




Hĺbka funkcionálnych dát

STANISLAV NAGY

s.nagy@volny.cz
KPMS UK, Praha



ABSTRAKT

Dôležitým neparametrickým nástrojom štatistickej analýzy mnohorozmerných dát je štatistická hĺbka. Na funkcionálne a špeciálne nekonečnorozmerné funkcionálne dáta sa však doposiaľ koncept hĺbky nepodarilo úspešne zovšeobecniť. V prípade konečnorozmerných funkcionálnych dát sa ponúka možnosť využiť izomorfizmus takéhoto priestoru s euklidovským priestorom. Iným prístupom k problematike hĺbky nekonečnorozmerných dát je koncept pásových hĺbok. V príspevku ilustrujeme rôzne prístupy na jednoduchých príkladoch.

ŠTATISTICKÁ HĽBKOVÁ FUNKCIA

Nech \mathcal{F} je trieda pravdepodobnostných rozdelení na priestore \mathbb{R}^d . **Štatistická hĺbková funkcia** na \mathbb{R}^d ako je definovaná v [1] je obmedzené a nezáporné zobrazenie $D(\cdot; \cdot) : \mathbb{R}^d \times \mathcal{F} \rightarrow \mathbb{R}$, splňujúce podmienky:


1. invariancia voči afinity transformácii rozdelenia
2. maximalita v strede symetrie pre symetrické rozdelenia
3. relatívna monotónia vzhľadom k najhlbšiemu bodu
4. nulovosť limity v každom smere

Nech I je kompaktný interval. V prípade, že priestor uvažovaných funkcií $\mathcal{L} \subset C(I)$ je d -rozmerný s L^2 -ortonormálnou bázou $\{\varphi_i(t)\}_{i=1}^d$, platí, že pre každú funkciu $f(t) = \sum_{i=1}^d c_i \varphi_i(t) \in \mathcal{L}$ je funkcionál



$$D_{\mathcal{L}}(f) := D\left((c_1, \dots, c_d)^T\right)$$

štatistickou hĺbkovou funkciou na priestore \mathcal{L} .

Ilustrujeme na reálnych dátach ročného priebehu teploty v Kanade a na simulovaných dátach taktúto indukovanú Tukeyho hĺbku. Funkcie náhodného výberu sú s rastúcou hĺbkou vykresľované tmavšou farbou.



Mediánová, teda najhlbšia funkcia, by však mala nielen ležať „uprostred“ funkcií náhodného výberu, mala by mať aj podobný tvar ako ostatné funkcie. Za predpokladu hladkosti funkcií by teda zovšeobením mohla byť **K-pásová hĺbka**, ktorú pre pevné $K \in \mathbb{N}$ definujeme ako vážený geometrický priemer generalizovaných pásových hĺbok funkcie $\frac{\partial^k f}{\partial x^k}$ voči deriváciám náhodnému výberu $\left\{\frac{\partial^k f_i}{\partial x^k}\right\}_{i=1}^n$ pre $0 \leq k \leq K$. Ukážka aplikácie takejto hĺbky na dáta je na poslednom obrázku.



PÁSOVÁ HĽBKA

Iným prístupom k určovaniu hĺbky funkcionálnych dát je použitie rôznych verzií **pásovej hĺbky** definovanej v [2] alebo [3]. Táto je založená na princípe vyhodnocovania toho, nakoľko graf funkcie $f \in C(I)$, ktorej hĺbku zisťujeme, leží v **páse** tvorenom grafmi $2 \leq j \leq J$ náhodných funkcií z náhodného výberu z rozdelenia \mathcal{F} o rozsahu $n > J$, kde J je predom volená konštanta, často $J = 3$. Pás tvorený grafmi funkcií $\{f_1, \dots, f_j\} \subset C(I)$ je pritom definovaný ako

$$\left\{ (x, y) \in \mathbb{R}^2 : (x \in I) \& \left(\min_{i=1, \dots, j} f_i(x) \leq y \leq \max_{i=1, \dots, j} f_i(x) \right) \right\}.$$

Voľbou indikátoru za mieru náležania dostávame štandardnú pásovú hĺbku, ktorej aplikácia na dáta je ilustrovaná na nasledujúcom obrázku, voľbou miery náležania ako Lebesgueovej miery takých bodov nezávisle premennej, že graf f leží v páse dostávame **generalizovanú pásovú hĺbku**. Vlastnosti takýchto pásových hĺbok sú študované v [3].

ZÁVER

Koncept indukovaných hĺbok konečnorozmerných funkcií zrejme nie je dobrým riešením, z dôvodu prílišnej redukcie informácie obsiahnutej vo funkciách. Naopak pásová hĺbka dobre odlišuje **pozorovania odľahlé v polohe**, vhodná K-pásová aj **pozorovania odľahlé v tvare**. Vlastnosti takto definovaných funkcionálov však ešte neboli systematicky skúmané.

Literatúra.

- [1] Zuo Y. a Serfling R. (2000). *General notions of statistical depth function*. Ann. Stat. **28**, 461–482.
- [2] López-Pintado S. a Romo J. (2004). *Depth-based inference for functional data*. Computational Statistics and Data Analysis **51**, 4957–4968.
- [3] López-Pintado S. a Romo J. (2009). *On the concept of depth for functional data*. Journal of the American Statistical Association **104**, 718–734.