

Sveučilišni diplomski studij medicinsko-laboratorijske dijagnostike  
Kolegij: Medicinska informatika u kliničko-laboratorijskoj dijagnostici  
(MIKL 2013./14.)

Mladen Petrovečki  
Lidiya Bilić-Zulle

## Obradba podataka

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

## Priprema podataka za obradbu

- vrsta podataka → izbor testa
- naziv varijable (plus opis varijable)
- šifriranje (binariziranje, "nula" = ne)
- nedostatak podatka → prazno polje
- preračunavanje složenih podataka

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

Programska potpora

SPSS Data Editor window showing a table of data with columns A through I. The 'Survival and Failure Time Analysis' dialog box is open, showing various survival analysis options.

## Dvodimenijska tablica podataka

	A	B	C	D	E	F	G	H	I
1	Brc	Dot	Reception (fmloing)	Prakti-jenje					Histološki
2	biopsije (gnd)		estrogen	progrest.	mjeseci	census			
3	BRBP	DOB	ER	PR					
4	1931	55	21	8	156	1	5,4	3	1
5	2017	54	214	31	101	1	3,7	2	1
6	2116	58	56	14	62	1	1,2	1	1
7	2144	44	42	71	36	1	1,0	1	1
8	2213	69	9	5	1		3,0	2	1
9	2481	71	216	451	22	1	3,3	2	2
10	2854	60	203	16	59	1	1,3	1	1
11	3084	62	24	20	119	1	4,0	2	2
12	3648	65	102	15	51	1	4,2	2	1
13	4322	68	248	120	118	1	1,1	1	1
14	4497	44	16	40	72	1	6,2	3	1
15	4652	42	15	44	18	0	4,1	2	1
16	4728	36			71	1	2,8	2	1
17	4880	33	13	38	181	0	4,2	2	1
18	4970	64	52	19	60	1	2,1	2	3
19	4986	54	24	1	59	0	2,0	2	1

Slika 8-1. Struktura podataka dvodimenijsne tablice. Tablica je izvedak podataka iz studije o invazivnim dojka u Ženevi s invazivnim karcinomom dojke. Redovi tablice su bolesnice, a stupci pokazatelji. (Belev B, Aleksić I, Vrbanec D, Petrovečki M, Unušić J, Jakšić-Razumović J. Nm-23 gene product expression in invasive breast cancer: immunohistochemical analysis and clinicopathological correlation. Acta Oncol 2002;41:555-561.)

Prikaz podataka

- prikaz podataka u znanstvenom radu → sažimanje
  - tablice i slike (grafikoni)
  - kvalitativni podaci
    - absolutne i relativne frekvencije
    - kontingencijske tablice, stupčasti i okrugli grafikoni
  - kvantitativni podaci
    - mjere prosjeka i odstupanja
    - grafikon okvira s ručicama

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

## Tablični prikaz podatka

- stvarna vrijednost podataka
- logički dobro organizirana velika količina podataka → jednostavno snalaženje i čitanje podataka
- tablica – samostalna cjelina:
  - naslov tablice
    - svrha tablice, ustroj istraživanja
    - iznad tablice, numeriran, bez točke na kraju
  - legenda
    - ispod tablice, opis kratica i simbola (paziti na upute časopisa)
  - jasni naslovi stupaca

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

## Slikovni prikaz podataka

- prikaz međusobnog odnosa podataka
- svrha: jasno tumačenje rezultata
- naslov slike (grafikoni, crteži, sheme...)
  - ispod slike, numeriran, s točkom na kraju
  - legenda
  - broj opažanja i vrsta prikazane pogreške
- nije dopušteno:
  - rabiti 3D grafikone
  - prikazivati mjere prosjeka bez mjera odstupanja



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Kvalitativni podatci

- utvrđuje se kvaliteta promatranoj obilježja i svrstava se u jednu od kategorija → nominalna ili ordinalna ljestvica
- opis podataka:
  - apsolutna učestalost (broj)
  - relativna učestalost (udio, postotak)
- prikaz podataka:
  - kontingencijske tablice
  - stupčasti grafikoni



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Apsolutna i relativna učestalost

- apsolutna učestalost (broj pojavnosti)
  - NE ukazuju na odnose među skupinama
- relativna učestalost (udjeli)
  - osim ukupnog broja pokazuju i odnos među skupinama

primjer: jednodimenzionska tablica s apsolutnim i relativnim učestalostima

Pušenje	N (%)
da	180 (62)
ne	110 (38)
ukupno	290 (100)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Kontingencijske tablice

- prikazuju obilježja mjerena nominalnom i ordinalnom ljestvicom (kvalitativni podatci)
- dvodimensijske: pokazuju podatke dvaju ili više obilježja

primjer: kontigencijska tablica s prikazom apsolutnih i relativnih učestalosti pušača s obzirom na spol u skupini ispitanika (N=290)

Pušenje	spol	
	žene N (%)	muškarci N (%)
da	120 (80)	60 (43)
ne	30 (20)	80 (57)
ukupno	150 (100)	140 (100)

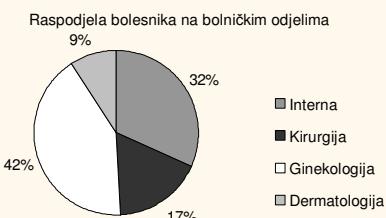


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Kružni grafikon

- prikaz relativnih učestalosti (ukupan zbroj prikazanih podataka 100%)

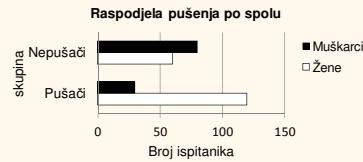


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Stupčasti grafikon

- koristi se za prikaz apsolutnih učestalosti (histogram frekvencija)
- položeni ili okomiti stupci



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Kvantitativni podatci

- brojčani podaci (slijede intervalnu i omjernu ljestvicu)
- prikaz podataka → mjere prosjeka i odstupanja

mjere prosjeka (središnjice)

aritmetička sredina

medijan (centralna vrijednost)

mod (dominantna vrijednost)

mjere odstupanja (raspršenja)

standardna devijacija

raspon, kvartili, percentili

---

- slikovni prikaz podataka:
  - grafikon okvira s ručicama



## Mjere središta i raspršenja

- najčešće se upotrebljavaju:
  - aritmetička sredina i standardna devijacija
    - normalna raspodjela
    - veliki uzorak
  - medijan i raspon (percentili, interkvartili)
    - ne-normalna raspodjela
    - mali uzorak
  - interval pouzdanosti (i za aritmetičku sredinu i za medijan)
- rijedno upotrebljavani: varijanca, računski raspon, standardna pogreška



## Aritmetička sredina

ispitanik → 

1	2	3	4	5	6	7	8	9
---	---	---	---	---	---	---	---	---

  
broj popuštenih cigareta → 

5	7	7	8	8	9	9	9	10
---	---	---	---	---	---	---	---	----

$$\bar{x} = \frac{5 + 7 + 7 + 8 + 8 + 9 + 9 + 9 + 10}{9} = \frac{72}{9} = 8$$



## Medijan

ispitanik → 

1	2	3	4	5	6	7	8	9
---	---	---	---	---	---	---	---	---

  
broj popuštenih cigareta → 

5	7	7	8	8	9	9	9	10
---	---	---	---	---	---	---	---	----

- vrijednost koja se u nizu podataka nalazi točno u sredini
- dijeli skup na dva jednakaka dijela
- ako je N = paran broj
  - medijan = aritmetička sredina dva središnja podatka



## Mod

ispitanik → 

1	2	3	4	5	6	7	8	9
---	---	---	---	---	---	---	---	---

  
broj popuštenih cigareta → 

5	7	7	8	8	9	9	9	10
---	---	---	---	---	---	---	---	----

  
primjer: aritmetička sredina = 8; medijan = 8; mod = 9

- najučestalija vrijednost u nizu podataka
- ako su podatci grupirani u razrede:
  - mod = aritmetička sredina razreda s najvećom učestalošću



## Standardna devijacija

$$S = \sqrt{\frac{\sum(X - \bar{X})^2}{N-1}}$$

- prosječno odstupanje od aritmetičke sredine
- smije se računati i prikazivati SAMO uz aritmetičku sredinu ( $X \pm SD$ )



## Raspon

- raspon od najmanje (minimuma) do najveće (maksimuma) izmjerene vrijednosti ( $X_{\min} - X_{\max}$ )
- moguće izraziti i kao brojčanu vrijednost razlike između najveće i najmanje vrijednosti u nizu:  
 $R = X_{\max} - X_{\min}$
- najmanje informativna mjera odstupanja
- ekstremni rezultati mogu znatno povećati raspon



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Kvartili

1	2	...	...	40	41	42	...	...	81	82
18	30			34			39		63	
min	1. kvartil			2. kvartil		3. kvartil		max		
	25.			medijan		75.		percentil		

- kvartil je rezultat koji se nalazi točno na četvrtini raspona
- interkvartilni raspon (IR):
  - raspon 25. i 75. percentila (ili 1. i 3. kvartila)
  - razlika vrijednosti 3. i 1. kvartila



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Percentili

- raspon podijeljen na sto dijelova – percentila
- označava postotak raspodjele
- 1. percentil = najmanja vrijednost (minimum)
- 25. percentil = 1. kvartil
- 50. percentil = medijan = 2. kvartil
- 75. percentil = 3. kvartil
- 100. percentil = najveća vrijednost (maksimum)

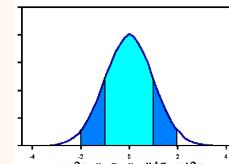


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Raspodjela podataka

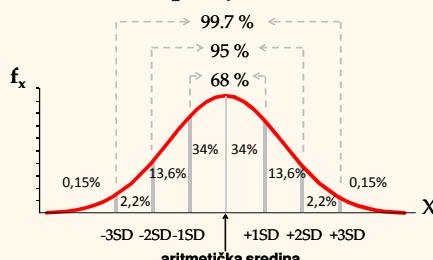
- grafički prikaz mjerjenja prikazan samostalno ili u odnosu na druge podatke
- prikazuje:
  - raspon mjerjenja
  - jednolikost raspodjele
  - modalnost raspodjele
  - simetričnost raspodjele
- normalna raspodjela



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Normalna raspodjela



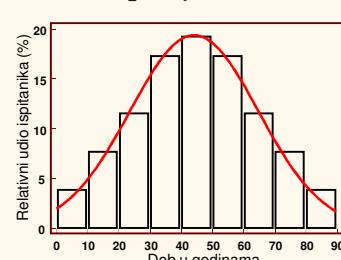
Raspodjela podataka prikazuje se histogramom frekvencije. Os x prikazuje promatrano obilježje, a os y frekvenciju promatranih obilježja.



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Normalna raspodjela



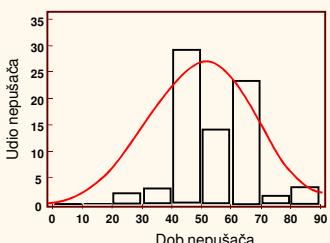
- podaci se opisuju s pomoću aritmetičke sredine i standardne devijacije



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Ne-normalna raspodjela



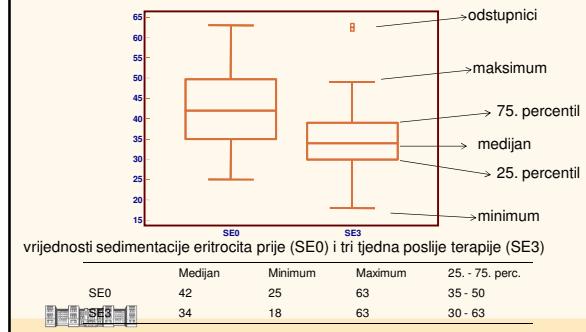
- podaci se opisuju s pomoću medijana i raspona



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Grafikon okvira s ručicama



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

## Odstupnici

- vrijednosti koje odstupaju (engl. *outlier*)
- kriterij za odstupnike:
  - 25. percentil  $-1,5 \times IR$  ( $<$  prosječne vrijednosti)
  - 75. percentil  $+1,5 \times IR$  ( $>$  prosječne vrijednosti)
  - "daleki" odstupnici
    - 25. percentil  $-3 \times IR$  ( $<$  prosječne vrijednosti)
    - 75. percentil  $+3 \times IR$  ( $>$  prosječne vrijednosti)
- provjera
  - pogreška mjerena i/ili upisivanja?
  - djelovanje neprepoznatog čimbenika?
  - NE smiju se izbrisati niti zatajiti



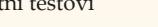
Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Odabir testa

- testovi dokazivanja statističkih hipoteza
- kriterij odabira
  - osobine obilježja → mjerne ljestvice
  - osobine uzorka
    - veličina
    - povezanost
  - osobine raspodjele (normalnost)
    - parametrijski testovi
    - neparametrijski testovi
  - broj obilježja → uni/bi/multivarijatni testovi

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Ovisnost o broju pokazatelja

- univariatni
  - raščlanjuju samo jedan pokazatelj
- bivariatni
  - raščlanjuju dva pokazatelja
- multivariatni
  - raščlanjuju više pokazatelja



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Ovisnost o raspodjeli

- parametrijski testovi
  - pokazatelji koji slijede normalnu raspodjelu
  - obrađuju izvorna mjerena
- neparametrijski testovi
  - nisu ograničeni normalnošću raspodjele
  - ne raščlanjuju izvorne podatke nego položaje (rangove)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Ovisnost o osobini uzorka

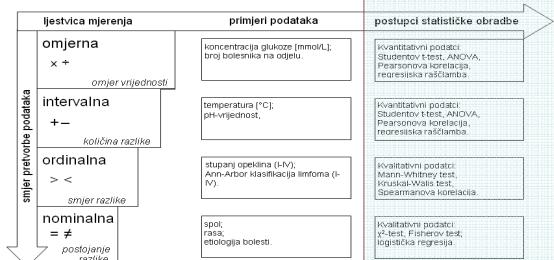
- veličina
    - veliki uzorci → parametrijski testovi
    - mali uzorci → neparametrijski testovi
  - zavisnost
    - nezavisni uzorci → neparni testovi
    - zavisni uzorci → parni testovi



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

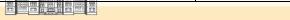


## Osobine obilježja – mjerne ljestvice



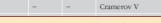
Biranje testa

VRSTA UZORKA		VRSTA PODATAKA		
		brojčani	kategorički	
		omjerni, intervalni	ordinalni	Nominalni
NEZAVISNI	2 skupine različitih jedinika	t-test za nezavisne uzorke	Mann-Whitneyjev test	t-test za proporcije ili $\chi^2$ test
	3 ili više skupina različitih jedinika	analiza varijance ANOVA	Kruskal-Wallisov test	
ZAVISNI	prije i poslije	t-test za zavisne uzorke	Wilcoxonov test	McNemarov test
	višestruko ponavljanje	ANOVA za ponavljana mjerjenja	Friedmanov test	Cochranov Q test
POVEZANOST PODATAKA		Korelacijska analiza	Spearmanova korelacija	omjer izgleda relativnog rizika



## Biranje testa

Pitanja	1. broj po kazaljci	2. pozeca-ka za radika	3. uskla- denost skupina	4. mjeru- ljestvica	5. rasplo- djela	6. broj skupina	7. broj jedinka	Odgovor
Sustav traženja odgovora								
						2	-	Studentov t-test jednomjerna ANOVA
			neuskla- denost (nepuni testovi)	omjerena intervalna ordinarna	nominalna	>2	-	Mann-Whitneyev test
		radika		nominarna	nije nominalna	2	-	Kruskal-Wallisov test
jedan ili dva				omjerena intervalna ordinarna	nominalna	>2	<20	Fleiberg test
			usklađenje (puni testovi)	omjerena intervalna ordinarna	nominalna	>2	>20	parcijski t-test
				omjerena intervalna ordinarna	nominalna	2	-	F-test
				omjerena intervalna ordinarna	nominalna	>2	-	Wilcoxonov test parova
				omjerena intervalna ordinarna	nominalna	>2	-	Friedmanov test
				omjerena intervalna ordinarna	nominalna	>2	-	McNemarov test
		pozveznost	-	omjerena intervalna ordinarna	-	-	-	Pearsonov r



## Tumačenje i prikaz rezultata

- Poopćavanje s uzorka na populaciju
  - Kontingencijske tablice i mjere središnjice
  - Tablični i slikovni prikaz podataka
    - frekvencije: stupčasti grafikon
    - središnjice i rasap: kutije i brkovi (*box and whisker*)
  - Vrijednosti koje odskaču (*outliers*)
  - Raspon pouzdanosti (*confidence interval, CI*)
  - **statističko i logičko zaključivanje**



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



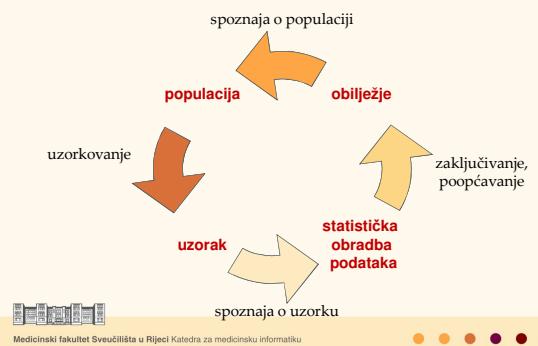
Populacija, uzorak



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



Populacija → uzorak → populacija



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



"Did you get my e-mail?"

[www.cartoonstock.com](http://www.cartoonstock.com)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

