

Dug od prošli puta: izvod  $M_6$

### Regresija s transformiranim varijablama

nelinearnu ovisnost prikazati u linearnom obliku ili računalom

## Korelacije

## Provjeravanje (testiranje) hipoteza

Provjera hipoteze vrlo je bitan dio statističkog zaključivanja.

Da bi se takva provjera formulirala, potrebno je postaviti neku teoriju koja se želi dokazati.

Npr.:

- Novi lijek bolji je za liječenje određenih simptoma od starog.
- Igrača kocka ima pomaknuto težište
- U svijetu se rada više muškaraca nego žena

U svakom takvom problemu postavljamo dvije tvrdnje (hipoteze) od kojih je točno jedna istinita:

$H_0$ = nul-hipoteza

$H_1$ = alternativna hipoteza

One se **ne** tretiraju **ravnopravno**:

U sudskom procesu:  $H_0$ : optuženi je nevin

$H_1$ : optuženi je kriv

Hipoteza  $H_0$  smatra se ispravnom dok se ne dokaže  $H_1$ .

Za  $H_0$  obično se uzima stara, postojeća teorija:

Npr., za lijek:  $H_0$ = stari lijek jednako je dobar kao i novi

za kocku:  $H_0$ = kocka je poštena

**Ako ne odbacimo  $H_0$ , to ne znači da je ona ispravna, nego samo da nemamo dovoljno dokaza da ju odbacimo.**


Primjer: ispitujemo simetričnost Galtonove daske sa 16 redova.

### 1. Postavljanje problema, izricanje hipoteza

$H_0$  : daska je simetrična, tj.  $X \sim \text{Bin}(16, 1/2)$

$H_1$  : daska je nagnuta udesno

Raspodjela dana nul-hipotezom:




### 2. Postavljanje problema, kritično područje

Prije uzimanja uzorka podijelimo skup mogućih ishoda u dva područja:

A = područje prihvatanja  $H_0$

B = područje odbacivanja  $H_0$  = **kritično područje**



Odlučimo se: A={0,1,2,...,11} B={12,13,...,16}

### Vrste pogrešaka

		odluka	
		odbaci $H_0$	prihvati $H_0$
istina	$H_0$	pogreška I. vrste	ispravan zaključak
	$H_1$	ispravan zaključak	pogreška II. vrste

Smatra se da je pogreška I. vrste mnogo ozbiljnija od pogreške II. vrste.

Vjerojatnost pogreške I. vrste:


$\alpha$  = vjerojatnost odbacivanja  $H_0$  kada je istinita =  $P(B/H_0)$

Vjerojatnost pogreške II. vrste:

$\beta$  = vjerojatnost prihvatanja  $H_0$  kada nije istinita =  $P(A/H_1)$

U našem primjeru je  $\alpha = 0,038 \approx 4\%$ .

Međutim, čak i da je daska toliko nagnuta da je  $p = 2/3$ , raspodjela varijable  $X$  bi bila



pa bi vjerojatnost pogreške II. vrste uz naš odabir kritičnog područja bila  $\beta = 0,6488$ .

Veliki  $\beta$  se događa kada je uzorak premalen ( $n = 16$ ).

### Signifikantnost testa (važnost, značajnost)

*Def:*

Za postupak provjere kažemo da ima **razinu signifikantnosti** (važnosti)  $\alpha$  ako je

$$P(\text{pogreška I. vrste}) \leq \alpha.$$

Kažemo da je to **test razine  $\alpha$** .

Naš primjer je test razine 0,04.

Tradicionalno se kao razine signifikantnosti uzimaju vrijednosti 0,01; 0,05 ili 0,10.

Za  $\alpha = 0,05$  kažemo da je test **signifikantan**, a za  $\alpha = 0,01$  kažemo da je test **vrlo signifikantan**.

### Moć testa

Moć statističkog testa mjeri sposobnost testa da odbaci nul-hipotezu kad je uistinu pogrešna, tj. da učini ispravnu odluku.

$$P = 1 - \beta$$

U našem primjeru je  $P = 0,34$ . Idealno je  $P = 1$ . Za snažniji test morali bismo imati veći uzorak.

### Opća pravila odabira testa

*Prije uzimanja uzorka:*

- 1) Izreci nul-hipotezu i alternativnu hipotezu.
- 2) Razmotri odgovarajuću raspodjelu danu nul-hipotezom.
- 3) Odluči o razini signifikantnosti testa.
- 4) Odredi kritično područje (odluči o kriteriju odbacivanja nul-hipoteze)

*Sada uzmi uzorak!*

- 5) Očitaj rezultat testa (izračunaj vrijednost statistike testa)
- 6) Učini odluku:

Ako je vrijednost statistike testa u kritičnom području, odbaci  $H_0$ !

Ako vrijednost statistike testa nije u kritičnom području, nemoj odbaciti  $H_0$ !

## Testiranje dobrote prilagodbe

### **$\chi^2$ raspodjela**

Neka je  $\nu \in \mathbf{N}$ . Kontinuirana slučajna varijabla  $X$  ima  **$\chi^2$  raspodjelu** s parametrom  $\nu$  ako je njezina funkcija gustoće vjerojatnosti dana s

$$f(x; \nu) = \begin{cases} \frac{x^{\nu/2-1} e^{-x/2}}{2^{\nu/2} \Gamma(\nu/2)} & , x \geq 0 \\ 0 & , x < 0 \end{cases}$$

Parametar  $\nu$  zove se "**broj stupnjeva slobode**" varijable  $X$ .



### Stupnjevi slobode

Parametar  $\nu$  definiran je kao:

$\nu$  = broj nezavisnih varijabli uključenih u izračun

Nalazimo ga na sljedeći način:

$\nu$  = broj razreda – broj ograničenja

### Normalna raspodjela, $\mu$ i $\sigma$ poznati

Primjer:

Dugogodišnje statistike pokazuju da je visina studenata na nekom sveučilištu normalno raspodijeljena s očekivanjem  $\mu = 173$  cm i standardnom devijacijom  $\sigma = 7$  cm.

Iz jedne generacije studenata na tom sveučilištu izdvojeno je 100 studenata, mjerene su njihove visine i svrstane u razrede.


Opažene su frekvencije:

$x$	154-160	160-166	166-172	172-178	178-184	184-190	Total
$f(x)$	5	17	38	25	9	6	100

Provjeri s 5% signifikantnosti je li raspodjela normalna s očekivanjem  $\mu = 173$  cm i standardnom devijacijom  $\sigma = 7$  cm !

Rješenje:

$H_0$ : Raspodjela je Gaussova s očekivanjem  $\mu = 173$  cm i standardnom devijacijom  $\sigma = 7$  cm.



Imamo jedno ograničenje:  $\sum f_i = \sum f_{ii} = N = 100$

Uvodimo standardnu normalnu slučajnu varijablu  $z_i = \frac{x - \mu}{\sigma}$ .


Za te vrijednosti  $z_i$  određujemo iz tablica funkciju raspodjele  $F(z)$  i vjerojatnosti razreda  $f(z)$ :

razred $i$	$f_i$	$z_i$	$F(z)$	$f(z)$	$f_{ii}$	$(f_i - f_{ii})^2 / f_{ii}$
154-160	5	$z < -1,86$	0,0314	0,0314	3	
160-166	17	$-1,86 < z < -1$	0,1587	0,1273	13	2,25
166-172	38	$-1 < z < -0,14$	0,4443	0,2856	28	3,57
172-178	25	$-0,14 < z < 0,71$	0,7611	0,3168	32	1,53
178-184	9	$0,71 < z < 1,57$	0,9418	0,1807	18	4,5
184-190	6	$z > 1,57$	1	0,0582	6	0
zbroj	100			1	100	11,85

Dakle, imamo pet razreda i jedno ograničenje pa je  $\nu = 5 - 1 = 4$

Za 4 stupnja slobode i 5% signifikantnosti, kritična vrijednost (iz tablica) je

$$\chi_{0,05,4}^2 = 9,49$$



Izračunata vrijednost  $\chi_{op}^2 = 11,85$  pada u kritično područje.

Stoga hipotezu  $H_0$  odbacujemo.

### Normalna raspodjela, $\mu$ i $\sigma$ nepoznati

Isti primjer:

Odbacili smo hipotezu o očekivanju i standardnoj devijaciji, ali i dalje vjerujemo da je raspodjela normalna.


Provjeri s 5% signifikantnosti je li raspodjela normalna!

Rješenje:

$H_0$ : Raspodjela je Gaussova s očekivanjem  $\mu = \bar{x}_{uzorka}$  i standardnom devijacijom  $\sigma = \sigma_{uzorka}$ .

Izračunamo:

$$\bar{x}_{uzorka} = \frac{1}{N} \sum f_i x_i = 171 \text{ cm} \quad \sigma_{uzorka} = \sqrt{\frac{1}{N} \sum f_i (x_i - \bar{x}_{uzorka})^2} = 7,1 \text{ cm}$$



razred $i$	$f_i$	$z_i$	$F(z)$	$f(z)$	$f_{ii}$	$(f_i - f_{ii})^2 / f_{ii}$
154-160	5	$z < -1,55$	0,0606	0,060	6	0,167
160-166	17	$-1,55 < z < -0,70$	0,2420	0,181	18	0,056
166-172	38	$-0,70 < z < 0,14$	0,5557	0,314	32	1,125
172-178	25	$0,14 < z < 0,99$	0,8389	0,283	28	0,321
178-184	9	$0,99 < z < 1,83$	0,9664	0,128	13	0,063
184-190	6	$z > 1,83$	1	0,033	3	
zbroj	100			1	100	1,732

Dakle, imamo pet razreda i tri ograničenja:  $N = 100$


$$\mu = \bar{x}_{uzorka}$$

$$\sigma = \sigma_{uzorka}$$


$$\text{pa je } \nu = 5 - 3 = 2$$

Za 2 stupnja slobode i 5% signifikantnosti, kritična vrijednost je


$$\chi_{0,05,2}^2 = 5,99$$



Izračunata vrijednost  $\chi_{op}^2 = 1,73$  ne pada u kritično područje. Stoga hipotezu  $H_0$  zadržavamo.



**ODBACUJEMO!**



**PRIHVAĆAMO!**