

Konzistencia hĺbky funkcií

Stanislav Nagy

Katedra pravděpodobnosti a matematické statistiky
Univerzita Karlova v Praze

Robust 2012

S podporou grantu GA ČR (grant P402/12/G097)

1 Pásová hĺbka a konzistencia

- Konzistencia
- Pásové hĺbky funkcií

2 Protipríklad

3 Konzistentné funkcionály

- Oprava 1: Zospojenie
- Oprava 2: Integrálne hĺbky

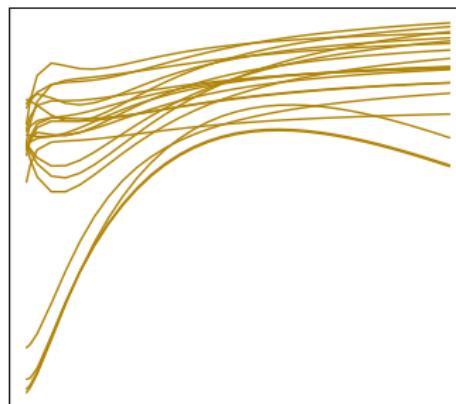
4 Záver

- Záver pre pásové hĺbky
- Vyhliadky do budúcnosti

Funkcionálne dátá

$X \sim P \in \mathcal{P}(C([0, 1]))$ a náhodný výber X_1, \dots, X_n z P . Uvažujme hĺbku funkcií náhodného výberu voči P (resp. P_n)

$$D : C([0, 1]) \times \mathcal{P}(C([0, 1])) \rightarrow [0, 1].$$



Silná konzistencia

Hĺbka D je na množine $S \subset \mathcal{C}([0, 1])$ **konzistentná**

- **bodove** ak

$$D(x; P_n) - D(x; P) \xrightarrow[n \rightarrow \infty]{s.i.} 0 \text{ pre každé } x \in S,$$

Silná konzistencia

Hĺbka D je na množine $S \subset C([0, 1])$ **konzistentná**

- **bodove** ak

$$D(x; P_n) - D(x; P) \xrightarrow[n \rightarrow \infty]{s.i.} 0 \text{ pre každé } x \in S,$$

- **rovnomerne** ak

$$\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0,$$

Silná konzistencia

Hĺbka D je na množine $S \subset \mathcal{C}([0, 1])$ **konzistentná**

- **bodove** ak

$$D(x; P_n) - D(x; P) \xrightarrow[n \rightarrow \infty]{s.i.} 0 \text{ pre každé } x \in S,$$

- **rovnomerne** ak

$$\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0,$$

- **univerzálnie** ak

$$\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0 \text{ pre každé } P \in \mathcal{P}(\mathcal{C}([0, 1])),$$

Silná konzistencia

Hĺbka D je na množine $S \subset \mathcal{C}([0, 1])$ **konzistentná**

- **bodove** ak

$$D(x; P_n) - D(x; P) \xrightarrow[n \rightarrow \infty]{s.i.} 0 \text{ pre každé } x \in S,$$

- **rovnomerne** ak

$$\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0,$$

- **univerzálnie** ak

$$\sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0 \text{ pre každé } P \in \mathcal{P}(\mathcal{C}([0, 1])),$$

- **uniformne** ak

$$\sup_{P \in \mathcal{P}(\mathcal{C}([0, 1]))} \sup_{x \in S} |D(x; P_n) - D(x; P)| \xrightarrow[n \rightarrow \infty]{s.i.} 0.$$

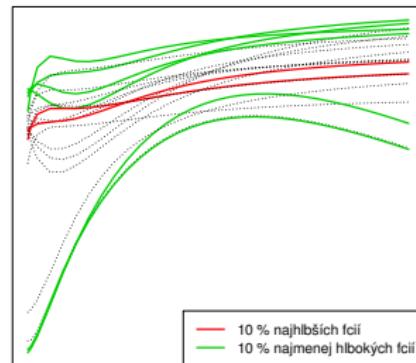
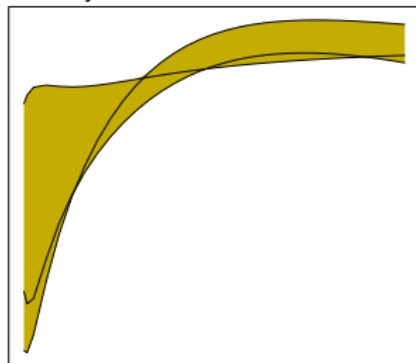
Pásová hĺbka

López-Pintado a Romo [8] pre $J = 2, 3, \dots$

$$BD^{(J)}(x; P) = \frac{1}{J-1} \sum_{j=2}^J P[G(x) \subset B(X_1, X_2, \dots, X_j)],$$

kde $G(x)$ je **graf funkcie** x a $B(x_1, x_2, \dots, x_j)$ je **pás funkcií**

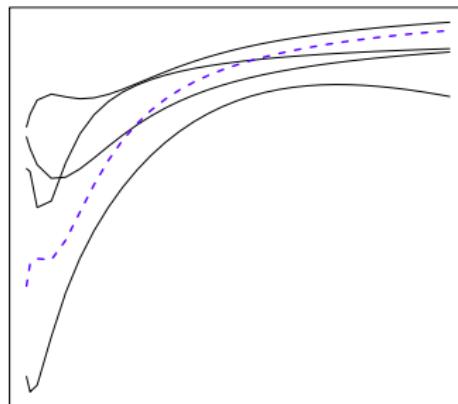
x_1, x_2, \dots, x_j



Pásová hĺbka

Výberová verzia je **U-štatistika rádu J .**

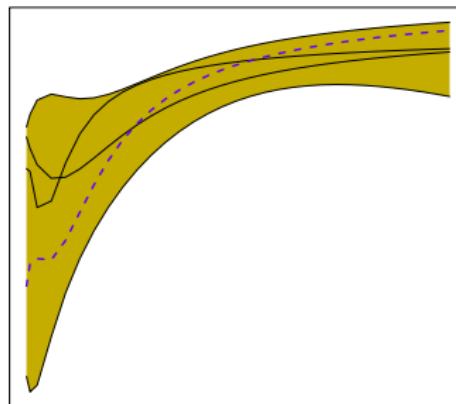
$$BD^{(J)}(x; P_n) = \frac{1}{J-1} \sum_{j=2}^J \binom{n}{j}^{-1} \sum_{1 \leq i_1 < i_2 < \dots < i_j \leq n} \mathbb{I}[G(x) \subset B(X_{i_1}, X_{i_2}, \dots, X_{i_j})].$$



Pásová hĺbka

Výberová verzia je **U-štatistika rádu J .**

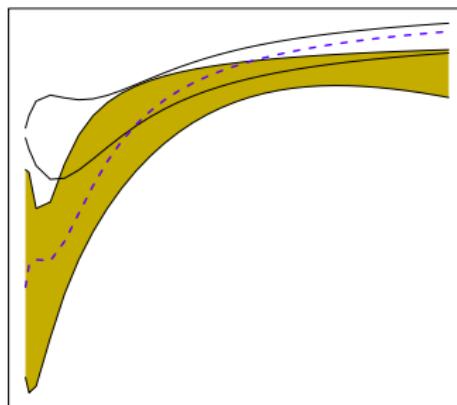
$$BD^{(J)}(x; P_n) = \frac{1}{J-1} \sum_{j=2}^J \binom{n}{j}^{-1} \sum_{1 \leq i_1 < i_2 < \dots < i_j \leq n} \mathbb{I}[G(x) \subset B(X_{i_1}, X_{i_2}, \dots, X_{i_j})].$$



Pásová hĺbka

Výberová verzia je **U-štatistika rádu J .**

$$BD^{(J)}(x; P_n) = \frac{1}{J-1} \sum_{j=2}^J \binom{n}{j}^{-1} \sum_{1 \leq i_1 < i_2 < \dots < i_j \leq n} \mathbb{I}[G(x) \subset B(X_{i_1}, X_{i_2}, \dots, X_{i_j})].$$



Pásová hĺbka

Pásová hĺbka (L-P López-Pintado, R Romo):

- L-P, R: Depth-based classification for functional data (DIMACS 2006)
- L-P, R: Depth-based inference for functional data (CSDA 2007)
- L-P, Jornsten: Functional analysis via extensions of the band depth (IMS Lecture Notes, 2007)
- **L-P, R: On the Concept of Depth for Functional Data (JASA 2009)**
- L-P, R: Robust depth-based tools for the analysis of gene expression data (Biostatistics 2010)
- L-P, R: A half-region depth for functional data (CSDA 2011)
- ...

Konzistencia pásovej hĺbky

López-Pintado a Romo [8, Thm 4]

Tvrdenie:

Nech P je rozdelenie na $C([0, 1])$ s absolútne spojitémi marginálnymi rozdeleniami. Potom BD^{J^} je rovnomerne konzistentná na každej rovnako spojitej množine S , t.j.*

$$\sup_{x \in S} \left| BD^{J^*}(x; P_n) - BD^{J^*}(x; P) \right| \xrightarrow[n \rightarrow \infty]{s.i.} 0.$$

Konzistencia pásovej hĺbky: Dôkaz

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.

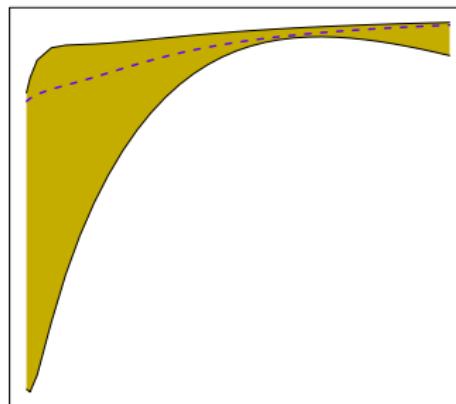
Pretože $BD^{J^*)}(\cdot; P)$ je pre P s absolútne spojitými marginálnymi rozdeleniami **spojitý funkcionál, stačí dokázať** pre $N \in \mathbb{N}$ pevné

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

čo platí, pretože $BD^{J^*)}(\cdot; P_n)$ je obmedzená U-štatistika. □

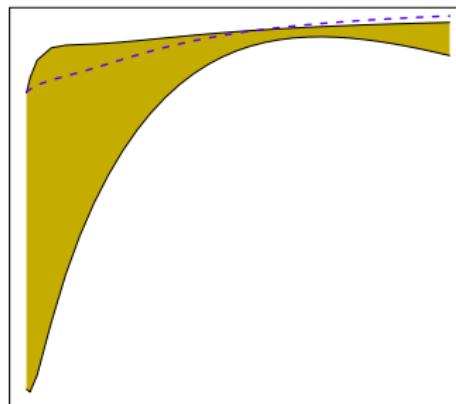
Prečo dôkaz nefunguje?

$BD^J(.; P)$ je spojitá, ale $BD^J(.; P_n)$ **nie je!**



Prečo dôkaz nefunguje?

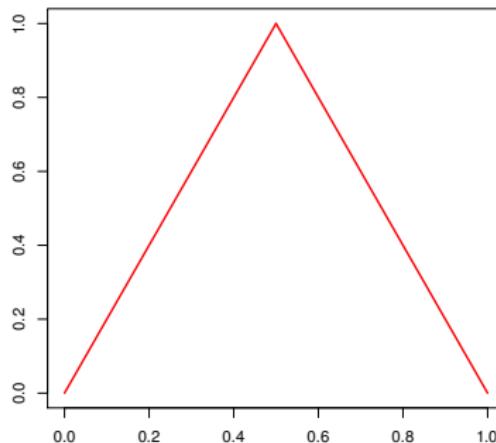
$BD^J(.; P)$ je spojitá, ale $BD^J(.; P_n)$ **nie je!**



Prečo dôkaz nefunguje?

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

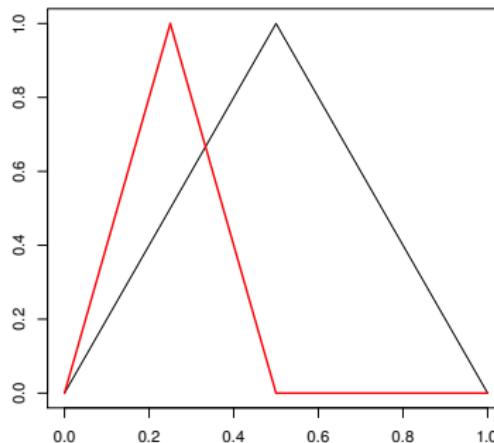
navyše nedáva rovnomernú konzistenciu!



Prečo dôkaz nefunguje?

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

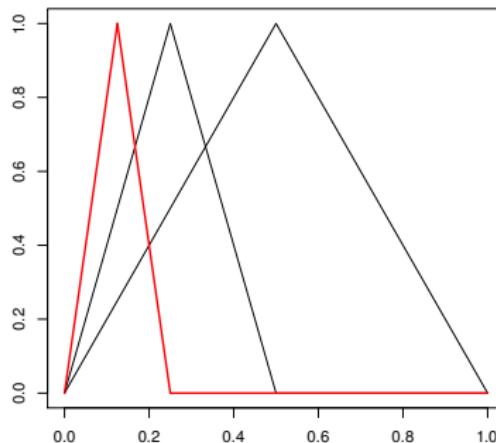
navyše nedáva rovnomernú konzistenciu!



Prečo dôkaz nefunguje?

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

navyše nedáva rovnomernú konzistenciu!



Je pásová hĺbka konzistentná?

Vyjdime z teórie **empirických procesov** (BÚNO $J = 2$):

- Platnosť'

$$\dim_{VC} \{(x_1, x_2) | G(x) \subset B(x_1, x_2)\}_{x \in S} = \infty$$

pre kompaktné množiny $S \subset C([0, 1])$ naznačuje, že hĺbka **nebude uniformne konzistentá** (Assouadova veta - [4, Thm 6.4.5]).

- Existencia **boolean σ -nezávislej postupnosti** funkcií v triede

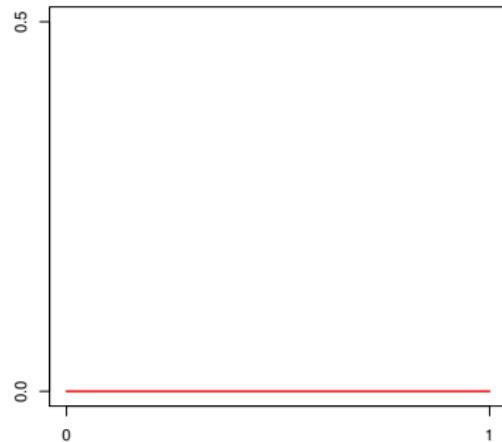
$$\{(x_1, x_2) | G(x) \subset B(x_1, x_2)\}_{x \in S}$$

naznačuje, že hĺbka **nebude univerzálnie konzistentá** (van Handelova veta - [9, Thm 1.3]).

Konzistencia pásovej hĺbky: Protipríklad

Definujme $X \sim P \in \mathcal{P}(\mathcal{C}([0, 1]))$ takto:

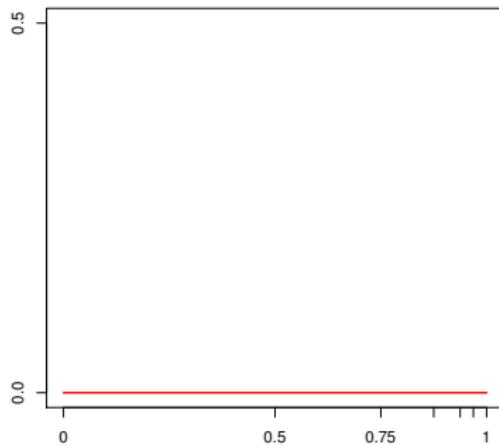
- $P(X(t) = 0 \text{ pre všetky } t \in [0, 1]) = 0.5$.



Konzistencia pásovej hĺbky: Protipríklad

Definujme $X \sim P \in \mathcal{P}(\mathcal{C}([0, 1]))$ takto:

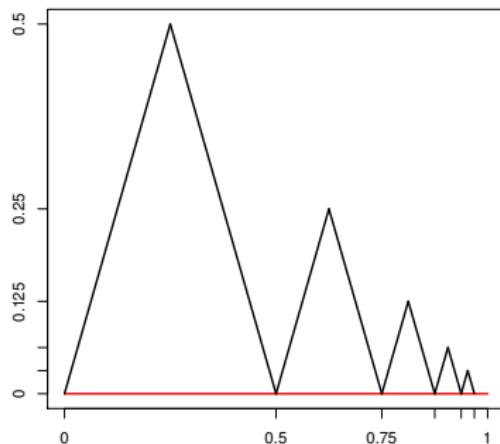
- Rozdeľme interval $[0, 1]$ „diadičky“ na disjunktné subintervaly I_j dĺžok $\{2^{-j}\}_{j \in \mathbb{N}}$.



Konzistencia pásovej hĺbky: Protipríklad

Definujme $X \sim P \in \mathcal{P}(\mathcal{C}([0, 1]))$ takto:

- Ak $X \not\equiv 0$, na každom I_j bude X nulová s pravdepodobnosťou 0.5 alebo nadobudne skok s pravdepodobnosťou 0.5. Skoky nastávajú nezávisle od seba.



Konzistencia pásovej hĺbky: Protipríklad

Označme ako x_j funkciu s **jediným skokom** práve na intervale I_j , inde

0. Potom platí:

- $BD^2(x_j; P) = 0.25$ pre každé $j \in \mathbb{N}$

Konzistencia pásovej hĺbky: Protipríklad

Označme ako x_j funkciu s **jediným skokom** práve na intervale I_j , inde

0. Potom platí:

- $BD^2(x_j; P) = 0.25$ pre každé $j \in \mathbb{N}$
- Nech n je párne. Ak existuje $j_n \in \mathbb{N}$ tak, že práve $n/2$ funkcií má skok v I_{j_n} a $n/2$ funkcií n.v. je nulových na $[0, 1]$, potom x_{j_n} leží v pásoch.

$$\binom{n}{2} - 2 \binom{n/2}{2} = \frac{n^2}{4}$$

Konzistencia pásovej hĺbky: Protipríklad

Označme ako x_j funkciu s **jediným skokom** práve na intervale I_j , inde

0. Potom platí:

- $BD^{(2)}(x_j; P) = 0.25$ pre každé $j \in \mathbb{N}$
- Nech n je párne. Ak existuje $j_n \in \mathbb{N}$ tak, že práve $n/2$ funkcií má skok v I_{j_n} a $n/2$ funkcií n.v. je nulových na $[0, 1]$, potom x_{j_n} leží v pásoch.

$$\binom{n}{2} - 2 \binom{n/2}{2} = \frac{n^2}{4}$$

- Pre takéto j_n teda platí

$$BD^{(J)}(x_{j_n}; P_n) = \frac{\frac{n^2}{4}}{\binom{n}{2}} = \frac{n}{2(n-1)} \xrightarrow{n \rightarrow \infty} 0.5.$$

Konzistencia pásovej hĺbky: Protipríklad

Označme ako x_j funkciu s **jediným skokom** práve na intervale I_j , inde

0. Potom platí:

- $BD^2(x_j; P) = 0.25$ pre každé $j \in \mathbb{N}$
- Nech n je párne. Ak existuje $j_n \in \mathbb{N}$ tak, že práve $n/2$ funkcií má skok v I_{j_n} a $n/2$ funkcií n.v. je nulových na $[0, 1]$, potom x_{j_n} leží v pásoch.

$$\binom{n}{2} - 2 \binom{n/2}{2} = \frac{n^2}{4}$$

- Pre takéto j_n teda platí

$$BD^{(J)}(x_{j_n}; P_n) = \frac{\frac{n^2}{4}}{\binom{n}{2}} = \frac{n}{2(n-1)} \xrightarrow{n \rightarrow \infty} 0.5.$$

Konzistencia pásovej hĺbky: Protipríklad

Označme ako x_j funkciu s **jediným skokom** práve na intervale I_j , inde

0. Potom platí:

- $BD^{(2)}(x_j; P) = 0.25$ pre každé $j \in \mathbb{N}$
- Nech n je párne. Ak existuje $j_n \in \mathbb{N}$ tak, že práve $n/2$ funkcií má skok v I_{j_n} a $n/2$ funkcií n.v. je nulových na $[0, 1]$, potom x_{j_n} leží v pásoch.

$$\binom{n}{2} - 2 \binom{n/2}{2} = \frac{n^2}{4}$$

- Pre takéto j_n teda platí

$$BD^{(J)}(x_{j_n}; P_n) = \frac{\frac{n^2}{4}}{\binom{n}{2}} = \frac{n}{2(n-1)} \xrightarrow{n \rightarrow \infty} 0.5.$$

Existuje ale **nekonečne veľa** takých dvojíc (n, j_n) ?

Konzistencia pásovej hĺbky: Protipríklad

Existuje ale nekonečne veľa takých dvojíc (n, j_n) ? **Áno!**

- Skoro iste existuje nekonečne veľa n takých, že práve $n/2$ funkcií bude nulových na $[0, 1]$ (**stav 0 v symetrickej náhodnej prechádzke je trvalý**).

Konzistencia pásovej hĺbky: Protipríklad

Existuje ale nekonečne veľa takých dvojíc (n, j_n) ? **Áno!**

- Skoro iste existuje nekonečne veľa n takých, že práve $n/2$ funkcií bude nulových na $[0, 1]$ (**stav 0 v symetrickej náhodnej prechádzke je trvalý**).
- Pre každé takéto n s.i. existuje j_n tak, že všetkých $n/2$ funkcií so skokmi bude mať v intervale I_{j_n} skok (**Borel-Cantelli**).

Konzistencia pásovej hľbky: Protipríklad

Existuje ale nekonečne veľa takých dvojíc (n, j_n) ? **Áno!**

- Skoro iste existuje nekonečne veľa n takých, že práve $n/2$ funkcií bude nulových na $[0, 1]$ (**stav 0 v symetrickej náhodnej prechádzke je trvalý**).
- Pre každé takéto n s.i. existuje j_n tak, že všetkých $n/2$ funkcií so skokmi bude mať v intervale I_{j_n} skok (**Borel-Cantelli**).
- Dostávame teda nekonečne veľa n , pričom pre každé existuje funkcia z $\{x_j\}_{j \in \mathbb{N}}$, pre ktorú $BD^{(2)}(x_{j_n}; P_n) \approx 0.5$. Preto pre každé $\varepsilon > 0$ a pre nekonečne veľa $n \in \mathbb{N}$ s.i. platí

$$\sup_{j \in \mathbb{N}} |BD^{(2)}(x_j; P_n) - BD^{(2)}(x_j; P)| > 0.25 - \varepsilon$$

Konzistencia pásovej hĺbky: Protipríklad

Existuje ale nekonečne veľa takých dvojíc (n, j_n) ? **Áno!**

- Skoro iste existuje nekonečne veľa n takých, že práve $n/2$ funkcií bude nulových na $[0, 1]$ (**stav 0 v symetrickej náhodnej prechádzke je trvalý**).
- Pre každé takéto n s.i. existuje j_n tak, že všetkých $n/2$ funkcií so skokmi bude mať v intervale I_{j_n} skok (**Borel-Cantelli**).
- Dostávame teda nekonečne veľa n , pričom pre každé existuje funkcia z $\{x_j\}_{j \in \mathbb{N}}$, pre ktorú $BD^{(2)}(x_{j_n}; P_n) \approx 0.5$. Preto pre každé $\varepsilon > 0$ a pre nekonečne veľa $n \in \mathbb{N}$ s.i. platí

$$\sup_{j \in \mathbb{N}} |BD^{(2)}(x_j; P_n) - BD^{(2)}(x_j; P)| > 0.25 - \varepsilon$$

Konzistencia pásovej hľbky: Protipríklad

Existuje ale nekonečne veľa takých dvojíc (n, j_n) ? **Áno!**

- Skoro iste existuje nekonečne veľa n takých, že práve $n/2$ funkcií bude nulových na $[0, 1]$ (**stav 0 v symetrickej náhodnej prechádzke je trvalý**).
- Pre každé takéto n s.i. existuje j_n tak, že všetkých $n/2$ funkcií so skokmi bude mať v intervale I_{j_n} skok (**Borel-Cantelli**).
- Dostávame teda nekonečne veľa n , pričom pre každé existuje funkcia z $\{x_j\}_{j \in \mathbb{N}}$, pre ktorú $BD^2(x_{j_n}; P_n) \approx 0.5$. Preto pre každé $\varepsilon > 0$ a pre nekonečne veľa $n \in \mathbb{N}$ s.i. platí

$$\sup_{j \in \mathbb{N}} |BD^2(x_j; P_n) - BD^2(x_j; P)| > 0.25 - \varepsilon$$

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

Oprava prvá: zospojitenie

Problém dôkazu López-Pintadovej a Roma bol v nespojiteosti $BD^J(\cdot; P_n)$. Nemerajme teda mieru náležania do pásu indikátorom, ale **vzdialenosťou od pásu**, t.j. pre metriku d na $C([0, 1])$ namiesto

$$P[G(x) \subset B(X_1, X_2)] = E[\mathbb{I}[G(x) \subset B(X_1, X_2)]]$$

v definícii hľbky používajme

$$E[1 - w(d(x; B(X_1, X_2)))],$$

kde $w : [0, \infty) \rightarrow [0, 1]$, $w(0) = 1$, $\lim_{t \rightarrow \infty} w(t) = 0$ je rovnako spojitá **zhľadzujúca funkcia**, napr. e^{-t} .

Obmedzíme sa pre jednoduchosť na suprémovú a L_1 metriku.

Oprava prvá: zospojitenie

Tvrdenie:

Nech w je zhľadzujúca funkcia a $S \subset C([0, 1])$ je relatívne kompaktná.
Potom pásové hľbky zhľadené w

$$BD^{J^*)}(\cdot; \cdot, w, d) : C([0, 1]) \times \mathcal{P}(C([0, 1])) \rightarrow [0, 1]$$

sú tak pre suprémovú, ako pre L_1 metriku uniformne konzistentné na S .

Dôkaz: Zosilnená verzia dôkazu López-Pintadovej a Roma obohatená o rovnakú spojitosť triedy

$$\left\{ BD^{J^*)}(x; P, w, d) \mid x \in C([0, 1]), P \in \mathcal{P}(C([0, 1])) \right\}$$

a vlastnosti kanonických U-štatistik (Borovskich a Koroljuk [7, Thm 2.1.4]).

Fraimanova-Munizovej hĺbka

Fraiman a Munizová [5]

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

kde D je jednorozmerná „hĺbka“ ako

- **polopriestorová hĺbka**

$$D(x(t); P_t) = \min \{F_t(x(t)), 1 - F_t(x(t))\},$$

- **simplexová hĺbka**

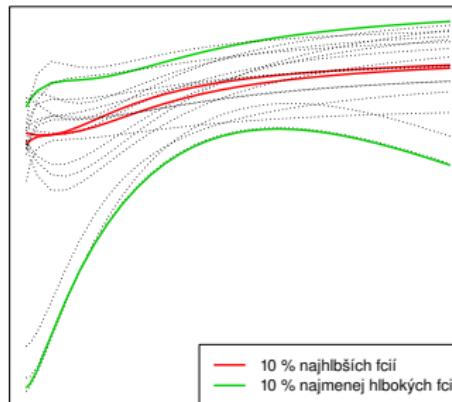
$$D(x(t); P_t) = F_t(x(t))(1 - F_t(x(t))).$$

Na rovnakom princípe fungujú **K-pásové hĺbky** (Hlubinka a Nagy [6])
a **duálne hĺbky** (Cuevas a Fraiman [2]).

Fraimanova-Munizovej hĺbka

Fraiman a Munizová [5]

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



Konzistencia integrálnych hĺbek

Tvrdenie:

Nech výberová verzia jednorozmernej hĺbky $D : \mathbb{R} \times \mathcal{P}(\mathbb{R}) \rightarrow [0, 1]$ má tvar U-štatistiky a D je univerzálne konzistentná. Potom funkcionálna hĺbka

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

je univerzálne konzistentná na $C([0, 1])$.

Dôkaz: Použitím Lebesguovej vety dostávame slabú univerzálnu konzistenciu, ktorá je pre U-procesy ekvivalentná (silnej) univerzálnej konzistencii (de la Peña a Giné [3, p.227]). □

Predpoklady tvrdenia sú splnené napr. voľbou **simplexovej hĺbky** za D .

Záver pre pásové hĺbky

Pásové hĺbky:

- dávajú **zlé výsledky v aplikáciách** (Hlubinka a Nagy [6]),
- **ťažko sa počítajú** ($O(n^J)$ proti $O(n)$ pre integrálne hĺbky),
- **nie sú konzistentné**.

Záver

Nepoužívať pásové hĺbky a voliť integrálne alternatívy.

Vyhliadky do budúcnosti

- Rozšírenie van Handelovej (Assouadovej) vety na U-procesy.
- **Uniformná konzistencia integrálnych hĺbek.**

$$P_\gamma - \dim \{\lambda[t] | x(t) \in B(x_1(t), x_2(t))\}_{x \in S} = \infty \quad \forall \gamma > 0$$

pre kompaktné množiny $S \subset C([0, 1])$ naznačuje, že hĺbka
nebude uniformne konzistentá (Alonova veta [1, Thm 2.2]).

Literatúra

-  Noga Alon, Shai Ben-David, Nicolò Cesa-Bianchi, and David Haussler. Scale-sensitive dimensions, uniform convergence, and learnability. *J. ACM*, 44(4):615–631, 1997.
-  Antonio Cuevas and Ricardo Fraiman. On depth measures and dual statistics. a methodology for dealing with general data. *J. Multivar. Anal.*, 100:753–766, April 2009.
-  Víctor H. de la Peña and Evarist Giné. *Decoupling: From Dependence to Independence (Probability and its Applications)*. Springer, 1998.
-  R.M. Dudley. *Uniform Central Limit Theorems*. Cambridge Studies in Advanced Mathematics. Cambridge University Press, 1999.
-  Ricardo Fraiman and Graciela Muniz. Trimmed means for functional data. *Test*, 10(2):419–440, 2001.
-  Daniel Hlubinka and Stanislav Nagy. Functional data depth and classification. *submitted to Comput. Stat.*
-  V. S. Koroljuk and Yu. V. Borovskich. *Theory of U-Statistics*. Kluwer, 1994.
-  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.
-  Ramon van Handel. The universal Glivenko-Cantelli property. *Probab. Th. Rel. Fields*, to appear.