

# EMPIRICKÝ PROCES

*Petr Lachout*

*ÚTIA ČSAV, Pod vodárenskou věží 4, 182 08 Praha 8*

V současné době se zabývám asymptotickými vlastnostmi empirických procesů typu

$$\left\{ \sum_{i=1}^n f_i(x_i, t); \alpha_j \leq t_j \leq \beta_j, j = 1, \dots, d \right\},$$

kde  $x_1, x_2, \dots, x_n$  jsou iid náhodné vektory a  
 $f_1, f_2, \dots, f_n$  jsou reálné funkce.

Pro speciální skokovitý typ funkcí  $f_1, f_2, \dots, f_n$  se mi podařilo odvodit konvergenční výsledky. Obecný výsledek je obsahem připravovaného článku. Mým příspěvkem do letošního ROBUSTu je aplikace dosažených výsledků na případ empirické distribuční funkce v modelu regrese.

Jsme v situaci  $y_i = x_i \beta + e_i, i \in N$ , kde

$y_1, y_2, \dots$  jsou pozorované náhodné vektory

$x_1, x_2, \dots$  nenáhodné matice,

$\beta$  je neznámý vektor parametrů,

$e_1, e_2, \dots$  jsou iid náhodné vektory s neznámou distribuční funkci  $F$ .

Naším úkolem je odhadnout neznámou distribuční funkci  $F$ . Sestavíme empirickou distribuční funkci  $F_n(t) = \frac{1}{n} \sum_{i=1}^n I[e_i < t]$ . Chyby  $e_1, e_2, \dots$  však neznáme a tak je musíme odhadnout. Sestrojíme nějaký odhad  $\hat{\beta}_n$  vektoru  $\beta$  na základě  $y_1, y_2, \dots, y_n, x_n$  a dostaneme

$$\hat{F}_n(t) = \frac{1}{n} \sum_{i=1}^n I[y_i - x_i \hat{\beta}_n < t] = \frac{1}{n} \sum_{i=1}^n I[e_i < t + x_i(\hat{\beta}_n - \beta)] .$$

Abychom vyšetřili chování procesu  $\hat{F}_n$ , je nutné se zabývat procesem s dalším parametrem  $s \in \mathbb{R}^k$ , kde  $k$  je rozměr vektoru  $\beta$ .

$$F_n(t, s) = \frac{1}{n} \sum_{i=1}^n I[e_i < t + \psi(n) x_i s] ,$$

kde  $\hat{\beta}_n = \beta = O_p(\psi(n))$ .

Dále budeme předpokládat  $\sup_{i=1}^{+\infty} \|x_i\| < +\infty$ ,  $\lim_{n \rightarrow +\infty} \sqrt{n} \psi(n) = \tilde{\psi} \in \mathbb{R}$

a symbolem  $\nabla f$  budeme označovat gradient funkce  $f$ , který je chápán jako řádek.

**Tvrzení 1:** Nechť  $F$  je spojitá v každém bodě  $t$ ,  $a_j \leq t_j \leq b_j, j = 1, \dots, d$ ; kde  $-\infty \leq a_j < b_j \leq +\infty$  jsou pevně zvolené. Potom

$$\left( \sqrt{n} (F_n(t, s) - F(t)) - \tilde{\psi} \nabla F(t) \bar{x}_n s, a_j \leq t_j \leq b_j, j = 1, \dots, d, s \in \mathbb{R}^k \right) \xrightarrow[n \rightarrow +\infty]{d} W ,$$

kde  $W$  je gausssovský proces s nulovou střední hodnotou a kovarianční funkci

$$H(t_1, s_1; t_2, s_2) = F(t_1 \wedge t_2) - F(t_1)F(t_2)$$

$$\text{a } \bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i .$$

Konvergence procesů v distribuci však nedává žádnou informaci o chování trajektorií procesu jako celku. Proto je třeba vyšetřit silnější typ konvergence, konvergenci v prostoru  $D$ . Zde však nastává nepřijemná technická potíž. Proces  $F_n(\dots)$  je prvkem prostoru  $D$  pouze v případě, že  $d = k$ ,  $x_i = \text{diag } \varrho_i$  a

$e_i$  jsou nezáporné vektory. Takový předpoklad je velmi svazující a připouští de facto pouze regresi s jedním parametrem.

Použijme proto approximaci

$$\frac{1}{n} \sum_{i=1}^n I[e_i < t + \psi(n) \bar{X}_i s - c\psi(n) Q_{i,n}] \leq F_n(t, s) \leq \frac{1}{n} \sum_{i=1}^n I[e_i < t + \psi(n) \bar{X}_i s + c\psi(n) Q_{i,n}], \quad t \in \mathbb{R}^d, -c \leq s_j \leq c, j = 1, \dots, k,$$

kde  $Q_{i,n}^j = \sum_{\ell=1}^k |x_i^\ell - \bar{x}_n^\ell|$ .

**Tvrzení 2:** Nechť  $-\infty \leq a_j < b_j \leq +\infty$ ,  $j = 1, \dots, d$  takové, že  $F$  má spojitý gradient v každém bodě  $t$ ,  $a_j \leq t_j \leq b_j$ ,  $j = 1, \dots, d$  a když nějaké  $a_j = -\infty$  nebo  $b_j = +\infty$ , pak  $\lim_{\substack{\|t\| \rightarrow +\infty \\ a_j \leq t_j \leq b_j, j=1, \dots, d}} \nabla F(t) = 0$ .

Existuje  $\epsilon, D > 0$  tak, že  $\forall B = \bigcup_{j=1}^d (a_j + r_j)$ ,  $a_j = -\infty$  nebo  $a_j \geq a_j$ ,  $a_j \leq r_j \leq b_j$  pro  $j = 1, \dots, d$  a  $\forall t \in \mathbb{R}^d$ ,  $\|t\| < \epsilon$  je  $F(B+t) \leq DF(B)$ .

Nechť navíc ještě  $F$  má spojité všechny jednorozměrné marginály. Potom

$$\left( \sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n I[e_i < t + c\psi(n) Q_{i,n}] - F(t) \right) + c\tilde{\psi}\nabla F(t)\bar{Q}_n; a_j \leq t_j \leq b_j, j=1, \dots, d \right) \xrightarrow[n \rightarrow +\infty]{} W \sim D \left( \bigcup_{j=1}^d (a_j, b_j) \right)$$

a

$$\left( \sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n I[e_i < t + c\psi(n) Q_{i,n}] - F(t) \right) - c\tilde{\psi}\nabla F(t)\bar{Q}_n; a_j \leq t_j \leq b_j, j=1, \dots, d \right) \xrightarrow[n \rightarrow +\infty]{} W \sim D \left( \bigcup_{j=1}^d (a_j, b_j) \right)$$

kde  $\bar{Q}_n = \frac{1}{n} \sum_{i=1}^n Q_{i,n}$

a  $W$  je gaussovský proces s nulovou střední hodnotou a kovarianční funkcí

$$H(t_1; t_2) = F(t_1 \wedge t_2) - F(t_1)F(t_2).$$

Konvergence odvozená v tvrzení 2 už dává jistou představu o chování trajektorií procesu  $F_n(\dots)$  a to například

$$\sup_{\substack{a_j \leq t_j < b_j \\ -c \leq s_i \leq c \\ j=1, \dots, d \\ i=1, \dots, k}} \sqrt{n} |F_n(t, s) - F(t)| = O_P(1)$$

když jsou splněny předpoklady tvrzení 2 pro  $a'_j := a_j - \eta$ ,  $b'_j = b_j + \eta$ , pro nějaké  $\eta > 0$ .

Pro původní problém to znamená, že když si předepíšeme  $\alpha \in (0, 1)$ , pak pro každé  $n$  najdeme  $c > 0$  tak, že

$$P(|\hat{\beta}_n - \beta| > c\psi(n)) \geq \alpha$$

$$\sup_{\substack{a_t \leq t_j \leq b_j \\ j=1, \dots, d}} \sqrt{n} |\hat{F}_n(t) - F(t)| = O_P(1).$$

$|\hat{\beta}_n - \beta| \leq c\psi(n)$

## LITERATURA

- [1] P. J. Bickel and M. J. Wichura: Convergence criteria for multiparameter stochastic processes and some application, Ann. Math. Statist. 42 (1971), 1656-1670.
- [2] P. Lachout: Billingsley-type tightness criteria for multiparameter stochastic processes, Kybernetika, 24, 5 (1988), 363-371.
- [3] G. Neuhaust: On weak convergence of stochastic process with multidimensional time parameter, Ann. Math. Statist. 42 (1971), 1285-1295.
- [4] M. L. Straf: A general Skorohod space and its applications to the weak convergence of stochastic processes with several parameters, Ph.D. Dissertation, Univ. of Chicago, 1969.