


UVODNA RAZMATRANJA

izv. prof. dr. sc. Vesna Ilakovac

vesna.ilakovac@mefos.hr



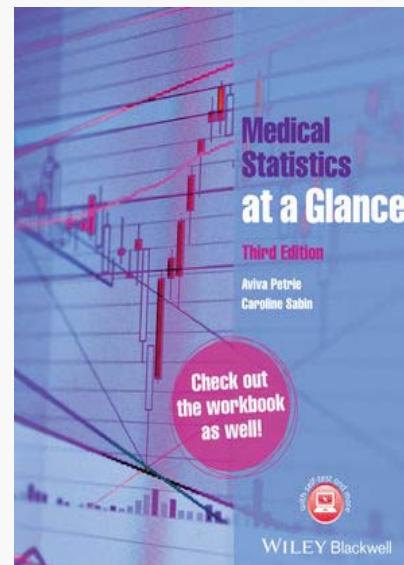
Literatura

- Dawson-Saunders B, Trapp RG. Basic & Clinical Biostatistics. Prentice-Hall Int. Inc., London
- Petrie A, Sabin C. Medical statistics at a glance. Blackwell Science, Oxford.
- Marušić M., Petrak J., Petrovečki M., Marušić A. Uvod u znanstveni rad u medicini. Medicinska naklada Zagreb.

2004.



2009.



2013.



MedCalc Manual

[https://www.medcalc.org/manual/index.php.](https://www.medcalc.org/manual/index.php)

MedCalc

easy-to-use statistical software

Home Features Download Order Contact FAQ **Manual**

Contents

Introduction

File menu

Edit menu

View menu

Format menu

Tools menu

Statistics menu

MedCalc manual - contents

Introduction

[Program installation](#)

[Auto-update](#)

[Regional settings support](#)

[Selection of display language](#)

Statistics menu (continued)

[Serial measurements](#)

[Reference intervals ...](#)

[Reference interval](#)

[Age-related reference interval](#)

PDF:

<http://www.medcalc.eu/download/medcalcmanual.pdf>



Medicinski fakultet Osijek

Katedra za medicinsku statistiku i medicinsku informatiku

Literatura

StatSoft, Inc. (2013). Electronic Statistics Textbook. Tulsa, OK:
StatSoft. WEB: <http://www.statsoft.com/textbook/>.

The screenshot shows the homepage of the StatSoft Electronic Statistics Textbook. At the top, there's a navigation bar with links for Software, Products, Solutions, Buy, Trials, Support, a search bar, and a 'Search' button. Below the navigation bar, a large banner features a blue grid pattern and the text 'Looking for info about statistics? We wrote the book on it. And you can read it for free!'. To the left, a sidebar lists various statistical analysis methods with corresponding icons. In the center, a box highlights the availability of a printed copy of the textbook, showing its cover and a link to Amazon. Below this, text explains the history of the textbook and its purpose. To the right, a testimonial from Mr. Daniel Chen Kwok Lee is displayed.

Software Products Solutions Buy Trials Support

What can we help you find? Search

Home > Textbook

Looking for info about statistics?
We wrote the book on it.
And you can read it for free!

Elementary Concepts
Statistics Glossary
Basic Statistics
ANOVA / MANOVA
Association Rules
Boosting Trees
Canonical Analysis
CHAID Analysis
C & R Trees
Classification Trees
Cluster Analysis
Correspondence Analysis
Data Mining Techniques
Discriminant Analysis
Distribution Fitting
Experimental Design
Factor Analysis
General Discrim. Analysis

Now Available
Printed Copy of this Textbook

A printed version of this textbook is now available!
STATISTICS: Methods and Applications is \$80
which includes a coupon for a free CD version.
[click here to order or go to amazon.com](#)

STATISTICS
Methods and Applications

StatSoft has freely provided the *Electronic Statistics Textbook* as a public service since 1995.

This textbook offers training in the understanding and application of statistics and data mining. The material was developed at the **StatSoft** R&D department based on many years of teaching undergraduate and graduate statistics courses. It covers a wide variety of applications, including laboratory research (biomedical, agricultural, etc.), business statistics, credit scoring, forecasting, social science statistics and survey research.

Testimonials

"Thank you and thank you again for providing a complete, well-structured, and easy-to-understand online resource. Every other website or snobbish research paper has not deigned to explain things in words consisting of less than four syllables. I was tossed to and fro like a man holding on to a frail plank that he calls his determination until I came across your electronic textbook... You have cleared the air for me. You have enlightened. You have illuminated. You have educated me."


— Mr. Daniel Chen Kwok Lee
October 2013

Literatura

Schulz KF, Altman DG, Moher D, for the CONSORT Group. CONSORT 2010 Statement: updated guidelines for reporting parallel group randomised trials. [Ann Int Med 2010;152](#).

(<http://annals.org/article.aspx?articleid=745807>)

<http://www.consort-statement.org/consort-2010>



CONSORT 2010

The CONSORT (CONsolidated Standards of Reporting Trials) 2010 guideline is intended to improve the reporting of parallel-group randomized controlled trial (RCT), enabling readers to understand a trial's design, conduct, analysis and interpretation, and to assess the validity of its results. This can only be achieved through complete adherence and transparency by authors.


CONSORT 2010 was developed through collaboration and consensus between clinical trial methodologists, guideline developers, knowledge translation specialists, and journal editors (see [CONSORT group](#)). CONSORT 2010 is the current version of the guideline and supersedes the 2001 and 1996 versions. It contains a 25-item [checklist](#) and [flow diagram](#), freely available for viewing and [downloading](#) through this website.

[Extensions of the CONSORT Statement](#) have been developed for different types of trial designs, different interventions, and different types of data.

The most important documents for understanding the CONSORT 2010 statement are the following:

1. **The CONSORT 2010 Statement:** This is a declaration of the standard, and how it was developed. This declaration or "statement" has been published in many prominent journals, including the British Medical Journal, the Lancet and PLoS Medicine. You can download the CONSORT 2010 Statement documents [here](#).
2. **The CONSORT 2010 Explanation and Elaboration (E&E) Document:** This 32-page document provides an explanation of each of the CONSORT Checklist items, and how to apply them in your reporting. You can download the CONSORT 2010 E&E Document [here](#).
3. **The CONSORT 2010 Checklist:** This is a checklist of each of the 25 items that must be reported in a Randomized Clinical Trial Report in order for it to be compliant with the standard. You can see an example of how the CONSORT checklist can be applied to a well-reported study by navigating to the [Sample Study](#) in the menu above. You can download the CONSORT 2010 Checklist [here](#).
4. **The CONSORT 2010 Flow Diagram:** This is a simple flow diagram showing how your study population was recruited and handled during the course of your study. You must complete a flow diagram in order to be compliant with the CONSORT 2010 standard. You can download the CONSORT 2010 Flow Diagram template [here](#).

Dopunsko štivo



BMJ STATISTICS NOTES

www.csm-oxford.org.uk/?o=1292

www.bmj.com/specialties/statistics-notes

How to Upset the Statistical Referee

www-users.york.ac.uk/~mb55/talks/upset.htm

Lang T. Twenty statistical errors even YOU can find in biomedical research articles. Croat Med J 2004;45:361-70.

www.cmj.hr/2004/45/4/15311405.htm

.....

Lako čitljiva literatura.....

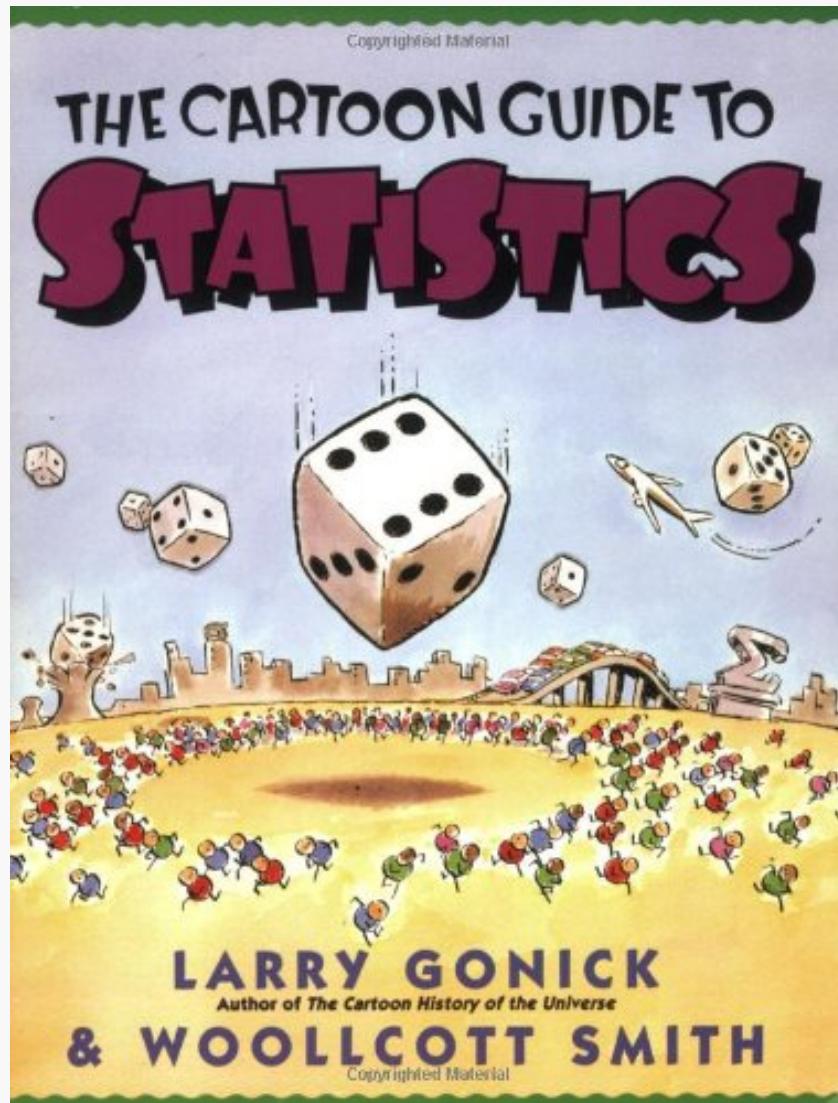
Petz B, Kolesarić V, Ivanec D.

Petzova statistika : osnovne statističke metode za nematematičare. Naklada Slap.

2012.




Ako ništa ne pomaže, pokušajte započeti s



WHAT IS STATISTICS?

WE MUDDLE THROUGH LIFE MAKING CHOICES
BASED ON INCOMPLETE INFORMATION...





SVRHA ISTRAŽIVANJA

- **opis**
 - stanje u populaciji
- **usporedba**
 - novi postupak VS stari postupak
- **povezanost**
 - rizični čimbenik i bolest/stanje

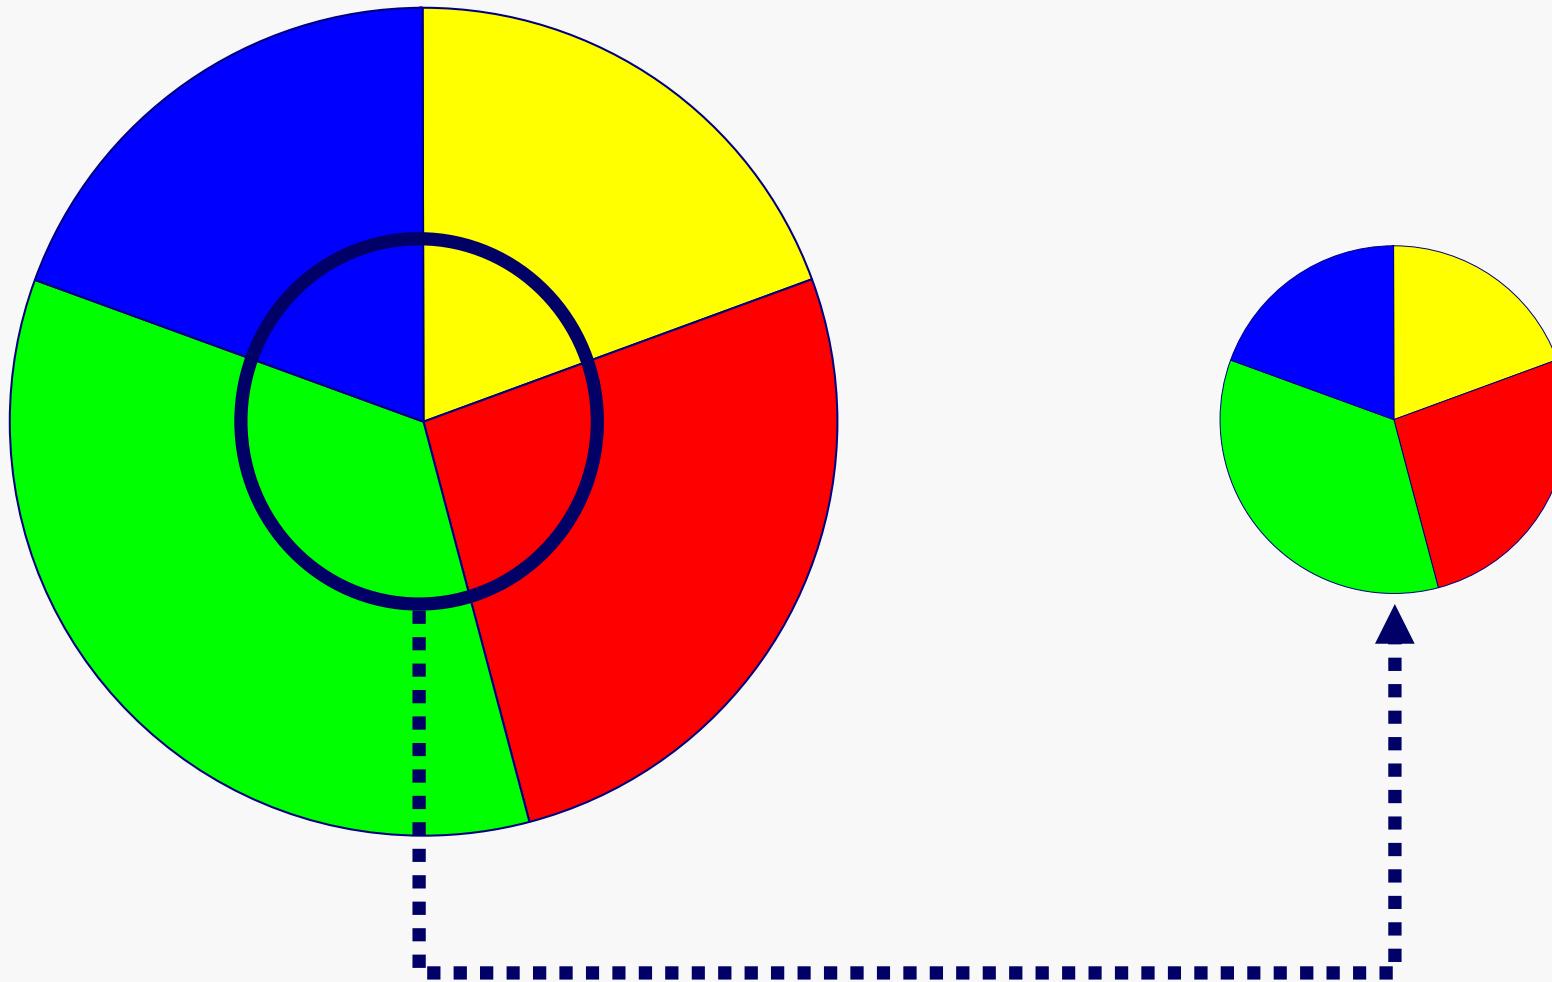
TEMELJNE VRSTE ISTRAŽIVANJA

- **opažajna istraživanja (observational studies)**
 - presječno istraživanje (cross-sectional)
 - istraživanje slučajeva i kontrola (case-control)
 - kohortno istraživanje (cohort)
- **pokusna istraživanja**
 - randomizirani kontrolirani pokus (randomised controlled trial-RCT)



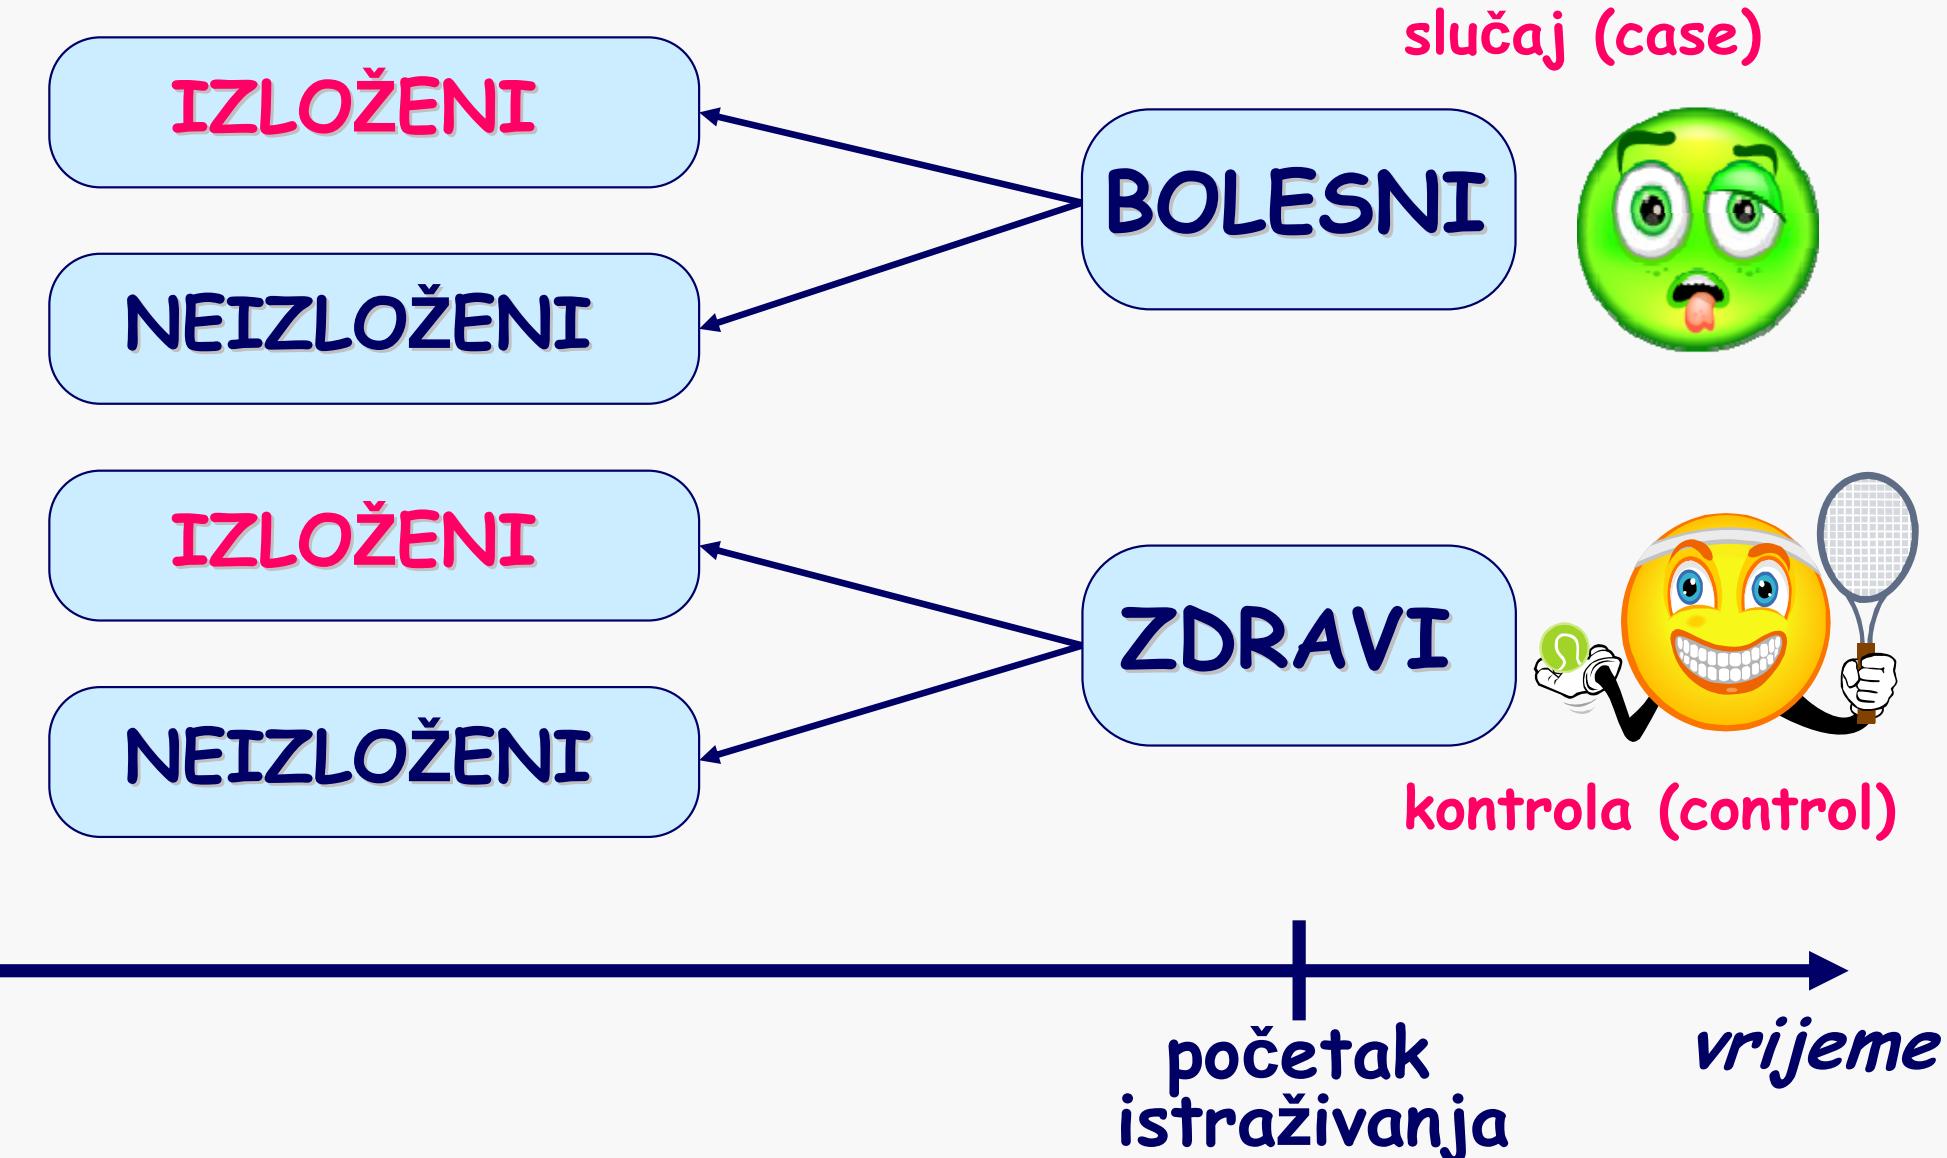
PRESJEČNO ISTRAŽIVANJE (cross-sectional)

"Što se dešava?"



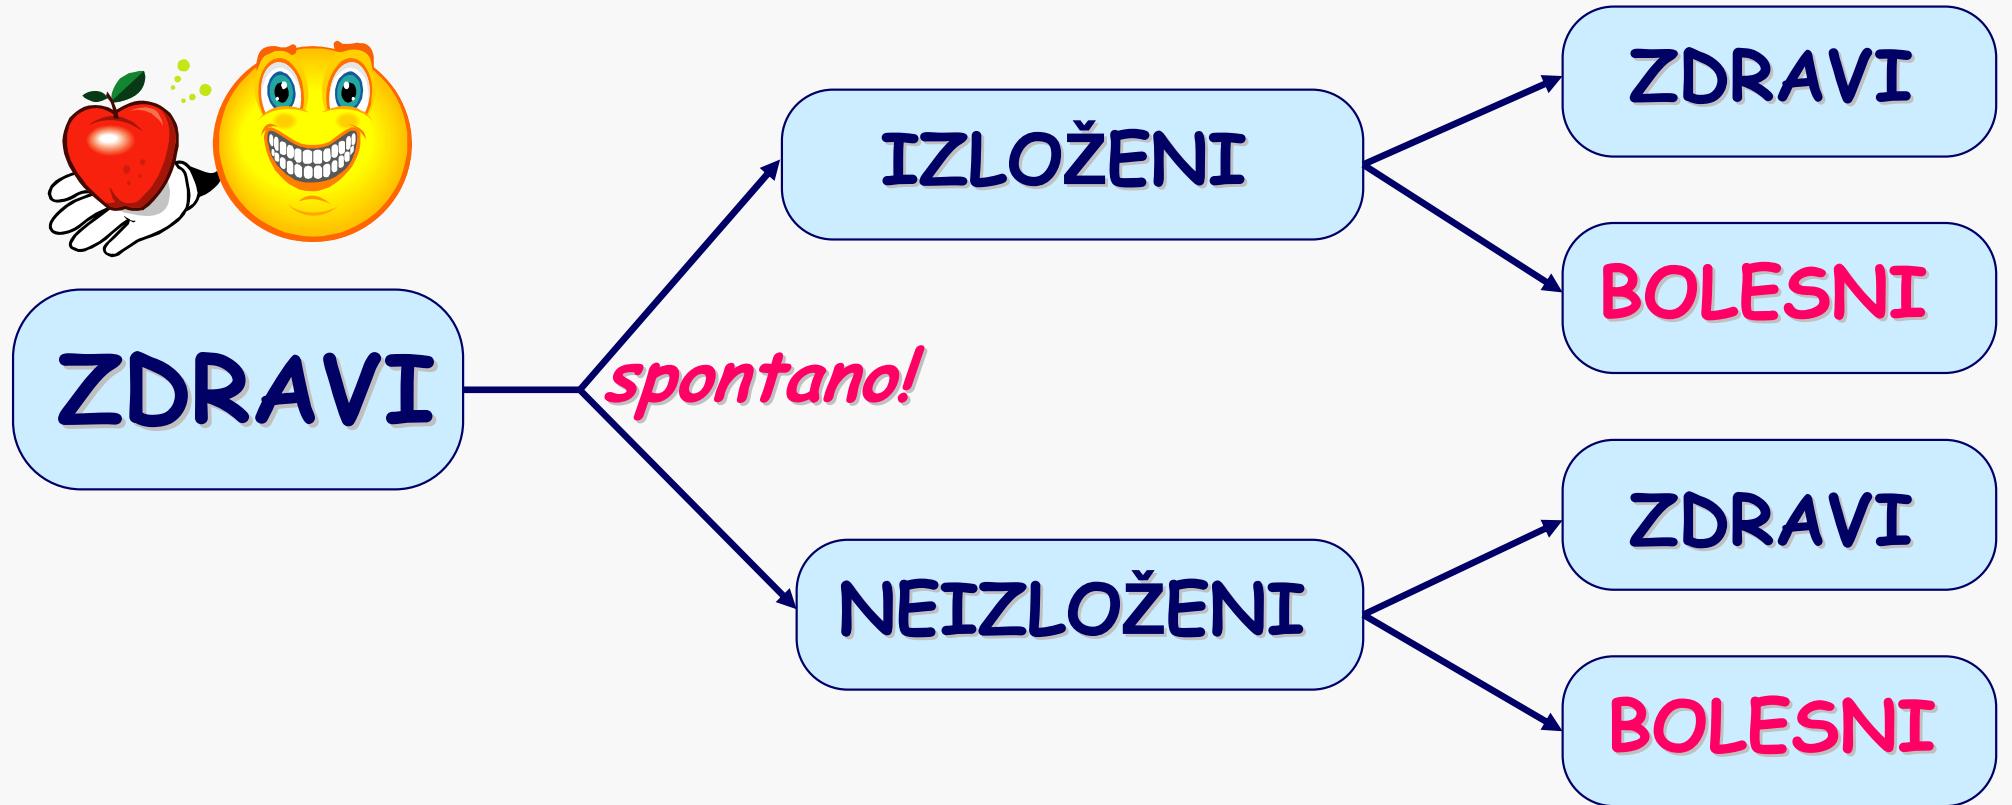
ISTRAŽIVANJE SLUČAJEVA I KONTROLA (case-control)

"Što se desilo?"



KOHORTNO ISTRAŽIVANJE

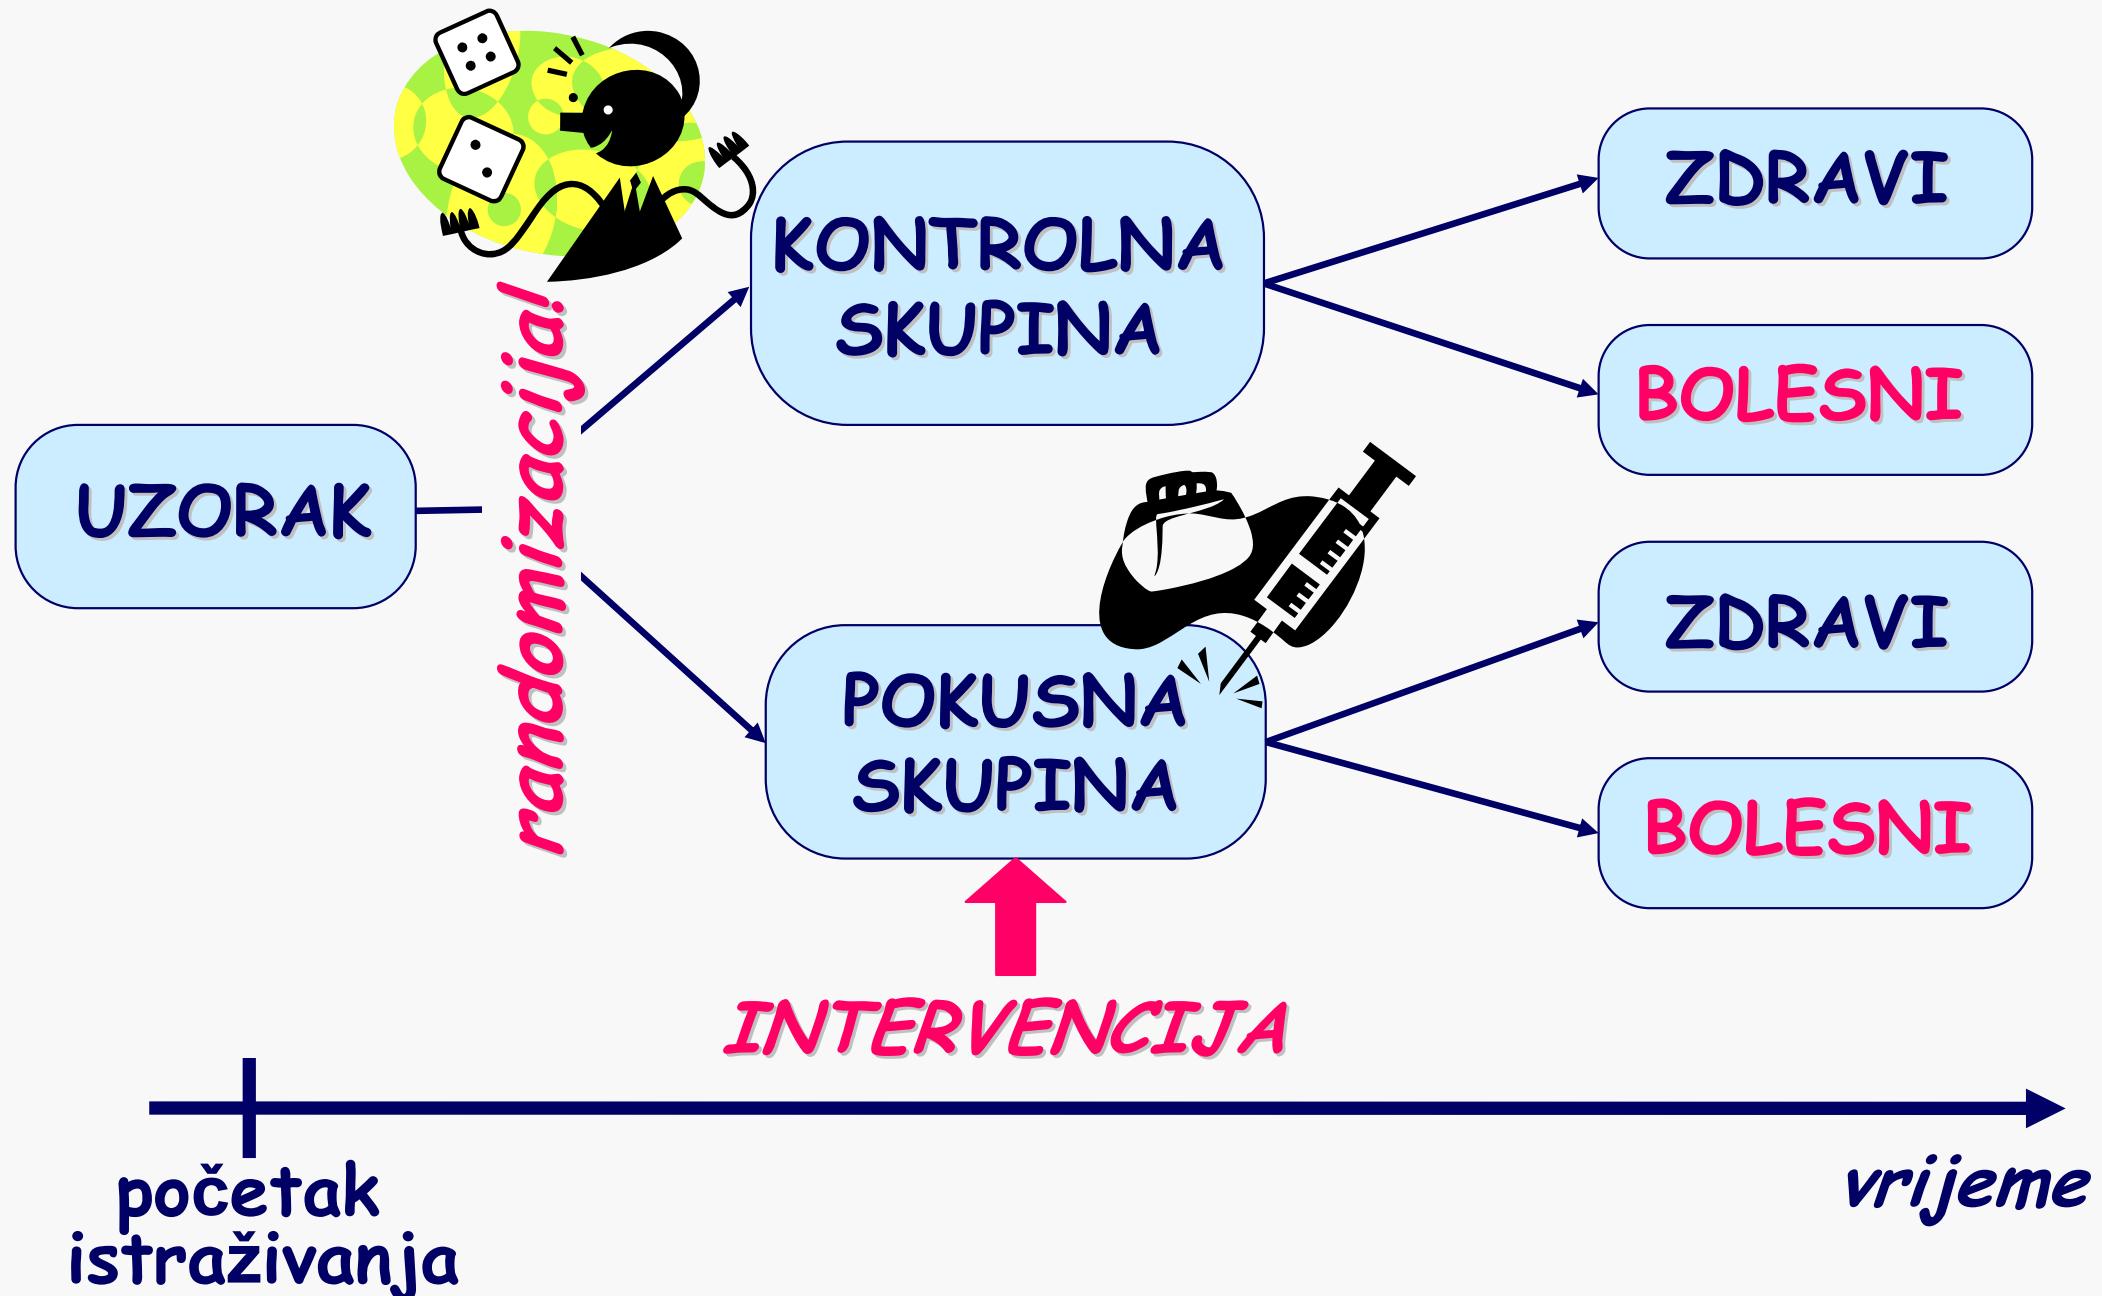
"Što će se desiti?"



početak
istraživanja

vrijeme

RANDOMIZIRANI KONTROLIRANI POKUS (RCT)



PRIKRIVANJE (*masking, blinding*)

- **jednostruko prikriveni (slijepi) pokus**
 - ispitanik ne zna kojoj skupini pripada



- **dvostruko slijepi pokus**
 - niti ispitanik niti istraživač ne znaju kojoj skupini pripada ispitanik

- **trostruko slijepi pokus**
 - niti ispitanik, niti istraživač niti osoba koja obrađuje podatke ne zna tko pripada ispitivanoj skupini



"DOKAZI" IZ ISTRAŽIVANJA

- različite vrste istraživanja donose "dokaze" različite "snage"
- dvostruko slijepi RCT smatra se "zlatnim standardom" za donošenje najsnažnijih uzročno-posljedičnih znanstvenih zaključaka

ISTRAŽIVANJE

"DOKAZNA" SNAGA ISTRAŽIVANJA

OPAŽAJNO

bez kontrole

slučajeva i kontrola

kohortno

POKUSNO

ne randomizirana kontrola

randomizirana
kontrola
(RCT)

bez prikrivanja

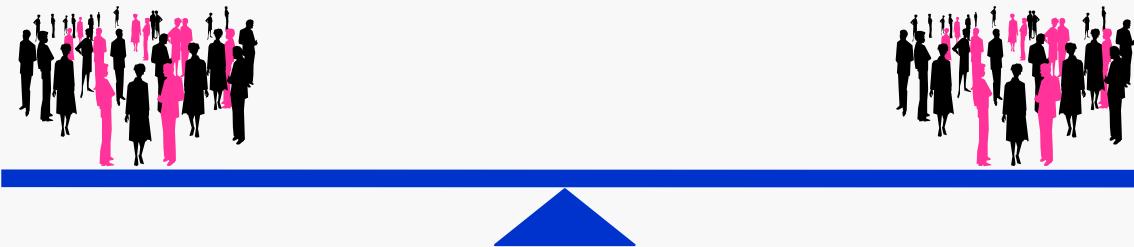
jednostruko slijepi

dvostruko slijepi



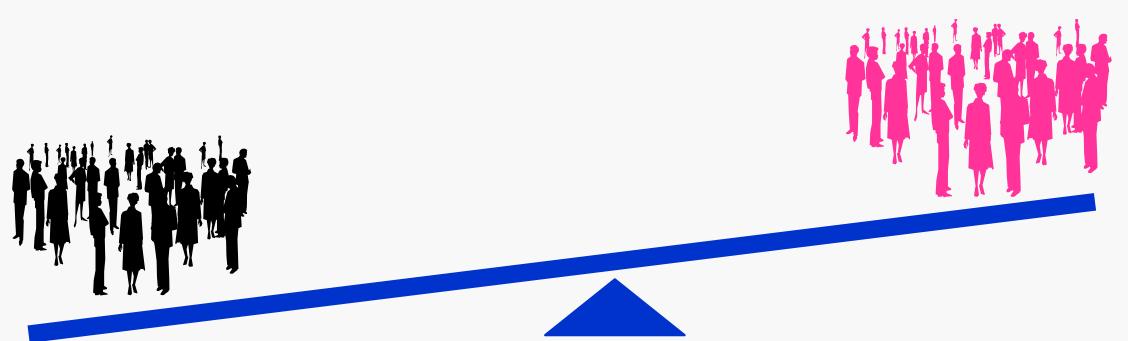
ZAŠTO JE POTREBNA RANDOMIZACIJA (nasumični odabir)?

- slučajnost izbora u postupku izbora grupa (tko dobiva koji tretman) izjednačava grupe s obzirom na poznate i nepoznate prognostičke faktore



"POŠTENO"!

PRISTRANO!



RANDOMIZACIJA (nasumični odabir)


- generatori slučajnih brojeva
 - mjerenja fizikalnih pojava (atmosferski šum, terbalni šum, ...)
 - matematički algoritmi (pseudo-slučajni brojevi)
- biranje slučajnih brojeva:
 - Excel: RAND(), RANDBETWEEN()
 - <https://www.random.org/>
 - <http://www.graphpad.com/quickcalcs/randMenu/>
 - <http://www.randomizer.org/>

ZAŠTO JE POTREBNO PRIKRIVANJE?



- prikrivanje alokacije tretmana je dio dobrog nacrta studije
- izbjegavaju se moguće optužbe za pristranost ukoliko niti ispitanici niti ispitivači ne znaju pripadnost pojedinim grupama
- dvostruko slijepi pokus je najbolji način da se očuva znanstvena strogost RCT

STATISTIKA?



....neki razlozi - praćenje literature....

“ ...povećan je rizik koronarnog incidenta kod bolesnika čija je koncentracija CRP u petoj kvantili u odnosu na prve četiri kvantile...”

“ ...srednja vrijednost dobi 42 ± 8 godina...”

“ ...značajnost razlike testirana je Studentovim T-testom...”

“ ... $p < 0.05$...”

Multiple R	.96764
R Square	.93632
Adjusted R Square	.92883
Standard Error	6.54079

....neki razlozi - deskripcija i analiza rezultata....

Rezultati mjerenja visine studenata prve godine:

188	175	179	179	173	193	183	177	165	170
165	164	168	182	193	183	160	183	165	166
168	172	178	193	167	174	176	176	172	181
169	172	184	190	182	176	176	164	162	167
189	187	168	175	173	182	175	165	167	181

Tko je najviši ? Tko je najniži ?

Koju visinu ima najveći broj studenata?

Kako varira visina studenata?

Koja je visina kojoj teži najveći broj rezultata?

?????

?

neki razlozi - zaključivanje iz pojedinačnog na “opće”..

Kada i pod kojim uvjetima možemo zaključivati o populaciji iz rezultata mjerjenja provedenih na nekoj skupini ispitanika?

Kako odabratи испитанike?

Koliko испитаника uključiti u promatranje?

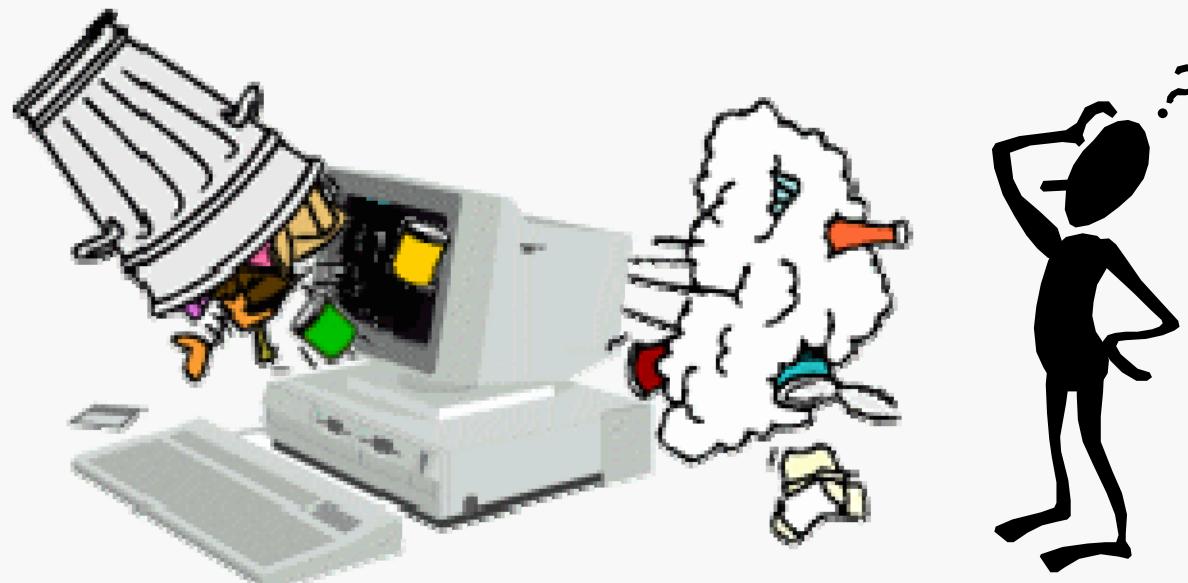
Kolika je pogreška pri zaključivanju?

...



neki razlozi - planiranje istraživanja i pokusa

- metoda "što ispadne" u istraživanju i eksperimentu može rezultirati nepouzdanim i neinterpretabilnim rezultatima





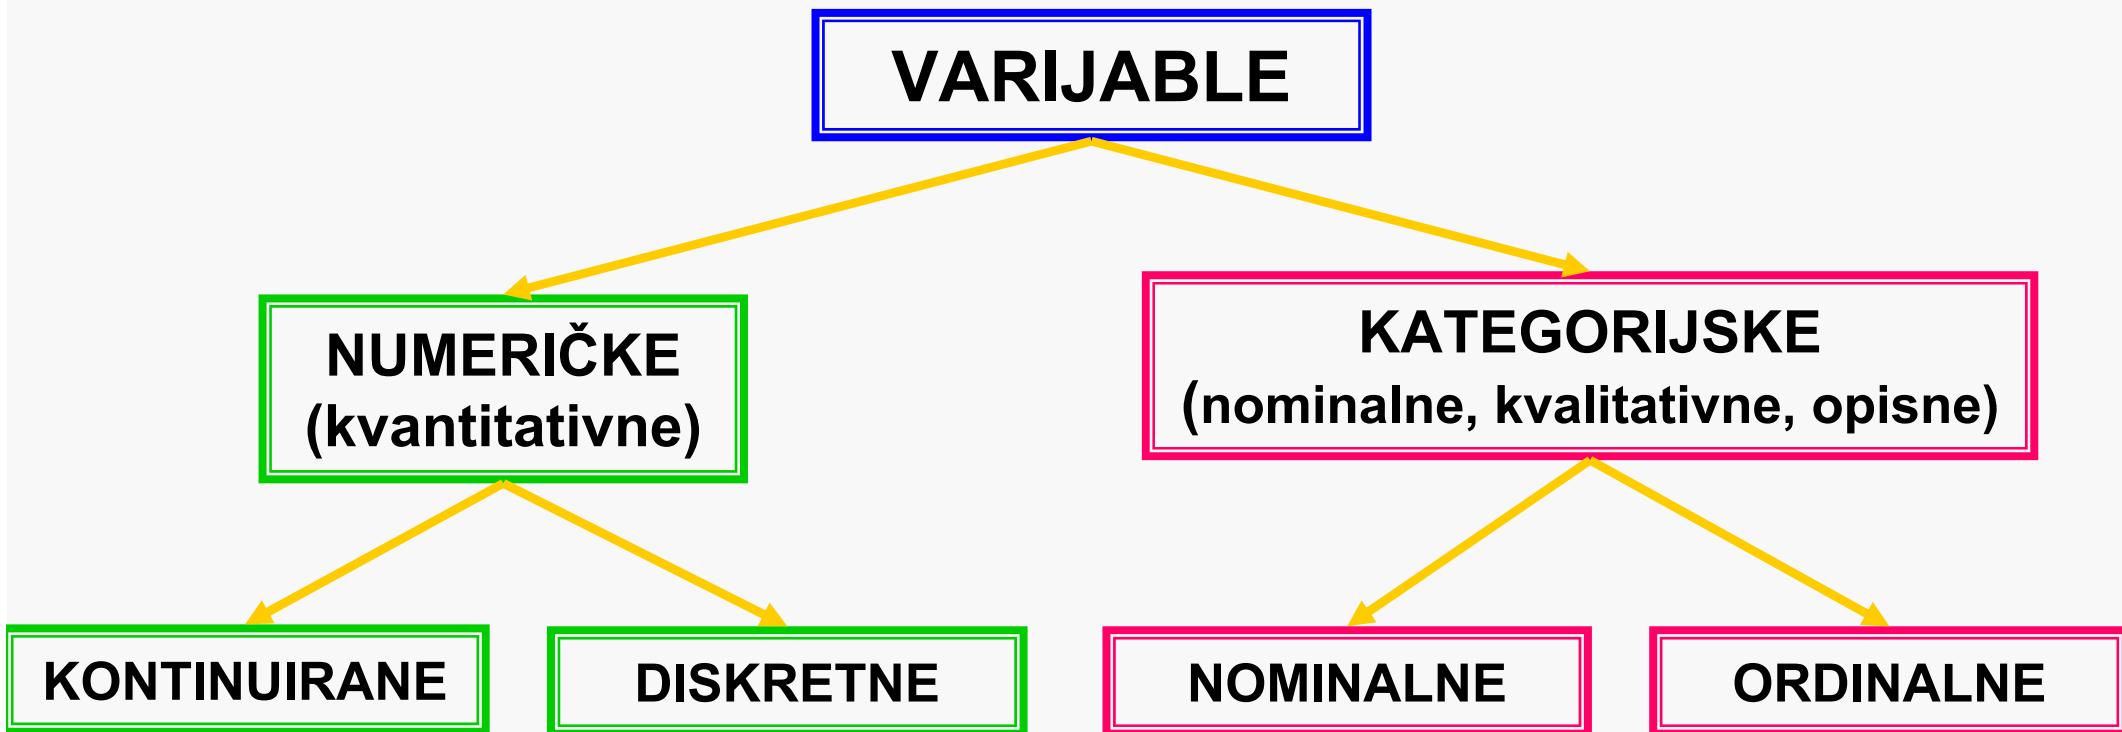
Sir Ronald Aylmer Fisher (1890. –1962.)

“To consult the statistician after an experiment is finished is often merely to ask him to conduct a *post mortem* examination.

He can perhaps say what the experiment died of.”

R. A. Fisher, 1938.

VARIJABLE



Kvantitativne (numeričke) varijable

- **kontinuirane varijable**

- varijable koje teorijski prepostavljaju postojanje beskonačnog broja vrijednosti
- **u pravilu dobivene mjerenjem**
 - visina, težina, dob, tlak,

- **diskretne varijable**

- varijable čija se vrijednost uvećava ili umanjuje za cijeli broj jedinica
- **u pravilu dobivene brojanjem**
 - broj popuštenih cigareta na dan, broj otkucaja srca u minuti, broj djece, broj proteinskih obroka tjedno,....


Kvalitativne (opisne) varijable

- **bez redosljeda (*nominalne*)**
 - bračno stanje, spol, krvna grupa, zanimanje, radni status,
- **s poznatim redosljedom (*ordinalne*)**
 - samostalnost: nije ovisan, ovisan u manjem stupnju, ovisan u višem stupnju, ovisan u visokom stupnju, potpuno ovisan
 - sluh: dobar, oštećen, gluhi
 -
- **dvije kategorije (*binarne, dihotomne*)**
 - spol (muški/ženski), pušač (da/ne), nesanica (da/ne),....

LJESTVICE MJERENJA


2 1 3

1. nominalna




2. ordinalna

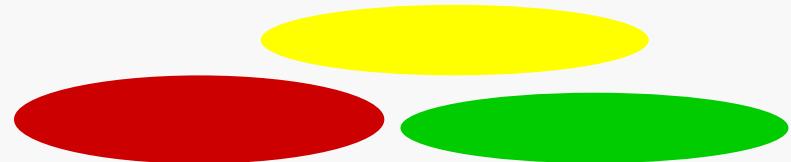
3. intervalna



4. omjerna



1. Nominalna ljestvica



- kategorizacija kojom objektima ili događajima pridružujemo riječi ili simbole
- nema informacije o veličini pojedinačnog rezultata

spol (muški/ženski)

ishod bolesti (preživljavanje/smrt)

boja očiju (plava, crna, smeđa,)

2. Ordinalna ljestvica

2


1

3

- ima sve karakteristike nominalne ljestvice i dodatno uključuje **redoslijed** (nominalna + rangiranje)
- intervali nisu jednaki, a granice među grupama nisu čvrste
- nema informacije o “jačini” razlike između pojedinih grupa

stupanj opekotine (prvi, drugi, treći)
ocjene na ispitu

3. Intervalna ljestvica



- ljestvica sa jednakim intervalima koji imaju definirane granice => **razlike imaju smisla**
- nema absolutnu nulu (moguće su i negativne vrijednosti) => **omjeri nemaju smisla**

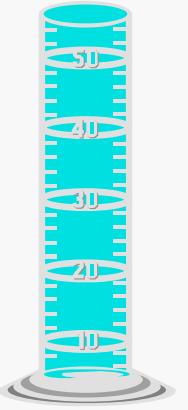
temperatura, kvocijent inteligencije

$$100^{\circ}\text{F} \neq 2 \cdot 50^{\circ}\text{F} \quad \text{jer je} \quad 100^{\circ}\text{F} = 38^{\circ}\text{C}$$

$$50^{\circ}\text{F} = 10^{\circ}\text{C}$$

$$\left(\frac{t^{\circ}\text{C}}{100} = \frac{t^{\circ}\text{F} - 32}{180} \right)$$

4. Omjerna ljestvica



- ima sva svojstva intervalne ljestvice ali i absolutnu nulu => **omjeri imaju smisla**
- nula znači totalnu odsutnost obilježja

visina, težina, dob

$$90\text{kg} = 3 * 30\text{kg}$$

$$3174.653\text{oz} = 3 * 1058.218\text{oz}$$

$$(1\text{kg}=35.27392\text{oz})$$

Još neke vrste podataka...

- **postotci ili proporcije** (*percentages or proportions*)
 - odnos dijela prema cjelini
 - omjer dva istovrsna podatka

ejekcijska frakcija, ...

- **omjeri** (*ratios*)
 - omjer dva raznovrsna podatka (može biti i omjer dviju varijabli)

BMI

...još neke vrste podataka...

- **stope** (rates)
 - odnos opaženog broja pojave nekog svojstva prema jedinici populacije nekog područja u nekom vremenskom periodu

morbiditet, mortalitet,...

- za izračunavanje stope trebamo:
 - **broj** pojave svojstva (npr. broj oboljelih)
 - **skup** u kojem se to obilježje pojavljuje (npr. broj stanovnika nekog područja)
 - **specifikaciju vremena i prostora** (npr. Slavonija, 1992.)

...još neke vrste podataka...

- **skorovi** (scores)
 - rezultat zbrajanja vrijednosti dodijeljenih kategorijama varijabli od interesa

Apgar, GCS, ...

...još neke vrste podataka...

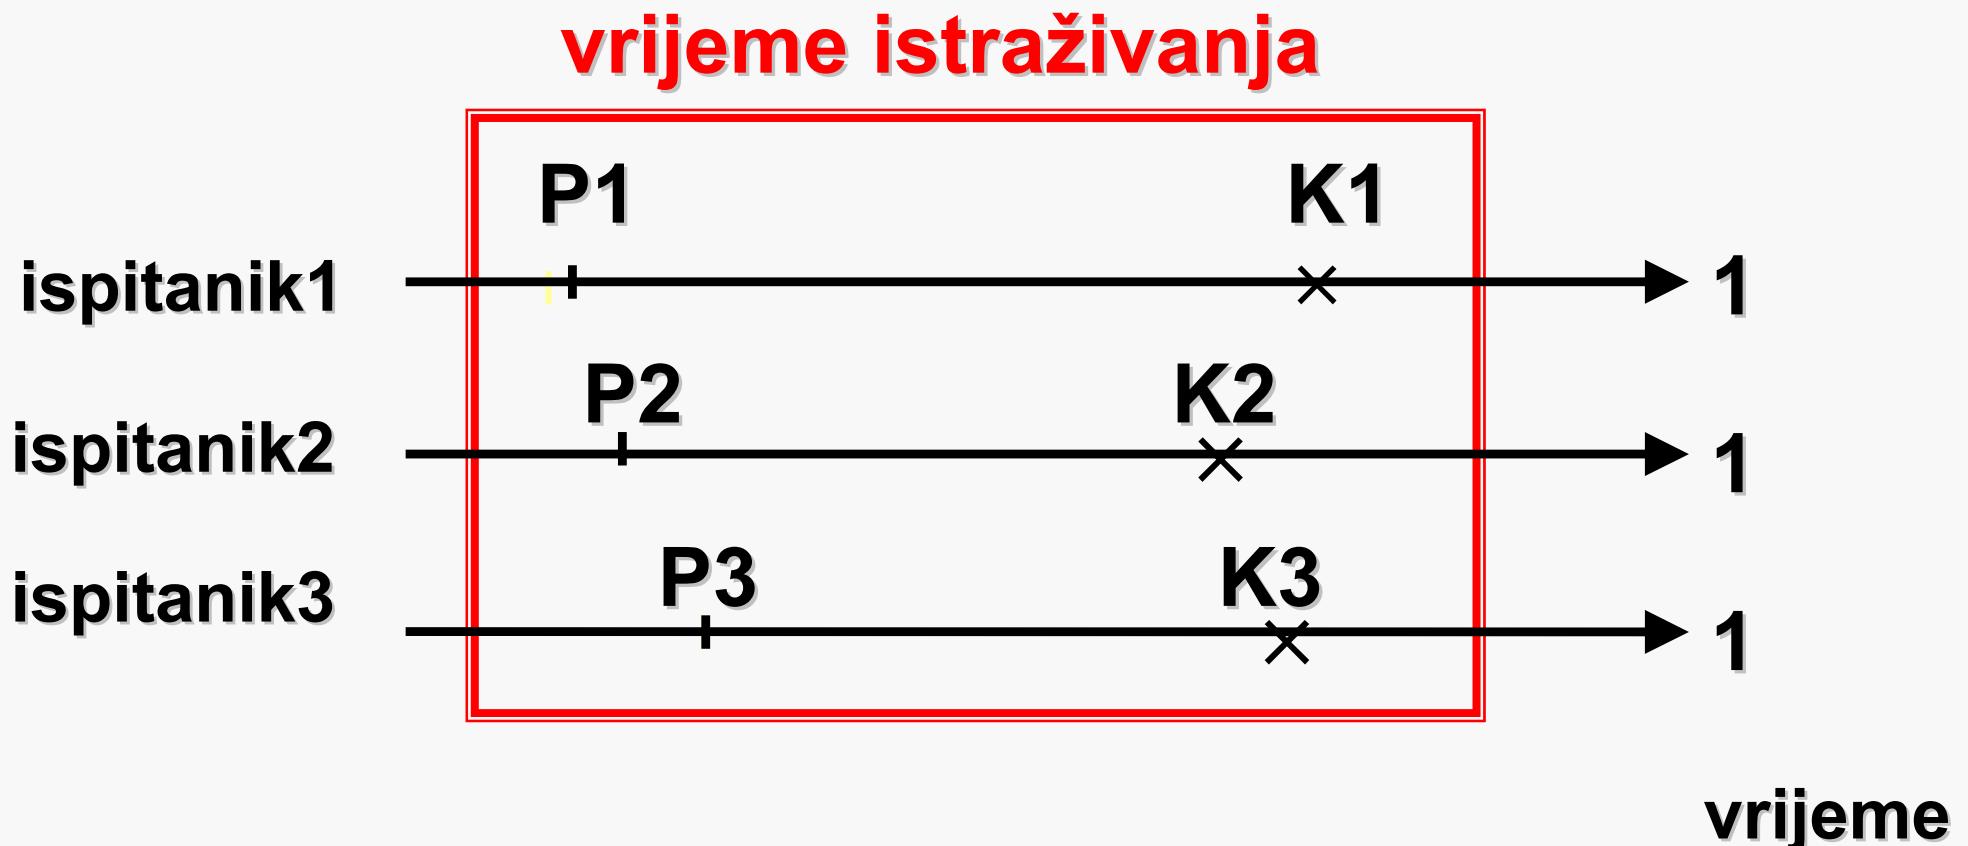
- **cenzorirani** (censored)
 - podatci koji se ne mogu točno izmjeriti, ali je poznato da prelaze neku granicu mjerenja
- najčešće se pojavljuju:
 - u laboratorijskim mjerenjima – vrijednosti ispod/iznad mogućnosti detekcije nekog uređaja
 - u studijama praćenja (follow-up):
 - očekivano svojstvo se nije pojavilo u promatranom periodu
 - ispitanik uključen u istraživanje je iz nekog razloga izuzet prije završetka istraživanja

Cenzuriranje

- događaj se ostvaruje = 1
- sve ostalo = 0 (cenzurirani podatci)


Cenzuriranje

- **potpuni podatci** (potpuno praćenje)
 - događaj se ostvario u promatranom vremenu istraživanja



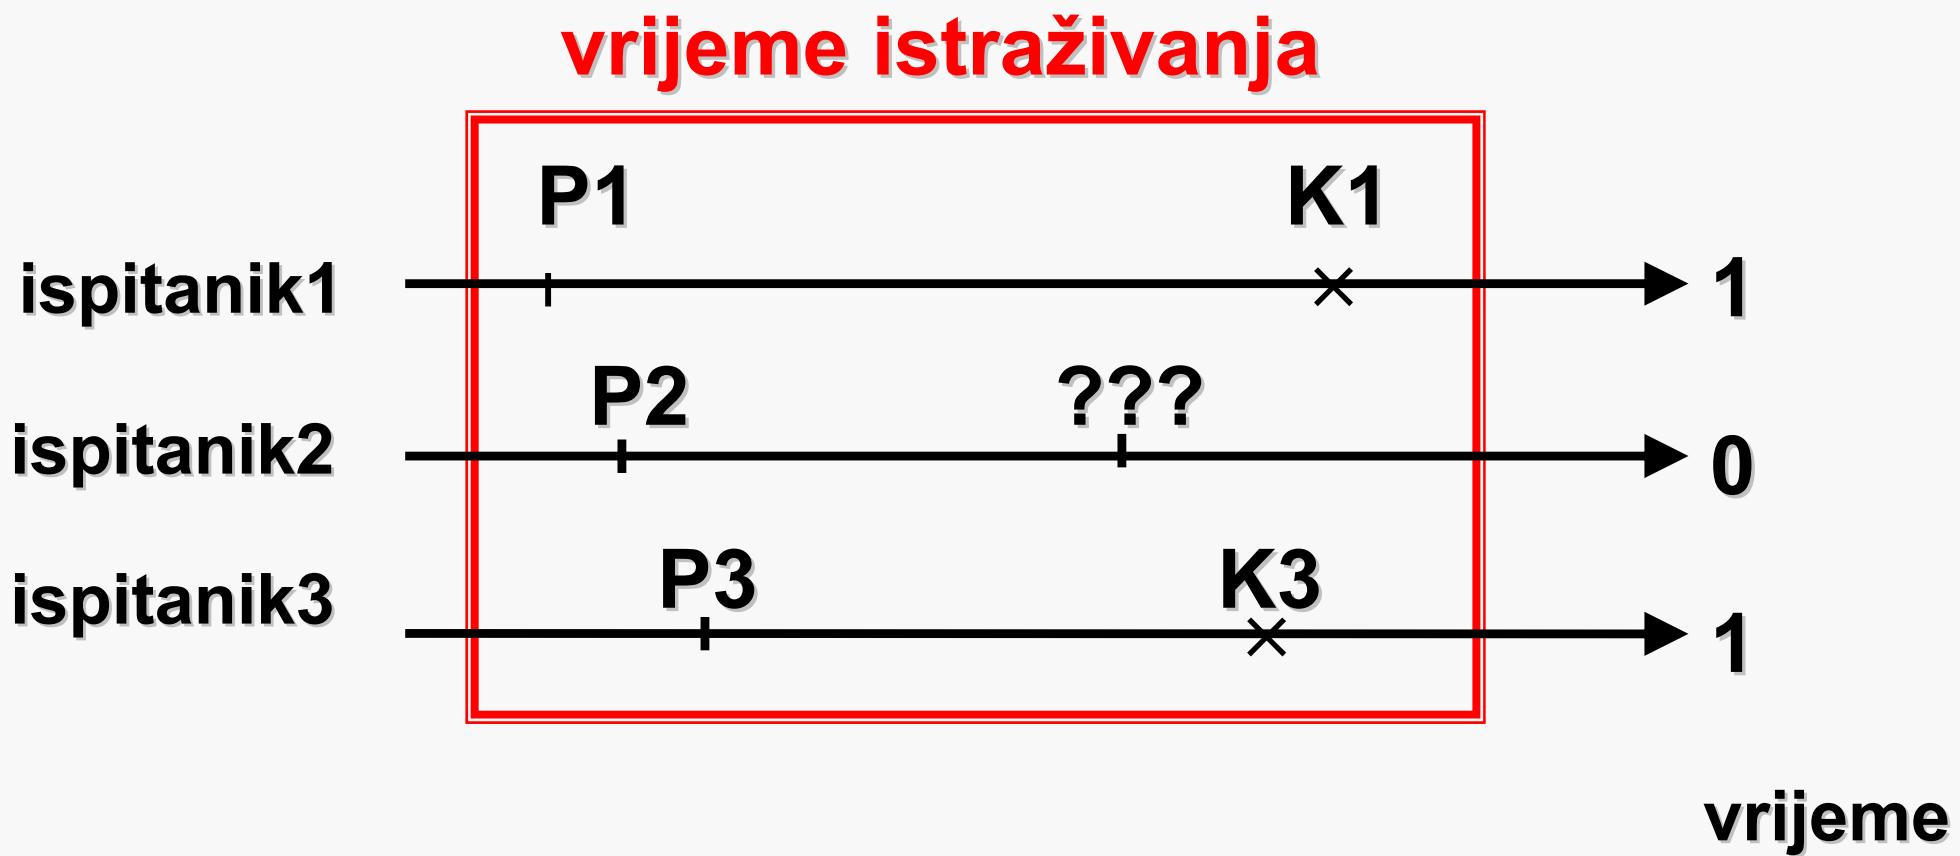
Cenzuriranje

- **cenzurirani podatci** (nepotpuni podatci)
 - za neke ispitanike događaj se ostvario IZVAN okvira promatranog vremena istraživanja




Cenzuriranje

- cenzurirani podatci (nepotpuni podatci)
 - izgubljeni ispitanici ("lost to follow-up")



Cenzuriranje

- **cenzurirani podatci** (nepotpuni podatci)
 - ispitanici koji iz nekih razloga ne mogu više biti praćeni (promjena mjesta boravka, smrt iz razloga nepovezanih s promatranim događajem)



Razlozi VIP tretmana cenzuriranih podataka


- ocjena sredine -

- **aritmetička sredina vremena preživljenja (od postavljanja dijagnoze) oboljelih od određene vrste karcinoma:**
 - srednje vrijeme preživljenja ovisi o tome KADA su podatci analizirani
 - nema smisla dok SVI ispitanici ne umru
- **medijan vremena preživljenja (od postavljanja dijagnoze) oboljelih od određene vrste karcinoma:**
 - može se procijeniti nakon što je POLOVINA ispitanika umrla
- **čekati????**

Razlozi VIP tretmana cenzuiranih podataka

- **čovjek-godine:**
 - svaki ispitanik doprinosi ukupnom vremenu preživljenja svojim vremenom provedenim u studiji (npr. 26 ispitanika promatrani su tijekom studije ukupno 336 mjeseci)
- **čovjek-godine:** suma vremena provedenih u studiji SVIH ispitanika svedena na godine:
$$336/12 = 28 \text{ čovjek-godina}$$
- **problem:** je li 1 čovjek praćen 28 godina ili 28 ljudi 1 godinu ili ???
- usporedba????

RAZDIOBA OBILJEŽJA



Na jednom čovjeku izvršeno je 50 mjerena vremena reakcije. Dobiveni su sljedeći podaci (u tisućinkama sekunde):

196	173	186	189	173	165	167	160	140	174
180	151	157	164	154	169	190	180	163	157
169	167	165	160	177	165	157	177	159	175
166	173	185	177	184	183	162	192	174	162
165	172	158	169	146	170	171	169	168	153



TABLICA FREKVENCIJA

- tablica u kojoj su originalni podaci sažeti u određeni broj kategorija (*razreda*) koje su opisane numerički izraženim granicama

raspon (interval) razreda

- razlika granica razreda

sredina razreda

- broj koji najbolje reprezentira dani razred

računanje sredine razreda:

- *diskretne varijable:*

suma granica razreda / 2

- *kontinuirane varijable:*

suma donjih granica razreda / 2

apsolutna frekvencija razreda(f)

- broj podataka koji pripadaju intervalu tog razreda

kumulativna frekvencija razreda(cf)

- broj podataka čija je vrijednost manja ili jednaka gornjoj granici razreda

relativna frekvencija razreda (rf)

- **apsolutna frekvencija razreda podijeljena s ukupnim brojem podataka**

kumulativna relativna frekvencija razreda (crf)

- **kumulativna frekvencija razreda podijeljena s ukupnim brojem podataka**

za dani razred:

- **apsolutna frekvencija:**
 - koliko mjerenja ima vrijednosti iz intervala tog razreda
- **apsolutna kumulativna frekvencija:**
 - koliko mjerenja ima vrijednost manju ili jednaku gornjoj granici tog razreda
- **relativna frekvencija:**
 - koliki udio (postotak) mjerenja od ukupnog broja mjerenja ima vrijednost iz intervala tog razreda
- **kumulativna relativna frekvencija:**
 - koliki udio (postotak) mjerenja od ukupnog broja mjerenja ima vrijednost manju ili jednaku gornjoj granici tog razreda

Tablica frekvencija podataka iz primjera


min = 140

max = 196

Broj r.	Granice r.	Sredina r.	f	cf	rf	crf
1	140 – 144	142	1	1	0,02	0,02
2	145 – 149	147	1	2	0,02	0,04
3	150 – 154	152	3	5	0,06	0,10
4	155 – 159	157	5	10	0,10	0,20
5	160 – 164	162	6	16	0,12	0,32
6	165 – 169	167	12	28	0,24	0,56
7	170 – 174	172	8	36	0,16	0,72
8	175 – 179	177	4	40	0,08	0,80
9	180 – 184	182	4	44	0,08	0,88
10	185 – 189	187	3	47	0,06	0,94
11	190 – 194	192	2	49	0,04	0,98
12	195 – 199	197	1	50	0,02	1,00
UKUPNO :			50		1,00	


RAZDIOBA FREKVENCIJA

HISTOGRAM FREKVENCIJA




GRAFIČKI PRIKAZ RAZDIOBE


POLIGON FREKVENCIJA




POLIGON KUMULATIVNIH FREKVENCIJA



POLIGON RELATIVNIH FREKVENCIJA



POLIGON KUMULATIVNIH RELATIVNIH FREKVENCIJA



Stablo i list (stem-and-leaf)

f	stablo	list
1.00	14 . 0	
1.00	14 . 6	
3.00	15 : 134	
5.00	15 : 77789	
6.00	16 : 002234	
12.00	16 : 555567789999	
8.00	17 : 01233344	
4.00	17 : 5777	
4.00	18 : 0034	
3.00	18 : 569	
2.00	19 : 02	
1.00	19 : 6	

PAŽNJA !

– broj razreda

- **preveliki broj razreda => male frekvencije ili prazni razredi**
- **premali broj razreda => razredi jako sažeti => izgubljeno puno informacija**
- **uobičajeno: 10-20 razreda** (ovisno o broju i prirodi podataka)
- **kod nominalnih varijabli:**
broj kategorija=broj razreda

PAŽNJA !

– granice razreda

- najmanje na onoj točnosti na kojoj je izvršeno mjerjenje**
- određene tako da SVAKI PODATAK PADNE U SAMO JEDAN OD RAZREDA!**

OPISIVANJE RAZDIOBE PODATAKA

PARAMETAR I STATISTIKA

POPULACIJA



1.UZORAK



2.UZORAK

:
:
:



n-ti UZORAK

PARAMETAR I STATISTIKA



aritmetička sredina
visine populacije
 $= 175.4$



aritmetička sredina
visine 1. uzorka
 $= 172.2$



aritmetička sredina
visine 2. uzorka
 $= 178.1$



aritmetička sredina
visine n-tog uzorka
 $= 173.7$


PARAMETAR I STATISTIKA

- **parametar:**
 - vrijednost (obično nepoznata) koja predstavlja neku karakteristiku populacije
 - unutar populacije, parametar je nepromjenljiva vrijednost koja NE VARIRA
- **statistika:**
 - veličina izračunata iz podataka izmjerenih na uzorku
 - vrijednost statistike MIJENJA SE od uzorka do uzorka


Uobičajene oznake:

	OCJENA PARAMETRA (STATISTIKA)	PARAMETAR POPULACIJE
ARITMETIČKA SREDINA	\bar{x}	μ
STANDARDNA DEVIJACIJA	s	σ
PROPORCIJA	p	π

OPISIVANJE RAZDIOBE PODATAKA



- sredina
- varijabilnost
- oblik



MJERE SREDINE (centralne tendencije)

(srednje vrijednosti, prosjeci, mjere lokacije)

ARITMETIČKA SREDINA

$$\mu = \frac{x_1 + x_2 + \dots + x_N}{N} = \frac{\sum_{i=1}^N x_i}{N}$$

MEDIJAN (središnja vrijednost)

- vrijednost koja se u nizu podataka poredanih po veličini nalazi na srednjem mjestu
- dijeli podatke "na pola"

MOD (dominantna ili tipična vrijednost)

GEOMETRIJSKA SREDINA

$$G = \sqrt[N]{x_1 \cdot x_2 \cdot \dots \cdot x_N}$$

HARMONIJSKA SREDINA

$$H = \frac{N}{\sum_{i=1}^N \frac{1}{x_i}}$$

ARITMETIČKA SREDINA

- oznake: \bar{X} uzorak μ populacija

ARITMETIČKA SREDINA INDIVIDUALNIH PODATAKA

$$\mu = \frac{x_1 + x_2 + \dots + x_N}{N} = \frac{\sum_{i=1}^N x_i}{N}$$

x_i ... vrijednosti mjerenog obilježja
 N ... ukupan broj podataka

Primjer

Kolika je aritmetička sredina niza podataka:

1, 2, 3, 3, 4, 5?

$$\bar{x} = \frac{x_1 + x_2 + x_3 + x_4 + x_5 + x_6}{6} =$$

$$= \frac{1 + 2 + 3 + 3 + 4 + 5}{6} = \frac{18}{6} = 3$$

Kolika je aritmetička sredina niza podataka:

1, 1, 1, 1, 2, 12?

$$\bar{x} = \frac{1 + 1 + 1 + 1 + 2 + 12}{6} = \frac{18}{6} = 3$$

A:	1	2	3	3	4	5
B:	1	1	1	1	2	12

aritmetička sredina niza A = 3

aritmetička sredina niza B = 3



- loše opisuje niz B
- veliki utjecaj ekstremne vrijednosti (12)

ARITMETIČKA SREDINA GRUPIRANIH PODATAKA

$$\mu = \frac{f_1 x_{S1} + f_2 x_{S2} + \dots + f_k x_{Sk}}{N} = \frac{\sum_{i=1}^k f_i x_{Si}}{N}$$

f_i ... frekvencija i-tog razreda

x_{Si} ... sredina i-tog razreda

k ... broj razreda

N ... ukupan broj podataka


Kolika je aritmetička sredina podataka u sljedećoj tablici:

x	1	2	3	4	5	6	7	8	9	10	11	12	13	14
f	33	31	30	12	12	10	9	9	9	8	7	7	6	3
f·x	33	62	90	48	60	60	63	72	81	80	77	84	78	42

$$\sum_{i=1}^{14} f_i = 186$$

$$\sum_{i=1}^{14} f_i \cdot x_i = 930$$

$$\bar{x} = \frac{930}{186} = 5$$



➤ razdioba frekvencija nije simetrična
 => primjer lošeg opisivanja rezultata aritmetičkom sredinom

ZAJEDNIČKA ARITMETIČKA SREDINA

*(aritmetička sredina aritmetičkih sredina,
ponderirana aritmetička sredina)*

$$\bar{x}_{zaj} = \frac{\bar{x}_1 N_1 + \bar{x}_2 N_2 + \dots + \bar{x}_n N_n}{\sum_{i=1}^n N_i} = \frac{\sum_{i=1}^n \bar{x}_i N_i}{\sum_{i=1}^n N_i}$$

x_i ... aritmetička sredina dobivena iz N_i mjerjenja
 n ... broj skupina mjerjenja

Dva studenta studija sestrinstva postigla su sljedeći uspjeh u V semestru studija:

PREDMET	OCJENA		ECTS
	STUDENT 1	STUDENT 2	
Osnove istraživačkog rada	2	5	4
Zdravstvena njega odraslih II	5	2	9
Zdravstvena njega psihijatrijskih bolesnika	5	3	8
Klinička medicina III	3	5	4

Koji je student postigao bolji uspjeh u V semestru?

PREDMET	OCJENA		ECTS
	STUDENT 1	STUDENT 2	
Osnove istraživačkog rada	2	5	4
Zdravstvena njega odraslih II	5	2	9
Zdravstvena njega psihijatrijskih bolesnika	5	3	8
Klinička medicina III	3	5	4
Σ	15	15	25

$$\text{uspjeh } s_1 = \frac{2 \cdot 4 + 5 \cdot 9 + 5 \cdot 8 + 3 \cdot 4}{25} = \frac{105}{25} = 4.20$$

$$\text{uspjeh } s_2 = \frac{5 \cdot 4 + 2 \cdot 9 + 3 \cdot 8 + 5 \cdot 4}{25} = \frac{82}{25} = 3.28$$

U dva navrata vršeno je mjerjenje neke dužine i dobiveni su slijedeći rezultati:

$$\bar{x}_1 = 20\text{cm} ; N_1 = 15$$

$$\bar{x}_2 = 23\text{cm} ; N_2 = 60$$


- a) Kolika je zajednička aritmetička sredina?
- b) Kolika je zajednička aritmetička sredina za $N_1=60; N_2=15$?

$$a) \bar{x}_{zaj} = \frac{20 \cdot 15 + 23 \cdot 60}{15 + 60} = \frac{300 + 1380}{75} = 22.4\text{cm}$$

$$b) \bar{x}_{zaj} = \frac{20 \cdot 60 + 23 \cdot 15}{15 + 60} = \frac{1200 + 354}{75} = 20.6\text{cm}$$



aritmetička sredina osjetljiva je **ne samo na vrijednost nego i na broj podataka**



Aritmetička sredina nema smisla, tj. nije dobar reprezentant podataka ako je:

- razdioba asimetrična
- broj podataka mali, a varijabilnost velika
(velike razlike u vrijednostima podataka)

Imamo niz podataka:

$$A: 2 \quad 2.5 \quad 3.5 \quad 3 \quad 4$$

Kolika je suma odstupanja pojedinačnih vrijednosti od aritmetičke sredine? Kolika je suma kvadrata odstupanja pojedinačnih vrijednosti od aritmetičke sredine te od vrijednosti 2; 4; 5?

$$(2-3)+(2.5-3)+(3.5-3)+(3-3)+(4-3) = -1-0.5+0.5+0+1 = 0$$

x_i	$(x_i-3)^2$	$(x_i-2)^2$	$(x_i-4)^2$	$(x_i-5)^2$
2	1	0	4	9
2.5	0.25	0.25	2.25	6.25
3	0	1	1	4
3.5	0.25	2.25	0.25	2.25
4	1	4	0	1
Σ	2.5	7.5	7.5	22.5

SVOJSTVA ARITMETIČKE SREDINE



$$\sum_{i=1}^N (x_i - \mu) = 0$$

$$\sum_{i=1}^N (x_i - \mu)^2 < \sum_{i=1}^N (x_i - a)^2, \forall a \neq \mu$$

MEDIJAN (središnja vrijednost)

- vrijednost koja se u nizu podataka poredanih po veličini nalazi točno u sredini – **središnja vrijednost po položaju**
- **vrijednost medijana:**
 - za *neparan N*: vrijednost koja se nalazi na $(N+1)/2$ mjestu
 - za *paran N*: sredina vrijednosti podataka koji se nalaze na $N/2$ i $(N+2)/2$ mjestu

MEDIJAN (središnja vrijednost)

- prednosti:
 - na vrijednost medijana **ne utječu ekstremne vrijednosti**
 - ⇒ **pogodan** kao mjera centralne tendencije kod **asimetričnih raspodjela**

oznaka: M_e (C , M_d)

PRIMJER

Za nizove podataka iz primjera:

A: 1 2 3 3 4 5


B: 1 1 1 1 2 12

niz A: medijan.... **Me=3** arit. sred. $\bar{X} = 3$


niz B: medijan.... **Me=1** arit. sred. $\bar{X} = 3$

MOD (dominantna vrijednost)


- vrijednost koja se u nizu mjerenja **najčešće** javlja (dominira svojom frekvencijom)
- na mod ne utječu ni broj ni veličina podataka, već **samo frekvencija**
oznaka: Mo



UNIMODALNA



BIMODALNA



UNIFORMNA

PAŽNJA !

PARAMETRIJSKA MJERA SREDINE

NEPARAMETRIJSKE MJERE SREDINE

	Aritmetička sredina	Medijan	Mod
Ljestvica	Najmanje intervalna	Najmanje ordinalna	Sve ljestvice
Prisustvo ekstremnih vrijednosti	NIJE POGODNA!	Ne smetaju	Ne smetaju
Razdioba	Normalna ili najmanje simetrična	Nije važno	Unimodalna

MJERE VARIJABILNOSTI

(mjere disperzije, raspršenja)

RASPON - max-min

KVANTILE - mjere varijabilnosti po položaju

- najčešće: kvartile (Q_1 - 25 %, Q_3 - 75 %)

VARIJANCA

$$s^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N-1}$$

STANDARDNA DEVIJACIJA

$$s = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N-1}}$$

KOEFICIJENT VARIJABILNOSTI

$$K.V. = \frac{s}{\bar{x}} \cdot 100$$

RASPON

$$R = \max - \min$$

- nedostaci:

- uzima u obzir samo dvije ekstremne vrijednosti koje uopće ne moraju biti karakteristične za promatranu varijablu
- ovisi o broju opažanja (veći broj opažanja => veći raspon)

KVANTILE

- mjere varijabilnosti po položaju
- kvartile, decile, centile
- donja kvartila (Q_1 ili 25%)
 - vrijednost podatka koji stoji na centralnom mjestu polovice podataka nižih od medijana
- gornja kvartila (Q_3 ili 75%)
 - vrijednost podatka koji stoji na centralnom mjestu polovice podataka viših od medijana
- Q_2 - medijan

centila	obuhvat jedinica promatranja
prva	1%
druga	2%
treća	3%
....	

decila	obuhvat jedinica promatranja
prva	10%
druga	20%
treća	30%
....	

VARIJANCA

- prosječno kvadratno odstupanje od aritmetičke sredine

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

**VARIJANCA
POPULACIJE**

$$s^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N-1}$$

**VARIJANCA
UZORKA**

STANDARDNA DEVIJACIJA

ZA POPULACIJU

ZA UZORAK

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$$

$$s = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N-1}}$$

- služi za ocjenu pojedinih rezultata oko aritmetičke sredine
- izražava se uz aritmetičku sredinu
- obično je

$$2s < \text{raspon} < 6s$$

KOEFICIJENT VARIJABILNOSTI

ZA POPULACIJU

$$K.V. = \frac{\sigma}{\mu} \cdot 100$$

ZA UZORAK

$$K.V. = \frac{s}{\bar{x}} \cdot 100$$

- relativna standardna devijacija
- govori o HOMOGENOSTI promatranog obilježja
- koristan je ako želimo znati:
 - a) razlike u varijabilnosti svojstava neke grupe ispitanika
 - b) razlike u varijabilnosti istog svojstva u različitim grupama ispitanika

MJERE ZA OCJENU OBLIKA RAZDIOBE

MOMENTI RAZDIOBE

- uzastopne mjere prosječnih odstupanja od aritmetičke sredine nultog, prvog, drugog, trećeg i višeg reda

MOMENT n-tog REDA (n-ti moment)

$$\mu_n = \frac{\sum_{i=1}^N (x_i - \mu)^n}{N}$$

NULTI I PRVI MOMENT

$$\mu_0 = \frac{\sum_{i=1}^N (x_i - \mu)^0}{N} = \frac{\sum_{i=1}^N 1}{N} = \frac{N}{N} = 1$$

prvo svojstvo aritmetičke sredine

$$\mu_1 = \frac{\sum_{i=1}^N (x_i - \mu)^1}{N} = \frac{0}{N} = 0$$

DRUGI MOMENT

$$\mu_2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N} = \sigma^2$$

VARIJANCA

TREĆI MOMENT




$$\mu_3 = \frac{\sum_{i=1}^N (x_i - \mu)^3}{N}$$

- za simetrične raspodjele $\mu_3 = 0$

KOEFICIJENT ASIMETRIJE (*coefficient of skewness*)

$$\alpha_3 = \frac{\mu_3}{\sigma^3}$$

- $\alpha_3 > 0$ asimetrija udesno (pozitivna asimetrija)
- $\alpha_3 < 0$ asimetrija ulijevo (negativna asimetrija)



ČETVRTI MOMENT

$$\mu_4 = \frac{\sum_{i=1}^N (x_i - \mu)^4}{N}$$

- koristi se za mjeru spljoštenosti

KOEFICIJENT SPLJOŠTENOSTI

(*coefficient of kurtosis*)

$$\alpha_4 = \frac{\mu_4}{\sigma^4}$$

$\alpha_4 > 3$ raspodjela je **uža**

(**šiljatija**) od normalne
(*leptokurtic*)

$\alpha_4 = 3$ normalna spljoštenost

$\alpha_4 < 3$ raspodjela je **šira**
(**spljoštenija**) od
normalne (*platykurtic*)


KOEFICIJENT SPLJOŠTENOSTI (*coefficient of kurtosis*)

- statistički programi koeficijent spljoštenosti prikazuju kao **eksces spljoštenosti** (kurtosis excess)

$$\text{eksces spljoštenosti} = \frac{\mu_4}{\sigma^4} - 3$$

- za normalnu raspodjelu eksces spljoštenosti = 0


ODNOS MJERA SREDINE I ASIMETRIJE



$$\bar{X} = 150 \quad Me = 150 \quad Mo = 150$$

$$\bar{X} = Me = Mo$$

ODNOS MJERA SREDINE I ASIMETRIJE




$$Mo = 37$$

$$\bar{X} = 42$$

$$Me = 38$$

Mo < Me < \bar{X}

ODNOS MJERA SREDINE I ASIMETRIJE



$$\bar{X} = 58$$

$$Mo = 63$$

$$Me = 62$$

$\bar{X} < Me < Mo$

MJERE SREDINE PREMA LJESEVICI MJERENJA

Ljestvica mjerenja	MOD	MEDIJAN	ARITMETIČKA SREDINA
NOMINALNA	✓	✗	✗
ORDINALNA	✓	✓	✗
INTERVALNA/OMJERNA (asimetrična raspodjela)	✓	✓	✗
INTERVALNA/OMJERNA (simetrična raspodjela)	✓	✓	✓

MJERE VARIJABILNOSTI PREMA LJESTVICI MJERENJA

Ljestvica mjerenja	RASPON	KVARTILE	VARIJANCA STANDARDNA DEVIJACIJA KOEFICIJENT VARIJABILNOSTI
NOMINALNA			
ORDINALNA			
INTERVALNA/OMJERNA (asimetrična raspodjela)			
INTERVALNA/OMJERNA (simetrična raspodjela)			

MJERE VARIJABILNOSTI


- iskazuju se uz odgovarajuću mjeru sredine

MJERA SREDINE	MJERA VARIJABILNOSTI
ARITMETIČKA SREDINA	STANDARDNA DEVIJACIJA
MEDIJAN	GRANICE INTERKVARTILNOG RASPONA (25%-75%)

GRAFIČKI PRIKAZ


RAZDIOBA OBILJEŽJA

- prikazuje se histogramom (stupičasti grafikon, “*column chart*”) ili poligonom frekvencija (linijski grafikon, “*line chart*”)




RAZDIOBA OBILJEŽJA


POLIGON FREKVENCIJA




POLIGON KUMULATIVNIH FREKVENCIJA



POLIGON RELATIVNIH FREKVENCIJA





POLIGON KUMULATIVNIH RELATIVNIH FREKVENCIJA




STRUKTURA OBILJEŽJA

- pokazuje udio pojedinih kategorija u ukupnom broju promatranja/mjerenja
- prikazuje se kružnim grafikonom (“torta”, “*pie chart*”) ili složenim stupičastim grafikonom (“*100% stacked column chart*”)



PROMJENE U VREMENIU


- prikazuju se linijskim grafikonom (“*line chart*”)
- na apscisu se nanose vremenski intervali, a na ordinatu vrijednost promatrane varijable




OSNOVNE MJERE SREDINE I RASPRŠENJA

- “kutija i brkovi” grafikon (“Box-and-Whisker” plot)
- najčešće prikazuje kombinacije:



sredina	kutija	brkovi
aritmetička sredina	standardna devijacija	2 SD ili raspon
medijan	25% - 75%	5% - 95% ili raspon



Statistica




MedCalc



POVEZANOST DVJU VARIJABLI

- raspršni grafikon (koreacijski, “scatter graph”)
- svaka točka predstavlja par vrijednosti promatranih varijabli



VJEROJATNOST

OSNOVNI POJMOVI TEORIJE VJEROJATNOSTI

● teorija vjerojatnosti

- matematička teorija slučajnih događaja

● SLUČAJNI DOGAĐAJ

- događaj koji ne mora bezuvjetno nastupiti (pod određenim okolnostima se može, ali i ne mora dogoditi)

POKUS

- proces dobivanja rezultata opažanja

- bacanje dva novčića
- određivanje krvne grupe 100 bolesnika i opažanje rezultata
- bacanje dvije igraće kocke
- prebrojavanje bolesnika koji uzimaju terapiju snižavanja lipida u krvi

PROSTOR ISHODA

- skup svih mogućih ishoda nekog pokusa

Prostor ishoda za pokus bacanja dva novčića
(P - pismo, G - glava)

$$\text{prostor ishoda} = \{ \text{GG}, \text{GP}, \text{PG}, \text{PP} \}$$

Prostor ishoda za izvlačenje dvije igraće karte (s obzirom na boju)

$$\text{prostor ishoda} = \{ \text{\color{red}{\fbox{}} \color{black}{\fbox{}}}, \text{\color{red}{\fbox{}} \color{black}{\fbox{}}}, \text{\color{black}{\fbox{}} \color{red}{\fbox{}}}, \text{\color{black}{\fbox{}} \color{red}{\fbox{}}} \}$$

PROSTOR ISHODA

Prostor ishoda za pokus bacanja dvije igraće kocke

prostor ishoda= $\{(1,1) (1,2) (1,3) (1,4) (1,5) (1,6)$
 $(2,1) (2,2) (2,3) (2,4) (2,5) (2,6)$
 $(3,1) (3,2) (3,3) (3,4) (3,5) (3,6)$
 $(4,1) (4,2) (4,3) (4,4) (4,5) (4,6)$
 $(5,1) (5,2) (5,3) (5,4) (5,5) (5,6)$
 $(6,1) (6,2) (6,3) (6,4) (6,5) (6,6) \}$

PROSTOR ISHODA

Prostor ishoda za pokus određivanja krvne grupe u 100 bolesnika

Krvna grupa	Broj bolesnika
O	42
A	43
B	11
AB	4
Ukupno	100

$$42 \times O \quad 43 \times A \quad 11 \times B \quad 4 \times AB$$


prostor ishoda= {O,O,..O, A,A,..A,B,B,..,B,AB, AB, AB, AB}

DOGAĐAJ

podskup prostora ishoda, tj. skup ishoda

Pokus: bacanje dva novčića

Događaj: pojava dvije "glave"

(P - pismo, G - glava)

prostor ishoda = { GG, GP, PG, PP}

ishod koji realizira
događaj

DOGAĐAJ

Pokus: bacanje dvije igraće kocke

Događaj: pojava barem jedne šestice

prostor ishoda= { (1,1) (1,2) (1,3) (1,4) (1,5) **(1,6)** ↗
(2,1) (2,2) (2,3) (2,4) (2,5) **(2,6)**
(3,1) (3,2) (3,3) (3,4) (3,5) **(3,6)**
(4,1) (4,2) (4,3) (4,4) (4,5) **(4,6)**
(5,1) (5,2) (5,3) (5,4) (5,5) **(5,6)**
(6,1) **(6,2)** **(6,3)** **(6,4)** **(6,5)** **(6,6)** }

ishodi koji realiziraju događaj

DOGAĐAJ

Pokus: određivanje krvne grupe u 100 bolesnika

Događaj: krvna grupa je AB

Krvna grupa	Broj bolesnika
O	42
A	43
B	11
AB	4
Ukupno	100

ishodi koji realiziraju događaj

$$42 \times O \quad 43 \times A \quad 11 \times B \quad 4 \times AB$$

prostor ishoda= {O,O,..O, A,A,..A,B,B,..,B,AB, AB, AB, AB}

KLASIČNA DEFINICIJA VJEROJATNOSTI (vjerojatnost A PRIORI)

ELEMENTARNI DOGAĐAJ

svaki od n jednakomogućih ishoda nekog događaja

prostor elementarnih događaja

skup svih elementarnih događaja

$$P(D) = \frac{m(D)}{n}$$

vjerovatnost događaja D

m(D).... broj povoljnih ishoda (događaja koji realiziraju događaj D)

n..... broj svih ishoda (kardinalni broj prostora elementarnih događaja)



PRIMJER

pokus: bacanje dva novčića

Doba novčića su pala na glavu

prostor ishoda = { GG, GP, PG, PP}

- taj događaj realizira 1 od 4 jednakomoguća događaja

$$P(D) = \frac{1}{4}$$

pokus: bacanje dvije igraće kocke
D....pojava barem jedne šestice

prostor ishoda= $\{(1,1) (1,2) (1,3) (1,4) (1,5) \underline{\textcolor{red}{(1,6)}}$
 $(2,1) (2,2) (2,3) (2,4) (2,5) \underline{\textcolor{red}{(2,6)}}$
 $(3,1) (3,2) (3,3) (3,4) (3,5) \underline{\textcolor{red}{(3,6)}}$
 $(4,1) (4,2) (4,3) (4,4) (4,5) \underline{\textcolor{red}{(4,6)}}$
 $(5,1) (5,2) (5,3) (5,4) (5,5) \underline{\textcolor{red}{(5,6)}}$
 $\underline{\textcolor{red}{(6,1)}} \underline{\textcolor{red}{(6,2)}} \underline{\textcolor{red}{(6,3)}} \underline{\textcolor{red}{(6,4)}} \underline{\textcolor{red}{(6,5)}} \underline{\textcolor{red}{(6,6)}} \}$

- taj događaj realizira 11 od 36 jednakih mogućih događaja

$$P(D) = \frac{11}{36}$$

RELATIVNA FREKVENCIJA

- omjer broja povoljnih ishoda i ukupnog broja pokusa ili ispitanika na kojima promatramo događaj



$$f(D) = \frac{m(D)}{n}$$

RELATIVNA FREKVENCIJA - primjer

Od 674 stanovnika otoka Suska, 312 stanovnika ima krvnu grupu O, 340 grupu A, 17 grupu B a 5 grupu AB. Kolika je vjerojatnost da jedan slučajno odabrani stanovnik ima krvnu grupu O?


D...krvna grupa je O

broj povoljnih
ishoda

$$P(D) = \frac{312}{674} \approx 0.46$$

broj ispitanika

ZAKON VELIKIH BROJEVA



KADA BROJ POKUSA RASTE,
APSOLUTNA RAZLIKA IZMEĐU
RELATIVNE FREKVENCIJE I
VJEROJATNOSTI SE SMANJUJE

VJEROJATNOST A POSTERIORI (statistička vjerojatnost)

- granična vrijednost relativne frekvencije kada broj pokusa raste u beskonačnost



$$P(D) = \lim_{n \rightarrow \infty} \frac{m(D)}{n}$$

vjerojatnost događaja D

$$m(D) \leq n \Rightarrow 0 \leq P(D) \leq 1$$

SKALA VJEROJATNOSTI



SUBJEKTIVNA VJEROJATNOST

- vjerojatnost događaju D se dodjeljuje prema subjektivnoj procjeni pojedinca



Prijatelj: Odgovor je: D

Ja: Koliko si siguran?

Prijatelj: Više od 77%

OSNOVNA PRAVILA RAČUNA VJEROJATNOSTI

PRAVILO KOMPLEMENTIRANJA (suprotna vjerojatnost)

A

\bar{A}

P(A)... vjerojatnost nastupanja događaja A

\bar{A} ... "non A" (događaj koji označava **ne nastupanje** događaja A)

$$P(\bar{A}) = 1 - P(A)$$

PRAVILO KOMPLEMENTIRANJA

- primjer

Ako je vjerojatnost rođenja muškog djeteta 0.52, kolika je vjerojatnost rođenja ženskog djeteta?


$$P(\text{muško}) = 0.52$$

$$P(\text{žensko}) = 1 - 0.52 = 0.48$$

DOGAĐAJI KOJI SE MEĐUSOBNO ISKLJUČUJU

- ne mogu nastupiti istovremeno
- disjunktni događaji

U pokusu bacanja dva novčića sva četiri moguća ishoda se međusobno isključuju



PRAVILO ADICIJE (za događaje koji se međusobno isključuju)

$A_1, A_2, A_3, \dots, A_k$

događaji koji se međusobno isključuju

$A_1 \cup A_2 \cup \dots \cup A_k$

složeni događaj, nastaje kada nastupi ili A_1 ili A_2 ili..ili A_k

$$P(A_1 \cup A_2 \cup \dots \cup A_k) = P(A_1) + P(A_2) + \dots + P(A_k)$$

PRAVILO ADICIJE - primjer

U nekoj populaciji vjerojatnosti pojedinih krvnih grupa su:

$$P(O)=0.42, P(A)=0.43, P(B)=0.11 \text{ i } P(AB)=0.04.$$

Kolika je vjerojatnost da slučajno odabrani pripadnik te populacije ima krvnu grupu A ili B?

$$\mathbf{P(A \text{ ili } B) = 0.43 + 0.11 = 0.54}$$

PRAVILO ADICIJE - primjer

Ako je vjerojatnost svijetle kose 0.20, vjerojatnost smeđe kose 0.40 a vjerojatnost crne kose 0.20, kolika je vjerojatnost da kosa bude:

a) smeđa ili crna

b) svijetla ili smeđa ili crna?

$$a) P(\text{smeđa ili crna}) = 0.40 + 0.20 = 0.60$$

$$b) P(\text{svijetla ili smeđa ili crna}) = 0.20 + 0.40 + 0.20 = 0.80$$


NEZAVISNI DOGAĐAJI

- događaji koji mogu nastupiti istovremeno, pri čemu vjerojatnost nasupanja nekog od njih ne ovisi o realizaciji drugih

PRAVILO MULTIPLIKACIJE

(za nezavisne događaje)

A , B nezavisni događaji



$A \cap B$ novi događaj koji nastupi kada se istovremeno realiziraju događaji A i B

PRAVILO MULTIPLIKACIJE

(za nezavisne događaje)

$A_1, A_2, A_3, \dots, A_k$... nezavisni događaji

$A_1 \cap A_2 \cap A_3 \cap \dots \cap A_k$ događaj koji nastupi kada se istovremeno realiziraju događaji $A_1, A_2, A_3, \dots, A_k$

$$P(A_1 \cap A_2 \cap A_3 \cap \dots \cap A_k) = P(A_1) \cdot P(A_2) \cdot P(A_3) \cdot \dots \cdot P(A_k)$$

PRAVILO MULTIPLIKACIJE

- primjer

Ako je vjerojatnost svijetle kose 0.30, a vjerojatnost crnih očiju 0.20, kolika je vjerojatnost istovremenog pojavljivanja svijetle kose i crnih očiju?

$$P(\text{svijetla kosa i crne oči}) = 0.30 * 0.20 = 0.06$$

primjer

Rezultati studije pokazali su da 60% majki djece do 10 godina radi puno radno vrijeme. Ako slučajno odaberemo tri majke, kolika je vjerojatnost da barem jedna od njih radi puno radno vrijeme?

$$\begin{aligned} P(\text{barem jedna radi PRV}) &= 1 - P(\text{niti jedna ne radi PRV}) = \\ &= 1 - [(0.4)(0.4)(0.4)] = \\ &= 1 - (0.4)^3 = 1 - 0.064 = \\ &= 0.936 \end{aligned}$$

...općenito....

vjerojatnost da se u nizu od **m** pokusa događaj **A** pojavi BAREM jedan puta dana je sa:


$$P(\text{barem jedan } A) = 1 - q^m$$

q.... vjerojatnost da se **A** NE DOGODI

$$q = 1 - P(A)$$

OPĆE PRAVILO ADICIJE

A , B događaji koji mogu istovremeno nastupiti



$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

OPĆE PRAVILO ADICIJE - primjer

Od 150 studenata u domu 40 je imalo CD, 80 TV a 30 i CD i TV. Kolika je vjerojatnost da slučajno odabrani student ima ili CD ili TV?

Astudent ima CD $P(A) = 40/150 = 0.2667$
Bstudent ima TV $P(B) = 80/150 = 0.5333$
A \cap B ...student ima i CD i TV $P(A \cap B) = 30/150 = 0.2$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B) = 0.2667 + 0.5333 - 0.2 = 0.6$$

UVJETNA VJEROJATNOST

- osnovna vjerojatnost u prirodnim i humanističkim istraživanjima
- ishodu nekog događaja prethodi neki drugi događaj kao uvjet za slijedeći potencijalni događaj

letalitet (stopa umrlih od neke bolesti) je tipična uvjetna vjerojatnost - mora biti zadovoljen uvjet da je osoba oboljela od te bolesti

UVJETNA VJEROJATNOST

A, B...događaji

vjerojatnost događaja B uz uvjet da se događaj A odigrao dana je sa:

$$P(B | A) = \frac{P(A \cap B)}{P(A)}$$

UVJETNA VJEROJATNOST - primjer

Učestalost sljepoće za boje u ljudskoj populaciji različita je prema spolu (X-kromosomska nasljedna anomalija).

	Učestalost (%)		
	muškarci	žene	ukupno
slijepi za boje	4,23	0,65	4,88
normalni	48,48	46,64	95,12
ukupno	52,21	47,29	100,00

UVJETNA VJEROJATNOST - primjer

Incidencija sljepoće za boje u muškoj subpopulaciji vodi na uvjetnu vjerojatnost

$$P(S | M) = \frac{P(S \cap M)}{P(M)}$$

$P(S \cap M)$	muškarci	žene	ukupno
slijepi za boje	0.0423	0.0065	0.0488
normalni	0.4848	0.4664	0.9512
ukupno $P(M)$	0.5221	0.4729	1.0000

OPĆE PRAVILO MULTIPLIKACIJE

neka su A, B događaji koji NISU nezavisni

$$P(A \cap B) = P(A)P(B|A)$$

$$P(A \cap B) = P(B)P(A|B)$$

A...preživljavanje kemoterapije ; $P(A)=0.9$

B...izlječenje leukemije

$B|A$ izlječenje leukemije pod uvjetom preživljavanja kemoterapije; $P(B|A)= 0.8$

Kolika je vjerojatnost da bolesnik preživi kemoterapiju i bude izlječen od leukemije?

$$P(A \cap B) = P(A)P(B|A) = 0.9 * 0.8 = 0.72$$

OPĆE PRAVILO MULTIPLIKACIJE

primjer

Morbiditet od neke bolesti u populaciji je 0.10, a letalitet od te iste bolesti u istoj populaciji 0.08. Kolika je vjerojatnost da slučajno odabran član te populacije oboli i umre?

$$P(A) = 0.10$$

$$P(B|A) = 0.08$$

$$P(A \cap B) = P(A)P(B|A) = 0.10 * 0.08 = 0.008$$

NEZAVISNI DOGAĐAJI

događaji A i B su **nezavisni** ako vrijedi:

$$P(A|B) = P(A)$$

ili

$$P(A \cap B) = P(A)P(B)$$

NEZAVISNI DOGAĐAJI

	gluhoća		
	postoji	ne postoji	ukupno
slijepi za boje	0.0004	0.0796	0.0800
normalni	0.0046	0.9154	0.9200
ukupno	0.0050	0.9950	1.0000

$$P(G)$$

$$P(\bar{G})$$

$$P(S \cap G) = P(S) \cdot P(G|S)$$

$$P(G|S) = 0.0004/0.0800$$

$$= 0.0050$$

$$P(\bar{G}|S) = 0.0796/0.0800$$

$$= 0.9950$$

$P(S \cap G) = P(S) \cdot P(G)$ događaji su nezavisni

$$P(G|S) = P(G)$$

RASPODJELE VJEROJATNOSTI

SLUČAJNA VARIJABLA

- pravilo po kojem se pojedinim slučajnim događajima dodjeljuju brojevi (atributi) tako da je uz svaki od njih pridružena određena vjerojatnost

Npr. varijabla broj infekcija može poprimiti vrijednosti 0, 1, 2,

Zovemo ju slučajnom ako je svakoj od vrijednosti pridružena određena vjerojatnost (npr. vjerojatnost da netko ima dvije infekcije u nekoj skupini ljudi je 0,07)

DISKRETKA SLUČAJNA VARIJABLA (definicija)

Diskretna slučajna varijabla je varijabla X koja poprima niz vrijednosti

$$x_1, x_2, \dots, x_k$$

ali svaku od njih s određenom vjerojatnošću

$$p(x_1), p(x_2), \dots, p(x_k), \quad p(x_i) \geq 0, \forall i$$

pri čemu za vjerojatnosti $p(x_i)$ vrijedi

$$\sum_{i=1}^k p(x_i) = 1$$

RASPODJELA slučajne varijable X

skup svih parova { $x_i, p(x_i)$ } , $i=1,2,\dots$

FUNKCIJA VJEROJATNOSTI slučajne varijable X

zakon $p(x)$ po kojem svakoj vrijednosti x_i pripada vjerojatnost $p(x_i)$

FUNKCIJA RASPODJELE slučajne varijable X

$$F(x_0) = \sum_{x_i \leq x_0} p(x_i)$$

- pokazuje kolika je vjerojatnost da slučajna varijabla X poprimi bilo koju vrijednost manju ili jednaku x_0 tj.

$$F(x_0) = P\{x \leq x_0\}$$

PRIMJER:

Na 35 preparata nekog biološkog materijala mjerena je broj nezrelih stanica. Dobiveni su slijedeći rezultati:


X_i	f_i	rf_i	crf_i
0	3	$0.09 = p(x_0)$	$0.09 = F(x_0) = p(x_0)$
1	8	$0.23 = p(x_1)$	$0.32 = F(x_1) = p(x_0) + p(x_1)$
2	12	$0.34 = p(x_2)$	$0.66 = F(x_2) = p(x_0) + p(x_1) + p(x_2)$
3	7	$0.20 = p(x_3)$	0.86 :
4	5	$0.14 = p(x_4)$	1.00 :

$$35 \quad 1.00$$

rf_i vjerojatnost da je broj nezrelih stanica jednak X_i - $p(x_i)$

crf_i ... vjerojatnost da je broj nezrelih stanica manji ili jednak X_i - $F(x_i)$

raspodjela vjerojatnosti



KONTINUIRANA SLUČAJNA VARIJABLA

- područje vrijednosti kontinuirane slučajne varijable je interval na brojevnom pravcu (moguće i čitav brojevni pravac)
- vjerojatnost pridružujemo intervalima brojevnog pravca
- pojedinačnim vrijednostima x_i pripada vjerojatnost 0
- nekom intervalu (x_1, x_2) pridružujemo vjerojatnost $P\{x_1 < x < x_2\}$ po funkciji vjerojatnosti $f(x)$

(definicija)

Funkcija vjerojatnosti kontinuirane slučajne varijable X je funkcija $f(x)$ koja ima slijedeća svojstva:

$$1. \ f(x) \geq 0, \forall x$$

$$2. \ \int_{-\infty}^{+\infty} f(x)dx = 1$$

$$3. \ \int_{x_1}^{x_2} f(x)dx = P\{x_1 < x < x_2\}$$

pri čemu su x_1, x_2 bilo koje dvije vrijednosti varijable x takve da je $x_1 < x_2$


značenje svojstava funkcije vjerojatnosti:

- **1. svojstvo** – NENEGATIVNOST (vjerojatnost ne može biti negativan broj)
- **2. svojstvo** – VJEROJATNOST SIGURNOG DOGAĐAJA je 1
 - ako je područje vrijednosti slučajne varijable X interval (a,b) , onda 2. svojstvo poprima oblik

$$\int_a^b f(x)dx = 1$$

i uzimamo da je $f(x)=0$ za sve vrijednosti x izvan područja vrijednosti, tj. intervala (a,b)


- 3. svojstvo – $P\{x_1 < x < x_2\}$ je numerički jednaka površini ispod krivulje vjerojatnosti nad intervalom (x_1, x_2)



FUNKCIJA RASPODJELE kontinuirane slučajne varijable

$$F(x_0) = \int_{-\infty}^{x_0} f(x)dx = P\{X \leq x_0\}$$

- pokazuje kolika je vjerojatnost da slučajna varijabla X poprimi bilo koju vrijednost manju ili jednaku x_0



KARAKTERISTIČNE VRIJEDNOSTI SLUČAJNIH VARIJABLI

OČEKIVANJE (sredina) SLUČAJNE VARIJABLE

$$E(x) = \mu = \sum_i x_i p(x_i)$$

očekivanje
diskretne slučajne
varijable

$$E(x) = \mu = \int_{-\infty}^{+\infty} xf(x)dx$$

očekivanje
kontinuirane slučajne
varijable

- kod empirijske raspodjele frekvencija to je aritmetička sredina:

$$\mu = \frac{\sum_i x_{i0}}{N} = \frac{\sum_i f_i x_i}{N} = \sum_i f_{ri} x_i$$

VARIJANCA (disperzija) SLUČAJNE VARIJABLE

$$V(x) = \sum_i (x_i - \mu)^2 p(x_i)$$

varijanca diskretne slučajne varijable

$$V(x) = \int_{-\infty}^{+\infty} (x - \mu)^2 f(x) dx$$

varijanca kontinuirane slučajne varijable

- kod empirijske raspodjele frekvencija:

$$\sigma^2 = \frac{\sum_i (x_{i0} - \mu)^2}{N} = \frac{\sum_i f_i (x_i - \mu)^2}{N} = \sum_i f_{ri} (x_i - \mu)^2$$

TEORIJSKE RASPODJELE

BINOMNA RASPODJELA $X \sim B(n, p)$

- $(p+q)^n$

BERNOULLIJEV DOGAĐAJ

- događaj A čija se vjerojatnost nastupanja
 $P(A) = p$
ne mijenja tijekom pokusa, a
vjerojatnost NE nastupanja događaja A je
 $q = 1 - p$

npr. u pokusu bacanja novčića pri svakom
bacanju novčića vjerojatnost pojave "grba" je
 $p = 0,5$

- vjerojatnost da Bernoullijev događaj A u nizu od n pokusa nastupi x puta:

$$P(X) = \binom{n}{x} p^x q^{n-x}$$

**BERNOULLIJEVA
FORMULA**

gdje je

$$\binom{n}{x} = \frac{n!}{x!(n-x)!}$$

BINOMNI KOEFICIJENT

BINOMNA RASPODJELA

- skup svih parova $\{x, P(x)\}$, $x = 0, 1, 2, \dots, n$

Primjer rekombinacije gena:

Vjerojatnost pojave gena A je $p(A)=p$, a vjerojatnost pojave gena a je $p(a)=q$. Koje su vjerojatnosti mogućih genotipova?

Mogu nastupiti kombinacije: AA, Aa, aA, aa.
Aa i aA se ne mogu biološki razlikovati => prostor ishoda je $\{AA, Aa, aa\}$

$$P(AA) = \binom{2}{2} p^2 q^{2-2} = p^2$$

$$P(Aa) = \binom{2}{1} p^1 q^{2-1} = 2pq$$

$$P(aa) = \binom{2}{0} p^0 q^{2-0} = q^2$$

KARAKTERISTIKE BINOMNE RASPODJELE

- jednoznačno je određena parametrima n, p

$$E(x) = np$$

OČEKIVANJE

$$\sigma^2 = V(x) = npq$$

VARIJANCA

KARAKTERISTIKE BINOMNE RASPODJELE

KOEFICIJENT ASIMETRIJE


$$\alpha_3 = \frac{q - p}{\sqrt{npq}}$$

KOEFICIJENT SPLJOSTENOSTI

$$\alpha_4 = 3 + \frac{1 - 6pq}{npq}$$




- SIMETRIČNA za $p = q = 1/2$
- POZITIVNO ASIMETRIČNA ako je $q > p$, tj. $q > 1/2$
- NEGATIVNO ASIMETRIČNA ako je $q < p$, tj. $q < 1/2$

BINOMNA RASPODJELA ZA RAZLIČITE PARAMETRE p



- bez obzira na međusobni odnos parametara p i q, vrijedi:

$$a_3 \rightarrow 0 \text{ kada } n \rightarrow \infty ; \quad a_4 \rightarrow 3 \text{ kada } n \rightarrow \infty$$



PRIMJENA BINOMNE RASPODJELE ZA PROCJENU VJEROJATNOSTI SMRTNOG ISHODA

Ako je letalitet od neke bolesti $p=0,30$ a vjerojatnost preživljavanja $q=0,70$ pitanje vjerojatnosti smrtnog ishoda i preživljavanja za 5 bolesnika možemo prikazati kao binomnu raspodjelu ($n=5$; $p=0,30$)

PRIMJENA BINOMNE RASPODJELE ZA PROCJENU VJEROJATNOSTI SMRTNOG ISHODA

BROJ UMRLIH	VJEROJATNOST	
0	$P(0) = \binom{5}{0} p^0 q^5 = q^5$	= 0.16807
1	$P(1) = \binom{5}{1} p^1 q^4 = 5pq^4$	= 0.36015
2	$P(2) = \binom{5}{2} p^2 q^3 = 10p^2q^3$	= 0.30870
3	$P(3) = \binom{5}{3} p^3 q^2 = 10p^3q^2$	= 0.13230
4	$P(4) = \binom{5}{4} p^4 q^1 = 5p^4q$	= 0.02835
5	$P(5) = \binom{5}{5} p^5 q^0 = p^5$	= 0.00243

PRILAGOĐAVANJE BINOMNE RASPODJELE EMPIRIJSKIM PODATCIMA

Pokus: 1000 bacanja 7 novčića. Kolike su očekivane frekvencije pojavljivanja grba uz pretpostavku da su novčići ispravni?

Znamo:

- novčići su ispravni $\Rightarrow p = 0.5, q = 0.5$
- u svakom je bacanju 7 novčića $\Rightarrow n = 7$
- vjerojatnost pojave X grbova dana je sa

$$P(x) = \binom{7}{x} p^x q^{7-x} = \binom{7}{x} 0.5^x 0.5^{7-x} = \binom{7}{x} 0.5^7$$

x	P(x)	P(x)*N	f_{ex}
0	$\binom{7}{0} 0.5^7 = 0.5^7$	7.81	8
1	$\binom{7}{1} 0.5^7 = 7 \cdot 0.5^7$	54.69	55
2	$\binom{7}{2} 0.5^7 = 21 \cdot 0.5^7$	164.06	164
3	$\binom{7}{3} 0.5^7 = 35 \cdot 0.5^7$	273.44	273
4	$\binom{7}{4} 0.5^7 = 35 \cdot 0.5^7$	273.44	273
5	$\binom{7}{5} 0.5^7 = 21 \cdot 0.5^7$	164.06	164
6	$\binom{7}{6} 0.5^7 = 7 \cdot 0.5^7$	54.69	55
7	$\binom{7}{7} 0.5^7 = 0.5^7$	7.81	8

POISSONOVA RASPODJELA

- granični prijelaz binomne raspodjele kada
 $n \rightarrow \infty$ uz uvjet $n \cdot p = \text{const.}$

$$P(x) = \frac{\mu^x e^{-\mu}}{x!}, \quad P(0) = e^{-\mu}$$

funkcija vjerojatnosti
Poissonove raspodjele

gdje je $\mu = n \cdot p$; e baza prirodnog logaritma
($e \approx 2.72$)

KARAKTERISTIKE POISSONOVE RASPODJELE

- jednoznačno je određena parametrom μ

$$E(x) = \mu$$

OČEKIVANJE

$$\sigma^2 = V(x) = \mu$$

VARIJANCA

KARAKTERISTIKE POISSONOVE RASPODJELE

KOEFICIJENT ASIMETRIJE


$$\alpha_3 = \frac{1}{\sqrt{\mu}}$$

KOEFICIJENT SPLJOŠTENOSTI

$$\alpha_4 = 3 + \frac{1}{\mu}$$

- $\alpha_3 > 0, \forall \mu$ (pozitivna asimetrija)
- povećanjem parametra μ asimetrija se smanjuje

POISSONOVA RASPODJELA ZA RAZLIČITE PARAMETRE μ



POISSONOVA RASPODJELA

- opisuje slučajnu raspodjelu događaja u vremenu ili sitnih čestica u prostoru
- raspodjela "rijetkih događaja"

PRIMJER: U promatranjima Rutherforda i Geigera ustanovljeno je da jedan radioaktivni izvor emitira u prosjeku 3.87 α čestica u vremenskom intervalu od 7.5 sekundi. Kolika je vjerojatnost da je u jednoj sekundi emitirana:

- a) najviše 1 čestica?
- b) najmanje 1 čestica?

$$P(x) = \frac{\mu^x e^{-\mu}}{x!}, \quad P(0) = e^{-\mu} \quad \mu = \frac{3.87}{7.5} = 0.516$$

a) $P(x \leq 1) = P(0) + P(1)$

$$P(0) = e^{-\mu} = e^{-0.516} = 0.5969$$

$$P(1) = \frac{0.516^1 e^{-0.516}}{1!} = 0.516 \cdot 0.5969 = 0.3080$$

$$P(x \leq 1) = P(0) + P(1) = 0.5969 + 0.3080 = 0.9049$$

b) $P(x \geq 1) = 1 - P(x < 1) = 1 - P(0) = 1 - 0.5969 = 0.4031$

Aproksimacija binomne razdiobe Poissonovom

- u slučajevima kad je $n \cdot p \leq 10$ uz $n > 50$

PRIMJER: U seriji automatski očitanih nalaza KKS prosječno je 1% pogrešnih.

- a) Kolika je vjerojatnost da od 200 nalaza ne bude niti jedan pogrešan?
- b) Kolika je vjerojatnost da će u 300 nalaza biti najviše 1 pogrešan?

a) $p=0.01$

$n=200$

$\mu=n \cdot p=2$

$$P(0)=e^{-\mu}=e^{-2}=0.1353$$

b) $p=0.01$

$n=300$

$\mu=n \cdot p=3$

$$P(x)=\frac{\mu^x e^{-\mu}}{x!}$$

$$P=P(x \leq 1)=P(0)+P(1)$$

$$P(0)=e^{-\mu}=e^{-3}=0.0498$$

$$P(1)=\frac{3^1 e^{-3}}{1!}=3 \cdot e^{-3}=3 \cdot 0.0498=0.1494$$

$$P=P(x \leq 1)=P(0)+P(1)=0.0498+0.1494=0.1992$$

PRILAGOĐAVANJE POISSONOVE RASPODJELE EMPIRIJSKIM PODATCIMA

Na 576 ploča hranjivih podloga prebrojane su bakterije i dobiveno je sljedeće:

- na 229 pločica nije nađena niti jedna bakterija
- na 211 pločica nađena je 1 bakterija
- na 93 pločice nađene su 2 bakterije
- na 35 pločica nađene su 3 bakterije
- na 7 pločica nađene su 4 bakterije
- na jednoj pločici nađeno je 7 bakterija.

Odgovara li rast bakterija Poissonovoj raspodjeli?

vrijedi:

$$\frac{p(x)}{p(x-1)} = \frac{\mu}{x} \Rightarrow p(x) = \frac{\mu}{x} p(x-1)$$

x	f_x	$x \cdot f_x$	μ/x	p(x)	$f_{ex} = N \cdot p(x)$	f_{ex}
0	229	0	-	0.39365	226.74	227
1	211	211	0.9323	0.36700	211.39	211
2	93	186	0.4662	0.17108	98.54	99
3	35	105	0.3108	0.05317	30.63	31
4	7	28	0.2331	0.01239	7.14	7
5	0	0	0.1865	0.00231	1.33	1
6	0	0	0.1554	0.00036	0.21	0
7	1	7	0.1332	0.00005	0.03	0
	576	537				576

$$\mu = \bar{x} = \frac{1}{N} \sum_i x_i f_{xi} = \frac{537}{576} = 0.9323;$$

$$P(0) = e^{-\mu} = e^{-0.9323} = 0.3936$$

NORMALNA RASPODJELA $X \sim N(\mu, \sigma^2)$

- slučajna varijabla X ima normalnu raspodjelu ako je područje njenih vrijednosti $(-\infty, +\infty)$, a funkcija vjerojatnosti

$$f(x) = \frac{1}{b\sqrt{2\Pi}} e^{-\frac{1}{2}\left(\frac{x-a}{b}\right)^2}$$

FUNKCIJA
VJEROJATNOSTI
NORMALNE
RASPODJELE

OČEKIVANJE

$$E(X) = \mu = a$$

VARIJANCA

$$V(X) = \sigma^2 = b^2$$

$$f(x) = \frac{1}{\sigma\sqrt{2\Pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

FUNKCIJA
VJEROJATNOST
I NORMALNE
RASPODJELE

- jednoznačno je određena parametrima

$$\mu, \sigma^2$$

koeficijent
asimetrije

$$\alpha_3 = 0$$

- simetrična s obzirom na pravac $x = \mu$

koeficijent
spljoštenosti


$$\alpha_4 = 3$$

NORMALNA RASPODJELA $X \sim N(\mu, \sigma^2)$... svojstva



1. $\mu = M_e = M_o$

2.





3. Površina ispod krivulje normalne raspodjele u intervalu između dvije vrijednosti koje su definirane udaljenošću od aritmetičke sredine izražene u standardnim devijacijama je **KONSTANTNA** bez obzira na stvarne vrijednosti aritmetičke sredine i standardne devijacije u pojedinom slučaju

Npr:

a)

$$x_1 = 2.5$$

$$x_2 = 3.5$$

$$\mu = 3$$

$$\sigma = 0.5$$

$$P(x_1 < x < x_2) = ?$$

$$x_1 = 2.5 = \mu - \sigma$$

$$x_2 = 3.5 = \mu + \sigma$$

$$P(x_1 < x < x_2) = P(\mu - \sigma < x < \mu + \sigma) = 0.68$$

b)

$$x_1 = 10$$

$$x_2 = 14$$

$$\mu = 12$$

$$\sigma = 2$$

$$P(x_1 < x < x_2) = ?$$

$$x_1 = 10 = \mu - \sigma$$

$$x_2 = 14 = \mu + \sigma$$

$$P(x_1 < x < x_2) = P(\mu - \sigma < x < \mu + \sigma) = 0.68$$

$$z = \frac{x - \mu}{\sigma}$$

$$z_{a1} = \frac{x_{a1} - \mu_a}{\sigma_a} = \frac{2.5 - 3}{0.5} = -1$$

$$z_{a2} = \frac{x_{a2} - \mu_a}{\sigma_a} = \frac{3.5 - 3}{0.5} = 1$$

$$z = \frac{x - \mu}{\sigma}$$

$$z_{b1} = \frac{x_{b1} - \mu_b}{\sigma_b} = \frac{10 - 12}{2} = -1$$

$$z_{b2} = \frac{x_{b2} - \mu_b}{\sigma_b} = \frac{14 - 12}{2} = 1$$

$$Z = \frac{x - \mu}{\sigma}$$

STANDARDIZIRANA
VRIJEDNOST

(standardized deviate, z-value)

- supstitucijom u funkciju vjerojatnosti normalne raspodjele dobivamo:

$$f(x) = \frac{1}{\sigma} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}$$

funkcija od z

STANDARDNA (jedinična) NORMALNA RASPODJELA

$X \sim N(0,1)$

$$\varphi(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}$$

FUNKCIJA
VJEROJATNOSTI
STANDARDNE NORMALNE
RASPODJELE

$$f(x) = \frac{1}{\sigma} \varphi(z)$$

OČEKIVANJE


$$E(z) = 0$$

VARIJANCA

$$V(z) = 1$$

$$X \sim N(0,1)$$

PRETVARANJE LJESTVICE MJERENJA U STANDARDIZIRANU Z-LJESTVICU




Ijestvica mjerena

z - Ijestvica

TABLICA POVRŠINA ISPOD STANDARDNE NORMALNE RASPODJELE

- Tablica sadrži vrijednosti površina samo za *nenegativne z vrijednosti* ($z \geq 0$) i to iznad intervala $(z, +\infty)$.
- Za odgovarajuće negativne z vrijednosti površina je jednaka, tj. $P_z = P(-\infty < x < -z) = P(z < x < +\infty) = P+z$



Z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.4960	0.4920	0.4880	0.4840	0.4801	0.4761	0.4721	0.4681	0.4641
0.1	0.4602	0.4562	0.4522	0.4483	0.4443	0.4404	0.4364	0.4325	0.4286	0.4247
0.2	0.4207	0.4168	0.4129	0.4090	0.4052	0.4013	0.3974	0.3936	0.3897	0.3859
0.3	0.3821	0.3783	0.3745	0.3707	0.3669	0.3632	0.3594	0.3557	0.3520	0.3483
0.4	0.3446	0.3409	0.3372	0.3336	0.3300	0.3264	0.3228	0.3192	0.3156	0.3121
0.5	0.3085	0.3050	0.3015	0.2981	0.2946	0.2912	0.2877	0.2843	0.2810	0.2776
0.6	0.2743	0.2709	0.2676	0.2643	0.2611	0.2579	0.2546	0.2514	0.2451	0.2148
0.7	0.2420	0.2389	0.2358	0.2327						
0.8	0.2119	0.2090	0.2061	0.2033						
0.9	0.1841	0.1814	0.1788	0.1762						
1.0	0.1587	0.1562	0.1539	0.1514						
1.1	0.1357	0.1335	0.1314	0.1293						0.1170
1.2	0.1151	0.1131	0.1112	0.1093						0.0985
1.3	0.0968	0.0951	0.0934	0.0918	0.0901	0.0885	0.0869	0.0853	0.0838	0.0823
1.4	0.0808	0.0793	0.0778	0.0764	0.0749	0.0735	0.0721	0.0708	0.0694	0.0681

površina ispod krivulje funkcije
vjerojatnosti standardne
normalne raspodjele iznad
intervala $(z, +\infty)$, za $z=0.44$

Na velikom uzorku izmjerena je visina desetogodišnjih dječaka. Aritmetička sredina visine bila je 137cm, a standardna devijacija 5cm. Kolika je visina od koje je 20% dječaka višlje?

$$P(z) = 0.20$$

Z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.4960	0.4920	0.4880	0.4840	0.4801	0.4761	0.4721	0.4681	0.4641
0.1	0.4602	0.4562	0.4522	0.4483	0.4443	0.4404	0.4364	0.4325	0.4286	0.4247
0.2	0.4207	0.4168	0.4129	0.4090	0.4052	0.4013	0.3974	0.3936	0.3897	0.3859
0.3	0.3821	0.3783	0.3745	0.3707	0.3669	0.3632	0.3594	0.3557	0.3520	0.3483
0.4	0.3446	0.3409	0.3372	0.3336	0.3300	0.3264	0.3228	0.3192	0.3156	0.3121
0.5	0.3085	0.3050	0.3015	0.2981	0.2946	0.2912	0.2877	0.2843	0.2810	0.2776
0.6	0.2743	0.2709	0.2676	0.2643	0.2611	0.2578	0.2546	0.2514	0.2483	0.2451
0.7	0.2420	0.2389	0.2358	0.2327	0.2296	0.2266	0.2236	0.2206	0.2177	0.2148
0.8	0.2119	0.2090	0.2061	0.2033	0.2005	0.1977	0.1949	0.1922	0.1894	0.1867
0.9	0.1841	0.1814	0.1788	0.1762	0.1736	0.1711	0.1685	0.1660	0.1635	0.1611

$$z=0.84$$

$$\text{iz } z = \frac{x - \mu}{\sigma} \Rightarrow x = \sigma \cdot z + \mu = 5\text{cm} \cdot 0.84 + 137\text{cm} = 141.2\text{cm}$$

Koliki postotak dječaka ima visinu:

a) do 126cm

b) između 126cm i 134cm

c) između 134cm i 144cm

d) iznad 144cm

e) do 144cm?

$$a) z_{126} = \frac{126 - 137}{5} = -2.2 \quad P(z_{126}) = P_a = 0.0139 \Rightarrow 1.39\%$$

$$b) z_{134} = \frac{134 - 137}{5} = -0.6 \quad P(z_{134}) = 0.2743$$

$$P_b = P(z_{134}) - P(z_{126}) = 0.2604 \Rightarrow 26.04\%$$

$$c) z_{144} = \frac{144 - 137}{5} = 1.4 \quad P(z_{144}) = 0.0808$$

$$P_c = 1 - [P(z_{134}) + P(z_{144})] = 1 - (0.2743 + 0.0808) = 0.6449 \Rightarrow 64.49\%$$

$$d) P_d = P(z_{144}) = 0.0808 \Rightarrow 8.08\%$$

$$e) P_e = 1 - P_d = 1 - P(z_{144}) = 1 - 0.0808 = 0.9192 \Rightarrow 91.92\%$$

UZORAK I POPULACIJA

POPULACIJA

- osnovni skup
- skup svih jedinica promatranja (entiteta) opisanih varijablama (atributima)

UZORAK - dio jedinica populacije (osnovnog skupa)


TEORIJA UZORAKA

- ustanavljava svojstva populacije iz svojstava uzorka
- procjenjuje parametre populacije na temelju podataka iz uzorka i ocjenjuje pouzdanost te procjene

UZORAK

● zašto uzorak?

- brzina dobivanja rezultata
- cijena istraživanja
- dostupnost (materijala ili ispitanika)
- stvarna nemogućnost ispitivanja populacije



temeljem podataka
dobivenih iz uzorka

UOBIČAJENE OZNAKE

	OCJENA PARAMETRA (STATISTIKA)	PARAMETAR POPULACIJE
ARITMETIČKA SREDINA	\bar{X}	μ
STANDARDNA DEVIJACIJA	s	σ
PROPORCIJA	p	π

OSNOVNI POJMOVI

Koja je skupina na koju želimo generalizirati?

Koja je populacija dostupna?

Na koji način možemo obuhvatiti populaciju?


Tko je uključen u istraživanje?

TEORETSKA POPULACIJA


POPULACIJA KOJU ISTRAŽUJEMO

OKVIR IZBORA

UZORAK




TEORETSKA POPULACIJA




- **potpuna skupina na koju želimo generalizirati**
- **npr.:**
 - svi oboljeli od AIDS-a
 - svi oboljeli od dijabetesa
 - starije osobe oboljele od Alzheimerove bolesti zbrinute u ustanovi

POPULACIJA KOJU ISTRAŽUJEMO



- **dostupna populacija**
- **može biti ograničena na instituciju, grad, županiju, državu, regiju**
- **npr.:**
 - svi oboljeli od AIDS-a u Osječko-baranjskoj županiji
 - svi oboljeli od dijabetesa registrirani u centru za dijabetes KBCO
 - starije osobe oboljele od Alzheimerove bolesti zbrinute u domovima za starije i nemoćne u OBŽ

OKVIR IZBORA



- popis svih članova (jedinica promatranja) dostupne populacije
- svaki član populacije treba biti identificiran i uključen u popis => svi trebaju imati jednaku šansu izbora u uzorak

UZORAK



- jedinice dostupne populacije izabrane iz okvira izbora nekom metodom uzorkovanja
- jedinice populacije koje će biti uključene u istraživanje (ispitanici ili objekti)

Kvaliteta ocjene parametara ovisi o:

- REPREZENTATIVNOSTI UZORKA
- ODABRANOJ VJEROJATNOSTI

REPREZENTATIVNI UZORAK

- uzorak koji dobro opisuje populaciju

Na reprezentativnost uzorka utječu:

1. Vrsta uzorka (prema metodi odabira)
2. Veličina uzorka
3. Varijabilnost promatranog obilježja

VRSTE UZORAKA

PROBABILISTIČKI (probability samples)

- svaka jedinica promatranja u populaciji ima jednaku vjerojatnost izbora u uzorak koja je različita od 0

NEPROBABILISTIČKI (non-probability samples)

- vjerojatnost izbora jedinica promatranja iz populacije je različita i nepoznata
(može biti i 0)

PROBABILISTIČKI UZORCI

**JEDNOSTAVNI SLUČAJNI
SUSTAVNI SLUČAJNI (SISTEMATSKI)
SLOJEVITI (STRATIFICIRANI)
UZORAK SKUPINE ("CLUSTER", GROZD)
VIŠEFAZNI**

JEDNOSTAVNI SLUČAJNI UZORAK (*simple random sample*)

svojstva:

- **svaki element** populacije ima **jednaku šansu** da bude izabran
- **svaki uzorak** ima **jednaku šansu** da bude izabran

način izbora:

- lutrijska metoda
- pomoću tablice slučajnih brojeva
- pomoću programske podrške koja ima funkciju generatora slučajnih brojeva

SUSTAVNI SLUČAJNI UZORAK (*systematic sample*)

- jedinice koje ulaze u uzorak odabiru se po nekakvom pravilu

postupak:

- numerirati jedinice populacije od 1 do N
- odrediti potrebnu veličinu uzorka (n)
- odrediti veličinu intervala $k = N/n$
- slučajno odabrati broj između 1 i k (početna jedinica)
- uzimati svaku k -tu jedinicu

SLOJEVITI (STRATIFICIRANI) UZORAK

- primjenjuje se u slučajevima kad je promatrano obilježje heterogeno u populaciji
- dobiva se uzimanjem jednostavnih slučajnih uzoraka iz stratuma određenih obzirom na promatrano obilježje

postupak:

- podijeliti populaciju na disjunktne skupine od n_1, n_2, \dots, n_s jedinica, pri čemu je
$$n_1 + n_2 + \dots + n_s = N$$
- uzeti jednostavni slučajni uzorak od
$$f_i = n_i / N$$
jedinica iz svake skupine



UZORAK SKUPINE (CLUSTER)

- primjenjuje se u slučajevima kada treba uzeti uzorak iz populacije koja se sastoji od skupina jedinica (ulice, popisni krugovi, škole, općine, ...)

postupak:

- podijeliti populaciju na skupine jedinica
- jednostavnim slučajnim izborom odabratи skupine
- ispitati SVE jedinice unutar odabranih skupina

VIŠEFAZNI UZORAK

- uzimanje "uzorka iz uzorka"
- kombinacija više metoda odabiranja uzorka

Npr. jedan od mogućih načina dobivanja uzorka iz populacije učenika osnovnih škola u Hrvatskoj:

- podijeliti osnovne škole u stratume s obzirom na županijsku pripadnost
- iz svakog struma jednostavnim slučajnim izborom odabrati škole (prva faza)
- unutar odabranih škola, jednostavnim slučajnim izborom odabrati razrede (druga faza)
- unutar odabranih razreda, jednostavnim slučajnim izborom odabrati učenike (treća faza)

NEPROBABILISTIČKI UZORCI

PRIGODNI (convenience)

UZORAK KOJI SLUŽI SVRSI (purposive)

UZORAK UDJELA (quota)

UZORAK SNJEŽNE GRUDE (snowball)


PRIGODNI UZORAK (convenient sample)

- u uzorak se biraju jedinice populacije koje su "pri ruci":
 - prolaznici
 - pozvani dobrovoljci
 - prvih 50 pacijenata u nekoj ambulanti



UZORAK KOJI SLUŽI SVRSI (purposive sample)

- u uzorak se biraju jedinice populacije koje imaju traženo svojstvo



UZORAK UDJELA (quota sample)

- u uzorak se bira određeni broj jedinica odabralih dijelova populacije

POPULACIJA



Traži se
uzorak:


20 %

20 %

30 %


30 %

Uzorak
veličine 10:



UZORAK SNJEŽNE GRUDE (snowball sample)

- ispitanici regrutiraju daljnje ispitanike
- zatvorene ili teško dostupne skupine:
 - oboljeli od AIDSa
 - ovisnici
 - beskućnici



U kojem od sljedećeg se koristi jednostavni slučajni uzorak:

- a) igra “Bingo”,
- b) popis stanovništva,
- c) izbori za lokalnu samoupravu?

Koje metode odabira uzorka se koriste u ovim primjerima?

- a) igra “Bingo” – jednostavni slučajni uzorak
- b) popis stanovništva - ne koristi jednostavni slučajni uzorak jer SVE jedinice populacije moraju biti obuhvaćene popisom
- c) izbori za lokalnu samoupravu – neprobabilistički uzorak; na izbore izlaze oni koji to žele (“dobrovoljci”)

VELIČINA UZORKA


dovoljno veliki uzorak:

- uzorak pomoću kojeg s razumnom pouzdanošću možemo prihvati ili odbaciti neku hipotezu i ocijeniti parametar populacije

ovisit će o:

- homogenosti populacije s obzirom na promatrano obilježje
- učestalosti promatranog obilježja (obrnuto proporcionalno)

ZAVISNI I NEZAVISNI UZORCI



Unos podataka o mjerljima na nezavisnim skupinama

- **nezavisne skupine = različiti ispitanici**
(ispitanici koji pripadaju nekoj skupini ne pripadaju niti jednoj od preostalih skupina)
- za unos podataka o nekom mjerljvu 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 mjerljva** za danog ispitanika

Unos podataka o mjerjenjima na nezavisnim skupinama

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

varijabla koja sadrži
vrijednost mjerjenja

varijabla koja definira
pripadnost skupini

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

Unos podataka o mjerjenjima na nezavisnim skupinama

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


varijabla koja sadrži
vrijednost mjerjenja

varijabla koja definira
pripadnost skupini

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

Unos podataka o mjerljima na zavisnim skupinama

- zavisne skupine = ponavljana mjerljiva na ISTIM ispitanicima
- SVAKO mjerljivo = JEDNA varijabla



koliko mjerljiva toliko varijabli

Unos podataka o mjerjenjima na zavisnim skupinama

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

po jedna varijabla za svako mjerjenje

	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

UTJECAJ VARIJABILNOSTI

- varijabilnost je često nepoznata
- poznata, a velika varijabilnost ugrožava reprezentativnost uzorka
- utjecaj varijabilnosti se smanjuje s povećanjem uzorka

STANDARDNA POGREŠKA


POKUS 1. Napraviti razdiobe aritmetičkih sredina 500 uzoraka veličine $n = 4$, $n = 20$ i $n = 50$ osnovnog skupa $N = 101$ brojeva od 0 do 100.

aritmetička sredina osnovnog skupa


$$\mu = 50$$

standardna devijacija osnovnog skupa


$$\sigma = 29,15$$



$n = 4$
 $\bar{x} = 50,96$
 $s = 14,451$



$n = 20$
 $\bar{x} = 50,10$
 $s = 6,639$



$n = 50$
 $\bar{x} = 50,07$
 $s = 4,189$

N veličina osnovnog skupa

n veličina slučajnih uzoraka

$\binom{N}{n}$ broj svih mogućih uzoraka veličine n uzetih iz osnovnog skupa veličine N

1. uzorak	$x_{11}, x_{12}, \dots, x_{1n}$	sa sredinom	\bar{x}_1
2. uzorak	$x_{21}, x_{22}, \dots, x_{2n}$	sa sredinom	\bar{x}_2
3. uzorak	$x_{31}, x_{32}, \dots, x_{3n}$	sa sredinom	\bar{x}_3
....			
k -ti uzorak	$x_{k1}, x_{k2}, \dots, x_{kn}$	sa sredinom	\bar{x}_k

$\bar{X}_1, \bar{X}_2, \bar{X}_3, \dots, \bar{X}_k$

slučajna varijabla
(*sampling distribucija*)

OČEKIVANJE

$$E(\bar{X}) = \mu$$

VARIJANCA

$$V(\bar{X}) = \frac{\sigma^2}{n}$$

standardna
devijacija

$$S_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

STANDARDNA
POGREŠKA
(SE, standard
error)

- za slučajne i dovoljno velike uzorke

$$S_{\bar{x}} = \frac{s}{\sqrt{n}}$$

**STANDARDNA
POGREŠKA
(SE, standard error)**

- standardna pogreška aritmetičke sredine (SEM, *standard error of the mean*)
- pogreška kojoj se izlažemo pri zaključivanju o populaciji na temelju uzorka

$s \uparrow \Rightarrow S_{\bar{x}} \uparrow$ **povećava se** s povećanjem *varijabilnosti obilježja*

$n \uparrow \Rightarrow S_{\bar{x}} \downarrow$ **smanjuje se** s povećanjem *veličine uzorka*

CENTRALNI GRANIČNI TEOREM



Razdioba aritmetičkih sredina uzoraka teži normalnoj razdiobi s očekivanjem μ i varijancom $\sigma_{\bar{x}}^2$ [$N(\mu, \sigma_{\bar{x}}^2)$] kada veličina uzorka n teži u beskonačnost.

⇒ za dovoljno velike uzorce razdioba aritmetičkih sredina uzoraka bit će *normalna*, bez obzira na razdiobu vrijednosti promatranog obilježja

za proporciju:

$$S_p = \sqrt{\frac{p \cdot q}{n}}$$

STANDARDNA POGREŠKA PROPORCIJE

$p \uparrow \Rightarrow S_{\bar{x}} \downarrow$ **smanjuje se** s povećanjem *homogenosti obilježja*

$n \uparrow \Rightarrow S_{\bar{x}} \downarrow$ **smanjuje se** s povećanjem *veličine uzorka*

STANDARDNA POGREŠKA

VS

STANDARDNA DEVIJACIJA

STANDARDNA POGREŠKA:

- procjenjuje “kvalitetu” ocjene parametra (statistike)
- velika standardna pogreška => ocjena parametra (ar. sredina, proporcija) je neprecizna

STANDARDNA DEVIJACIJA:

- opisuje varijabilnost podataka
- velika standardna devijacija => velika varijabilnost podataka

RASPON POUZDANOSTI

RASPON POUZDANOSTI

- confidence interval (CI)
- uobičajeno tumačenje:
raspon unutar kojega se, s određenom vjerojatnošću, nalazi prava vrijednost (parametar) populacije

RASPON POUZDANOSTI ARITMETIČKE SREDINE

$$\bar{x} - z \cdot s_{\bar{x}} \leq \mu \leq \bar{x} + z \cdot s_{\bar{x}}$$

RASPON POUZDANOSTI PROPORCIJE

$$p - z \cdot s_p \leq \Pi \leq p + z \cdot s_p$$

z - standardizirana vrijednost normalne raspodjele
(ovisi o prepostavljenoj vjerojatnosti)

PRIMJER. Koliki je raspon pouzdanosti ako želimo obuhvatiti μ sa:

- a) 99 % pouzdanosti
- b) 95 % pouzdanosti
- c) 90 % pouzdanosti

uz pretpostavku normalne razdiobe?

a) $z_{0,005} = 2,576 \approx 2,58 \quad \bar{x} - 2,58 \cdot s_{\bar{x}} \leq \mu \leq \bar{x} + 2,58 \cdot s_{\bar{x}}$

b) $z_{0,025} = 1,96 \quad \bar{x} - 1,96 \cdot s_{\bar{x}} \leq \mu \leq \bar{x} + 1,96 \cdot s_{\bar{x}}$

c) $z_{0,05} = 1,65 \quad \bar{x} - 1,65 \cdot s_{\bar{x}} \leq \mu \leq \bar{x} + 1,65 \cdot s_{\bar{x}}$

PRIMJER. Od 1000 ljudi koji su cijepljeni, 200 ih je pokazalo alergične reakcije. Koliku proporciju alergičnih očekujemo u populaciji cijepljenih uz vjerojatnost od 95 %?

$$z_{0,025} = 1,96$$

$$p - 1,96 \cdot s_p \leq \Pi \leq p + 1,96 \cdot s_p$$

$$p = 0,20; \quad q = 0,80;$$

$$s_p = \sqrt{\frac{0,2 \cdot 0,8}{1000}} = \sqrt{\frac{0,16}{1000}} = \sqrt{0,00016} = 0,0126$$


$$0,2 - 1,96 \cdot 0,0126 \leq \Pi \leq 0,2 + 1,96 \cdot 0,0126$$

$$0,2 - 0,025 \leq \Pi \leq 0,2 + 0,025$$

$$0,175 \leq \Pi \leq 0,225$$

95% raspon pouzdanosti aritmetičke sredine izračunat iz nekog uzorka:

- ***uobičajeno*** se tumači kao raspon vrijednosti unutar kojeg se s 95% pouzdanosti nalazi prava vrijednost aritmetičke sredine (aritmetička sredina populacije)
- ***u stvari znači*** da očekujemo da 95% takvih intervala dobivenih iz uzoraka iste veličine dane populacije uključuje pravu vrijednost aritmetičke sredine



95% raspon pouzdanosti:


Slučajan interval čije granice se mogu izračunati iz podataka o uzorku, takav da 95 od svakih 100 takvih intervala obuhvaća pravu vrijednost parametra koji se procjenjuje.

- također i raspon poželjnih vrijednosti parametra populacije (prihvatljiva nul-hipoteza)


Širina raspona pouzdanosti ovisi o:

- pretpostavljenoj vjerojatnosti
- varijabilnosti promatranog obilježja
- veličini uzorka

širi se s
povećanjem pouzdanosti



sužava se s
povećanjem uzorka



POTREBNA VELIČINA UZORKA za procjenu aritmetičke sredine

Ovisit će o:

- pogrešci procjene koju ćemo tolerirati
- stupnju pouzdanosti
- pretpostavljenoj varijabilnosti

$$E = z \cdot S_{\bar{x}} = z \cdot \frac{s}{\sqrt{n}}$$

POGREŠKA PROCJENE

$$n = \left(\frac{z \cdot s}{E} \right)^2$$

POTREBNA VELIČINA
UZORKA

PRIMJER. Koliko ispitanika treba izabrati u uzorak kako bi se procijenila prosječna starost stanovnika nekog sela u 95 % rasponu pouzdanosti od 2 godine? Pretpostavlja se kako je standardna devijacija populacije 8 godina.

Koliki uzorak treba biti ako toleriramo pogrešku od najviše ± 10 mjeseci?

$$z_{0,025} = 1,96$$

$$E = 1$$

$$\sigma = 8$$

$$n = \left(\frac{z_{0,025} \cdot \sigma}{E} \right)^2 = \left(\frac{1,96 \cdot 8}{1} \right)^2 = 15,68^2 = 245,86 \approx 246$$

$$z_{0,025} = 1,96$$

$$E = 10/12 = 0,83$$

$$\sigma = 8$$

$$n = \left(\frac{z_{0,025} \cdot \sigma}{E} \right)^2 = \left(\frac{1,96 \cdot 8}{0,83} \right)^2 = 18,89^2 = 356,83 \approx 357$$

POTREBNA VELIČINA UZORKA za procjenu proporcije

Ovisit će o:

- pogrešci procjene koju ćemo tolerirati
- stupnju pouzdanosti
- pretpostavljenoj proporciji

$$E = z \cdot s_p = z \cdot \sqrt{\frac{p \cdot q}{n}}$$

POGREŠKA PROCJENE

$$n = \left(\frac{z}{E} \right)^2 \cdot p \cdot q$$

POTREBNA VELIČINA
UZORKA

PRIMJER. Studija provedena na Fakultetu javnog zdravstva na Harvardu utvrdila je da 19 % studenata nikada ne piju alkohol. Koliki uzorak vam je potreban za procjenu proporcije studenata koji ne piju alkohol na vašem fakultetu unutar raspona od 10 % uz pouzdanost od 95 %, vodeći se rezultatima harvardske studije?

$$z_{0,025} = 1,96$$

$$E = 0,1/2 = 0,05$$

$$p = 0,19$$

$$n = \left(\frac{z}{E} \right)^2 \cdot p \cdot q = \left(\frac{1,96}{0,05} \right)^2 \cdot 0,19 \cdot 0,81 = 39,3^2 \cdot 0,19 \cdot 0,81 = 236,49 \approx 237$$

p = 0,5 koristimo kada nemamo prethodnih saznanja o pretpostavljenoj proporciji

$$z_{0,025} = 1,96$$

$$E = 0,1/2 = 0,05$$

$$p = 0,5$$

$$n = \left(\frac{z}{E} \right)^2 \cdot p \cdot q = \left(\frac{1,96}{0,05} \right)^2 \cdot 0,5 \cdot 0,5 = 39,3^2 \cdot 0,25 = 384,15 \approx 385$$

STATISTIČKI TESTOVI


"Severely dependent patients had a longer duration of the disease ($p<0.001$) and a longer duration of stay at a nursing home ($p=0.001$) than mildly dependent patients."

"The addicts perceived their mothers as more rejecting ($p=0.018$ for total score), more aggressive ($p=0.007$), and showing more undifferentiated rejection ($p=0.001$) than non-addicts."

STATISTIČKI TEST

- postupak pomoću kojeg se dolazi do **odluke** o prihvaćanju ili odbacivanju **statističke hipoteze** uz **određenu vjerojatnost**

HIPOTEZA ISTRAŽIVANJA



STATISTIČKA HIPOTEZA

HIPOTEZA ISTRAŽIVANJA

- pretpostavka (slutnja) o nekoj populaciji/populacijama koja motivira istraživanje

- medicinske sestre/tehničari mlađih dobnih skupina imaju pozitivniji stav prema uvođenju IT u odnosu na medicinske sestre/tehničare starijih dobnih skupina
- oboljeli od KOBP uključeni u XY program rehabilitacije imaju veće funkcionalne sposobnosti od bolesnika na standardnom tretmanu KOBP
- osobe oboljele od dijabetesa imaju povišen sistolički tlak

STATISTIČKA HIPOTEZA

- izjava (tvrdnja) o nekoj karakteristici (parametru) populacije
- izvodi se iz hipoteze istraživanja
- matematički oblikovana

- može se vrednovati odgovarajućim statističkim postupcima
- prihvaćamo ju ili odbacujemo na osnovu informacija dobivenih iz podataka prikupljenih na uzorku.

STATISTIČKI TEST

NUL-HIPOTEZA
 (H_0)

**ALTERNATIVNA
HIPOTEZA**
 (H_1)

NUL-HIPOTEZA

- polazna hipoteza koja se testira
- "hipoteza o nepostojanju razlike"

ALTERNATIVNA HIPOTEZA

- negacija nul-hipoteze

$$H_0 \dots \mu_1 = \mu_2$$

$$H_1 \dots \mu_1 \neq \mu_2$$

POSTUPAK:

POSTAVLJANJE NUL-HIPOTEZE

I

ALTERNATIVNE HIPOTEZE

**PRIKUPLJANJE
PODATAKA**

TESTIRANJE

DONOŠENJE ODLUKE

POSTAVLJANJE NUL- HIPOTEZE I ALTERNATIVNE HIPOTEZE

- odnose se na neki parametar populacije (sredina, varijanca,...)
- zajedno, moraju obuhvatiti sve moguće odnose promatranih parametara

npr.

$$H_0 \dots \mu_1 = \mu_2$$

⇒ parametri populacija iz kojih su uzorci uzeti su jednaki

⇒ uzorci pripadaju istoj populaciji

$$H_1 \dots \mu_1 \neq \mu_2$$

TESTIRANJE

= izračunavanje odgovarajuće test-statistike



$$\text{test statistika} = \frac{\text{opažena vrijednost} - \text{hipotetska vrijednost}}{\text{standardna pogreška opažene vrijednosti}}$$

npr.

$$\text{test statistika} = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\text{SE}(\bar{x}_1 - \bar{x}_2)}$$

uz


$$H_0 \dots \mu_1 = \mu_2 \Rightarrow \mu_1 - \mu_2 = 0$$

$$\text{test statistika} = \frac{(\bar{x}_1 - \bar{x}_2)}{\text{SE}(\bar{x}_1 - \bar{x}_2)}$$

P-vrijednost

razdioba vjerojatnosti
test statistike kada je H_0 istinita

P-vrijednost



vrijednost test statistike za
dane podatke

ŠTO JE P-VRIJEDNOST?


- NIJE vjerojatnost istinitosti nul-hipoteze (iako je vrlo slično)
- JESTE vjerojatnost dobivanja istih ili ekstremnijih rezultata kada je nul-hipoteza istinita

DONOŠENJE ODLUKE

o odbacivanju H_0

ili

prihvaćanju H_0



POGREŠKE PRI ODLUČIVANJU

		STVARNO STANJE	
		H_0 točna	H_1 točna
ODLUKA	PRIHVATI H_0	ISPRAVNO	POGREŠKA TIPA 2 (β)
	ODBACI H_0	POGREŠKA TIPA 1 (α)	ISPRAVNO

VJEROJATNOSTI POGREŠKE

Najveća vjerojatnost pogreške tipa 1 (α)


- razina značajnosti
- najmanja vjerojatnost uz koju još prihvaćamo H_0
- kada je $P < \alpha$, test sugerira odbacivanje H_0
("statistički značajno")
- određuje ju istraživač na temelju modela pokusa

Najveća vjerojatnost pogreške tipa 2 (β)

- djelomično je pod kontrolom
- ovisi o:
 - stvarnom stanju u populaciji (varijabilitet)
 - efektu od interesa
 - razini značajnosti a
- α i β su inverzno povezane (ali ne direktno)

PODRUČJE PRIHVAĆANJA H_0

razdioba
vjerojatnosti
test statistike kada
je H_0 istinita



PODRUČJE ODBACIVANJA H_0

razdioba
vjerojatnosti
test statistike
kada je H_1 istinita

ODABIR NIVOA ZNAČAJNOSTI

Pitanje štetnih posljedica pogreške:

1. Odluka/zaključak da razlike postoje onda kada ih u stvarnosti nema može prouzročiti štetne posljedice => ***smanjiti vjerovatnost nastajanja pogreške tipa 1, tj. odabrati manji α***
2. Odluka/zaključak da nema razlike onda kada u stvarnosti razlika postoji može prouzročiti štetne posljedice => ***smanjiti vjerovatnost pogreške tipa 2, tj. odabrati veći α***

Ispitivanja lijeka X pokazala su da njegovo korištenje izaziva vrlo štetne posljedice te je lijek X povučen iz uporabe.

Ispitan je novi alternativni lijek Y i ustanovljeno je smanjenje štetnog utjecaja u odnosu na lijek X.

Koju razinu značajnosti treba upotrijebiti za ocjenu značajnosti smanjenja štetnog utjecaja lijeka Y u odnosu na lijek X?

**STVARNO
STANJE:** Oba
lijeka jednako su
štetna.

ODLUKA: Lijek Y
ima manje štetne
posljedice od
lijeka X.

**STVARNO
STANJE:** Lijek Y
manje je štetan
od lijeka X.

ODLUKA: Lijek Y
ima jednako
štetne posljedice
kao i lijek X.

α



β


**STVARNO
STANJE:** Oba
lijeka jednako su
štetna.

ODLUKA: Lijek Y
ima manje štetne
posljedice od
lijeka X.

**STVARNO
STANJE:** Lijek Y
manje je štetan
od lijeka X.

ODLUKA: Lijek Y
ima jednako
štetne posljedice
kao i lijek X.

α



β

Na slučajnom uzorku vozača ispitivan je utjecaj alkohola na vrijeme reagiranja. Mjerenja vremena reakcije prije i nakon konzumacije određene količine alkohola pokazala su prosječno povećanje vremena reakcije nakon konzumacije alkohola.

Koju razinu značajnosti treba upotrijebiti za ocjenu značajnosti pronađene razlike?

**STVARNO
STANJE:**
Alkohol ne
utječe na
vrijeme reakcije.

**STVARNO
STANJE:**
Alkohol
produljuje
vrijeme reakcije.

ODLUKA:
Alkohol
produljuje
vrijeme reakcije

ODLUKA:
Alkohol ne utječe
na vrijeme
reakcije.

α



β

**STVARNO
STANJE:**
Alkohol ne
utječe na
vrijeme reakcije.

ODLUKA:
Alkohol
produljuje
vrijeme reakcije

**STVARNO
STANJE:**
Alkohol
produljuje
vrijeme reakcije.

ODLUKA:
Alkohol ne utječe
na vrijeme
reakcije.

α



β

POSTAVKE DIZAJNA

- općenito testove treba dizajnirati tako da imaju

$$\beta \geq \alpha$$

a gdje je odabrani β 0.2 ili 0.1

- izraz

$$100 \cdot (1 - \beta) \%$$

naziva se (*statistička*) **SNAGA TESTA**

SNAGA TESTA

- šansa da se detektira određena alternativna hipoteza kada je stvarno točna
- **NEETIČNO je (a i skupo!) raditi istraživanja male snage !**

ŠTO I KAKO UTJEČE NA SNAGU TESTA



Statistička značajnost

NIJE isto što i

klinička važnost!


VIŠESTRUKA TESTIRANJA

- ugrožavaju valjanost
- povećavaju pogrešku tipa 1

$$\alpha_r = 1 - (1 - \alpha)^r$$

za $\alpha = 0.05$ i r višestrukih testova

r	1	2	3	4	5	10	15	20
α_r	0.050	0.098	0.143	0.185	0.226	0.401	0.537	0.642



AKO MUČITE PODATKE
DOVOLJNO DUGO
ONI ĆE NAPOSLIJETKU
PRIZNATI !!!



- rješenje:
 - prilagodba P-vrijednosti u cilju održavanja općeg nivoa značajnosti (Bonferroni, Sidak, Hochberg...)
 - primjena složenijih metoda analize (npr. ANOVA, multivariatne metode)

IZBOR STATISTIČKOG TESTA

Ne ovisi u velikoj mjeri o veličini uzorka nego:

- prirodi (tipu i raspodjeli) varijabli
- broju uzoraka (1, 2 ili više)
- jesu li su uzorci zavisni ili ne

		VARIJABLA		
BROJ UZORAKA		NOMINALNA	ORDINALNA ILI NUMERIČKA KOJA NIJE NORMALNO DISTRIBUIRANA	NUMERIČKA NORMALNO DISTRIBUIRANA
JEDAN		χ^2 -test	Kolmogorov-Smirnov test	t-test
DVA	NEZAVISNI	χ^2 -test Fisherov egzaktni test	Mann-Whitney U test Medijan test	Studentov t-test
	ZAVISNI	McNemarov test	Wilcoxonov test	t-test diff.
VIŠE OD 2	NEZAVISNI	χ^2 -test	Kruskall-Wallis test	ANOVA
	ZAVISNI	Cochran Q Stuart-Maxwell	Friedmanov test	ANOVA za ponavljana mjerenja
POVEZANOST DVIJU VARIJABLJI		Koef. kontingencije Kappa koef.	Spermanov r Kendalov τ	Pearsonov r

POSTAVLJANJE H_0 i H_1

izbor α i $(1-\beta)$


određivanje veličine uzorka POTREBNE
da se uz ODABRANE α i $(1-\beta)$
detektira ŽELJENI efekt

prikupljanje primjerenih podataka

izbor odgovarajućeg testa

računanje test statistike

određivanje odgovarajuće P-vrijednosti



DONOŠENJE ODLUKE - TUMAČENJE