

Štatistická inferencia

Asymptotické vlastnosti odhadov

Stanislav Katina¹

¹Ústav matematiky a štatistiky, Masarykova univerzita
Honorary Research Fellow, The University of Glasgow

11. decembra 2018

Štatistická inferencia o θ_* sa vykonáva na základe odhadu $\hat{\theta} = \hat{\theta}_n$. Podobne štatistická inferencia o $g(\theta_*)$ sa vykonáva na základe odhadu $g(\hat{\theta}_n)$. **Bodový odhad** parametrickej funkcie $g(\theta)$ je štatistika $T_n = T(X_1, X_2, \dots, X_n)$ nadobúdajúca hodnoty blízko $g(\theta)$. Nech $T_n = g(\hat{\theta}_n)$ je nejaký odhad $g(\theta)$, podobne $T_n = \hat{\theta}_n$ je nejaký odhad θ .

Potom môžeme definovať nasledovné typy konvergencií pre T_n (čo platí aj pre $g(\theta) = \theta$):

1 / 12

Stanislav Katina

Štatistická inferencia

Asymptotické vlastnosti odhadov

Konvergenencie

1 konvergenca skoro všade

$$\Pr\left(\lim_{n \rightarrow \infty} T_n = g(\theta)\right) = 1, \text{ pre } \forall \theta \in \Theta,$$

2 konvergenca v kvadratickom strede

$$T_n \xrightarrow{n \rightarrow \infty} g(\theta) \Leftrightarrow E_\theta \left[(T_n - g(\theta))^2 \right] \xrightarrow{n \rightarrow \infty} 0, \text{ pre } \forall \theta \in \Theta,$$

3 konvergenca podľa pravdepodobnosti (ozn. \xrightarrow{P})

$$\lim_{n \rightarrow \infty} (\Pr(|T_n - g(\theta)| \geq \varepsilon)) = 0, \text{ pre } \varepsilon > 0, \text{ pre } \forall \theta \in \Theta,$$

4 konvergenca v distribúcii (ozn. \xrightarrow{D})

$$\lim_{n \rightarrow \infty} F_n(x) = F_X(x)$$

vo všetkých bodoch x , kde $F_n(x)$ je empirická distribučná funkcia a $F_X(x)$ je spojitá distribučná funkcia.

3 / 12

Stanislav Katina

Štatistická inferencia

2 / 12

Stanislav Katina

Štatistická inferencia

Asymptotické vlastnosti odhadov

Vlastnosti odhadov

Nech X_1, X_2, \dots, X_n je náhodný výber z rozdelenia F_* , $g(\theta)$ je parametrická funkcia a T_n, T_1 a T_2 sú štatistiky, $E[T_n]$ je stredná hodnota a $\text{Var}[T_n]$ rozptyl štatistiky T_n .

- hovoríme, že štatistika T_n je **nevychýlený odhad** parametrickej funkcie $g(\theta)$, ak $E[T_n] = g(\theta), \forall \theta \in \Theta$, t.j. odhad T_n nesmie parametrickú funkciu *systematicky nadhodnocovať* alebo *podhodnocovať* – ak táto podmienka nie je splnená, hovoríme o **vychýlenom odhade**,
- ak T_1, T_2 sú dva nevychýlené odhady tej istej parametrickej funkcie $g(\theta)$, potom T_1 je **lepší odhad** $g(\theta)$ ako T_2 , ak $\text{Var}[T_1] < \text{Var}[T_2], \forall \theta \in \Theta$, t.j. ak existuje odhad s menším rozptylom, je potrebné ho v štatistickej inferencii použiť namiesto odhadu s väčším rozptylom (to môžeme docieľiť optimalizáciou dizajnu experimentu vhodnou voľbou bodov, v ktorých budeme merať),

4 / 12

Stanislav Katina

Štatistická inferencia

- T_n sa nazýva **asymptoticky nevychýlený odhad** $g(\theta)$, ak platí $\lim_{n \rightarrow \infty} E[T_n] = g(\theta)$, t.j. s rastúcim rozsahom náhodného výberu n , klesá výchylka odhadu (to môžeme doceliť optimalizáciou dizajnu experimentu vhodnou voľbou n),
- T_n sa nazýva **konzistentný odhad** $g(\theta)$, ak platí $\lim_{n \rightarrow \infty} \Pr(|T_n - g(\theta)| \geq \epsilon) = 0$, t.j. s rastúcim rozsahom náhodného výberu n klesá pravdepodobnosť, že odhad sa bude realizovať ďaleko od $g(\theta)$ (to môžeme doceliť optimalizáciou dizajnu experimentu vhodnou voľbou n),

- T_n sa nazýva **konzistentný a asymptoticky efektívny (eficientný, výdatný) odhad** $g(\theta)$, ak platí

$(T_n - g(\theta)) \stackrel{\mathcal{D}}{\sim} N(0, C(g(\theta)))$, kde \mathcal{D} znamená v distribúcii, $C(g(\theta))$ je Raova-Cramerova spodná hranica definovaná ako $C(g(\theta)) = -\frac{[g'(\theta)]^2}{E_{\theta}[\frac{\partial^2}{\partial \theta^2} \ln L(\theta|\mathbf{x})]} = \frac{[g'(\theta)]^2}{ni(\theta)}$, kde $i(\theta)$ je Fisherova miera informácie jedného pozorovania, $L(\theta|\mathbf{x})$ je funkcia vierohodnosti (táto vlastnosť sa používa pri testovaní hypotéz ako predpoklad asymptotického rozdelenia testovacej štatistiky za predpokladu normality rozdelenia X),

- T_n sa nazýva **asymptoticky normálny odhad** $g(\theta)$, ak platí $\frac{T_n - g(\theta)}{\sqrt{C(g(\theta))}} \stackrel{\mathcal{D}}{\sim} N(0, 1)$ (táto vlastnosť sa tiež používa pri testovaní hypotéz ako predpoklad asymptotického rozdelenia testovacej štatistiky za predpokladu normality rozdelenia X).

Z nevychýlenosti odhadu vyplýva jeho asymptotická nevychýlenosť a z asymptotickej nevychýlenosti vyplýva konzistencia, ak $\lim_{n \rightarrow \infty} \text{Var}[T_n] = 0$. Implikáciou posleného bodu je

$$T_n \stackrel{\mathcal{D}}{\sim} N(g(\theta), \frac{[g'(\theta)]^2}{ni(g(\theta))}),$$

kde $ni(g(\theta)) = \mathcal{I}(g(\theta))$. Ak $g(\theta) = \theta$, potom

$$T_n \stackrel{\mathcal{D}}{\sim} N(\theta, \frac{1}{ni(\theta)}),$$

kde $ni(\theta) = \mathcal{I}(\theta)$. Ak $k > 1$, potom je θ vektor a môžeme písať

$$\sqrt{n} (g(\hat{\theta}_n) - g(\theta)) \stackrel{\mathcal{D}}{\sim} N_k(\mathbf{0}, \Delta^T (i(\theta))^{-1} \Delta),$$

kde $\Delta = \frac{\partial}{\partial \theta} g(\theta)$. Ak $g(\theta) = \theta$, potom

$$\sqrt{n} (\hat{\theta}_n - \theta) \stackrel{\mathcal{D}}{\sim} N_k(\mathbf{0}, (i(\theta))^{-1}).$$

Nech náhodná premenná X pochádza z **normálneho rozdelenia** s parametrami μ a σ^2 , $X \sim N(\mu, \sigma^2)$, kde $E[X] = \mu$ je stredná hodnota a $\text{Var}[X] = \sigma^2$ je rozptyl náhodnej premennej X . Potom výberový aritmetický priemer $\bar{X}_n = \bar{X}$ je **nevychýleným odhadom** μ a výberový rozptyl $S_{n-1}^2 = S^2$ je **nevychýleným odhadom** σ^2 ($n - 1$ v dolnom indexe S_{n-1}^2 znamená počet stupňov voľnosti). Zároveň platí, že \bar{X} a S^2 sú **asymptoticky nevychýlené, konzistentné, asymptoticky efektívne a asymptoticky normálne**. Preto môžeme písať nasledovné

$$\sqrt{n}(\bar{X}_n - \mu) \stackrel{\mathcal{D}}{\sim} N(0, \sigma^2), \text{ čo je ekvivalentné } \bar{X}_n \stackrel{\mathcal{D}}{\sim} N\left(\mu, \frac{\sigma^2}{n}\right).$$

a

$$\sqrt{n}(S_n^2 - \sigma^2) \stackrel{\mathcal{D}}{\sim} N(0, 2\sigma^4), \text{ kde } S_n^2 = \frac{n-1}{n} S_{n-1}^2.$$

Tiež môžeme písať

$$\sqrt{n}(S_{n-1}^2 - \sigma^2) \stackrel{\mathcal{D}}{\sim} \sqrt{n}\sigma^2 \left(\frac{\chi_{n-1}^2}{n-1} - 1 \right) \text{ a } \sqrt{n}(S_n^2 - \sigma^2) \stackrel{\mathcal{D}}{\sim} \sqrt{n}\sigma^2 \left(\frac{\chi_{n-1}^2}{n} - 1 \right),$$

čo je ekvivalentné $(n-1) \frac{S_{n-1}^2}{\sigma^2} \stackrel{\mathcal{D}}{\sim} \chi_{n-1}^2$ a $n \frac{S_n^2}{\sigma^2} \stackrel{\mathcal{D}}{\sim} \chi_{n-1}^2$. Potom môžeme písať nasledovné

$$\sqrt{n}(\hat{\theta}_n - \theta) \stackrel{\mathcal{D}}{\sim} N_2(\mathbf{0}, \Sigma),$$

kde $\hat{\theta}_n = (\bar{X}_n, S_n^2)^T$, $\theta = (\mu, \sigma^2)^T$, $\mathbf{0} = (0, 0)^T$ a $\Sigma = \text{diag}(\sigma^2, 2\sigma^4)$. Na tomto mieste ale treba zdôrazniť, že n použité pri odhadovaní musí byť dostatočne veľké, zvyčajne sa uvádza $n > 30$. Realizáciou \bar{X} je \bar{x} a realizáciou S^2 je s^2 .



Ďalej platí, že výberová kovariancia S_{12} je **nevychýleným odhadom** σ_{12} , ako aj, že je **asymptoticky nevychýlený, konzistentný, asymptoticky efektívny a asymptoticky normálny** odhad. Na tomto mieste ale treba zdôrazniť, že n použité pri odhadovaní musí byť dostatočne veľké, zvyčajne sa uvádza $n > 30$.

Avšak $E[R_{12}]$ sa rovná ρ len približne (zhoda nastane až pre $n > 30$). Naviac píšeme, že R_{12} je **nevychýleným odhadom** ρ . Zároveň platí, že R_{12} je **asymptoticky nevychýlený a konzistentný**.

Realizáciou S_{12} je s_{12} a realizáciou R_{12} je r .



Nech dvojrozmerná náhodná premenná $(X_1, X_2)^T$ pochádza z **dvojrozmerného normálneho rozdelenia** s parametrami μ a Σ , $(X_1, X_2)^T \sim N_2(\mu, \Sigma)$, kde $\mu = (\mu_1, \mu_2)^T$, $\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{pmatrix}$,

$\sigma_{12} = \sigma_{21} = \rho\sigma_1\sigma_2$, $E[X_1] = \mu_1$ je stredná hodnota a $\text{Var}[X_1] = \sigma_1^2$ je rozptyl náhodnej premennej X_1 ; $E[X_2] = \mu_2$ je stredná hodnota a $\text{Var}[X_2] = \sigma_2^2$ je rozptyl náhodnej premennej X_2 . Potom výberové aritmetické priemery \bar{X}_j ($j = 1, 2$) sú **nevychýlené odhady** μ_j a výberové rozptyly $S_{n-1,j}^2 = S_j^2$ sú **nevychýlenými odhadmi** σ_j^2 . Zároveň platí, že \bar{X}_j a $S_{n-1,j}^2$ sú **asymptoticky nevychýlené, konzistentné, asymptoticky efektívne a asymptoticky normálne**.



Nech náhodná premenná X pochádza z normálneho rozdelenia s parametrami μ a σ^2 , $X \sim N(\mu, \sigma^2)$, kde $E[X] = \mu$ je stredná hodnota a $\text{Var}[X] = \sigma^2$ je rozptyl náhodnej premennej X . Nech $g(\theta) = \sigma/\mu$, kde $\theta = (\mu, \sigma^2)^T$, $g(\hat{\theta}_n) = \frac{S_n}{\bar{X}_n}$ a $\Delta = \frac{\partial}{\partial \theta} g(\theta) = \left(-\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \right)^T$. Potom

$$\sqrt{n} \left(\frac{S_n}{\bar{X}_n} - \frac{\sigma}{\mu} \right) \stackrel{\mathcal{D}}{\sim} N_k \left(0, \Delta^T (i(\theta))^{-1} \Delta \right),$$

kde

$$\Delta^T (i(\theta))^{-1} \Delta = \left(-\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \right) \begin{pmatrix} \sigma^2 & 0 \\ 0 & 2\sigma^4 \end{pmatrix} \begin{pmatrix} -\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \end{pmatrix}^T = \frac{\sigma^2}{\mu^2} \left(\frac{\sigma^2}{\mu^2} + \frac{1}{2} \right).$$

