

# VZNIK LINEÁRNÍHO SPOJITÉHO TRENDU

Daniela JARUŠKOVÁ

FSt ČVUT, KM

**Abstrakt.** V článku se studují testy pro nalezení změny v jednoduché lineární regresi za předpokladu spojité regresní funkce, kde čas hraje roli nezávisle proměnné. Problém byl motivován snahou nalézt změny v meteorologických měřeních.

**Abstract:** Tests for detection of a change in simple linear regression are studied assuming the regression function is continuous at the change-point and the independent variable is equally spaced. Problem was motivated by effort of meteorologists to discover a change in meteorological measurements.

**Резюме:** В этой статье предлагаются тесты для нахождения разладки в модели линейной регрессии, которая непрерывна в точке разладки. Проблема выходит из анализа метеорологических данных.

## 1. ÚVOD.

Uvažujeme problém testování posloupnosti nezávislých stejně rozdělených náhodných veličin proti alternativě, že v neznámém čase dojde ke spojité změně ve střední hodnotě takové, že po okamžiku změny bude střední hodnota růst lineárně s časem. Přesněji řečeno to znamená, že chceme testovat nulovou hypotézu  $H_0$  proti alternativě  $A$ :

$$\begin{aligned} H_0 : X_i &= \mu + e_i, & i = 1, \dots, n, \\ A : \exists k \in \{0, \dots, n-1\} & \quad \text{takové, že} \\ X_i &= \mu + e_i, & i = 1, \dots, k, \\ X_i &= \mu + b \cdot (i - k) + e_i, & i = k+1, \dots, n, \end{aligned} \tag{1.1}$$

kde  $e_i$ ,  $i = 1, \dots, n$  jsou nezávislé stejně rozdělené, přičemž  $E e_i = 0$ ,  $E e_i^2 = \sigma^2$  a  $E |e_i|^{2+\delta} < \infty$  ( $\delta > 0$ ). Alternativa může být jednostranná, jestliže  $b > 0$  (resp.  $b < 0$ ), nebo oboustranná, jestliže  $b \neq 0$ .

## 2. PŘÍPADZNÁMÉHO $\mu$ .

Nejprve studujme případ, kde parametry  $\mu$  a  $\sigma^2$  jsou známé. Bez újmy na obecnosti můžeme předpokládat, že  $\mu = 0$ . Kdybychom uvažovali situaci, kde čas změny  $k$  je v modelu (1.1) známý, pak statistika

$$\hat{b}_k = \frac{\sum_{i=k+1}^n X_i(i-k)}{\sqrt{\frac{(n-k)(n-k+1)(2n-2k+1)}{6}}} \quad (2.1)$$

je odhadem parametru  $b$  metodou nejmenších čtverců. V případě, že čas změny neznáme, pak je přirozené použít pro testování nulové hypotézy proti jednostranné alternativě  $b > 0$  statistiku

$$\max_{0 \leq k \leq n-1} \tilde{b}_k / \sigma, \quad (2.2)$$

kde

$$\tilde{b}_k = \frac{\sum_{i=k+1}^n X_i(i-k)}{\sqrt{\frac{(n-k)(n-k+1)(2n-2k+1)}{6}}} \quad (2.3)$$

Poznamenejme, že tato statistika je ekvivalentní s poměrem věrohodnosti, jestliže chyby  $e_i$ ,  $i = 1, \dots, n$  jsou normálně rozdelené. Pro oboustrannou alternativu můžeme použít obdobné

$$\max_{0 \leq k \leq n-1} |\tilde{b}_k| / \sigma. \quad (2.4)$$

Zřejmě platí

$$\begin{aligned} \mathbb{E} \tilde{b}_k &= 0, \quad \text{Var } \tilde{b}_k = \sigma^2, \\ \text{Corr}(\tilde{b}_k, \tilde{b}_l) &= \frac{\frac{(n-l)(n-l+1)(2(n-l)+1)}{6} + (l-k)\frac{(n-l)(n-l+1)}{2}}{\sqrt{\frac{(n-k)(n-k+1)(2(n-k)+1)}{6}} \sqrt{\frac{(n-l)(n-l+1)(2(n-l)+1)}{6}}}, \quad k \leq l. \end{aligned} \quad (2.5)$$

Rozdělení statistiky  $\max_{0 \leq k \leq n-1} \tilde{b}_k / \sigma$  (resp.  $\max_{0 \leq k \leq n-1} |\tilde{b}_k| / \sigma$ ) je velmi komplikované, a proto je přirozené studovat asymptotické rozdělení této statistiky pro velká  $n$ . Na intervalu  $(0, 1)$  definujme proces  $\tilde{b}_n(t)$ ,  $t \in (0, 1)$  tak, že  $\tilde{b}_n(t) = \tilde{b}_{[nt]}$ . Tento proces pro každé  $T < 1$  konverguje v distribuci na  $D\langle 0, T \rangle$  ke standardizovanému gaussovskému procesu

$$IW(t) = \frac{\int_t^1 (W(1) - W(s)) ds}{\sqrt{\frac{(1-t)^3}{3}}} = \frac{\int_t^1 (s - t) dW(s)}{\sqrt{\frac{(1-t)^3}{3}}}, \quad t \in (0, 1). \quad (2.6)$$

( $W(t)$ ,  $t \geq 0$  označuje Wienerův proces.) Platí  $\overline{\lim}_{t \rightarrow 1} IW(t) = \infty$  s.j., stejně jako  $\lim_{n \rightarrow \infty} \max_{0 \leq k \leq n-1} \tilde{b}_k / \sigma = \infty$  s.j. Abychom dostali nedegenerované limitní rozdělení, je třeba zkoumat překročení hranice, která s  $n$  roste nade všechny meze.

Platí

$$\lim_{n \rightarrow \infty} P \left( \max_{0 \leq k \leq n-1} \tilde{b}_k / \sigma > u_n \right) = 1 - \exp(-e^{-x}), \quad (2.7)$$

$$\lim_{n \rightarrow \infty} P \left( \max_{0 \leq k \leq n-1} |\tilde{b}_k| / \sigma > u_n \right) = 1 - \exp(-2e^{-x}), \quad (2.8)$$

kde

$$u_n = \sqrt{2 \ln \ln n} + \frac{1}{\sqrt{2 \ln \ln n}} \left( \ln \frac{\sqrt{3}}{4\pi} + x \right), \quad x \in R_1. \quad (2.9)$$

Pokud parametr  $\sigma$  neznáme, je možno jej nahradit odhadem

$$\hat{\sigma}^2 = \sqrt{\sum X_i^2 / n}$$

nebo uvažovat statistiku

$$\max_{0 \leq k \leq n-1} \tilde{b}_k / \hat{\sigma}_k$$

kde  $\hat{\sigma}_k = \sqrt{(\sum X_i^2 - \tilde{b}_k^2) / (n-1)}$ . Limitní vztahy (2.7) a (2.8) zůstanou v platnosti.

Jiná možnost se nabízí v případě, kdy víme jistě, že ke změně nemohlo dojít v posledních  $(1-\alpha)100\%$  časových okamžikách. Pak je vhodné uvažovat statistiku  $\max_{0 \leq k \leq [(1-\alpha)n]} \tilde{b}_k / \sigma$ . Kritické hodnoty je možno odvodit pomocí approximace limitním procesem

$$P \left( \max_{0 \leq k \leq [(1-\alpha)n]} \tilde{b}_k / \sigma > x \right) = P \left( \max_{0 \leq t \leq (1-\alpha)} IW(t) > x \right), \quad (2.10)$$

přičemž

$$P \left( \max_{0 \leq t \leq (1-\alpha)} IW(t) > x \right) \simeq \sqrt{\frac{3}{8}} \frac{\phi(x)}{\sqrt{\pi}} \ln \frac{1}{\alpha}, \quad (2.11)$$

kde  $\phi(x)$  je hustota  $N(0, 1)$  rozdělení.

### 3. PRÍPAD NEZNÁMÉHO $\mu$ .

Jestliže parametr  $\mu$  neznáme, je odhadem  $b$  metodou nejmenších čtverců v modelu (1.1)

$$\hat{B}_k = \frac{\sum_{i=k+1}^n (X_i - \bar{X})(i-k)}{\frac{(n-k)(n-k+1)(2n-2k+1)}{6} - \frac{(n-k)^2(n-k+1)^2}{4n}}. \quad (3.1)$$

Přirozenou testovou statistikou pro jednostrannou alternativu  $b > 0$  je

$$\max_{0 \leq k \leq n-1} \tilde{B}_k / \sigma, \quad (3.2)$$

resp. pro oboustrannou alternativu  $b \neq 0$ ,

$$\max_{0 \leq k \leq n-1} |\tilde{B}_k| / \sigma, \quad (3.3)$$

kde

$$\tilde{B}_k = \frac{\sum_{i=k+1}^n (X_i - \bar{X})(i-k)}{\sqrt{\frac{(n-k)(n-k+1)(2n-2k+1)}{6} - \frac{(n-k)^2(n-k+1)^2}{4n}}}. \quad (3.4)$$

Opět budeme zkoumat rozdělení těchto statistik pro velká  $n$ . Na intervalu  $\langle 0, 1 \rangle$  definujeme proces  $\tilde{B}_n(t)$ ,  $t \in \langle 0, 1 \rangle$  tak, že  $\tilde{B}_n(t) = \tilde{B}_{[nt]}$ . Pro každé  $T < 1$  proces  $\tilde{B}_n(t)$  konverguje v distribuci na  $D\langle 0, T \rangle$  ke standardizovanému gaussovskému procesu

$$IB(t) = \frac{\int_t^1 (s-t)dW(s) - W(1)\frac{(1-t)^2}{2}}{\sqrt{\frac{(1-t)^3}{3} - \frac{(1-t)^4}{4}}}, \quad t \in \langle 0, 1 \rangle. \quad (3.5)$$

Vzhledem k tomu, že opět platí  $\lim_{n \rightarrow \infty} \max_{0 \leq k \leq n-1} \tilde{B}_k / \sigma = \infty$  s.j., je třeba pro získání nedegenerovaného rozdělení uvažovat pravděpodobnosti meze překročení, která jde s rostoucím  $n$  do nekonečna. Platí

$$\lim_{n \rightarrow \infty} P \left( \max_{0 \leq k \leq n-1} \tilde{B}_k / \sigma > u_n \right) = 1 - \exp(-e^{-x}), \quad (3.6)$$

$$\lim_{n \rightarrow \infty} P \left( \max_{0 \leq k \leq n-1} |\tilde{B}_k| / \sigma > u_n \right) = 1 - \exp(-2e^{-x}), \quad (3.7)$$

kde

$$u_n = \sqrt{2 \ln \ln n} + \frac{1}{\sqrt{2 \ln \ln n}} \left( \ln \frac{\sqrt{3}}{4\pi} + x \right), \quad x \in R_1.$$

Pokud parametr  $\sigma$  neznáme, je možno jej nahradit odhadem

$$\hat{\sigma}^2 = \sqrt{\sum (X_i - \bar{X})^2 / n}$$

nebo uvažovat statistiku

$$\max_{0 \leq k \leq n-1} \tilde{B}_k / \hat{\sigma}_k,$$

kde

$$\hat{\sigma}_k = \sqrt{(\sum (X_i - \bar{X})^2 - \tilde{B}_k^2) / (n-2)}.$$

Limitní vztahy (3.6) a (3.7) zůstanou v platnosti.

Tabulka 1 porovnává kritické hodnoty statistiky  $\max_{0 \leq k \leq n-1} \tilde{B}_k / \hat{\sigma}_k$  pro některé hodnoty  $n$  spočtené z asymptotického rozdělení (3.7) s kritickými hodnotami získanými simulací. Simulované kritické hodnoty byly odhadnuty odpovídajícími kvantily empirické distribuční funkce statistiky

$$\max_{0 \leq k \leq n-1} \tilde{B}_k / \hat{\sigma}_k$$

vytvořené na základě 100 000 realizací.

5 % kritické hodnoty			1 % kritické hodnoty		
n	by (3.7)	simul.	n	by (3.7)	simul.
100	2.71	2.63	100	3.64	3.21
200	2.75	2.65	200	3.64	3.22
300	2.77	2.65	300	3.64	3.22
500	2.79	2.68	500	3.64	3.22

**Tabulka 1.** Několik příkladů 5% and 1% kritických hodnot statistiky  $\max_{0 \leq k \leq n-1} |\tilde{B}_k|/\tilde{\sigma}_k$  spočtených pomocí (3.7) a odhadnutých ze simulace.

V případě, kdy víme jistě, že ke změně nemohlo dojít v posledních  $(1 - \alpha)100\%$  časových okamžikách, můžeme uvažovat statistiku  $\max_{0 \leq k \leq [(1-\alpha)n]} \tilde{B}_k/\sigma$ . Kritické hodnoty je možno odvodit pomocí approximace limitním procesem

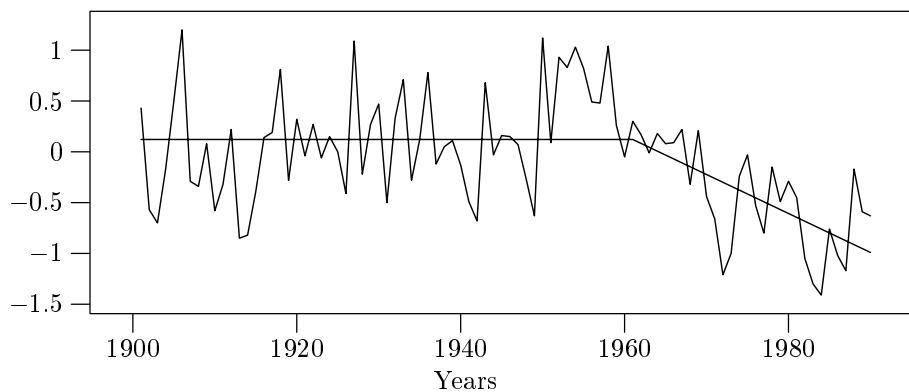
$$P \left( \max_{0 \leq k \leq [(1-\alpha)n]} \tilde{B}_k/\sigma > x \right) = P \left( \max_{0 \leq t \leq (1-\alpha)} IB(t) > x \right), \quad (3.8)$$

přičemž

$$\begin{aligned} P \left( \max_{0 \leq t \leq (1-\alpha)} IB(t) > x \right) &\simeq (1 - \Phi(x)) + \\ &+ \left( \frac{\sqrt{3}}{2} \log \left( \frac{1 + \sqrt{1 - \alpha}}{1 - \sqrt{1 - \alpha}} \right) - \arctan \sqrt{3(1 - \alpha)} \right) \frac{e^{-x^2/2}}{2\pi}. \end{aligned} \quad (3.9)$$

#### 4. PŘÍKLAD.

Příkladem postupné lineární změny může sloužit postupné zmenšování množství srážek v oblasti Sahelu. Obrázek 1 ukazuje vývoj standardizovaných ročních srážkových odchylek pro období 1901–1990 ( $\frac{x_i - \bar{x}}{s}$ ,  $i = 1, \dots, 90$ ) sestavený Nicolsonem (1993).



**Obrázek 1.** Standardizované roční srážkové odchylky v Sahelu, 1901 – 1990.

Statistická analýza prokazuje lineární úbytek srážek, přičemž změna nastala kolem roku 1960. Hodnota statistiky  $\max_{0 \leq k \leq n-1} |\tilde{B}_k|/\hat{\sigma}_k = 6.4452$  vysoko překračuje 1% kritickou hodnotu 3.64 získanou z (3.7). Hodnoty autoregresní funkce spočtené z residuí pro několik prvních zpoždění jsou:  $ar(1) = 0.21, ar(2) = 0.13, ar(4) = 0.9, ar(5) = 0.13, ar(6) = -0.03, ar(7) = -0.01 \dots$ . Zdá se tedy, že by původní veličiny měly být spíš modelovány nějakou ARMA posloupností. Vzhledem k tomu, že hodnoty autoregresní funkce nejsou příliš vysoké, závěr o statisticky významném snížení množství srážek zůstane v platnosti, viz Antoch et al (1995).

#### REFERENCE

- Antoch, J., M. Hušková and Z. Prášková (1996) "Effect of dependence on statistics for determination of change", *Journal of Statistical Planning and Inference* (to appear).
- Gombay, E. and L. Horváth (1994b), "Limit theorems for change in linear regression". *Journal of Multivariate Analysis* **48**, 43–69.
- Davies R.B. (1987), "Hypothesis testing when a nuisance parameter is present only under the alternative." *Biometrika* **74**, 33–43.
- Jarušková, D. (1996), "Some problems with application of change-point detection methods to environmental data". *Environmetrics* (to appear).
- Kim, H.J. and D. Siegmund (1989), "The likelihood ratio test for a change-point in simple linear regression". *Biometrika* **76**, 409–423.
- Nicholson, S.E. (1994), "Century-scale series of standardized annual departure of African rainfall". In *Trends'93: A Compendium of Data on Global Change*, T.A. Boden, D.P. Kaiser, R.J. Sepanski and F.W. Stoss (eds.) 952–962. ORNL/CDIAC - 65, Carbon Dioxide Information Analysis Center, Oak Ridge National Laboratory, Oak Ridge, Tenn., U.S.A.