

# **ANALIZE PODATAKA U BIOLOŠKIM ISTRAŽIVANJIMA**

**2P + 3V**

Izv. prof. Anamaria Štambuk, Biološki odsjek, PMF [astambuk@biol.pmf.hr](mailto:astambuk@biol.pmf.hr)

Izv. prof. Toni Safner, Agronomski fakultet [tsafner@agr.hr](mailto:tsafner@agr.hr), [tsafner@gmail.com](mailto:tsafner@gmail.com)

Izv. prof. Rosa Karlić, Biološki odsjek, PMF [rosa@bioinfo.hr](mailto:rosa@bioinfo.hr)

Lucija Kanjer, Biološki odsjek, PMF [lucija.kanjer@biol.pmf.hr](mailto:lucija.kanjer@biol.pmf.hr)

## **Opcija 1 – kontinuirano praćenje:**

- Studenti trebaju položiti **dva kolokvija** tijekom semestra. Svaki kolokvij sastoji se od zadataka s podacima koje treba analizirati na računalu. Na kolokviju je moguće **koristiti sve mrežne izvore i literaturu**. Iz oba kolokvija potrebno je ostvariti minimalnu uspješnost 70%. Ocjena odgovara ukupnom postotku savladanog gradiva kroz oba kolokvija.

## **Opcija 2 (polaganje ispita u ispitnim rokovima):**

- Ispit se sastoji od projektnog zadatka koji student treba riješiti prije ispita, te na usmenom ispitу prezentirati i obrazložiti postupak i rješenje.

Izvrstan (5)	90-100%
Vrlo dobar (4)	80-89%
Dobar (3)	70-79%
Dovoljan (2)	60-69%

# ANALIZE PODATAKA U BIOLOŠKIM ISTRAŽIVANJIMA

## Ciljevi kolegija?

- Matematičko razumijevanje statističkih modela
- Programiranje u R-u
- Odvedene biostatističke metode

### Ishodi učenja

- 1) Raspoznati vrste bioloških podataka i varijabli
- 2) Razumjeti osnovne postavke prikupljanja podataka u biološkim istraživanjima
- 3) Primijeniti odgovarajuće osnovne statističke analize podataka u biološkim istraživanjima
- 4) Koristiti se programskim okruženjem R za prikaz i statističku analizu podataka u biološkim istraživanjima
- 5) Interpretirati rezultate osnovnih deskriptivnih i statističkih metoda u biologiji

# **ANALIZE PODATAKA U BIOLOŠKIM ISTRAŽIVANJIMA**

## **Ciljevi kolegija?**

- Percepcija bioloških pitanja i eksperimenata kroz varijable
- Koncepti eksperimentalnog pristupa kroz postavljanje hipoteze
- Dizajniranje istraživanja s obzirom na hipotezu, uzorkovanje i varijable
- Testiranje hipoteza kroz osnovne biostatističke metode
- Grafički prikaz podataka
- Snalaženje u radu u okruženju R

# **ANALIZE PODATAKA U BIOLOŠKIM ISTRAŽIVANJIMA**

Kvalitativna i kvantitativna istraživanja

Kvalitativni i kvantitativni podaci

# ~~ANALIZE PODATAKA U BIOLOŠKIM ISTRAŽIVANJIMA~~

## Kvalitativna istraživanja - opisna/deskriptivna istraživanja

- Istraživanja u kojima ne analiziramo podatke kvantitativno
  - Nema testiranja hipoteze
- 
- Popis vrsta ptica selica na području Parka Prirode Kopački rit
  - Popis lokaliteta invazivne biljne vrste žljezdasti nedirak *Impatiens glandulifera* Royle na području Zagrebačke županije
  - Taksonomija i rasprostranjenost uholaža (Insecta: Dermaptera) u Hrvatskoj

## Kvantitativna istraživanja

- Položaj kromosoma 1 i 9, obilježenih pomoću tehnologije CRISPR/Cas9, u odnosu na jezgrinu ovojnicu i centrosome
- Neofobija juvenilnih jedinki iz pokusa križanja populacija primorske gušterice (*Podarcis siculus*)
- Mutacijski potpisi u topološki asocirajućim domenama uvealnog i kožnog melanoma čovjeka
- Morfološke značajke riba roda *Romanogobio* u dunavskom slijevu Hrvatske

## KVALITATIVNI I KVANTITATIVNI PODACI

- Mjerenja ili opažanja podataka na setu uzoraka su **varijable**
- **Biološke varijable** su **mjerenja ili svojstva koja se razlikuju na bilo kojoj razini biološke organizacije** (molekula, stanica, tkivo, jedinka, populacija/vrsta, ekosustav..)

npr. DNA sekvenca promotora, broj mitohondrija, aktivnost enzima, veličina i broj makrofaga, ekspresija gena, prokrvljenost tumora, genotip, broj točki na krilima, duljina tibije, spol, dob, agresivnost, generacijsko vrijeme, udio mužjaka, broj bakterija, raznolikost vrsta, ...

- U ekološkim, biomedicinskim, biokemijskim i mnogim molekularnim istraživanjima važne su i kemijske i fizikalne (**okolišne**) **varijable**

npr. konc.  $\text{CO}_2$ , temperatura, mineralni sastav, kemijski sastav otopine (uključujući koncentracije), elektromagnetska i ionizirajuća zračenja, brzina strujanja zraka/vjetra, udaljenost od kopna, izomerna konfiguracija molekule...

# ANALIZE PODATAKA U BIOLOŠKIM ISTRAŽIVANJIMA

Kvantitativna istraživanja – uključuju kvantitativnu analizu podataka

Vrlo često biostatistika podrazumijeva utvrđivanje povezanost (*association*) dvije varijable, ili nalaženje razlika među grupama

Npr. *pokazuju li mladi poskoci brži agresivni odgovor na prijetnju?*

- Brzina reakcije ovisi o starosnoj kategoriji
- Starost i brzina reakcije su povezani



Npr. *Ima li najviše polifenola u grožđu sorte Plavac mali, sorte Zifandel ili Shiraz?*

- Količina polifenola ovisi o sorti grožđa
- Sorta grožđa i količina polifenola su povezani



## PITANJE – **HIPOTEZA/VARIJABLE** – DIZAJNIRANJE EKSPERIMENTA (UZORAK) – TESTIRANJE HIPOTEZE

- ZAVISNE I NEZAVISNE VARIJABLE
- KATEGORIČKE I NUMERIČKE VARIJABLE
- GRUPIRAJUĆE VARIJABLE

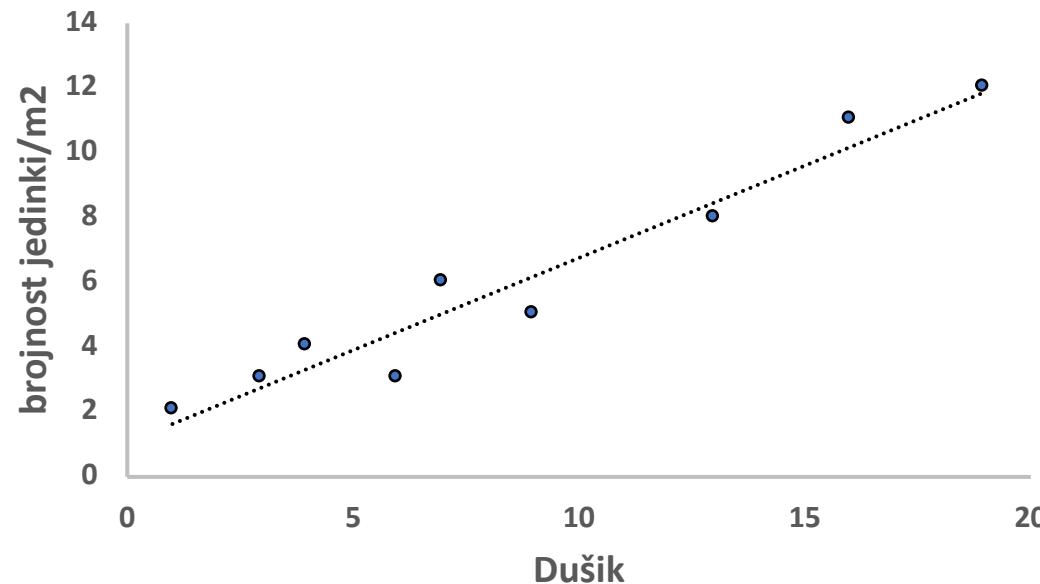
## ZAVISNE I NEZAVISNE VARIJABLE

- **Nezavisne varijable (*predictor, explanatory*) su one koje mogu uzrokovati promjenu u zavisnoj varijabli (*outcome, response*)**
  - Nezavisne varijable manipuliramo u eksperimentima
- 
- Pokazuju li mladi poskoci brži agresivni odgovor na prijetnju?
  - Ima li najviše polifenola u grožđu sorte *Plavac mali*, sorte *Zifandel* ili *Shiraz*?
  - Imaju li miševi s tumorom štitnjače višu temperaturu od zdravih?
  - Induciraju li muški istraživači veći strah kod štakora?
  - Jesu li maslačci na višim nadmorskim visinama niži?
  - Spavaju li meduze duže po noći ili danu?
  - Pribjegavaju li brašnari kanibalizmu više prema ličinkama ili kukuljicama?



## ZAVISNE I NEZAVISNE VARIJABLE

- OPREZ! Katkada je povezanost varijabli nejasna na prvi pogled!
- Npr. sadržaj dušika u tlu i brojnost neke biljne vrste – ukoliko postoji povezanost (korelacija), potrebno je manipulirati jednu i drugu varijablu jer gustoća biljne populacije može utjecati na sadržaj dušika!

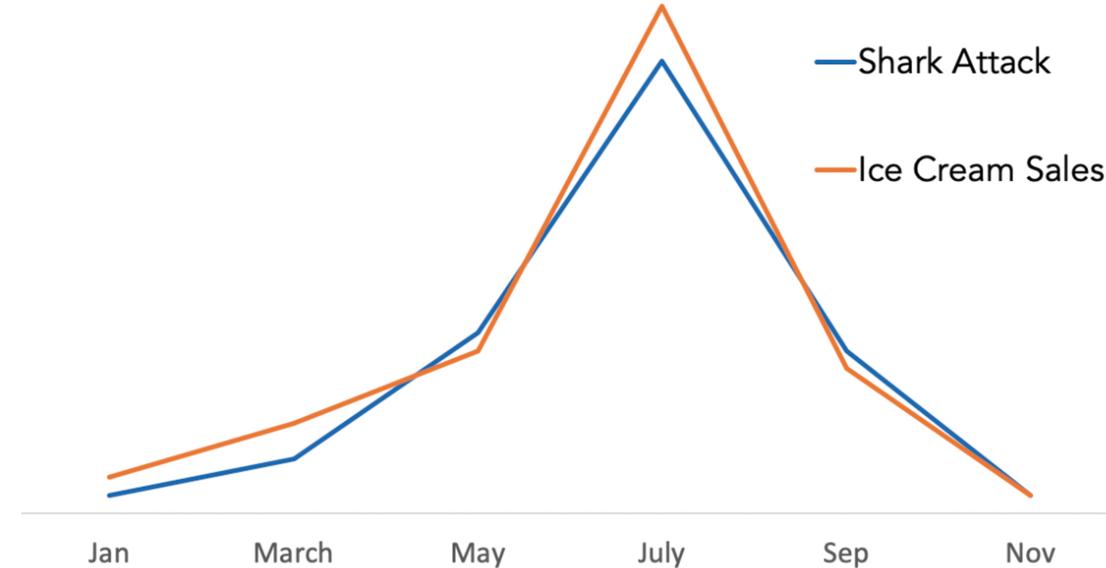


KORELACIJA NIJE REGRESIJA I NE UKAZUJE NA UZORČNO POSLJEDIČNI ODNOS VARIJABLI

## ZAVISNE I NEZAVISNE VARIJABLE

- OPREZ! Katkada je povezanost varijabli netočna na prvi pogled!

## PRIVIDNE (*spurious*) POVEZANOSTI



KORELACIJA NIJE REGRESIJA I NE UKAZUJE NA UZORČNO POSLJEDIČNI ODнос VARIJABLI

## ZAVISNE I NEZAVISNE VARIJABLE

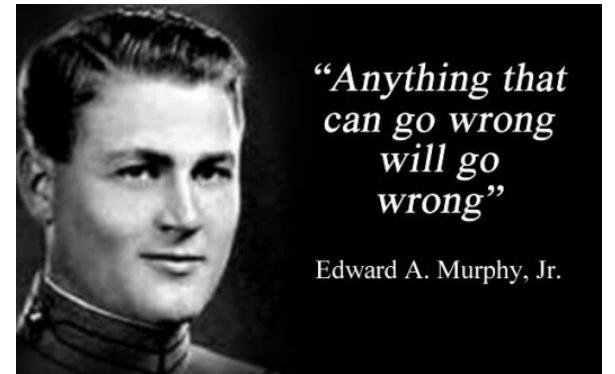
Posebna kategorija **nezavisnih varijabli** su **kontrolirane varijable** – važno je da su jednake kroz cijeli eksperiment (istraživanje)

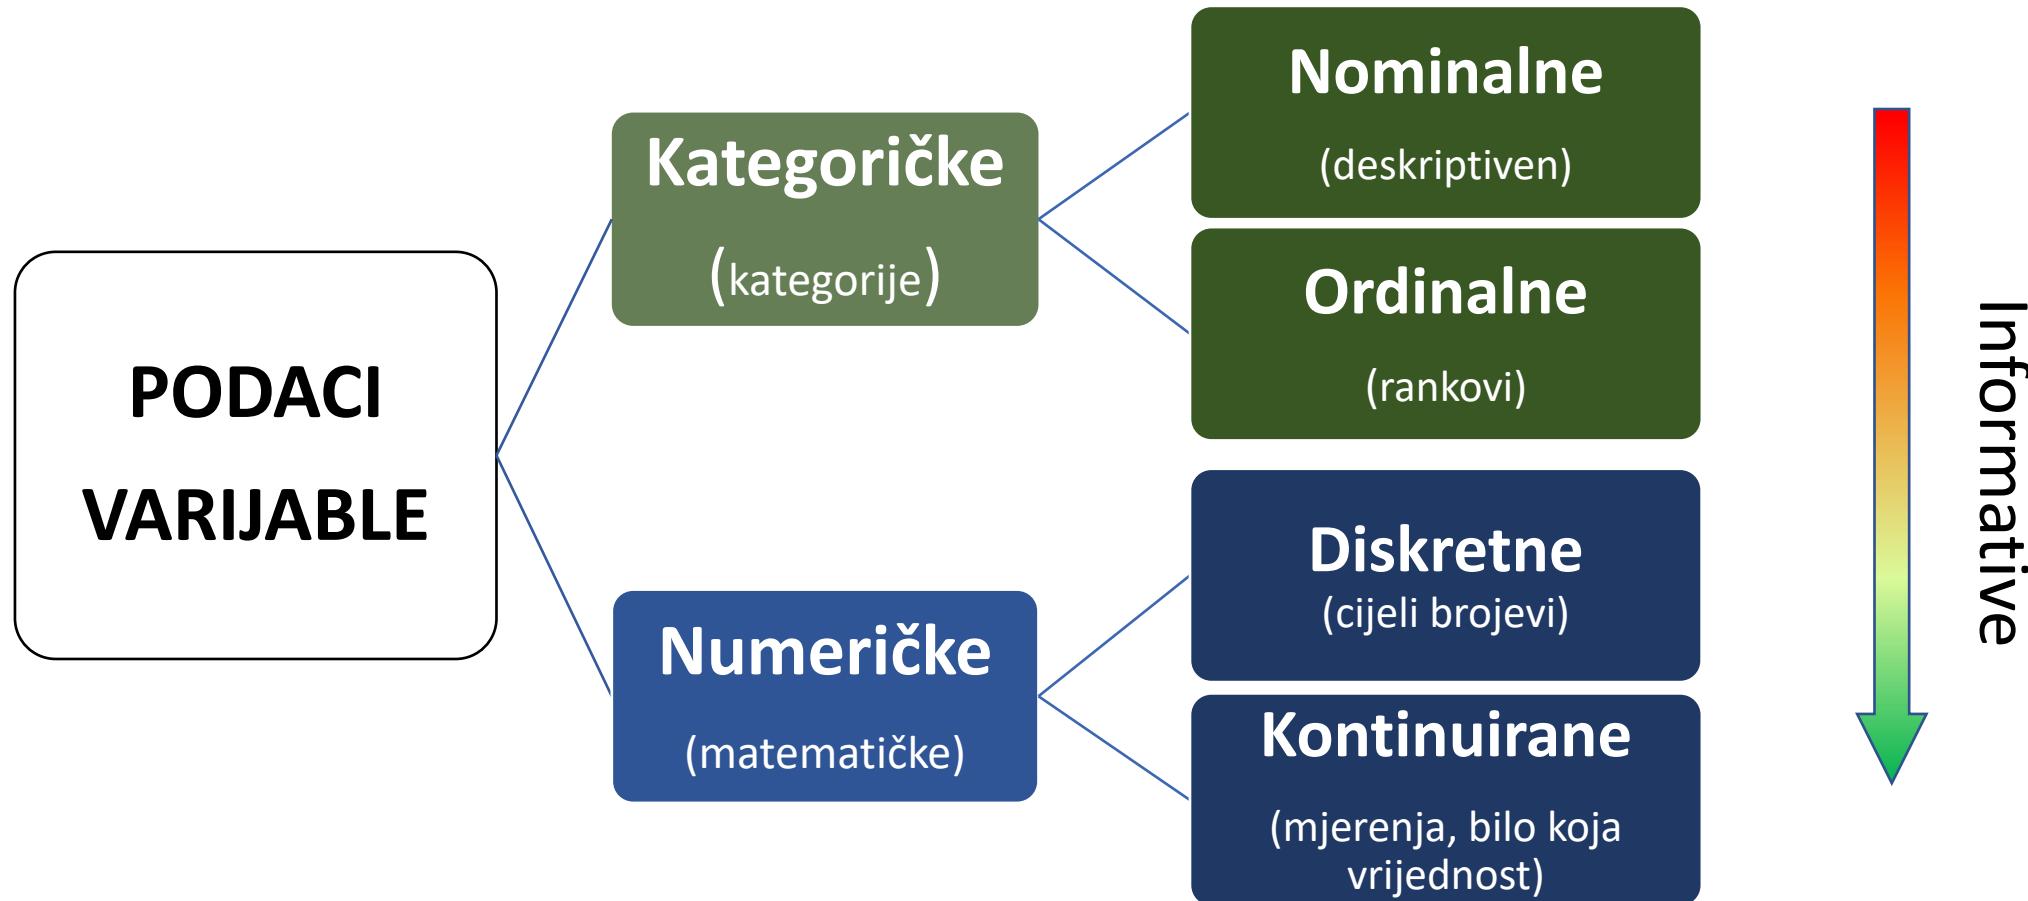
- Npr. *Pokazuju li mladi poskoci brži agresivni odgovor na prijetnju?*

Ukoliko se poskoci razlikuju u brzini agresivnog odgovora po spolu, idealno bi bilo da se odvojeno testira za mušjake i ženke (u nekim slučajevima dovoljno je da obje skupine sadrže jednaku zastupljenost po spolovima)

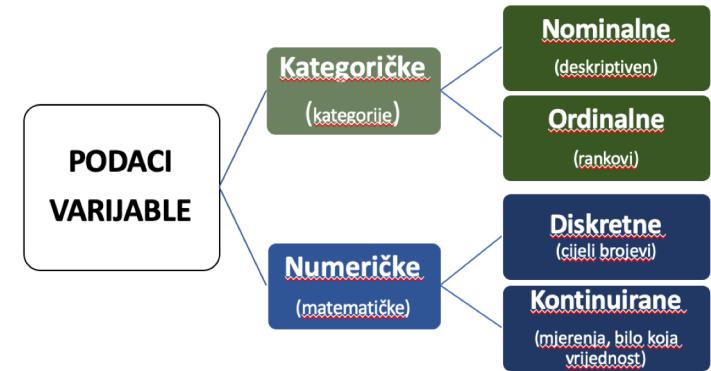
**Starost i spol** su samo neke od varijabli koje su često kontrolirane! – bitno je razmisliti koje varijable mogu još utjecati na zavisnu varijablu (**interni i eksterni, abiotiski i biotski mikrookoliš**)

- Npr. *položaj jedinke ili posude u prostoriji, u staništu, pušački status, prehrana, utjecaj istraživača, režim svjetlosti, temperatura, reproduktivni status, microbiom, iste kemikalije korištene*

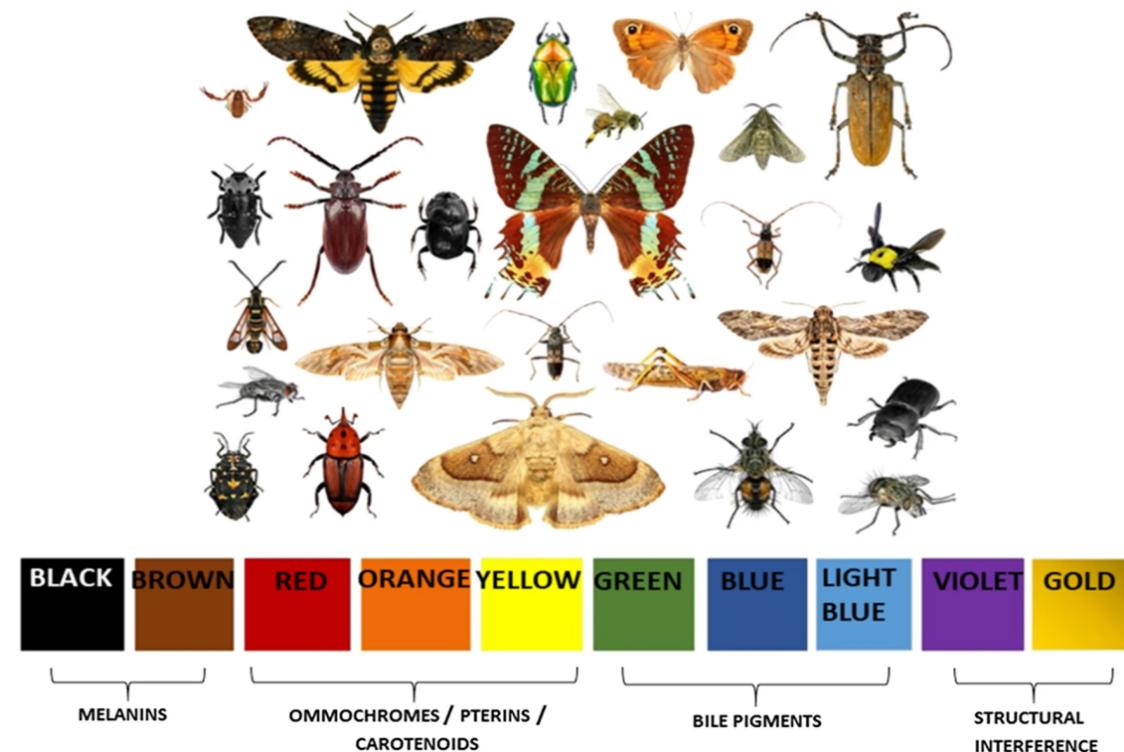




# KATEGORIČKE (KVALITATIVNE) VARIJABLE

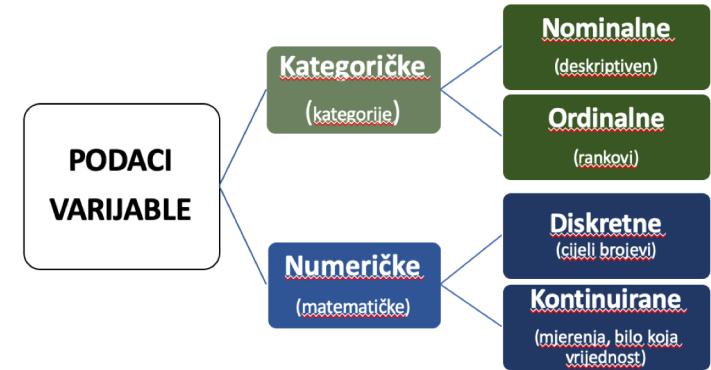


- Sve koje nisu izmjerene
- Svojstva ili kategorije
- Konačni broj mogućih vrijednosti



# Nominalne (kategoričke) varijable

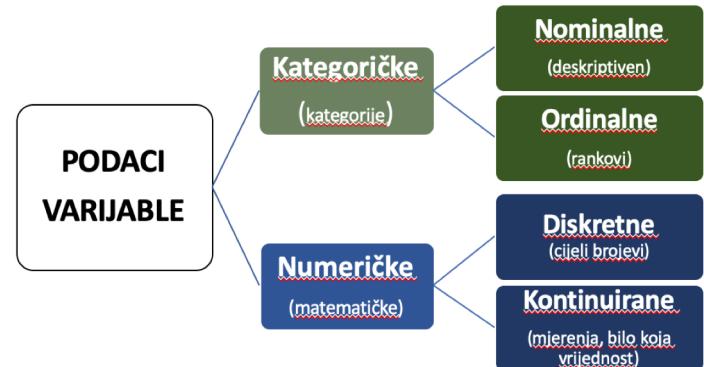
- **Opisne, kvalitativne (bez vrijednosti)**
- **Često se koriste kao grupirajuće varijable**
- *Populacija, tip stanica, spol, vrsta, genotip (npr. XX, XY), aminokiselina na 52. mestu fosfomukoglutaze vinske mušice (VA, AV, VV, AA), boja, krvna grupa, stanište (šuma, polje, livada..), tip imunomodulatora..*
- Mogu biti dihotomske: DA/NE, ŽIV/MRTAV, 0/1



**Ime uzorka je isto nominalna varijabla**, npr. Miš\_1, Miš\_2, Miš\_3, pacijent Pero Perić, XX\_AB\_27

## Ordinalne (kategoričke) varijable

- **Kvalitativne (često opisne) ali se mogu rangirati**
- Životni stadiji: jaje, ličinka, kukuljica, odrasli; juvenilni, odrasli, stari.
- Kategoriziranje kvantitativnih vrijednosti: spor, srednje brz, brz; nizak HDL, normalan HDL, visok HDL
- Svjetlo, sjena, mrak
- Nezrel plod, zrel, prezrel, truo
- Malen, srednje velik, velik

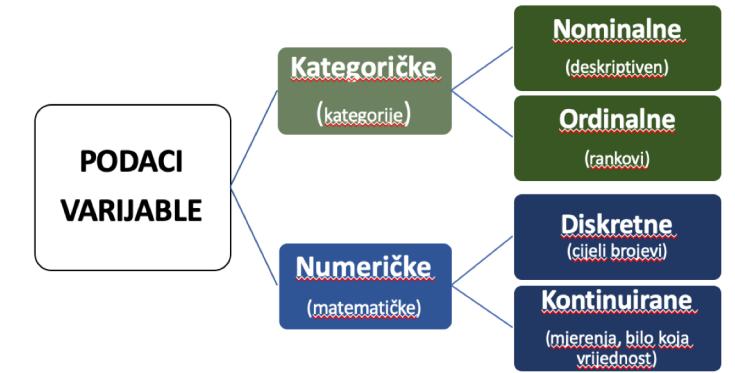


**U slučaju kada su brojčane vrijednosti, nemaju numeričke odnose kao korišteni brojevi**

- Npr. pratite vremenski redoslijed izlijeganje mladih kornjača po spolu

1.	2.	3.	4.	5.	6.	7.	8.	9.	10.
F	F	F	F	M	F	M	M	M	M

**Spol nije ordinalna varijabla!**

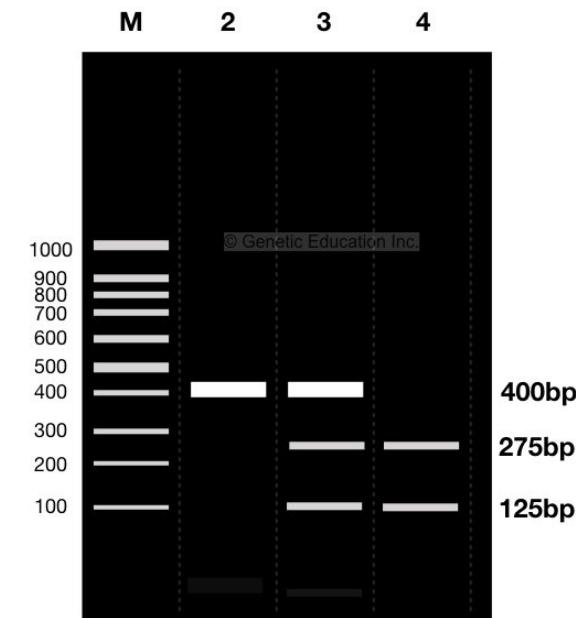
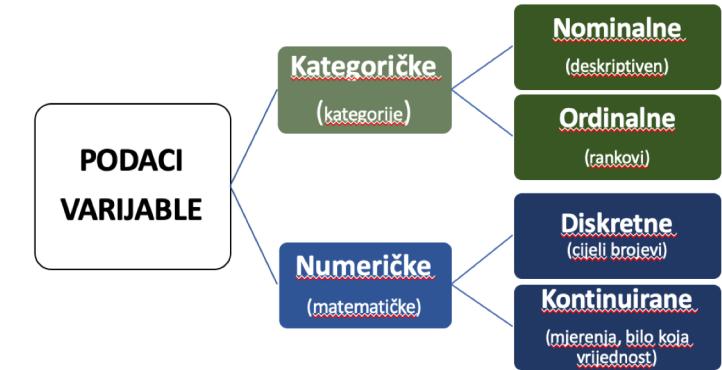


## NUMERIČKE (KVANTITATIVNE) VARIJABLE

- Najčešće ih mjerimo ili brojimo

# Diskretne (numeričke) varijable

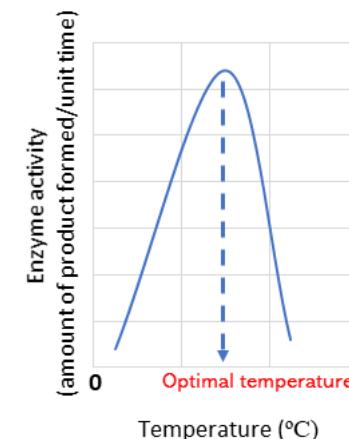
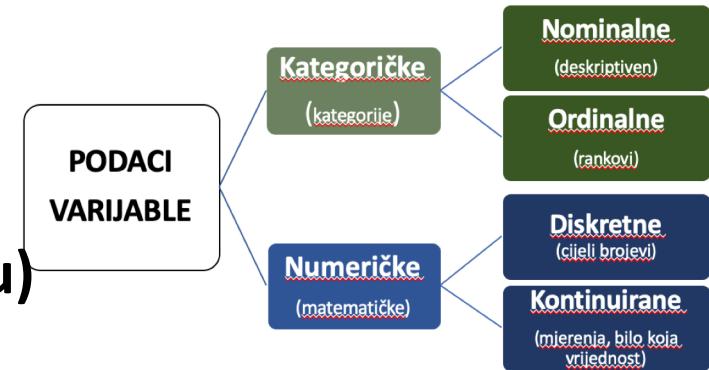
- **Cijeli brojevi (nisu moguće sve numeričke vrijednosti)**
- **Uglavnom brojnosti**
- *Broj sjemenki, duljina sekvence (bp), broj mladunaca, broj zamaha krilima*
- *Merističke značajke: broj trnaca na kliještima, šipčica u peraji*



U slučajevima kada je mali broj mogućih vrijednosti, bolje ih je tretirati kao ordinalne (nominalne) varijable

# Kontinuirane (numeričke) varijable

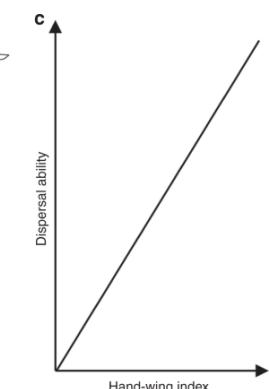
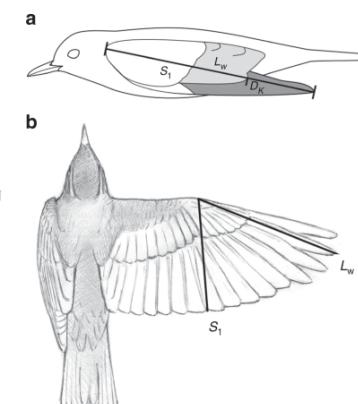
- **Uglavnom mjerena**
- **Realni brojevi (moguće sve numeričke vrijednosti u intervalu)**
- **Sadržaj informacije i moć statističke analize je mnogo veća!**
- Statistički testovi komplikiraniji jer je neophodno provjeriti distribuciju i druge pretpostavke
- *Morfometrijske veličine (masa, visina, širina), količina lipida u stanici, gustoća populacije, aktivnost enzima*
- *Veličine kemijskih i fizikalnih čimbenika (valne duljine, pH, temperatura, koncentracija agensa u tretmanu; put koji pređe makrofag, energetska učinkovitost razmnožavanja*

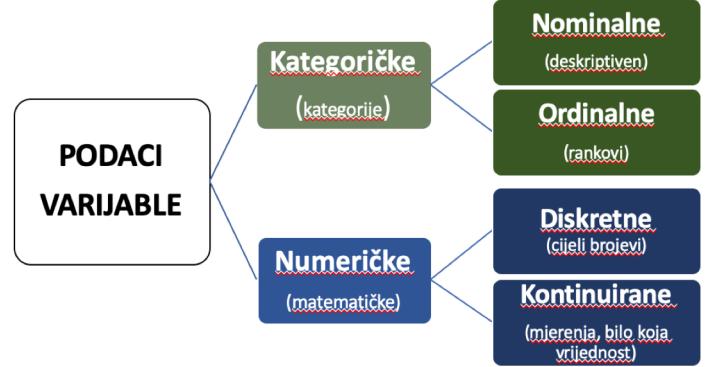


$$\begin{aligned} n &= 1 \\ \sum R_i &\approx 61 \text{ MJ} \\ \sum M_i &= 30 \text{ kg} \end{aligned}$$



$$\begin{aligned} n &= 37 \\ \sum R_i &\approx 61 \text{ MJ} \\ \sum M_i &= 74 \text{ kg} \end{aligned}$$





- Sva četiri tipa varijabli mogu biti i zavisne i nezavisne!