

# Osnove verjetnosti in statistika

Gašper Fijavž

Fakulteta za računalništvo in informatiko  
Univerza v Ljubljani

Ljubljana, 7. maj 2010

## Statistika

1. Opisna statistika.
2. Vzorčenje.
3. Ocenjevanje parametrov.
4. Testiranje hipotez.
5. Linearna regresija.
6. Morda še kaj.

## Vzorčenje

*Populacija* ... velika količina podatkov ...  $N$

*Vzorec* ... majhna podmnožica podatkov ...  $n$

*Slučajni vzorec* ... vsak vzorec iste moči ima isto verjetnost, da bo izbran

*Slučajni vzorec s ponavljanjem* ... dovolimo, da se podatki v vzorcu ponavljajo

*Cilj statističnih metod*: na podlagi analize vzorca želimo sklepati na celotno populacijo.

## Zgledi

- ▶ Volitve.
- ▶ Kontrola izdelkov.
- ▶ Študenti.
- ▶ Psevdonaključna števila.

## Ponavljanje, da ali ne

$N$  ... velikost populacije

$n$  ... velikost vzorca

### Trditev

*Če je  $N$  velik v primerjavi z  $n$ , potem je število vzorcev brez ponavljanja približno enako kot število vzorcev s ponavljanjem.*

## Ponavljanje, načeloma da, v praksi ne.

*Zgled:* Ocene šestih študentov so 10, 7, 7, 8, 6, 10. Vzorčimo brez ponavljanja, vzorci so velikosti 2. Koliko je vzorcev? Kaj lahko poveš o povprečni oceni vzorca?

## Kvantili, mediana, kvartili, percentili

Naj  $X$  določa slučajno spremenljivko - vrednost parametra na populaciji.

Izberimo  $q \in (0, 1)$ . Vrednosti  $a$  pravimo *q-kvantil* za  $X$ , če je

$$P(X \leq a) \geq q \text{ in } P(a \leq X) \geq 1 - q.$$

*Mediana* je 0,5-kvantil.

0,25, 0,5 in 0,75-kvantilom pravimo *kvartili*.

0,01, ..., 0,99-kvantili so *percentili*.

## Vzorčno povprečje

Naj bo  $Y$  spremenljivka na populaciji. Izberemo vzorec velikosti  $n$ , pridobimo vrednosti  $Y_1, Y_2, \dots, Y_n$ .

*Vzorčno povprečje* je  $\bar{Y} = \frac{1}{n}(Y_1 + Y_2 + \dots + Y_n)$ .

### Izrek

*Matematično upanje vzorčnega povprečja je enako povprečni vrednosti (matematičnemu upanju) na celotni populaciji:*

$$E(\bar{Y}) = E(Y).$$

## Vzorčno povprečje

### Izrek

Naj bo  $Y$  spremenljivka na populaciji velikosti  $N$ ,  $\mu = E(Y)$ ,  $\sigma^2 = D(Y)$ . Vzorčimo brez ponavljanja, vzorci velikosti  $n$ . Velja:

- (a)  $E(\bar{Y}) = E(Y) = \mu$
- (b)  $D(\bar{Y}) = D(Y) \cdot \frac{N-n}{n(N-1)} \xrightarrow{n \rightarrow \infty} \frac{1}{n} D(Y) = \frac{1}{n} \sigma^2$   
in  $\sigma(\bar{Y}) \approx \frac{1}{\sqrt{n}} \sigma$
- (c) Če je  $Y$  na populaciji normalno porazdeljena z  $N(\mu, \sigma)$ , potem je  $\bar{Y}$  na vzorcih tudi normalno porazdeljena z  $N(\mu, \frac{\sigma}{\sqrt{n}})$ .
- (d) Četudi  $Y$  na populaciji **ni** normalno porazdeljena, je  $\bar{Y}$  na populaciji **približno** normalno porazdeljena z  $N(\mu, \frac{\sigma}{\sqrt{n}})$ .

## Vzorčno povprečje

*Naloga:* Populacija šteje 3000 študentov (moških). Predpostavimo, da so njihove višine porazdeljene s povprečjem 180 cm in standardno deviacijo 5 cm.

Naključno izberemo vzorec 25 študentov in izmerimo povprečno višino vzorca.

- ▶ Določi matematično upanje za povprečno višino vzorca.
- ▶ Določi standardno deviacijo za povprečno višino vzorca.
- ▶ Oceni verjetnost, da bo imel naključno izbrani vzorec povprečje višin
  - ▶ med 178 in 182 cm.
  - ▶ več kot 183 cm.
  - ▶ manj kot 175 cm.

## Disperzija vzorca

Vzorec velikosti  $n$  z vrednostmi  $X_1, \dots, X_n$  in vzorčnim povprečjem  $\bar{X}$ . *Vzorčno disperzijo  $s^2$*  in *popravljeno vzorčno disperzijo  $\hat{s}^2$*  definiramo kot

$$s^2 = \frac{(X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2}{n}$$

$$\hat{s}^2 = \frac{(X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2}{n - 1}$$

## Izrek

$$E(s^2) = \frac{N}{N - 1} \cdot \frac{n - 1}{n} \cdot \sigma^2 \quad \text{in} \quad E(\hat{s}^2) = \frac{N}{N - 1} \cdot \sigma^2$$

## Zgled

*Naloga:* Vzorec ocen študentov vsebuje ocene 7, 9, 10, 10, 6, 10, 8, 8, 7, 7, 7, 7. Izračunaj vzorčno povprečje, vzorčno disperzijo in popravljeno vzorčno disperzijo.

## Porazdelitev vzorčnega povprečja

Naj bo  $\mu$  matematično upanje na populaciji. Potem je:

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1) \quad T = \frac{\bar{X} - \mu}{\hat{s}/\sqrt{n}}$$

Če  $\sigma$  ne poznamo, jo nadomestimo z  $\hat{s}$ . Če je vzorec dovolj velik ( $n \geq 30$ ), je tudi  $T \sim N(0, 1)$ .

Če je  $n \leq 30$ , potem je potrebno uporabiti Studentovo porazdelitev.

## Zgled

Merimo življensko dobo žarnic;  $N = 1.000.000$  in  $n = 100$ . Na vzorcu izmerimo

$$\begin{array}{c|cccccc} & 500 & 1000 & 1500 & 2000 & 2500 & 3000 \\ \hline & 10 & 5 & 5 & 65 & 10 & 5 \end{array} .$$

Določi  $\bar{X}$ ,  $s^2$ ,  $\hat{s}^2$ . Določi  $T$  in oceni interval za  $\mu$ .

## Ocenjevanje parametrov

Naj bo  $\lambda$  parameter, odvisen od slučajne spremenljivke  $X$ .

$I$  je **interval zaupanja** za vrednost parametra  $\lambda$  pri stopnji zaupanja  $\gamma$ , če velja naslednje:

- ▶ Verjetnost, da parameter  $\lambda$  pripada intervalu  $I$  je (ne glede na porazdelitev  $X$ ) vsaj  $\gamma$ .
- ▶ Interval  $I$  je najmanjši možen.

## Ocenjevanje $\mu$

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

Torej je  $\bar{X}$  na vzorcih je porazdeljen približno kot  $N(\mu, \frac{\sigma}{\sqrt{n}})$ .

Recept:

1. Izberi stopnjo zaupanja  $\gamma$  (tipično 0,9 , 0,95 , 0,99 ali 0,999).
2. Določi  $c$  za katerega velja  $\Phi(c) = \gamma/2$ .
3. Izračunaj  $\bar{X}$  in  $k = \frac{c \cdot \sigma}{\sqrt{n}}$  .
4. Interval zaupanja je  $I = [\bar{X} - k, \bar{X} + k]$ .

## Ocenjevanje $\mu$

Kaj če  $\sigma$  ne poznamo?

Kaj če je vzorec majhen ( $n \leq 30$ )?

## Porazdelitev $\chi^2$

Naj bodo slučajne spremenljivke  $X_1, X_2, \dots, X_n$  porazdeljene standardno normalno in neodvisne.

$$\chi^2(n) := X_1^2 + X_2^2 + \dots + X_n^2$$

Slučajna spremenljivka  $\chi^2(n)$  hi-kvadrat z  $n$ -prostostnimi stopnjami je vsota  $n$  kvadratov neodvisnih standardno normalno porazdeljenih slučajnih spremenljivk.

$$P(\chi^2 \leq a) = \frac{1}{2^{\frac{n}{2}} \Gamma\left(\frac{n}{2}\right)} \int_0^a x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx$$

če je  $a \geq 0$ .

## Porazdelitev $\chi^2$

Za izračun verjetnosti slučajne spremenljivke  $\chi^2$  uporabimo tabele. Fiksirajmo število prostostnih stopenj.

$\chi_p^2$  je vrednost, pri kateri je  $P(\chi^2 \leq \chi_p^2) = p$ .

## Interval zaupanja za standardno deviacijo

Izrek

$$\frac{n \cdot s^2}{\sigma^2} = \frac{(n - 1) \cdot \hat{s}^2}{\sigma^2} \sim \chi^2(n - 1)$$

Radi bi določili interval  $[c_1, c_2]$  za katerega velja, da je

$$P(c_1 \leq \sigma \leq c_2) \geq \gamma$$

kjer je  $\gamma$  izbrana stopnja zaupanja.

## Interval zaupanja za standardno deviacijo

Iščemo interval, za katerega je

- $P(\chi^2 \leq \chi^2_{p_1})$  za  $p_1 = \frac{1+\gamma}{2}$
- $P(\chi^2 \leq \chi^2_{p_2})$  za  $p_2 = \frac{1-\gamma}{2}$

Potem je

$$P(\chi^2_{p_2} \leq \chi^2 \leq \chi^2_{p_1}) = \frac{1+\gamma}{2} - \frac{1-\gamma}{2} = \gamma$$

## Žarnice, znova

$$N = 1.000.000, n = 100, \hat{s} = 591,92, \hat{s}^2 = 350379$$

Naloga: Določi interval zaupanja za  $\sigma$  pri stopnjah zaupanja  $\gamma = 0,99, 0,95$  in  $0,90$ .

## Žarnice, znova

99 prostostnih stopenj:

1.  $\chi^2$  lahko izračunamo:

$$\begin{aligned}\chi_{0,005}^2 &= 66,5, \quad \chi_{0,025}^2 = 73,4, \quad \chi_{0,05}^2 = 77,0, \\ \chi_{0,95}^2 &= 123,2, \quad \chi_{0,975}^2 = 128,4, \quad \chi_{0,995}^2 = 138,9\end{aligned}$$

2.  $\chi^2$  lahko ocenimo z linearno interpolacijo:

$$\begin{aligned}\chi_{0,005}^2 &= 66,5, \quad \chi_{0,025}^2 = 73,7, \quad \chi_{0,05}^2 = 77,0, \\ \chi_{0,95}^2 &= 122,9, \quad \chi_{0,975}^2 = 128,8, \quad \chi_{0,995}^2 = 138,8\end{aligned}$$

3.  $\chi^2$  lahko ocenimo s pomočjo centralnega limitnega izreka:

$$\begin{aligned}\chi_{0,005}^2 &= 62,8, \quad \chi_{0,025}^2 = 71,4, \quad \chi_{0,05}^2 = 75,9, \\ \chi_{0,95}^2 &= 122,1, \quad \chi_{0,975}^2 = 126,6, \quad \chi_{0,995}^2 = 135,2\end{aligned}$$

## Žarnice, primerjava

Intervali zaupanja za  $\sigma$ , glede na različne metode izračuna  $\chi^2(99)$ .

stopnja zaupanja $\gamma$	1.	2.	3.
0.99	[500,722]	[500,722]	[506,743]
0.95	[520,678]	[519,687]	[523,697]
0.90	[531,671]	[531,671]	[533,676]

## Statistične hipoteze

*Statistična hipoteza* je hipoteza o porazdelitvi slučajne spremenljivke.

*Statistični test* je bodisi

- ▶ *parametričen* ... znan je tip porazdelitve, hipoteza govori o parametru.
- ▶ *neparametričen* ... porazdelitev je neznana, hipoteza govori o vrsti porazdelitve. Parametrični testi so *enostranski* in *dvostranski*.

## Statistične hipoteze

$H_0$  *ničelna hipoteza* o porazdelitvi slučajne spremenljivke.

... Slučajna spremenljivka je porazdeljena normalno.

... Slučajna spremenljivka ima matematično upanje enako 2.

$H_{alt}$  *alternativna hipoteza* o porazdelitvi slučajne spremenljivke.

... Slučajna spremenljivka **ni** porazdeljena normalno.

... Slučajna spremenljivka ima matematično upanje **različno od** 2.

S statističnim testom testiramo ničelno hipotezo  $H_0$  *proti* alternativni hipotezi  $H_{alt}$ .

## Napake, ki jih lahko naredimo

*Napaka 1. vrste* ničelna hipoteza je pravilna, s testom jo zavrnemo.

Verjetnost, da naredimo napako 1. vrste je merljiva in jo lahko poljubno zmanjšamo.

*Napaka 2. vrste* ničelna hipoteza je napačna, s testom jo sprejmemo.

Verjetnosti, da naredimo napako 2. vrste **ni mogoče** oceniti. Zato napak 2. vrste **ne delamo**.

To pomeni, da ničelnih hipotez nikoli ne sprejmemo.

*Stopnja značilnosti* testa je verjetnost, da zavrnemo pravilno hipotezo (naredimo napako 1. vrste).

Stopnja značilnosti  $\alpha$  je tipično 0,1, 0,05 ali 0,01.

## Parametrični test — dvostranski

*Naloga:* Imamo vzorec  $n = 3000$  otrok, od katerih je 1578 dečkov.

Pri stopnji značilnosti  $\alpha = 0,01$  testiraj ničelno hipotezo

$H_0$  verjetnost rojstva dečka je enaka  $\frac{1}{2}$ .

proti alternativni hipotezi

$H_{alt}$  verjetnost rojstva dečka je različna od  $\frac{1}{2}$ .

## Parametrični test — enostranski

Naloga: Imamo vzorec  $n = 3000$  otrok, od katerih je 1578 dečkov.

Pri stopnji značilnosti  $\alpha = 0,01$  testiraj ničelno hipotezo

$H_0$  verjetnost rojstva dečka je večja ali enaka  $\frac{1}{2}$ .

proti alternativni hipotezi

$H_{alt}$  verjetnost rojstva dečka je manjša od  $\frac{1}{2}$ .

## Neparametrični test $\chi^2$

Naj bo  $X_{ref}$  znana slučajna spremenljivka. Poznamo njen verjetnostno shemo.

$$X_{ref} \sim \begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix}$$

Naj bo  $X$  opazovana slučajna spremenljivka.

Z neparametričnim testom  $\chi^2$  testiramo ničelno hipotezo

$H_0$  slučajna spremenljivka  $X$  je porazdeljena **enako** kot slučajna spremenljivka  $X_{ref}$ .

proti alternativni hipotezi

$H_{alt}$  slučajna spremenljivka  $X$  **ni** porazdeljena enako kot slučajna spremenljivka  $X_{ref}$ .

## Neparametrični test $\chi^2$

Izberemo  $X$ -vzorec velikosti  $n$  in sestavimo tabelico :

Dogodek	$X = x_1$	$X = x_2$	$\dots$	$X = x_k$
Izmerjena frekvenca	$X_1$	$X_2$	$\dots$	$X_k$
Pričakovana frekvenca	$n \cdot p_1$	$n \cdot p_2$	$\dots$	$n \cdot p_k$

Izračunamo statistiko

$$\chi^2 = \frac{(X_1 - np_1)^2}{np_1} + \frac{(X_2 - np_2)^2}{np_2} + \dots + \frac{(X_k - np_k)^2}{np_k} = \sum_{i=1}^k \frac{(X_i - np_i)^2}{np_i}$$

pri čemer je  $X_1 + X_2 + \dots + X_k = n$ .

## Neparametrični test $\chi^2$

### Izrek

*Pri veljavni ničelni hipotezi, dovolj velikem vzorcu ( $n \geq 30$ ) in če je  $n \cdot p_i \geq 5$  za vsak  $i$ , je statistika  $\chi^2$  porazdeljena približno kot hi-kvadrat s  $(k - 1)$  prostostnimi stopnjami  $\chi^2(k - 1)$ .*

Izberemo stopnjo značilnosti  $\alpha$ .

Če je  $\chi^2 > \chi^2_{1-\alpha}(k - 1)$ , potem hipotezo **zavnemo**.

Če je  $\chi^2 \leq \chi^2_{1-\alpha}(k - 1)$ , potem hipoteze **ne zavnemo**.

## Neparametrični test $\chi^2$

*Naloga:* Kocko vržemo 600 krat. Padlo je 105 enic, 99 dvojk, 102 trojki, 104 štirice, 93 petic in 97 šestic. Pri stopnji zaupanja  $\alpha = 0,05$  testiraj ničelno hipotezo "Kocka je poštena."

## Test $\chi^2$ za testiranje neodvisnosti

V prodajalni bureka vzorčimo kupce in spremljamo njihova naročila. Dobili smo naslednjo kontingenčno tabelo.

starost/vrsta	mesni	sirov	pizza
mladi	25	17	18
mlajši	42	25	23
starejši	33	25	22
stari	12	10	8

*Naloga:* Testiraj ničelno hipotezo "Izbira vrste bureka je neodvisna od starosti kupca."

## Test $\chi^2$ za testiranje neodvisnosti

Kot v prejšnjem primeru izračunamo količino

$$\chi^2 = \sum_{\text{po vseh celicah}} \frac{(\text{izmerjena vrednost} - \text{pričakovana vrednost})^2}{\text{pričakovana vrednost}}$$

### Izrek

*Pri veljavni ničelni hipotezi , dovolj velikem vzorcu ( $n \geq 30$ ) in če je vsaka pričakovana vrednost  $\geq 5$ , je statistika  $\chi^2$  porazdeljena približno kot hi-kvadrat s  $(r - 1)(s - 1)$  prostostnimi stopnjami.*

## Test $\chi^2$ za testiranje neodvisnosti

Naj bosta  $X$  in  $Y$  slučajni spremenljivki.

*Test  $\chi^2$  uporabljam za testiranje ničelne hipoteze*

*$H_0$   $X$  in  $Y$  sta neodvisni.*

proti alternativni hipotezi

*$H_{\text{alt}}$   $X$  in  $Y$  sta odvisni.*

## Test z znaki

Naj bosta  $X$  in  $Y$  slučajni spremenljivki.

*Test z znaki* uporabljamo za testiranje ničelne hipoteze

$$H_0 \quad P(X > Y) = 0.5 .$$

proti alternativni hipotezi

$$H_{alt} \quad P(X > Y) \neq 0.5 .$$

Potrebujemo isto število meritev  $X_1, X_2, \dots, X_n$  in  $Y_1, Y_2, \dots, Y_n$ .

## Mann-Whitneyev test

Naj bosta  $X$  in  $Y$  slučajni spremenljivki.

*Mann-Whitneyev test* uporabljamo za testiranje ničelne hipoteze

$H_0$   $X$  in  $Y$  sta **enako porazdeljeni**.

proti alternativni hipotezi

$H_{alt}$   $X$  in  $Y$  nista enako porazdeljeni.