

Testiranje razlika u srednjoj vrijednosti (parametrijske i neparametrijske metode)

03.12.2024.

Rosa Karlić

Analize bioloških podataka 2024/2025

Zašto testirati razlike u srednjoj vrijednosti?

Primjer:

Kako izloženost zagađivaču iz vode (poliklorirani bifenili, PCB) utječe na imunološki odgovor vodozemaca i koji su daljnji učinci na dinamiku populacije i zdravlje ekosustava?

Ciljevi studije:

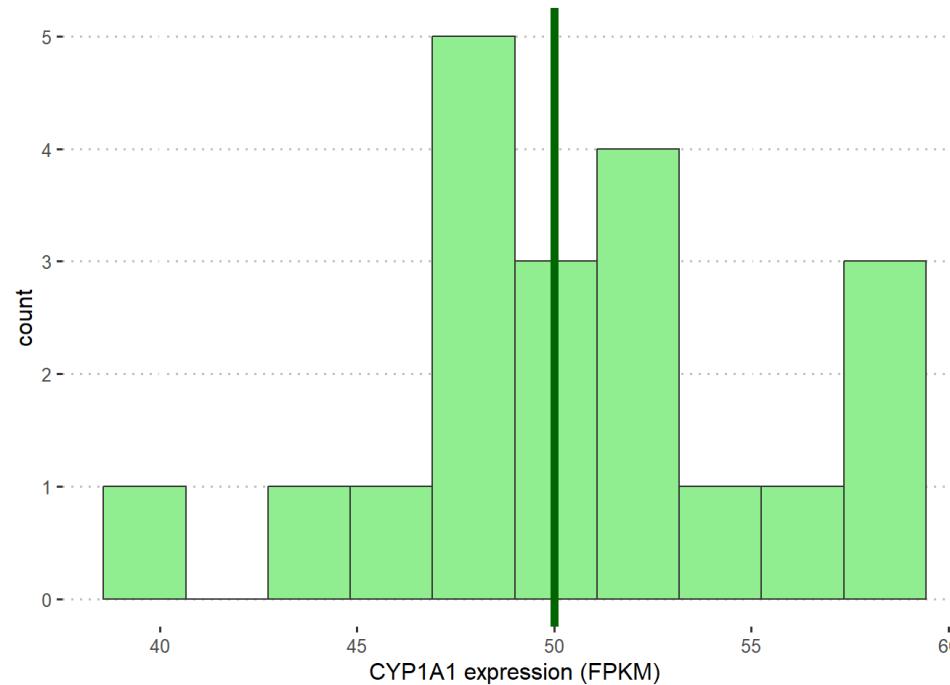
1. Istražiti promjene ekspresije gena u genima povezanim s imunološkim sustavom kod vodozemaca izloženih zagađenju (npr. CYP1A1, IL-6, IL-1 β and TNF- α).
2. Istražiti imunološku reakciju (npr. razinu citokina) kod izloženih vodozemaca.
3. Kvantificirati razinu onečišćujućih tvari u vodi i procijeniti njihov ekološki utjecaj na ekosustav.
4. Mjeriti preživljenje, reprodukciju i ponašanje vodozemaca u zagađenim naspram kontrolnih okoliša.

Zašto testirati razlike u srednjoj vrijednosti?

- **Testiranje znanstvenih ili istraživačkih hipoteza o parametrima populacije.**
Povećava li PCB razinu ekspresije CYP1A1?
- **Jesu li uočene razlike posljedica prirodne varijacije ili značajnog učinka.**
Jesu li razlike razini ekspresije CYP1A1 uzrokovane tretmanom ili slučajnom varijacijom?
- **Kvantifikacija veličine učinka (ne samo postoji li razlika, nego i kolika je razlika)**
Koliko razina PCB-a utječe ekspresiju gena CYP1A1?
- **Identifikacija trendova tijekom vremena (promjene unutar iste grupe ispitanika/subjekata)**
Je li se razina ekspresije gena CYP1A1 vratila na normalnu razinu nakon uklanjanja onečišćenja?

Testiranje hipoteza

- Na temelju prethodnih istraživanja prepostavljamo da je srednja vrijednost ekspresije gena CYP1A1 50 FPKM.
- Kako testirati ovu hipotezu?
- Podupiru li naši podaci ovu hipotezu?

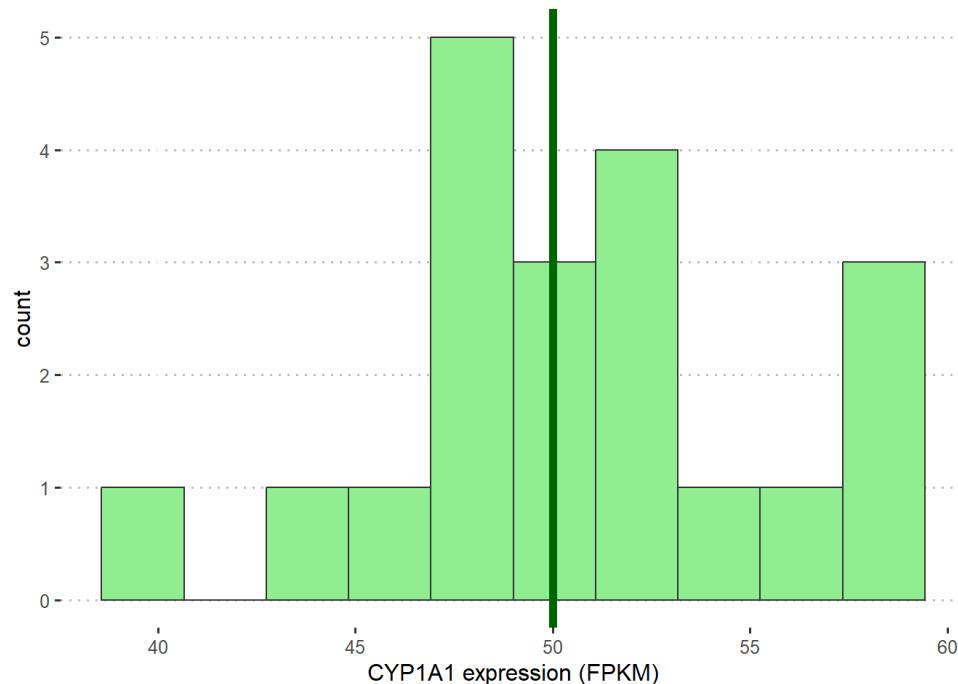


Testiranje statističkih hipoteza

- **Statistička hipoteza** – pretpostavka o parametru populacije (može i ne mora biti istinita)
- **Nulta hipoteza (H_0)** – hipoteza koju testiramo, uglavnom hipoteza koja govori da su naša opažanja rezultat slučajnosti
- **Alternativna hipoteza (H_1 ili H_a)** – hipoteza koja govori da na ispitanike u uzorku utječe neki ne-slučajni (non-random) uzrok
- Ispitujemo nasumičan uzorak iz populacije
- Ako su podaci iz uzorka u skladu s nultom hipotezom (na određenoj razini pouzdanosti) ne odbacujemo ju, u suprotnom – odbacujemo nultu hipotezu

Testiranje hipoteza

- Na temelju prethodnih istraživanja prepostavljamo da je srednja vrijednost ekspresije gena CYP1A1 50 FPKM.
- Kako testirati ovu hipotezu?
- Podupiru li naši podaci ovu hipotezu?



$$t = \frac{\bar{x} - \mu}{s / \sqrt{n}}$$

test statistika = $\frac{\text{sistematska varijacija}}{\text{nesistematska varijacija}} = \frac{\text{učinak}}{\text{greška}}$

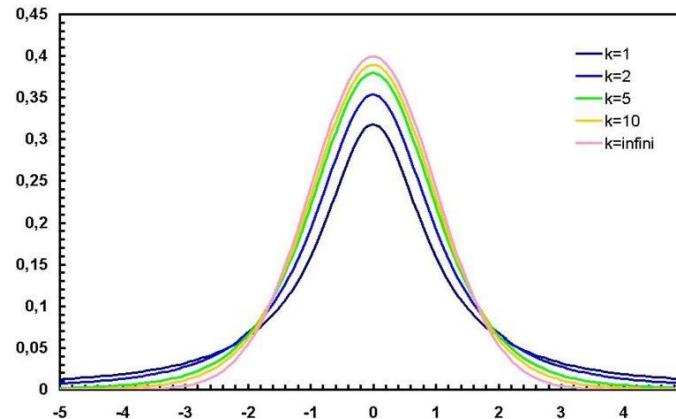
Studentov t-test (jedan uzorak)

- t-statistika

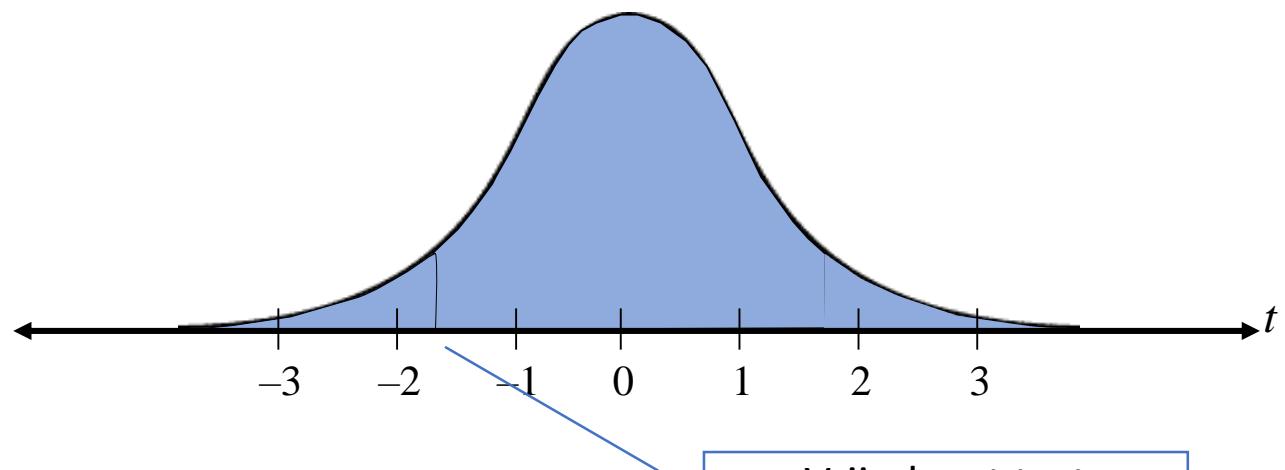
$$t = \frac{\bar{x} - \mu}{s / \sqrt{n}}$$

$$SE_{\bar{x}} = s / \sqrt{n}$$

- Ukoliko je nulta hipoteza točna t-statistika će slijediti t-distribuciju sa $n-1$ stupnjeva slobode



$$f_{\nu}(t) = \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\nu\pi}\Gamma(\frac{\nu}{2})} (1 + \frac{t^2}{\nu})^{-(\nu+1)/2}$$

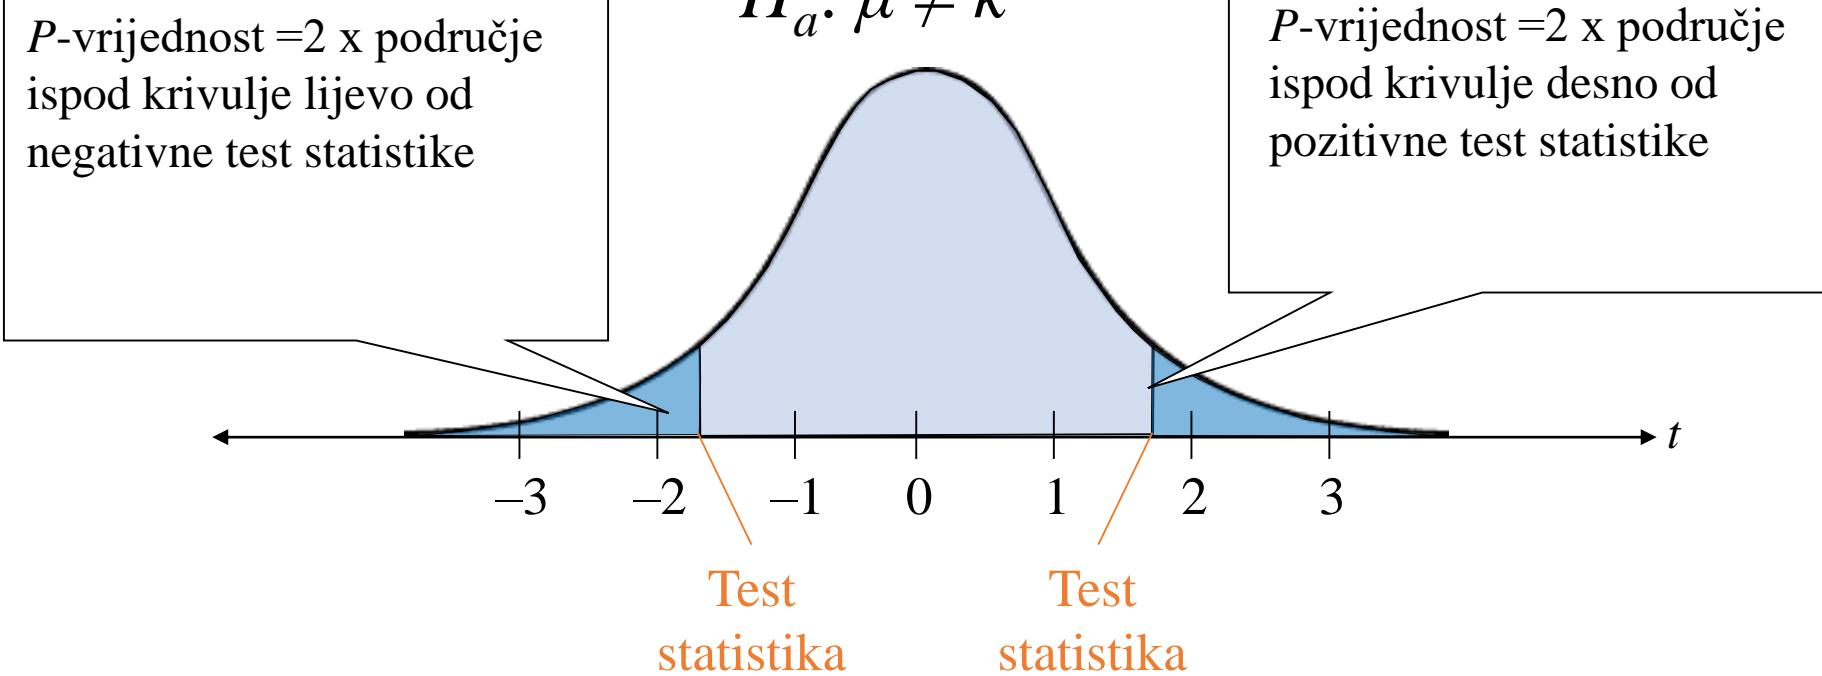


Vrijednost test statistike

Studentov t-test (jedan uzorak)

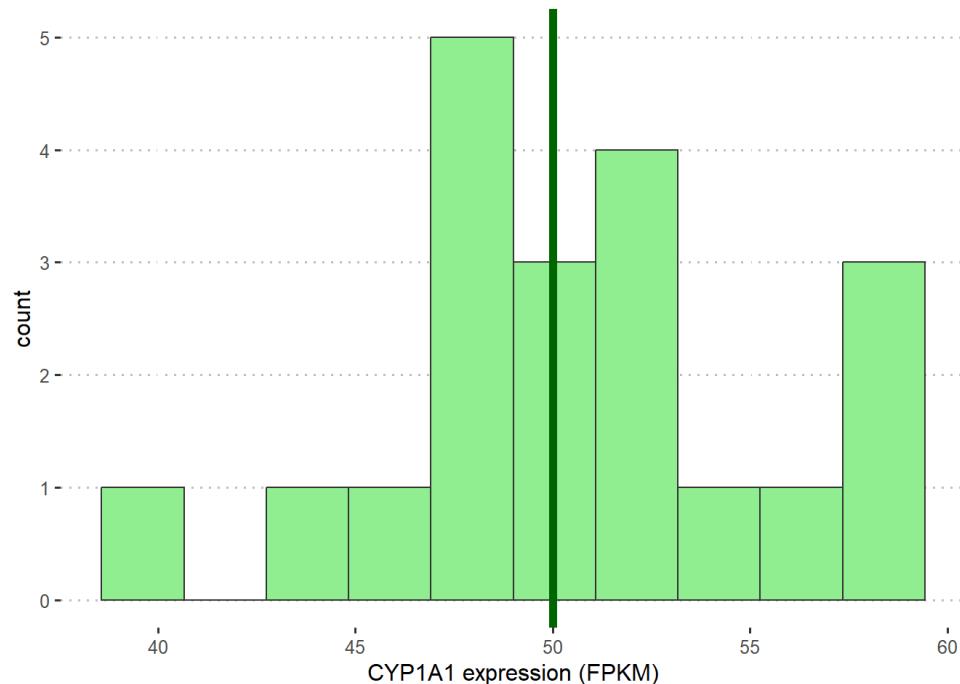
$$H_0: \mu = k$$

$$H_a: \mu \neq k$$



Testiranje hipoteza

- Na temelju prethodnih istraživanja prepostavljamo da je srednja vrijednost ekspresije gena CYP1A1 50 FPKM.
- Kako testirati ovu hipotezu?
- Podupiru li naši podaci ovu hipotezu?



One-sample t-test

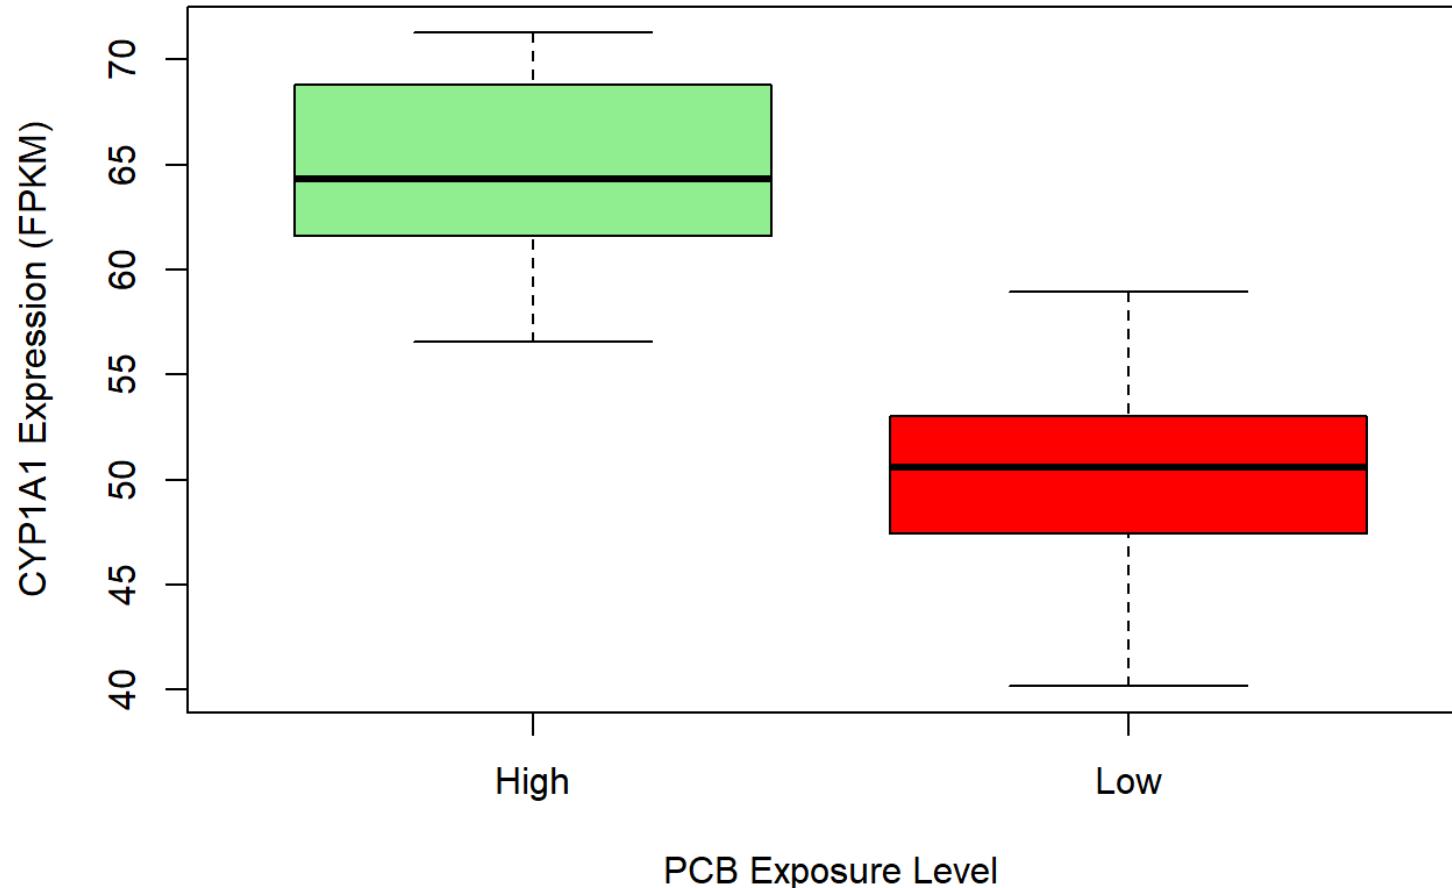
```
t.test(pcb_data[pcb_data$Exposure == "Low", "GeneExpression"], mu = 50)
```

```
##  
## One Sample t-test  
##  
## data: pcb_data[pcb_data$Exposure == "Low", "GeneExpression"]  
## t = 0.65116, df = 19, p-value = 0.5227  
## alternative hypothesis: true mean is not equal to 50  
## 95 percent confidence interval:  
## 48.43201 52.98423  
## sample estimates:  
## mean of x  
## 50.70812
```

Ne odbacujemo nultu hipotezu!

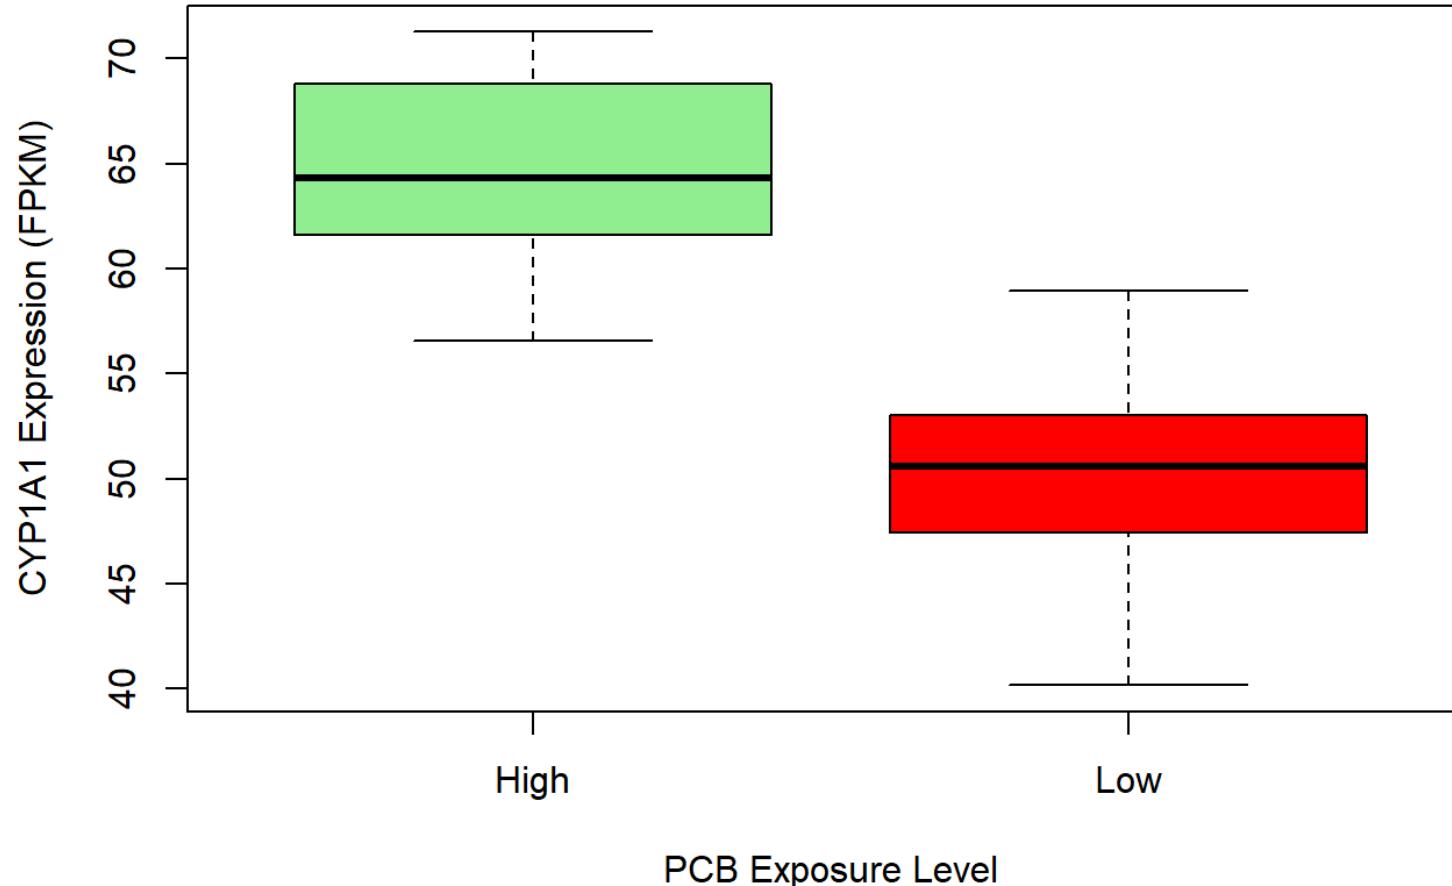
Što ako želimo usporediti dvije različite skupine?

- Ekspresija gena CYP1A1 u kontrolnoj skupini i u vodozemaca izloženih PCB-u.



Što ako želimo usporediti dvije različite skupine?

- Ekspresija gena CYP1A1 u kontrolnoj skupini i u vodozemaca izloženih PCB-u.



$$t_{n_1+n_2-2} = \frac{\bar{X}_1 - \bar{X}_2}{SE_{\bar{X}_1 - \bar{X}_2}} = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{s_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

Studentov t-test (dva uzorka)

$$H_0: \mu_1 = \mu_2$$

$$H_a: \mu_1 \neq \mu_2$$

```
# Perform t-test to compare gene expression between low and high PCB exposure
t_test_result <- t.test(GeneExpression ~ Exposure, data = pcb_data, var.equal = T )
print(t_test_result)
```

```
##
##  Two Sample t-test
##
## data:  GeneExpression by Exposure
## t = 9.8182, df = 38, p-value = 5.67e-12
## alternative hypothesis: true difference in means between group High and group Low is not
## equal to 0
## 95 percent confidence interval:
## 11.14164 16.92955
## sample estimates:
## mean in group High  mean in group Low
##             64.74371          50.70812
```

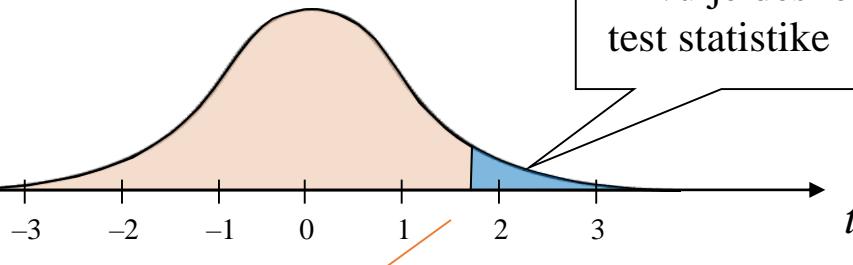
Jednostrani (one-tailed) Studentov t-test (dva uzorka)

- Nas zapravo zanima povećava li se ekspresija gena CYP1A1 kod vodozemaca izloženih PCB-u.

$$H_0: \mu \leq k$$

$$H_a: \mu > k$$

P-vrijednost =
područje ispod
krivulje desno od
test statistike

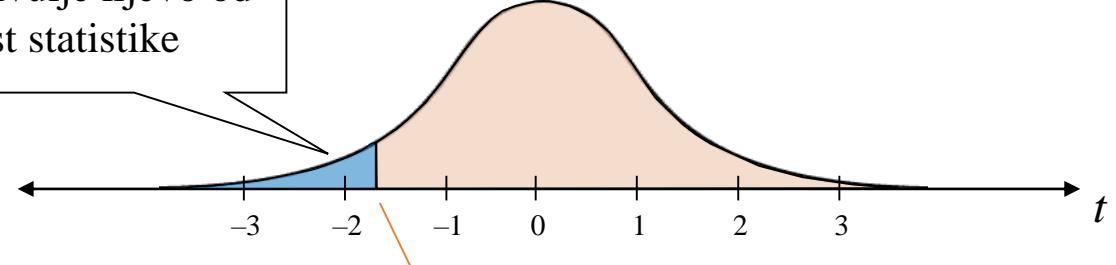


Test
statistika

$$H_0: \mu \geq k$$

$$H_a: \mu < k$$

P-vrijednost =
područje ispod
krivulje lijevo od
test statistike



Test
statistika

Jednostrani (one-tailed) Studentov t-test (dva uzorka)

- Nas zapravo zanima povećava li se ekspresija gena CYP1A1 kod vodozemaca izloženih PCB-u.

```
# Perform t-test to compare gene expression between low and high PCB exposure
t_test_result_one <- t.test(GeneExpression ~ Exposure, data = pcb_data, var.equal = T,
  alternative = "g")
print(t_test_result_one)
```

```
##
##  Two Sample t-test
##
## data: GeneExpression by Exposure
## t = 9.8182, df = 38, p-value = 2.835e-12
## alternative hypothesis: true difference in means between group High and group Low is
## greater than 0
## 95 percent confidence interval:
## 11.62545      Inf
## sample estimates:
## mean in group High  mean in group Low
##                 64.74371          50.70812
```

Prepostavke za t-test

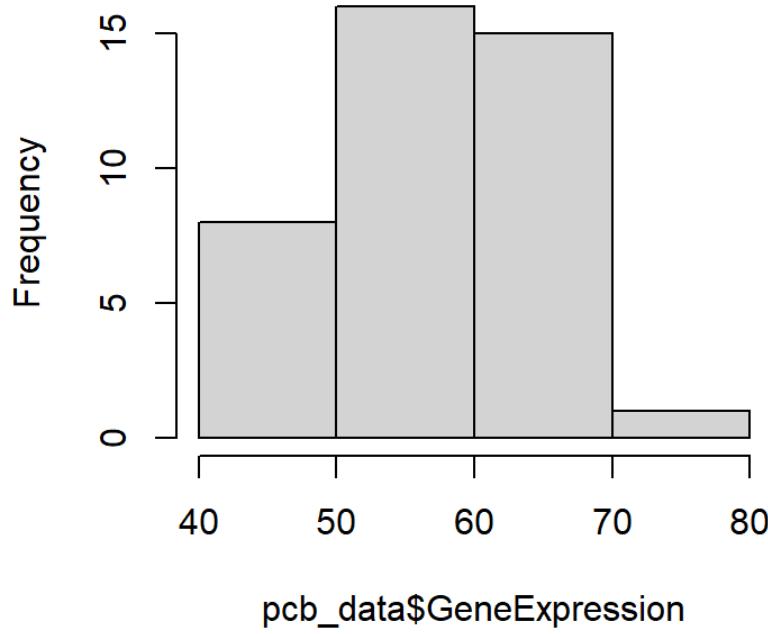
- Varijabla koju testiramo je normalno distribuirana
- Uzorci imaju jednake varijance
- Uzorci su međusobno neovisni

Testiranje normalnosti:

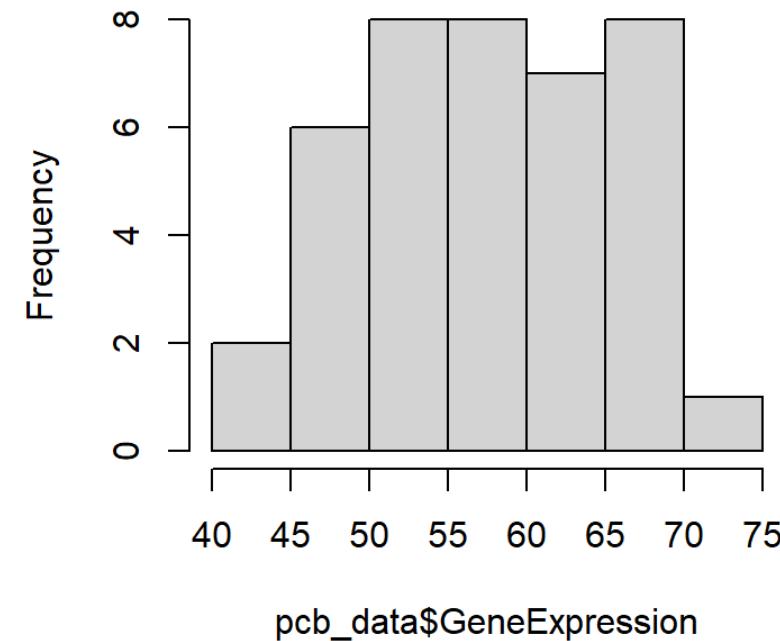
- Histogram, QQplot (kvantil-kvantil graf)
- Statistički testovi (Shapiro-Wilk, Kolmogorov-Smirnov, Anderson-Darling) – mogu biti preosjetljivi ako je $n > 50$

Histogram za testiranje normalnosti

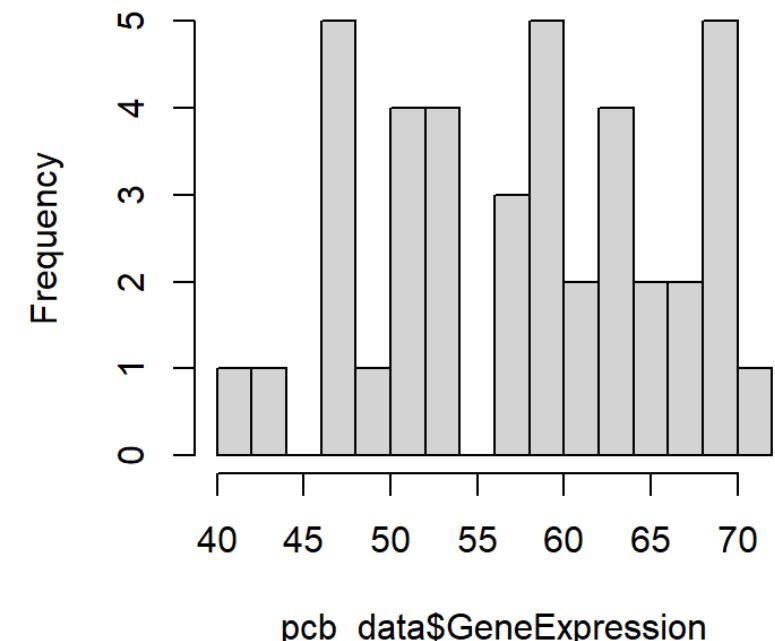
Histogram (3 bins)



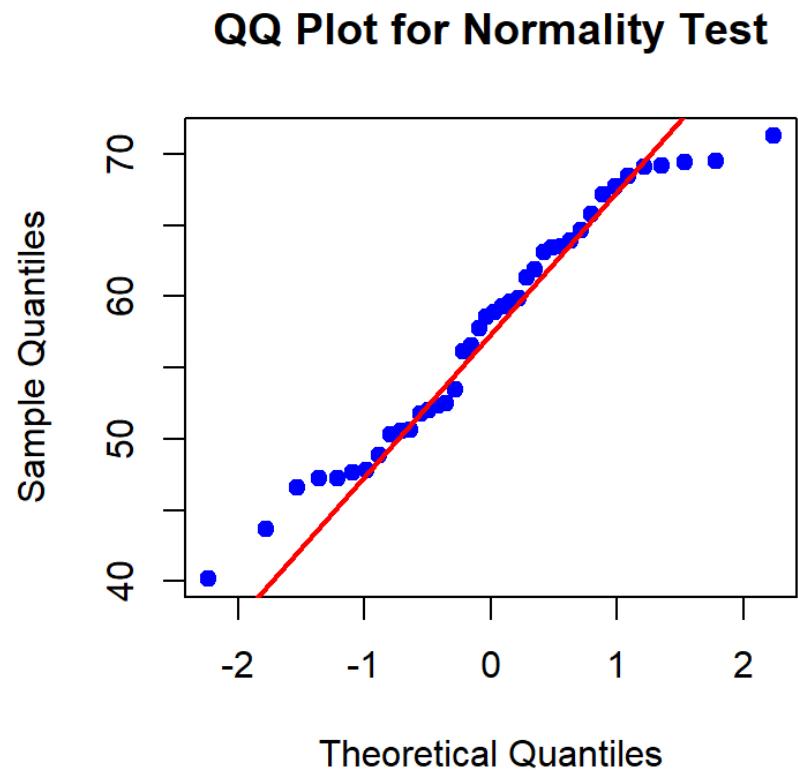
Histogram (5 bins)



Histogram (15 bins)

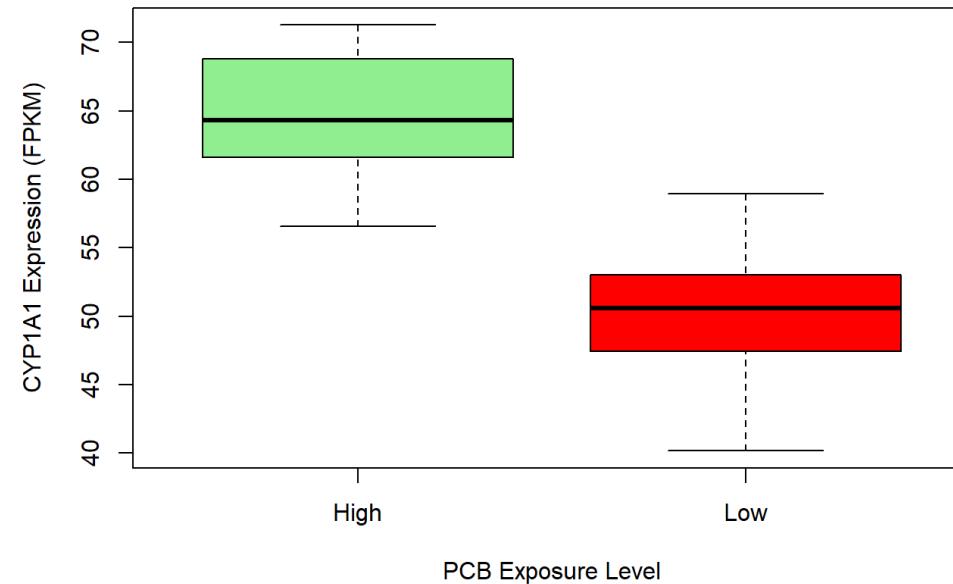


QQplot za testiranje normalnosti



Testiranje homogenosti varijance

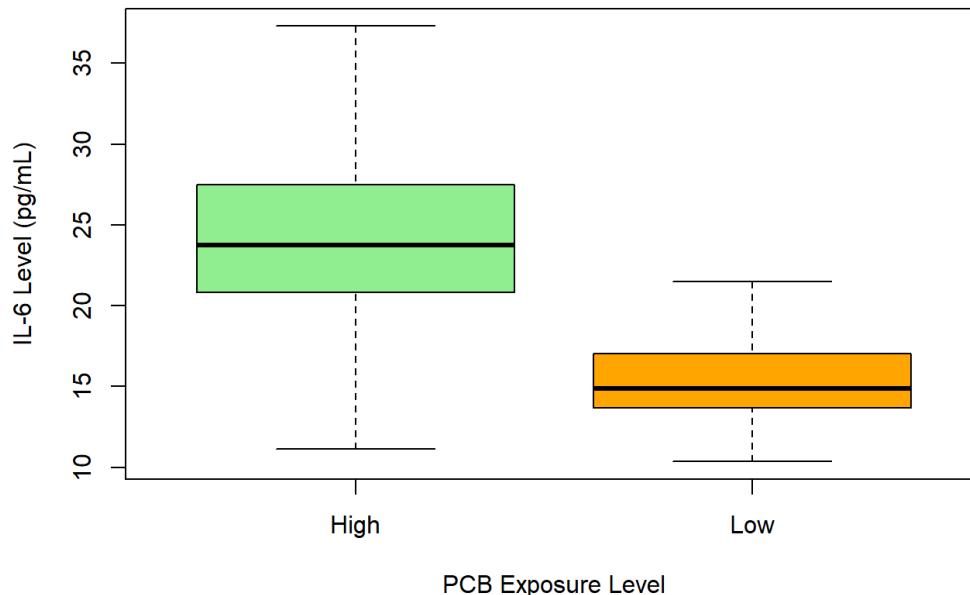
- Grafičke metode (boxplot)



- Statistički testovi (Levene-ov test, Bartlettov test)

Testiranje srednje vrijednosti razine citokina (IL-6)

- Provjera pretpostavki o homogenosti varijance:



```
### Levene's test
```
leveneTest(CytokineLevel ~ Exposure, data = cytokine_data)

Levene's Test for Homogeneity of Variance (center = median)
 Df F value Pr(>F)
group 1 9.0952 0.004551 **
 38

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

# Studentov t-test za nejednake varijance (Welchov test)

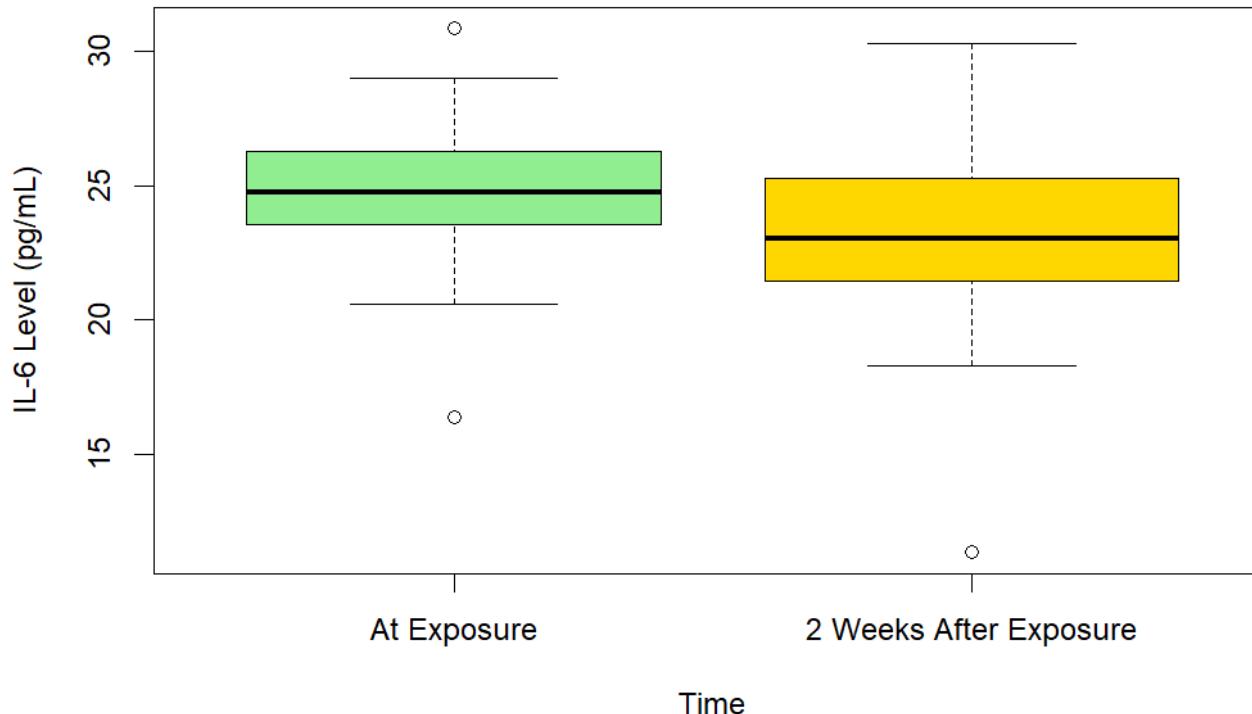
$$t_{df} = \frac{\bar{X}_1 - \bar{X}_2}{SE_{\bar{X}_1 - \bar{X}_2}} = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

```
T-test for cytokine levels
t_test_cytokine <- t.test(CytokineLevel ~ Exposure, data = cytokine_data, var.equal =
F)
print(t_test_cytokine)
```

```
##
Welch Two Sample t-test
##
data: CytokineLevel by Exposure
t = 6.159, df = 27.686, p-value = 1.253e-06
alternative hypothesis: true difference in means between group High and group Low is
not equal to 0
95 percent confidence interval:
5.979168 11.942916
sample estimates:
mean in group High mean in group Low
24.28050 15.31946
```

## Što ako uzorci nisu međusobno neovisni

- Npr. Mjerimo promjenu u razini citokina u vrijeme izlaganja PCB-u i 2 tjedna nakon izlaganja PCB-u
- Hipoteza: Postoji razlika u razini IL-6 ovisno o vremenu mjerjenja



# Studentov t-test za povezane uzorke

- Kada uspoređujemo dva povezana uzorka često nas ne zanimaju absolutne vrijednosti već razlike između izmjerениh vrijednosti za svaki par observacija u povezanih uzorcima

| <u>Uzorak 1</u> | <u>Uzorak 2</u> | <u>Razlika</u>    |  |
|-----------------|-----------------|-------------------|--|
| $X_{11}$        | $X_{21}$        | $X_{11} - X_{21}$ |  |
| $X_{12}$        | $X_{22}$        | $X_{12} - X_{22}$ |  |
| .               | .               | .                 |  |
| .               | .               | .                 |  |
| .               | .               | .                 |  |
| $X_{1n}$        | $X_{2n}$        | $X_{1n} - X_{2n}$ |  |

A curly brace on the right side of the table groups the three columns under the heading "Razlika".

- Uzorak razlika u mjerljima uzet iz populacije razlika
- Karakterizira ga srednja vrijednost i standardna devijacija
- Srednja vrijednost razlika u mjerljima  $\bar{D}$

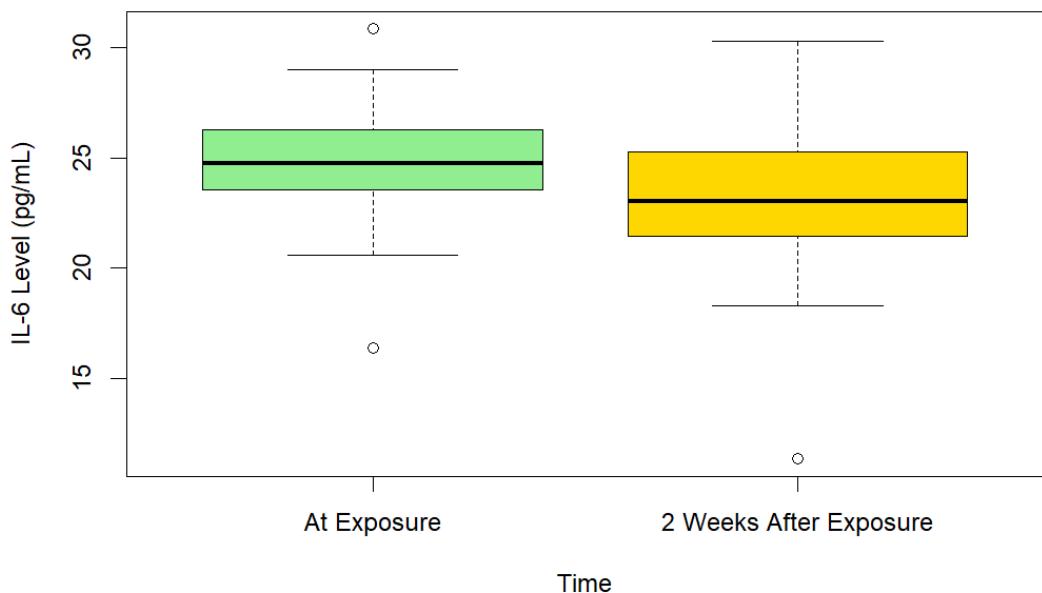
## Studentov t-test za povezane uzorke

- Nulta hipoteza: Nema razlike među dva međusobno ovisna mjerenja u našem uzorku
- Zbog varijabilnosti očekujemo da će neke razlike biti pozitivne, neke negativne, ali srednja vrijednost tih razlika biti će jednaka nuli

$$t_{n-1} = \frac{\bar{D} - \mu_{\bar{D}}}{SE_{\bar{D}}}$$

- Koristimo t-test kako bismo utvrdili je li srednja vrijednost razlika značajno različita od nule
- Naš uzorak je zapravo stupac s razlikama u mjeranjima na kojem ćemo napraviti t-test na jednom uzorku s nultom hipotezom da je  $\mu = 0$

# Studentov t-test za povezane uzorke



```
Welch Two Sample t-test
##
data: CytokineLevel by Exposure
t = 1.3661, df = 35.587, p-value = 0.1805
alternative hypothesis: true difference in means between group At Exposure and group 2 Weeks After Exposure is not equal to 0
95 percent confidence interval:
-0.7668215 3.9280175
sample estimates:
mean in group At Exposure mean in group 2 Weeks After Exposure
24.7520
23.1714
```

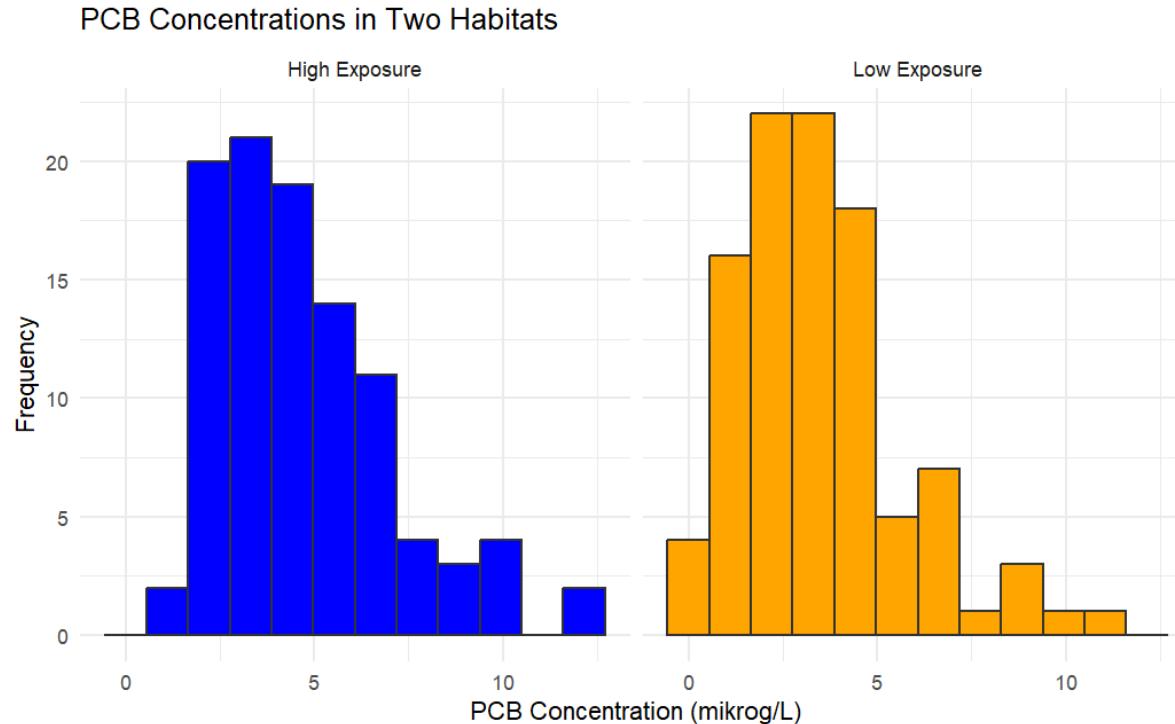
Ne odbacujemo nultu hipotezu na razini značajnosti 0.05!

```
Paired t-test
##
data: CytokineLevel by Exposure
t = 3.374, df = 19, p-value = 0.003186
alternative hypothesis: true mean difference is not equal to 0
95 percent confidence interval:
0.6001007 2.5610954
sample estimates:
mean difference
1.580598
```

Odbacujemo nultu hipotezu na razini značajnosti 0.05!

# Što kad podaci nisu normalno distribuirani?

- Želimo testirati koncentraciju PCB-a u staništima koja jesu/nisu izložena zagađenju.
- Koncentracija PCB-a nije normalno distribuirana.



## Neparametarski testovi

- Testovi koji nemaju prepostavki o distribuciji proučavanih varijabli
  - Testiraju se rangovi podataka, a ne same vrijednosti podataka
  - Mogu se koristiti za male uzorke ( $N<30$ ) i za varijable koje ne slijede normalnu distribuciju (!)
  - Manja statistička snaga testa
- 
- **Wilcoxon-Mann-Whitney rank-sum test (Mann-Whitney U)** – usporedba dva neovisna uzorka
  - **Wilcoxon signed rank test** – usporedba dva ovisna uzorka

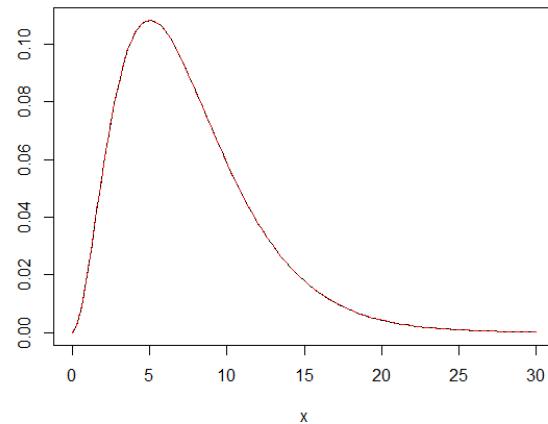
## Wilcoxon-Mann-Whitney Rank Sum Test

- Test statistika računa se na rangovima, a ne sirovim podacima
- Hipoteza
  - $H_0$  – dvije populacije imaju identičnu distribuciju
  - $H_1$  – “lokacije populacija se razlikuju”
- Prepostavke:
  - Podaci dolaze iz nasumičnih uzoraka
  - Podaci unutar uzorka su međusobno neovisni
  - Uzorci su međusobno neovisni

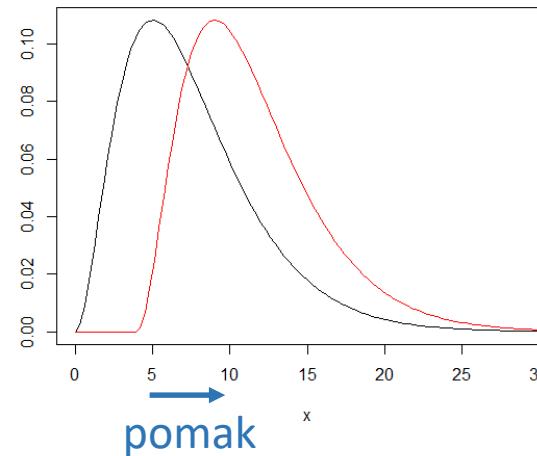
# Wilcoxon-Mann-Whitney Rank Sum Test

- Wilcoxon -Mann-Whitney Rank Sum Test pokušava otkriti pomake u lokaciji
  - $H_1 : A > B$  (A pomaknuta u desno od B)
  - $H_1 : A < B$  (A pomaknuta u lijevo od B)
  - $H_1 : A \neq B$

$H_0: A = B$

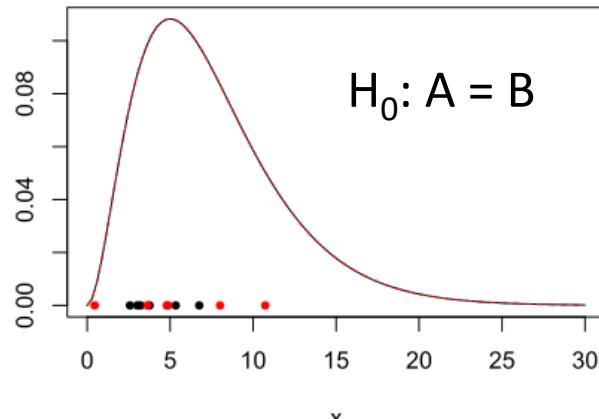


$H_1: A > B$



# Wilcoxon-Mann-Whitney Rank Sum Test

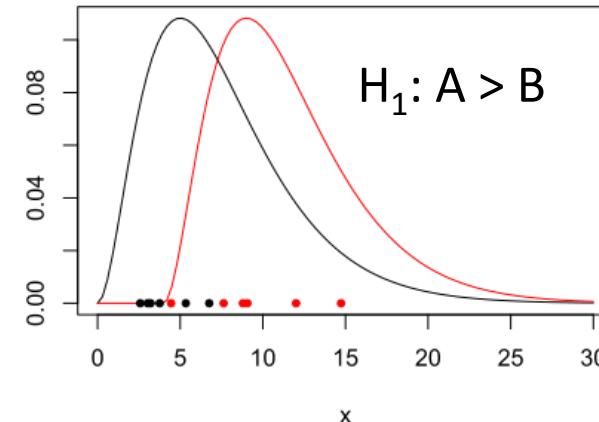
- Staviti sve observacije u jedan uzorak i rangirati  $n_A + n_B$  observacija kombiniranog uzorka
- Wilcoxon rank-sum statistika – suma rangova observacija iz jednog od uzoraka
- $w_A$  = suma rangova observacija iz uzorka A
- a)  $H_0: A=B$       b)  $H_1: A>B$



1 2 4 6 9 10 11 12  
3 5 7 8

$$(H_1 : A > B)$$

$$(H_1 : A < B)$$

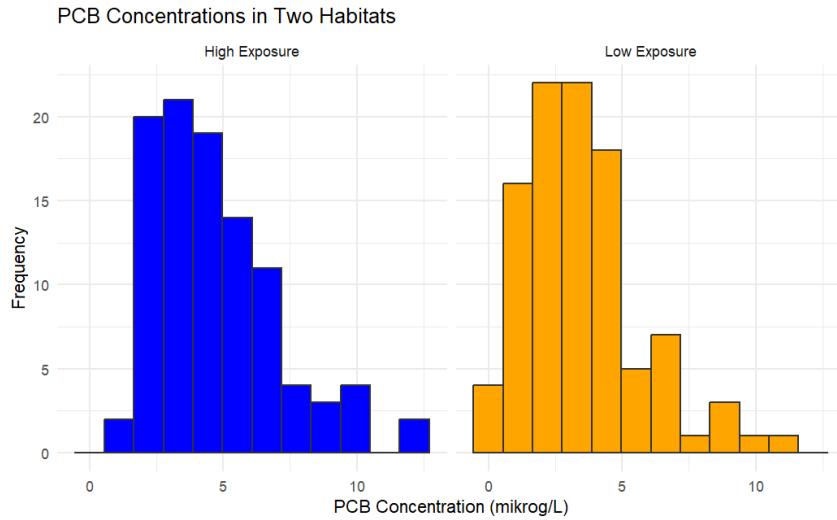


1 2 4 6 7 8 9 10 11 12  
3 5

$$P\text{-value} = \text{pr}(W_A \geq w_A),$$

$$P\text{-value} = \text{pr}(W_A \leq w_A).$$

# Wilcoxon-Mann-Whitney Rank Sum Test



```
Test difference in distributions using a non-parametric test (Wilcoxon-Mann-Whitney U Test)
wilcox_test_result <- wilcox.test(Concentration ~ Habitat, data = pcb_data)
print(wilcox_test_result)
```

```

Wilcoxon rank sum test with continuity correction
##
data: Concentration by Habitat
W = 6697, p-value = 3.395e-05
alternative hypothesis: true location shift is not equal to 0
```

```
Test difference in means using a t-test
t_test_result <- t.test(Concentration ~ Habitat, data = pcb_data)
print(t_test_result)
```

```

Welch Two Sample t-test
##
data: Concentration by Habitat
t = 3.9501, df = 197.54, p-value = 0.0001086
alternative hypothesis: true difference in means between group High Exposure and group Low Exposure is not equal to 0
95 percent confidence interval:
0.6405625 1.91177830
sample estimates:
mean in group High Exposure mean in group Low Exposure
4.722172 3.442999
```

## Wilcoxon signed rank test

- Verzija prethodnog testa gdje se pojedinci mogu mjeriti dvaput ili se mogu uzeti u obzir mjerena prije i poslije (spareni test)
- Podaci koji imaju isti broj mjerena.
- Upareni uzorci  $(X_i, Y_i) \rightarrow D_i = X_i - Y_i$
- Ako niti jedan tretman nema učinka, tada ne samo da bi razlike trebale biti jednak raspoređene s obje strane 0, nego bi i to koliko su razlike udaljene od 0 trebale biti isto s obje strane.
- Postupak:
  - Izračunajte  $D_i$  i rangirati
  - Izračunajte  $W+ =$  zbroj rangova s pozitivnim predznakom ili  $W- =$  zbroj rangova s negativnim predznakom
  - Idejako je distribucija  $X (F(x))$  ista kao distribucija  $Y (F(y))$ , tada je jednako vjerojatno da će  $D_i$  biti pozitivni kao i negativni. Dakle, oko pola rangova je pozitivno, a pola je negativno. Ako je  $F(y)$  veći od  $F(x)$ , očekujte da većina rangova ima pozitivne predznačke i stoga će  $W+$  biti velik
- Za  $n \geq 20$  približno normalno raspoređen

## Kada koristiti neparametarske testove

- Podaci koji nisu normalno distribuirani (jako asimetrične distribucije)
- Podaci koji sadrže stršeće vrijednosti (*outliere*)
- Mali broj podataka

### Tipovi varijabli:

- Numeričke (kvantitativne) - diskretne i kontinuirane
- Kategoričke (kvalitativne) - nominalne i ordinalne

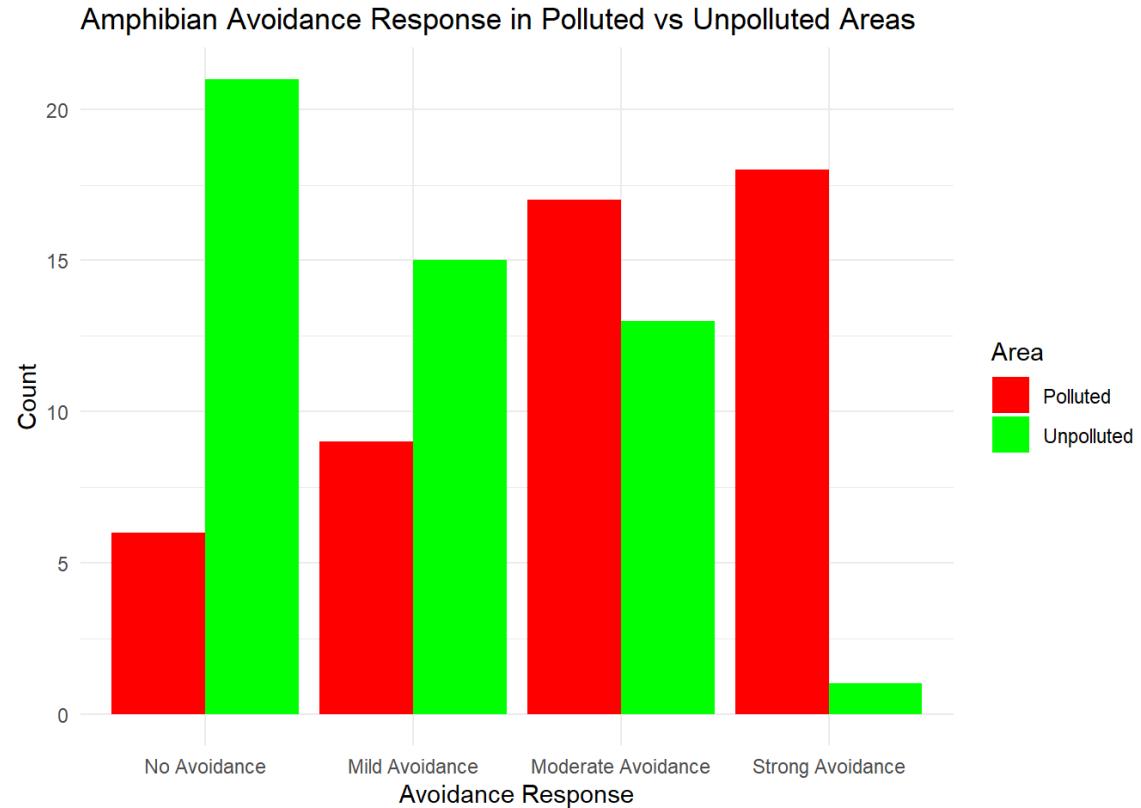
# Neparametarski testovi za ordinalne variable

- Izbjegavanje kontaminiranog područja

1. Bez izbjegavanja: Vodozemci ostaju u kontaminiranoj zoni unatoč prisutnosti PCB-a.
2. Blago izbjegavanje: Vodozemci pokazuju povremeno kretanje izvan kontaminirane zone.
3. Umjereno izbjegavanje: Vodozemci često izbjegavaju kontaminirano područje, ali se ipak povremeno vraćaju.
4. Strogo izbjegavanje: Vodozemci rijetko ili nikad ne ulaze u kontaminirano područje.

|                    | Polluted | Unpolluted |
|--------------------|----------|------------|
| No Avoidance       | 6        | 21         |
| Mild Avoidance     | 9        | 15         |
| Moderate Avoidance | 17       | 13         |
| Strong Avoidance   | 18       | 1          |

# Neparametarski testovi za ordinalne variable



- Vrijednosti moramo pretvoriti u numeričke
- Udaljenosti između brojeva 1, 2, 3, 4 kod ordinalne varijable ne moraju biti jednake kao kod numeričke varijable

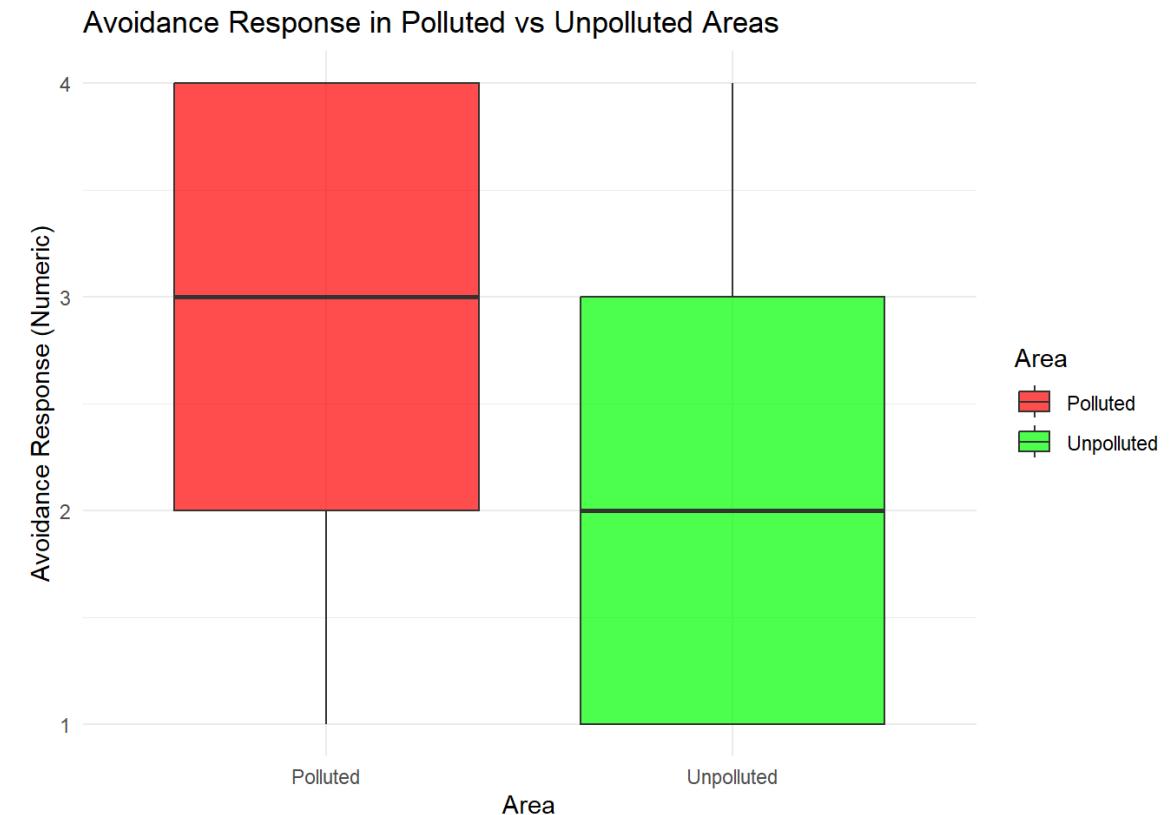
# Neparametarski testovi za ordinalne variable

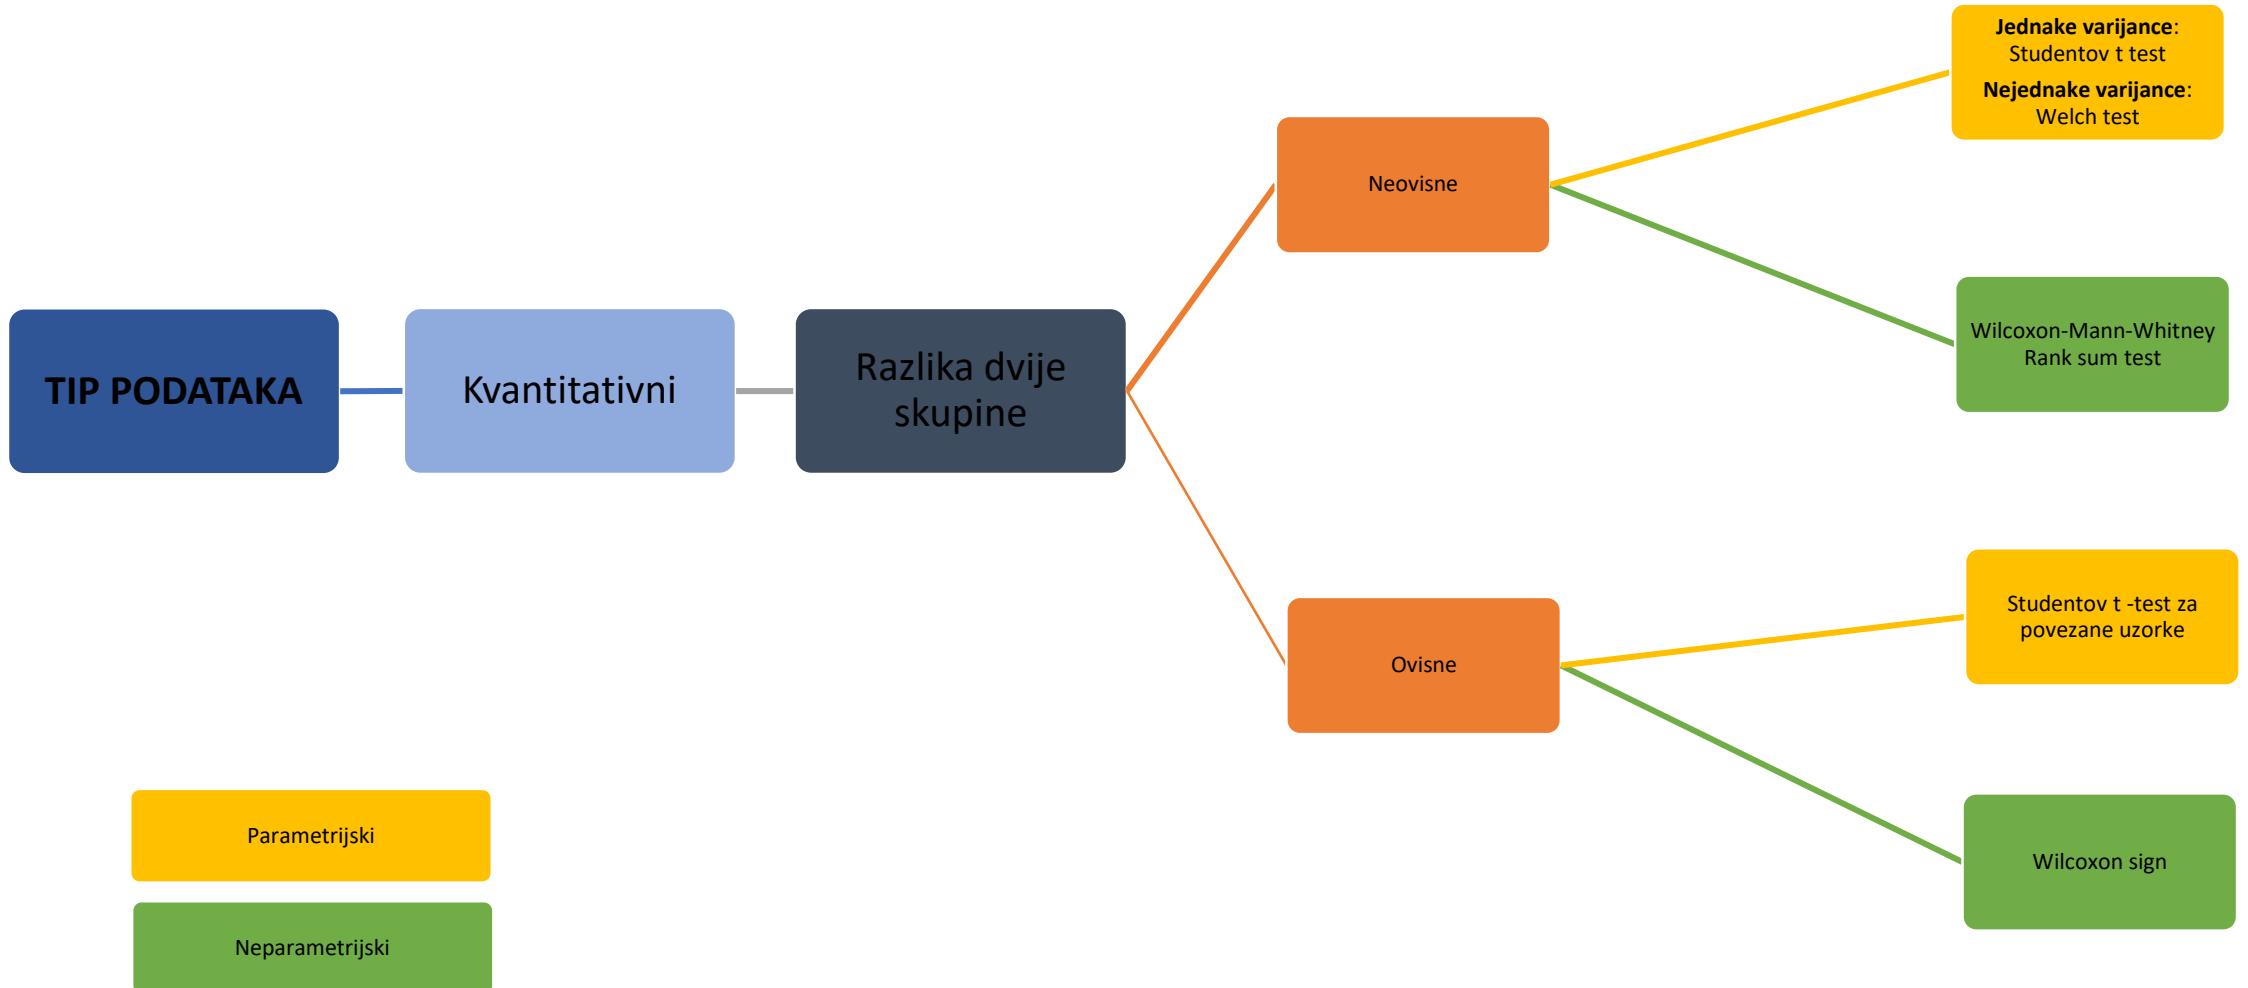
```
Convert ordinal variable to numeric for Wilcoxon test
amphibian_data$Avoidance_Numeric <- as.numeric(amphibian_data$Avoidance)

Wilcoxon rank-sum test
test_result <- wilcox.test(Avoidance_Numeric ~ Area, data = amphibian_data)
print(test_result)
```

```

Wilcoxon rank sum test with continuity correction
##
data: Avoidance_Numeric by Area
W = 1933, p-value = 1.106e-06
alternative hypothesis: true location shift is not equal to 0
```





## Ostale neparametarske metode

- Kruskal-Wallis test, Friedmanov test – neparametarska ANOVA
- Spearmanov rho i Kendallov tau – naparametarska korelacija
- Ordinalna regresija – neparametarska regresija