

Sadržaj

Sadržaj	1
12 TEORIJA PROCJENA	3
12.1 TOČKASTE PROCJENE	5
12.2 REGRESIJSKA ANALIZA	11
12.3 ML-PROCJENITELJI <i>tko želi znati više</i>	15
12.4 Ponovimo	19

Poglavlje 12

TEORIJA PROCJENA

Teorija procjene sastoji se u konstrukciji metoda za ocjenu vrijednosti jednog ili više parametara poznate distribucije slučajne varijable.

U prethodnom poglavlju smo za slučajnu varijablu X (statističko obilježje) promatrati n vrijednosti x_1, x_2, \dots, x_n kao uzorak veličina n .

U ovom poglavlju ćemo vrijednosti x_1, x_2, \dots, x_n promatrati kao pojedinačne vrijednosti niza od n nezavisnih slučajnih varijabli X_1, X_2, \dots, X_n koje imaju istu distribuciju kao i slučajna varijable X .

Definicija 12.1 (SLUČAJNI UZORAK veličine n)

Neka je X slučajna varijabla (statističko obilježje populacije) s funkcijom distribucije $F(x)$. Slučajni uzorak veličine n za slučajnu varijablu X je slučajni vektor (X_1, X_2, \dots, X_n) , gdje su sve slučajne varijable $X_i, i=1, \dots, n$, nezavisne sa zajedničkom funkcijom distribucije vjerojatnosti $F(x)$.

Vrijednost slučajnog uzorka je uređena n -torka (x_1, x_2, \dots, x_n) ako je izmjerena vrijednost slučajnih varijabli X_i jednakna $x_i \in R(X), i=1, \dots, n$.

Ako je X diskretna slučajna varijabla ($R(X)$ je konačan ili prebrojiv), onda je (X_1, X_2, \dots, X_n) diskretni slučajni uzorak, a ako je X kontinuirana slučajna varijabla ($R(X) \subseteq \mathbb{R}$), onda je (X_1, X_2, \dots, X_n) kontinuirani slučajni uzorak.

Definicija 12.2 (STATISTIKA)

Ako je $Y = h(X_1, X_2, \dots, X_n)$, gdje je h funkcija od n varijabli, onda se slučajna varijabla Y naziva statistika.

NAPOMENA 12.1 Odabrani elementi uzorka veličine n iz populacije trebaju biti izabrani slučajno. Trebamo koristiti tablicu slučajnih brojeva za izbor n slučajnih brojeva ili program za generiranje slučajnih brojeva.

PRIMJER 12.1 Zadana je diskretna slučajna varijabla X s funkcijom vjerojatnosti

x_i	0	1	2
p_i	$\frac{1}{2}$	$\frac{1}{3}$	$\frac{1}{6}$

Što je uzorak veličine 2 za ovu slučajnu varijablu?

Odredi sve moguće vrijednosti slučajnog uzorka veličine 2 za X .

Rješenje:

Slučajni uzorak veličine 2 za slučajnu varijablu X je slučajni vektor (X_1, X_2) , gdje su sve slučajne varijable X_1 i X_2 nezavisne i jednake funkcije distribucije kao i X . Slika slučajne varijable X je $R(X) = \{0, 1, 2\}$. Slučajne varijable X_1 i X_2 mogu poprimiti iste vrijednosti kao i X . Vrijednost slučajnog uzorka je uređena dvojka (x_1, x_2) elemenata iz $R(X)$, tj. to je varijacija s ponavljanjem $r = 2$ -og razreda od $n = 3$ elemenata. Broj svih takvih varijacija je $V_3^{(2)} = 3^2 = 9$.

Sve moguće vrijednosti slučajnog uzorka veličine 2 za slučajnu varijablu X :

$(0,0), (0,1), (0,2),$

$(1,0), (1,1), (1,2),$

$(2,0), (2,1), (2,2).$

12.1 TOČKASTE PROCJENE PARAMETARA

MOTIV 12.1 Koliki uzorak iz normalne razdiobe s varijancom 81 treba biti da bi s vjerojatnošću 0.9544 apsolutna razlika uzoračke aritmetičke sredine i očekivanja bila manja od 5.5?

Slučajna varijabla je određena svojom funkcijom distribucije. Mnoga statistička obilježja imaju zajedničku teorijsku funkciju distribucije pa govorimo o poznatim distribucijama (razdiobama): binomna, uniformna, normalna, Poissonova,....

Svaka razdioba karakterizirana je svojim parametrima $n, p, a, b, \mu, \sigma^2, \lambda, \dots$:

$$X \sim B(n, p),$$

$$X \sim U(a, b),$$

$$X \sim N(\mu, \sigma^2),$$

$$X \sim Po(\lambda), \dots$$

Ako želimo odrediti vezu između teorijske i statističke razdiobe postavljaju se dva zadatka:

1. parametarske procjene, kada prepostavimo teorijsku razdiobu i moramo odrediti (procijeniti) parametre te razdiobe.
2. neparametarske procjene, kada moramo odabrati razdiobu.

Definicija 12.3 (PROCJENITELJ ILI ESTIMATOR)

Procjenitelj nepznatog parametra t je funkcija slučajnog uzorka

$$\widehat{T} = h(X_1, X_2, \dots, X_n).$$

Procjenitelj je statistika.

Zadatak je odrediti procjenitelj \widehat{T} za parametar t koji će "najbolje" procijeniti t .

Za procjenu jednog parametra možemo izabirati razne procjenitelje (funkcije h).

Definicija 12.4 (NEPRISTRANI PROCJENITELJ)

Procjenitelj \widehat{T} je nepristran za parametar t ako je očekivanje od \widehat{T} jednako vrijednosti parametra t : $E(\widehat{T}) = t$.

Definicija 12.5 (ASIMPTOTSKI NORMALAN PROCJENITELJ)

Procjenitelj \widehat{T} je asimptotski normalan za parametar t ako slučajnoj varijabli $\frac{\widehat{T} - t}{\sqrt{Var(\widehat{T})}}$ asimptotski, kad $n \rightarrow \infty$, pripada standardna normalna razdioba (distribucija) $N(0,1)$.

Definicija 12.6 (UZORAČKA ARITMETIČKA SREDINA)

Statistika $\bar{X} = h(X_1, X_2, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i$ zove se uzoračka aritmetička sredina.

Vrijednost uzoračke aritmetičke sredine računa pomoću

$$\bar{x} = h(x_1, x_2, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{x} = \frac{1}{n} \sum_{k=1}^r x_k^* f_k.$$

TEOREM 12.1 (Svojstva uzoračke aritmetičke sredine)

(i) Neka je X slučajna varijabla s teorijskim očekivanjem μ , i varijancom σ^2 , $0 < \sigma^2 < \infty$, koju ispitujemo pomoću slučajnog uzorka (X_1, X_2, \dots, X_n) . Uzoračka aritmetička sredina \bar{X} je pouzdan procjenitelj za μ :

$$E(\bar{X}) = \mu.$$

$$(ii) \quad Var(\bar{X}) = \frac{1}{n} \sigma^2.$$

$$(iii) \quad \bar{X} \sim N(\mu, \frac{1}{n} \sigma^2) \text{ ako je normalna distribucija.}$$

$$(iv) \quad \text{Uzoračka aritmetička sredina } \bar{X} \text{ je asimptotski normalan procjenitelj za } \mu: \quad \frac{\bar{X} - \mu}{\sqrt{Var(\bar{X})}} \sim N(0, 1).$$

Dokaz:ko želi znati više

$$(i) \quad E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \mu.$$

(ii)

$$\begin{aligned} Var(\bar{X}) &= Var\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} Var\left(\sum_{i=1}^n X_i\right) = \frac{1}{n^2} Var\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n Var(X_i) = \frac{1}{n^2} n \cdot Var(X_i) = \frac{1}{n} \sigma^2. \end{aligned}$$

(iii) prema (i) i (ii).

(iv) Prisjetimo se centralnog graničnog teorema:

Neka je $S_n = X_1 + X_2 + \dots + X_n$, tada slučajna varijabla $\frac{S_n - n\mu}{\sigma \sqrt{n}}$ konvergira k $N(0, 1)$.

$$\bar{X}^* = \frac{\bar{X} - \mu}{\sqrt{Var(\bar{X})}} = \frac{\frac{S_n}{n} - \mu}{\sqrt{\frac{1}{n} \sigma^2}} = \frac{S_n - n\mu}{\sigma \sqrt{n}} \quad \text{konvergira } (n \rightarrow \infty) \text{ k } N(0, 1).$$

12. TEORIJA PROCJENA

PRIMJER 12.2 Izračunati $P(69 < \bar{X} < 75)$, ako je \bar{X} uzoračka aritmetička sredina uzorka veličine $n=36$ iz normalne razdiobe $X \sim N(70, 144)$.

Rješenje:

Ako je $X \sim N(70, 144)$ i $n = 36$, onda je $\bar{X} \sim N(70, 4)$,

$$\bar{X}^* = \sqrt{n} \frac{\bar{X} - \mu}{\sigma} = \frac{\bar{X} - 70}{2} \sim N(0, 1).$$

$$\begin{aligned} P(69 < \bar{X} < 75) &= F^*\left(\sqrt{n} \frac{75 - \mu}{\sigma}\right) - F^*\left(\sqrt{n} \frac{69 - \mu}{\sigma}\right) \\ &= F^*\left(\frac{75 - 70}{2}\right) - F^*\left(\frac{69 - 70}{2}\right) = F^*(2.5) - F^*(-0.5) = 0.68. \end{aligned}$$

Prisjetimo se motivacijskog primjera:

PRIMJER 12.3 *motiv*

Koliki uzorak iz normalne razdiobe s varijancom 81 treba biti da bi s vjerojatnošću 0.9544 apsolutna razlika uzoračke aritmetičke sredine i očekivanja bila manja od 5.5?

Rješenje:

Neka je $X \sim N(\mu, 81)$ i $P(|\bar{X} - \mu| < 5.5) \geq 0.9544$.

Trebamo odrediti veličinu uzorka n.

$$\text{Znamo da je } \bar{X} \sim N(\mu, \frac{81}{n}), \text{ a } \bar{X}^* = \sqrt{n} \frac{\bar{X} - \mu}{\sigma} = \sqrt{n} \frac{\bar{X} - \mu}{9} \sim N(0, 1).$$

$$\begin{aligned} P(|\bar{X} - \mu| < 5.5) &= P\left(|\sqrt{n} \frac{\bar{X} - \mu}{\sigma}| < \sqrt{n} \frac{5.5}{\sigma}\right) = P\left(|\bar{X}^*| \leq \sqrt{n} \frac{5.5}{\sigma}\right) \\ &= 2F^*\left(\sqrt{n} \frac{5.5}{\sigma}\right) - 1. \end{aligned}$$

Iz zadane vjerojatnosti dobivamo: $2F^*\left(\sqrt{n} \frac{5.5}{\sigma}\right) - 1 \geq 0.9544$,

$$F^*\left(\sqrt{n} \frac{5.5}{\sigma}\right) \geq 0.9772 \Rightarrow \sqrt{n} \frac{5.5}{\sigma} \geq 2 \Rightarrow n \geq 11.$$

Definicija 12.7 (UZORAČKA VARIJANCA)

Statistika $\widehat{\Sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ zove se uzoračka varijanca.

$$\widehat{\Sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

Vrijednost uzoračke varijance računa se formulom

$$\widehat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2.$$

12.1. TOČKASTE PROCJENE

$$\widehat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^r (x_k^* - \bar{x})^2 f_k = \frac{1}{n} \sum_{k=1}^r (x_k^*)^2 f_k - \bar{x}^2.$$

TEOREM 12.2 (*Svojstva uzoračke varijance*)

Neka je X slučajna varijabla s teorijskim očekivanjem μ i varijancom σ^2 , koju ispitujemo pomoću slučajnog uzorka (X_1, X_2, \dots, X_n) . Uzoračka varijanca $\widehat{\Sigma}^2$ nije pouzdan procjenitelj za σ^2 : $E(\widehat{\Sigma}^2) = \frac{n-1}{n}\sigma^2$.

Dokaz: tko želi znati više

Prisjetimo se da je $Var(X) = E(X^2) - E(X)^2$ i $Var(\bar{X}) = \frac{1}{n}\sigma^2$.

$$\begin{aligned} E(\widehat{\Sigma}^2) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2\right) = \frac{1}{n} \sum_{i=1}^n E(X_i^2) - E(\bar{X}^2) \\ &= \frac{1}{n} \sum_{i=1}^n [Var(X_i) + E(X_i)^2] - [Var(\bar{X}) + E(\bar{X})^2] \\ &= [Var(X_i) + E(X_i)^2] - [Var(\bar{X}) + E(\bar{X})^2] \\ &= [\sigma^2 + \mu^2] - [\frac{1}{n}\sigma^2 + \mu^2] = \frac{n-1}{n}\sigma^2. \end{aligned}$$

Definicija 12.8 (*KORIGIRANA UZORAČKA VARIJANCA*)

Statistika $\widehat{S}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ zove se korigirana uzoračka varijanca.

$$\widehat{S}^2 = \frac{n}{n-1} \widehat{\Sigma}^2 = \frac{1}{n-1} \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2 \right).$$

Vrijednost korigirane uzoračke varijance računa se formulom

$$\widehat{s}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right).$$

$$\widehat{s}^2 = \frac{1}{n-1} \sum_{k=1}^r (x_k^* - \bar{x})^2 f_k = \frac{1}{n-1} \left(\sum_{k=1}^r (x_k^*)^2 f_k - n\bar{x}^2 \right).$$

TEOREM 12.3 (*Svojstva korigirane uzoračke varijance*)

Neka je X slučajna varijabla s teorijskim očekivanjem μ i varijancom σ^2 , koju ispitujemo pomoću slučajnog uzorka (X_1, X_2, \dots, X_n) .

Korigirana uzoračka varijanca \widehat{S}^2 je pouzdan procjenitelj za σ^2 : $E(\widehat{S}^2) = \sigma^2$.

12. TEORIJA PROCJENA

Dokaz: Prisjetimo se da je $E(\widehat{\Sigma}^2) = \frac{n-1}{n}\sigma^2$.

$$E(\widehat{S}^2) = E\left(\frac{n}{n-1}\widehat{\Sigma}^2\right) = \frac{n}{n-1}E(\widehat{\Sigma}^2) = \frac{n}{n-1} \cdot \frac{n-1}{n}\sigma^2 = \sigma^2.$$

TEOREM 12.4 (O VEZI $\widehat{S}^2, \widehat{\Sigma}^2$ I DISTRIBUCIJA $\chi^2(n-1), t(n-1)$)

Neka su $\bar{X}, \widehat{S}^2, \widehat{\Sigma}^2$ statistike slučajnog uzorka (X_1, X_2, \dots, X_n) iz normalne razdiobe $X \sim N(\mu, \sigma^2)$.

Tada vrijedi:

- (i) Statistika $\frac{n-1}{\sigma^2}\widehat{S}^2 = \frac{n}{\sigma^2}\widehat{\Sigma}^2 \sim \chi^2(n-1)$,
- (ii) Statistika $\sqrt{n}\frac{\bar{X}-\mu}{\widehat{S}} = \sqrt{n-1}\frac{\bar{X}-\mu}{\widehat{\Sigma}} \sim t(n-1)$.

Dokaz: tko želi znati više

(i) Dokaz je složen i koristi svojstvo $\chi^2(n)$ distribucije: $Y \sim \chi^2(n)$ ako je

$$Y = Y_1^2 + Y_2^2 + \dots + Y_n^2, \quad Y_i \sim N(0, 1).$$

(ii) Koristimo svojstvo Studentove distribucije s n stupnjeva slobode $t(n)$:

$$Z \sim t(n) \text{ ako je } Z = Y \sqrt{\frac{n}{U}}, \text{ za } Y \sim N(0, 1), \quad U \sim \chi^2(n).$$

Računamo za $X \sim N(\mu, \sigma^2)$, $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$, $\bar{X}^* = \sqrt{n}\frac{\bar{X}-\mu}{\sigma} \sim N(0, 1)$:

$$\begin{aligned} \sqrt{n}\frac{\bar{X}-\mu}{\widehat{S}} &= \sqrt{n}\frac{\bar{X}-\mu}{\sigma} \cdot \frac{\sigma}{\sqrt{n-1}} \cdot \frac{1}{\sqrt{\widehat{S}^2}} = \sqrt{n}\frac{\bar{X}-\mu}{\sigma} \cdot \frac{\sqrt{n-1}}{\sqrt{\frac{n-1}{\sigma^2}}} \cdot \frac{1}{\sqrt{\widehat{S}^2}} \\ &= \sqrt{n}\frac{\bar{X}-\mu}{\sigma} \cdot \frac{\sqrt{n-1}}{\sqrt{\frac{n-1}{\sigma^2} \cdot \widehat{S}^2}}. \end{aligned}$$

Prema tvrdnji (i) zaključujemo $\sqrt{n}\frac{\bar{X}-\mu}{\widehat{S}} \sim t(n-1)$.

Koristeći $\widehat{S}^2 = \frac{n}{n-1}\widehat{\Sigma}^2$ možemo dobiti i tvrdnju $\sqrt{n-1}\frac{\bar{X}-\mu}{\widehat{\Sigma}} \sim t(n-1)$.

PRIMJER 12.4 Izračunati uzoračku aritmetičku sredinu, uzoračku varijancu i korigirani uzoračku varijancu u primjeru "težina studenata".

x_{ksr}	f_k
61	5
64	18
67	42
70	27
73	8
	$n=100$

12.1. TOČKASTE PROCJENE

Rješenje: $\bar{x} = \frac{1}{n} \sum_{k=1}^r x_k^* f_k.$

$$\begin{aligned}\bar{x} &= \frac{1}{n} \sum_{k=1}^r x_{ksr}^* f_k = \frac{1}{100} (61 * 5 + 64 * 18 + 67 * 42 + 70 * 27 + 73 * 8) \\ &= \frac{1349}{20} = 67,45\end{aligned}$$

$$\widehat{s}^2 = \frac{1}{n-1} \left(\sum_{k=1}^r (x_k^*)^2 f_k - n \bar{x}^2 \right)$$

$$\widehat{s}^2 = \frac{1}{n-1} \left(\sum_{k=1}^r (x_{ksr}^*)^2 f_k - n \bar{x}^2 \right) = \frac{379}{44} = 8,6136$$

$$\widehat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^r (x_k^*)^2 f_k - \bar{x}^2.$$

$$\widehat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^r (x_{ksr}^*)^2 f_k - \bar{x}^2 = \frac{3411}{400} = 8,5275$$

12.2 REGRESIJSKA ANALIZA

MOTIV 12.2 Deformacije x [mm] i Brinellova tvrdoća y [$\frac{kg}{mm^2}$] za neki tip čelika dani su tablicom

x	06	09	11	11	13	22	26	28	33	35
y	68	67	65	53	44	40	37	28	34	32

Odredite pravce regresije, uzorački koeficijent regresije i uzorački koeficijent korelacoje. Jesu li deformacija i Brinellova tvrdoća jako korelirane?

Definicija 12.9 (UZORAČKA KOVARIJANCA. UZORAČKI KOEFICIJENT KORELACIJE)

Neka je za zadani slučajni 2-dim vektor (X, Y) dobiven slučajni uzorak $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.

Statistika

$$\widehat{\mu}_{XY} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

zove se uzoračka kovarijanca. Vrijednost korigirane uzoračke kovarijance računa se formulom

$$\widehat{\mu}_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

Neka su $\widehat{\sigma}_1$ i $\widehat{\sigma}_2$ uzoračke standardne devijacije od X i Y . Uzorački koeficijent korelacijske komponenti X i Y slučajnog vektora je definiran s

$$\widehat{\rho}_{xy} = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1 \cdot \widehat{\sigma}_2}.$$

$$\widehat{\rho}_{xy} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{\sqrt{n \sum x^2 - (\sum x)^2} \cdot \sqrt{n \sum y^2 - (\sum y)^2}}.$$

NAPOMENA 12.2 (regresijska analiza)

Regresijska analiza (engl. regression analysis) je statistička metoda za održavanje veze među slučajnim varijablama. Promatramo u slučajnom vektoru (X, Y) jednu slučajnu varijablu (npr. X) kao nezavisnu-kontroliranu (njene vrijednosti zadajemo). Druga varijabla Y je slučajna varijabla i zanima nas kako ona ovisi o X .

Prema Napomeni ?? u poglavljju Dvodimenzionalni slučajni vektor računamo uzoračke pravce regresije.

Ako je X nezavisna varijabla i $Y = aX + b$, parametre a i b možemo odrediti metodom najmanjih kvadrata tako da $E((Y - (aX + b))^2)$ ima minimalnu vrijednost.

12.2. REGRESIJSKA ANALIZA

$a = \widehat{\rho}_{xy} \cdot \frac{\widehat{\sigma}_2}{\widehat{\sigma}_1} = \frac{\widehat{\mu}_{XY}}{\widehat{\sigma}_1^2}$ je uzorački koeficijent regresije Y po X .

$$b = \bar{y} - \widehat{\rho}_{xy} \cdot \frac{\widehat{\sigma}_2}{\widehat{\sigma}_1} \bar{x} = \bar{y} - \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} \cdot \bar{x}$$

$$y - \bar{y} = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} (x - \bar{x}),$$

$$y - \bar{y} = \rho_{XY} \cdot \frac{\sigma_2}{\sigma_1} (x - \bar{x}) \text{ je pravac regresije } Y \text{ po } X.$$

Analogno, ako je $X = aY + b$

$a = \widehat{\rho}_{xy} \cdot \frac{\widehat{\sigma}_1}{\widehat{\sigma}_2} = \frac{\widehat{\mu}_{XY}}{\widehat{\sigma}_2^2}$ je uzorački koeficijent regresije X po Y

$$x - \bar{x} = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_2^2} (Y - \bar{y})$$

$$x - \bar{x} = \widehat{\rho}_{xy} \cdot \frac{\widehat{\sigma}_1}{\widehat{\sigma}_2} (y - \bar{y}) \text{ je pravac regresije } X \text{ po } Y.$$

PRIMJER 12.5 U tablici su zapisani uzorci visina x i y od 12 mama i njihovih kćeri.

x	165	160	170	163	173	158	178	168	173	170	175	180
y	173	168	173	165	175	168	173	165	180	170	173	178

Odredite uzorački pravac regresije Y u odnosu na X i uzorački pravac regresije X u odnosu na Y . Odredite uzorački koeficijent korelacije i uzorački koeficijent regresije Y po X . Jesu li visine mama i kćeri jako korelirane?

Rješenje: Trebamo odrediti a i b u jednadžbi $y = ax + b$:

$$a = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{n \sum x^2 - (\sum x)^2}$$

$$b = \bar{y} - \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} \cdot \bar{x} = \frac{(\sum y) \cdot (\sum x^2) - (\sum x) \cdot (\sum x \cdot y)}{n \sum x^2 - (\sum x)^2}$$

Računamo: $\sum x = 2033$, $\sum y = 2061$, $\sum x^2 = 344.95$, $\sum x \cdot y = 349.42$, $\sum y^2 = 354.22$.

Uzorački koeficijent regresije Y po X je $a = 0.48$, $b = 90.9$ pa je pravac regresije Y

12. TEORIJA PROCJENA

po X $y = 0.48x + 90.9$.

Trebamo odrediti a' i b' u jednadžbi $x = a'y + b'$:

$$a' = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_2^2} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{n \sum y^2 - (\sum y)^2}$$

$$b' = \bar{x} - \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} \cdot \bar{y} = \frac{(\sum x) \cdot (\sum y^2) - (\sum y) \cdot (\sum x \cdot y)}{n \sum y^2 - (\sum y)^2}$$

Uzorački koeficijent regresije X po Y je $a' = 1.02$, $b' = -5.12$ pa je pravac regresije X po Y $x = 1.02x - 5.12$.

Uzorački koeficijent korelacije je

$$\widehat{\rho}_{xy} = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1 \cdot \widehat{\sigma}_2}.$$

$$\widehat{\rho}_{xy} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{\sqrt{n - \sum x^2 - (\sum x)^2} \cdot \sqrt{n - \sum y^2 - (\sum y)^2}} = 0.69.$$

Prisjetimo se motivacijskog primjera:

PRIMJER 12.6 motiv

Deformacije x [mm] i Brinellova tvrdoća y [$\frac{kg}{mm^2}$] za neki tip čelika dani su tablicom

x	06	09	11	11	13	22	26	28	33	35
y	68	67	65	53	44	40	37	28	34	32

Odredite pravce regresije, uzorački koeficijent korelacije i uzorački koeficijent regresije. Jesu li deformacije i Brinellova tvrdoća jako korelirane?

Rješenje: Trebamo odrediti a i b u jednadžbi $y = ax + b$:

$$a = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{n \sum x^2 - (\sum x)^2}$$

$$b = \bar{y} - \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} \cdot \bar{x} = \frac{(\sum y) \cdot (\sum x^2) - (\sum x) \cdot (\sum x \cdot y)}{n \sum x^2 - (\sum x)^2}$$

Računamo: $\sum x = 183$, $\sum y = 440$, $\sum x^2 = 4665$, $\sum x \cdot y = 7701$, $\sum y^2 = 23232$.

Uzorački koeficijent regresije Y po X je $a = -1.32$, $b = 75.72$ pa je pravac regresije

12.2. REGRESIJSKA ANALIZA

Y po X $y = -1.32x + 75.72$.

Trebamo odrediti a' i b' u jednadžbi $x = a'y + b'$:

$$a' = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_2^2} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{n \sum y^2 - (\sum y)^2}$$

$$b' = \bar{x} - \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} \cdot \bar{y} = \frac{(\sum x) \cdot (\sum y^2) - (\sum y) \cdot (\sum x \cdot y)}{n \sum y^2 - (\sum y)^2}$$

Uzorački koeficijent regresije X po Y je $a' = -0.72$, $b' = 55.72$ pa je pravac regresije X po Y $x = -0.72x + 55.72$.

Uzorački koeficijent korelacije je

$$\widehat{\rho}_{xy} = \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{\sqrt{n - \sum x^2 - (\sum x)^2} \cdot \sqrt{n - \sum y^2 - (\sum y)^2}} = -0.97$$

Budući je $\widehat{\rho}_{xy} \approx -1$ slučajne varijable su linearnoj vezi, jako korelirane.

12.3 METODA NAJVEĆE VJEROJATNOSTI (ML)

tko želi znati više

U ovom poglavlju istaknuli smo primjere s oznakom *važno* u kojima su dani procjenitelji za parametre osnovnih distribucija u smislu najveće vjerojatnosti.

MOTIV 12.3 *U četiri mjerena Rockwellove tvrdoće jedne ploče radnici du dobili sljedeće vrijednosti:*

64.9, 64.1, 63.8, 64.0.

(a) Izračunajte vrijednost procjenitelja (u smislu najveće vjerojatnosti) za očekivanje i varijancu tvrdoće ako prepostavimo normalnu distribuciju.

(b) Izračunajte vrijednost nepristranih procjenitelja za očekivanje i varijancu tvrdoće ako prepostavimo normalnu distribuciju.

Definicija 12.10 (FUNKCIJA VJERODOSTOJNOSTI) Neka je X slučajna varijabla (statističko obilježje) sa teorijskom funkcijom distribucije $F(x,t)$ s nepoznatim parametrom t i sa funkcijom vjerojatnosti za diskretnu razdiobu i funkcijom gustoće vjerojatnosti za kontinuiranu $f(x,t)$. Neka je (x_1, x_2, \dots, x_n) vrijednost slučajnog uzorka (X_1, X_2, \dots, X_n) za promatranoj varijablu.

Za diskretnu razdiobu funkcija vjerodostojnosti $L(t)$ definira se kao funkcija vjerojatnosti slučajnog uzorka (slučajnog vektora):

$$L(t) = P(X_1 = x_1, t) \cdot P(X_2 = x_2, t) \cdot \dots \cdot P(X_n = x_n, t).$$

Za kontinuiranu razdiobu funkcija vjerodostojnosti $L(t)$ definira se kao funkcija gustoće vjerojatnosti slučajnog uzorka (slučajnog vektora):

$$L(t) = f(x_1, t) \cdot f(x_2, t) \cdot \dots \cdot f(x_n, t).$$

Metoda najveće vjerojatnosti (ML = maximum likelihood method), za određivanje procjenitelja $\widehat{T} = h(X_1, X_2, \dots, X_n)$ za nepoznati parametar t sastoji se u izboru one funkcije h takve da funkcija vjerodostojnosti $L(t)$ (ili $\ln L(t)$) dostiže najveću vrijednost za $t = h(x_1, x_2, \dots, x_n)$.

$$\frac{d}{dt} L(t) = 0 \Rightarrow t = h(x_1, x_2, \dots, x_n) \Rightarrow \widehat{T} = h(X_1, X_2, \dots, X_n).$$

PRIMJER 12.7 *važno*

Metodom najveće vjerojatnosti pokažite da je procjenitelj za parametar λ u populaciji s Poisonovom razdiobom $Po(\lambda)$ jednak $\widehat{T} = \bar{X}$.

Rješenje: Neka je $X \sim Po(\lambda)$.

Teorijska funkcija vjerojatnosti je $f(x, \lambda) = P(X = x, \lambda) = \frac{\lambda^x}{x!} e^\lambda$.

Trebamo naći ML-procenitelj za λ .

Funkcija vjerodostojnosti je

$$\begin{aligned} L(\lambda) &= P(X_1 = x_1, \lambda) \cdot P(X_2 = x_2, \lambda) \cdots P(X_n = x_n, \lambda) \\ &= \frac{\lambda^{x_1}}{x_1!} e^\lambda \cdot \frac{\lambda^{x_2}}{x_2!} e^\lambda \cdots \frac{\lambda^{x_n}}{x_n!} e^\lambda = \frac{\lambda^{\sum x_i}}{x_1! x_2! \cdots x_n!} e^{-n\lambda}. \end{aligned}$$

Tražimo maksimum funkcije vjerodostojnosti $\ln L(\lambda)$:

$$\begin{aligned} \ln L(\lambda) &= -n\lambda + \sum x_i \ln \lambda - \sum \ln(x_i!), \\ \frac{d}{d\lambda} \ln L(\lambda) &= -n + \frac{1}{\lambda} \sum x_i. \\ \frac{d}{d\lambda} \ln L(\lambda) = 0 &\Rightarrow \lambda = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}. \\ \lambda = h(x_1, x_2, \dots, x_n) &= \frac{1}{n} \sum_{i=1}^n x_i \Rightarrow \widehat{T} = h(X_1, X_2, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i. \end{aligned}$$

ML-procenitelj za λ u Poisonovoj razdiobi je $\widehat{T} = \bar{X}$.

Možemo pokazati da je \widehat{T} nepristrani procenitelj $E(\widehat{T}) = \lambda$.

Prisjetimo se da je $E(X) = \lambda$ i da je \bar{X} nepristrani procenitelj za očekivanje.

$E(\widehat{T}) = E(\bar{X}) = E(X) = \lambda$.

PRIMJER 12.8 važno

Metodom najveće vjerojatnosti pokažite da je procenitelj

(a) za parametar μ u populaciji s Normalnom razdiobom $N(\mu, \sigma^2)$ ako je σ^2 poznato jednak $\widehat{T} = \bar{X}$

(b) za parametar σ^2 u populaciji s Normalnom razdiobom $N(\mu, \sigma^2)$ ako je μ poznato jednak $\widehat{T} = \widehat{\Sigma}^2$.

Rješenje: Neka je $X \sim N(\mu, \sigma^2)$.

Teorijska funkcija gustoće vjerojatnosti je $f(x, \mu, \sigma^2) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$.

Trebamo naći ML-procenitelje za μ i σ^2 .

Funkcija vjerodostojnosti je:

$$L(\mu, \sigma^2) = f(x_1, \mu, \sigma^2) \cdot f(x_2, \mu, \sigma^2) \cdots f(x_n, \mu, \sigma^2) = \left(\frac{1}{\sigma \sqrt{2\pi}} \right)^n \cdot e^{-\frac{1}{2\sigma^2} \sum (x_i - \mu)^2}.$$

12. TEORIJA PROCJENA

$$\ln L(\mu, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 - n \ln \sigma - n \ln \sqrt{2\pi}.$$

$$(a) \frac{d}{d\mu} \ln L(\mu, \sigma^2) = -\frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0,$$

$$\frac{d}{d\mu} \ln L(\mu, \sigma^2) = 0 \Rightarrow \mu = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x},$$

ML-procjenitelj za očekivanje u normalnoj razdiobi je $\widehat{T} = \bar{X}$. To je nepristrani procjenitelj za μ jer je $E(\widehat{T}) = \mu$.

$$(b) \frac{d}{d\sigma} \ln L(\mu, \sigma^2) = -\frac{1}{\sigma^3} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{\sigma} = 0,$$

$$\frac{d}{d\sigma} \ln L(\mu, \sigma^2) = 0 \Rightarrow \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \widehat{\sigma^2}, \text{ uzoračka varijanca.}$$

ML-procjenitelj za varijancu u normalnoj razdiobi je $\widehat{T} = \widehat{\Sigma^2}$. To nije nepristrani procjenitelj za σ^2 jer je $E(\widehat{T}) = \frac{n-1}{n} \sigma^2$.

Prisjetimo se motivacijskog primjera:

PRIMJER 12.9 motiv

U četiri mjerena Rockwellove tvrdoće jedne ploče radnici du dobili sljedeće vrijednosti: 64.9, 64.1, 63.8, 64.0. (a) Izračunajte vrijednost procjenitelja (u smislu najveće vjerojatnosti-ML-procjenitelj) za očekivanje i varijancu tvrdoće ako prepostavimo normalnu distribuciju.

(b) Izračunajte vrijednost nepristranih procjenitelja za očekivanje i varijancu tvrdoće ako prepostavimo normalnu distribuciju.

Rješenje: (a) ML-procjenitelj za očekivanje μ je uzoračka aritmetička sredina \bar{X} .

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 64.2$$

ML-procjenitelj za varijancu σ^2 je uzoračka varijanca $\widehat{\Sigma^2}$.

$$\widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = 0.175$$

(b) Nepristrani procjenitelj za očekivanje μ je uzoračka aritmetička sredina \bar{X} .

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 64.2$$

Nepristrani procjenitelj za varijancu σ^2 je korigirana uzoračka varijanca $\widehat{S^2}$.

$$\widehat{S^2} = \frac{1}{n-1} \sum_{i=1}^{n-1} (x_i - \bar{x})^2 = 0.233.$$

PRIMJER 12.10 *važno*

Metodom najveće vjerojatnosti pokažite da je procjenitelj za parametar p u populaciji s Binomnom razdiobom $B(m, p)$ uz pretpostavku da je m poznato jednak $\widehat{T} = \frac{\bar{X}}{m}$

Rješenje: Neka je $X \sim B(m, p)$. Teorijska funkcija vjerojatnosti je $f(x, m, p) = P(X = x, m, p) = \binom{m}{x} (1-p)^{m-x} p^x$. Trebamo naći ML-procjentelj za p . Funkcija vjerodostojnosti je

$$\begin{aligned} L(p) &= P(X_1 = x_1, m, p) \cdot P(X_2 = x_2, m, p) \cdot \dots \cdot P(X_n = x_n, m, p) \\ &= \prod_{i=1}^n \binom{m}{x_i} (1-p)^{m-x_i} p^{x_i} \end{aligned}$$

Tražimo maksimum funkcije vjerodostojnosti $\ln L(p)$:

$$\ln L(p) = \sum [\ln \binom{m}{x_i} + (m - x_i) \ln(1-p) + x_i \ln p],$$

$$\frac{d}{dp} \ln L(p) = -\frac{1}{1-p} \sum (m - x_i) + \frac{1}{p} \sum x_i$$

$$\frac{d}{d\lambda} \ln L(\lambda) = 0 \Rightarrow p = \frac{1}{m} \cdot \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{m} \bar{x}.$$

$$p = h(x_1, x_2, \dots, x_n) = \frac{1}{m} \cdot \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{m} \bar{x}$$

$$\widehat{T} = h(X_1, X_2, \dots, X_n) = \frac{1}{m} \cdot \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{m} \bar{X}.$$

ML-procjentelj za p u Binomnoj razdiobi $B(m, p)$ s poznatim m je $\widehat{T} = \frac{1}{m} \bar{X}$.

Možemo pokazati da je \widehat{T} nepristrani procjenitelj $E(\widehat{T}) = p$.

Prisjetimo se da je $E(X) = mp$ i da je \bar{X} nepristrani procjenitelj za očekivanje.

$$E(\widehat{T}) = E\left(\frac{1}{m} \bar{X}\right) = \frac{1}{m} E(\bar{X}) = \frac{1}{m} E(X) = \frac{1}{m} mp = p.$$

12. TEORIJA PROCJENA

12.4 Ponovimo

PROCJENITELJI PARAMETARA ZADANE DISTRIBUCIJE s očekivanjem μ i varijancom σ^2

slučajni uzorak	$(X_1, X_2, \dots, X_n) : \Omega \rightarrow \mathbb{R}^n$
statistika	$T = h(X_1, X_2, \dots, X_n), T : \Omega \rightarrow \mathbb{R}$
procjenitelj	$\widehat{T} = h(X_1, X_2, \dots, X_n)$
nepristrani procjenitelj za parametar t	$E(\widehat{T}) = t$
uzoračka aritm. sredina	$\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
	$E(\bar{X}) = \mu,$
	$Var(\bar{X}) = \frac{\sigma^2}{n}$
$n \rightarrow \infty$	$\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$
uzoračka varijanca	$\widehat{\Sigma}^2 = \frac{1}{n} \sum_i (X_i - \bar{X})^2$
	$\widehat{\sigma}^2 = \frac{1}{n} \sum_i (x_i - \bar{x})^2$
uzoračka stand. devijacija	$\widehat{\sigma}$
	$E(\widehat{\Sigma}^2) = \frac{n-1}{n} \sigma^2$
korigirana uzoračka varijanca	$\widehat{S}^2 = \frac{1}{n-1} \sum_i (X_i - \bar{X})^2$
	$\widehat{s}^2 = \frac{1}{n-1} \sum_i (x_i - \bar{x})^2$
korigirana uz. stand. devijacija	\widehat{s}
	$E(\widehat{S}^2) = \sigma^2$

PROCJENITELJI PARAMETARA ZADANE DISTRIBUCIJE (ML)

distribucija ; parametar	procjenitelj
$Po(\lambda); \lambda$	$\widehat{T} = \bar{X}$
$N(\mu, \sigma^2); \mu$	$\widehat{T} = \bar{X}$
$N(\mu, \sigma^2); \sigma^2$	$\widehat{T} = \widehat{\Sigma}^2$
$(B(m, p); p$	$\widehat{T} = \frac{1}{m} \bar{X}$

STATISTIKE PARAMETARA NORMALNE DISTRIBUCIJE $N(\mu, \sigma^2)$

slučajni uzorak za X	$(X_1, X_2, \dots, X_n) : \Omega \rightarrow \mathbb{R}^n$
statistika $T = h(X_1, X_2, \dots, X_n)$	distribucija
\bar{X}	$\sim N(\mu, \frac{\sigma}{\sqrt{n}})$
$\sqrt{n} \frac{\bar{X} - \mu}{\sigma}$	$\sim N(0, 1)$
$\sqrt{n} \frac{\bar{X} - \mu}{\widehat{S}}$	$\sim t(n-1)$
$\frac{n-1}{\sigma^2} \widehat{S}^2$	$\sim \chi^2(n-1)$

REGRESIJSKA ANALIZA

slučajni uzorak za (X, Y)	$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$
uzoračka kovarijanca	$\widehat{\mu}_{xy} = \frac{1}{n} \sum_i (x_i - \bar{x})(y_i - \bar{y})$
uzorački koef. korelacije	$\widehat{\rho}_{xy} = \frac{\widehat{\mu}_{xy}}{\sqrt{n \sum x \cdot y - (\sum x) \cdot (\sum y)}} \cdot \sqrt{\frac{1}{n \sum x^2 - (\sum x)^2} \cdot \frac{1}{n \sum y^2 - (\sum y)^2}}$
$Y = aX + b$	a- uzorački koef. regresije
a	$\widehat{\mu}_{xy}$ $= \frac{n \sum x \cdot y - (\sum x) \cdot (\sum y)}{n \sum x^2 - (\sum x)^2}$
b	$\bar{y} - \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} \cdot \bar{x}$ $= \frac{(\sum y) \cdot (\sum x^2) - (\sum x) \cdot (\sum x \cdot y)}{n \sum x^2 - (\sum x)^2}$
pravac regresije Y po X	$y - \bar{y} = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_1^2} (x - \bar{x})$
pravac regresije X po Y	$x - \bar{x} = \frac{\widehat{\mu}_{xy}}{\widehat{\sigma}_2^2} (y - \bar{y})$