

*Statisztika elméleti összefoglaló*

## 1. Tartalomjegyzék

1. Tartalomjegyzék.....	2
2. Becslésmélet.....	3
3. Intervallumbecslések.....	5
4. Hipotézisvizsgálat .....	8
5. Regresszió-számítás .....	11

MATEKPORTÁL

## 2. Becsléelmélet

### *Alapfogalmak, jelölések*

A sokaság elemszáma:  $N$

A sokaság paramétereinek általános jele:  $\Theta$

A sokaság legfontosabb paramétere:

- várható érték:  $\mu$
- szórás:  $\sigma$
- arány:  $P$

A minta elemszáma:  $n$

A mintából számított paraméterek általános jele:  $\hat{\Theta}$ .

A mintából számított legfontosabb paraméterek:

- várható érték:  $\bar{y}$
- szórás:  $s$
- arány:  $p$

### *A becslések tulajdonságai*

Torzítatlanság: a mintából számított becslések várható értéke megegyezik a sokasági paraméterrel, azaz

$$E(\hat{\theta}) = \theta$$

A torzítás mértéke:  $Bs(\hat{\theta}) = \theta - E(\hat{\theta})$

A becslés varianciája:  $Var(\hat{\theta})$

### *Becslések összehasonlítása*

Két torzítatlan becslőfüggvény esetén a hatásosabbat kell választani.

Két torzítatlan becslőfüggvény közül azt tekintjük hatásosabbnak, amelyiknek kisebb a varianciája.

Egy torzított és egy torzítatlan becslőfüggvény közül az átlagos négyzetes hiba (MSE) alapján kell választani. Az a jobb becslés, amelynek kisebb az átlagos négyzetes hibája.

$$MSE(\hat{\theta}) = Bs^2(\hat{\theta}) + Var(\hat{\theta})$$

MATEKPORTÁL

### 3. Intervallumbecslések

#### *Mintavételi módok*

- FAE: független azonos eloszlású (visszatevéses)
- EV: egyszerű véletlen (visszatevés nélküli)
- R: rétegzett
- TL: többlépcsős
- CS: csoportos

#### *Általános képlet*

$$Int_{1-\alpha}(\theta) = \hat{\theta} \pm \varphi_{1-\frac{\alpha}{2}} s_{\hat{\theta}}$$

A fenti képlet a konfidencia-intervallumok általános képlete.

A jelölések tartalma:

$1 - \alpha$ : megbízhatósági szint

$\Theta$ : a sokaság paramétere

$\hat{\theta}$ : a paraméter mintából becsült értéke (pontbecslés)

$\varphi$ : valószínűségi változó

$s_{\hat{\theta}}$ : a paraméterbecslés standard hibája

$\varphi_{1-\frac{\alpha}{2}} s_{\hat{\theta}} = \Delta_{\hat{\theta}}$ : a konfidencia intervallum sugara, a becslés abszolút hibahatára

### Konfidencia intervallumok konkrét esetekben

Sokasági átlag (várható érték,  $\mu$ )

	kis minta ( $n \leq 30$ ) ismert sokasági szórás ( $\sigma$ )	kis minta ( $n \leq 30$ ) ismeretlen sokasági szórás ( $\sigma$ )	nagy minta ( $n > 30$ )
FAE minta	$\bar{y} \pm z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}$	$\bar{y} \pm t_{1-\frac{\alpha}{2}}(v) \frac{s}{\sqrt{n}}$ szabadságfok: $v=n-1$	$\bar{y} \pm z_{1-\frac{\alpha}{2}} \frac{s}{\sqrt{n}}$
EV minta	$\bar{y} \pm z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \sqrt{1-\frac{n}{N}}$	$\bar{y} \pm t_{1-\frac{\alpha}{2}}(v) \frac{s}{\sqrt{n}} \sqrt{1-\frac{n}{N}}$ szabadságfok: $v=n-1$	$\bar{y} \pm z_{1-\frac{\alpha}{2}} \frac{s}{\sqrt{n}} \sqrt{1-\frac{n}{N}}$
R minta	-	-	$\bar{y}_R \pm z_{1-\frac{\alpha}{2}} \sqrt{\sum W^2 \frac{s_j^2}{n} \left(1-\frac{n}{N}\right)}$
AR minta	-	-	$\bar{y} \pm z_{1-\frac{\alpha}{2}} \frac{\sigma_B}{\sqrt{n}}$

s: a mintából becsült szórás

$$s = \sqrt{\frac{\sum (y_i - \bar{y})^2}{n-1}}$$

Sokasági szórás ( $\sigma$ )

$$Int_{1-\alpha}(\sigma) = \left[ \sqrt{\frac{(n-1)s^2}{\chi_{\frac{\alpha}{2}}^2(n-1)}}; \sqrt{\frac{(n-1)s^2}{\chi_{1-\frac{\alpha}{2}}^2(n-1)}} \right]$$

Sokasági arány (P)

	nagy minta ( $n > 30$ )
FAE minta	$p \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}$
EV minta	$p \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \sqrt{1-\frac{n}{N}}$

**Értékösszegbecslés**

$$Int_{1-\alpha}(Y') = N \cdot Int_{1-\alpha}(\mu)$$

**Mintaelemszámok**

	Átlagbecslés
FAE minta	$\frac{\left(z_{1-\frac{\alpha}{2}} \cdot \sigma\right)^2}{\Delta^2}$
EV minta	$\frac{\left(z_{1-\frac{\alpha}{2}} \cdot \sigma\right)^2}{\frac{\left(z_{1-\frac{\alpha}{2}} \cdot \sigma\right)^2}{N} + \Delta^2}$

Neyman-féle optimális mintaelosztás:

$$n_j = n \frac{N_j \sigma_j}{\sum N_j \sigma_j}$$

**Független részminták módszere (FRM)**

$$Int_{1-\alpha}(\theta) = \hat{\theta}_{FRM} \pm t_{1-\frac{\alpha}{2}}(n-1) \cdot s_{\hat{\theta}_{FRM}}$$

$$\hat{\theta}_{FRM} = \frac{\sum \hat{\theta}_i}{k}$$

$$s_{\hat{\theta}_{FRM}} = \sqrt{\frac{\sum (\hat{\theta}_i - \hat{\theta}_{FRM})^2}{k(k-1)}}$$

## 4. Hipotézisvizsgálat

### *Egymintás paraméteres próbák*

Kétoldali próbák: egyenlőséget vizsgálnak egy sokasági paraméterre vonatkozóan

Egyoldali próbák: egyenlőtlenséget vizsgálnak egy sokasági paraméterre vonatkozóan

a) várható értékre vonatkozó próbák

- kis minta és ismert sokasági szórás, illetve nagy minta esetén

$$Z = \frac{\bar{y} - \mu_0}{\frac{\sigma}{\sqrt{n}}}$$

- kis minta és ismeretlen sokasági szórás esetén

$$T = \frac{\bar{y} - \mu_0}{\frac{s}{\sqrt{n}}}$$

b) szórásra vonatkozó próba

$$\chi^2 = \frac{(n-1)s^2}{\sigma_0^2}$$

c) arányra vonatkozó próba

$$Z = \frac{p - P_0}{\sqrt{\frac{P_0(1-P_0)}{n}}}$$

### *Egymintás nemparaméteres próbák*

Minden esetben egyoldali, felső kritikus értékkel végrehajtandó próbák.

a) Illeszkedésvizsgálat

$$\chi^2 = \sum \frac{(f_i - nP_i)^2}{nP_i} = n \left( \sum \frac{g_i^2}{P_i} - 1 \right)$$



szabadságfok:  $k-b-1$  ( $k$ : kategóriák száma;  $b$ : a becsült paraméterek száma)

b) Függetlenségvizsgálat

$$\chi^2 = \sum \frac{(n_{ij} - n_{ij}^*)^2}{n_{ij}^*}$$

szabadságfok:  $(r-1)(c-1)$  ( $r$ : a táblázat sorainak;  $c$ : a táblázat oszlopainak száma)

p-érték (empirikus szignifikancia-szint)

Az a valószínűség, amely mellett a  $H_0$  már éppen elvethető.

A próbafüggvény empirikus értékéhez, mint kritikus értékhez tartozó szignifikancia-szint.

### ***Két-, és többmintás próbák***

Két várható értékre vonatkozó próbák:

- nagy minta, vagy ismert szórások esetén:

$$Z = \frac{\bar{y} - \bar{x} - \delta_0}{\sqrt{\frac{\sigma_y^2}{n_y} + \frac{\sigma_x^2}{n_x}}}$$

- kis minta és ismeretlen szórások esetén:

$$T = \frac{\bar{y} - \bar{x} - \delta_0}{s_c \sqrt{\frac{1}{n_y} + \frac{1}{n_x}}}$$

$$s_c = \sqrt{\frac{s_y^2(n_y - 1) + s_x^2(n_x - 1)}{n_y + n_x - 2}}$$

szabadságfok:  $n_y + n_x - 2$

Két arányra vonatkozó próbák:

- van feltételezett különbség ( $\varepsilon_0$ ) a két arány közt

$$Z = \frac{p_y - p_x - \varepsilon_0}{\sqrt{\frac{p_y q_y}{n_y} + \frac{p_x q_x}{n_x}}}$$

- nincs feltételezett különbség a két arány között

$$Z = \frac{p_y - p_x}{\sqrt{\bar{p}\bar{q}\left(\frac{1}{n_y} + \frac{1}{n_x}\right)}}$$

Két szórásra vonatkozó próba

$$F = \frac{s_y^2}{s_x^2}$$

Szabadságfokok:  $n_y - 1$ ;  $n_x - 1$

Több várható érték azonosságára vonatkozó próba (varianciaanalízis)

$$F = \frac{s_k^2}{s_b^2}$$

$$s_k^2 = \frac{SSK}{M - 1} \quad s_b^2 = \frac{SSB}{n - M}$$

$$SSK = \sum n_j (\bar{y}_j - \bar{y})^2 \quad SSB = \sum n_j s_j^2$$

Szabadságfokok:  $M - 1$ ;  $n - M$

## 5. Regresszió-számítás

### Kétváltozós regresszió

x: ok

y: okozat

Az általános egyenlet:

$$y = \underbrace{\hat{\beta}_0 + \hat{\beta}_1 x}_{\hat{y}} + e$$

A paraméterek becslése

$$\hat{\beta}_1 = \frac{\sum d_x d_y}{\sum d_x^2} = \frac{\sum xy - n\bar{x}\bar{y}}{\sum x^2 - n\bar{x}^2} \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

$$d_x = x_i - \bar{x}$$

Illeszkedés:

$$s_e = \sqrt{\frac{\sum e^2}{n-2}} \quad \sum e^2 = SSE = \sum (y_i - \hat{y})^2$$

Kapcsolatszoroság

$$r = \frac{\sum d_x d_y}{\sqrt{\sum d_x^2 \sum d_y^2}} = \frac{\sum xy - n\bar{x}\bar{y}}{\sqrt{(\sum x^2 - n\bar{x}^2)(\sum y^2 - n\bar{y}^2)}} \quad r^2 = \frac{SSR}{SST}$$

$$SSR = \hat{\beta}_1^2 \sum d_x^2 = \sum (\hat{y} - \bar{y})^2 \quad SST = \sum d_y^2 = \sum (y_i - \bar{y})^2$$

Rugalmasság

$$El(\hat{y}, x) = \frac{\hat{\beta}_1 x}{\hat{y}}$$

## Intervallumbecslések

- paraméterekre

$$Int_{1-\alpha}(\beta_1) = \hat{\beta}_1 \pm t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{\beta}_1}$$

$$s_{\hat{\beta}_1} = \frac{s_e}{\sqrt{\sum d_x^2}}$$

$$Int_{1-\alpha}(\beta_0) = \hat{\beta}_0 \pm t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{\beta}_0}$$

$$s_{\hat{\beta}_0} = s_e \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{\sum d_x^2}}$$

- várható értékre

$$Int_{1-\alpha}(E(Y_*)) = \hat{y}_* \pm t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{y}_*}$$

$$s_{\hat{y}_*} = s_e \sqrt{\frac{1}{n} + \frac{(x_* - \bar{x})^2}{\sum d_x^2}}$$

## Hipotézisek

- paraméter szignifikanciája

$$H_0: \beta_1 = 0$$

$$H_1: \beta_1 \neq 0$$

$$T = \frac{\hat{\beta}_1}{s_{\hat{\beta}_1}}$$

szabadságfok: n-2

$$F = \frac{SSR}{\frac{SSE}{n-2}}$$

Szabadságfokok: 1, n-2

Idősoros regresszió

Durbin-Watson próba (reziduális autokorreláció)

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

Durbin-Watson segédregresszió:

$$\varepsilon_t = \rho\varepsilon_{t-1} + \eta_t$$

Próbafüggvény:

$$d = \frac{\sum(e_t - e_{t-1})^2}{\sum e_t^2}$$

Nemlineáris regresszió

- exponenciális regresszió

$$\hat{y} = \hat{\beta}_0 \hat{\beta}_1^x$$

- hatványkitevős regresszió

$$\hat{y} = \hat{\beta}_0 x^{\hat{\beta}_1}$$

Kapcsolatszoroság

$$I = \sqrt{1 - \frac{SSE}{SST}}$$

**Többsváltozós regresszió**

Általánosságban

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k$$

Paraméterek becslése

$$\vec{\beta} = (X^T X)^{-1} X^T y$$

Illeszkedés:

$$s_e = \sqrt{\frac{\sum e^2}{n-k-1}} \quad \sum e^2 = SSE = \sum (y_i - \hat{y})^2 = e^T e$$

Kapcsolatszoroság

$$R^2 = \frac{SSR}{SST} = 1 - \frac{1}{q_{yy}} = \frac{r_{y1}^2 + r_{y2}^2 - 2r_{y1}r_{y2}r_{12}}{1 - r_{12}^2}$$

Parciális korreláció

$$r_{yj.12\dots k} = \frac{-q_{yj}}{\sqrt{q_{yy}q_{jj}}}$$


Háromváltozós esetben

$$r_{y1.2} = \frac{r_{y1} - r_{y2}r_{12}}{\sqrt{(1 - r_{y2}^2)(1 - r_{12}^2)}}$$

Rugalmasság

$$El(\hat{y}; x_j) = \frac{\hat{\beta}_j x_j}{\hat{y}}$$

## Útelemzés



Közvetlen hatás:  $\beta_1$  és  $\beta_2$

regresszió:  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2$

Közvetett hatások:  $\beta_{12}\beta_2$  és  $\beta_{21}\beta_1$

regressziók:  $\hat{x}_2 = \hat{\beta}_0 + \hat{\beta}_{12}x_1$  és  $\hat{x}_1 = \hat{\beta}_0 + \hat{\beta}_{21}x_2$

Teljes hatások:  $\beta_1 + \beta_{12}\beta_2$  és  $\beta_2 + \beta_{21}\beta_1$

regressziók:  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1$  és  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_2 x_2$

## Multikollinearitás

$$VIF_j = \frac{1}{1 - R_j^2}$$

$1 < VIF_j < 2$ , *gyenge*

$2 < VIF_j < 5$ , *erős*

$5 < VIF_j$ , *káros*

## Hipotézisek

- parciális T-próba

$$H_0: \beta_j = 0$$

$$H_1: \beta_j \neq 0$$

$$T = \frac{\hat{\beta}_j}{s_{\hat{\beta}_j}}$$

szabadságfok:  $n-k-1$

- globális F-próba (varianciaanalízis)

$$F = \frac{\frac{SSR}{k}}{\frac{SSE}{n-k-1}} = \frac{n-k-1}{k} \frac{R^2}{1-R^2}$$

szabadságfokok: k, n-k-1

ANOVA-tábla

A variancia eredete	Négyzetösszeg	Szabadságfok	Átlagos négyzetösszeg	F-érték
Regresszió	SSR	k	$\frac{SSR}{k}$	$\frac{\frac{SSR}{k}}{\frac{SSE}{n-k-1}}$
Maradék	SSE	n-k-1	$\frac{SSE}{n-k-1}$	
Teljes	SST	n-1		

### Intervallum-becslések

- paraméterekre

$$Int_{1-\alpha}(\beta_j) = \hat{\beta}_j \pm t_{1-\frac{\alpha}{2}}(n-k-1) s_{\hat{\beta}_j}$$

$$s_{\hat{\beta}_j} = s_e \sqrt{(X^T X)^{-1}_{jj}}$$

- várható értékre

$$Int_{1-\alpha}(E(Y_*)) = \hat{y}_* \pm t_{1-\frac{\alpha}{2}}(n-k-1) s_{\hat{y}_*}$$

$$s_{\hat{y}_*} = s_e$$