

# NAHODNE CENZOROVANI A JEHO APLIKACE

Jan HURT, MFF UK Praha

## 1a... Úvod

Předpokládáme, že sledujeme určitý prvek (výrobek, systém), který se během doby svého využití může porouchat. Označme  $X$  dobu do poruchy (tj. doby bezporuchového chodu) téhoto prvku. Z povahy věci vyplývá, že  $X$  je nezáporná náhodná veličina. Označme  $f(x; \theta)$  její distribuční funkci, která závisí na neznámém, obecně vektorovém parametru  $\theta$ . Předpokládáme dále, že  $f(x; \theta)$  je odpovídající hustota. V teorii spolehlivosti se používá též funkce spolehlivost  $R(x; \theta) = 1 - F(x; \theta)$  znamenající pravděpodobnost bezporuchového chodu na časovém intervalu  $[0, x]$  a intenzita poruch  $r(x; \theta) = f(x; \theta)/R(x; \theta)$  vystihující dobu chování chvostu rozdělení. Statistická analýza se pak soustředí na 1) odhad funkce  $R$ , 2) odhad parametrů, 3) odhad charakteristik spolehlivosti, tj. parametrických funkcí (střední doba do poruchy, 100 $\gamma$ -ní kvantil doby do poruchy, t.j. tzv. 100(1- $\gamma$ )-ní život apod.). V teorii spolehlivosti se zabýváme většinou chováním chvostu rozdělení, z čehož vyplývá, že parametrické metody převažují.

## 2a... Pravděpodobnostní modely

Podobnou úlohu jako hraje v klasické parametrické analýze normální rozdělení, hraje v teorii spolehlivosti exponenciální rozdělení  $Exp(\theta)$  s funkcí spolehlivosti  $R(x; \theta) = e^{-x/\theta}$ . Jeho charakteristickou vlastností je, že má konstantní intenzitu poruch  $r(x; \theta) = 1/\theta$ , což odráží skutečnost, že exponenciální rozdělení "nemá paměť". Velice oblíbené a užívané je Weibullovo rozdělení  $W(\theta, \beta)$  s funkcí spolehlivosti  $R(x; \theta) = \exp(-x/\theta)^\beta$ . Lze jím dobře vystihnout rozdělení doby do poruchy s monotonou intenzitou poruch. V závislosti na parametru  $\beta$  je intenzita poruch klesající ( $\beta < 1$ ), konstantní ( $\beta = 1$ ), rostoucí konkávní ( $1 < \beta < 2$ ), rostoucí kónvexní ( $\beta > 2$ ). Dále jsou užívána rozdělení normální, logaritmicko-normální a rozdělení gamma.

## 3a... Výběrové plány

V čase  $t=0$  začneme pozorovat  $n$  identických prvků. Označme jejich dobu do poruchy  $x_1, \dots, x_n$ . Některá možná uspořádání experimentu jsou tato:

3.1... Úplný výběr: Experiment se provádí tak dlouho, dokud se všechny prvky neporouchají. Výsledkem experimentu je náhodný výběr  $x_1, \dots, x_n$ .

3.2... Cenzorování typu I (cenzorování řadou): Předpisuje se  $T > 0$  zvané časový cenzor. Experiment se ukončí v okamžiku  $T$  bez ohledu na to, kolik prvků se porouchalo. Označme  $x_{(1)} \leq \dots \leq x_{(n)}$  uspořádaný náhodný výběr z  $x_1, \dots, x_n$ . Výsledkem experimentu je potom prvních  $r$  hodnot pořadkových statistik  $x_{(1)} \leq \dots \leq x_{(r)} \leq T$  a informace  $x_{(r+1)} \geq I$ . Zde je  $r$  náhodná veličina.

3.3... Cenzorování typu II (cenzorování poruchou): Předpisuje se přirozeně číslo  $r$ . Experiment se ukončí v okamžiku poruchy  $r$ -tého prvku. Výsledkem experimentu je prvních  $r$  hodnot pořadkových statistik  $x_{(1)} \leq \dots \leq x_{(r)}$ . Doba trvání experimentu je náhodná veličina.

3.4. Náhodné cenzorování. Vzniklo při studiu spolehlivosti složitých systémů a v lékařském výzkumu. Objekty  $1, \dots, n$  jsou pozorovány do okamžiků  $T_1, \dots, T_n$ , které jsou svou povahou náhodné. Jednoduchý přístup spočívá v převedení na cenzorování typu I s časovým cenzorem  $T = \min(T_1, \dots, T_n)$ . To však není příliš ekonomické. Alternativní přístup spočívá v tom, že spolu s dobou do poruchy  $X$  uvažujeme náhodnou veličinu  $T$ , tzv. časový censor. Položme  $I_i = 1$ , je-li  $X_i < T_i$  a  $I_i = 0$ , je-li  $X_i \geq T_i$ . Hodnota  $I_i = 1$  odpovídá tomu, že i-té pozorování není cenzorované! Položme  $W_i = \min(X_i, T_i)$ . Výsledkem experimentu je nyní (hodnota  $I_i = 0$  tomu, že i-té pozorování je cenzorované.)

$$(W_1, I_1), \dots, (W_n, I_n),$$

tj. dvourozměrný (úplný) náhodný výběr.

#### 4. Metody odhadu

Metody odhadu jsou v zásadě parametrické a neparametrické, přičemž parametrické metody z výše zmíněných důvodů převládají. Největší význam z parametrických metod má metoda maximální věrohodnosti. Uveďme věrohodnostní funkce pro výběrové plány z odstavce 3. Pro cenzorování typu I je věrohodnostní funkce

$$f(x_{(1)}, \dots, x_{(r)}, r) = \frac{n!}{(n-r)!} \prod_{i=1}^r f(x_{(i)}) R^{n-r}(T),$$

$$0 \leq x_{(1)} \leq \dots \leq x_{(r)} \leq T,$$

$$r = 0, 1, \dots, n.$$

(Pro jednoduchost zápisu zde i v dalším nevyznačujeme závislost na parametru  $\theta$ ). Pro cenzorování typu II je věrohodnostní funkce

$$f(x_{(1)}, \dots, x_{(r)}) = \frac{n!}{(n-r)!} \prod_{i=1}^r f(x_{(i)}) R^{n-r}(x_{(r)}), \quad 0 \leq x_{(1)} \leq \dots \leq x_{(r)}.$$

Předpokládejme nyní, že časový censor  $T$  má rozdělení s distribuční funkcí  $G(t; \theta)$  a hustotou  $g(t; \theta)$  ( $\theta$  je obecně vektorový parametr!), že  $X$  a  $T$  jsou nezávislé. Naležeme nyní rozdělení vektoru  $(W_i, I_i)$ :

$$P(W_i < w, I_i = 1) = P(X_i < w, X_i < T_i) = \int_{x < w, x < t} dF(x) dG(t) = F(w) - \int_0^w f(x) G(x) dx,$$

analogicky

$$P(W_i < w, I_i = 0) = G(w) - \int_0^w F(x) g(x) dx,$$

z čehož

$$\frac{\partial}{\partial w} P(W_i < w, I_i = 1) = f(w)(1-G(w))$$

$$\frac{\partial}{\partial w} P(W_i < w, I_i = 0) = g(w)(1-F(w)).$$

Definujme funkci  $h$  takto:

$$\begin{aligned} h(u, v) &= 0 & u \leq 0 \\ &= g(u)(1-F(u)) & u > 0, v = 0 \\ &= f(u)(1-G(u)) & u > 0, v = 1. \end{aligned}$$

Distribuční funkce náhodného vektoru  $(W_i, I_i)$  je potom

$$H(w, y) = \int_0^w \int_0^y h(u, v) d\mu(u), d\lambda(v),$$

kde  $\lambda$  je čítací míra přiřazující bodům 0 a 1 míru 1 a  $\mu$  je Lebesguerova míra na přímce. funkce  $h$  je zřejmě hustota vzhledem k součinné míře  $\mu \times \lambda$ . Věrohodnostní funkce je potom

$$f(u_1, t_1), \dots, (u_n, t_n)) = \prod_{i=1}^n h(u_i, t_i).$$

je to tedy věrohodnostní funkce dvouzměrného (nezávislého) náhodného výběru a je možno použít standardních metod.

Příklad 4a1 Předpokládejme, že  $X$  má rozdělení  $\text{Exp}(1/\alpha)$  a  $T$  rozdělení  $\text{Exp}(1/\beta)$ , tj. rozdělení s hustotami  $f(x) = \alpha e^{-\alpha x}$  a  $g(t) = \beta e^{-\beta t}$ . Bez újmy na obecnosti předpokládejme, že  $u_1 = x_1, \dots, u_r = x_r, u_{r+1} = t_{r+1}, \dots, u_n = t_n$ . Řešením věrohodnostních rovnic je

$$\hat{\alpha} = \frac{r}{\sum_1^r x_i + \sum_{r+1}^n t_i} \quad , \quad \hat{\beta} = \frac{n-r}{\sum_1^r x_i + \sum_{r+1}^n t_i} .$$

Fisherova informační matici je

$$I(\alpha, \beta) = \begin{pmatrix} \frac{1}{\alpha(\alpha+\beta)} & 0 \\ 0 & \frac{1}{\beta(\alpha+\beta)} \end{pmatrix} .$$

V tomto případě je možné ověřit, že jsou splněny podmínky regularity a tudíž je možné použít výsledků o asymptotické normalitě maximálně věrohodných odhadů.

Příklad 4a2 Předpokládejme, že  $X$  má rozdělení  $W(a^{-1/\beta}, \beta)$  a  $T$  rozdělení  $\text{Exp}(1/b)$ . Soustava věrohodnostních rovnic pak zní

$$(4.1) \quad \hat{a} = \frac{n-r}{\sum_1^r x_i + \sum_{r+1}^n t_i}$$

$$(4.2) \quad \hat{b} = \frac{r}{\sum_1^r x_i^{\hat{a}} + \sum_{r+1}^n t_i^{\hat{a}}}$$

$$(4.3) \quad \hat{\beta} = \frac{r}{\hat{a} \sum_1^r x_i^{\hat{a}} \ln x_i + \hat{a} \sum_{r+1}^n t_i^{\hat{a}} \ln t_i - \sum_1^r x_i} .$$

Soustava se řeší tak, že se za  $\hat{a}$  v (4.2) dosadí ze (4.2) čímž se (4.3) stane neelineární rovnici pro jednu neznámou  $\hat{\beta}$ . Numerická zkouška ukazuje, že velmi efektivní metoda pro řešení této rovnice je metoda Newton-Raphsonova. Za počáteční řešení se doporučuje vzít  $\beta_0 = 1.5$ . Přesnost řádu  $10^{-4}$  se obvykle dosáhne již po několika iteracích. Získaná hodnota  $\hat{\beta}$  se dosadí do (4.2). O vlastnostech takto získaných odhadů není pedagogicky jako v obecném případě mnoho známo.

Dalšími užívanými metodami jsou metoda nejménších čtverců a metoda kvantilových odhadů.

Na závěr uvedeme ještě neparametrický Kaplan-Meierův odhad funkce spolehlivosti  $R(x)$ . Nechť  $u_{(1)} < \dots < u_{(n)}$  je uspořádaný náhodný výběr z  $u_1, \dots, u_n$ . Pak

$$\hat{R}(x) = \prod_{j=1}^k \left[ \frac{n-j}{n-j+1} \right]^{1/j} \quad , \quad u_{(k+1)} \leq x < u_{(k)} \\ = 0, \quad x \geq u_{(n)} .$$

Ukazuje se, že  $\hat{R}(x)$  je silně konsistentní a asymptoticky normální, a že  $\hat{R}(x)$  je maximálně věrohodný odhad ve třídě všech distribucí. Výhodou tohoto odhadu je, že je neparametrický, poměrně jednoduše se počítá a umožňuje výpočet některých charakteristik spolehlivosti (např. střední hodnoty doby do poruchy). Nevhodou je nemožnost provést statistické závěry pro hodnoty větší než  $u_{(n)}$  a jistá ztráta eficiency ve srovnání s odhady parametrickými.

## Literatura

- [1] Breslow,N. - Crowley,J.: A large sample study of the life table and product limit estimates under random censorship. Annals of Statistics 2 (1974), 437-453.
- [2] Gill,R.D. : Testing with replacement and the product limit estimator. Annals of Statistics 9 (1974), 853-860.
- [3] Roubík,F. : Spolehlivost systémů. Diplomová práce MFF UK Praha, 1980.