

TESTY A ODHADY POLOHY A REGRESE PŘI PORUŠENÍ PŘEDPOKLADU

NEZÁVISLOSTI

Jana Jurečková, MFF UK Praha

1. Úvod. Je známa řada postupů, robustních vzhledem k odchytkám od předpokládaného tvaru rozdělení pravděpodobnosti, z něhož pozorování pocházejí. Z těchto postupů jmenujme např. pořadové testy a robustní odhadы (M, L- a R-odhadы) parametru polohy a regrese.

Z praxe víme, že často bývá porušen předpoklad o nezávislosti pozorování. Jak ukazují teoretické i numerické studie řady autorů, jsou na porušení tohoto předpokladu citlivé jak klasické i pořadové testy, tak klasické i neklasické odhadы. Např. se ukazuje, že velikost pořadových testů přestává být nezávislá na rozdělení pravděpodobnosti, že se zcela mění rozptyl odhadu apod.

Proto je žádoucí modifikovat standardní postupy tak, aby se citlivost vzhledem k porušení předpokladu nezávislosti maximálně snížila. Jde o obtížný problém a neexistuje jednotný návod na jeho řešení, už proto, že závislost mezi náhodnými veličinami může být různých typů. Proto neuvedeme nějaký univerzální postup, jak modifikovat běžné statistické postupy, jako spíše ukážeme, jaká modifikace byla navržena v některých důležitých speciálních případech. Přesněji řečeno, budeme uvažovat situaci, kdy předpoklad nezávislosti posloupnosti pozorování x_1, x_2, \dots je nahrazen předpokladem nezávislosti. Pro tuto situaci popišeme modifikace dvou statistických postupů:

- (1) modifikaci klasického t-testu, kterou navrhl Albers (1978a) a
(2) modifikaci Huberova M-odhadu parametru polohy, kterou navrhl Portnoy (1977). Další postupy a úvahy lze nalézt v seznamu literatury.

2. nezávislost. Nechť x_1, x_2, \dots je posloupnost náhodných veličin se stejným rozdělením pravděpodobnosti. Řekneme, že veličiny x_1, x_2, \dots jsou m-závislé, jestliže korelační koeficienty $\rho(x_i, x_j)$, $i, j = 1, 2, \dots$ vyhovují podmínce

$$(2.1) \quad \rho(x_i, x_j) = \begin{cases} \rho_{|i-j|} & \text{pro } 1 \leq |i-j| \leq m \\ 0 & \text{pro } |i-j| > m \end{cases}$$

kde ρ_k , $k = 1, 2, \dots$ jsou konstanty takové, že korelační matice

libovolných n po sobě jdoucích veličin jsou pozitivně definované a takové, že

$$(2.2) \quad \sigma^{*2} = 1 + 2 \sum_{k=1}^m p_k > 0;$$

m je dané nezáporné celé číslo.

3. Modifikace t-testu o průměru normálního rozdělení při m-závislých pozorováních (Albers (1978a)).

Nechť x_1, \dots, x_n jsou náhodné veličiny, všecky s normálním rozdělením $N(\mu, \sigma^2)$. Jestliže jsou x_i nezávislé, pak obvyklým testem hypotézy $H_0 : \mu = 0$ proti alternativě $H_1 : \mu > 0$ je Studentův t-test s kritickým oborem

$$(3.1) \quad T_n > t_\alpha(n-1) \quad (\text{asymptoticky } T_n > u_\alpha), \quad \text{kde}$$

$$(3.2) \quad T_n = \frac{\bar{x}_n}{S_n} \sqrt{n}, \quad S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2, \quad \bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i,$$

$t_\alpha(n-1)$ je 100α -procentní kritická hodnota rozdělení t o $(n-1)$ stupních volnosti a u_α je 100α -procentní kritická hodnota normálního rozdělení $N(0, 1)$.

Předpokládejme, že x_1, \dots, x_n jsou m -závislé, kde m je dané přirozené číslo. Pak

$$\sqrt{n} \frac{\bar{x}_n - \mu}{\sigma}$$

má normální rozdělení $N(0, \sigma^{*2})$, kde

$$(3.3) \quad \sigma_n^{*2} = 1 + 2 \sum_{k=1}^m \left(1 - \frac{k}{n}\right) p_k.$$

Protože platí $S_n^2 \xrightarrow{P} \sigma^2$ při $n \rightarrow \infty$, dostáváme ze Slutského věty, že $\sqrt{n}(\bar{x}_n - \mu)/S_n$ má při $n \rightarrow \infty$ asymptoticky normální rozdělení $N(0, \sigma^{*2})$, kde σ^{*2} je definováno ve (2.2).

Kdybychom použili t-test nebo asymptotický t-test (viz (3.1)), byla by asymptotická velikost testu nikoli α , ale byla by rovna

$$(3.4) \quad P_0(T_n > u_\alpha) = P_0\left(\frac{T_n}{\sigma^*} > \frac{u_\alpha}{\sigma^*}\right) = 1 - \Phi\left(\frac{u_\alpha}{\sigma^*}\right) + o(1),$$

což se může značně lišit od α , jsou-li ρ_1, \dots, ρ_m ne-nulové.

Naším cílem je modifikovat t-test tak, aby jeho asymptotická velikost byla rovna α pro všecky hodnoty ρ_1, \dots, ρ_m a nikoli jen v případě $\rho_1 = \dots = \rho_m = 0$. K tomu účelu nejprve odhadneme ρ_1, \dots, ρ_m pomocí odhadů

$$(3.5) \quad \hat{\rho}_k = \sum_{i=1}^n (x_i - \bar{x}_n)(x_{i+k} - \bar{x}_n) / ((n-1)s^2), \quad k=1, \dots, m$$

(kde dodefinujeme $x_{n+k} = x_k$, $k=1, \dots, n$) nebo pomocí odhadů

$$(3.6) \quad \hat{\rho}_k = \sum_{i=1}^{n-k} (x_i - \bar{x}_n)(x_{i+k} - \bar{x}_n) / ((n-1)s_n^2), \quad k=1, \dots, m.$$

Oba typy odhadů (3.5) a (3.6) vedou ke stejným asymptotickým výsledkům. Definujme statistiku w_m

$$(3.7) \quad w_m^2 = \begin{cases} s_n^2 (1 + 2 \sum_{k=1}^m \hat{\rho}_k) & \text{pro } x = (x_1, \dots, x_n) \in B \\ \text{libovolná ohrazená pro } x \notin B, & \end{cases}$$

kde

$$(3.8) \quad B = \left\{ x = (x_1, \dots, x_n) : 1 + 2 \sum_{k=1}^m \hat{\rho}_k > 0 \right\}.$$

t-test daný ve (3.1) a (3.2) nahradíme modifikovaným testem s kritickým oborem

$$(3.9) \quad v_m = \sqrt{n} \bar{x}_n / w_m > u_\alpha .$$

Následující věta ukazuje, že test (3.9) má asymptotickou velikost α i při m-závislých pozorováních.

VĚTA 3.1. Nechť x_1, x_2, \dots, x_n jsou m-závislé náhodné veličiny, všecky s normálním rozdělením $N(\mu, \sigma^2)$. Pak pro lib. $x \in \mathbb{R}$ platí

$$(3.10) \quad P \left\{ \sqrt{n} \frac{\bar{x}_n - \mu}{w_m} \leq x \right\} \rightarrow \Phi(x) \quad \text{při } n \rightarrow \infty ,$$

kde Φ je distribuční funkce $N(0,1)$. Konvergence (3.10) je stejněměrná na množině

$$A = \left\{ (\sigma, \rho_1, \dots, \rho_m) : \sigma^2 > c_1 > 0 \text{ a } 1 + 2 \sum_{k=1}^m \rho_k > c_2 > 0 \right\},$$

kde c_1 a c_2 jsou libovolné kladné konstanty. Test hypotézy $H_0 : \mu = 0$ proti $H_1 : \mu > 0$ tvaru

$$(3.11) \quad \psi_v^{(m)}(x) = \begin{cases} 1 & \dots v_m \geq u_\alpha \left[= \Phi^{-1}(1-\alpha) \right] \\ 0 & \dots v_m < u_\alpha \end{cases}$$

má asymptotickou velikost \propto pro vš. $(\sigma, \rho_1, \dots, \rho_m) \in A$.

Důkaz : viz Albers (1978a).

Poznámka. Jestliže je $m=0$, je test $\psi_v^{(0)}$ shodný s asymptotickým t-testem.

Jestliže víme, že x_1, \dots, x_n jsou m-závislé a kromě toho známe ρ_1, \dots, ρ_m , můžeme použít t-testu, optimálního pro tuto situaci (Scheffé (1959)). Test je založen na statistice

$$(3.12) \quad L = (\tilde{s}_n^2 \sum_{i=1}^n \sum_{j=1}^n u_{ij})^{-1/2} \sum_{i=1}^n (\sum_{j=1}^n u_{ij}) x_i$$

kde $U_n = [u_{ij}]_{i,j=1}^n$ je inverzní korelační matice veličin x_1, \dots, x_n (a tedy známá) a

$$(3.13) \quad \tilde{s}_n^2 = \frac{1}{n-1} \left\{ \sum_{i=1}^n \sum_{j=1}^n u_{ij} x_i x_j - \left[(\sum_{i=1}^n \sum_{j=1}^n u_{ij} x_i)^2 / \sum_{i=1}^n \sum_{j=1}^n u_{ij} \right] \right\}.$$

Albers (1978a) dokázal, že test $\psi_v^{(m)}$, odpovídající situaci, kdy neznáme ρ_1, \dots, ρ_m , je při $n \rightarrow \infty$ asymptoticky ekvivalentní optimálnímu t-testu, a tedy je asymptoticky optimální.

Další otázka, která s použitím testu $\psi_v^{(m)}$ vzniká, je, jakou utrpíme ztrátu, jestliže použijeme modifikovaného testu $\psi_v^{(m)}$ v případě, že veličiny x_1, \dots, x_n jsou skutečně závislé a kdy je tedy optimální klasický t-test (3.1). Intuitivně je

zřejmě, že chceme-li pak testem $\Psi_v^{(m)}$ dosáhnout stejné asymptotické sily jako t-testem, musíme vzít více pozorování.

Z předcházejících úvah vyplývá, že síla testu $\Psi_v^{(m)}$ proti alternativě μ je rovna

$$(3.14) \quad \beta_v^{(m)}(\mu) = 1 - \Phi(u_\alpha - n^{1/2} \mu \left[\sigma^2 (1 + 2 \sum_{k=1}^m p_k) \right]^{-1/2}) + o(1).$$

V případě nezávislosti je $p_k = 0$, $k=1, \dots, m$, a tedy síla (3.14) je s přesností řádu $o(1)$ shodná se sílou $\beta_t(\mu)$ klasického t-testu Ψ_t . To znamená, že v případě nezávislosti je relativní asymptotická vydatnost e testu $\Psi_v^{(m)}$ vzhledem k t-testu rovna 1. Jinak řečeno, pokud Ψ_t požaduje n pozorování k dosažení určité sily a $\Psi_v^{(m)}$ požaduje k_n pozorování k dosažení stejně sily, platí $k_n/n \rightarrow 1$ při $n \rightarrow \infty$.

Hodges a Lehmann (1970) srovnávali statistické postupy pomocí tzv. deficiency $d_n = k_n - n$, tj. dodatečného počtu pozorování, který potřebuje méně vydatný postup. Albers (1978a) studoval deficienci $d_n(v_m, t)$ testu $\Psi_v^{(m)}$ vzhledem k t-testu a odvodil

$$(3.15) \quad d_n(v_m, t) = m u_\alpha^2 + O(n^{-1}),$$

což lze interpretovat tak, že chránime-li se proti možnému vlivu m-závislosti použitím modifikovaného testu $\Psi_v^{(m)}$, potřebujeme k tomu asymptoticky o $m \cdot u_\alpha^2$ více pozorování více než t-test.

4. Modifikace M-odhadu parametru polohy při m-závislých pozorováních (Portnoy 1977)

Nechť x_1, x_2, \dots je posloupnost m-závislých náhodných veličin se společnou marginální distribuční funkcí $F(x-\theta)$ takovou, že $F(x) + F(-x) = 1$, $x \in \mathbb{R}$. Nechť $\hat{\theta}_n = \hat{\theta}_n(x_1, \dots, x_n)$ je libovolný konsistentní odhad θ založený na x_1, \dots, x_n (např. $\hat{\theta}_n = \bar{x}_n$). Pak M-odhad $T_n = T_n(x_1, \dots, x_n)$ parametru θ definujeme jako řešení rovnice

$$(4.1) \quad \sum_{i=1}^n \Psi(x_i - t) = 0 \quad \text{vzhledem k } t$$

nejbližší $\hat{\theta}_n$ [a větší, jestliže jsou 2 kořeny stejně vzdálené od $\hat{\theta}_n$; položime $T_n=0$, jestliže neexistuje kořen rovnice (4.1)]; ψ je vhodně zvolená funkce, jejíž vlastnosti dále upřesníme.

Následující věta udává asymptotické rozdělení pravděpodobnosti posloupnosti $\sqrt{n}(T_n - \theta)$ za předpokladu m-závislosti.

VĚTA 4.1. Nechť ψ je spojitá ohrazená funkce, která má stejnoměrně spojitu a ohrazenou derivaci ψ' na doplnku libovolného okolí uzavřené množiny D Lebesgueovy míry 0 takové, že $0 \notin D$. Nechť dále platí

$$(4.2) \quad \int_{\mathbb{R}^1} \psi(x) dF(x-t) \text{ je různe rostoucí v } t \text{ v okolí } t=0;$$

$$(4.3) \quad \int \psi(x) dF(x) = 0; \quad g = \int \psi'(x) dF(x) > 0.$$

Nechť F má spojitu derivaci v okolí D . Pak $\sqrt{n}(T_n - \theta)$ má při $n \rightarrow \infty$ asymptoticky normální rozdělení $N(0, \tilde{\sigma}_0^2/g^2)$, kde

$$(4.4) \quad \tilde{\sigma}_0^2 = \lim_{n \rightarrow \infty} \frac{1}{n} \text{var}_0 \left(\sum_{i=1}^n \psi(x_i) \right).$$

Důkaz: viz Portnoy (1977).

Dále budeme uvažovat speciální model m-závislosti, ve kterém pozorování x_1, \dots, x_n mají tvar

$$(4.5) \quad x_i = \theta + y_i + \rho y_{i-1} + \rho y_{i+1}; \quad i=1, \dots, n,$$

kde y_1, \dots, y_n jsou nezávislé náhodné veličiny se společnou distribuční funkcí G a hustotou g takovou, že $g(x)=g(-x)$, $x \in \mathbb{R}^1$ [dodefinujme $y_0=y_n$, $y_{n+1}=y_1$]; θ je parametr polohy a ρ je další parametr, $|\rho| < 1$. Pak x_1, \dots, x_n jsou m-závislé, kde $m=2$ a mají stejné rozdělení pravděpodobnosti, jehož distribuční funkci označíme F .

Z věty 4.1 vyplývá, že M-odhad $T_n = T_n(x_1, \dots, x_n)$ má asymptoticky normální rozdělení. Přesněji, platí věta

VĚTA 4.2. Nechť náhodné veličiny x_1, \dots, x_n vychovují modelu (4.5), kde y_1, \dots, y_n jsou nezávislé náhodné veličiny se společnou hustotou g , $g(-x)=g(x) \forall x$, která má konečný druhý mo-

ment a jejíž charakteristická funkce splňuje podmíinku

$$(4.6) \quad \int u^2 |\psi_Y(u)| du < \infty.$$

Nechť T_n je M-odhad definovaný ve (4.1), kde funkce ψ je absolutně spojitá a má ohrazenou derivaci ψ' . Pak

$$(4.7) \quad \sqrt{n}(T_n - \theta) \xrightarrow{\mathcal{D}} N(0, \sigma^2), \quad \text{kde}$$

$$(4.8) \quad \sigma^2 = \frac{\int \psi^2 dG}{(\int \psi' dG)^2} + 4\theta \frac{\int y \psi(y) dG(y)}{\int \psi' dG} + o(\theta^2).$$

Důkaz : viz Portnoy (1977).

Poznámka. První člen pravé strany (4.8) je roven asymptotickému rozptylu M-odhadu, založeného na veličinách y_1, \dots, y_n .
Pozorování jsou však x_1, \dots, x_n .

Označme

$$(4.9) \quad V(g, \psi) = \frac{E[\psi^2(Y)]}{(E[\psi'(Y)])^2} + 4\theta \frac{E[Y \cdot \psi(Y)]}{E(\psi'(Y))};$$

asymptotický rozptyl $\sqrt{n}(T_n - \theta)$ je pro malá $|\theta|$ přibližně roven $V(g, \psi)$. Předpokládáme, že neznáme přesné rozdělení G ; pouze víme, že $G \in \mathcal{F}_1$, kde

$$(4.10) \quad \mathcal{F}_1 = \left\{ G = (1-\varepsilon)\Phi + \varepsilon H; \quad H \text{ symetrická spojitá distribuční funkce} \right\}$$

a Φ je distribuční funkce normálního rozdělení $N(0, 1)$; $0 \leq \varepsilon < 1$; [model kontaminovaného normálního rozdělení]. Za těchto podmínek hledáme M-odhad odpovídající funkci ψ_0 a rozdělení $g_0 \in \mathcal{F}_1$ (nejméně příznivé rozdělení) tak, aby asymptotický rozptyl $V(g_0, \psi_0)$ tvořil sedlový bod funkce $V(g, \psi)$, tj. aby platilo

$$(4.11) \quad V(g, \psi_0) \leq V(g_0, \psi_0) \leq V(g_0, \psi)$$

pro vš. $g \in \mathcal{F}_1$ a vš. ψ .

Pro případ nezávislých pozorování (tj. $\rho=0$) je tento problém vyřešen v Huberově práci (1964). V tomto případě řešení odpovídá funkci

$$(4.12) \quad \psi(x) = \begin{cases} x & \dots |x| \leq k \\ k \cdot \text{sign } x & \dots |x| > k \end{cases}$$

kde k závisí na ε podle vztahu

$$(4.13) \quad 2\bar{\Phi}(k) - 1 + \frac{2}{k}\bar{\Phi}'(k) = \frac{1}{1-\varepsilon} .$$

Portnoy (1977) řešil analogický problém pro model (4.5). Při znenedbání členů řádu $O(\rho^2)$ (tj. pro malé hodnoty $|\rho|$) dospěl k M-odhadu odpovídajícímu funkci

$$(4.14) \quad \psi_0(x) = \begin{cases} x & \dots |x| \leq k \\ k \cdot \text{sign } x - \frac{2\rho a}{1+2\rho(1-a)}(x-k \cdot \text{sign } x) & \dots |x| > k, \end{cases}$$

kde $a = (1-\varepsilon)(2\bar{\Phi}(k)-1)$ a k je dáno vztahem (4.13); příslušné nejméně příznivé rozdělení g_0 je stejné jako v nezávislém případě a je dáno vztahem

$$(4.15) \quad -\frac{g_0(x)}{g_0(x)} = \begin{cases} x & \dots |x| \leq k \\ k \cdot \text{sign } x & \dots |x| > k . \end{cases}$$

Jestliže $x \rightarrow \infty$, funkce $\psi_0(x)$ lineárně klesá k $-\infty$. Na druhé straně, $P_0(\psi_0(x) < 0) = E_0 X^2 \cdot O(\rho^2)$. Proto Portnoy navrhuje následující modifikaci funkce ψ_0 , vhodnou při $E_0 X^2 < \infty$: usekneme-li funkci ψ_0 v bodech, kde protíná osu x , dostaneme

$$(4.16) \quad \psi_1(x) = \begin{cases} x & |x| \leq k \\ k \cdot \text{sign } x & k < |x| \leq k' \\ 0 & k' < |x| , \end{cases}$$

kde k vychovuje (4.13), $a = (1-\varepsilon)(2\bar{\Phi}(k)-1)$ a

$$(4.17) \quad k' = k \frac{1+2\rho a}{2\rho a} .$$

Poznámka. Funkce ψ_1 je shodná s funkcí, kterou navrhl Hampel (viz např. Andrews a kol. (1972)).

Ze známého vztahu mezi M-odhady a L-odhady (lineární kombinace pořádkových statistik - viz např. Jaeckel (1971)) můžeme odvodit L-odhad, který také poskytuje minimaximální řešení problému s přesností do členů řádu $O(|\rho|)$. Uvažujme L-odhad tvaru

$$(4.18) \quad T_n^* = \sum_{i=1}^n c_i x^{(i)}, \quad \text{kde } c_i = J\left(\frac{i}{n+1}\right), \quad i=1, \dots, n;$$

volíme-li funkci $J(t)$, $0 < t < 1$ tvaru

$$(4.19) \quad J(t) = \begin{cases} -2\rho & \dots 0 < t < \alpha, \quad 1-\alpha < t < 1 \\ \frac{1+4\alpha\rho}{1-2\alpha} & \dots \alpha \leq t \leq 1-\alpha \end{cases}$$

pak při vhodné volbě konstanty α , $0 < \alpha < \frac{1}{2}$, dostáváme L-odhad s asymptoticky minimaximálním rozptylem v modelu kontaminovaného normálního rozdělení. Všimněme si, že koeficienty u krajních pořádkových statistik jsou záporné; při $\rho = 0$ dostáváme useknutý průměr.

LITERATURA :

- [1] Albers,W.(1978a). Testing the mean of a normal population under dependence. Ann.Statist.6,1337-1344.
- [2] Albers,W.(1978b). One-sample rank tests under autoregressive dependence. Ann.Statist.6,836-845.
- [3] Andrews,D.F.,Bickel,P.J., Hampel,F.R., Huber,P.J., Rogers,W.H., Tukey,J.W. (1972). Robust Estimates of Location. Survey and Advances. Princeton University Press.
- [4] Gastwirth,J.L. and Rubin,H.(1971). Effect of dependence on the level of some one-sample tests. J.Amer.Statist.Assoc. 66, 816-820.
- [5] Gastwirth,J.L. and Rubin,H.(1975a). Asymptotic distribution theory of empiric cdf for mixing processes. Ann.Statist. 3, 809-824.

- [6] Gastwirth, J.L. and Rubin, H.(1975b). The behavior of robust estimators on dependent data. *Ann.Statist.* 3, 1070-1100.
- [7] Gastwirth, J.L., Rubin, H. and Wolf, S.S.(1976). The effect of autoregressive dependence on a nonparametric test. *IEEE Trans.Information Theory* IT-13, 311-313.
- [8] Hodges, J.L.Jr. and Lehmann, E.L.(1970). Deficiency. *Ann.Statist.* 41, 783-801.
- [9] Huber, P.J.(1964). Robust estimation of a location parameter. *Ann.Math.Statist.* 35, 73-101.
- [10] Jaeckel, L.A.(1971). Robust estimates of location Symmetry and asymmetry contamination. *Ann.Math. Statist.* 42, 1020-1034.
- [11] Koul, H.L.(1977). Behavior of robust estimators in the regression model with dependent errors. *Ann.Statist.* 5, 681-699.
- [12] Lehmann, E.L.(1966). Some concepts of dependence. *Ann.Statist.* 37, 1137-1152.
- [13] Modestino, J.W.(1969). Nonparametric and adaptive detecting on dependent data. Technical Report 27, Dept.of Electrical Engineering, Princeton Univ.
- [14] Ramachandramurty, P.V. and Rao, M.S.(1971). Some problems of robust estimation against dependence. *Sankhyā A* 33, 193-200.
- [15] Scheffé, H.(1959). *The analysis of Variance*. Wiley, N.York.
- [16] Serfling, R.J.(1968). The Wilcoxon two-sample statistic on strongly mixing processes. *Ann.Math.Statist.* 39, 1202-1209.