

Statistika



Statistična obdelava podatkov

FRI – 2007

Aleksandar Jurišić

Statistika

preučuje podatke, jih
zbira,
klasificira,
povzema,
organizira,
analizira in
interpretira.



Pogled od zunaj



Be gone & you will be homesome
Mark Twain



Dve glavni veji statistike



Opisna statistika se ukvarja z
organiziranjem, povzemanjem in
opisovanjem zbirk podatkov
(reduciranje podatkov na povzetke)

Analitična statistika jemlje vzorce podat
in na osnovi njih naredi zaključke
(inferenčnost) o populaciji
(ekstrapolacija).



Načrt

• Opisna statistika

- ena spremenljivka
 - Mere centralne tendence
 - Mere razpršnosti
 - Mere oblike
- dve spremenljivki
 - Mere asociacije

• Inferenčna (analitična) statistika


- točkovno in intervalno ocenjevanje
- ena- in dva- vzorčno testiranje hipotez
- kontingenčne tabele
- regresija



Tipi podatkovnih množic

• Populacija

- vsi objekti, ki jih opazujemo



• Vzorec

- podmnožica populacije



- Primer: 100 registriranih glasovalcev



Populacija je podatkovna množica, ki ji je namenjena naša pozornost.



Vzorec je podmnožica podatkov,


ki so izbrani iz

Populacije

(po velikosti

bistveno manjši

od populacije).




Tipi podatkov

- **kvantitativni**

(numerični)

predstavljajo kvantiteto
ali količino nečesa.



- **kvalitativni (kategorije)**

ni kvantitativnih interpretacij.



Kvantitativni (numerični)

- interval
 - poljubna ničla
 - enaki intervali predstavljajo enake količine
- razmerje
 - smiselna točka nič
 - operacije seštevanje, odštevanje, množenje in deljenje so smiselne

Kvalitativni (kategorični)


- nominalni
 - kategorije brez odgovarjajočega vrstnega reda – urejenosti
- ordinalni/številski
 - kategorije z urejenostjo

Oddelek sistemskih inženirjev


kategorija	frekvenca	relativna frekvenca
vrsta zaposlenih	število zaposlenih	delež
učitelji	16	0,8421
skupne službe	3	0,1579
skupaj	19	1,0000

Grafična predstavitev kvalitativnih podatkov


- stolpčni graf,
poligonski diagram
- strukturni krog
pogača, kolač




Stolpčni graf oddelek sistemskih inženirjev



Pareto diagram (po italijanskem ekonomistu) oddelek sistemskih inženirjev




Strukturni krog (pogača, kolač) oddelek sistemskih inženirjev




Grafična predstavitev kvantitativnih podatkov


- runs plot (X, Y plot)
- zaporedje (dot plot)
- steblo-list predstavitev (angl. stem-and-leaf)
- histogrami
- škatla z brki (box plot)



Runs Chart



Dot Plot



Koraki za konstrukcijo steblo-list predstavitev

1. Razdeli vsako opazovanje-podatke na dva dela, **steba** (angl. stem) in **listi** (angl. leaf).
2. Naštej steba po vrsti v stolpec, tako da začneš pri najmanjšem in končaš pri največjem.



Urejeno zaporedje/ranžirana vrs

Urejeno zaporedje je zapis podatkov v vrsto po njihovi numerični velikosti (ustreznemu mestu pravimo **rang).**



Primer zaporedja podatkov (nal. 2.48, str.64)

- a. Konstruiraj urejeno zaporedje.
- | | | | | |
|-----|-----|-----|-----|-----|
| 88 | 103 | 113 | 122 | 132 |
| 92 | 108 | 114 | 124 | 133 |
| 95 | 109 | 116 | 124 | 133 |
| 97 | 109 | 116 | 124 | 135 |
| 97 | 111 | 117 | 128 | 136 |
| 97 | 111 | 118 | 128 | 138 |
| 98 | 112 | 119 | 128 | 138 |
| 98 | 112 | 120 | 131 | 142 |
| 100 | 112 | 120 | 131 | 146 |
| 100 | 113 | 122 | 131 | 150 |
- e. Nariši steblo-list diagram.
- i. Naredi histogram.



Koraki za konstrukcijo steblo-list predstavitev

1. Upoštevaj vse podatke in postavi liste za vsak dogodek/meritev v ustrezno vrstico/steblo.
4. Naštej frekvence za vsako steblo.



Steblo-list diagram

steba/listi	frekvenca	relativna frekvenca
08 8	1	2%
09 2 5 7 7 7 8 8	7	14%
10 0 0 3 8 9 9	6	12%
11 1 1 2 2 2 3 3 4 6 6 7 8 9	13	26%
12 0 0 2 2 4 4 4 8 8 8	10	20%
13 1 1 1 2 3 3 5 6 8 8	10	20%
14 2 6	2	4%
15 0	1	2%
	50	100%



Histogrami

- kako zgradimo histogram
- število razredov
- frekvenca
- procenti



Frekvenčna porazdelitev

razred	interval razreda	frekvenca	relativn frekvenc
1	80 - 90	1	2%
2	90 - 100	7	14%
3	100 - 110	6	12%
4	110 - 120	13	26%
5	120 - 130	10	20%
6	130 - 140	10	20%
7	140 - 150	2	4%
8	150 - 160	1	2%

50 100%




Kako zgradimo histogram

1. Izračunaj **razpon** podatkov.
2. Razdeli razpon na **5 do 20 razredov** enake širine.
4. Za vsak razred preštej število vzorcev, ki spadajo v ta razred.
To število imenujemo **frekvenca razredov**.
8. Izračunaj vse **relativne frekvence razredov**.



Frekvenčni histogram



št. delovnih ur




Pravilo za določanje števila razredov v histogramu

število vzorcev v množici podatkov	število razredov
manj kot 25	5 ali 6
25 - 50	7 - 14
več kot 50	15 - 20



Procentni histogram



št. delovnih ur



Mere za lokacijo in razpršeno

- srednje vrednosti
- razpon (min./max)
- centili, kvartili
- varianca
- standardni odklon
- Z-vrednosti



Mediana

populacije: μ



vzorca: m



Modus (M_o)

Modus množice podatkov je tista vrednost, ki se pojavi z največjo frekvenco.




Povprečje

populacije:

$$\mu = \frac{\sum_{i=1}^n y_i}{n}$$

vzorca:

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n}$$




Mediana (M_e)

Da bi prišli do mediane za neko množico podatkov, naredimo naslednje:

1. podatke uredimo po velikosti v naraščajočem vrstnem redu,
2. če je število podatkov liho, potem je mediana podatek na sredini,
12. če je število podatkov sodo, je mediana enaka povprečju dveh podatkov na sredini.



Povprečje in mediana




Razpon ali variacijski razmik

Razpon je razlika med največjo in najmanjšo meritvijo v množici podatkov.



- 25. centil se imenuje tudi **1. kvartil**.
- 50. centil se imenuje **2. kvartil ali media**
- 75. centil se imenuje tudi **3. kvartil**.



Centili

100 p -ti centil (p je med 0 in 1) je definiran kot število, od katerega ima $100p$ procentov meritev manjšo ali enako numerično vrednost.




Določanje 100 p -tega centila

Izračunaj vrednost $i = p(n+1)$ in jo zaokroži na najbližje celo število. To število je enako i .

Izmerjena vrednost z i -tim rangom je **100 p -ti centil**.



Škatla z brki (angl. box plot)



Mere razpršenosti

- **varianca**
 - kvadrat pričakovanega odklona (populacije)
 - vsota kvadratov odklonov deljena s stopnjo prostosti (vzorec)
- **standardni odklon (deviacija)**
 - pozitivni kvadratni koren variance
- **koeficient variacije**
 - standardni odklon deljen s povprečjem



Mere razpršenosti

	populacija	vzorec
varianca	σ^2	S^2, s^2
standardni odklon	σ	S, s



Varianca

vzorca:


$$s^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1}$$
$$= \frac{\sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i\right)^2}{n-1}$$

(z n meritvami).



Za vzorec smo vzeli osebje na FRI.

Zabeležili smo naslednje število otrok:



Varianca

populacije:

$$\sigma^2 = \frac{\sum_{i=1}^n (y_i - \mu)^2}{n}$$


(končne populacije z n meritvami).



Empirična pravila

Če ima podatkovna množica porazdelitev približno zvonaste oblike (unimodalna oblika – ima en sam vrh), potem veljajo naslednja pravila (angl. rule of thumb), ki jih lahko uporabimo za opis podatkovne množice:

7. Približno **68,3%** vseh meritev leži na razdalji **1 x standardnega odklona** od njihovega povprečja.



Standardni odklon

Standardni odklon je pozitivno predznačen kvadratni koren variance.



Empirična pravila

- Približno **95,4%** meritev leži na razdalji do **2 x standardnega odklona** od njihovega povprečja.
- Skoraj vse** meritve (**99,7%**) ležijo na razdalji **3 x standardnega odklona** od njihovega povprečja.



Mere asimetrije

Razlike med srednjimi vrednostimi so tem večje, čim bolj je porazdelitev asimetrična:

$$KA_{Mo} = (\mu - M_o)/\sigma$$

$$KA_{Me} = 3(\mu - M_e)/\sigma$$

Koeficient asimetrije (s centralnimi momenti)

$$g_1 = m_3/m_2^{3/2}$$



Mere oblike

Če je spremenljivka približno normalnopravljena, potem jo statistični karakteristiki povprečje in standardni odklon zelo dobro opisujeta.

V primeru unimodalne porazdelitve spremenljivke, ki pa je bolj asimetrična, bolj ali manj sploščena (koničasta), pa potrebno izračunati še stopnjo **asimetrije** in **sploščenosti** (koničavosti).



Centralni momenti

***l*-ti centralni moment** je

$$m_l = \frac{\sum_{i=1}^n (y_i - \mu)^l}{n}$$

$$m_1 = 0, \quad m_2 = \sigma^2$$



Mera sploščenosti (kurtosis)

Koeficient sploščenosti
(s centralnimi momenti)

$$K = g_2 = m_4/m_2^2 - 3$$




Mera sploščenosti (kurtosis)

- $K = 3$ (ali 0)**
 - normalna porazdelitev zvonaste-oblike (mesokurtic)
- $K < 3$ (ali negativna)**
 - bolj kopasta kot normalna porazdelitev, s krajšimi repi (platykurtic)
- $K > 3$ (ali pozitivna)**
 - bolj špičasta kot normalna porazdelitev, z daljšimi repi (leptokurtic)




Normalna porazdelitev



asimetričnost = 0, sploščenost = 3 (mesokurt)




Asimetrična v desno



asimetričnost = 1,99, sploščenost = 8,85 (leptok)




Kopasta porazdelitev



asimetričnost = 0, sploščenost = 1,86 (platykurtic)

Špičasta porazdelitev



asimetričnost = -1,99, sploščenost = 8,85 (leptok)




Standardizacija

Vsaki vrednosti x_i spremenljivke X odštejemo njeno povprečje μ in delimo z njenim standardnim odklonom σ :


$$z_i = (x_i - \mu) / \sigma$$

Z imenujemo standardizirana spremenljivka,
 z_i pa standardizirana vrednost.
Potem je $\mu(Z)=0$ in $\sigma(Z)=1$.

Frekvenčni histogram



Relativni frekvenčni histogram



Histogram standardiziranih Z-vrednosti

