.
- Funkcionální dataset  $\mathcal{X}_{s_1}, \dots, \mathcal{X}_{s_n}$  je množinou  $n$  pozorování náhodného pole vzhledem k lokacím  $s_1, \dots, s_n \in D$

# Funkcionální geostatistika

- Nechť  $(\Omega, \mathcal{F}, \mathbb{P})$  je pravděpodobnostní prostor a  $\mathcal{H}$  je Hilbertův prostor, na němž je definovaný skalární součin  $\langle ., . \rangle$  indukující normu  $\|.\|$ .
- Funkcionální náhodnou proměnnou nazveme měřitelnou funkci  $\mathcal{X} : \Omega \rightarrow H$
- Množina  $\{\mathcal{X}_s, s \in D \subset \mathbb{R}^d\}$  je funkcionální náhodné pole.
- Funkcionální dataset  $\mathcal{X}_{s_1}, \dots, \mathcal{X}_{s_n}$  je množinou  $n$  pozorování náhodného pole vzhledem k lokacím  $s_1, \dots, s_n \in D$



- Množina  $\{\mathcal{X}_s, s \in D \subset \mathbb{R}^d\}$  je nestacionární náhodné pole, jehož prvky lze vyjádřit jako  $\mathcal{X}_s = m_s + \delta_s$ .
- Drift lze modelovat jako  $m_s(t) = \sum_{l=0}^L \beta_l(t) f_l(s), s \in D, t \in T$ ,  $\beta_l(t)$  jsou funkcionální regresní parametry a  $f_l(s)$  regresory.
- Nechť  $\delta_{s_1}, \dots, \delta_{s_n}$  jsou realizace reziduálního procesu  $\{\delta_s, s \in D\}$ , který má nulový průměr, stacionaritu druhého řádu a je isotropní [Menaoglio, Secchi 2016]. Empirický semivariogram tohoto reziduálního procesu má tvar

$$\hat{\gamma}(h) = \frac{1}{2|N(h)|} \sum_{(i,j) \in N(h)} \|\delta_{s_i} - \delta_{s_j}\|^2,$$

kde  $N(h) = \{(i,j) : \|s_i - s_j\| = h\}$  a  $|N(h)|$  je mohutnost této množiny.

- Empirický variogram je definován jako  $2\hat{\gamma}(h)$

# Funkcionální permutační testy pro dvě populace

Nechť  $\mathcal{X}_{s_i}^{(1)}$  a  $\mathcal{X}_{s_i}^{(2)}$  jsou dva náhodné výběry funkcí,  
 $i = 1, \dots, n_g, g = 1, 2$  je populační index. Testujeme hypotézu

$$H_0 : \mathcal{X}_s^{(1)} \sim \mathcal{X}_s^{(2)}$$

proti alternativě  $H_1 : \mathcal{X}_s^{(1)} \not\sim \mathcal{X}_s^{(2)}$ .

- Testujeme pomocí intervalových permutačních testů pro funkcionální data.
- Výhody: Umožní identifikovat, v které části definičního oboru dochází k porušení  $H_0$ .
- Neklade žádné předpoklady na rozdělení funkcionálních dat.

# Permutační testy – testování významnosti regresních parametrů

- Uvažujme lineární model

$$\mathcal{X}_s = \beta_0(t) + \sum_{l=1}^L \beta_l(t) f_l(s) + \delta_s, t \in \langle a, b \rangle, s \in D$$

- Chceme testovat hypotézu

$$H_0 : \beta_1(t) = \dots = \beta_L(t) = 0, \forall t \in \langle a, b \rangle$$

proti alternativě  $H_1 : \beta_l(t) \neq 0$  pro nějaké  $l \in 1, \dots, L$ .

- Předpoklad: zaměnitelnost pozorování  $\mathcal{X}_s$  [Pini & Vantini, 2017].

# Model pro data se stejným rozptylem

Za předpokladu  $\mathcal{X}_s^{(1)} \sim \mathcal{X}_s^{(2)}$ , uvažujme model

$$\mathcal{X}_s(t) = \beta_0(t) + \beta_1(t)d + \delta_s(t).$$

Prostorové vztahy jsou dány indikátorovou funkcí

$$d = \begin{cases} 0 & \text{pro } s \in \{-15, -12, -9, -6, -3\}, \\ 1 & \text{pro } s \in \{3, 6, 9, 12, 15\}. \end{cases}$$

# Ověření shody rozptylů pomocí permutačních testů

$H_0 : \mathcal{X}^{(1)} \sim \mathcal{X}^{(2)}$  testujeme na reziduích  $\delta_s^{(g)}, g = 1, 2$ , z modelu

$$\mathcal{X}_s(t) = \beta_0(t) + \beta_1(t)d + \delta_s(t)$$

pomocí statistiky

$$T^{\mathcal{I}} = \frac{1}{|\mathcal{I}|} \int_{|\mathcal{I}|} [\text{vár}[\delta^{(1)}(t)] - \text{vár}[\delta^{(2)}(t)]]^2 dt,$$

kde  $\mathcal{I}$  je libovolný podinterval  $\langle a, b \rangle$ ,  $t \in \langle a, b \rangle$  a  
 $\text{vár}[\delta^{(g)}(t)], g = 1, 2$ , značí rozptyl reziduí z 1. nebo 2. populace.

# Ověření shody rozptylů pomocí permutačních testů


$H_0 : \mathcal{X}^{(1)} \sim \mathcal{X}^{(2)}$  testujeme na reziduích  $\delta_s^{(g)}, g = 1, 2$ , z modelu

$$\mathcal{X}_s(t) = \beta_0(t) + \beta_1(t)d + \delta_s(t)$$

pomocí statistiky

$$T^{\mathcal{I}} = \frac{1}{|\mathcal{I}|} \int_{|\mathcal{I}|} [\text{vár}[\delta^{(1)}(t)] - \text{vár}[\delta^{(2)}(t)]]^2 dt,$$

kde  $\mathcal{I}$  je libovolný podinterval  $\langle a, b \rangle$ ,  $t \in \langle a, b \rangle$  a  
 $\text{vár}[\delta^{(g)}(t)], g = 1, 2$ , značí rozptyl reziduů z 1. nebo 2. populace.



# Model pro data s různým rozptylem

Není-li splněn předpoklad  $\mathcal{X}_s^{(1)} \sim \mathcal{X}_s^{(2)}$  a funkcionální pozorování mají různý rozptyl v závislosti na typu půdy, lze použít model

$$\mathcal{X}_s^{(g)}(t) = \beta_0(t) + \beta_1(t)d + \delta_s^{(g)}(t), g = 1, 2.$$

$$\delta_s^{(g)}(t) = \sigma^{(g)}\delta_s(t)$$

Prostorové vztahy modelujeme indikátorovou funkcí

$$d = \begin{cases} 0 & \text{pro } s \in \{-15, -12, -9, -6, -3\}, \\ 1 & \text{pro } s \in \{3, 6, 9, 12, 15\} \end{cases}$$

Rozptyly  $\sigma^{(g)}$  odhadneme z parciálních modelů

$$\mathcal{X}_s^{(g)}(t) = \beta_0^{(g)}(t) + \delta_s^{(g)}(t), g = 1, 2.$$

# Testování významnosti regresních parametrů

V modelu  $\mathcal{X}_s^{(g)}(t) = \beta_0(t) + \beta_1(t)d + \delta_s^{(g)}(t)$ ,  $g = 1, 2$ , testujeme hypotézu  $H_0 : \beta_1(t) = 0 \forall t \in \langle a, b \rangle$  proti alternativě  $H_1 : \beta_1 \neq 0$  pomocí testové statistiky

$$T_0 = \int \left[ [C\hat{\beta}(t)]' (CZ'WZC')^{-1} [C\hat{\beta}(t)] \right] dt,$$

kde  $W$  je matice vah,  $Z$  designová matice a vektor  $C = (0, 1)$ .

Permutační schéma:

- ① Redukovaný model  $\hat{\mathcal{X}}_s^{(g)}(t) = \hat{\beta}_0(t)$
- ② Vydělit  $\hat{\delta}_s^{(g)}(t)$  příslušným rozptylem a získaná  $\hat{\delta}_s(t)$  permutovat  $\rightarrow \mathcal{X}_s^*(t) = \hat{\beta}_0(t) + \hat{\sigma}^{(g)}\hat{\delta}_s^*(t)$ .
- ③ Z  $\mathcal{X}_s^*(t)$  odhadnout parametry původního modelu a vypočítat testovou statistiku.
- ④  $p$ -hodnota permutačního testu je vypočtena jako poměr permutací vedoucích k vyšší hodnotě testové statistiky, než byla ta z původních dat, k celkovému počtu permutací.

- Návrh modelů pro nekorelovaná funkcionální data se stejnými a různými rozptyly.
- Test pro 2 populace na reziduích prostorového lineárního modelu s funkcionální závisle proměnnou.
- Testování významnosti parametrů funkcionální regrese s využitím permutačních testů.

A co dál?

- Intervalový test významnosti regresních parametrů.
- Model pro v prostoru korelovaná data.

- J.O. Ramsay, B.W. Silverman (2005): Functional Data Analysis. Springer, New York.
- A. Menaoglio, P. Secchi (2016): Statistical analysis of complex and spatially dependent data: a review of Object Oriented Spatial Statistics, European Journal of Operational Research, 258(2), pages 401–410.
- A. Pini & S. Vantini (2017): Interval-wise testing for functional data, Journal of Nonparametric Statistics, DOI: 10.1080/10485252.2017.1306627
- Abramowicz, K.; Häger, C.; Pini, A.; Schelin, L.; Sjöstedt de Luna, S.; Vantini, S.: Nonparametric inference for functional-on-scalar linear models applied to knee kinematic hop data after injury of the anterior cruciate ligament, MOX technical report 30/2016, Politecnico di Milano