

# Osnove statistike u demografiji

Predavanje 10

# Analiza odnosa varijabli

- Univariatna analiza: jedna varijabla (obilježje)
  - Mjere deskriptivne statističke analize
    - Mjere centralne tendencije
    - Mjere disperzije
    - Mjere asimetrije
  - Metode inferencijalne statistike:
    - Testiranje hipoteza i procjena parametara jedne populacije
    - Usporedba parametara **iste** varijable za različite populacije (grupe)
- Jedna varijabla: prosječna dob (jedne populacija ili usporedba više populacija)
- Pored univariatne analize u demografskim istraživanjima se često analizira i odnos varijabli

# Analiza odnosa varijabli

- Odnos varijabli:
  - Plaća i dob
  - Plaća i spol
- Odnos dvije varijable: bivarijatna analiza
- Odnos više od dvije varijable: multivarijatna analiza
- Metode analize ovise o metričkim svojstvima varijabli
- Numeričke varijable

# Analiza odnosa varijabli

- Najzastupljenije metode u analizi statističke povezanosti varijabli su:
  - koreacijska i
  - regresijska analiza.
- Obje metode analiziraju linearu povezanost varijabli.
- Pritom, u koreacijskoj se analizi utvrđuje smjer i jakost povezanosti dviju slučajnih varijabli  $x$  i  $y$  koje se tretiraju simetrično.
- S druge strane, u regresijskoj analizi se prepostavlja odnos između varijabli, tj. varijable se dijele na zavisnu (varijabla  $y$ ) i nezavisnu varijablu (varijabla  $x$ ).

# Koreacijska analiza

- Prepostavka o linearnoj povezanosti pojava česta je u empirijskim istraživanjima.
- Linearu povezanost dviju pojava moguće je analizirati:
  1. izračunavanjem odgovarajuće mjere povezanosti ili
  2. grafičkim putem (dijagramom rasipanja).
- Najčešće korišteni pokazatelji statističke povezanosti među pojavama su:
  - Pearsonov koeficijent korelaciije, kojim se analizira linearna povezanost dviju numeričkih varijabli, te
  - Spearmanov i Kendallov koeficijent korelaciije ranga kojima se analizira stupanj povezanosti rangova dviju varijabli

# Dijagram rasipanja

- Dijagram rasipanja (engl. *scatter plot*) je grafički prikaz točaka u pravokutnom koordinatnom sustavu na temelju kojeg se analizira povezanost dviju varijabli
- Točke (parovi vrijednosti varijabli  $x$  i  $y$ ) se crtaju u pravokutnom koordinatnom sustavu s aritmetičkim mjerilom za vrijednosti  $x_i$  na osi apscisa i aritmetičkim mjerilom za vrijednosti  $y_i$  na osi ordinata
- Aritmetička mjerila ne moraju imati nulu kao početnu vrijednost
- Analizom oblika “raspršenosti” točaka utvrđuje se oblik, smjer i intenzitet povezanosti dviju pojava

# Pearsonov koeficijent korelaciјe

- Najčešće korištena mjera jakosti i smjera linearne statističke povezanosti dviju varijabli.
- Računa se kao omjer kovarijance dviju varijabli i umnoška njihovih standardnih devijacija.
- Kovarijanca je mjera zajedničke varijabilnosti među varijablama  $x$  i  $y$  
$$\text{Cov}(x, y) = E[(x - E(x))(y - E(y))] = E[xy] - E(x)E(y)$$
- Kovarijanca je absolutna mjera povezanosti čije vrijednosti ovise o mjernim jedinicama promatranih varijabli (pojava).
  - Ako ne postoji linearna povezanost varijabli, kovarijanca je jednaka nuli.
  - Ako se (u prosjeku) povećanjem vrijednosti  $x_i$  povećavaju i vrijednosti  $y_i$ , kovarijanca je pozitivna.
  - Povezanost velikih vrijednosti  $x_i$  s malim vrijednostima  $y_i$ , rezultirat će negativnom vrijednošću kovarijance

# Pearsonov koeficijent korelaciјe

- Procjena kovarijance varijabli  $x$  i  $y$  na temelju uzorka parova vrijednosti varijabli, definira se kao prvi mješoviti moment
- Standardizirana mjeri jakosti i smjera linearne statističke povezanosti dviju varijabli je Pearsonov koeficijent korelaciјe
- Koeficijent linearne korelaciјe poprima vrijednosti iz intervala  $[-1, 1]$
-

# Regresijska analiza

- Regresijska analiza je najčešće korištena metoda u empirijskim istraživanjima.
- Njome se želi kvantificirati odnos dviju (ili više) pojava.
- Osnova regresijske analize je regresijski model.
- Regresijski model je hipotetički model (formula) kojim se izražava statistička (stohastička) povezanost između pojava.
- Na temelju uzorka vrijednosti odabralih varijabli procjenjuju se parametri pretpostavljenog modela i testiraju pretpostavke kako bi se odredila adekvatnost procijenjenog modela.
- Ako je procijenjeni model adekvatan, koristi se za testiranje ekonomske teorije i u prognostičke svrhe.

# Regresijska analiza

- Model jednostavne linearne regresije prepostavlja linearnu povezanost između zavisne varijable  $y$  i jedne eksplanatorne (nezavisne) varijable  $x$ .
- Model višestruke regresije: varijacije zavisne varijable opisuju se većim brojem eksplanatornih (nezavisnih) varijabli

# Model jednostavne linearne regresije

$$y = \beta_0 + \beta_1 x + \varepsilon$$

- $\beta_0$  i  $\beta_1$  regresijski parametri (parametri populacije) koji se procjenjuju na osnovi opažanja (mjerenja) varijabli
- Varijabla  $\varepsilon$  naziva se greška relacije i komponenta je koja modelu daje statistički (stohastički) karakter.
  - Slučajna varijabla s nepoznatom funkcijom gustoće vjerojatnosti.
  - Nemjerljiva i uključuje sve "ostale" faktore (osim varijable  $x$ ) koji utječu na zavisnu varijablu  $y$ .
- Uključivanje varijable  $\varepsilon$  u model posljedica:
  - utjecaja varijabli koje nisu uključene u model,
  - utjecaja pogrešaka pri mjerenu vrijednosti zavisne varijable,
  - nepredvidivih ekonomskih ili prirodnih utjecaja na zavisnu varijablu kao što je npr. donošenje novih mjera ekonomske politike, prirodne katastrofe i slično.

$$y = \beta_0 + \beta_1 x + \varepsilon$$

- Najjednostavniji oblik modela u kojem se pretpostavlja aditivnost determinističke i slučajne komponente
- Linearan regresijski model
- Linearnost modela u pravilu se odnosi na način na koji se parametri i varijable pojavljuju u modelu
- U statističkim analizama, pojam linearan regresijski model podrazumijeva linearost u parametrima (parametri se ne potenciraju)

# Polazne pretpostavke u analizi modela jednostavne linearne regresije

1. Model populacije (osnovnog skupa) je linearan.
- Cilj regresijske analize je da se na temelju  $n$  opažanja varijabli procijene nepoznati regresijski parametri (parametri populacije). U tu svrhu potrebno je uvesti teorijske pretpostavke o greškama relacije (slučajnoj varijabli)  $\varepsilon$

# Procjene parametara u modelu jednostavne linearne regresije

- Uz pretpostavku da se povezanost varijabli opisuje linearnom funkcijom, tj. da je model populacije

$$y = \beta_0 + \beta_1 x + \varepsilon,$$

- zadatak regresijske analize je da se pronađu procjene nepoznatih parametara (parametara populacije)  $\beta_0$  i  $\beta_1$ , te procjena nepoznate varijance  $\sigma^2$  slučajnih varijabli  $\varepsilon_i$
- U tu svrhu potrebno je odabrati slučajni uzorak od  $n$  parova vrijednosti varijabli.  
$$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + \hat{\varepsilon}_i, \quad i = 1, 2, \dots, n.$$
- Procijenjen model na temelju uzorka je

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i, \quad i = 1, 2, \dots, n,$$

$$y_i = \hat{y}_i + \hat{\varepsilon}_i, \quad i = 1, 2, \dots, n.$$

-

# Procjene parametara u modelu jednostavne linearne regresije

- Razlika između stvarne vrijednosti zavisne varijable i njene procijenjene vrijednosti,

$$\hat{\varepsilon}_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i), \quad i = 1, 2, \dots, n,$$

- je rezidualno odstupanje i procjena je vrijednosti varijable  $\varepsilon_i$

# Metoda najmanjih kvadrata

- Odabire one procjene parametara za koje će zbroj kvadrata rezidualnih odstupanja biti najmanji.

$$\sum_{i=1}^n \hat{\varepsilon}_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i))^2 \rightarrow \text{minimum.}$$

$$\sum_{i=1}^n \hat{\varepsilon}_i^2 \rightarrow \text{minimum.}$$

- dobiva se sustav normalnih jednadžbi čijim se rješavanjem dolazi do izraza za izračunavanje regresijskih koeficijenata (procjena nepoznatih parametara) koristeći empirijske vrijednosti iz uzorka

# Procijenjeni model (model uzorka)

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x.$$

- $\hat{\beta}_1$  Regresijski koeficijent
- $\hat{\beta}_0$  Konstantni član
- Ako su ispunjene polazne pretpostavke o modelu jednostavne linearne regresije, procjenitelji imaju dobra statistička svojstva:
  - nepristrani su i
  - imaju najmanju varijancu u klasi svih linearnih procjenitelja (efikasni su).
- Za navedena svojstva procjenitelja pretpostavka o normalnoj distribuiranosti grešaka relacije nije nužna.
- Ta je pretpostavka nužna u kasnijim koracima analize kako bi se odredile intervalne procjene parametara i testirale hipoteze.

# Definicija modela i procjene parametara

- Prepostavlja se da je zavisna varijabla  $y$  linearna funkcija k nezavisnih varijabli, odnosno da je model populacije
$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_k x_k + \varepsilon$$
- Slučajna varijabla  $\varepsilon$  je greška relacije koja nije mjerljiva i njenim uključivanjem u model u obliku aditivnog člana, model postaje stohastički (statistički).
- Ako se jednadžba procjenjuje na osnovi  $n$  opažanja (mjerena) varijabli, jednadžba se može zapisati kao sustav od  $n$  jednadžbi

# Prepostavke

odnosno, za svako  $i$ ,  $i = 1, 2, \dots, n$  vrijedi da je

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_j x_{ij} + \cdots + \beta_k x_{ik} + \varepsilon_i$$

- Prepostavke modela višestruke linearne regresije su jednake prepostavkama za model jednostavne linearne regresije uz dodatnu prepostavku da su regresorske varijable nekorelirane, tj. da nisu linearno povezane.
- 1. Veza između zavisne varijable i odabranog skupa nezavisnih varijabli je linearna (u parametrima)

# Definicija modela i procjene parametara

- Parametri regresijskog modela procjenjuju se metodom najmanjih kvadrata.
- U tu svrhu potrebno je odabratи slučajni uzorak
- U procjeni se polazi od osnovnog modela (modela populacije)

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_j x_{ij} + \cdots + \beta_k x_{ik} + \varepsilon_i, \quad \text{za svaki } i = 1, 2, \dots, n,$$

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \cdots + \hat{\beta}_j x_{ij} + \cdots + \hat{\beta}_k x_{ik}, \quad i = 1, 2, \dots, n$$

$$y_i = \hat{y}_i + \hat{\varepsilon}_i \quad i = 1, 2, \dots, n.$$

- Razlika između stvarne vrijednosti zavisne varijable i njene procijenjene vrijednosti je rezidualno odstupanje

$$\hat{\varepsilon}_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \cdots + \hat{\beta}_j x_{ij} + \cdots + \hat{\beta}_k x_{ik}), \quad i = 1, 2, \dots, n,$$

# Metoda najmanjih kvadrata

- Odabire procjene parametara za koje će zbroj kvadrata rezidualnih odstupanja biti najmanji

$$\sum_{i=1}^n \hat{\epsilon}_i^2 \rightarrow \text{minimum},$$

$$\sum_{i=1}^n \hat{\epsilon}_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n \left( y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \cdots + \hat{\beta}_j x_{ij} + \cdots + \hat{\beta}_k x_{ik}) \right)^2 \rightarrow \text{minimum}.$$

- Minimiziranjem rezidualnog zbroja kvadrata, iz nužnog uvjeta za minimum dobiva se sustav  $(k + 1)$  normalnih jednadžbi nepoznatih parametara

# Primjer

- Analizira se odnos broja stanovnika (u milijunima, oznaka pop) Danske u odnosu na skup odabranih nezavisnih varijabli u razdoblju od 1990 do 2017 godine (izvor: EUROSTAT)
- Odabране nezavisne varijable su:
  - Broj iseljenika (em) u tis.
  - Broj useljenika (im) u tis.
  - Pokazatelj fertiliteta (fert)
  - Prosječna dob majki pri porodu (dob)
  - Broj sklopljenih brakova (brak) u tis.
  - Broj razvedenih brakova (raz) u tis.
  - Bruto domaći proizvod (bdp) u mIrd EUR

## SUMMARY OUTPUT

## Regression Statistics

Multiple R	0,996383
R Square	0,992778
Adjusted R Square	0,990251
Standard Error	0,017551
Observations	28

## ANOVA

	df	SS	MS	F	Significance F
Regression	7	0,846896	0,120985	392,7823	5,38E-20
Residual	20	0,00616	0,000308		
Total	27	0,853057			

	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%	Lower 95,0%	Upper 95,0%
Intercept	4,168317	0,971706	4,289691	0,000357	2,141374	6,19526	2,141374	6,19526
em	0,004531	0,001389	3,263417	0,003889	0,001635	0,007428	0,001635	0,007428
im	0,000753	0,00059	1,276592	0,216371	-0,00048	0,001983	-0,00048	0,001983
fert	-0,03183	0,103469	-0,3076	0,761564	-0,24766	0,184006	-0,24766	0,184006
dob	0,03085	0,035853	0,860458	0,399735	-0,04394	0,105638	-0,04394	0,105638
brak	-0,00764	0,001841	-4,15181	0,000493	-0,01149	-0,0038	-0,01149	-0,0038
raz	-0,00168	0,003681	-0,45714	0,652497	-0,00936	0,005995	-0,00936	0,005995
bdp	0,002102	0,000543	3,869618	0,000954	0,000969	0,003235	0,000969	0,003235

# Interpretacija parametara regresijskog modela

- Procijenjeni model (model uzorka)

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \cdots + \hat{\beta}_j x_j + \cdots + \hat{\beta}_k x_k.$$

- $\hat{\beta}_0$  konstantni član.

- Označava procijenjenu (prosječnu) vrijednost zavisne varijable ako su vrijednosti svih regresorskih varijabli jednake nuli.
- Premda konstantni član najčešće nema suvislu interpretaciju, on se uvijek uključuje u model
- Izuzetak je analiza modela na temelju transformiranih vrijednosti varijabli (standardiziranje, prve diferencije, logaritamske transformacije) ili ako se to eksplicitno prepostavlja na temelju ekonomske teorije

# Interpretacija procjena parametara regresijskog modela

- Uključivanje konstante osigurava da je prosječna vrijednost reziduala jednaka nuli što je nužan uvjet metode najmanjih kvadrata.
- Nadalje, uloga konstantnog člana u modelu povezana je i s jednadžbom regresijskog pravca.
- Naime, kada bi regresijski pravac bio definiran bez konstantnog člana, geometrijski bi to značilo da pravac prolazi ishodištem

# Interpretacija parametara regresijskog modela

- Procijenjeni model (model uzorka)

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \cdots + \hat{\beta}_j x_j + \cdots + \hat{\beta}_k x_k.$$

$$\hat{\beta}_j = \frac{\partial \hat{y}}{\partial x_j}$$

- $\hat{\beta}_1$  regresijski koeficijent .

- procjena regresijskog parametra uz  $j$ -tu regresorsku varijablu
- vrijednost parcijalnog utjecaja varijable  $x_j$  na  $\hat{y}$
- promjena prosječne (regresijske) vrijednosti zavisne varijable, za jedinično povećanje vrijednosti varijable  $x_j$ , uz uvjet da su vrijednosti ostalih regresorskih varijabli nepromijenjene

	Coefficients	Standard Error	t Stat	P-value
Intercept	4,168317	0,971706	4,289691	0,000357
em	0,004531	0,001389	3,263417	0,003889
im	0,000753	0,00059	1,276592	0,216371
fert	-0,03183	0,103469	-0,3076	0,761564
dob	0,03085	0,035853	0,860458	0,399735
brak	-0,00764	0,001841	-4,15181	0,000493
raz	-0,00168	0,003681	-0,45714	0,652497
bdp	0,002102	0,000543	3,869618	0,000954

$$\widehat{pop} = 4,17 + 0,004 \cdot em + 0,0007 \cdot im - 0,03 \cdot fert + 0,03 \cdot dob - 0,0076 \cdot brak - 0,0017 \cdot raz + 0,002 \cdot bdp$$

# Standardne pogreške procjena parametara u modelu višestruke linearne regresije

- Kako bi se odredila preciznost procjena regresijskih parametara, potrebno je definirati mjeru preciznosti procjene, tj. standardnu pogrešku procjene
- Ako su ispunjene sve pretpostavke o regresijskom modelu sampling-distribucija procjenitelja regresijskog parametra je  $\hat{\beta}_j \sim N(\beta_j, \sigma_{\hat{\beta}_j}^2)$
- Varijanca procjenitelja ovisi o:
  - veličini uzorka  $n$ ,
  - disperzijama (varijancama) nezavisnih varijabli,
  - korelaciji između nezavisnih varijabli i
  - varijanci regresije.
- U slučaju modela s dvjema nezavisnim varijablama

# Standardne pogreške procjena parametara u modelu višestruke linearne regresije

- Ako je varijanca regresije nepoznata, zamjenjuje se (nepristranom) procjenom na bazi uzorka

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n \hat{\varepsilon}_i^2}{n - (k + 1)} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - (k + 1)}$$

- a standardizirana varijabla pridružena procjenitelju

$$\frac{\hat{\beta}_j - \beta_j}{\sigma_{\hat{\beta}_j}} \sim t(n - (k + 1))$$

- Ako je uzorak  $n$  dovoljno velik, tada prema centralnom graničnom teoremu aproksimativno vrijedi

$$\frac{\hat{\beta}_j - \beta_j}{\sigma_{\hat{\beta}_j}} \sim N(0, 1).$$

-

# Intervalne procjene parametara u modelu višestrukog linearne regresije

- Intervalna procjena regresijskog parametra je interval koji uz zadanu pouzdanost uključuje stvarnu vrijednost parametra.
- Granice intervala procjene ovise o obliku sampling-distribucije procjenitelja
- Uz razinu pouzdanosti  $(1-\alpha)$ , intervalna procjena regresijskog parametra je

$$P(\hat{\beta}_j - t_{\alpha/2} \sigma_{\hat{\beta}_j} < \beta_j < \hat{\beta}_j + t_{\alpha/2} \sigma_{\hat{\beta}_j}) = 1 - \alpha$$

- Ako je:
  - uzorak dovoljno velik ili
  - ako je varijanca populacije poznata,
- umjesto koeficijenta pouzdanosti  $t_{\alpha/2}$  uzima se odgovarajući percentil jedinične normalne distribucije  $Z_{\alpha/2}$ .

# Primjer: Intervalne procjene parametara

	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	4,168317	0,971706	4,289691	0,000357	2,141374	6,19526
em	0,004531	0,001389	3,263417	0,003889	0,001635	0,007428
im	0,000753	0,00059	1,276592	0,216371	-0,00048	0,001983
fert	-0,03183	0,103469	-0,3076	0,761564	-0,24766	0,184006
dob	0,03085	0,035853	0,860458	0,399735	-0,04394	0,105638
brakovi	-0,00764	0,001841	-4,15181	0,000493	-0,01149	-0,0038
raz	-0,00168	0,003681	-0,45714	0,652497	-0,00936	0,005995
bdp	0,002102	0,000543	3,869618	0,000954	0,000969	0,003235

$$P(\hat{\beta}_j - t_{\alpha/2} \sigma_{\hat{\beta}_j} < \beta_j < \hat{\beta}_j + t_{\alpha/2} \sigma_{\hat{\beta}_j}) = 1 - \alpha$$

$$P(0,000969 < \beta_7 < 0,003235) = 0,95$$

# Analiza varijance u modelu jednostavne linearne regresije

- Je li procijenjeni regresijski model reprezentativan:
- Koliko dobro varijabla x "objašnjava" zavisnu varijablu y , tj. koliki je dio varijabilnosti variable y objasnjen pretpostavljenom linearnom vezom s varijablom x
- Kako bi se odredilo koliko dobro varijabla x objašnjava varijaciju zavisne varijable y , tj. koliko je procijenjeni regresijski model dobar, polazi se od rastava varijance zavisne varijable procijenjene na bazi uzorka na:
  - dio varijance protumačen modelom i
  - rezidualni dio, tj. dio varijance neprotumačen modelom.

$$(y_i - \bar{y}) = (\hat{y}_i - \bar{y}) + (y_i - \hat{y}_i)$$

# Analiza varijance u modelu višestruke linearne regresije

- U modelu višestruke linearne regresije ukupna varijacija zavisne varijable  $y$  oko prosječne vrijednosti  $\bar{y}$  nastoji se što bolje objasniti skupom nezavisnih varijabli
- U tu svrhu polazi se od rastava varijance zavisne varijable procijenjene na bazi uzorka na dvije komponente:
  - varijacije koje se mogu objasniti linearnom funkcijom nezavisnih varijabli i
  - varijacije koje ostaju neprotumačene
- Osnova analize je jednadžba analize varijance:

$$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{ST} = \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{SP} + \underbrace{\sum_{i=1}^n (y_i - \hat{y}_i)^2}_{SR}.$$

$$ST = SP + SR$$

-

# Tablica analize varijance (ANOVA)

Tablica 12.6. Analiza varijance za model višestruke linearne regresije – tablica ANOVA

Izvor varijacije	Stupnjevi slobode	Zbroj kvadrata	Sredina kvadrata	F - omjer
Protumačen modelom	$k$	$SP$	$\frac{SP}{k}$	$\frac{\frac{SP}{k}}{SR}$
Neprotumačen modelom	$n - (k + 1)$	$SR$	$\frac{SR}{n - (k + 1)}$	$\frac{n - (k + 1)}{SR}$
Ukupno	$n - 1$	$ST$		

- Procjena varijance regresije

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - (k + 1)} = \frac{SR}{n - (k + 1)}$$

- Procjena standardne devijacije regresije

$$\hat{\sigma} = \sqrt{\frac{SR}{n - (k + 1)}}$$

- Pridružena relativna mjera je procjena koeficijenta varijacije regresije

$$\hat{V} = \frac{\hat{\sigma}}{\bar{y}} \cdot 100 \%$$

# Regresijske vrijednosti i rezidualna odstupanja

- Regresijske vrijednosti dobivaju se uvrštavanjem odgovarajućih empirijskih vrijednosti nezavisnih varijabli u procijenjenu regresijsku jednadžbu.
- Regresijske vrijednosti su procjene dobivene na temelju uzorka i razlikuju se od stvarnih vrijednosti zavisne varijable.
- Razlika je rezidualno odstupanje i procjena je greške relacije

$$\hat{\varepsilon}_i = y_i - \hat{y}_i, \quad i = 1, 2, \dots, n$$

- Rezidualna odstupanja izražena u mjernim jedinicama zavisne varijable y (apsolutno rezidualno odstupanje).
- Pripadna relativna rezidualna odstupanja su

$$\hat{\varepsilon}_{i,rel} = \frac{\hat{\varepsilon}_i}{y_i} \cdot 100 \% = \frac{y_i - \hat{y}_i}{y_i} \cdot 100 \%.$$

-

# Procjena varijance i standardne devijacije regresije

- Nepristrana procjena varijance regresije

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n \hat{\epsilon}_i^2}{n - (k + 1)} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - (k + 1)}$$

$$\hat{\sigma} = \sqrt{\frac{\sum_{i=1}^n \hat{\epsilon}_i^2}{n - (k + 1)}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - (k + 1)}}$$

- Procjena standardne devijacije regresije
  - interpretira se kao prosječno odstupanje empirijskih vrijednosti zavisne varijable od regresijskih (procijenjenih) vrijednosti
  - interpretira se kao prosječno odstupanje empirijskih vrijednosti zavisne varijable ( $y_i$ ) od regresijskih (procijenjenih) vrijednosti
- Odgovarajuća relativna mjera disperzije je procjena koeficijenta varijacije regresije

$$\hat{V} = \frac{\hat{\sigma}}{\bar{y}} \cdot 100 \%$$

-

# Koeficijent determinacije $R^2$

$$ST = SP + SR$$

$$R^2 = \frac{SP}{ST} = 1 - \frac{SR}{ST}$$

- Koeficijent determinacije:
- proporcija varijacije varijable y protumačena modelom
- Najčešće korištena mjeru reprezentativnosti regresijskog modela.
- poprima vrijednosti iz intervala  $[0, 1]$
- mogu se koristiti za usporedbu regresijskih modela samo ako su modeli procijenjeni na temelju istog uzorka empirijskih vrijednosti

# Koeficijent determinacije

- Ako je veliki dio varijabilnosti zavisne varijable protumačen modelom,  $SP \approx ST$ , te je  $R^2 \approx 1$ .
- S druge strane, ako je zanemariv dio varijabilnosti zavisne varijable protumačen modelom, tada je  $SP \approx 0$  pa je  $R^2 \approx 0$
- oprez pri interpretaciji!
- Empirijske analize pokazuju da je u analizi vremenskih nizova vrijednost  $R^2$  obično vrlo visoka (0,8 i veća).
- Ako se regresijska analiza provodi na prostornim podatcima vrijednost je obično između 0,4 i 0,6.
- Modeli koji uključuju varijable koje se odnose na pojedine ljudske karakteristike obično imaju vrlo niske vrijednosti (između 0,1 i 0,2).
- Monotonu neopadajuću funkciju broja nezavisnih varijabli  $k$ , te se povećanjem broja regresorskih varijabli u modelu njegova vrijednost povećava

# Korigirani koeficijent determinacije

- Jedan od nedostataka koeficijenta determinacije je da se njegova vrijednost povećava s brojem nezavisnih varijabli u modelu, bez obzira na proporciju varijacija zavisne variable koje objašnjavaju.
- Budući da je osnovna ideja regresijske analize parsimonija, odnosno da se uz što manje nezavisnih varijabli objasni što više varijacija zavisne varijable  $y$ , promatra se korigirani koeficijent determinacije

$$\bar{R}^2 = 1 - \frac{n-1}{n-(k+1)}(1-R^2), \quad \bar{R}^2 \leq R^2$$

- “Kažnjava” uključivanje u model regresorskih varijabli koje zanemarivo (ili nedovoljno) smanjuju rezidualni zbroj kvadrata

# Primjer: ANOVA

- Analizirajte tablicu analize varijance (ANOVA)

## SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,996383
R Square	0,992778
Adjusted R Square	0,990251
Standard Error	0,017551
Observations	28

## ANOVA

	df	SS	MS	F	Significance F
Regression	7	0,846896	0,120985	392,7823	5,38E-20
Residual	20	0,00616	0,000308		
Total	27	0,853057			

ANOVA					
	df	SS	MS	F	Significanc e F
Regression	7	0,846896	0,120985	392,7823	5,38E-20
Residual	20	0,00616	0,000308		
Total	27	0,853057			

$$k = 7$$

$$n - (k + 1) = 28 - 8 = 20$$

$$\frac{SP}{k} = \frac{0,846896}{7} = 0,120985$$

$$\frac{SR}{n-(k+1)} = \frac{0,00616}{20} = 0,000308$$

$$ST = SP + SR$$

$$0,853057 = 0,846896 + 0,00616$$

$$F = \frac{\frac{SP}{k}}{\frac{SR}{n-(k+1)}} = \frac{\frac{0,846896}{7}}{\frac{0,00616}{20}} = \frac{0,120985}{0,000308} = 392,7823$$

# Primjer: pokazatelji reprezentativnosti

- Analizirajte pokazatelje reprezentativnosti modela

## SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,996383
R Square	0,992778
Adjusted R Square	0,990251
Standard Error	0,017551
Observations	28

$$R^2 = \frac{SP}{ST} = \frac{0,846896}{0,853057} = 0,992778$$

## ANOVA

	df	SS	MS	F	Significance F
Regression	7	0,846896	0,120985	392,7823	5,38E-20
Residual	20	0,00616	0,000308		
Total	27	0,853057			

# Testiranje hipoteza u modelu višestruke linearne regresije

1. test značajnosti (jedne) regresorske varijable (pojedinačni t -test)
  2. test značajnosti regresije (skupni test značajnosti svih regresorskih varijabli, F -test)
  3. test značajnosti podskupa regresorskih varijabli (parcijalni F -test).
- Postupak testiranja bazira se na obliku sampling-distribucije standardiziranog procjenitelja
  - Za danu razinu značajnosti  $\alpha$ , testna veličina se uspoređuje s teorijskom (kritičnom) vrijednosti odgovarajuće sampling-distribucije.
  - U postupku testiranja polazi se od modela (populacije),
$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_k x_k + \varepsilon,$$
  - i procijenjenog modela na bazi uzorka
$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \cdots + \hat{\beta}_j x_j + \cdots + \hat{\beta}_k x_k.$$

# *t* -test značajnosti regresorske varijable

- Ako su ispunjene polazne pretpostavke o modelu i ako je  $H_0$  istinita, testna veličina

$$t_j = \frac{\hat{\beta}_j}{\sigma_{\hat{\beta}_j}} \sim t(n - (k + 1))$$

# *p*-vrijednost ili empirijska razina značajnosti

- Odluka o ishodu testa može se donijeti i usporedbom empirijske i teorijske razine značajnosti.
- *p*-vrijednost je vjerojatnost da test veličina koja, uz pretpostavku da je  $H_0$  istinita, ima  $t$  -distribuciju s  $df = n - 2$  stupnjeva slobode, poprimi vrijednost jednaku ili veću od absolutne vrijednosti testne veličine izračunane na osnovi podataka iz uzorka       $p\text{-vrijednost} < \alpha \implies H_1$

# Primjer: Pojedinačni testovi

- Hipoteze jednosmjernih testova?
- Za pojedine varijable, naznačite pripadne p-vrijednosti jednosmjernih testova
- Na razini značajnosti 5%, koje varijable su statistički značajne?

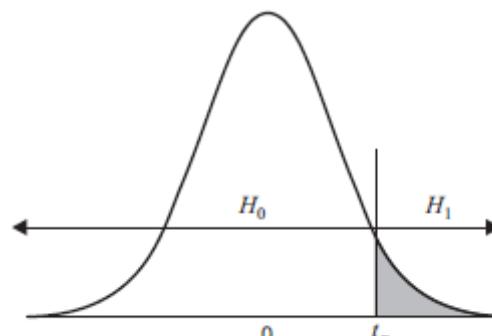
	Coefficients	Standard Error	t Stat	P-value
Intercept	4,168317	0,971706	4,289691	0,000357
em	0,004531	0,001389	3,263417	0,003889
im	0,000753	0,00059	1,276592	0,216371
fert	-0,03183	0,103469	-0,3076	0,761564
dob	0,03085	0,035853	0,860458	0,399735
brak	-0,00764	0,001841	-4,15181	0,000493
raz	-0,00168	0,003681	-0,45714	0,652497
bdp	0,002102	0,000543	3,869618	0,000954

$$\widehat{pop} = 4,17 + 0,004 \cdot em + 0,0007 \cdot im - 0,03 \cdot fert + 0,03 \cdot dob - 0,0076 \cdot brak - 0,0017 \cdot raz + 0,002 \cdot bdp$$

$$H_0: \beta_7 = 0$$

$$H_1: \beta_7 > 0$$

$$p\text{-vrijednost} = \frac{0,000954}{2} = 0,000477$$



Za  $\alpha = 0,05$ ,  $p$ -vrijednost  $< \alpha \Rightarrow H_1$ .

	Coefficients	Standard Error	t Stat	P-value
Intercept	4,168317	0,971706	4,289691	0,000357
em	0,004531	0,001389	3,263417	0,003889
im	0,000753	0,00059	1,276592	0,216371
fert	-0,03183	0,103469	-0,3076	0,761564
dob	0,03085	0,035853	0,860458	0,399735
brak	-0,00764	0,001841	-4,15181	0,000493
raz	-0,00168	0,003681	-0,45714	0,652497
bdp	0,002102	0,000543	3,869618	0,000954

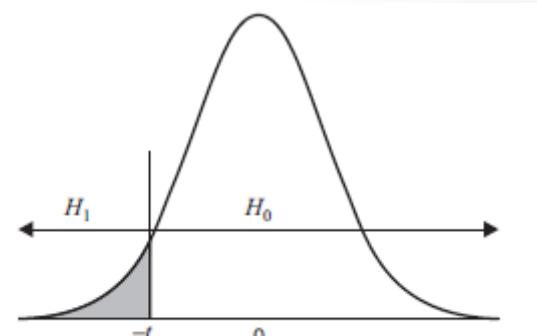
$$\widehat{pop} = 4,17 + 0,004 \cdot em + 0,0007 \cdot im - 0,03 \cdot fert + 0,03 \cdot dob - 0,0076 \cdot brak - 0,0017 \cdot raz + 0,002 \cdot bdp$$

$$H_0: \beta_6 = 0$$

$$H_1: \beta_6 < 0$$

$$p\text{-vrijednost} = \frac{0,652497}{2} = 0,326249$$

$$p\text{-vrijednost} > \alpha \rightarrow H_1$$



	Coefficients	Standard Error	t Stat	P-value
Intercept	4,168317	0,971706	4,289691	0,000357
em	0,004531	0,001389	3,263417	0,003889
im	0,000753	0,00059	1,276592	0,216371
fert	-0,03183	0,103469	-0,3076	0,761564
dob	0,03085	0,035853	0,860458	0,399735
brak	-0,00764	0,001841	-4,15181	0,000493
raz	-0,00168	0,003681	-0,45714	0,652497
bdp	0,002102	0,000543	3,869618	0,000954

# *F*-test značajnosti regresije

- Test značajnosti regresije je skupni test o značajnosti svih regresorskih varijabli.

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1 : \exists \beta_j \neq 0, \quad j = 1, 2, \dots, k$$

- Ako su ispunjene polazne pretpostavke o modelu i ako je  $H_0$  istinita, testna veličina

$$F = \frac{\frac{SP}{k}}{\frac{SR}{n - (k + 1)}} = \frac{\frac{R^2}{k}}{\frac{1 - R^2}{n - (k + 1)}}$$

- pripada F-distribuciji s  $df_1 = k$  stupnjeva slobode u brojniku i  $df_2 = n - (k + 1)$  stupnjeva slobode u nazivniku
- Uz razinu značajnosti  $\alpha$ , odluka o ishodu testa donosi se usporedbom testne veličine F i teorijske vrijednosti F distribucije s  $(k, n - (k + 1))$  stupnjeva slobode.
- $H_0$  se odbacuje ako je  $F > F_{(k, n - (k + 1))}^\alpha$

# Primjer F-test

ANOVA					
	df	SS	MS	F	Significance F
Regression	7	0,846896	0,120985	392,7823	5,38E-20
Residual	20	0,00616	0,000308		
Total	27	0,853057			

$$H_0: \beta_1 = \beta_2 = \dots = \beta_7 = 0$$

$$H_1: \exists \beta_j \neq 0, j = 1, 2, \dots, 7$$

$$p\text{-vrijednost} = 5,38 \cdot 10^{-20} \quad \text{Za } \alpha = 0,05, \text{ } p\text{-vrijednost} < \alpha \implies H_1.$$

# Koreacijska matrica

- U modelu višestruke linearne regresije, koji uključuje zavisnu varijablu  $y$  i  $k$  nezavisnih varijabli, za svaki par varijabli može se izračunati koeficijent linearne korelacije, tj. pokazatelj smjera i jakosti linearne statističke povezanosti dviju varijabli.

# Koreacijska matrica

- Dobivene vrijednosti zapisuju se u koreacijskoj matrici R oblika

# Primjer: korelacija

- Interpretirajte vrijednosti koeficijenata korelacije

	pop	em	im	fert	dob	brakovi	raz	bdp
pop	1							
em	0,822645	1						
im	0,774462	0,670238	1					
fert	0,111644	0,088996	0,061183	1				
dob	0,978242	0,817136	0,744308	0,219267	1			
brakovi	-0,43081	-0,03103	-0,24026	0,451796	-0,31491	1		
raz	0,760095	0,610075	0,587805	-0,19606	0,752883	-0,41562	1	
bdp	0,988107	0,81481	0,765067	0,20836	0,99154	-0,34744	0,747643	1

# Koeficijent višestrukne linearne korelacijske

- Standardizirana mjeru jakosti, linearne statističke povezanosti zavisne varijable  $y$  i skupa nezavisnih varijabli

$$R = \sqrt{R^2}$$

- Vrijednost koeficijenta je uvijek nenegativna i ne pridružuje mu se predznak.
- Naime, povezanost varijable  $y$  i pojedine nezavisne varijable iz skupa od  $k$  nezavisnih varijabli može biti različitog smjera.
- Vrijednost  $R \approx 0$  označava zanemarivu, a  $R \approx 1$  jaku povezanost varijabli

## SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,996383
R Square	0,992778
Adjusted R Square	0,990251
Standard Error	0,017551
Observations	28

$$R = 0,996383$$

ANOVA					
	df	SS	MS	F	Significance F
Regression	7	0,846896	0,120985	392,7823	5,38E-20
Residual	20	0,00616	0,000308		
Total	27	0,853057			