

Statistika i osnovna mjerenja

Procjenitelji i pogreške

M. Makek

2017/2018

Procjena parametara populacije

- Uzmimo da populacija ima karakteristične parametre poput μ , σ , σ^2 , momenti, itd.
- Te parametre je nemoguće odrediti na cijeloj populaciji, stoga se uzima **uzorak** i na temelju njega se procjenjuju parametri populacije
- Uzmimo slučajnu varijablu Θ kao **procjenitelj** parametra θ
- Θ je nepristrani procjenitelj parametra θ ako vrijedi:

$$E(\Theta) = \theta$$

tj. mu je očekivanje stvarno jednako tom parametru

Procjena parametara populacije

- Ako je X_1, \dots, X_n slučajni uzorak populacije, onda je slučajna varijabla \bar{X} (prosjek uzorka) nepristrani procjenitelj očekivanja populacije μ

Dokaz: pokazali smo da je očekivanje \bar{X} jednako očekivanju populacije

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

- Ako je X_1, \dots, X_n slučajni uzorak populacije, onda je slučajna varijabla S^2 nepristrani procjenitelj varijance populacije σ^2

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}$$

- Dokaz slijedi

Procjena parametara populacije

- Pokazali smo da za bilo koju slučajnu varijablu Y vrijedi:

$$V(Y) = E(Y^2) - [E(Y)]^2$$

- Stoga za slučajnu varijablu X_i možemo pisati:

$$E(X_i^2) = [E(X_i)]^2 + V(X_i)$$

- Raspišemo izraz za S^2 :

$$S^2 = \frac{1}{n-1} \left[\sum X_i^2 - \frac{1}{n} \left(\sum X_i \right)^2 \right]$$

Procjena parametara populacije

$$\begin{aligned} E(S^2) &= \frac{1}{n-1} \left\{ \sum E(X_i^2) - \frac{1}{n} E \left[\left(\sum X_i \right)^2 \right] \right\} \\ &= \frac{1}{n-1} \left\{ \sum (\mu^2 + \sigma^2) \right. \\ &\quad \left. - \frac{1}{n} \left\{ V \left[\sum X_i \right] + \left[E \left(\sum X_i \right) \right]^2 \right\} \right\} \\ &= \frac{1}{n-1} \left\{ \sum (\mu^2 + \sigma^2) - \frac{1}{n} \{ V[T_0] + [E(T_0)]^2 \} \right\} \\ &= \frac{1}{n-1} \left\{ \sum (\mu^2 + \sigma^2) - \frac{1}{n} \{ n\sigma^2 + [n\mu]^2 \} \right\} = \sigma^2 \end{aligned}$$

- Što je i trebalo pokazati

Pogreške mjerenja

- U fizici se rezultati mjerenja pišu kao srednja vrijednost nezavisnih mjerena u intervalu od 68% pouzdanosti: $\bar{x} \pm M$
- Gdje je $M = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n(n-1)}}$ nepouzdanost prosjeka, koju nazivamo i **standardnom greškom** (sad znamo od kuda dolazi ova formula)
- Pri tome je rasipanje odn.
Standardna devijacija uzorka: $m = s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$
- Obzirom da je rasipanje dolazi zbog nemogućnosti kontrole slučajnih pogrešaka, kažemo da je m mjera **preciznosti aparature**
- m se ne mijenja značajno s povećanjem broja mjerena, no $M=m/\sqrt{n}$ se smanjuje te kažemo da je rezultat pouzdaniji ako napravimo više mjerena

Intervali pouzdanosti

- Procjenom parametara dobivamo njihove iznose, no ne znamo koliko su ti iznosi pouzdani!
- Npr. ako izračunamo prosjek uzorka on neće biti identičan očekivanju populacije, no zanima nas koliko je njihovo odstupanje
- Prema središnjem graničnom teoremu, srednja vrijednost uzorka ima normalnu raspodjelu $\bar{X} \sim N(\mu, \sigma^2/n)$ gdje su μ i σ očekivanje i varijanca populacije

Pouzdanost procjene prosjeka populacije

- Obzirom da srednja vrijednost uzorka ima normalnu raspodjelu, vrijedi:

$$P\left(-1 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1\right) = 68\%$$

$$P\left(-1,96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1,96\right) = 95\%$$

$$P\left(-2,575 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 2,575\right) = 99\%$$

- Dakle možemo reći da se prava vrijednost očekivanja populacije nalazu i intervalu:
 $\bar{x} \pm \frac{\sigma}{\sqrt{n}}$

Pouzdanost procjene prosjeka populacije

- u prethodnoj relaciji smo pretpostavili da je varijanca populacije σ poznata.
- Ako nije poznata onda je procjenjujemo pomoću slučajne varijable:

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}}$$

- Tada interval od 68% pouzdanosti postaje:

$$\bar{x} \pm \frac{s}{\sqrt{n}}$$

Mjerenja različitih statističkih težina

- Mjerimo neku fizikalnu veličinu u nekoliko različitih mjerena s različitim pouzdanostima → zanima nas procjena prave vrijednosti te veličine na temelju tih mjerena
- Izvedeno je k nizova mjerena te fizikalne veličine te je za svaki niz dobivena srednja vrijednost i standardna pogreška:

$$x_i = \bar{x}_i \pm M_i, \quad i = 1 \dots k$$

- Tražimo najvjerojatniju vrijednost x_p mjerene fizikalne veličine na temelju tih mjerena

Opća srednja vrijednost

- Funkcija gustoće vjerojatnosti je na temelju k serija mjerena:

$$f(x_p; \bar{x}_1, \dots, \bar{x}_k) = \frac{1}{M_1 \dots M_k (\sqrt{2\pi})^k} e^{-\sum_{i=1}^k \frac{(\bar{x}_i - x_p)^2}{2M_i^2}}$$

- Da bi našli za koji x_p je f maksimalan logaritmiramo i tražimo minimum sume:

$$\sum_{i=1}^k \frac{(\bar{x}_i - x_p)^2}{2M_i^2} = \min.$$

Opća srednja vrijednost

- Iz uvjeta minimuma slijedi:

$$\frac{d}{dx_p} \sum_{i=1}^k \frac{(\bar{x}_i - x_p)^2}{2M_i^2} = - \sum_{i=1}^k \frac{(\bar{x}_i - x_p)}{M_i^2} = 0$$

$$x_p = \frac{\sum_{i=1}^k \frac{\bar{x}_i}{M_i^2}}{\sum_{i=1}^k \frac{1}{M_i^2}}$$

Pri tome definiramo statističke težine pojedine serije kao:

$$w_i = \frac{1}{\sum_{j=1}^k \frac{1}{M_j^2}}$$

- Slijedi opća srednja vrijednost:



$$x_p = \sum_{i=1}^k w_i \bar{x}_i$$

Nepouzdanost opće srednje vrijednosti

- Da bi odredili pouzdanost sjetimo se da je procjenitelj prave vrijednosti veličine, linearna kombinacija:

$$X_p = \sum_{i=1}^k w_i \bar{X}_i$$

- Prema relaciji za varijancu linearne kombinacije dobivamo:

$$M^2 = V(X_p) = \sum_{i=1}^k w_i^2 V(\bar{X}_i) = \sum_{i=1}^k w_i^2 M_i^2$$

- Primjetimo još da se statističke težine onose kao:

$$w_1 : w_2 : \dots : w_n = \frac{1}{M_1^2} : \frac{1}{M_2^2} : \dots : \frac{1}{M_n^2}$$

- I da vrijedi:

$$\sum_{i=1}^k w_i = 1$$

Propagacija pogreške

- Želimo odrediti neku fizikalnu veličinu preko njene funkcijске ovisnosti u neposredno mjerenim veličinama
- Primjeri:
 - a) Mjerimo masu i volumen predmeta i želimo odrediti njegovu gustoću
 - b) Mjerimo put i vrijeme koje auto prijeđe i želimo odrediti njegovu brzinu
- Pitanje je kako pogreška posredno mjerene veličine ovisi o pogreškama neposredno mjerenih veličina?
- Pri sljedećim razmatranjima pretpostavljamo da su pogreške mjerjenja slučajne (normalno raspodijeljene) i malene tj. da vrijedi $M_i \ll \mu_i$
- Razmotrimo prvo dva specifična primjera koja ćemo poopćiti

Propagacija pogreške

1. Posredna veličina f je linearna kombinacija izravno mjerenih veličina X i Y : $f(X,Y) = aX + bY$

-> Za slučaj linearne kombinacije *nezavisnih* varijabli znamo izračunati očekivanje i varijancu, dakle:

$$E[f(X,Y)] = aE(X) + bE(Y) \quad M_f = a^2 M_X^2 + b^2 M_Y^2$$

2. Posredna veličina f je nelinearna funkcija veličine X : $f(X)$

-> za očekivanje vrijedi (uz pretpostavku malene pogreške):

$$E[f(X)] \simeq f(\mu_X) = f(\bar{X})$$

-> za varijancu vrijedi:

$$M_f^2 = V[f(X)] = E \left[(f(X) - f(\mu_X))^2 \right]$$

Propagacija pogreške

- dalje razvijemo $f(X)$ u red: $f(X) = f(\mu_X) + (X - \mu_X) \frac{df}{dX} \Big|_{\mu_X} + \dots$
- slijedi da je:
$$\begin{aligned} E[(f(X) - f(\mu_X))^2] &\simeq E\left[\left((X - \mu_X) \frac{df}{dX} \Big|_{\mu_X}\right)^2\right] \\ &= \left(\frac{df}{dX} \Big|_{\mu_X}\right)^2 M_X^2 \end{aligned}$$
- odnosno: $f(X) - f(\mu_X) \simeq (X - \mu_X) \frac{df}{dX} \Big|_{\mu_X}$
- Dakle za male pogreške vrijedi: $M_f = \left|\frac{df}{dX} \Big|_{\mu_X}\right| M_X$

Propagacija pogreške

3. Općeniti slučaj – posredna veličina f je funkcija n izravno mjerenih neposrednih *nezavisnih* veličina X_1, \dots, X_n
-> pokazuje se da tada vrijedi:

$$\bar{f}(X_1, \dots, X_n) = f(\bar{x}_1, \dots, \bar{x}_n)$$

$$M_f = \sqrt{\sum_{i=1}^n \left(\frac{\partial f}{\partial X_i} \Big|_{\bar{X}_1, \dots, \bar{X}_n} \right)^2 M_{X_i}^2}$$

To su relacije koje smo uveli na početku, a sada je objašnjeno odakle one dolaze

Propagacija pogrešaka s korelacijom

- Prethodne relacije za propagaciju pogreške vrijede kada su slučajne varijable X i Y nezavisne
- Sada promatramo općenit slučaja kada dopuštamo da mjerena X i Y nisu međusobno nezavisna
- Uzmimo da smo izvršili n mjerena X i Y i kao rezultat dobili (x_i, y_i) , gdje $i=1\dots n$. Na temelju dobivenih vrijednosti izračunamo n vrijednosti veličine $q_i = q(x_i, y_i)$
- Zanima nas srednja vrijednost i pogreška veličine q

Propagacija pogrešaka s korelacijom

- Prepostavljamo da su pogreške opservabli X i Y relativno male tj. da su odstupanja $x_i - \bar{x}$ i $y_i - \bar{y}$ mala tako da pri razvoju u red možemo uzeti samo linearne članove:

$$q_i \approx q(\bar{x}, \bar{y}) + (x_i - \bar{x}) \frac{\partial q}{\partial x} \Big|_{\bar{x}, \bar{y}} + (y_i - \bar{y}) \frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}}$$

- Prema definiciji **srednja vrijednost** je:

$$\bar{q} = \frac{1}{n} \sum_{i=1}^n q_i = \frac{1}{n} \sum_{i=1}^n \left[q(\bar{x}, \bar{y}) + (x_i - \bar{x}) \frac{\partial q}{\partial x} \Big|_{\bar{x}, \bar{y}} + (y_i - \bar{y}) \frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}} \right]$$

$\underbrace{\sum}_{0} \quad \underbrace{\sum}_{0}$

- Slijedi: $\boxed{\bar{q} = q(\bar{x}, \bar{y})}$

Propagacija pogrešaka s korelacijom

- Prema definiciji standardnu devijaciju možemo dobiti prema:

$$\begin{aligned}\sigma_q^2 &= \frac{1}{n} \sum_{i=1}^n (q_i - \bar{q})^2 = \frac{1}{n} \sum_{i=1}^n \left[(x_i - \bar{x}) \frac{\partial q}{\partial x} \Big|_{\bar{x}, \bar{y}} + (y_i - \bar{y}) \frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}} \right]^2 \\ &= \left(\frac{\partial q}{\partial x} \right)^2 \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 + \left(\frac{\partial q}{\partial y} \right)^2 \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 + 2 \frac{\partial q}{\partial x} \frac{\partial q}{\partial y} \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \\ \rightarrow \quad \boxed{\sigma_q^2 = \left(\frac{\partial q}{\partial x} \Big|_{\bar{x}, \bar{y}} \right)^2 \sigma_x^2 + \left(\frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}} \right)^2 \sigma_y^2 + 2 \frac{\partial q}{\partial x} \frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}} \sigma_{xy}}\end{aligned}$$

- gdje je σ_{xy} kovarijanca
- Gornja relacija daje standardnu devijaciju veličine q bez obzira na to jesu li veličine X i Y povezane.
- Za nezavisne varijable X i Y kovarijanca je 0, a relacija za standardnu devijaciju se svodi na prva dva člana

Propagacija pogrešaka s korelacijom

- Ako kovarijanca ne iščezava kažemo da su pogreške opservabli X i Y korelirane, a standardna devijacija σ_q je očito različita nego u slučaju neovisnih, slučajnih pogrešaka.
- Može se pokazati da relacija za σ_q daje opću gornju granicu standardne devijacije veličine q .
- Da bi to dokazali iskoristit ćemo **Cauchy-Schwarzovu** nejednakost:
$$\sigma_{xy} \leq \sigma_x \sigma_y$$
- Uvrštavanjem te nejednakosti u izraz za standardnu devijaciju:

$$\sigma_q^2 \leq \left(\frac{\partial q}{\partial x} \Big|_{\bar{x}, \bar{y}} \right)^2 \sigma_x^2 + \left(\frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}} \right)^2 \sigma_y^2 + 2 \frac{\partial q}{\partial x} \frac{\partial q}{\partial y} \Big|_{\bar{x}, \bar{y}} \sigma_x \sigma_y$$

Propagacija pogrešaka s korelacijom

- Dalje slijedi: $\sigma_q^2 \leq \left[\left| \frac{\partial q}{\partial x} \right| \sigma_x + \left| \frac{\partial q}{\partial y} \right| \sigma_y \right]^2$
- Čime dobivamo gornju granicu za standardnu devijaciju bez obzira na korelaciju varijabli X i Y

$$\sigma_q \leq \left| \frac{\partial q}{\partial x} \right| \sigma_x + \left| \frac{\partial q}{\partial y} \right| \sigma_y$$