

# UVOD U LINEARNE MODELE

## JEDNOSTAVNA LINEARNA REGRESIJA

maj 2012. godine



## SADRŽAJ

O LOGICI I ELEMENTIMA LINEARNIH MODELA

IZRAČUNAVANJE PARAMETARA

PODEŠAVANJE (*FITTING*) LINEARNIH MODELA U R-U

DODATAK

# OSNOVE LINEARNE REGRESIJE

- Osnovna formula jednostavne linearne regresije jeste:

$$Y_i = \beta_0 + \beta_1 X_i + \epsilon_i,$$

gde je  $\epsilon_i \sim^{iid} N(0, \sigma^2)$

- Dakle, mi tu imamo posla sa sistemom linearnih jednačina, koje bi se, pojedinačno, mogle zapisati kao:

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 X_1 + \epsilon_1 \\ Y_2 &= \beta_0 + \beta_1 X_2 + \epsilon_2 \\ &\vdots \\ Y_n &= \beta_0 + \beta_1 X_n + \epsilon_n \end{aligned}$$



## MATRIČNI ZAPIS

- Prethodno je daleko elegantnije računati s osloncem na **matričnu algebru**:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 X_1 \\ \beta_0 + \beta_1 X_2 \\ \vdots \\ \beta_0 + \beta_1 X_n \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

odnosno:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \\ 1 & X_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$



# ELEMENTI JEDNOSTAVNE REGRESIJE

- U regresionoj analizi postoji nekoliko ključnih elemenata – matrica i vektora – sa posebnim ulogama:
  - **matrica nacrti ili dizajna** (*design matrix*) – nezavisni podaci

$$\mathbf{X} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \\ 1 & X_n \end{bmatrix}$$



# ELEMENTI JEDNOSTAVNE REGRESIJE

- U regresionoj analizi postoji nekoliko ključnih elemenata – matrica i vektora – sa posebnim ulogama:
  - **vektor parametara** (*vector of parameters*)

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$$



# ELEMENTI JEDNOSTAVNE REGRESIONE ANALIZE

- U regresionoj analizi postoji nekoliko ključnih elemenata – matrica i vektora – sa posebnim ulogama:
  - **vektor greške** (*vector of error terms*)

$$\epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$



# ELEMENTI JEDNOSTAVNE REGRESIONE ANALIZE

- U regresionoj analizi postoji nekoliko ključnih elemenata – matrica i vektora – sa posebnim ulogama:
  - **vektor odgovora** (*vector of responses*) – zavisni podaci

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}$$



# NAJMANJA SUMA KVADRATA

- U rešavanju linearne regresije mi tražimo minimum sume kvadriranih reziduala
- Praktično, tražimo minimum za proizvod matrica

$$\sum \epsilon_i^2 = [\epsilon_1 \quad \epsilon_2 \quad \dots \quad \epsilon_n] \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix} = \epsilon' \times \epsilon$$



# NAJMANJA SUMA KVADRATA

- Zamenom u osnovnom izrazu dobijamo da je:

$$\epsilon = \mathbf{Y} - \mathbf{X}\beta$$

pa je:

$$\epsilon' \epsilon = (\mathbf{Y} - \mathbf{X}\beta)' (\mathbf{Y} - \mathbf{X}\beta)$$



# NAJMANJA SUMA KVADRATA

- Uzimamo derivat s obzirom na  $\beta$ , pa sledi:

$$\frac{d}{d\beta}((\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta)) = -2\mathbf{X}'(\mathbf{Y} - \mathbf{X}\beta)$$

- Tražimo rešenje u 0, za  $\beta$ :

$$-2\mathbf{X}'(\mathbf{Y} - \mathbf{X}\beta) = 0$$

dakle:

$$\mathbf{X}'\mathbf{Y} = \mathbf{X}'\mathbf{X}\beta$$



# NAJMANJA SUMA KVADRATA

- Rešavanje za  $\beta$  daje nam najmanje kvadratno odstupanje:

$$\mathbf{b} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$$

$$\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$



O LOGICI I ELEMENTIMA LINEARNIH MODELA

IZRAČUNAVANJE PARAMETARA

PODEŠAVANJE (*FITTING*) LINEARNIH MODELA U R-U

DODATAK



## PODSETNIK: TRANSPONOVANJE MATRICE

$$\mathbf{X} = \begin{bmatrix} 1 & 4 \\ 2 & 5 \\ 3 & 6 \end{bmatrix}$$

$$\mathbf{X}' = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix}$$



# PODSETNIK: PROIZVOD DVE MATRICE

$$\begin{aligned}\mathbf{AB} &= \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix} \begin{bmatrix} 3 & 0 \\ 1 & 2 \\ 0 & 1 \end{bmatrix} \\ &= \begin{bmatrix} 1 * 3 + 2 * 1 + 3 * 0 & 1 * 0 + 2 * 2 + 3 * 1 \\ 4 * 3 + 5 * 1 + 6 * 0 & 4 * 0 + 5 * 2 + 6 * 1 \end{bmatrix} \\ &= \begin{bmatrix} 5 & 7 \\ 17 & 16 \end{bmatrix}\end{aligned}$$



# PODSETNIK: INVERZ MATRICE

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$$
$$\mathbf{A}^{-1} = \frac{1}{a_{11}a_{22} - a_{12}a_{21}} \begin{bmatrix} a_{22} & -a_{12} \\ -a_{21} & a_{11} \end{bmatrix}$$



- Uzmimo jedan sasvim jednostavan slučaj:

$$\mathbf{X} = \begin{bmatrix} 1 & 4.5 \\ 1 & 7.1 \\ 1 & 9.6 \end{bmatrix}$$

$$\mathbf{Y} = \begin{bmatrix} 6 \\ 9 \\ 11 \end{bmatrix}$$

## MATRIČNO IZRAČUNAVANJE POMOĆU R-A

```
> X <- matrix(data=c(1.0, 4.5, 1.0, 7.1, 1, 9.6), nrow=3, ncol=2, byrow=TRUE)
> Y <- matrix(data=c(6, 9, 11), nrow=3, ncol=1, byrow=TRUE)
```

```
> X
```

```
      [,1] [,2]
[1,]    1  4.5
[2,]    1  7.1
[3,]    1  9.6
```

```
> Y
```

```
      [,1]
[1,]    6
[2,]    9
[3,]   11
```

```
> t(X)
```

```
      [,1] [,2] [,3]
[1,]  1.0  1.0  1.0
[2,]  4.5  7.1  9.6
```

# MATRIČNO IZRAČUNAVANJE POMOĆU R-A

```
> t(X) %*% X
      [,1] [,2]
[1,]  3.0 21.20
[2,] 21.2 162.82

> solve(t(X) %*% X)
      [,1] [,2]
[1,] 4.1727319 -0.54331112
[2,] -0.5433111 0.07688365

> solve(t(X) %*% X) %*% (t(X) %*% Y)
      [,1]
[1,] 1.7303947
[2,] 0.9815479
```



## IZRAČUNAVANJE POMOĆU R FUNKCIJA

```
> solve(t(X) %*% X) %*% (t(X) %*% Y)
```

- Osnovna funkcija za sprovođenje postupka linearne regresije u R-u jeste `lm()`
- Za naš jednostavni slučaj:

```
> lm(Y ~ X[,2])

Call:
lm(formula = Y ~ X[, 2])
Coefficients:
(Intercept)      X[, 2]
    1.7304      0.9815
```



# lm() FUNKCIJA

- Naravno, funkcija `lm()` ima daleko veće mogućnosti

```
> summary(lm(Y ~ X[,2]))

Call:
lm(formula = Y ~ X[, 2])
Residuals:
    1      2      3 
-0.1474  0.3006 -0.1533 

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.7304      0.7521   2.301   0.261
X[, 2]       0.9815      0.1021   9.614   0.066

Residual standard error: 0.3682 on 1 degrees of freedom
Multiple R-squared:  0.9893, Adjusted R-squared:  0.9786 
F-statistic: 92.43 on 1 and 1 DF,  p-value: 0.06598
```

- Zapamtite još i ovo:

```
> rezultat <- lm(Y ~ X[,2])
> summary(rezultat)
```



## VEŽBA 1

- Otvorite tabelu sa podacima 'hsb.txt' i pokušajte da sprovedete jednostavnu linearnu regresiju na oba načina, sa promenljivama:
  - $X \rightarrow read$  (čitanje)
  - $Y \rightarrow write$  (pisanje)

```
> hsb = read.table('data/hsb.txt', header=TRUE, sep='\t')
> head(hsb)
> attach(hsb)
> X = cbind(1, read)
> Y = write
> solve(t(X) %*% X) %*% (t(X) %*% Y)
> summary(lm(Y ~ X[,2]))
> summary(lm(write ~ read))
```



O LOGICI I ELEMENTIMA LINEARNIH MODELA

IZRAČUNAVANJE PARAMETARA

PODEŠAVANJE (*FITTING*) LINEARNIH MODELA U R-U

DODATAK



## OSNOVE FUNKCIJE `lm()`

- Počecemo sa podacima merenja i izveštavanja o visini i težini 200 muškaraca i žena (Davis, 1990):

```
> require(car)
> head(Davis)
> nrow(Davis)
> names(Davis)
> davis.lm <- lm(weight ~ repwt, data=Davis)
```

- Obratite pažnju: sada smo u samoj funkciji `lm()` naveli tabelu sa podacima (*data frame*)
- Pomoću koje funkcije u R-u smo mogli da ovu tabelu aktiviramo i tako učinimo navođenje parametra `data` nepotrebnim?



# REZULTATI KOJE DAJE FUNKCIJA `lm()`

```
> davis.lm

Call:
lm(formula = weight ~ repwt, data = Davis)
Coefficients:
(Intercept)      repwt
      5.3363      0.9278

> summary(davis.lm)

Call:
lm(formula = weight ~ repwt, data = Davis)
Residuals:
    Min       1Q   Median       3Q      Max
-7.048 -1.868 -0.728  0.601 108.705

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    5.3363     3.0369   1.757  0.0806
repwt          0.9278     0.0453  20.484 <2e-16

Residual standard error: 8.419 on 181 degrees of freedom
(17 observations deleted due to missingness)
Multiple R-squared:  0.6986, Adjusted R-squared:  0.697
F-statistic: 419.6 on 1 and 181 DF, p-value: < 2.2e-16

> confint(davis.lm)

              2.5 %      97.5 %
(Intercept) -0.6560394 11.328560
repwt        0.8384665  1.017219
```



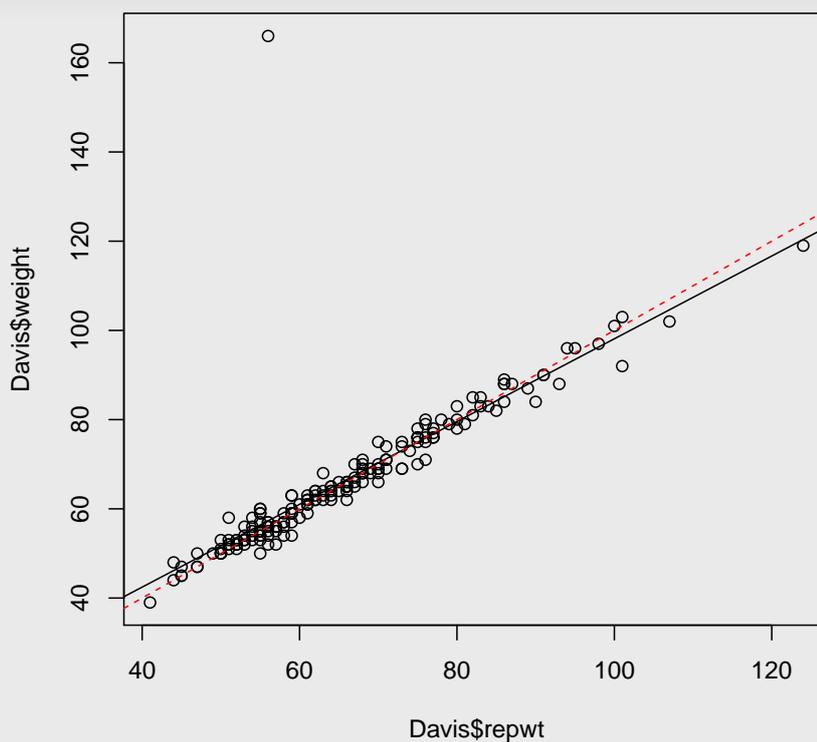
## PREISPITIVANJA REZULTATA

- Pošto vizuelno ispitivanje linearnosti odnosa  $i$ , uopšte, prirode raspodela nismo obavili prethodno, to moramo učiniti sada:

```
> plot(Davis$repwt, Davis$weight)
> abline(davis.lm)
> abline(0, 1, lty=2, col='red')
```



# DIJAGRAM RASPRŠENJA ZA MODEL $weight \sim repwt$



## INTERAKTIVNI RAD SA DIJAGRAMOM RASPRŠENJA

```
> plot(Davis$repwt, Davis$weight)  
> identify(Davis$repwt, Davis$weight)
```

- Dakle, utvrdili smo da postoje:
  - jedan **odstupajući podatak** (*outlier*)
  - jedan **istupajući podatak** (*extreme value*)



# REZULTATI NAKON KRITIČKE ANALIZE MODELA

- Možemo ukloniti odstupajući podatak i uporediti početni i konačni model:

```
> davis.lm.2 <- lm(weight ~ repwt, data=Davis, subset=-12)
> summary(davis.lm.2)
```

Call:

```
lm(formula = weight ~ repwt, data = Davis, subset = -12)
```

Residuals:

```
      Min       1Q   Median       3Q      Max
-7.5296 -1.1010 -0.1322  1.1287  6.3891
```

Coefficients:

```
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.73380     0.81479   3.355 0.000967
repwt        0.95837     0.01214  78.926 < 2e-16
```

Residual standard error: 2.254 on 180 degrees of freedom  
(17 observations deleted due to missingness)

Multiple R-squared: 0.9719, Adjusted R-squared: 0.9718

F-statistic: 6229 on 1 and 180 DF, p-value: < 2.2e-16

```
> cbind(Original=coef(davis.lm), NoCase12=coef(davis.lm.2))
```

```
              Original  NoCase12
(Intercept) 5.3362605 2.7338020
repwt       0.9278428 0.9583743
```

- Pokušajte sami sa istupajućim podatkom...



## VEŽBE

**VEŽBA 2** Sprovedite postupak jednostavne linearne regresije za model  $height \sim repht$ , sa podacima iz tabele 'Davis'

**VEŽBA 3** Sprovedite postupak jednostavne linearne regresije za model  $prestige \sim income$ , sa podacima iz tabele 'Prestige'



O LOGICI I ELEMENTIMA LINEARNIH MODELA

IZRAČUNAVANJE PARAMETARA

PODEŠAVANJE (*FITTING*) LINEARNIH MODELA U R-U

DODATAK



## VRSTE “UTICAJNIH PODATAKA”

- odstupajuća vrednost (*outlier*)
- ekstremna vrednost (*extreme value*)
  
- Kakvu vrstu problema mogu proizvesti pomenuti podaci?
- Kako ih možemo dijagnostikovati?
- Kako možemo izolovati/blokirati njihov uticaj?



