

# Statistika

Vanja Wagner

## 5. Statistički testovi

## Testiranje pripadnosti diskretnoj distribuciji

Promatramo diskretno obilježje s konačno mnogo vrijednosti:  $x_1, x_2, \dots, x_k$ . Modeliramo to obilježje u danoj populaciji sa slučajnom varijablom  $X$ .

**Cilj:** ustvrditi je li razdioba obilježja u populaciji jednako zadanoj razdiobi.

## Testiranje pripadnosti diskretnoj distribuciji

Promatramo diskretno obilježje s konačno mnogo vrijednosti:  $x_1, x_2, \dots, x_k$ . Modeliramo to obilježje u danoj populaciji sa slučajnom varijablom  $X$ .

**Cilj:** ustvrditi je li razdioba obilježja u populaciji jednako zadanoj razdiobi.

**Hipoteza:**  $H_0$  : distribucija obilježja  $X$  u populaciji jednaka je zadanoj distribuciji:

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix},$$

odnosno, testiramo hipotezu da je  $\mathbf{P}(X = x_i) = p_i, i = 1, \dots, k$ . ( $H_1$  : ne  $H_0$ )

## Testiranje pripadnosti diskretnoj distribuciji

Promatramo diskretno obilježje s konačno mnogo vrijednosti:  $x_1, x_2, \dots, x_k$ . Modeliramo to obilježje u danoj populaciji sa slučajnom varijablom  $X$ .

**Cilj:** ustvrditi je li razdioba obilježja u populaciji jednako zadanoj razdiobi.

**Hipoteza:**  $H_0$  : distribucija obilježja  $X$  u populaciji jednaka je zadanoj distribuciji:

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix},$$

odnosno, testiramo hipotezu da je  $\mathbf{P}(X = x_i) = p_i, i = 1, \dots, k$ . ( $H_1$  : ne  $H_0$ )

Testiranje provodimo na temelju uzorka (mjerena promatranog obilježja u populaciji), koji je reprezentiran frekvencijskom tablicom:

Kategorija	Frekvencija
$x_1$	$f_1$
$x_2$	$f_2$
$\vdots$	$\vdots$
$x_k$	$f_k$
Ukupno	$n$

Pri tome je:

$f_i$  - frekvencija vrijednosti  $x_i$  u uzorku  
(opažena frekvencija,  $O_i$ )

$n$  - duljina uzorka

## Pearsonov $\chi^2$ test pripadnosti distribuciji

Ovu hipotezu ćemo testirati preko Pearsonovog  $\chi^2$  testa.

## Pearsonov $\chi^2$ test pripadnosti distribuciji

Ovu hipotezu ćemo testirati preko Pearsonovog  $\chi^2$  testa.

**Statistika:** Za zadanu testnu razdiobu

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix}$$

i uzorak veličine  $n$  definiramo **teorijske frekvencije**:

$$E_i = n \cdot p_i.$$

Rezultat možemo prikazati tablično

Kategorija	Frekvencije	
	Opažena	Teorijska
$x_1$	$f_1$	$E_1$
$x_2$	$f_2$	$E_2$
$\vdots$	$\vdots$	$\vdots$
$x_k$	$f_k$	$E_k$
Ukupno	$n$	$n$

Uočimo da  $E_i$  predstavlja očekivani broj pojava vrijednosti  $x_i$  u uzorku duljine  $n$  za obilježje  $X$  ako vrijedi

# Pearsonov $\chi^2$ test pripadnosti distribuciji

Definiramo statistiku

$$Hi^2 = \sum_i \frac{(f_i - E_i)^2}{E_i}.$$



## Pearsonov $\chi^2$ test pripadnosti distribuciji

Definiramo statistiku

$$Hi^2 = \sum_i \frac{(f_i - E_i)^2}{E_i}.$$

Ako vrijedi  $H_0$ ,  $Hi^2$  je distribuirana prema  $\chi^2$  razdiobi s  $k - p - 1$  stupnjeva slobode:

$$Hi^2 \sim \chi^2(k - p - 1).$$

Ovdje je  $p$  broj parametara koje smo morali procijeniti da bismo posve definirali testnu razdiobu.

## Pearsonov $\chi^2$ test pripadnosti distribuciji

Definiramo statistiku

$$Hi^2 = \sum_i \frac{(f_i - E_i)^2}{E_i}.$$

Ako vrijedi  $H_0$ ,  $Hi^2$  je distribuirana prema  $\chi^2$  razdiobi s  $k - p - 1$  stupnjeva slobode:

$$Hi^2 \sim \chi^2(k - p - 1).$$

Ovdje je  $p$  broj parametara koje smo morali procijeniti da bismo posve definirali testnu razdiobu.

**Pretpostavka  $\chi^2$  testa:**  $E_i \geq 5$  (postoje razne modifikacije)

## Pearsonov $\chi^2$ test pripadnosti distribuciji

Definiramo statistiku

$$Hi^2 = \sum_i \frac{(f_i - E_i)^2}{E_i}.$$

Ako vrijedi  $H_0$ ,  $Hi^2$  je distribuirana prema  $\chi^2$  razdiobi s  $k - p - 1$  stupnjeva slobode:

$$Hi^2 \sim \chi^2(k - p - 1).$$

Ovdje je  $p$  broj parametara koje smo morali procijeniti da bismo posve definirali testnu razdiobu.

**Pretpostavka  $\chi^2$  testa:**  $E_i \geq 5$  (postoje razne modifikacije)

**Kritično područje:** uz razinu značajnosti  $\alpha \in (0, 1)$  je

$$[\chi_{1-\alpha}^2(k - p - 1), \infty),$$

pri čemu je  $\chi_{1-\alpha}^2(k - p - 1)$   $1 - \alpha$  kvantil  $\chi^2$  razdiobe s  $k - p - 1$  stupnjeva slobode.

## Primjer.

Istraživač za slučajni izbor u uzorak koristi igraću kocku. Prije početka izbora uzorka htio je provjeriti je li njegova kocka simetrična (svi brojevi imaju iste vjerojatnosti). Kocku je bacio 120 puta i zabilježio frekvencije brojeva:

Vrijednost	Opažena frekvencija
1	23
2	15
3	16
4	28
5	17
6	21
Ukupno	120

Je li kocka simetrična?

## Primjer.

Istraživač za slučajni izbor u uzorak koristi igraću kocku. Prije početka izbora uzorka htio je provjeriti je li njegova kocka simetrična (svi brojevi imaju iste vjerojatnosti). Kocku je bacio 120 puta i zabilježio frekvencije brojeva:

Vrijednost	Opažena frekvencija
1	23
2	15
3	16
4	28
5	17
6	21
Ukupno	120

Je li kocka simetrična? Označimo s  $X$  rezultat bacanja kocke. Nulta hipoteza je:

$$H_0: X \sim \begin{pmatrix} 1 & 2 & \dots & 6 \\ 1/6 & 1/6 & \dots & 1/6 \end{pmatrix}.$$

## Primjer.

Istraživač za slučajni izbor u uzorak koristi igraču kocku. Prije početka izbora uzorka htio je provjeriti je li njegova kocka simetrična (svi brojevi imaju iste vjerojatnosti). Kocku je bacio 120 puta i zabilježio frekvencije brojeva:

Vrijednost	Opažena frekvencija
1	23
2	15
3	16
4	28
5	17
6	21
Ukupno	120

Je li kocka simetrična? Označimo s  $X$  rezultat bacanja kocke. Nulta hipoteza je:

$$H_0: X \sim \begin{pmatrix} 1 & 2 & \dots & 6 \\ 1/6 & 1/6 & \dots & 1/6 \end{pmatrix}.$$

Izračunamo teorijske frekvencije ( $E_i = 120 \cdot \frac{1}{6} = 20$ ) i u Excelu pozovemo funkciju

$$=CHISQ.TEST(f1:f6,E1:E6).$$

Funkcija vraća  $p$ -vrijednost testa. U ovom primjeru je  $p = 0.287 \geq 0.05$  pa ne odbacujemo pretpostavku da je kocka simetrična.

## Primjer.

Želimo ispitati je li broj rekombinacija  $X$  tijekom mejoze na jednom kromosomu neke biljne vrste Poissonova slučajna varijabla,

$$\mathbf{P}(X = i) = \frac{\lambda^i}{i!} e^{-\lambda}, \quad i = 0, 1, 2, \dots$$

za neki parametar  $\lambda$  (očekivani broj rekombinacija). Pretpostavljamo da imamo podatke nakon  $n = 60$  mejoza danih tablicom

<b>Broj rekombinacija</b>	0	1	2	3	Ukupno
<b>Frekvencija</b>	32	15	9	4	60

## Primjer.

Želimo ispitati je li broj rekombinacija  $X$  tijekom mejoze na jednom kromosomu neke biljne vrste Poissonova slučajna varijabla,

$$P(X = i) = \frac{\lambda^i}{i!} e^{-\lambda}, \quad i = 0, 1, 2, \dots$$

za neki parametar  $\lambda$  (očekivani broj rekombinacija). Pretpostavljamo da imamo podatke nakon  $n = 60$  mejoza danih tablicom

<b>Broj rekombinacija</b>	0	1	2	3	Ukupno
<b>Frekvencija</b>	32	15	9	4	60

Da bismo procijenili parametar  $\lambda$ , prisjetimo se da je očekivanje Poissonove razdiobe upravo jednako  $\lambda$ , stoga je prirodan procjenitelj upravo aritmetička sredina uzorka  $\bar{x}$ . Kako je

$$\hat{\lambda} = \bar{x} = \frac{0 \cdot 32 + 1 \cdot 15 + 2 \cdot 9 + 3 \cdot 4}{60} = 0.75$$

možemo odrediti teorijske frekvencije

$$E_i = 60 \cdot \frac{0.75^j}{j!} e^{-0.75}.$$



## Primjer.

Dobivamo tablicu

<b>Broj rekombinacija</b>	0	1	2	3	Ukupno
<b>Opažena frekvencija</b>	32	15	9	4	60
<b>Teorijska frekvencija</b>	28.34	21.26	7.97	1.99	59.56

## Primjer.

Dobivamo tablicu

<b>Broj rekombinacija</b>	0	1	2	3	Ukupno
<b>Opažena frekvencija</b>	32	15	9	4	60
<b>Teorijska frekvencija</b>	28.34	21.26	7.97	1.99	59.56

Uočimo:

- Teorijska frekvencija za razred 3 je manja od 5 - grupiramo ga s razredom 2.
- Ukupna teorijska frekvencija je  $59.56 < 60$ , što je posljedica toga da Poissonova slučajna varijabla može poprimiti i vrijednosti  $\geq 4$ .

## Primjer.

Dobivamo tablicu

<b>Broj rekombinacija</b>	0	1	2	3	Ukupno
<b>Opažena frekvencija</b>	32	15	9	4	60
<b>Teorijska frekvencija</b>	28.34	21.26	7.97	1.99	59.56

Uočimo:

- Teorijska frekvencija za razred 3 je manja od 5 - grupiramo ga s razredom 2.
- Ukupna teorijska frekvencija je  $59.56 < 60$ , što je posljedica toga da Poissonova slučajna varijabla može poprimiti i vrijednosti  $\geq 4$ .

→ grupiramo zadnja dva razreda i preimenujemo ga u razred  $\geq 2$  te njegovu teorijsku frekvenciju odredimo kao

$$E_2 = 60 \cdot \mathbf{P}(Y \geq 2) = 60 - E_0 - E_1.$$

Dobivamo tablicu frekvencija

<b>Broj rekombinacija</b>	0	1	$\geq 2$	Ukupno
<b>Opažena frekvencija</b>	32	15	13	60
<b>Teorijska frekvencija</b>	28.34	21.26	10.4	60

## Primjer.

Ne možemo kao u prošlom primjeru koristiti istu Excel naredbu za dobivanje  $p$ -vrijednosti, obzirom da imamo **jedan procijenjeni parametar**.

Stoga ćemo sami odrediti vrijednost  $Hi^2$  testne statistike,  $Hi^2 = 2.94$ , te pomoću nje  $p$ -vrijednost pozivanjem funkcije

$$p = \text{CHISQ.DIST.RT}(2.94, 3-1-1) = 0.086410733.$$

Kako je  $p \geq 0.05$  ne odbacujemo pretpostavku da broj rekombinacija slijedi Poissonovu distribuciju.

## Ostali $\chi^2$ -testovi

Dva često korištena  $\chi^2$  testa su test **nezavisnosti** i test **homogenosti** dvaju obilježja  $X$  i  $Y$ . Provođenje ova dva testa je veoma slično, ali interpretacija je drukčija:

- test nezavisnosti - nulta hipoteza je da su obilježja  $X$  i  $Y$  **nezavisna**;
- test homogenosti - nulta hipoteza je da su obilježja  $X$  i  $Y$  (ili isto obilježje promatrano u dvije populacije) **jednako distribuirana**;

## 6. Korelacija i linearna regresija

## Korelacija slučajnih varijabli

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

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

## Korelacija slučajnih varijabli

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

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

Kovarianca mjeri zajedničku varijaciju varijabli  $X$  i  $Y$  (izražena je u mjernim jedinicama slučajnih varijabli  $X$  i  $Y$ ).



## Korelacija slučajnih varijabli

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

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

Kovarianca mjeri zajedničku varijaciju varijabli  $X$  i  $Y$  (izražena je u mjernim jedinicama slučajnih varijabli  $X$  i  $Y$ ).

S druge strane, **korelacija**:

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

nema mjernu jedinicu i poprima vrijednosti iz skupa  $[-1, 1]$ .

## Korelacija slučajnih varijabli

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

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

Kovarijanca mjeri zajedničku varijaciju varijabli  $X$  i  $Y$  (izražena je u mjernim jedinicama slučajnih varijabli  $X$  i  $Y$ ).

S druge strane, **korelacija**:

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

nema mjernu jedinicu i poprima vrijednosti iz skupa  $[-1, 1]$ .

Može se pokazati da ako su  $X$  i  $Y$  **nezavisne** slučajne varijable, tada je

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

pa je

$$\text{Cov}(X, Y) = 0 \text{ i } \text{Corr}(X, Y) = 0.$$

## Korelacija i linearna povezanost

Za **linearno povezane** slučajne varijable  $X$  i  $Y$ :

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

vrijedi

$$\text{Var}(Y) = a^2 \text{Var}(X), \quad \text{tj.} \quad \sigma_Y = |a| \sigma_X \implies \text{Corr}(X, Y) = \begin{cases} 1, & a > 0 \\ -1, & a < 0 \end{cases}.$$

## Korelacija i linearna povezanost

Za **linearno povezane** slučajne varijable  $X$  i  $Y$ :

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

vrijedi


$$\text{Var}(Y) = a^2 \text{Var}(X), \quad \text{tj.} \quad \sigma_Y = |a| \sigma_X \implies \text{Corr}(X, Y) = \begin{cases} 1, & a > 0 \\ -1, & a < 0 \end{cases}.$$

Bitna svojstva:

- Slučajne varijable  $X$  i  $Y$  **nezavisne**  $\rightarrow \text{Corr}(X, Y) = 0$ .
- Slučajne varijable  $X$  i  $Y$  **linearno povezane**  $\rightarrow \text{Corr}(X, Y) = \pm 1$ .
- Uočimo, ako su  $X$  i  $Y$  linearno povezane onda su i zavisne.
- Može se pokazati da  $\text{Corr}(X, Y) = \pm 1 \rightarrow X$  i  $Y$  su linearno povezane.
- Uočimo da  $\text{Corr}(X, Y) = 0$  ne znači da su  $X$  i  $Y$  nezavisne slučajne varijable.

## Dijagram raspršenosti

Za varijable  $X$  i  $Y$  promatramo  $(X, Y)$ -graf: *scatterplot*, graf raspršenosti.



Razmislite koji graf odgovara uzorcima za obilježja  $(X, Y)$  koja imaju korelaciju:

a)  $\rho = 0$ ; b)  $\rho = 0.46$ ; c)  $\rho = 0.98$ ; d)  $\rho = -0.82$ .



## Linearna povezanost i transformacije

Koleracija mjeri **linearnu** povezanost dvije varijable. Što ako su varijable povezane, ali ne linearno?

## Linearna povezanost i transformacije

Korelacija mjeri **linearnu** povezanost dvije varijable. Što ako su varijable povezane, ali ne linearno?

Promotrimo dva primjera nelinearne povezanosti:



Možete li naslutiti tip povezanosti? Kako povezanost nije linearna, u oba slučaja korelacija može biti malena.

## Procjena Pearsonova koeficijenta korelacije

Korelaciju slučajnih varijabli (obilježja)  $X$  i  $Y$  (često nazivanu još Pearsonovim koeficijentom korelacije za populaciju) možemo procijeniti temeljem uzorka za ta dva statistička obilježja. Uzorak duljine  $n$  dan je mjerenjima

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n),$$

gdje je  $(x_i, y_i)$  izmjerena vrijednost obilježja  $X$  i  $Y$  na  $i$ -toj jedinki uzorka.



## Procjena Pearsonova koeficijenta korelacije

Korelaciju slučajnih varijabli (obilježja)  $X$  i  $Y$  (često nazivanu još Pearsonovim koeficijentom korelacije za populaciju) možemo procijeniti temeljem uzorka za ta dva statistička obilježja. Uzorak duljine  $n$  dan je mjerenjima

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n),$$

gdje je  $(x_i, y_i)$  izmjerena vrijednost obilježja  $X$  i  $Y$  na  $i$ -toj jedinki uzorka.

**Pearsonov koeficijent korelacije** uzorka dan je s:

$$r = \frac{\frac{1}{n} \sum_i (x_i - \bar{x})(y_i - \bar{y})}{s_X \cdot s_Y},$$

gdje su  $\bar{x}$ ,  $\bar{y}$  aritmetičke sredine uzoraka, a  $s_X$ ,  $s_Y$  standardne devijacije uzoraka.

U Excelu koristimo naredbu:

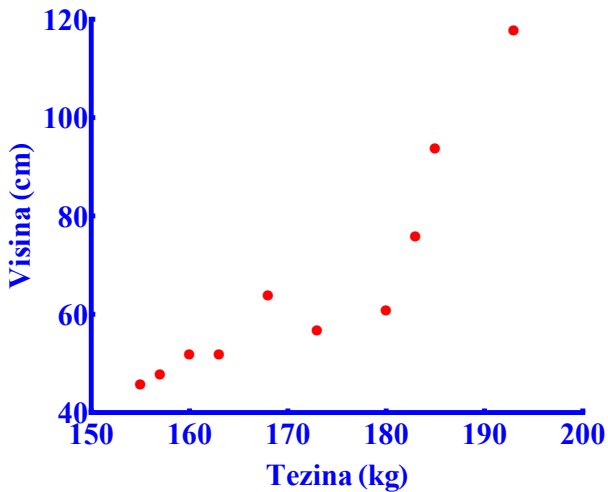
$$=CORREL(X1:Xn;Y1:Yn)$$

## Primjer.

Na osnovu uzorka od 10 osoba procijenite koeficijent korelacije 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:



$$r = 0.89$$

## Pearsonov koeficijent korelacije - svojstva i interpretacija

:

- broj iz intervala  $[-1, 1]$
- iskazuje smjer i jakost linearne statističke veze između dva obilježja
- $r$  bliži  $-1$  ili  $1$   $\rightarrow$  jača korelacija
- $r = 1$  ili  $r = -1$   $\rightarrow$  potpuna povezanost, linearna 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

### Interpretacija primjera:

Vratimo se na primjer s visinama i težinama:

- 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.

## 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).

## 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).

Koristimo statistiku

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

koja je uz  $H_0$  distribuirana prema Studentovoj razdiobi:  $t \sim t(n-2)$ .

Kritično područje na razini značajnosti  $\alpha$  je analogno kao i kod  $t$ -testa, a ovisi o alternativnoj hipotezi (lijeva/desna jednostrana, dvostrana).

Malo kasnije ćemo vidjeti provođenje testa korelacije u Excelu (uočite da je hipoteza  $H_0: \rho = 0$  ekvivalentna hipotezi  $H_0: a = 0$ ).

## Jednostavna linearna regresija

Jednom kada naslutimo koreliranost dvaju varijabli (obilježja), prirodno se postavlja pitanje kako izgleda linearna povezanost tih varijabli, odnosno procjene parametara  $a$  i  $b$  iz linearne veze:

$$Y = aX + b,$$



## Jednostavna linearna regresija

Jednom kada naslutimo koreliranost dvaju varijabli (obilježja), prirodno se postavlja pitanje kako izgleda linearna povezanost tih varijabli, odnosno procjene parametara  $a$  i  $b$  iz linearne veze:

$$Y = aX + b,$$

gdje je

- $a$  - koeficijent smjera (*slope*)
- $b$  - slobodni koeficijent (*intercept*)

## Jednostavna linearna regresija

Jednom kada naslutimo koreliranost dvaju varijabli (obilježja), prirodno se postavlja pitanje kako izgleda linearna povezanost tih varijabli, odnosno procjene parametara  $a$  i  $b$  iz linearne veze:

$$Y = aX + b,$$

gdje je

- $a$  - koeficijent smjera (*slope*)
- $b$  - slobodni koeficijent (*intercept*)


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 - općenito



- 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 pojednostavljena 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

## Primjer: podaci za visinu i težinu:



Kako odrediti pravac koji najbolje opisuje podatke?

# Metoda najmanjih kvadrata



Za svaki pravac  $y = ax + b$  i svaku točku uzorka pogledamo kolika je razlika  $y_i - (ax_i + b)$ . Tražimo  $a$  i  $b$  za koje je suma kvadrata tih razlika po svim točkama uzorka najmanja:

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

## Regresijski pravac

Pravac koji minimizira srednje kvadratno odstupanje naziva se **regresijski pravac**, a koeficijenti regresijskog pravca nazivaju se **regresijski koeficijenti**.

## Regresijski pravac

Pravac koji minimizira srednje kvadratno odstupanje naziva se **regresijski pravac**, a koeficijenti regresijskog pravca nazivaju se **regresijski koeficijenti**.

Eksplisitni izraz za regresijske koeficijente:

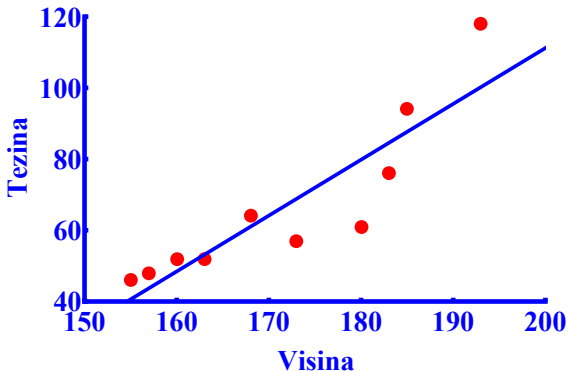
$$\begin{aligned} a &= \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} = \\ &= \frac{\text{Cov}(X, Y)}{S_X^2} = \\ &= r_{X,Y} \frac{S_Y}{S_X} \\ b &= \bar{Y} - a \cdot \bar{X} \end{aligned}$$

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

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

Pokazat ćemo da je regresijski pravac za visine i težine jednak:

$$\text{Težina} = 1.5685 \cdot \text{Visina} - 202.519$$





## Linearna regresija u Excelu

U sklopu *Data Analysis* paketa koristimo proceduru *Correlation* koja vraća sljedeći skup analiza:

SUMMARY OUTPUT						
<i>Regression Statistics</i>						
Multiple R	0,890660908					
R Square	0,793276853					
Adjusted R Square	0,767436459					
Standard Error	11,1458636					
Observations	10					
<i>ANOVA</i>						
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>	
Regression	1	3813,757796	3813,758	30,6991	0,000546925	
Residual	8	993,8422037	124,2303			
Total	9	4807,6				
	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>
Intercept	-202,5189988	48,73521949	-4,1555	0,003185	-314,9026164	-90,13538111
Visina	1,568543965	0,283096087	5,540677	0,000547	0,915723218	2,221364711

## Regresijske statistike - analiza

<i>Regression Statistics</i>	
Multiple R	0,890660908
R Square	0,793276853
Adjusted R Square	0,767436459
Standard Error	11,1458636
Observations	10

Koliko dobro regresijski pravac opisuje podatke?

- *Multiple R* - kod linearne regresije to je upravo koeficijent korelacije.
- *R Squared* - **koeficijent determinacije** - kvadrat od *Multiple R* - mjeri koliki udio u ukupnoj varijabilnosti varijable  $y$ , možemo objasniti linearnom regresijom.
- *Adjusted R Squared* - *R Squared* prilagođen za broj procijenjenih parametara u modelu (kod jednostavne linearne regresije to su 2 procijenjena parametra)

## Testiranje hipoteza o koeficijentima

Uz određene pretpostavke na greške modela (razlike između stvarne vrijednosti  $y_i$  i procijenjene vrijednosti na pravcu), tzv. Gauss-Markovljeve uvjete, moguće je reći nešto više o samim koeficijentima modela.

## Testiranje hipoteza o koeficijentima

Uz određene pretpostavke na greške modela (razlike između stvarne vrijednosti  $y_i$  i procijenjene vrijednosti na pravcu), tzv. Gauss-Markovljeve uvjete, moguće je reći nešto više o samim koeficijentima modela.

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>
Intercept	-202,5189988	48,73521949	-4,1555	0,003185	-314,9026164	-90,13538111
Visina	1,568543965	0,283096087	5,540677	0,000547	0,915723218	2,221364711

## Testiranje hipoteza o koeficijentima

Uz određene pretpostavke na greške modela (razlike između stvarne vrijednosti  $y_i$  i procijenjene vrijednosti na pravcu), tzv. Gauss-Markovljeve uvjete, moguće je reći nešto više o samim koeficijentima modela.

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>
Intercept	-202,5189988	48,73521949	-4,1555	0,003185	-314,9026164	-90,13538111
Visina	1,568543965	0,283096087	5,540677	0,000547	0,915723218	2,221364711

- *Intercept* se odnosi na koeficijent  $b$ , *Tezina* se odnosi na koeficijent  $a$  (nalazi se uz varijablu  $X$ =težina).
- stupac *Coefficients* su procijenjene vrijednosti parametara.
- stupci *t-test* i *p-value* daju vrijednost testne statistike i *p*-vrijednost u testovima **značajnosti koeficijenata**. To su testovi koji za nultu hipotezu uzimaju  $b = 0$ , odnosno  $a = 0$ .
- stupci *t-test* i *p-value* daju vrijednost testne statistike i *p*-vrijednost u testovima **značajnosti koeficijenata**. To su testovi koji za nultu hipotezu uzimaju  $b = 0$ , odnosno  $a = 0$ .
- stupci *Lower 95%* i *Upper 95%* daju donji i gornji rub 95% pouzdanog intervala za vrijednosti koeficijenata.

## Značajnost modela

ANOVA					
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	1	3813,757796	3813,758	30,6991	0,000546925
Residual	8	993,8422037	124,2303		
Total	9	4807,6			

## Značajnost modela

ANOVA					
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	1	3813,757796	3813,758	30,6991	0,000546925
Residual	8	993,8422037	124,2303		
Total	9	4807,6			

Promatramo nultu hipotezu da nezavisne varijable (u našem slučaju  $X = \text{Visina}$ ) nisu korelirane sa zavisnom (u našem slučaju  $Y = \text{Težina}$ ), odnosno da promatrani model opisuje  $Y$  jednako dobro kao model sa samo slobodnim koeficijentom ( $Y = \textit{konst.}$ ).

- $F$  je vrijdnost testne statistike testa značajnosti modela;
- *Significance F* je  $p$ -vrijdnost testa značajnosti modela.