

M7988 Modely ztrát v neživotním pojištění

Parametrický model a úlohy matematické statistiky

Model: X_1, \dots, X_n je náhodný výběr z rozdělení s distribuční funkcí $F(x, \theta)$. Tuto distribuční funkci známe až na neznámý parametr $\theta \in \Theta \subset \mathbb{R}^p$.

Úlohy matematické statistiky:

- Bodový odhad parametru θ .
- Intervalový odhad parametru θ .
- Testy hypotéz o parametru θ .

Někdy nás místo samotného parametru θ zajímá nějaká jeho funkce, tzv. *parametrická funkce* $\gamma(\theta)$, kde $\gamma : \Theta \rightarrow \mathbb{R}$ je reálná funkce.

Bodové odhady

Řekneme, že $T : \mathbb{R}^n \rightarrow \mathbb{R}$ je bodový odhad parametru $\theta \in \Theta \subset \mathbb{R}$, jestliže T je měřitelnou funkcí náhodného výběru X_1, \dots, X_n . Tedy $T = T(X_1, \dots, X_n)$ je náhodná veličina.

Vlastnosti bodových odhadů:

- T je nestranný odhad parametru θ , jestliže $\mathbb{E} T = \theta$ pro všechna $\theta \in \Theta$.
- T je konzistentní odhad parametru θ , jestliže $T = T(X_1, \dots, X_n) \rightarrow \theta$ v pravděpodobnosti pro $n \rightarrow \infty$ pro všechna $\theta \in \Theta$.

Který odhad je nejlepší?

- Nechť T_1, T_2 jsou dva nestranné odhady parametru θ . Řekneme, že T_1 je více eficientní (*lepší*) než T_2 , jestliže $D T_1 \leq D T_2$ pro všechna $\theta \in \Theta$.
- Nechť T je nestranný odhad parametru θ . Řekneme, že T je nejlepší nestranný odhad parametru θ , jestliže $D T \leq D T^*$ pro všechna $\theta \in \Theta$ a pro všechny nestranné odhady T^* .
- Nechť T je odhad parametru θ . Střední čtvercovou (kvadratickou) chybu odhadu definujeme jako $MSE(T) = \mathbb{E}(T - \theta)^2$.
- Je-li T je nestranný odhad parametru θ , pak $MSE(T) = D T$.
- Nechť T_1, T_2 jsou dva odhady parametru θ . Řekneme, že T_1 je více eficientní (*lepší*) než T_2 , jestliže $MSE(T_1) \leq MSE(T_2)$ pro všechna $\theta \in \Theta$.
- (Stejnoměrně) nejlepší odhad parametru θ neexistuje.

Metoda momentů

- Dále předpokládejme, že neznámý parametr θ je p -rozměrný ($\Theta \subset \mathbb{R}^p$).
- Nechť existují obecné momenty $\mu'_k = \mu'_k(\theta) = \mathbb{E}X_1^k$ pro $k = 1, \dots, p$.
- Označme jejich výběrové protějšky $M'_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ pro $k = 1, 2, \dots$.
- Řekneme, že $\tilde{\theta}$ je odhad parametru θ metodou momentů, jestliže $\mu'_k(\tilde{\theta}) = M'_k$ pro $k = 1, \dots, p$.
- Je-li řešení předchozí soustavy nejednoznačné (rovnice jsou lineárně závislé), přidáme další rovnici pro $k = p + 1$, pokud ovšem existuje příslušný moment.

Metoda maximální věrohodnosti

- Označme sdruženou hustotu náhodného vektoru $(X_1, \dots, X_n)'$ jako

$$L(\theta) = \prod_{i=1}^n f(x_i, \theta).$$

- $L(\theta) = L(\theta, x_1, \dots, x_n)$ se nazývá věrohodnostní funkce.
- $\hat{\theta}$ se nazývá maximálně věrohodným odhadem parametru θ , jestliže $L(\hat{\theta}) \geq L(\theta)$, $\forall \theta \in \Theta$.
- $\hat{\theta} = \arg \max\{L(\theta); \theta \in \Theta\}$.
- $I(\theta) = \log L(\theta) = \sum_{i=1}^n \log f(x_i, \theta)$ se nazývá logaritmická věrohodnostní funkce.
- $\hat{\theta} = \arg \max\{I(\theta); \theta \in \Theta\}$.

Vlastnosti maximálně věrohodných odhadů

- Za mírných předpokladů (podmínky regularity) jsou maximálně věrohodné odhady asymptoticky nestranné, konzistentní a mají asymptoticky normální rozdělení.
- $\sqrt{n}(\hat{\theta} - \theta)$ má asymptoticky rozdělení $\mathcal{N}_p(\mathbf{0}, \mathbf{J}^{-1}(\theta))$.

•

$$\mathbf{J}(\theta) = \left(\mathbb{E} \frac{\partial \log f(X_1, \theta)}{\partial \theta_i} \frac{\partial \log f(X_1, \theta)}{\partial \theta_j} \right)_{i,j=1}^p$$

je Fisherova informační matice o parametru θ příslušná X_1 .

•

$$\mathbf{J}(\theta) = -\mathbb{E} \left(\frac{\partial^2 \log f(X_1, \theta)}{\partial \theta_i \partial \theta_j} \right)_{i,j=1}^p.$$

- $\hat{\theta} \approx \mathcal{N}_p(\theta, \frac{1}{n} \mathbf{J}^{-1}(\theta))$.

Metoda maximální věrohodnosti pro intervalová data

- Obor hodnot náhodného výběru je rozdělen na intervaly $(c_0, c_1], (c_1, c_2], \dots, (c_{k-1}, c_k]$.
- Označme n_j počet pozorování, které leží v intervalu $(c_{j-1}, c_j]$.
- Pravděpodobnost, že dané pozorování X_i leží v intervalu $(c_{j-1}, c_j]$ je

$$P(X_i \in (c_{j-1}, c_j]) = F(c_j, \theta) - F(c_{j-1}, \theta).$$

- $L(\theta) = \prod_{i=1}^n P(X_i \in (c_{j-1}, c_j]) = [F(c_1, \theta) - F(c_0, \theta)]^{n_1} \cdot [F(c_2, \theta) - F(c_1, \theta)]^{n_2} \cdot \dots \cdot [F(c_{k-1}, \theta) - F(c_k, \theta)]^{n_k} = \prod_{j=1}^k [F(c_j, \theta) - F(c_{j-1}, \theta)]^{n_j}$.
- $I(\theta) = \log L(\theta) = \sum_{j=1}^k n_j \log[F(c_j, \theta) - F(c_{j-1}, \theta)]$ se nazývá logaritmická věrohodnostní funkce.
- $\hat{\theta} = \arg \max\{I(\theta); \theta \in \Theta\}$.

Maximálně věrohodné odhady pro parametrickou funkci γ

- Nechť $\gamma : \Theta \rightarrow \Theta^*$ je prostá parametrická funkce.
- Funkci $\tilde{L}(\theta^*) = \prod_{i=1}^n f(x_i, \gamma^{-1}(\theta^*))$ pro $\theta^* \in \Theta^*$ nazveme věrohodnostní funkcí indukovanou parametrickou funkcí γ .
- $\hat{\theta}^*$ je maximálně věrohodný odhad parametrické funkce $\gamma(\theta) = \theta^*$, jestliže $\tilde{L}(\hat{\theta}^*) \geq \tilde{L}(\theta^*)$ pro všechna $\theta^* \in \Theta^*$.
- Zehnaova věta (princip invariance MLE): Je-li $\hat{\theta}$ maximálně věrohodný odhad parametru θ , pak $\gamma(\hat{\theta})$ je maximálně věrohodný odhad parametrické funkce $\gamma(\theta)$.

Delta metoda

Theorem

Nechť $\{\mathbf{X}_n\}_{n=1}^{\infty}$ je posloupnost p -rozměrných náhodných vektorů takových, že $\sqrt{n}(\mathbf{X}_n - \boldsymbol{\theta})$ má asymptoticky normální rozdělení $\mathcal{N}_p(\mathbf{0}, \boldsymbol{\Sigma})$. Dále bud' $\gamma : \mathbb{R}^p \rightarrow \mathbb{R}$ měřitelná funkce, která má totální diferenciál v bodě $\boldsymbol{\theta}$. Pak platí: $\sqrt{n}(\gamma(\mathbf{X}_n) - \gamma(\boldsymbol{\theta}))$ má asymptoticky normální rozdělení $\mathcal{N}(0, \sigma^2)$, kde $\sigma^2 = \nabla \gamma'(\boldsymbol{\theta}) \boldsymbol{\Sigma} \nabla \gamma(\boldsymbol{\theta})$, kde

$$\nabla \gamma(\boldsymbol{\theta}) = \left(\frac{\partial \gamma(\boldsymbol{\theta})}{\partial \theta_1}, \dots, \frac{\partial \gamma(\boldsymbol{\theta})}{\partial \theta_p} \right)'$$

je gradient funkce γ v bodě $\boldsymbol{\theta}$.

Aplikace na MLE

- Víme, že za mírných předpokladů (podmínky regularity) platí:
 $\sqrt{n}(\hat{\theta} - \theta)$ má asymptoticky rozdělení $\mathcal{N}_p(\mathbf{0}, \mathbf{J}^{-1}(\theta))$.
- Aplikací delta metody dostaneme, že za mírných předpokladů platí:
 $\sqrt{n}(\gamma(\hat{\theta}) - \gamma(\theta))$ má asymptoticky rozdělení
 $\mathcal{N}(0, \nabla\gamma'(\theta)\mathbf{J}^{-1}(\theta)\nabla\gamma(\theta))$.
- $\gamma(\hat{\theta}) \approx \mathcal{N}(\gamma(\theta), \frac{1}{n}\nabla\gamma'(\theta)\mathbf{J}^{-1}(\theta)\nabla\gamma(\theta))$.
- Je-li θ jednorozměrný parametr, pak $\gamma(\hat{\theta}) \approx \mathcal{N}\left(\gamma(\theta), \frac{[\gamma'(\theta)]^2}{nJ(\theta)}\right)$.

Metoda minimálního χ^2

- ① Rozděl obor hodnot náhodné veličiny X_i na k po dvou disjunktních intervalů B_1, \dots, B_k .
- ② Označ $Y_j = \sum_{i=1}^n \mathbb{I}\{X_i \in B_j\}$ pro $j = 1, \dots, k$ počet pozorování, které padnou do intervalu B_j .
- ③ Spočítej teoretickou pravděpodobnost, že náhodná veličina X_i nabude hodnoty z intervalu B_j = pravděpodobnost, že dané pozorování padne do intervalu B_j : $p_j(\theta) = P(X_i \in B_j) = \int_{B_j} f(x, \theta)$.
- ④ Porovnej očekávaný a skutečný (pozorovaný) počet pozorování v jednotlivých intervalech B_j pomocí Pearsonovy χ^2 statistiky testu dobré shody:

$$\chi^2(\theta) = \sum_{j=1}^k \left(\frac{Y_j - np_j(\theta)}{\sqrt{np_j(\theta)}} \right)^2.$$

- ⑤ Odhad parametru θ metodou minimálního χ^2 minimalizuje $\chi^2(\theta)$ přes všechny hodnoty $\theta \in \Theta$, tj. $\tilde{\theta} = \arg \min \{\chi^2(\theta), \theta \in \Theta\}$.

Metoda minimálního χ^2 - poznámky



$$\chi^2(\theta) = \sum_{j=1}^k \frac{Y_j^2}{np_j(\theta)} - n.$$

- Intervaly B_j by se měly volit stejně pravděpodobné, tj. $p_j(\tilde{\theta}) = \frac{1}{k}$ pro $j = 1, \dots, k$.
- Volba počtu tříd k - heuristická pravidla, např. $k \doteq 15 \left(\frac{n}{100}\right)^{2/5}$, nebo $k \doteq 2n^{2/5}$.

Bayesovské odhady (Bayesovská statistika)

- Kombinuje informaci obsaženou v datech (parametrický model) s apriorní informací o neznámém parametru θ (zkušenosti, domněnky, dřívější pozorování).
- Závěry (odhadů) vyvozuje až z aposteriorního rozdělení.
- Idea: Naše informace o hodnotě neznámého parametru může být vyjádřena pomocí pravděpodobnostního rozdělení, tj. neznámý parametr θ považujeme za náhodnou veličinu.

Matematický model

- X_1, \dots, X_n je náhodný výběr z rozdělení s hustotou $f(x, \theta)$, kde $\theta \in \Theta$.
- θ je nyní náhodná veličina s hustotou $q(\theta)$.
- Označme podmíněnou hustotu náhodného vektoru $(X_1, \dots, X_n)'$ při dané hodnotě parametru θ jako $r(\mathbf{x}|\theta) = \prod_{i=1}^n f(x_i, \theta)$, kde $\mathbf{x} = (x_1, \dots, x_n)'$.

Theorem (Bayesova věta)

Pro podmíněnou hustotu náhodné veličiny θ při daných hodnotách $\mathbf{X} = \mathbf{x}$ platí:

$$\pi(\theta|\mathbf{x}) = \begin{cases} \frac{r(\mathbf{x}|\theta)q(\theta)}{\int_{\Theta} r(\mathbf{x}|\theta)q(\theta)d\theta}, & \text{pokud } \int_{\Theta} r(\mathbf{x}|\theta)q(\theta)d\theta \neq 0, \\ 0, & \text{jinak.} \end{cases}$$

- $q(\theta)$ se nazývá apriorní hustota - vyjadřuje informaci o parametru θ ještě před realizací náhodného výběru \mathbf{X} .
- $\pi(\theta|\mathbf{x})$ se nazývá aposteriorní hustota - vyjadřuje informaci o parametru θ až po realizaci náhodného výběru \mathbf{X} .
- Při Bayesovském přístupu používáme kromě dat (realizace náhodného výběru) ještě informaci o parametru θ nezávisle na našich datech.
- Tato informace může mít objektivní i subjektivní charakter.

Volby apriorního rozdělení

- Pokud máme informace (výsledky) z minulosti
 - přesná znalost rozdělení
 - jádrové odhady hustoty
 - parametrický model
- Pokud nemáme informace (výsledky) z minulosti
 - neinformativní (rovnoměrné) rozdělení
 - Jeffreysovo apriorní rozdělení $q(\theta) \sim \sqrt{|\mathbf{J}(\theta)|}$
 - konjugované apriorní rozdělení

Bodové odhady

- Definujme ztrátovou funkci $L(\theta, \hat{\theta})$ - ztráta, kterou utrpíme, když odhadneme parametr θ pomocí odhadu $\hat{\theta}$.
- Dále definujme bayesovské riziko (průměrná aposteriorní ztráta):

$$r(\theta) = \int_{\Theta} L(\theta, \hat{\theta}) \pi(\theta | \mathbf{x}) d\theta.$$

- Hledáme odhad, který minimalizuje bayesovské riziko.
- Pro kvadratickou ztrátovou funkci $L(\theta, \hat{\theta}) = (\theta - \hat{\theta})^2$ je bayesovským odhadem aposteriorní střední hodnota, tj. $\hat{\theta} = \mathbb{E}(\theta | X_1, \dots, X_n)$.
- Pro absolutní ztrátovou funkci $L(\theta, \hat{\theta}) = |\theta - \hat{\theta}|$ je bayesovským odhadem aposteriorní medián, tj. $\hat{\theta} = \text{med}(\theta | X_1, \dots, X_n)$.
- Pro 0-1 ztrátovou funkci $L(\theta, \hat{\theta}) = \mathbb{I}\{\theta \neq \hat{\theta}\}$ je bayesovským odhadem aposteriorní modus, tj. $\hat{\theta} = \arg \max \pi(\theta | X_1, \dots, X_n)$.

Intervalové odhady

Definition

100(1 - α)% věrohodnostní interval pro parametr θ je takový interval $[a, b] = [a(X_1, \dots, X_n), b(X_1, \dots, X_n)]$, pro který

$$P(a \leq \theta \leq b | \mathbf{X}) = 1 - \alpha.$$

- Equal tail - je takový interval $[a, b]$, kde a je $\alpha/2$ -kvantil aposteriorního rozdělení $\theta | \mathbf{X}$ a b je $1 - \alpha/2$ -kvantil aposteriorního rozdělení $\theta | \mathbf{X}$.
- HPD (interval o největší aposteriorní hustotě) je takový interval $[a, b]$ takový, že $\pi(\theta | \mathbf{x}) \geq c$ pro všechna $\theta \in [a, b]$ a $c > 0$ je nejmenší číslo takové, že $P(\pi(\theta | \mathbf{x}) \geq c) = 1 - \alpha$.

Theorem

Je-li $\pi(\theta | \mathbf{x})$ spojitá a unimodální, pak HPD interval je nejkratší mezi všemi věrohodnostními intervaly.

Predikce budoucího pozorování

- Nechť se budoucí pozorování X_{n+1} řídí stejným modelem jako X_1, \dots, X_n - tedy má hustotu $f(x, \theta)$.
- Chceme predikovat(předpovídat) jeho budoucí hodnotu.
- S pomocí Bayesovy věty můžeme odvodit aposteriorní prediktivní hustotu

$$f(x_{n+1}|\mathbf{x}) = \int_{\Theta} f(x_{n+1}, \theta) \pi(\theta|\mathbf{x}) d\theta.$$

Model selection (výběr modelu)

- ① Je náš model vhodný? Popisuje dobře naše data?
- ② Máme-li více modelů, který z nich je nejlepší? Který máme použít?

Grafické metody pro posouzení vhodnosti modelu

- jsou založené na porovnání teoretického a empirického rozdělení
- porovnání teoretické a empirické distribuční funkce (hustoty) v jednom grafu
- Q-Q plot
- P-P plot

Kolmogorovův - Smirnovův test

- Nulová hypotéza $H_0: F = F^*$, kde F^* je známá distribuční funkce.
- Definujme empirickou distribuční funkci

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}_{\{X_i \leq x\}}.$$

- Testová statistika $D_n = \max_{x \in \mathbb{R}} \{|\hat{F}_n(x) - F^*(x)|\}$.
- Za platnosti H_0 má $\sqrt{n}D_n$ asymptotické rozdělení stejné jako $\sup_{t \in [0,1]} |B(t)|$, kde $B(t)$ je Brownův most v $\mathcal{C}(0, 1)$.
- Test se dá použít jen, když F^* je plně specifikována modelem.
Pokud jsou k jejímu odhadu použita data, test nefunguje - je příliš konzervativní - nutná jeho modifikace, např. Lillieforsova.

Pearsonův χ^2 test dobré shody

- Nulová hypotéza $H_0: F = F^*$, kde F^* je známá distribuční funkce.
- Definujme si intervaly $(c_{j-1}, c_j]$, $j = 1, \dots, k$.
- Označme n_j počet pozorování, které padnou do intervalu $(c_{j-1}, c_j]$ pro $j = 1, \dots, k$.
- Určíme očekávaný počet pozorování, které by měly padnout do intervalu $(c_{j-1}, c_j]$:

$$e_j = np_j = nP(X_1 \in (c_{j-1}, c_j]) = n(F^*(c_j) - F^*(c_{j-1})).$$

- Testová statistika

$$\chi^2 = \sum_{j=1}^k \frac{(e_j - n_j)^2}{e_j}.$$

- χ^2 má za platnosti nulové hypotézy asymptoticky χ^2 rozdělení s $k - 1$ stupni volnosti.

Modifikace Pearsonova χ^2 testu dobré shody

- Nulová hypotéza H_0 : F je distribuční funkce nějakého rozdělení.
- Nejprve z dat odhadneme neznámý p -rozměrný parametr θ a postupujeme stejně jako v předchozím.
- Upravená testová statistika má za platnosti nulové hypotézy asymptoticky χ^2 rozdělení s $k - 1 - p$ stupni volnosti.

Volba tříd:

- $p_j = \frac{1}{k}$ pro $j = 1, \dots, k$.
- Heuristická pravidla pro počet tříd – $k \doteq 2n^{2/5}$, nebo $k \doteq 15(n/100)^{2/5}$.

Výběr modelu z několika kandidátů

Princip Occamovy břitvy - vybíráme co nejjednodušší vhodný model.

- ① Judgement-based přístup - založený na subjektivním úsudku analytika
 - rozhodnutí založené na různých grafech či tabulkách (tail vs. mod fit)
 - rozhodnutí založené na předchozí zkušenosti (Paretovo rozdělení pro výši příjmů, Benfordovo pro četnost prvních číslic)
 - model je plně určen situací, kterou má popisovat (házení mincí - alternativní rozdělení)
- ② Score-based přístup - založený na číselných charakteristikách
 - nejnižší hodnota statistiky nějakého statistického testu
 - nejvyšší p -hodnota nějakého statistického testu
 - nejvyšší hodnota věrohodnosti
 - nejvyšší hodnota nějaké penalizované funkce, např. AIC, BIC