

Uporabna statistika

Gregor Dolinar

Fakulteta za elektrotehniko
Univerza v Ljubljani

12. november 2013

Na podlagi statistične analize vzorca želimo sklepati o lastnostih populacije in sprejemati različne odločitve.
Slučajno spremenljivko X oziroma populacijo, ki jo ta spremenljivka predstavlja, opišemo z njeno slučajno porazdelitvijo.

Slučajna porazdelitev je točno določena z nekaj parametri, ki jih običajno ne poznamo:

- ▶ povprečna vrednost μ
- ▶ varianca σ^2
- ▶ delež "dobrih" elementov populacije p
- ▶ razlika povprečnih vrednosti dveh populacij $\mu_1 - \mu_2$
- ▶ razlika deležev v dveh populacijah $p_1 - p_2$

S pomočjo vzorca dobimo oceno vrednosti parametrov. Slučajna porazdelitev je potem določena in s tem dobimo opis celotne populacije.

Primer

Zanima nas življenjska doba procesorja. Primeren model za življenjsko dobo je Weibullova porazdelitev

$$f(x) = \frac{\beta}{\delta} \left(\frac{x}{\delta}\right)^{\beta-1} e^{-\left(\frac{x}{\delta}\right)^{\beta}}.$$

Ne poznamo parametrov β in δ , vemo pa da se $E(X)$ in $V(X)$ izražata s pomočjo β in δ .

Na podlagi vzorca naredimo oceno za $E(X)$ in $V(x)$.

Ločimo dve vrsti ocen parametrov:

- ▶ točkovna ocena
- ▶ intervalna ocena

Točkovna ocena parametrov

Cenilka Θ parametra θ je funkcija slučajnih spremenljivk X_1, \dots, X_n slučajnega vzorca velikosti n .

Primer

Ena izmed cenilk za $E(X)$ je na primer

$$\Theta = h(X_1, \dots, X_n) = \frac{X_1 + \dots + X_n}{n} = \bar{X}.$$

Cenilka za $V(X)$ je na primer

$$\Theta = h(X_1, \dots, X_n) = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}.$$

Definicija

Cenilka za parameter θ je nepristranska (unbiased estimator), če je $E(\Theta) = \theta$.

Če cenilka ni nepristranska, potem razliko $E(\Theta) - \theta$ imenujemo pristranskost (bias).

Primer

X_1, \dots, X_n normalno porazdeljene. Zanima nas točkovna ocena za μ . Možne cenilke:

- ▶ X_1
- ▶ \bar{X}
- ▶ 10 % največjih in najmanjših vrednosti vzorca ne upoštevamo
- ▶ $\frac{2X_1 - X_2 + X_3}{2}$

Katera cenilka je najboljša?

Cenilka naj bi bila nepristranska.

Vse cenilke v prejšnjem primeru so nepristranske.

Trditev

Najboljša je nepristranska cenilka z najmanjšo varianco - minimal variance unbiased estimator (MVUE).

Opomba

Najbolj verjetno je, da bo napoved $\hat{\theta}$ nepristranske cenilke z najmanjšo varianco najbližje pravi vrednosti parametra θ od vseh nepristranskih cenilk.

Izrek

X_1, \dots, X_n normalno porazdeljene s parametroma μ, σ^2 , potem je vzorčna sredina \bar{X} nepristranska cenilka z najmanjšo varianco (MVUE) za parameter μ .

Opomba

Opomba. Včasih je pristranska cenilka z majhno varianco boljša od nepristranske z veliko varianco.

Določanje cenilk

Kako poiskati cenilko, s katero bomo na podlagi vzorca ocenjevali vrednost iskanega parametra?

Cenilke lahko določamo z:

- ▶ metodo momentov
- ▶ metodo največjega verjetja

Metoda momentov

Definicija

Naj bodo X_1, \dots, X_n vzorčne slučajne spremenljivke s slučajno porazdelitvijo $f(x)$. Populacijski moment r -tega reda je potem $E(X^r)$, vzorčni moment r -tega reda pa $\frac{1}{n} \sum_{i=1}^n X_i^r$

Vrednosti parametrov določimo tako, da momente izbrane porazdelitve z neznanimi parametri izenačimo z momenti, ki jih izračunamo s pomočjo vzorca.

Primer.

Gama porazdelitev:

$$f(x) = \frac{\lambda^r x^{r-1} e^{-\lambda x}}{\Gamma(r)},$$

$$E(X) = \frac{r}{\lambda},$$

$$E(X^2) = \frac{r(r+1)}{\lambda^2}.$$

Izenačimo

$$\frac{r}{\lambda} = \bar{X},$$

$$\frac{r(r+1)}{\lambda^2} = \sum_{i=1}^n \frac{1}{n} X_i^2.$$

Življenjska doba izdelka je modelirana z Gamma porazdelitvijo. Za 6 izdelkov so bile življenjske dobe 5, 12, 15, 22, 33 in 62 dni. Koliko odstotkov izdelkov ima pričakovano življenjsko dobo krajšo od 30 dni?