

Analiza brojčanih podataka, korelacija i regresija

doc.dr.sc. Vesna Ilakovac

Katedra za biofiziku, medicinsku statistiku i medicinsku informatiku

Medicinski fakultet Osijek

TESTIRANJE RAZLIKA

- **razlike mjerenja neke varijable na dvije ili više skupina ispitanika -> nezavisni uzorci**
- **razlike dva ili više mjerenja neke varijable na istoj skupini ispitanika ->zavisni uzorci**


Priprema podataka

1. jedinica promatranja (*ispitanik, preparat, pokusna životinja, organ*)
2. varijable:
 - vrsta varijable (numerička, kategorička)
 - ljestvica mjerenja (nominalna, ordinalna, intervalna, omjerna)
 - za numeričke varijable, broj decimalnih mjesta

Upis podataka

- numerički podatci
 - onako kako su izmjereni
- kategorički podatci
 - klasificirati u logičke, isključive skupine (prema problemu)

Unos podataka



Unos podataka o mjerenjima na nezavisnim skupinama

- nezavisne skupine = različiti ispitanici
(ispitanici koji pripadaju nekoj skupini ne pripadaju niti jednoj od preostalih skupina)
- za unos podataka o nekom mjerenju na nezavisnim skupinama ispitanika UVIJEK imamo 2 varijable (bez obzira koliko je skupina ispitanika):
 1. varijabla koja određuje pripadnost ispitanika pojedinoj skupini
 2. varijabla u koju unosimo vrijednost mjerenja za danog ispitanika

Unos podataka o mjerenjima na nezavisnim skupinama

- npr. mjerenje dobi; skupine po spolu
- broj mogućih skupina: 2

varijabla koja sadrži
vrijednost mjerenja

varijabla koja definira
pripadnost skupini

	Dob	Spol	
ispitanik1	35	M	
ispitanik2	37	M	
ispitanik3	32	M	
ispitanik4	33	Z	

Unos podataka o mjerenjima na nezavisnim skupinama

- npr. mjerenje visine; skupine po razredu (osnovna škola)
- broj mogućih skupina: 8

varijabla koja sadrži
vrijednost mjerenja

varijabla koja definira
pripadnost skupini

	Visina	Razred	
ispitanik1	110	2	
ispitanik2	140	2	
ispitanik3	100	1	
ispitanik4	176	7	

Unos podataka o mjerenjima na zavisnim skupinama

- zavisne skupine = ponavljana mjerenja na ISTIM ispitanicima
- SVAKO mjerenje = JEDNA varijabla



koliko mjerenja toliko varijabli

Unos podataka o mjerenjima na zavisnim skupinama

- npr. praćenje dnevnih varijacija sistoličkog tlaka; mjerenja u 6h, 10h, 14h, 18h, 22h

po jedna varijabla za svako mjerenje



	ST6	ST10	ST14	ST18	ST22
ispitanik1	120	135	140	180	160
ispitanik2	115	120	120	125	120
ispitanik3	140	145	150	150	180
ispitanik4	118	110	110	115	120

STUDENTOV T-TEST

(t-test za nezavisne uzorke)

za što se koristi:

- testiranje razlike između dvije nezavisne skupine ispitanika

pod kojim uvjetima:

- varijabla koju testiramo mjerena je najmanje intervalnom skalom
- varijabla koju testiramo ima normalnu razdiobu u promatranim skupinama
- varijance mjerenja varijable koju testiramo u promatranim skupinama su slične (homogenost varijanci)

test statistika:

$$t = \frac{(\bar{x}_A - \bar{x}_B) - (\mu_A - \mu_B)}{SE(\bar{x}_A - \bar{x}_B)}$$

ima Studentovu (t) razdiobu
s $n_A + n_B - 2$ stupnja slobode

$$SE(\bar{x}_A - \bar{x}_B) = \sqrt{s_{zaj}^2 \left(\frac{1}{n_A} + \frac{1}{n_B} \right)}$$

standardna pogreška razlike
aritmetičkih sredina

$$s_{zaj}^2 = \frac{(n_A - 1)s_A^2 + (n_B - 1)s_B^2}{(n_A - 1) + (n_B - 1)}$$

zajednička varijanca

test homogenosti varijanci (F-test):

$$F = \frac{s_A^2}{s_B^2}$$

ima F razdiobu
s $n_A - 1, n_B - 1$ stupnjeva slobode

ako koristimo tablice:

- tablice za F sadrže obično samo desnu stranu distribucije
 $\Rightarrow$ u *brojnik* stavljamo *veću varijancu*

ZADATAK 1

Ispitivan je utjecaj sniženja tjelesne temperature na protrombinsko vrijeme. Izvršena su mjerenja PV na dvije skupine ispitanika. U jednoj skupini bilo je 16 ispitanika normalne temperature (kontrolna skupina). U drugoj skupini bilo je 14 ispitanika sa sniženom temperaturom (pokusna skupina).

Mjerenjem su dobiveni sljedeći rezultati (u sekundama):

Kontrolna skupina (37 ⁰ C)	Pokusna skupina (15 ⁰ C)
7	8
8	6
9	8
6	9
8	10
10	12
8	11
12	8
9	7
11	8
10	8
8	9
9	9
7	9
7	
8	

7

PDL

- nezavisne skupine

2 varijable:

protrombinsko vrijeme
skupina

1 – kontrolna skupina

2 – pokusna skupina

pvrjeme	skupina
7	1
8	1
9	1
:	:
7	1
7	1
8	1
8	2
6	2
8	2
:	:
9	2
9	2
9	2

Opis varijabli

protrombinsko vrijeme:

- numerička varijabla, omjerna ljestvica

skupina:

- kategorička varijabla, nominalna ljestvica

- ispitati mjere sredine i raspršenja za PV u svakoj skupini
- ispitati normalnost raspodjele PV u svakoj skupini

Opisna statistika i ispitivanje normalnosti - MedCalc:

Statistics-> Summary statistics

za kontrolnu skupinu:

Variable -> pvrijeme

Select -> skupina=1


Options -> Test for normal distribution

za pokusnu skupinu:

Variable -> pvrijeme

Select -> skupina=2

Options -> Test for normal distribution



Summary statistics

Variable : PVRIJEME
Select : SKUPINA=1

Sample size	=	16
Lowest value	=	6.0000
Highest value	=	12.0000
Arithmetic mean	=	8.5625
95% CI for the mean	=	7.7152 to 9.4098
Median	=	8.0000
95% CI for the median	=	7.0800 to 9.9200
Variance	=	2.5292
Standard deviation	=	1.5903
Relative standard deviation	=	0.1857
Standard error of the mean	=	0.3976
Test for Normal distribution	:	P = 0.1792 (Chi-square=1.864 DF=1)

Summary statistics

Variable:

PVRIJEME

Select:

SKUPINA=2

Options

- ☒ Test for normal distribution
☐ Percentiles

Help

Cancel

Ok

Summary statistics

Variable : PVRIJEME
Select : SKUPINA=2

Sample size	=	14
Lowest value	=	6.0000
Highest value	=	12.0000
Arithmetic mean	=	8.7143
95% CI for the mean	=	7.8249 to 9.6037
Median	=	8.5000
95% CI for the median	=	8.0000 to 9.6668
Variance	=	2.3736
Standard deviation	=	1.5407
Relative standard deviation	=	0.1768
Standard error of the mean	=	0.4118
Test for Normal distribution	:	P = 0.8357 (Chi-square=0.047 DF=1)

Homogenost varijanci - MedCalc:

- preko usporedbe standardnih devijacija:

Tests-> Comparison of... -> standard deviations (F-test)

Comparison of standard ...

1st set of data

Standard deviation 1.5903

Number of cases 16

2nd set of data

Standard deviation 1.5407


Number of cases 14

Help

Test

Exit

Homogenost varijanci - MedCalc:



Comparison of standard ...

1st set of data

Standard deviation: 1.5903

Number of cases: 16

2nd set of data

Standard deviation: 1.5407


Number of cases: 14

F statistic = 1.0654
P = 0.459

Buttons: Help, Test, Exit

Studentov t-test - MedCalc:

Statistics-> T tests



T-Test

Sample 1

Variable: PVRJEME

Select: SKUPINA=1

Sample 2

Variable: PVRJEME

Select: SKUPINA=2

Buttons: Paired, Unpaired, Help, Test, Exit

T-Test

Sample 1
 Variable: PVRIJEME
 Select: SKUPINA=1

Sample 2
 Variable: PVRIJEME
 Select: SKUPINA=2

Mean sample 1 : 8.5625 SD: 1.5903 (n=16)
 Mean sample 2 : 8.7143 SD: 1.5407 (n=14)
 Difference : 0.1518
 95% CI : -1.0230 to 1.3266
 t=-0.265 DF=28 **P = 0.7933 > 0.05**

=> ne odbacujemo H_0

☐ Paired ☒ Unpaired

ŠTO AKO NISU ZADOVOLJENI UVJETI ?

Mann-Whitney-Wilcoxon test
 (Mann-Whitney U test)

MedCalc:

Statistics-> Wilcoxon tests

Wilcoxon test

Sample 1
Variable: PVRJEME
Select: SKUPINA=1

Sample 2
Variable: PVRJEME
Select: SKUPINA=2

☐ Paired ☒ Unpaired

Help Test Exit

T-TEST DIFERENCIJA (t-test za zavisne uzorke)

za što se koristi:

- testiranje razlike između dvije zavisne skupine ispitanika (ponavljana mjerenja na istim ispitanicima)

pod kojim uvjetima:

- razlike parova vrijednosti mjerene su najmanje intervalnom skalom
- razlike parova vrijednosti imaju normalnu razdiobu

test statistika:

$$t = \frac{\bar{d} - (\mu_A - \mu_B)}{\sqrt{\frac{s_d^2}{n}}}$$

ima Studentovu (t) razdiobu
s n-1 stupnjeva slobode

$$\bar{d} = \bar{x}_A - \bar{x}_B$$
 srednja razlika

$$s_d^2 = \frac{\sum_i (d_i - \bar{d})^2}{n-1}$$
 varijanca razlike

ZADATAK 2

Ispitivan je utjecaj alkohola na vrijeme reakcije vozača. Izvršeno je mjerenje vremena reakcije 14 vozača na standardne zadatke prije i nakon konzumacije određene količine alkohola.

Mjerenjem su dobiveni slijedeći rezultati:

	prije	nakon
1	0.68	0.73
2	0.64	0.66
3	0.68	0.66
4	0.82	0.92
5	0.58	0.68
6	0.80	0.87
7	0.72	0.77
8	0.65	0.70
9	0.84	0.88
10	0.73	0.79
11	0.63	0.68
12	0.72	0.68
13	0.68	0.75
14	0.69	0.78

PD

7

- zavisne skupine

2 varijable:

prije

nakon

prije	nakon
0.68	0.73
0.64	0.66
0.68	0.66
0.82	0.92
0.58	0.68
0.80	0.87
0.72	0.77
0.65	0.70
0.84	0.88
0.73	0.79
0.63	0.68
0.72	0.68
0.68	0.75
0.69	0.78

Opis varijabli

prije, nakon:

- numeričke, omjerna ljestvica

za obje varijable:

- ispitati mjere sredine i raspršenja

kreirati novu varijablu prije-nakon:

- ispitati normalnost

Opisna statistika i ispitivanje normalnosti - MedCalc:

Statistics-> Summary statistics

prije:

Variable -> prije


poslije:

Variable -> poslije

razlika:

Variable-> razlika

Options -> Test for normal distribution



	A	B	C
	prije	nakon	razlika
1	0.68	0.73	A1-B1
2	0.64	0.66	
3	0.68	0.66	
4	0.82	0.92	
5	0.58	0.68	
6	0.8	0.87	
7	0.72	0.77	
8	0.65	0.7	
9	0.84	0.88	
10	0.73	0.79	
11	0.63	0.68	
12	0.72	0.68	
13	0.68	0.75	
14	0.69	0.78	
15			

Zadatak2			
	A	B	C
	prije	nakon	razlika
1	0.68	0.73	-0.05
2	0.64	0.66	-0.02
3	0.68	0.66	0.02
4	0.82	0.92	-0.1
5	0.58	0.68	-0.1
6	0.8	0.87	-0.07
7	0.72	0.77	-0.05
8	0.65	0.7	-0.05
9	0.84	0.88	-0.04
10	0.73	0.79	-0.06
11	0.63	0.68	-0.05
12	0.72	0.68	0.04
13	0.68	0.75	-0.07
14	0.69	0.78	-0.09

Summary statistics			
Variable	:	PRIJE	
Sample size	=	14	
Lowest value	=	0.5800	
Highest value	=	0.8400	
Arithmetic mean	=	0.7043	
95% CI for the mean	=	0.6613 to 0.7473	
Median	=	0.6850	
95% CI for the median	=	0.6433 to 0.7767	
Variance	=	0.0055	
Standard deviation	=	0.0745	
Relative standard deviation	=	0.1058	
Standard error of the mean	=	0.0199	

Summary statistics			
Variable	:	NAKON	
Sample size	=	14	
Lowest value	=	0.6600	
Highest value	=	0.9200	
Arithmetic mean	=	0.7536	
95% CI for the mean	=	0.7038 to 0.8034	
Median	=	0.7400	
95% CI for the median	=	0.6800 to 0.8433	
Variance	=	0.0074	
Standard deviation	=	0.0863	
Relative standard deviation	=	0.1145	
Standard error of the mean	=	0.0231	




Variable : RAZLIKA

Sample size	=	14
Lowest value	=	-0.1000
Highest value	=	0.0400
Arithmetic mean	=	-0.0493
95% CI for the mean	=	-0.0728 to -0.0258
Median	=	-0.0500
95% CI for the median	=	-0.0833 to -0.0267
Variance	=	0.0017
Standard deviation	=	0.0407
Relative standard deviation	=	-0.8250
Standard error of the mean	=	0.0109

Test for Normal distribution : $P = 0.4908$
(Chi-square=0.478 DF=1)

T-test diferencija - MedCalc:

Statistics-> T tests



T-Test

Sample 1
Variable: PRIJE
Select:

Sample 2
Variable: NAKON
Select:

Mean difference : -0.0493
Standard deviation : 0.0407
95 % CI : -0.0728 to -0.0258

t=-4.535 DF=13 P = 0.0006

☒ Paired ☐ Unpaired Help Test Exit

razlika < 0 i $p < 0.05 \Rightarrow$ vrijeme reakcije vozača nakon konzumacije te količine alkohola značajno je dulje nego prije konzumacije te količine alkohola

ŠTO AKO NISU ZADOVOLJENI UVJETI ?

Wilcoxonov test

MedCalc:

Statistics-> Wilcoxon tests

Wilcoxon test

Sample 1
Variable: PRIJE
Select:

Sample 2
Variable: NAKON
Select:

☒ Paired ☐ Unpaired

Help Test Exit

JEDNOSMJERNA ANALIZA VARIJANCE (One-way ANOVA)

za što se koristi:

- testiranje razlike između tri i više skupina

faktor

- kategorička varijabla prema kojoj su definirane skupine


jednosmjerna analiza varijance

- analiza varijance s jednim faktorom


- postupak u kojem donosimo dvije procjene varijance za promatrane grupe (model):
 - procjenu koja odražava *varijabilitet između grupa*
 - procjenu koja odražava *varijabilitet unutar grupa*

OSNOVNA IDEJA:

- utvrditi je li varijabilitet *između grupa* veći od varijabiliteta *unutar grupa*



VARIJABILITET IZMEĐU GRUPA VEĆI JE OD VARIJABILITETA UNUTAR GRUPA



VARIJABILITET UNUTAR GRUPA VEĆI JE OD VARIJABILITETA IZMEĐU GRUPA

pretpostavke:

- varijabla koju testiramo mjerena je najmanje intervalnom skalom
- varijabla koju testiramo ima normalnu razdiobu u promatranim skupinama
- varijance mjerenja varijable koju testiramo u promatranim skupinama su slične (**homogenost varijanci**)

test statistika:

$$F = \frac{MS_{\text{tretman}}}{MS_{\text{pogreška}}}$$

procjena koja odražava
varijabilitet IZMEĐU grupa

procjena koja odražava
varijabilitet UNUTAR grupa

- F ima F razdiobu s $k-1$, $N-k$ stupnjeva slobode

ZADATAK 3

Bolesnici s uznapređovalim stadijem raka želuca, bronhija, kolona i dojke tretirani su novim lijekom. Svrha istraživanja je utvrditi je li preživljenje bolesnika povezano sa zahvaćenim organom. Vrijeme preživljenja (u mjesecima) dano je u tablici:

Želudac	Bronhiji	Kolon	Dojke
11	9	16	35
8	21	19	45
9	4	14	40
7	21	8	34
20	16	13	46
11	13	23	35
33	8	23	52
12	8	21	28
10	12	20	42
19	29	19	49
12	12	31	38
18	13	28	32
20	6	19	43
18	15	13	28
17	12	10	
10	8	4	
	16	17	

- nezavisne skupine

4 skupine , ali 2 varijable:

vrijeme

organ

1 - želudac

2 - bronhiji

3 - kolon

4 - dojke

organ	vrijeme
1	11
:	:
1	10
2	9
:	:
2	16
3	16
:	:
3	17
4	35
:	:
4	28

Opisna statistika i ispitivanje normalnosti - MedCalc:

Statistics-> Summary statistics

za želudac:

Variable -> vrijeme

Select -> organ=1

Options -> Test for normal distribution

za bronhije:

Variable -> vrijeme

Select -> organ=2

Options -> Test for normal distribution

za kolon:

Variable -> vrijeme

Select -> organ=3

Options -> Test for normal distribution

za dojke:

Variable -> vrijeme

Select -> organ=4

Options -> Test for normal distribution

Summary statistics				Summary statistics			
Variable : VRIJEME		Variable : VRIJEME		Variable : VRIJEME		Variable : VRIJEME	
Select : ORGAN=1		Select : ORGAN=2		Select : ORGAN=3		Select : ORGAN=4	
Sample size	=	16		Sample size	=	17	
Lowest value	=	7.0000		Lowest value	=	4.0000	
Highest value	=	33.0000		Highest value	=	29.0000	
Arithmetic mean	=	14.6875		Arithmetic mean	=	13.1176	
95% CI for the mean	=	11.1551 to 18.2199		95% CI for the mean	=	9.8918 to 16.3435	
Median	=	12.0000		Median	=	12.0000	
95% CI for the median	=	10.0000 to 18.9200		95% CI for the median	=	8.0000 to 16.0000	
Variance	=	43.9625		Variance	=	39.3603	
Standard deviation	=	6.6304		Standard deviation	=	6.2738	
Relative standard deviation	=	0.4514		Relative standard deviation	=	0.4783	
Standard error of the mean	=	1.6576		Standard error of the mean	=	1.5216	
Test for Normal distribution :		P = 0.1996		Test for Normal distribution :		P = 0.2308	
		(Chi-Square=1.646 DF=1)				(Chi-Square=1.467 DF=1)	

Summary statistics				Summary statistics			
Variable : VRIJEME		Variable : VRIJEME		Variable : VRIJEME		Variable : VRIJEME	
Select : ORGAN=3		Select : ORGAN=4		Select : ORGAN=3		Select : ORGAN=4	
Sample size	=	17		Sample size	=	14	
Lowest value	=	4.0000		Lowest value	=	28.0000	
Highest value	=	31.0000		Highest value	=	52.0000	
Arithmetic mean	=	17.5294		Arithmetic mean	=	39.0714	
95% CI for the mean	=	13.9805 to 21.0783		95% CI for the mean	=	34.7487 to 43.3942	
Median	=	19.0000		Median	=	39.0000	
95% CI for the median	=	13.0000 to 22.0813		95% CI for the median	=	32.6664 to 45.6668	
Variance	=	47.6397		Variance	=	56.0714	
Standard deviation	=	6.9022		Standard deviation	=	7.4881	
Relative standard deviation	=	0.3937		Relative standard deviation	=	0.1917	
Standard error of the mean	=	1.6740		Standard error of the mean	=	2.0013	
Test for Normal distribution :		P = 0.6711		Test for Normal distribution :		P = 0.6836	
		(Chi-Square=0.185 DF=1)				(Chi-Square=0.169 DF=1)	

Test homogenosti varijanci - MedCalc:


- ver. 4.1 NEMA!!!!

Test homogenosti varijanci - SPSS:

Test of Homogeneity of Variances

vrijeme

Levene Statistic	df1	df2	Sig.
.410	3	60	.746



One-way analysis of variance			
DATA : VRIJEME			
FACTOR CODES : ORGAN			
Source of variation	Sum of squares	D.F.	Mean square
Between groups (influence factor)	6444.3683	3	2148.1228
Within groups (other fluctuations)	2780.3661	60	46.3394
Total	9224.7344	63	
F-ratio : 46.356			
Significance level : P = 0.005			
Student-Newman-Keuls test for all pairwise comparisons			
Factor	n	mean	Different (P<0.05) from factor nr
(1) 1	16	14.6875	(4)
(2) 2	17	13.1176	(4)
(3) 3	17	17.5294	(4)
(4) 4	14	39.0714	(1) (2) (3)

najmanje jedna skupina značajno je različita od neke od preostalih

KORELACIJA

KORELACIJA

- veza među obilježjima (varijablama)
- obilježja koja “variraju zajedno”


KOEFICIJENT KORELACIJE

- mjera stupnja povezanosti



PEARSONOV KOEFICIJENT KORELACIJE r

- mjera stupnja *linearne* povezanosti dviju kvantitativnih varijabli



$$-1 \leq r \leq 1$$



nema povezanosti



stohastička povezanost



funkcionalna povezanost

x, ynizovi vrijednosti varijabli čiju povezanost ocjenjujemo

POSTUPAK ZA OCJENU KORELACIJE

- a) crtanje korelacionog dijagrama
- b) ocjena postojanja povezanosti
- c) u slučaju da postoji **linearna** povezanost, računamo koeficijent korelacije r

$$r = \frac{\sum_{i=1}^N z_{xi} z_{yi}}{N - 1}$$

z_{xi} , z_{yi} standardizirane vrijednosti pojedinačnih vrijednosti varijabli x i y, tj.

$$z_{xi} = \frac{x_i - \bar{x}}{s_x}$$

$$z_{yi} = \frac{y_i - \bar{y}}{s_y}$$

skraćeni postupak računanja r:

$$r = \frac{\sum_{i=1}^N x_i y_i - \frac{1}{N} \left(\sum_{i=1}^N x_i \right) \left(\sum_{i=1}^N y_i \right)}{\sqrt{\left[\sum_{i=1}^N x_i^2 - \frac{1}{N} \left(\sum_{i=1}^N x_i \right)^2 \right] \left[\sum_{i=1}^N y_i^2 - \frac{1}{N} \left(\sum_{i=1}^N y_i \right)^2 \right]}}$$

ZNAČAJNOST KOEFICIJENTA KORELACIJE

- testiramo je li r značajno različit od 0
- test statistika

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

slijedi t razdiobu uz $df = N - 2$

ZADATAK 4

Izmjerena je visina u centimetrima i vitalni kapacitet pluća (VC) u litrama 33 studentice prve godine. Dobiveni su sljedeći rezultati:

Rbr.	Visina	VC	Rbr.	Visina	VC	Rbr.	Visina	VC
1.	180.6	4.74	12.	155.0	2.20	23.	174.2	4.27
2.	168.0	3.63	13.	171.0	3.38	24.	167.0	3.45
3.	163.0	3.40	14.	171.5	3.82	25.	162.0	2.88
4.	171.0	3.75	15.	167.6	3.26	26.	172.0	4.13
5.	177.0	4.23	16.	160.2	2.63	27.	161.0	2.90
6.	169.4	3.20	17.	166.6	3.06	28.	155.0	2.65
7.	161.0	2.90	18.	167.0	3.52	29.	162.0	3.12
8.	170.0	3.88	19.	163.0	2.82	30.	174.0	4.02
9.	158.0	2.40	20.	172.0	3.41	31.	161.0	2.80
10.	161.0	2.60	21.	158.0	2.81	32.	166.0	3.46
11.	163.0	2.72	22.	165.0	3.07	33.	166.0	3.26

Ocijenite postoji li povezanost visine i vitalnog kapaciteta pluća


Crtanje korelacionog dijagrama (točkasti "scatter" grafikon)

MedCalc:

Statistics -> Correlation -> Scatter diagram

visina -> X os

VC -> Y os



Izračun koeficijenta korelacije - MedCalc:

Statistics -> Correlation -> Correlation coefficient

The MedCalc Correlation dialog box is shown. It includes the following fields and options:

- Variable Y: VC
- Variable X: VISINA
- Select: (empty)
- Options:
 - ☐ Logarithmic transformation Y
 - ☐ Logarithmic transformation X
- Buttons: Help, Cancel, Ok

Correlation

Variable Y : VC

Variable X : VISINA

Sample size = 33

Correlation coefficient r = 0.9303 P=0.0000

95% Confidence interval for r = 0.8624 to 0.9653

Interpretacija koeficijenta korelacije

statistička značajnost

- ocjenjuje je li r značajno različit od 0
- ovisi o veličini uzorka - za velike uzorke, mali r će biti značajan

praktična značajnost


- ocjenjuje se pomoću *koeficijenta determinacije* r^2
- koliki udio varijabilnosti je “zajednički”

Interpretacija koeficijenta korelacije

N	Najmanji značajni r (p<0.05)	r ²
10	0.632	0.399
20	0.444	0.197
30	0.361	0.130
40	0.312	0.097
50	0.279	0.078
100	0.197	0.039
200	0.139	0.019
300	0.113	0.013
500	0.088	0.008

VAŽNO:

Pearsonov koeficijent korelacije daje stupanj LINEARNE povezanosti dviju varijabli!






VAŽNO:


Korelacija daje povezanost, a ne UZROČNOST !



VAŽNO:

Na koeficijent korelacije jako utječu ekstremne vrijednosti!





SPEARMANOV KOEFICIJENT KORELACIJE ρ

- neparametrijski koeficijent korelacije

KADA?

- Dvije ordinalne varijable
- Jedna ili obje numeričke varijable nisu normalno distribuirane
- Prisustvo ekstremnih vrijednosti

LINEARNA REGRESIJA

- ako parovi varijabli pokazuju prisustvo korelacije, funkcionalnu vezu prikazuje JEDNADŽBA REGRESIJE

REGRESIJA - prognoza iz jedne varijable u drugu

linearni slučaj - povezanost varijabli je linearna

- *jednadžba regresije je jednadžba pravca oko kojeg se grupiraju parovi varijabli u korelacionom dijagramu*

$$y = a + bx$$


OPĆI OBLIK JEDNADŽBE LINEARNE REGRESIJE

x ... nezavisna varijabla (prediktorska)

y ... zavisna varijabla (kriterijska)

b ... koeficijent smjera

—u realnoj situaciji:



- jednadžba regresijskog pravca dobiva se METODOM NAJMANJIH KVADRATA

y'_i ... vrijednost na regresijskom pravcu koja odgovara x_i

$$\sum_i y_i - y'_i = 0$$

$$\sum_i (y_i - y'_i)^2 = \min$$

iz normalnih jednadžbi

$$\sum_{i=1}^N y_i = Na + b \sum_{i=1}^N x_i$$

$$\sum_{i=1}^N x_i y_i = a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2$$

$$b = \frac{\sum_{i=1}^N x_i y_i - \frac{1}{N} \left(\sum_{i=1}^N x_i \right) \left(\sum_{i=1}^N y_i \right)}{\sum_{i=1}^N x_i^2 - \frac{1}{N} \left(\sum_{i=1}^N x_i \right)^2}$$

KOEFICIJENT
REGRESIJE


a ... odsječak na ordinati

$$a = \bar{y} - b\bar{x}$$


- pravac regresije izražava "prosječni odnos" ("prosječnu vezu") varijabli x i y

Linearna regresija - MedCalc:

Statistics -> Regression -> Regression



The image shows the 'Regression' dialog box in MedCalc. It has a blue title bar with a close button. The main area is light beige. It contains three dropdown menus: 'Variable Y:' with 'VC' selected, 'Variable X:' with 'VISINA' selected, and 'Select:' which is empty. Below these is a group box 'Regression equation' containing five radio button options: $Y = a + bX$ (selected), $Y = a + b \log(X)$, $\log(Y) = a + bX$, $\log(Y) = a + b \log(X)$, and $Y = a + bX + cX^2$. To the right of the group box are three buttons: 'Help', 'Cancel', and 'Ok'.



The image shows the 'Regression' results window in MedCalc. It has a blue title bar with standard window controls. The main area is white with black text. It displays the dependent variable 'VC' and independent variable 'VISINA'. It shows sample size, coefficient of determination, and residual standard deviation. It then displays the regression equation $Y = -11.5374 + 0.0893 X$. Below this is a table of parameter estimates (Intercept and Slope) with their coefficients, standard errors, T-values, and P-values. Finally, it shows an analysis of variance table with sources (Regression and Residual), degrees of freedom, sum of squares, and mean squares. The F-ratio is 199.4107 and the P-value is 0.000.

Parameter	Coefficient	Std.Error	T-value	P
Intercept	-11.53739	1.05028	-10.9851	0.0000
Slope	0.08927	0.00632	14.1213	0.0000

Source	DF	Sum of Squares	Mean Square
Regression	1	9.7037	9.7037
Residual	31	1.5085	0.0487

F-Ratio = 199.4107 P = 0.000

86% varijabilnosti vitalnog kapaciteta pluća može se objasniti visinom

Sample size	=	33
Coefficient of determination	=	0.8655
Residual standard deviation	=	0.2206

standardna devijacija reziduala (standardna pogreška procjene)

-- REGRESSION EQUATION -----
Y = -11.5374 + 0.0893 X

Parameter	Coefficient	Std.Error	T-value	P
Intercept	-11.53739	1.05028	-10.9851	0.0000
Slope	0.08927	0.00632	14.1213	0.0000

β_0		β_1		
-- REGRESSION EQUATION -----				
Y = -11.5374 + 0.0893 X				
Parameter	Coefficient	Std.Error	T-value	P
Intercept	-11.53739	1.05028	-10.9851	0.0000
Slope	0.08927	0.00632	14.1213	0.0000

vitalni kapacitet pluća = $\beta_0 + \beta_1 * \text{Visina} = -11.537 + 0.089 * \text{Visina}$

VAŽNO:

Predviđanja se smiju raditi samo za vrijednosti iz postojećeg raspona varijabli!



npr. za visinu 175,

vitalni kapacitet pluća = $-11.537 + 0.089 \times 175 = 4.04$

razlika $SS_T - SS_R$; (SS_M); predstavlja poboljšanje u predviđanju zbog korištenja regresijskog modela

suma kvadrata odstupanja od vrijednosti predviđene regresijskim pravcem (SS_R)

-- ANALYSIS OF VARIANCE -----				
Source	DF	Sum of Squares	Mean Square	
Regression	1	9.7037	9.7037	
Residual	31	1.5085	0.0487	
F-Ratio = 199.4107		P = 0.000		

SS_T - suma kvadrata odstupanja od aritmetičke sredine

regresijski model značajno bolje predviđa zavisnu varijablu od predviđanja aritmetičkom sredinom