

# KORELACIJA

# Korelacija slučajnih varijabli

Za slučajne varijable  $X$  i  $Y$  **kovarianca** se definira kao

$$\text{Cov}(X, Y) = E[(X - E(X))(Y - E(Y))].$$

Kovarianca mjeri zajedničku varijaciju varijabli  $X$  i  $Y$ .

Kovarianca je izražena u mjernim jedinicama slučajnih varijabli  $X$  i  $Y$ .

**Korelacija:**

$$\text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y}$$

Korelacija nema mjernu jedinicu.

$$-1 \leq \text{Corr}(X, Y) \leq 1$$

Ukoliko su  $X$  i  $Y$  **nezavisne** slučajne varijable, tada je

$$E(X \cdot Y) = E(X) \cdot E(Y),$$

a posebno je

$$\begin{aligned} \text{Cov}(X, Y) &= E[(X - E(X))(Y - E(Y))] = \\ &= E[X - E(X)] \cdot E[Y - E(Y)] = \\ &= 0 \cdot 0 = 0. \end{aligned}$$

Isto vrijedi i za korelaciju:

$$\text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y} = 0.$$

Ukoliko su  $X$  i  $Y$  **linearno povezane** slučajne varijable:

$$Y = a \cdot X + b$$

tada je

$$\text{Var}(Y) = a^2 \text{Var}(X), \quad \text{tj.} \quad \sigma_Y = |a| \sigma_X$$

i

$$\begin{aligned}\text{Cov}(X, Y) &= E[(X - E(X))(Y - E(Y))] = \\ &= E[(X - E(X))(a \cdot X + b - a \cdot E(X) - b)] = \\ &= E[(X - E(X))(a \cdot X - a \cdot E(X))] = \\ &= aE[(X - E(X))(X - E(X))] = \\ &= a \cdot \text{Var}(X).\end{aligned}$$

Korelacija:

$$\begin{aligned} \text{Corr}(X, Y) &= \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y} = \\ &= \frac{a \cdot \text{Var}(X)}{\sigma_X |a| \sigma_X} = \\ &= \frac{a}{|a|} = \begin{cases} 1, & \text{za } a > 0; \\ -1, & \text{za } a < 0. \end{cases} \end{aligned}$$

Slučajne varijable  $X$  i  $Y$  **nezavisne**  $\rightarrow \text{Corr}(X, Y) = 0.$

Slučajne varijable  $X$  i  $Y$  **linearno zavisne**  $\rightarrow \text{Corr}(X, Y) = \pm 1.$

Uočimo da  $\text{Corr}(X, Y) = 0$  ne znači da su  $X$  i  $Y$  nezavisne slučajne varijable.

# Pearsonov koeficijent korelaciјe

Promatramo dva obilježja  $X$  i  $Y$  u populaciji veličine  $N$ .

**Pearsonov koeficijent korelaciјe** obilježja  $X$  i  $Y$ :

$$\rho = \frac{\frac{1}{N} \sum (x_i - \mu_x)(y_i - \mu_y)}{\sigma_X \cdot \sigma_Y}$$

$\sigma_X$  - standardna devijacija obilježja  $X$


$\sigma_Y$  - standardna devijacija obilježja  $Y$

$\mu_X$  - standardna devijacija obilježja  $X$


$\mu_Y$  - standardna devijacija obilježja  $Y$

# Dijagram raspršenja


Za varijable  $X$  i  $Y$  promatramo  $(X, Y)$ -graf:




$$\rho = 0$$




$$\rho = 0.47$$




$$\rho = -0.46$$




$$\rho = 0.80$$




$$\rho = -0.82$$




$$\rho = 0.98$$




$$\rho = -0.98$$



$$\rho = 0.999$$



$$\rho = -0.999$$



$$\rho = 1$$




$$\rho = -1$$

Potpuna linearna povezanost!

Pearsonov koeficijent korelacijske mjeri **linearu** povezanost dvije varijable.

→ **koeficijent linearne korelacijske**

Primjer nelinearne povezanosti:



$$\rho = 0, \quad y = x^2$$

## Pearsonov koeficijent korelacijske:

- broj iz intervala  $[-1, 1]$
- iskazuje smjer i jakost liniarne statističke veze između dvije pojave
- $r$  bliži -1 ili 1  $\rightarrow$  jača korelacija
- $r = 1$  ili  $r = -1$   $\rightarrow$  potpuna povezanost, funkcionalna povezanost
- $r > 0$   $\rightarrow$  pozitivna korelacija (veći  $x \rightarrow$  veći  $y$ )
- $r < 0$   $\rightarrow$  negativna korelacija (veći  $x \rightarrow$  manji  $y$ )
- - 0 – 0.25 - linearna korelacija slaba
  - 0.25 – 0.64 - korelacija srednje jačine
  - 0.64 – 1 - čvrsta korelacija

# Procjena Pearsonova koeficijenta korelacijske

$n$  - veličina uzorka

Uzorak:  $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$

$S_X = \sqrt{S_X^2}$  - procjena standardne devijacije za obilježje  $X$

$S_Y = \sqrt{S_Y^2}$  - procjena standardne devijacije za obilježje  $Y$

## Procjena Pearsonova koeficijenta korelacijske:

$$r = \frac{\frac{1}{n-1} \sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{S_X \cdot S_Y}$$

# Testiranje hipoteze o koeficijentu korelacije

Na osnovu uzorka  $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$  možemo testirati hipotezu

$$H_0 : \rho = 0$$

gdje je  $\rho$  Pearsonov koeficijent korelacije (za populaciju).

Statistika


$$t = \frac{\sqrt{n-2} \cdot r}{\sqrt{1 - r^2}}$$

je distribuirana prema Studentovoj razdiobi:  $t \sim t(n-2)$ .

**Primjer.** Na osnovu uzorka od 10 osoba procijenite koeficijent korelacijske za visinu i težinu.

Visina (cm)	Težina (kg)
183	76
163	52
180	61
168	64
160	52
157	48
185	94
155	46
193	118
173	57

## Dijagram raspršenja:



$$r = 0.89$$

Podaci:

```
> visina <-  
c(183,163,180,168,160,157,185,155,193,173)  
> tezina <- c(76,52,61,64,52,48,94,46,118,57)
```

Korelacija:

```
> cor(visina,tezina)
```

```
[1] 0.8906609
```

## Testiranje hipoteze $\rho = 0$ :

```
> t <- cor.test(visina,tezina)
```

```
> t
```

Pearson's product-moment correlation

data: visina and tezina

t = 5.5407, df = 8, p-value = 0.0005469

alternative hypothesis: true correlation is not equal to 0

95 percent confidence interval:

0.5943188 0.9740538


sample estimates:

cor

0.8906609

Dijagram raspršenja:

```
> plot(tezina ~ visina ,  
       main = "Visina vs. Težina",  
       xlab = "Težina (kg)",  
       ylab = "Visina (cm)")
```



## Interpretacija:

- Kod osobe s većom visinom očekujemo i veću težinu (pozitivna koreliranost)
- Kod osobe s većom težinom očekujemo i veću visinu (pozitivna koreliranost)
- Korelacija ne pokazuje uzročno-posljedičnu povezanost!
- Povećanjem težine nećemo povećati visinu.


# LINEARNA REGRESIJA

# Jednostavna linearna regresija

## Pravac

**Primjer.** Nacrtajte pravac koji prolazi kroz točke  $(1, 1)$  i  $(3, 2)$ .

Nacrtamo točke:




# Jednostavna linearna regresija

## Pravac

**Primjer.** Nacrtajte pravac koji prolazi kroz točke  $(1, 1)$  i  $(3, 2)$ .

Nacrtamo točke i provučemo pravac kroz njih:



**Primjer.** Nacrtajte pravac  $y = 2 \cdot x - 1$ .


Odredimo dvije točke na pravcu:

$$x = 1 \quad \Rightarrow \quad y = 2 \cdot 1 - 1 = 1$$

$$x = 2 \quad \Rightarrow \quad y = 2 \cdot 2 - 1 = 3$$

Točke:  $(1, 1)$  i  $(2, 3)$ .

Nacrtamo točke i provučemo pravac kroz dvije točke.



**Primjer.** Nacrtajte pravac  $y = -3 \cdot x + 8$ .


Odredimo dvije točke na pravcu:

$$x = 1 \implies y = -3 \cdot 1 + 8 = 5$$

$$x = 2 \implies y = -3 \cdot 2 + 8 = 2$$

Točke:  $(1, 5)$  i  $(2, 2)$ .

Nacrtamo točke i provučemo pravac kroz dvije točke.






## Jednadžba pravca:


$$y = a \cdot x + b.$$

$a$  - koeficijent smjera (*engl. 'slope'*)


$b$  - slobodni koeficijent (*engl. 'intercept'*)

## Koeficijent smjera





$$y = 2 \cdot x - 1$$



$$y = -3 \cdot x + 8$$

**Jednadžba pravca:**

$$y = a \cdot x + b.$$

**Interpretacija koeficijenata:**

Koeficijent smjera ( $a$ ) - ukoliko veličinu  $x$  povećamo za 1,  $y$  će se povećati za  $a$

Slobodni koeficijent ( $b$ ) - za  $x = 0$  je  $y = b$ .

# Regresijska analiza

- primjena metoda kojima se analitički (jednadžbom) objašnjava statistička ovisnost jedne varijable o drugoj ili o više drugih
- iz podataka jedne varijable 'prognoziramo' rezultat druge varijable
- zavisna varijabla - varijabla čiju ovisnost objašnjavamo
- nezavisne varijable - objašnjavaju ponašanje zavisne
- zasniva se na modelu
- model je pojednostavljenja slika stvarne pojave
- oblik modela ovisi o primjeru kojeg rješavamo
- ako je odnos između dvije pojave oblikom linearan - model jednostavne linearne regresije
- jedna nezavisna varijabla → jednostavna linearna regresija
- više nezavisnih varijabli → multivarijatna regresija

## Dijagram rasipanja

- prvi korak u regresijskoj analizi
- uočiti odnos među pojavama
- pravokutni koordinatni sustav (XY-graf)
- što više vrijednosti (parova) - kvalitetniji zaključak o pojavi

# Jednostavna linearna regresija


Odrediti oblik linearne veze znači odrediti vezu oblika

$$Y = a \cdot X + b.$$

Odrediti vezu  $\longleftrightarrow$  Odrediti koeficijente  $a$  i  $b$ .


Kako odrediti koeficijente  $a$  i  $b$ ?

## Podaci za visinu i težinu:



Kako odrediti pravac koji najbolje opisuje podatke?


## Podaci za visinu i težinu:



Koji pravac bolje opisuje podatke?


# Kvadratno odstupanje

## Udaljenost pravca od točke (podatka)




# Kvadratno odstupanje


## Udaljenost pravca od točke (podatka)



# Kvadratno odstupanje

## Odstupanje pravca od točke (podatka)





$$\text{Odstupanje} = a \cdot x_0 + b - y_0$$

**Odstupanje =**  $a \cdot x_0 + b - y_0$

**Apsolutno odstupanje =**  $|a \cdot x_0 + b - y_0|$


**Kvadratno odstupanje =**  $(a \cdot x_0 + b - y_0)^2$

U regresiji se najčešće koristi kvadratno odstupanje.

Kako definirati udaljenost pravca od skupa točaka?

**Srednje kvadratno odstupanje** aritmetička sredina kvadratnih odstupanja od pojedine točke.


# Srednje kvadratno odstupanje



**Primjer.** Izračunajte kvadratno odstupanje točke  $(2, 3)$  od pravca  $y = 0.5x - 1$ .

$$(x_0, y_0) = (2, 3)$$


$$(a \cdot x_0 + b - y_0)^2 = (0.5x_0 - 1 - y_0)^2 = (0.5 \cdot 2 - 1 - 3)^2 = (-3)^2 = 9$$



**Primjer.** Izračunajte srednje kvadratno odstupanje podataka iz tablice od pravca  $y = 2x - 1$ .


$x$	$y$
1	2
4	2
3	4


$x$	$y$	$2x - 1$	$2x - 1 - y$	$(2x - 1 - y)^2$
1	2	1	-1	1
4	2	7	5	25
3	4	5	1	1
$\sum$				27
$\sum/n$				9



**Primjer.** Koji od pravaca  $y = 0.5x$  i  $y = -0.5x + 4$  bolje opisuje podatke iz tablice?

$x$	$y$
1	2
3	1
5	4





Pravac	Srednje kvadratno odstupanje
$y = 0.5x$	1.58
$y = -0.5x + 4$	3.58

Manje srednje kvadratno odstupanje  
→ Pravac bolje opisuje podatke.

Koji pravac najbolje opisuje podatke?

Pravac s **najmanjim** srednjim kvadratnim odstupanjem.

Za podatke  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  tražimo pravac za koji je

$$\frac{1}{n} \sum_i (a \cdot x_i + b - y_i)^2$$

najmanje.

Tražimo  $a$  i  $b$  za koje je

$$\frac{1}{n} \sum_i (a \cdot x_i + b - y_i)^2$$

najmanje.

Pravac koji minimizira srednje kvadratno odstupanje naziva se **regresijski pravac**.

Koeficijenti regresijskog pravca nazivaju se **regresijski koeficijenti**.


Eksplicitni izraz za regresijske koeficijente:

$$\begin{aligned}
 a &= \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} = \\
 &= \frac{Cov(X, Y)}{S_x^2} = \\
 &= r_{X,Y} \frac{S_y}{S_x} \\
 b &= \bar{Y} - a \cdot \bar{X}
 \end{aligned}$$

$r_{X,Y}$  - Pearsonov koeficijent korelacije varijabli  $X$  i  $Y$

**Primjer.** Regresijski pravac za podatke o visini i težini.

$$\text{Težina} = 1.56854 \cdot \text{Visina} - 202.519$$



# Standardizirani koeficijenti

Umjesto regresije s varijablama  $X$  i  $Y$  možemo napraviti regresiju sa standardiziranim varijablama  $Z_X$  i  $Z_Y$ :

$$Z_Y = \alpha Z_X + \beta.$$

Zbog standardizacije je

$$\bar{Z}_X = \bar{Z}_Y = 0$$

te je slobodni koeficijent

$$\beta = \bar{Z}_Y - a \cdot \bar{Z}_X = 0.$$

Nadalje:

$$\alpha = r_{Z_X, Z_Y} \frac{S_{Z_X}}{S_{Z_Y}} = r_{X, Y}$$

jer su  $Z_X$  i  $Z_Y$  standardizirane varijable:

$$S_{Z_X} = S_{Z_Y} = 1$$

i


$$r_{Z_X, Z_Y} = r_{X, Y}.$$

Veza između regresijskih koeficijenata i standardiziranih regresijskih koeficijenata:

$$\alpha = a \cdot \frac{S_Y}{S_X}.$$

# Koeficijent determinacije

Koliko dobro regresijski pravac opisuje podatke?



Srednje kvadratno odstupanje regresijskog pravca je manje nego za pravac  $y = \bar{Y}$ .

$$\sum_i (a \cdot x_i + b - y_i)^2 \leq \sum_i (y_i - \bar{Y})^2$$

Desna strana je proporcionalna  $\text{Var}(Y)$ .

Član

$$\sum_i (a \cdot x_i + b - y_i)^2$$


je **neobjašnjena varijanca** od  $Y$ .

Oznake:

$$\text{SSE} = \sum_i (a \cdot x_i + b - y_i)^2$$

$$\text{SST} = \sum_i (y_i - \bar{Y})^2$$

# Ukupna varijacija      Objasnjena varijacija



Neobjasnjena varijacija

**Objašnjena varijanca:**  $SST - SSE$

SSE ovisi o mjernim jedinicama.

$$0 \leq SSE \leq SST$$

$SSE = 0 \rightarrow$  pravac idealno opisuje podatke

$SSE = SST \rightarrow$  nema utjecaja obilježja  $X$  na obilježje  $Y$ .

Mjera kvalitete regresije

$$\frac{\text{objašnjena varijanca}}{\text{ukupna varijanca}} = \frac{SST - SSE}{SST}$$

## Koeficijent determinacije:

$$r^2 = \frac{SST - SSE}{SST} = 1 - \frac{SSE}{SST}$$

$r^2$  - udio objašnjene varijacije u ukupnoj varijaciji

$r^2 = 1$  - pravac idealno opisuje podatke


$r^2 = 0$  - nema utjecaja obilježja  $X$  na obilježje  $Y$

## Veza koeficijenta determinacije i koeficijenta korelacije:





$$r^2 = r_{XY}^2$$

$r^2$  - koeficijent determinacije

$r_{XY}$  - koeficijent korelacijske funkcije



$$r^2 = 0.79$$



## Parcijalna korelacija

Zanima nas korelacija varijabli  $X$  i  $Y$  ali bez dijela varijacije koja je opisana obilježjem  $Z$ .


Od varijabli  $X$  i  $Y$  oduzmemmo dio koji opisuje  $Z$  (dobiven regresijom, za svaku varijablu posebno):

$$R_{X.Z} = X - a_1 Z - b_1$$

$$R_{Y.Z} = Y - a_2 Z - b_2$$

**Parcijalna korelacija** od  $X$  i  $Y$ :

$$r_{XY.Z} = \text{Corr}(R_{X.Z}, R_{Y.Z})$$



# Testiranje hipoteza o koeficijentima

Pretpostavka:  $X$  i  $Y$  imaju **bivariatnu normalnu** razdiobu.

Regresijski model:

$$Y = a \cdot X + b$$

Možemo testirati hipoteze

$$a = 0 \quad \text{i / ili} \quad b = 0.$$

Znamo:

$$\text{SST} = S_Y^2 = \sum_i (Y_i - \bar{Y})^2 \sim \chi^2(n-1)$$

Vrijedi

$$\text{SSE} = \sum_i (a \cdot X_i + b - Y_i)^2 \sim \chi^2(n-2)$$

Može se pokazati da je

$$\text{SST} - \text{SSE} \sim \chi^2(1)$$

## Testiranje hipoteze $a = 0$

Promatramo regresijski pravac za koji je  $a = 0$ :

$$Y = b$$

Suma kvadratnih odstupanja

$$\sum_i (y_i - b)^2$$

je najmanja za  $b = \bar{Y}$ .

Suma kvadratnih odstupanja je

$$\sum_i (y_i - \bar{Y})^2 = SST$$

Statistika:

$$F = \frac{SST - SSE}{SSE} \sim F(1, n - 2)$$

**Testiranje hipoteze  $b = 0$**  je analogno jedino promatramo model za koji je  $b = 0$ :

$$Y = a \cdot X.$$

Statistiku dobijemo analogno kao kod testiranja hipoteze  $a = 0$ .

Drugi pristup je konstrukcija testa na osnovu distribucije regresijskih koeficijenata i uporaba  $t$ -statistike.

**R**

**Primjer.** Podaci o visini i težini.

```
> lm(tezina ~ visina)
```

Call:

```
lm(formula = tezina ~ visina)
```

Coefficients:

(Intercept)	visina
-202.519	1.569

Prikazani su samo koeficijent.

## Drugi pristup:

```
> regresija=lm(tezina    visina)  
> regresija
```

Call:

```
lm(formula = tezina    visina)
```

Residuals:

	Min	1Q	Median	3Q	Max						
-18.819	-6.682	3.278	5.110	17.790	Coefficients:						
						Estimate Std. Error t value Pr(> t )					
(Intercept)	-202.5190		48.7352	-4.155	0.003185	**					
visina		1.5685		0.2831	5.541	0.000547 ***					
--											
Signif. codes:	0	'***'	0.001	'**'	0.01	'*'	0.05	'.'	0.1	' '	1

Residual standard error: 11.15 on 8 degrees of freedom

Multiple R-squared: 0.7933, Adjusted R-squared:  
0.7674

F-statistic: 30.7 on 1 and 8 DF, p-value:  
0.0005469

# Višestruka linearna regresija

Promatra se ovisnost **jedne** varijable o **više** varijabli.

Model:

$$Y = a_0 + a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_k \cdot X_k$$

zavisna varijabla:  $Y$

Nezavisne varijable:  $X_1, X_2, \dots, X_k$

Još se koristi naziv **multivarijatna regresija**.

Zavisna varijabla = **varijabla odziva** ('response')

nezavisne varijable = **prediktorske varijable**

Uzorak:

$$(y_1, x_{11}, x_{21}, \dots, x_{k1})$$

$$(y_2, x_{12}, x_{22}, \dots, x_{k2})$$

$$\vdots$$

$$(y_n, x_{1n}, x_{2n}, \dots, x_{kn})$$

Regresijske koeficijente dobijemo minimiziranjem sume kvadratnih odstupanja:

$$\sum_i (a_0 + a_1 \cdot x_{1i} + a_2 \cdot x_{2i} + \dots + a_k \cdot x_{ki} - y_i)^2$$

# Koeficijent determinacije

Isti princip kao u jednostavnoj linearnej regresiji.

Koeficijent determinacije je udio objašnjene varijance u ukupnoj varijanci.

Ukupna varijanca:  $SST = \sum_i (y_i - \bar{Y})^2$

Neobjašnjena varijanca od  $Y$ :

$SSE = \sum_i (a_0 + a_1 \cdot x_{1i} + a_2 \cdot x_{2i} + \dots + a_k \cdot x_{ki} - y_i)^2$

Objašnjena varijanca od  $Y$ :  $SST - SSE$

## Koeficijent determinacije

$$r^2 = \frac{SST - SSE}{SST} = 1 - \frac{SSE}{SST}$$

## Značajnost modela

Testiramo hipotezu da nezavisne varijable nisu korelirane s zavisnom.

↔ Model opisuje zavisnu varijablu jednako dobro kao model sa slobodnim koeficijentom.

Distribucije suma:

$$\text{SST} \sim \chi^2(n - 1)$$

$$\text{SSE} \sim \chi^2(n - k - 1)$$

$$\text{SST} - \text{SSE} \sim \chi^2(k)$$

Statistika:

$$F = \frac{(\text{SST} - \text{SSE})/k}{\text{SSE}/(n - k - 1)} \sim F(k, n - k - 1)$$

$k$  - broj nezavisnih varijabli

## Značajnost regresijskih koeficijenata

Želimo provjeriti da li varijabla  $X_m$  značajno doprinosi opisu zavisne varijable  $Y$  u modelu

$$Y = a_0 + a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_k \cdot X_k$$

Npr., za  $m = k$ , gornji model uspoređujemo s modelom

$$Y = a_0 + a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_{k-1} \cdot X_{k-1}$$

(polazni model bez varijable  $X_k$ )

Ukoliko varijabla  $X_k$  nije značajna tada oba modela podjednako opisuju  $Y$ .

Uspoređujemo sume kvadratnih odstupanja za oba modela.

Ukupna varijanca:  $\text{SST} = \sum_i (y_i - \bar{Y})^2$

Neobjašnjena varijanca od  $Y$  (puni model):

$$\text{SSE} = \sum_i (a_0 + a_1 \cdot x_{1i} + a_2 \cdot x_{2i} + \dots + a_k \cdot x_{ki} - y_i)^2$$

Neobjašnjena varijanca od  $Y$  (model bez  $X_k$ ):

$$\text{SSE}_k = \sum_i (b_0 + b_1 \cdot x_{1i} + b_2 \cdot x_{2i} + \dots + b_{k-1} \cdot x_{(k-1)i} - y_i)^2$$

Distribucija:

$$\text{SSE}_k \sim \chi^2(n - k) \quad \text{i} \quad \text{SSE} - \text{SSE}_k \sim \chi^2(1)$$

Statistika:

$$F = \frac{\text{SSE}_k - \text{SSE}}{\text{SSE}/(n - k - 1)} \sim F(k, n - k - 1)$$

## R. Primjer.

Na 22 slučajno izabranih muških osoba starih između 16 i 30 godina izmjereno je:

- ① mass - masa osobe u kg
- ② fore - maksimalni opseg podlaktice
- ③ bicep - maksimalni opseg bicepsa
- ④ chest - opseg grudi
- ⑤ neck - opseg vrata
- ⑥ waist - opseg struka
- ⑦ thigh - opseg bedra
- ⑧ calf - maksimalni opseg potkoljenice
- ⑨ height - visina
- ⑩ shoulders - opseg ramena
- ⑪ head - opseg glave

Može li se masa osobe procijeniti na osnovu izmjerenih veličina?

## Regresija:

```
> reg=lm(Mass ~ Fore + Bicep + Chest + Neck +  
Shoulder + Waist + Height + Calf + Thigh + Head,  
data = podaci)  
> summary(reg)
```

R Console

```

Estimate Std. Error t value Pr(>|t|)
(Intercept) -69.51714 29.03739 -2.394 0.035605 *
Fore         1.78182  0.85473  2.085 0.061204 .
Bicep        0.15509  0.48530  0.320 0.755275
Chest         0.18914  0.22583  0.838 0.420132
Neck          -0.48184  0.72067 -0.669 0.517537
Shoulder     -0.02931  0.23943 -0.122 0.904769
Waist         0.66144  0.11648  5.679 0.000143 ***
Height        0.31785  0.13037  2.438 0.032935 *
Calf          0.44589  0.41251  1.081 0.302865
Thigh         0.29721  0.30510  0.974 0.350917
Head          -0.91956  0.52009 -1.768 0.104735
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '*' 0.1 ' ' 1

Residual standard error: 2.287 on 11 degrees of freedom
Multiple R-squared:  0.9772,    Adjusted R-squared:  0.9565
F-statistic: 47.17 on 10 and 11 DF,  p-value: 1.408e-07

```

> |

$r^2 = 0.9772$  - varijable dobro opisuju masu

$p = 1.408 \cdot 10^{-7}$  - model je značajan

Height, waist su značajne


Jesu li druge varijable značajne u opisu mase?


# Izgradnja modela u višestrukoj regresiji

Samo su dvije varijable značajne.

Znači li to da druge varijable ne sudjeluju značajno u opisu zavisne varijable Masa?

Prediktorske varijable mogu biti korelirane.





## Modeli

$$Y = a_0 + a_1 \cdot X_1 + a_2 \cdot X_2$$

i

$$Y = a_0 + a_1 \cdot X_1$$

jednako dobro opisuju  $Y$ .

U prvom modelu  $X_1$  i  $X_2$  nisu značajne.

Međutim,  $X_1$  je značajna u drugom modelu.

**Primjer.** Analiziramo tri varijable:

Hcm - visina u centimetrima

Hm - visina u metrima

Hinch - visina u inchima

Promatramo model

$$Hcm = a_0 + a_1 \cdot Hm + a_2 \cdot Hinch$$

Jer je

$$Hcm = 100 \cdot Hm \quad i \quad Hcm = 2.54 \cdot Hinch$$

modeli

$$Hcm = a_0 + a_1 \cdot Hm$$

i

$$Hcm = a_0 + a_1 \cdot Hinch$$

jednako dobro opisuju Hcm ( $r^2 = 1$  za sva tri modela).

Varijable Hm i Hinch će biti nesignifikantne u modelu

$$Hcm = a_0 + a_1 \cdot Hm + a_2 \cdot Hinch$$

iako je svaka od njih jako povezana s zavisnom varijablom Hcm.

**Prediktorska varijabla može biti nesignifikantna jer je linearno zavisna s jednom ili više drugih prediktorskih varijabli.**

## Interpretacija koeficijenata.

```
R Console
```

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-69.51714	29.03739	-2.394	0.035605 *
Fore	1.78182	0.85473	2.085	0.061204 .
Bicep	0.15509	0.48530	0.320	0.755275
Chest	0.18914	0.22583	0.838	0.420132
Neck	-0.48184	0.72067	-0.669	0.517537
Shoulder	-0.02931	0.23943	-0.122	0.904769
Waist	0.66144	0.11648	5.679	0.000143 ***
Height	0.31785	0.13037	2.438	0.032935 *
Calf	0.44589	0.41251	1.081	0.302865
Thigh	0.29721	0.30510	0.974	0.350917
Head	-0.91956	0.52009	-1.768	0.104735
---				
Signif. codes:	0 ****	0.001 **	0.01 *	0.05 .
	'.'	0.1 ' '	1	
Residual standard error:	2.287	on 11 degrees of freedom		
Multiple R-squared:	0.9772,	Adjusted R-squared:	0.9565	
F-statistic:	47.17	on 10 and 11 DF,	p-value: 1.408e-07	

> |

Širina leđa i ramena te opseg glave negativno utječu na masu!

Treba odrediti model u kojem su sve varijable značajne.

Strategija: Izbacujemo jednu po jednu varijablu iz modela.

Izbacujemo varijablu koja najmanje doprinosi objašnjenoj varijanci.

→ Izbacujemo varijablu s najvećom p-vrijednosti za regresijski koeficijent.

Ovaj postupak se naziva **eliminacija unatrag** ('backward elimination').

Izbacivanje prekinemo kada su sve varijable značajne.

Često se za izbacivanje koristi veća razina značajnosti od standardnih  $\alpha = 0.05$  (npr. 0.10).

## 1.korak

R Console

```

            Estimate Std. Error t value Pr(>|t|)
(Intercept) -69.51714   29.03739 -2.394 0.035605 *
Fore         1.78182   0.85473  2.085 0.061204 .
Bicep        0.15509   0.48530  0.320 0.755275
Chest        0.18914   0.22583  0.838 0.420132
Neck         -0.48184   0.72067 -0.669 0.517537
Shoulder     -0.02931   0.23943 -0.122 0.904769
Waist        0.66144   0.11648  5.679 0.000143 ***
Height       0.31785   0.13037  2.438 0.032935 *
Calf          0.44589   0.41251  1.081 0.302865
Thigh        0.29721   0.30510  0.974 0.350917
Head         -0.91956   0.52009 -1.768 0.104735
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '*' 0.1 '.' 1

Residual standard error: 2.287 on 11 degrees of freedom
Multiple R-squared:  0.9772,    Adjusted R-squared:  0.9565
F-statistic: 47.17 on 10 and 11 DF,  p-value: 1.408e-07

```

&gt; |

Izbacujemo varijablu Shoulder.

## 2.korak

```
R Console

Coefficients:
              Estimate Std. Error t value Pr(>|t|)    
(Intercept) -70.5386   26.6470  -2.647   0.0213 *  
Fore         1.7179    0.6484   2.650   0.0212 *  
Bicep        0.1615    0.4622   0.350   0.7328    
Chest         0.1729    0.1749   0.988   0.3425    
Neck          -0.4846   0.6901  -0.702   0.4960    
Waist         0.6585    0.1091   6.034   5.9e-05 *** 
Height        0.3108    0.1122   2.771   0.0169 *  
Calf          0.4529    0.3914   1.157   0.2698    
Thigh         0.3123    0.2676   1.167   0.2659    
Head          -0.8932   0.4537  -1.969   0.0725 .  
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '*' 0.1 '.' 1

Residual standard error: 2.191 on 12 degrees of freedom
Multiple R-squared:  0.9772,    Adjusted R-squared:  0.9601 
F-statistic: 57.09 on 9 and 12 DF,  p-value: 1.784e-08

> |
```

I varijabla Fore je značajna!

Izbacujemo varijablu Bicep.

### 3.korak

```
R Console

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -71.95027   25.43433 -2.829  0.01422 *  
Fore         1.79678    0.58696  3.061  0.00910 ** 
Chest        0.19282    0.15965  1.208  0.24864    
Neck        -0.37432    0.59271 -0.632  0.53864    
Waist        0.65393    0.10463  6.250 2.97e-05 *** 
Height       0.28849    0.08902  3.241  0.00644 ** 
Calf          0.47487    0.37305  1.273  0.22533    
Thigh        0.30508    0.25761  1.184  0.25749    
Head         -0.85259    0.42348 -2.013  0.06527 .  
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '*' 0.1 '.' 1

Residual standard error: 2.116 on 13 degrees of freedom
Multiple R-squared:  0.9769,    Adjusted R-squared:  0.9628 
F-statistic: 68.87 on 8 and 13 DF,  p-value: 2.165e-09

> |
```

Izbacujemo varijablu Neck.

## 4.korak

```
R Console


Coefficients:
              Estimate Std. Error t value Pr(>|t|)    
(Intercept) -76.05013   24.05809 -3.161  0.00694 ** 
Fore          1.62588   0.50955  3.191  0.00654 ** 
Chest         0.13796   0.13103  1.053  0.31025    
Waist         0.63648   0.09873  6.447  1.53e-05 *** 
Height        0.26875   0.08154  3.296  0.00530 ** 
Calf           0.54684   0.34751  1.574  0.13791    
Thigh          0.32121   0.25077  1.281  0.22105    
Head          -0.82210   0.41159 -1.997  0.06560 .  
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '*' 0.1 '.' 0.1 ' ' 1 

Residual standard error: 2.07 on 14 degrees of freedom
Multiple R-squared:  0.9762,    Adjusted R-squared:  0.9644 
F-statistic: 82.18 on 7 and 14 DF,  p-value: 2.744e-10

> |
```

Izbacujemo varijablu Chest.

## 5.korak



R Console

```
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -79.72624   23.88925  -3.337  0.00450 **
Fore          1.79485    0.48536   3.698  0.00215 **
Waist         0.65671    0.09719   6.757  6.45e-06 ***
Height        0.25388    0.08059   3.150  0.00661 **
Calf           0.50718    0.34671   1.463  0.16415
Thigh          0.43298    0.22801   1.899  0.07698 .
Head          -0.65722    0.38200  -1.720  0.10590
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '*' 0.1 '.' 0.1 ' ' 1

Residual standard error: 2.077 on 15 degrees of freedom
Multiple R-squared:  0.9744,    Adjusted R-squared:  0.9641
F-statistic:  95 on 6 and 15 DF,  p-value: 4.501e-11
```

> |

Izbacujemo varijablu Calf.

## 6.korak

R Console

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -80.45330   24.72024 -3.255  0.00497 ** 
Fore         2.12319    0.44541  4.767  0.00021 ***  
Waist        0.66561    0.10040  6.630  5.79e-06 ***  
Height       0.27704    0.08179  3.387  0.00376 **  
Thigh        0.52317    0.22720  2.303  0.03506 *   
Head         -0.63714   0.39512  -1.613  0.12639  
---
Signif. codes:  0 '****' 0.001 '***' 0.01 '**' 0.05 '.' 0.1 ' ' 1 

Residual standard error: 2.15 on 16 degrees of freedom
Multiple R-squared:  0.9707,    Adjusted R-squared:  0.9615 
F-statistic:  106 on 5 and 16 DF,  p-value: 1.104e-11

> |
```

I varijabla Thigh je značajna!

Izbacujemo varijablu Head.

## R Console

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-113.31204	14.63911	-7.740	5.70e-07	***
Fore	2.03558	0.46243	4.402	0.00039	***
Waist	0.64688	0.10431	6.201	9.67e-06	***
Height	0.27175	0.08548	3.179	0.00549	**
Thigh	0.54008	0.23740	2.275	0.03614	*

---

Signif. codes: 0 '\*\*\*\*' 0.001 '\*\*\*' 0.01 '\*\*' 0.05 '\*' 0.1 '.' 1

Residual standard error: 2.249 on 17 degrees of freedom

Multiple R-squared: 0.9659, Adjusted R-squared: 0.9579

F-statistic: 120.5 on 4 and 17 DF, p-value: 3.079e-12

Sve su varijable značajne!

**Model:**

$$\text{Mass} = -113.312 + 2.036 \cdot \text{Fore} + 0.647 \cdot \text{Waist} + \\ + 0.272 \cdot \text{Height} + 0.540 \cdot \text{Thigh}$$

Može se koristiti i strategija dodavanja najznačajnije varijable (**dodavanje unaprijed**).

Prvo u model stavimo varijablu koja ima najveću objašnjenu varijancu (najmanju p-vrijednost u modelima s jednom varijablom).

Zatim, korak po korak, dodajemo varijablu koja najviše povećava objašnjenu varijancu.

Može se koristiti i kombinacija ova dva pristupa, u svakom koraku ubacimo ili izbacimo po jednu varijablu.

## Napomene o regresiji

- Broj podataka treba biti barem 5 puta veći od broja parametara (broj varijabli + slobodni koeficijent).
- Preveliki broj podataka može rezultirati zaključkom da su sve varijable značajne.
- Preporučljivo je između 20 i 40 podataka po parametru.
- Normalnost. Pretpostavka je da je zavisna varijabla  $Y$  normalna za svaku moguću vrijednost varijabli  $X_1, X_2, \dots, X_k$ .
- Varijanca slučajne varijable  $Y$  treba biti ista za svaku moguću vrijednost varijabli  $X_1, X_2, \dots, X_k$ . (homoskedastičnost)
- postojanje ekstremnih vrijednosti (outliera) može znatno utjecati na rezultat regresije.
- Regresijskom analizom ispitujemo povezanost **neprekidnih** varijabli.

# Napomene o regresiji

- Ukoliko je jedna nezavisna varijabla linearna kombinacija nekoliko preostalih varijabli tada se ne mogu odrediti regresijski koeficijenti.  
Ovo se najčešće događa kada jednu varijablu u regresiji definiramo preko nekoliko drugih varijabli (zbroj ili aritmetička sredina)
- U regresiju je moguće uključiti i kategoriske varijable upotrebom tzv. praznih ('dummy') varijabli.
- Ukoliko želimo u regresiji kao zavisnu varijablu koristiti kategorisku (dihotomnu) varijablu koristi se **logistička regresija**.
- Povezanost varijabli ne znači uzročno posljedičnu povezanost!