




KONZISTENCIA HĽBKY FUNKCIÍ

STANISLAV NAGY

nagy@karlin.mff.cuni.cz

Univerzita Karlova v Praze, Matematicko-fyzikální fakulta
Katedra pravděpodobnosti a matematické statistiky



ABSTRAKT


V príspevku sa zameriavame na funkcionálne dát a niekoľko rôznych prístupov k určovaniu hlbky funkcií používaných v literatúre. Ukazujeme, že silný výsledok autorov López-Pintado a Romo [4, Thm 4] o rovnomernej konzistencii výberovej pásovej hlbky neplatí (ani za silnejších predpokladov). Navrhujeme dva rôzne prístupy k úprave pásovej hlbky tak, aby rovnomernú konzistenciu už bolo možné zaručiť. Pre integrálne hlbky tým rozširujeme výsledky Fraimana a Munizovej [1, Thm 3.1].

HĽBKA FUNKCIÍ

Štatistická hlbková funkcia (hlbka) je zobrazenie

$$D : S \times \mathcal{P}(S) \rightarrow \mathbb{R}^+ \quad (\rightarrow [0, 1]),$$

kde $\mathcal{P}(S)$ označuje triedu pravdepodobnostných rozdelení na priestore S . Hlbka indukuje na S usporiadanie v smere z „od centra k okrajom“, t.j. typické po- čo platí, pretože $BD^J(\cdot; P_n)$ je obmedzená U-štatistika. □ zorovania v okolí „centra“ rozdelenia $P \in \mathcal{P}(S)$ majú vysoké hodnoty hlbky, Problémy dôkazu sú ale dva: $BD^J(\cdot; P_n)$ je iba polospojitá (P_n nemá abs. zatial čo odľahlé a „netypické“ pozorovania voči P majú hlbku blízku 0. Jedná spojité marg. rozdelenia). Navyše by nastačila ani spojitost $BD^J(\cdot; P_n)$, sa o moderný nástroj neparametrickej analýzy dát, ktorý sa dá považovať za ak by platila. Aby dôkaz fungoval, nutná by bola rovnaká spojitosť všetkých zovšeobecnenie kvantilov pre mnohorozmerné dát. Výčet používaných hlbok a ich vlastností pre $S = \mathbb{R}^d$ nájdeme napr. v článku Zua a Serflinga [5].



Obr. 1: Pás troch funkcií vľavo, pásová hlbka náhodného výberu vpravo ($J = 3$).

V prípade funkcionálnych dát ($S = \mathcal{C}([0, 1])$) existujú dva základné prístupy k určovaniu hlbky. Nech $x \in \mathcal{C}([0, 1])$ a $P \in \mathcal{P}(\mathcal{C}([0, 1]))$.

- **Pásové hlbky** (López-Pintado a Romo [4]) pre $J = 2, 3, \dots$

$$BD^J(x; P) = \frac{1}{J-1} \sum_{j=2}^J P(G(x) \subset B(X_1, \dots, X_j)), \quad (1)$$

kde $G(x)$ je graf funkcie x a $B(X_1, \dots, X_j)$ je pás, teda oblasť medzi minimom a maximom náhodných funkcií X_1, \dots, X_j (pozri obr. 1).

- **Integrálne hlbky** (Fraiman a Muniz [1], Hlubinka a Nagy [2]) pre hlbku D na \mathbb{R}

$$ID(x; P) = \int_0^1 D(x(t); P(t)) dt,$$

kde $P(t)$ je marginálne rozdelenie P v t .

KONZISTENCIA HĽBKY

Každá rozumná hlbka D musí byť konzistentná. Označme $P_n \in \mathcal{P}(S)$ rozdele- nie náhodného výberu z P o rozsahu n . Potom D je konzistentná na S

- **bodove** ak $D(x; P_n) - D(x; P) \xrightarrow[n \rightarrow \infty]{s.i.} 0$ pre každé $x \in S$,
- **rovnomerne** ak $\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0$,
- **univerzálnie** ak $\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0$ pre každé $P \in \mathcal{P}(S)$,
- **uniformne** ak $\sup_{P \in \mathcal{P}(S)} \sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0$.

(Ne)konzistencia pásovej hlbky

Kľúčovým výsledkom práce López-Pintadovej a Roma [4, Thm 4] je

Tvrdenie: Nech $P \in \mathcal{P}(\mathcal{C}([0, 1]))$ má absolútne spojité marginálne rozdele- nia. Potom BD^J rovnomerne konzistentná na každej rovnako spojitej množine $E \subset \mathcal{C}([0, 1])$.

Dôkaz: Pretože $\lim_{\|x\| \rightarrow \infty} BD^J(x; P) = 0$, môžeme sa obmedziť sa na množinu $\{\|x\| < M\}$ pre $M > 0$. Rovnako obmedzená množina rovnako spojitých funkcií je podľa Arzéla-Ascoliho vety totálne obmedzená. Pretože

$BD^J(\cdot; P)$ je spojity funkcionál pre P s absolútne spojitými marginálnymi rozdeleniami, stačí dokázať pre $N \in \mathbb{N}$ pevné

$$\max_{\{x_i\}_{i=1}^N \subset E} |BD^J(x_i; P_n) - BD^J(x_i; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0$$

Problémy dôkazu sú ale dva: $BD^J(\cdot; P_n)$ je iba polospojitá (P_n nemá abs. zatial čo odľahlé a „netypické“ pozorovania voči P majú hlbku blízku 0. Jedná spojité marg. rozdelenia). Navyše by nastačila ani spojitost $BD^J(\cdot; P_n)$, sa o moderný nástroj neparametrickej analýzy dát, ktorý sa dá považovať za ak by platila. Aby dôkaz fungoval, nutná by bola rovnaká spojitosť všetkých

$$\{BD^J(x; P_n) - BD^J(x; P)\}_{x \in E, n \in \mathbb{N}}.$$

To, že BD^J skutočne nie je univerzálnie konzistentná, je možné ukázať na príklade postupnosti (lipschitzovských) funkcií. Definujme $X \sim P \in \mathcal{P}(\mathcal{C}([0, 1]))$ takto:

- $P(X(t) = 0 \text{ pre všetky } t \in [0, 1]) = 0.5$.
- Rozdeľme interval $[0, 1]$ „diadičky“ na disjunktné subintervaly dĺžok $\{2^{-j}\}_{j \in \mathbb{N}}$. Ak $X \not\equiv 0$, na každom subintervale bude X nulová s pravou 0.5 alebo nadobudne skok s pravou 0.5. Skoky nastávajú nezávisle od seba.
- Pre postupnosť $\{x_j\}_{j \in \mathbb{N}}$ funkcií s práve jedným skokom, inde 0 (obr. 2) platí

$$\sup_{j \in \mathbb{N}} |BD^2(x_j; P_n) - BD^2(x_j; P)| \geq 0.25 \text{ pre nekonečne veľa } n \in \mathbb{N} \text{ s.i.}$$


(Napríklad) BD^2 teda **nie je rovnomerne konzistentná** voči P .

Rozdelenie P nie je marginálne abs. spojité, je však jednoduché modifikovať ho tak, aby bolo a zároveň protipríklad fungoval.

Konzistentné funkcionály

Pretože BD^J je obmedzená U-štatistika, je **bodove konzistentná**. Ďalej, nahradením indikátoru v 1 „lipschitzovskou“ verziou je BD^J **uniformne konzistentná na kompaktných množinách**. Výsledok môžeme dokázať doplnením dôkazu López-Pintadovej a Roma o vlastnosti U-štatistik [3, Thm 2.1.4]. Univerzálna konzistencia sa dá dokázať aj priamo pomocou Blum-deHardtovho ZVČ.

Inou možnosťou je **prechod k integrálnym hlbkam**, pre ktoré je možné dokázať univerzálnu konzistenciu bez akýchkoľvek predpokladov, ak je výberová verzia hlbky U-štatistika. K -pásové hlbky [2], rovnako ako Fraimanove-Munizovej hlbky [1], sú teda **vždy univerzálnie konzistentné**. Fraiman a Munizová [1, Thm 3.1] dokázali analogickú vetu za ďalších predpokladov na rozdelenie P .



Obr. 2: Pryčich šesť funkcií x_j .

Literatúra

- [1] Ricardo Fraiman and Graciela Muniz. Trimmed means for functional data. *Test*, 10(2):419–440, 2001.
- [2] Daniel Hlubinka and Stanislav Nagy. Functional data depth and classification. *submitted to Comput. Stat.*
- [3] V. S. Koroliuk and Yu. V. Borovskich. *Theory of U-Statistics*. Kluwer, 1994.
- [4] Sara López-Pintado and Juan Romo. On the concept of depth for functional data. *Journal of the American Statistical Association*, 104(486):718–734, 2009.
- [5] Yijun Zuo and Robert Serfling. General notions of statistical depth function. *Ann. Stat.*, 28(2):461–482, 2000.