

Osnove matematične statistike

Iz *populacije* S vzamemo *vzorec* n objektov. Na vzorcu izvedemo meritve naključne spremenljivke X , ki jih združimo v naključni vektor $\mathbf{V} = (X_1, X_2, \dots, X_n)$. *Statistika* je vsaka merljiva funkcija vzorca $Z(\mathbf{V})$. V splošnem je statistika naključna spremenljivka.

Vzorčno povprečje za vzorec z n elementi je:

$$\langle X \rangle_n = \frac{1}{n} \sum_{i=1}^n X_i. \quad (1)$$

Vzorčno povprečje je nepristranska in dosledna cenilka populacijskega povprečja m :

$$E[\langle X \rangle_n] = \frac{1}{n} \sum_{i=1}^n E[X_i] = \frac{1}{n} nm = m, \quad P(|\langle X \rangle_n - m| \geq \varepsilon) \leq \frac{\sigma_x^2}{n\varepsilon^2} \xrightarrow{n \rightarrow \infty} 0, \text{ za } \varepsilon > 0. \quad (2)$$

Če je spremenljivka X normalno porazdeljena z gostoto $\mathcal{N}(X; m, \sigma)$, potem je vzorčno povprečje tudi normalno porazdeljeno, in sicer z gostoto $\mathcal{N}(\langle X \rangle_n; m, \sigma/\sqrt{n})$. Če pa X ni normalno porazdeljena, potem se porazdelitev vzorčnega povprečja z naraščajočo velikostjo vzorca približuje normalni:

$$\lim_{n \rightarrow \infty} f_{\langle X \rangle_n}(\langle x \rangle_n) = \mathcal{N}(\langle X \rangle_n; m, \sigma/\sqrt{n}). \quad (3)$$

Običajno predpostavimo, da je za $n \geq 30$ porazdelitev $\langle X \rangle_n$ približno normalna, ne glede na porazdelitev spremenljivke X .

Vzorčna varianca za vzorec z n elementi je:

$$s^2 = \langle (X - \langle X \rangle_n)^2 \rangle_n = \frac{1}{n} \sum_{i=1}^n (X_i - \langle X \rangle_n)^2. \quad (4)$$

Vzorčna varianca je pristranska cenilka populacijske variance σ^2 :

$$E[s^2] = \left(1 - \frac{1}{n}\right) \sigma^2 = \sigma^2 + \mathcal{O}(1/n). \quad (5)$$

Popravljen vzorčna varianca za vzorec z n elementi je:

$$S^2 = \frac{ns^2}{n-1} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \langle X \rangle_n)^2. \quad (6)$$

Popravljen vzorčna varianca je nepristranska in dosledna cenilka populacijske variance σ^2 :

$$E[S^2] = \sigma^2 \quad \text{Var}[S^2] \xrightarrow{n \rightarrow \infty} 0. \quad (7)$$

Osnove teorije cenilk - točkovno ocenjevanje

Parametre porazdelitev (npr. m , σ , p , λ itn.) lahko ocenjujemo točkovno ali intervalno. Pri točkovni oceni sta na voljo dve metodi: *metoda momentov* in *metoda največje zanesljivosti*.

Pri **metodi momentov** izraze za teoretične momente verjetnostne porazdelitve, katere parametre želimo oceniti, izenačimo z izrazi za ustrezne vzorčne momente. Potrebujemo toliko parov momentov, kolikor parametrov želimo oceniti. V dobljenem sistemu enačb so ocenjevani parametri neznanke. Z rešitvijo sistema enačb dobimo cenilke za parametre. Cenilko parametra θ označimo z $\hat{\theta}$.

Pri **metodi največje zanesljivosti** tvorimo *funkcijo zanesljivosti*:

$$L(\mathbf{v}; \theta) = f(x_1; \theta) \cdot f(x_2; \theta) \cdot \dots \cdot f(x_n; \theta), \quad (8)$$

kjer je $f(x; \theta)$ gostota verjetnosti naključne spremenljivke X s parametrom θ . Funkcija zanesljivosti je torej enaka verjetnosti, da pri vzorčenju dobimo vzorec v prostornini $d\mathbf{v}$ okoli \mathbf{v} . Parameter θ verjetnostne porazdelitve določimo tako, da ima vrednost funkcije $L(\mathbf{v}; \theta)$ na konkretnem vzorcu meritev \mathbf{v} maksimum, to je, da smo izmerili vzorec \mathbf{v} zato, ker je najbolj verjeten. V ta namen $L(\mathbf{v}; \theta)$ odvajamo po θ in odvod izenačimo z nič. Iz dobljene enačbe dobimo izraz za parameter θ , ki predstavlja izraz za cenilko $\hat{\theta}$. Če je ocenjevanih parametrov več, potem funkcijo zanesljivosti odvajamo po vsakem parametru posebej, s čimer dobimo sistem enačb za parametre. Rešitve sistema so cenilke za parametre.