

Prof. dr. sc. Mladen Petrovečki
Katedra za medicinsku informatiku
Medicinski fakultet Sveučilišta u Rijeci
Klinička bolnica "Dubrava", Zagreb

Osnove biostatistike u svakodnevnoj praksi

Korelacija i regresija

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku 22. studeni 2008.

Teme i podaci

- podaci (Bolnica milosrdnih sestara, Zgb)
 - TIBC, total iron binding capacity
 - UIBC, unsaturated...
 - (transferin)+Fe=feritin
 - dob, spol
- dopunski podaci
 - *in vitro* uzgoj matičnih stanica
 - istraživanje polipoidnog melanoma
- korelacija
- pravocrtna regresija
- višestruka regresija
- logistička regresija
- Coxova regresija
- Passing-Bablokova regresija

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Linearni sustavi i kaos

Kaos za početnike
Z. Sardar
I. Abrams

Linearni sustavi

Dakle: jednostavno rečeno, kaos je pojava aperiodičnih, naizgled slučajnih događaja u determinističkom sustavu. U kaosu ima reda, a u redu leži kaos. To dvoje je uzajamno povezano, bliskije no što smo ikada prije pomisljali.

Ali, to se čini neobičnim, budući da su deterministički sustavi predvidljivi i stabilni. Iz puke navike, ljudi su oduvijek tražili uzorce i linearne odnose u onome što vide.

Linearni odnosi dopuštaju nam da predvidimo što će se dogoditi unutar sustava, i lako se mogu grafički prikazati.

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Korelacija

- povezanost pokazatelja
- uvjet pokazatelja: numerički (brojčana mjerna ljestvica)
 - nominalna ☹
 - ordinalna ☺
 - intervalna ☺
 - omjerna ☺
- broj pokazatelja: dva

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Pearsonov koeficijent korelacije

- jednostavna linearna korelacija, r_p
- dva pokazatelja
- intervalna ili omjerna mjerna ljestvica
- vrijednosti: $-1 \leq r \leq +1$

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



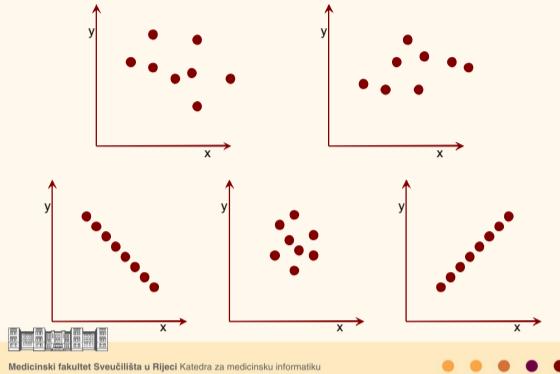
Spearmanov koeficijent korelacije

- neparametrijska linearna korelacija, ρ , r_s
 - dva pokazatelja
 - ordinalna mjerna ljestvica
 - vrijednosti: $-1 \leq r \leq +1$
- zašto r_s , a ne r_p :
 - ordinalna mjerna ljestvica
 - mali uzorak
 - x i y ne slijede normalnu raspodjelu

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Koeficijenti korelacijske



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Tumačenje $|r|$

0	– matematička nepovezanost
$\leq 0,25$	– nema povezanosti
0,26-0,50	– slaba povezanost
0,51-0,75	– umjerena povezanost
$> 0,75$	– izvrsna povezanost
1	– matematička povezanost

Colton, 1974., *Statistics in Medicine*
(prema: Dawson & Trapp, 2007.)

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Značajnost povezanosti – P

- nulta hipoteza: $p = 0$
- statistika: t ovisi o r, N
- P – mjera značajnosti

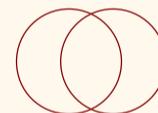
uvjet	N	r	p
TIBC/UIBC svi	61	0,63	<0,001
izolirana DNA	18	0,66	0,003
dob>62 god.	04	0,97	0,035
Fe/UIBC svi	61	-0,38	0,002
dob>62 god.	04	-0,91	0,088

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Jakost povezanosti – r^2

- koeficijent determinacije

uvjet	N	r	p	r^2
TIBC/UIBC svi	61	0,63	<0,001	39,7%
dob>62 god.	04	0,97	0,035	94,1%

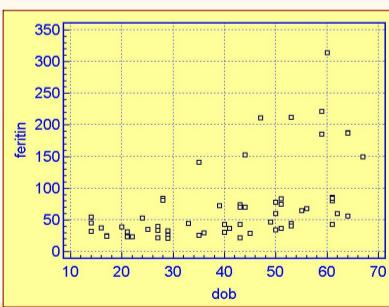


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer 1

r_p

uvjet	N	r	p
dob : feritin	61	0,53	<0,001
dob : Fe	61	-0,01	0,917
UIBC : TIBC	61	0,63	<0,001

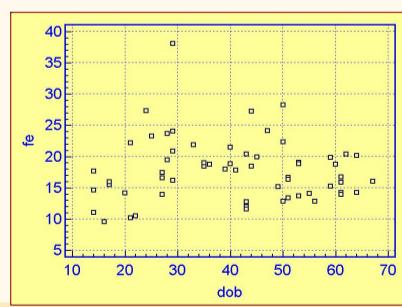


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer 2

r_p

uvjet	N	r	p
dob : feritin	61	0,53	<0,001
dob : Fe	61	-0,01	0,917
UIBC : TIBC	61	0,63	<0,001

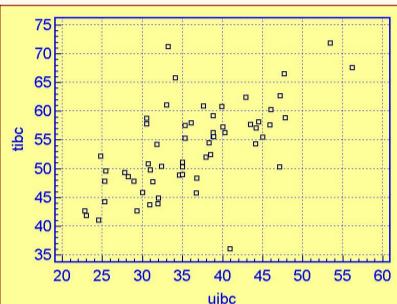


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer 3

r_p

uvjet	N	r	p
dob : feritin	61	0,53	<0,001
dob : Fe	61	-0,01	0,917
UIBC : TIBC	61	0,63	<0,001



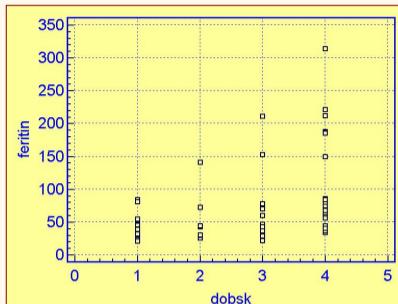
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer 4

r_s

uvjet	N	r	p
dob. sk. : feritin	61	0,59	<0,001
dob. sk. : Fe	61	-0,12	0,356

dobne skupine
(u god.):
(1) do 30,
(2) 31-40,
(3) 41-50,
(4) više od 50



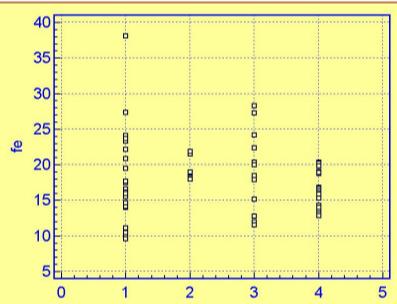
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer 5

r_s

uvjet	N	r	p
dob. sk. : feritin	61	0,59	<0,001
dob. sk. : Fe	61	-0,12	0,356

dobne skupine
(u god.):
(1) do 30,
(2) 31-40,
(3) 41-50,
(4) više od 50

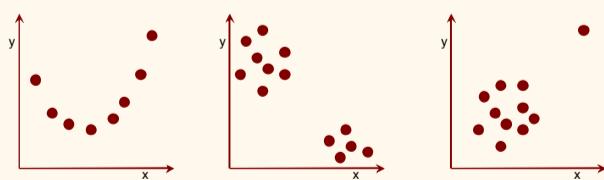


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Pet "ne" r

- **r nema** mjerne jedinice
- **ne ovisi** o tome koji je pokazatelj x, a koji y
- $r=0$ znači: **nema** pravocrtnе povezanosti
- **ne smije** se rabiti za ekstrapolacije (samo interpolacije)
- **ne označava** uzročno-posljedičnu vezu (samo povezanost)

Kada ne računati r



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Promjena podataka \Rightarrow

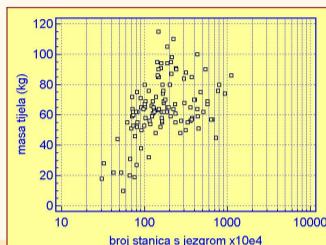
uvjet	N	r	p
lin(bsj) : mt	118	0,25	0,006
log(bsj) : mt	118	0,43	<0,001



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Promjena podataka

uvjet	N	r	p
lin(bsj) : mt	118	0,25	0,006
log(bsj) : mt	118	0,43	<0,001



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Pravocrtna regresija

- matematička povezanost...
- ...dvaju pokazatelja (x i y)
- nezavisna mjerena
- koliko promjena jednog (x) određuje promjenu drugog (y):
 - x: nezavisna varijabla (prediktor)
 - y: zavisna varijabla (kriterij)

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

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

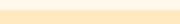


Pravocrtna regresija

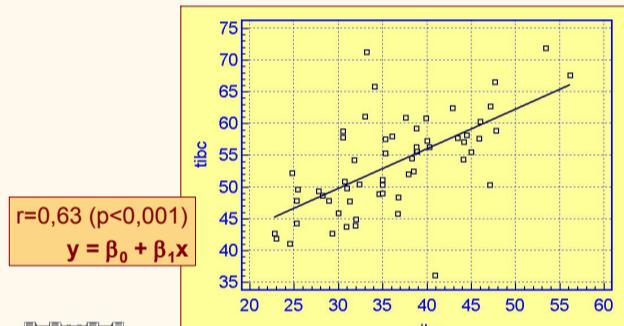
- matematička pov...
 - ...dvaju pokazat...
 - nezavisna mjer...
 - koliko promjena...
 - drugog (y):
 - x: nezavisna va...
 - y: zavisna vari...
- NAPOMENA:**
 $y = a + bx$,
 $y = l + kx$,
 $y = b_0 + b_1 x$,
 $y = \beta_0 + \beta_1 x$...
 a – slobodan član (*intercept*)
 b – nagib pravca (*slope*)

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

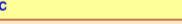
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Primjer: TIBC vs. UIBC \Rightarrow

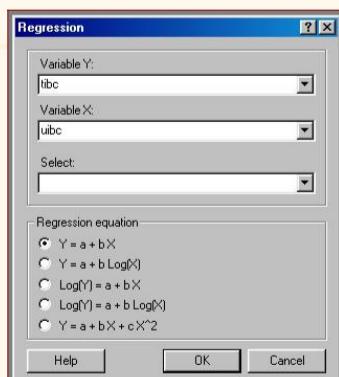


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



primjer \Rightarrow

MedCalc Version 7.1.0
Windows 95/98/NT/Me/2000/XP
<http://www.medcalc.be>

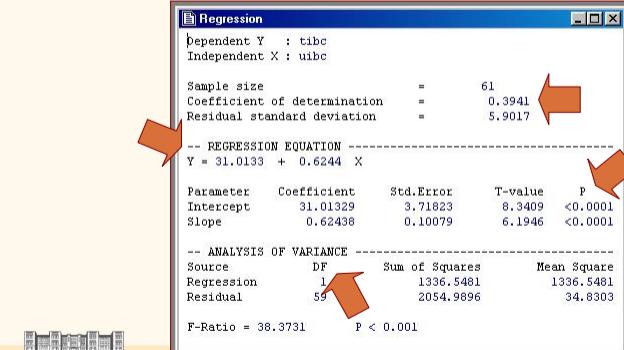


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



r=0,63 (p<0,001)
 $tibc = (31,0 \pm 3,7) + (0,6 \pm 0,1) uibc$

primjer \Rightarrow



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



primjer \Rightarrow

$r=0,63 (p<0,001)$
 $tibc = (31,0 \pm 3,7) + (0,6 \pm 0,1) uibc$

Ovisnost pokazatelja TIBC o:

	$\beta \pm s.e.(\beta)$	t	p
UIBC	β_0	$31,0 \pm 3,7$	$8,34 <0,001$
	β_1	$0,6 \pm 0,1$	$6,19 <0,001$
Fe	β_0	$44,0 \pm 3,4$	$12,94 <0,001$
	β_1	$0,5 \pm 0,2$	$2,91 0,005$

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer

$r=0,63 (p<0,001)$
 $tibc = (31,0 \pm 3,7) + (0,6 \pm 0,1) uibc$

SPSS for Windows
Release 7.5 (Nov 14 1998)
SPSS
Hardware Secured Version

Model Sum of Squares

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.628*	.394	.384	5.9017

a. Predictors: (Constant), UIBC

Coefficients^a

Model	Unstandardized Coefficients			95% Confidence Interval for B			
	B	Std. Error	t	Sig.	Lower Bound	Upper Bound	
1	(Constant)	31,013	3,718	8,341	,000	23,573	38,453
	UBC	,624	,101	6,195	,000	,423	,826

a. Dependent Variable: TIBC

ANOVA^b

Model	Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1336,548	1	1336,548	
	Residual	2054,990	59	34,830	
	Total	3391,538	60		

a. Predictors: (Constant), UIBC
b. Dependent Variable: TIBC

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer: granice pouzdanosti

Ovisnost pokazatelja TIBC o:

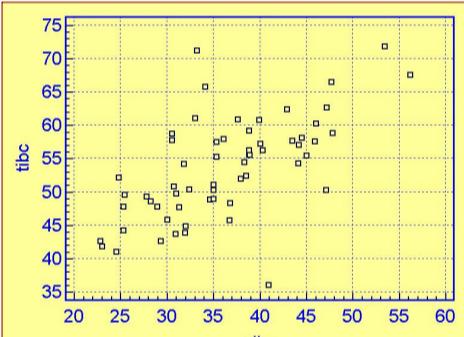
UIBC

	$\beta \pm s.e.(\beta)$	95%GP(β)	t	p
β_0	$31,0 \pm 3,7$	23,6-38,5	8,34	$<0,001$
β_1	$0,6 \pm 0,1$	0,4-0,8	6,19	$<0,001$

granice pouzdanosti (Confidence Interval Limits):
95%: $\beta \pm [1,96 \times s.e.(\beta)] = 31 \pm (1,96 \times 3,7) = 31 \pm 7,3 = 23,7-38,3$
99%: $\beta \pm [2,58 \times s.e.(\beta)] = 31 \pm (2,58 \times 3,7) = 31 \pm 9,5 = 21,5-40,5$

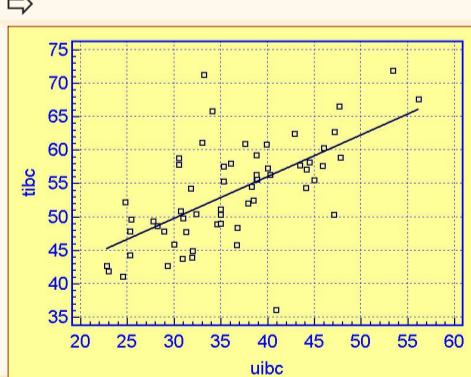
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer \Rightarrow



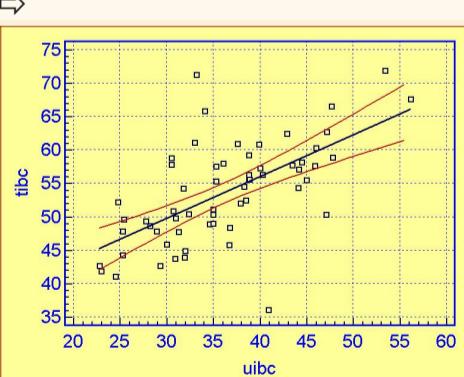
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer \Rightarrow



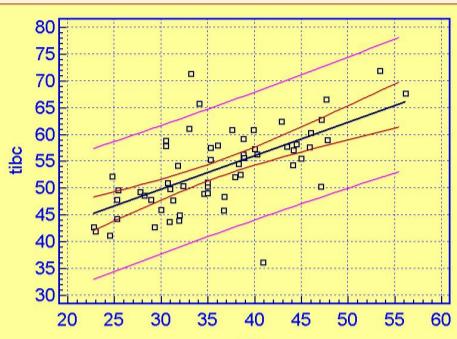
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer \Rightarrow



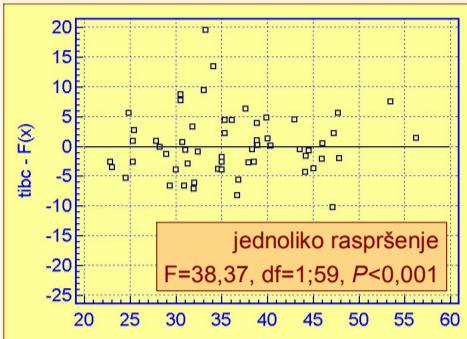
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer \Rightarrow



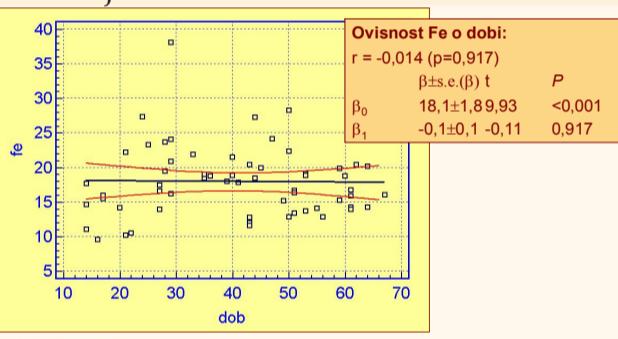
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer: reziduali



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer: ovisnost Fe o dobi



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Višestruka regresija

- matematička povezanost više pokazatelja (x_1-x_n i y)
- nezavisna mjerena
- koliko promjena svakog od x određuje promjenu y :
 - x : nezavisne varijable (prediktori)
 - y : zavisna varijabla (kriterij)

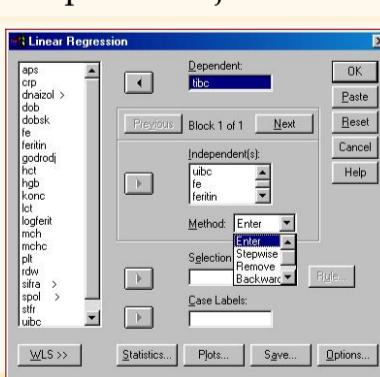
$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer: TIBC vs. 4 pokazatelja \Rightarrow

SPSS for Windows
Release 7.5 (Nov-14-1996)
SPSS
Hardware Secured Version

UIBC
Fe
feritin
dob



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer (univariatno) \Rightarrow



Mjera	$\beta \pm s.e.(\beta)$	t	P
UIBC	β_0	31,0 ± 3,7	<0,001
	β_1	0,6 ± 0,1	<0,001
Fe	β_0	44,0 ± 3,4	<0,001
	β_1	0,5 ± 0,2	0,005
feritin	β_0	57,1 ± 1,4	<0,001
	β_1	-0,1 ± 0,01	<0,001
dob	β_0	62,4 ± 2,4	<0,001
	β_1	-0,2 ± 0,1	<0,001

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer (multivarijatno)

Mjera	$\beta \pm s.e.(\beta)$	t	P
konstanta	β_0 4,5±4,3	0,96	0,341
UIBC	β_1 0,8±0,1	11,68	<0,001
Fe	β_2 1,0±0,1	11,01	<0,001
feritin	β_3 0,01±0,01	0,31	0,760
dob	β_4 0,01±0,03	-0,97	0,338

$$TIBC = 0,8 \times UIBC + 1 \times Fe$$



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Method:	Stepwise
Enter	Stepwise
Remove	Backward

Logistička regresija

- povezanost više pokazatelja (x_1-x_n i y)
- nezavisna mjerena
- koliko promjena svakog od x određuje promjenu binarne varijable y:
 - x: nezavisne varijable (prediktori)
 - y: zavisna varijabla (kriterij)
- e^β = omjer izgleda (OR, odds ratio)

$$\text{logit}(p) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Primjer: spol vs. 5 pokazatelja \Rightarrow

Dependent Y: zspol (dummy)

Sample size: 61

Cases with Y=0: 25 (40,98%)

Cases with Y=1: 36 (59,02%)

--- Overall Model Fit -----

Null model -2 Log Likelihood = 82,56946

Full model -2 Log Likelihood = 69,46355

Chi-square = 13,10; df = 5; P = 0,022



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



primjer \Rightarrow

Var β s.e. P OR (95% CI)

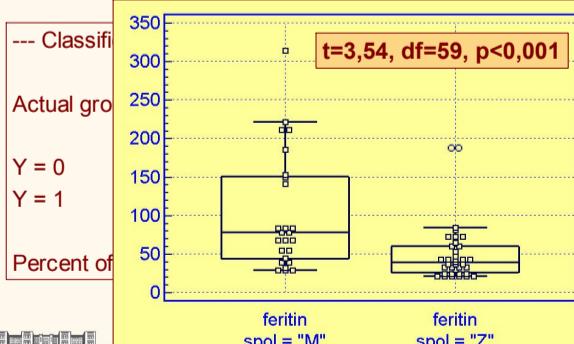
tibc	0,05	0,09	0,563	
uibc	-0,05	0,09	0,615	
fe	-0,03	0,11	0,757	
feritin	-0,02	0,01	0,006	0,98 (0,96 – 0,99)
dob	-0,02	0,02	0,421	
cons.	1,60	0,49	0,003	



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



primjer



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Coxova regresija

- povezanost više pokazatelja (x_1-x_n i y)
- nezavisna mjerena
- koliko promjena x određuje y:
 - x: nezavisne varijable (prediktori)
 - y: zavisna varijabla (kriterij) = mjera rizika
- e^β = omjer rizika (RH, relative hazard)

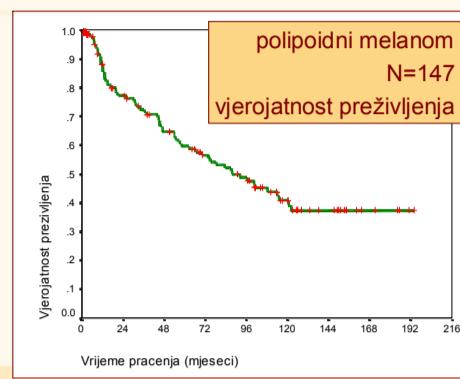
$$\lambda_i(t) = \lambda_0(t) \exp [\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n]$$



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Primjer: utjecaj niza varijabli na $P \Rightarrow$

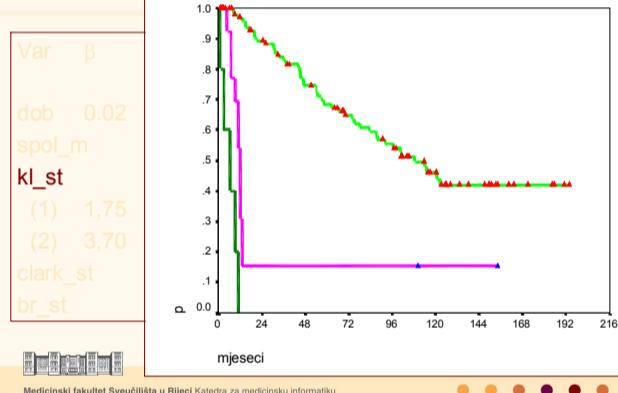


primjer \Rightarrow

Var	β	s.e.	p	RH (95% CI)
dob	0,02	0,011	0,019	1,02 (1,001 – 1,04)
spol_m			0,941	
kl_st			<0,001	
(1)	1,75	0,35	<0,001	5,81 (2,91 – 11,58)
(2)	3,70	0,58	<0,001	40,60 (13,02 – 126,65)
clark_st			0,098	
br_st			0,433	

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

primjer



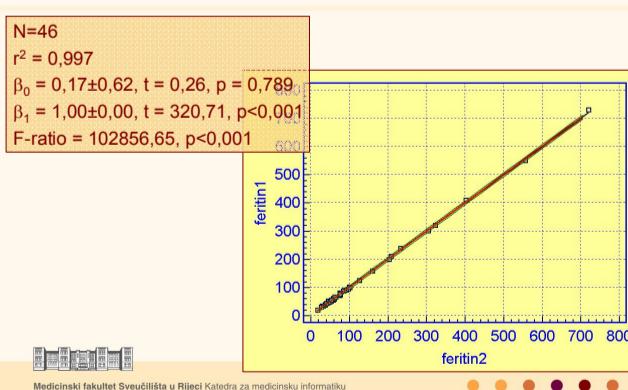
Passing-Bablok regresija

- povezanost dvaju istih pokazatelja (x i y)
- nezavisna mjerena: x/y ili y/x
- koliko promjena bilo kojeg određuje promjenu onog drugog
 - x : nezavisna varijabla (prediktor)
 - y : zavisna varijabla (kriterij) (i obrnuto)

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

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Primjer: feritin, 2 postupka mjerjenja \Rightarrow

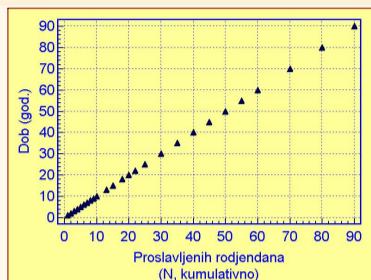


primjer

$y = 0,956 + 0,991x$
Intercept ($A=0$): 0,956
95% CI : 0,500 to 2,163
Slope ($B=1$): 0,991
95% CI : 0,979 to 1,000
Cusum test for linearity:
Significant deviation from linearity ($P < 0,01$)

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Zadnji primjer 😊



Regresijski dokaz da je zdravo slaviti rođendan

(S. den Hartog (Ph.D. Thesis), University of Groningen)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



MEDICINSKA
INFORMATIKA

Hvala na pozornosti

mp@kbd.hr



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

