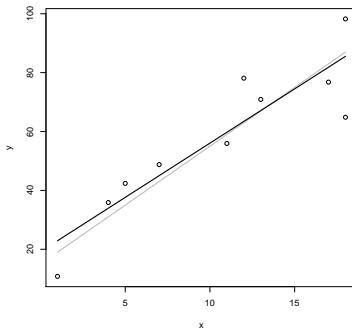


# 1 Linearna regresija

Zanima nas povezanost števila ur učenja na teden z rezultatom na izpitu iz statistike. Vzemimo, da vemo, da se rezultat na izpitu v populaciji porazdeljuje pogojno normalno:  $Y|X \sim N(\beta_0 + \beta_1 X, \sigma^2)$ .

- Naj bo  $X$  enakomerno porazdeljena spremenljivka (med 0 in 20, zaokrožena navzdol),  $\beta_0 = 15$ ,  $\beta_1 = 4$ ,  $\sigma = 10$ . Generirajte vzorec velikosti 10, narišite podatke in vrišite populacijsko ter ocenjeno vrednost premice.

```
> set.seed(1)
> n <- 10
> beta0 <- 15
> beta1 <- 4
> sigma <- 10
> x <- floor(runif(n)*20)           #velikost vzorca
> x <- sort(x)                     #navzdol zaokrožene vrednosti x
> y <- rnorm(n,mean=beta0+beta1*x, sd=sigma) #uredimo podatke po velikosti x
                                                #generiramo iz normalne porazdelitve
> plot(x,y)                         #narisemo tocke
> popul <- beta0 + beta1*x          #populacijska vrednost premice
> lines(x,popul,col="grey",lwd=2)    #dodamo populacijsko vrednost premice v sivi barvi
> fit <- lm(y~x)                   #ocenimo premico na podatkih
> summary(fit)                      #ogledamo si ocene koeficientov
> beta0h <- fit$coef[1]             #ocenjena beta0
> beta1h <- fit$coef[2]             #ocenjena beta1
> napoved <- beta0h + beta1h*x
> lines(x,napoved,lwd=2)            #vrisemo ocenjeno premico na sliko
```



Slika 1: Točke na vzorcu, ocenjena premica (črna) in populacijska premica (siva).

- Iz spodnjega izpisa preberite ocene populacijskih parametrov. Interpretirajte rezultate, katere ničelne domneve so testirane in kako?

```

Call:
lm(formula = y ~ x)

Residuals:
    Min      1Q  Median      3Q     Max 
-20.683 -4.746  2.844  4.512 14.693 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 19.2049    7.5172   2.555 0.033921 *  
x            3.6850    0.6217   5.927 0.000351 *** 
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1 

Residual standard error: 11.44 on 8 degrees of freedom
Multiple R-squared:  0.8145,    Adjusted R-squared:  0.7913 
F-statistic: 35.13 on 1 and 8 DF,  p-value: 0.0003508

```

Ocene parametrov so  $\hat{\beta}_0 = 19,2$ ,  $\hat{\beta}_1 = 3,7$ ,  $\hat{\sigma} = 11,4$ . Testirani sta dve ničelni domnevi:  $H_{0int}$ :  $\beta_0 = 0$  in  $H_0$ :  $\beta_1 = 0$ . Pri linearni regresiji nas ponavadi zanima le druga - saj ta govori o povezanosti med spremenljivkama v populaciji. Metoda največjega verjetja nam pove, da se ocene parametrov okrog prave vrednosti porazdeljujejo približno normalno (za dovolj velik  $n$ ). Standardna napaka je ocenjena iz podatkov, uporabimo test  $t$ :

$$T = \frac{\hat{\beta}_1}{\widehat{SE}_{\beta_1}} = \frac{3,7}{0,6} = 5,9$$

Vemo, da je slučajna spremenljivka  $T$  porazdeljena približno kot  $t$  z 8 stopinjam prostosti (pri ocenjevanju  $SE$  porabimo dve stopinji prostosti). Ta test se imenuje Waldov test.

- Kako bi ničelno domnevo  $H_0 : \beta_1 = 0$  preverili s testom razmerja verjetij?  
Uporabite rezultat, da ocena  $\hat{\sigma}$  po metodi največjega verjetja ni nepristranska in je enaka

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{\beta}_0 - x_i \hat{\beta}_1)^2}{n}$$

Izračunati moramo vrednost maksimuma funkcije verjetja pod ničelno in alternativno domnevo. Funkcija verjetja je enaka:

$$l(y, x, \beta_0, \beta_1, \sigma) = \frac{1}{(\sqrt{2\pi}\sigma)^n} \exp\left\{-\frac{\sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2}{2\sigma^2}\right\}$$

Maksimum funkcije verjetja je enak

$$\begin{aligned} l(y, x, \hat{\beta}_0, \hat{\beta}_1, \hat{\sigma}) &= \frac{1}{(\sqrt{2\pi}\hat{\sigma})^n} \exp\left\{-\frac{\sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2}{2\hat{\sigma}^2}\right\} \\ &= \frac{1}{(\sqrt{2\pi}\hat{\sigma})^n} \exp\left\{-\frac{n \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2}{2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2}\right\} \\ &= \frac{1}{(\sqrt{2\pi}\hat{\sigma})^n} \exp\left\{-\frac{n}{2}\right\} \end{aligned}$$

Logaritem funkcije verjetja v ocenjenih vrednostih je zato enak

$$\begin{aligned} \log l(y, x, \hat{\beta}_0, \hat{\beta}_1, \hat{\sigma}) &= \\ &= -\frac{n}{2} \left( \log(2\pi) - \log[\sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2] + \log n - 1 \right) \end{aligned}$$

Vrednost maksimuma pod alternativno domnevo izračunamo tako, da vstavimo ocenjene  $\hat{\beta}_0$  in  $\hat{\beta}_1$ , za izračun vrednosti pod ničelno domnevo moramo oceniti še  $\beta_0$  v ničelnem modelu. Dobljeni Wilksov  $\Lambda$  se porazdeljuje kot  $\chi_1^2$ .

```
> fit0 <- lm(y~1)                                #ocenimo premico pod nicelno domnevo - le konstanta
> res0 <- y - fit0$coef                         #ostanki pod nicelno domnevo
> resA <- y - beta0h - beta1h*x                 #ostanki pod alternativno domnevo
> logl0 <- .5*n*(-log(2*pi) - log(sum(res0^2))+log(n) - 1 )   #loglik pod nicelno
> loglA <- .5*n*(-log(2*pi) - log(sum(resA^2))+log(n) - 1 )   #loglik pod alternativno
> Lambda <- 2*(loglA-logl0)                      #Wilksov lambda
> 1-pchisq(Lambda,1)                             #likelihood ratio test
[1] 4.048e-05
```

## 2 Matrično računanje

Vrednosti neodvisnih spremenljivk združimo v matriko  $X$  (design matrix), vrednosti odvisne spremenljivke ter koeficientov predstavljajo vektorja  $Y$  in  $\beta$ :

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{p1} \\ 1 & x_{12} & \dots & x_{p2} \\ \vdots & \vdots & \dots & \vdots \\ 1 & x_{1n} & \dots & x_{pn} \end{bmatrix}; Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}; \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}$$

Matrika  $X$  je dimenzijs  $n \times (p + 1)$ , kjer je  $p$  število spremenljivk. Če naš model ne bi vseboval konstante, bi prvi stolpec  $X$  izpustili. V našem primeru imamo le eno neodvisno spremenljivko, matrika  $X$  je enaka:

```
> X <- cbind(1,x)                      #zlepimo dva stolpca
> X
      x
[1,] 1 1
[2,] 1 3
[3,] 1 5
[4,] 1 7
[5,] 1 7
[6,] 1 8
[7,] 1 11
[8,] 1 16
[9,] 1 19
[10,] 1 19
> round(y)                            #zaokrožimo za vecjo preglednost
[1] 11 36 42 49 56 78 71 77 65 98
```

- Zapišite vsoto vrednosti  $\sum_{i=1}^n Y_i^2$  v matrični obliki.

$$Y^T Y = \begin{bmatrix} Y_1 & Y_2 & \dots & Y_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = Y_1^2 + Y_2^2 + \dots + Y_n^2$$

- Kaj dobimo, če matrično pomnožimo  $X\beta$ ?

$$X\beta = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 x_1 \\ \beta_0 + \beta_1 x_2 \\ \vdots \\ \beta_0 + \beta_1 x_n \end{bmatrix} = \begin{bmatrix} E(Y_1) \\ E(Y_2) \\ \vdots \\ E(Y_n) \end{bmatrix} = E(Y)$$

- V matrični obliki oceno koeficientov po metodi najmanjših kvadratov (= po metodi največjega verjetja) zapišemo kot  $\hat{\beta} = (X^T X)^{-1} X^T Y$ . Pokažite, da za  $p = 1$  dobite oceni:

$$\hat{\beta}_1 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

Izračunajmo najprej  $X^T X$ :

$$X^T X = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} = \begin{bmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{bmatrix}$$

Inverz te  $2 \times 2$  matrike je enak:

$$(X^T X)^{-1} = \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{bmatrix} \sum_{i=1}^n x_i^2 & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & n \end{bmatrix}$$

Izračunajmo še  $X^T Y$ :

$$X^T Y = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_i Y_i \end{bmatrix}$$

Velja torej

$$\begin{aligned}(X^T X)^{-1} X^T Y &= \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{bmatrix} \sum_{i=1}^n x_i^2 & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & n \end{bmatrix} \begin{bmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_i Y_i \end{bmatrix} \\ &= \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{bmatrix} \sum_{i=1}^n x_i^2 \sum_{i=1}^n Y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i Y_i \\ -\sum_{i=1}^n x_i \sum_{i=1}^n Y_i + n \sum_{i=1}^n x_i Y_i \end{bmatrix}\end{aligned}$$