



Ekonomická  
fakulta  
Faculty  
of Economics

Jihočeská univerzita  
v Českých Budějovicích  
University of South Bohemia  
in České Budějovice

# MODIFIKACE RANDLESOVÝCH NADROVIN

Jana Klicnarová

KMI EF, Jihočeská univerzita v Českých Budějovicích

ROBUST 2018 - Rybník



- 1 Úvod.
- 2 Randlesovy interdirekce (interdirections).
- 3 Výsledky využívající klasické interdirekce.
- 4 Lift-interdirections.
- 5 Deep interdirections.
- 6 Simulace.
- 7 A co dál.
- 8 Literatura.



Klasické znaménkové a pořádkové testy jsou velmi využívané neparametrické testy v případě jednorozměrných náhodných veličin — lze tyto testy zobecnit i pro vícerozměrná rozdělení?

Uvažujeme náhodný vzorek  $\mathcal{X}_n$ , který obsahuje  $n$  pozorování  $\mathbf{X}_1, \dots, \mathbf{X}_n \in \mathbb{R}^p$  sledující "symetrické" rozdělení s neznámým středem symetrie  $\theta \in \mathbb{R}^p$ .



## SFÉRICKY SYMETRICKÉ ROZDĚLENÍ

Řekneme, že náhodný vektor  $\mathbf{X}$  sleduje **sféricky symetrické rozdělení** okolo  $\theta$ , jestliže rotace vektoru  $\mathbf{X}$  okolo středu  $\theta$  rozdělení nezmění.

Přesněji:

$$\mathbf{X} - \theta \stackrel{d}{=} \mathbf{A}(\mathbf{X} - \theta)$$

pro všechny ortonormální matice  $\mathbf{A}$ .

## ELIPTICKY SYMETRICKÁ ROZDĚLENÍ

Řekneme, že náhodný vektor  $\mathbf{X}$  sleduje **elipticky symetrické rozdělení** s parametry  $\theta$  a  $\Sigma$ , jestliže existuje sféricky symetricky rozdělený náhodný vektor  $\mathbf{Y}$  takový:

$$\mathbf{X} \stackrel{d}{=} \mathbf{A}'\mathbf{Y} + \theta,$$

kde matice  $\mathbf{A}_{k \times d}$  je taková, že  $\mathbf{A}'\mathbf{A} = \Sigma$ .

## TŘI ZÁKLADNÍ PŘÍSTUPY K VÍCEROZMĚRNÝM NEPARAMETRICKÝM TESTŮM

- 1 Puri, Sen (1971);
- 2 prostorová znaménka, pořadí, Ojův medián – Oja (1999);
- 3 interdirekce (interdirections).

## INTERDIREKCE

Myšlenka přístupu pomocí interdirekcí byla představena Randlesem (1989).

## DEFINICE

Řekneme, že nadrovina je **interdirekcí mezi body**  $\mathbf{y}_1, \mathbf{y}_2 \in \mathbf{R}^p$  ve vzorku  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ , pokud tato nadrovina prochází středem rozdělení a dalšími  $p - 1$  body z pozorování  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$  a zároveň tato nadrovina odděluje body  $\mathbf{y}_1$  a  $\mathbf{y}_2$ .

## RANDLES (1989): JEDNOVÝBĚROVÝ TEST NA POLOHU ROZDĚLENÍ

Nulová hypotéza:

$$H_0 : \theta = \mathbf{0}.$$

$$V_n = \frac{p}{n} \sum_{j=1}^n \sum_{k=1}^n \cos(\pi \hat{p}_{jk}),$$

kde

$$\begin{aligned} \hat{p}_{jk} &= (C_{jk} + d_n) / \binom{n}{p-1} \quad j \neq k \\ &= 0 \quad j = k, \end{aligned}$$

$C_{jk}$  je počet interdirekcí mezi  $X_j$  a  $X_k$ ; a  $d_n = \left( \binom{n}{p-1} - \binom{n-2}{p-1} \right) / 2$ .

## JEDNOVÝBĚROVÝ TEST NA POLOHU ROZDĚLENÍ

Nulová hypotéza:

$$H_0 : \theta = \mathbf{0}.$$

## RANDLES (1989)

Jestliže pozorování pochází z elipticky symetrického rozdělení, potom za platnosti hypotézy  $H_0$  platí:  $V_n^2 \rightarrow \chi_p^2$  v rozdělení pro  $n \rightarrow \infty$ .

## JEDNOVÝBĚROVÝ TEST NA PARAMETR POLOHY ROZDĚLENÍ

Později Peters and Randles (90), Jan and Randles (94) tyto výsledky vylepšili, porovnali je s jinými testy. Hallin a Paindaveine ve článku z roku 2002 ukázali nové statistiky založené na interdirekcích, ukázali jejich asymptotické vlastnosti.

## TEST DVOU VÝBĚRŮ NA SHODU PARAMETRŮ POLOHY

Randles and Peters (Randles and Peters (90)) uvažovali test s nulovou hypotézou

$$H_0 : \theta_1 = \theta_2$$

za podmínky elipticky symetrického rozdělení.

## VÍCEVÝBĚROVÝ TEST NA SHODU PARAMETRŮ POLOHY

Později např. Um, Randles (98) zobecnili jejich výsledky také pro situaci více než dvou výběrů.

## NEPARAMETRICKÉ TESTY NEZÁVISLOSTI

V roce 1997 Gieser a Randles představili také test nezávislosti mezi vektory také založený na Randlesových interdirekcích.

## KLÍČOVÝ KROK (HALLIN, PAINDEVIENE (02))

Nechť  $\mathbf{X}_1, \mathbf{X}_2, \dots$  jsou i.i.d.  $p$ -rozměrné vektory se sféricky symetrickým rozdělením. Označme  $\alpha(y_1, y_2) := \arccos((y_1' y_2) / (\|y_1\| \|y_2\|))$  úhel mezi  $y_1, y_2$  (vůči středu rozdělení).

Potom

$$\binom{n}{d-1}^{-1} C^{(n)}(y_1, y_2)$$

konverguje v  $L_2$  k  $\pi^{-1} \alpha(y_1, y_2)$  pro  $n \rightarrow \infty$ .

## DŮKAZ

Založen na U-statistikách...



## PROBLÉM SE ZNALOSTÍ PARAMETRŮ POLOHY ROZDĚLENÍ

Výše uvedené metody předpokládají znalost středu rozdělení, k jejich realizaci je tedy zapotřebí nejprve odhadnout střed rozdělení.

Je skutečně nezbytné odhadovat střed rozdělení? Nebylo by možné najít podobnou techniku, která by nepotřebovala znalost středu rozdělení?



## OJA, PAINDAVEINE (2005)

Oja a Paindaveine (2005) představili ve své práci tzv. lift-interdirections.

**Lift-interdirections** jsou založeny na všech nadrovinách, které procházejí  $p$  body z pozorování a oddělují body  $y_1$  a  $y_2$ .

Ukazují, že (za předpokladu elipticky symetrického rozdělení) pořadí jejich lift-interdirections se asymptoticky shoduje s pořadím v Mahalanobisově vzdálenosti. Ukázali, že lift-interdirection společně s Randlesovými interdirekcemi mohou být použity v testech, které odvodili Hallin, Paindaveine (2002).



## NÁPAD

Tento přístup kombinuje obě výše zmíněné metody. Interdirekce hloubky  $\delta$  jsou takové nadroviny v prostoru, které procházejí  $p$  body pozorování a zároveň rozdělují pozorované hodnoty na dvě "poloviny". (Nemusíme nutně uvažovat poloviny, stačí nám, pokud povolíme, že rozdíl mezi počtem bodů v jednotlivých poloprostorech se liší maximálně o předem zvolené číslo –  $\delta$ ).

Nebo je možné ukázat, že některé výsledky platí i pro modifikované Randlesovy nadroviny ve smyslu, že uvažujeme všechny lift-interdirection, které procházejí dostatečně blízko ke středu rozdělení?



$\mathcal{X}_n = (\mathbf{X}_1, \dots, \mathbf{X}_n)$  je vzorek,  $\mathbf{q} := (q_1, q_2, \dots, q_p)$ ,  
 $1 \leq q_1 < q_2 < \dots < q_p \leq n$ , nadrovina  $H^{\mathbf{q}}$  je nadrovina procházející body  
 $X_{q_1}, X_{q_2}, \dots, X_{q_p}$ .

## $\delta$ -HLUBOKÁ NADROVINA

Je každá nadrovina  $H^{\mathbf{q}}$ :  $|\sum_{k=1}^n S^{\mathbf{q}}(\mathbf{X}_k)| \leq \delta$ ,  $\delta \in \mathbb{N}$ , kde  $S^{\mathbf{q}}(\mathbf{X}_k)$  je  
znaménko  $X_k$  vůči nadrovině  $H^{\mathbf{q}}$ .

Položme

$$N_n^\delta = \sum_{\mathbf{q} \in \mathcal{Q}} I_{\{|\sum_{k=1}^n S^{\mathbf{q}}(\mathbf{x}_k)| \leq \delta\}} \equiv \sum_{\mathbf{q} \in \mathcal{Q}} w_n^\delta(\mathbf{q})$$

a

$$\tilde{C}_{\mathbf{y}_1, \mathbf{y}_2}^\delta(\mathcal{X}_n) = \sum_{\mathbf{q} \in \mathcal{Q}} w_n^\delta(\mathbf{q}) h(\mathcal{X}^{\mathbf{q}}),$$

kde  $h(\mathcal{X}^{\mathbf{q}}) = (1 - S^{\mathbf{q}}(\mathbf{y}_1)S^{\mathbf{q}}(\mathbf{y}_2)) / 2$ .

Chtěli bychom ukázat, že

$$\frac{\tilde{C}_{\mathbf{y}_1, \mathbf{y}_2}^\delta(\mathcal{X}_n)}{N_n^\delta} \rightarrow \frac{1}{\pi} \alpha(\mathbf{y}_1, \mathbf{y}_2).$$

Pokud uvažujeme

$$U_2^\varepsilon := \frac{\tilde{B}_{\mathbf{y}_1, \mathbf{y}_2}^\varepsilon(\mathcal{X}_n)}{M_n^\varepsilon}$$

kde

$$M_n^\varepsilon = \sum_{\mathbf{q} \in \mathcal{Q}} I_{\{\Delta(H^{\mathbf{q}}, \theta) < \varepsilon\}} \equiv \sum_{\mathbf{q} \in \mathcal{Q}} v^\varepsilon(\mathbf{q})$$

a

$$\tilde{B}_{\mathbf{y}_1, \mathbf{y}_2}^\varepsilon(\mathcal{X}_n) = \sum_{\mathbf{q} \in \mathcal{Q}} v^\varepsilon(\mathbf{q}) h(\mathcal{X}^{\mathbf{q}}).$$

Pro sféricky symetrická rozdělení s kladnou hustotou okolo středu rozdělení  $\theta$ :

$$\lim_{\varepsilon \rightarrow 0} \lim_{n \rightarrow \infty} E \frac{\tilde{B}_{\mathbf{y}_1, \mathbf{y}_2}^\varepsilon(\mathcal{X}_n)}{M_n^\varepsilon} = \frac{1}{\pi} \alpha(\mathbf{y}_1, \mathbf{y}_2).$$



## TVRZENÍ

Pokud  $\mathbf{X}_1, \mathbf{X}_2, \dots$  pochází ze sféricky symmetrického spojitého rozdělení s kladnou hustotou v okolí středu symetrie  $\theta$ , potom

$$E \frac{C_{\mathbf{y}_1, \mathbf{y}_2}^\delta(\mathcal{X}_n)}{N_n^\delta} \rightarrow \frac{1}{\pi} \alpha(\mathbf{y}_1, \mathbf{y}_2),$$

kde  $C_{\mathbf{y}_1, \mathbf{y}_2}^\delta(\mathcal{X}_n)$  je počet  $\delta$ -hlubokých interdirekcí, které oddělují body  $\mathbf{y}_1$  a  $\mathbf{y}_2$  a  $N_n^\delta$  je počet všech  $\delta$ -hlubokých nadrovin, které procházejí  $p$  body z pozorování  $\mathcal{X}_n$ .



# SIMULACE – DVOUVÝBĚROVÝ TEST NA SHODU PARAMETRŮ

## POLOHY

Předpokládáme dva nezávislé  $p$ -rozměrné náhodné vzorky  $\chi_{n_A}^A$  a  $\chi_{n_B}^B$  o velikostech  $n_A$  a  $n_B$ , které pocházejí ze dvou elipticky symetrických rozdělení, která se liší pouze v parametru polohy –  $\theta_A, \theta_B$ .

### RANDLES A PETERS (1990)

Randles a Peters (1990) představili test založený na Randlesových interdirekcích. Jako testovou statistiku položili:

$$S = \frac{pn_A n_B}{n_A + n_B} \left( \frac{1}{n_A^2} \sum_{i=1}^{n_A} \sum_{j=1}^{n_A} \cos(\beta_{ij}) + \frac{1}{n_B^2} \sum_{i=n_A+1}^{n_A+n_B} \sum_{j=n_A+1}^{n_A+n_B} \cos(\beta_{ij}) - \frac{2}{n_A n_B} \sum_{i=1}^{n_A} \sum_{j=n_A+1}^{n_A+n_B} \cos(\beta_{ij}) \right).$$



# DVOUVÝBĚROVÝ TEST NA SHODU PARAMETRŮ POLOHY

## RANDLES A PETERS (1990)

$$\beta_{ij} = \pi C_{\mathbf{x}_i - \hat{\boldsymbol{\theta}}, \mathbf{x}_j - \hat{\boldsymbol{\theta}}}(\mathcal{X}_n - \hat{\boldsymbol{\theta}}) / \binom{n}{p-1}, \quad i, j = 1, \dots, n,$$

kde  $C_{\mathbf{x}_i}$  je počet Randlesových interdirekcí ze spojeného vzorku centrovány odhadem parametru polohy  $\hat{\boldsymbol{\theta}}$  (za platnosti  $H_0$ ).

## ODHAD PARAMETRU POLOHY

Pro odhad parametru polohy  $\hat{\boldsymbol{\theta}}$  jsme využili dvou různých metod – jednou jsme parametr polohy odhadli jako výběrový střed a podruhé jako výběrový robustní prostorový medián (Hettmanspeger a Randles (2002)) – testy označme postupně  $T_1$  a  $T_2$ .



## DEEP INTERDIRECTIONS

$$\beta_{ij} = \pi \tilde{C}_{\mathbf{X}_i, \mathbf{X}_j}^{\delta}(\mathcal{X}_n) / N_n^{\delta}$$

V tomto případě jsme využili modifikovanou verzi interdirekcí, a to takových, kde nepředpokládáme znalost středu rozdělení, využíváme tzv. interdirekcí hloubky  $\delta$ .

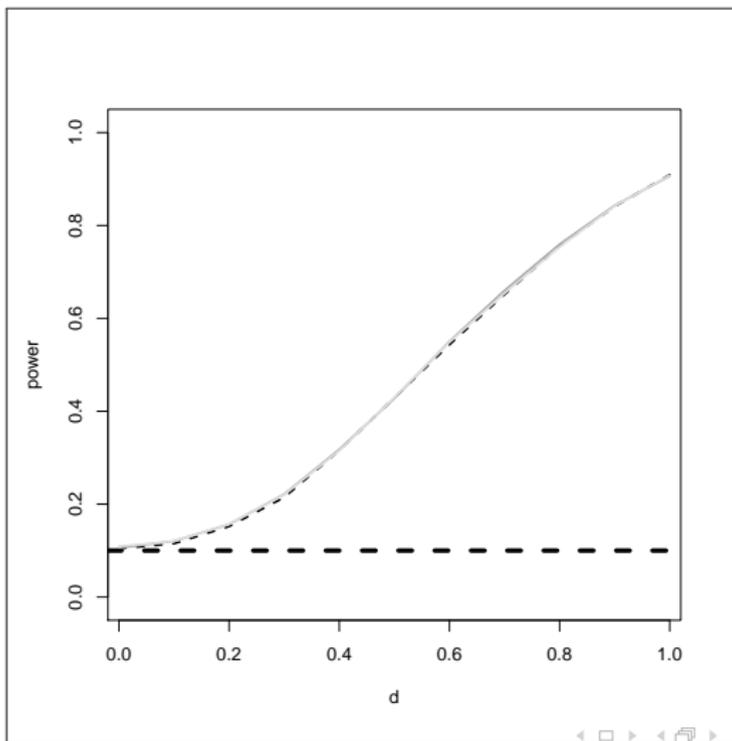
V simulaci jsme tento test označili jako  $T_3^{\delta}$ .



Pro porovnání výše uvedených tří testů  $T_1$ ,  $T_2$  a  $T_3^\delta$  zobrazíme empirické síly testů (založené na  $N = 5\,000$  nez. experimentech) testu  $T_1$  (světle šedá),  $T_2$  (tmavošedá) a  $T_3^\delta$  (černá čárkovaná) na hladině  $\alpha = 0.1$  (horizontální černá čárkovaná) pro  $\delta = 2$  (Obrázek 1) a pro  $\delta = 4$  (Obrázek 2) aplikovaného na dva nezávislé vzorky o stejných velikostech  $n_A = n_B = 15$  (Obrázek 1) a  $n_A = n_B = 25$  (Obrázek 2) pocházející z dvourozměrných normálních rozdělání (Obrázek 1) a z dvourozměrných studentovo rozdělání  $t(1)$  (Obrázek 2), jejichž parametry polohy se lišily o  $(d, d)'$ ,  $d \in \{0, 0.1, \dots, 1.0\}$ . Všechny nasimulované varianty byly ohodnoceny všemi testy (za předpokladu platnosti hypotézy  $H_0$ ) a postupně s využitím všem možných deseti posunů.

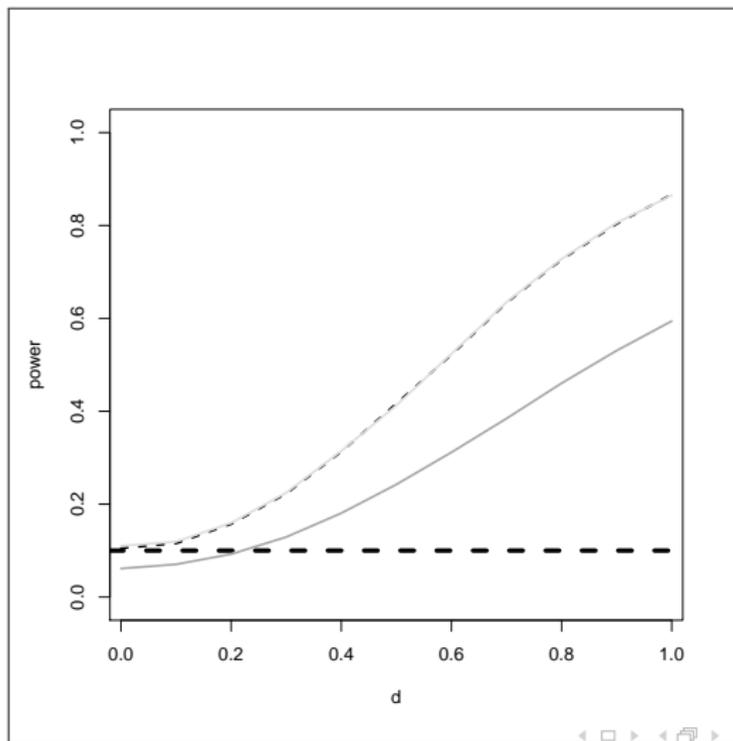


# POROVNÁNÍ KLASICKÝCH A MODIFIKOVANÝCH INTERDIREKČÍ





# POROVNÁNÍ KLASICKÝCH A MODIFIKOVANÝCH INTERDIREKČÍ





Předpokládáme, že stejně jako v dvou výběrovém testu je možné nahradit Randlesovy interdirekce interdirekcemi hloubky  $\delta$  v mnoha dalších testech, které jsou založeny na interdirekcích. Např. v testech pro vícenásobný test shodnosti parametrů polohy – Um, Randles (1998), pro test nezávislosti mezi dvěma vektory – Gieser, Randles (1997), testy proporcionality rozptylu – Ghoush and Sengupta (2001), pro test nezávislosti Hallin, Paindaveine (2002), Paindaveine (2009) aj. Na druhou stranu, jsou samozřejmě testy, kde není zapotřebí původní interdirekce nahrazovat – see, e.g., Hallin, Paindaveine (2002b) and Taskinen and al. (2005).

-  Gieser, P. W., Randles, R. H.: A nonparametric test of independence between two vectors. *Journal of the American Statistical Association* **92 (438)** (1997), 561-567.
-  Hallin, M., Paindaveine, D.: Optimal tests for multivariate location based on interdirections and pseudo-Mahalanobis ranks. *The Annals of Statistics*, **30(4)** (2002), 1103–1133.
-  Hallin, M., Paindaveine, D.: Optimal procedures based on interdirections and pseudo-Mahalanobis ranks for testing multivariate elliptic white noise against ARMA dependence. *Bernoulli* **8 (6)** (2002) 787-815.
-  Oja, H., Paindaveine, D.: Optimal signed-rank tests based on hyperplanes. *Journal of statistical planning and inference*, **135(2)** (2005), 300–323.
-  Paindaveine, D.: On multivariate runs tests for randomness. *Journal of the American Statistical Association*, **104(488)** (2009), 1525-1538.

-  Randles, R. H.: A distribution-free multivariate sign test based on interdirections. *Journal of the American Statistical Association*, **408(84)**, (1989), 1045–1050.
-  Randles, R. H., Peters, D.: Multivariate rank tests for the two-sample location problem. *Communications in Statistics-Theory and Methods*, **19(11)** (1990), 4225-4238.
-  Serfling, R. J.: Multivariate symmetry and asymmetry. *Encyclopedia of statistical sciences*. (2006).
-  Taskinen, S., Oja, H., Randles, R. H.: Multivariate nonparametric tests of independence. *Journal of the American Statistical Association*, **100(471)** (2005), 916-925.
-  Um, Y., Randles, R. H.: Nonparametric tests for the multivariate multi-sample location problem. *Statistica Sinica* (1998), 801-812.