

# Přednáška IX.

## Analýza rozptylu (ANOVA)

- ➔ Princip a metodika výpočtu
- ➔ Předpoklady analýzy rozptylu a jejich ověření
- ➔ Rozbor rozdílů jednotlivých skupin – násobné testování hypotéz
- ➔ Analýza rozptylu jako lineární model



evropský  
sociální  
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání  
pro konkurenceschopnost



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ




# Opakování – parametrické a neparametrické testy

- ➔ Jmenujte příklad parametrického a neparametrického testu.
- ➔ Znáte jejich předpoklady?

# 1. Motivace

# Příklad – CHOPN

- ➔ Sledujeme plicní funkce u pacientů s chronickou obstrukční plicní nemocí (CHOPN) ve stadiu II, III a IV. Zajímá nás, jestli se u pacientů v jednotlivých stadiích liší maximální inspirační tlak ( $P_{Imax}$ ).



# Příklad – CHOPN

→ Jak můžeme pro CHOPN stadia II, III a IV ověřit rozdíl (resp. rovnost) v maximálním inspiračním tlaku ( $P_{I\max}$ )?

**A. Můžeme použít vhodný test pro dva výběry (např.  $t$ -test) a otestovat, jak se liší stadium II od III, II od IV a III od IV – tedy provést 3 testy.**

**B. Musíme použít vhodný test pro více než dvě srovnávané skupiny.**

→ V čem je zásadní rozdíl mezi A a B?

# Problém násobného testování hypotéz

## ➔ **Problém s možností A je v násobném testování hypotéz – pro připomenutí:**

S narůstajícím počtem testovaných hypotéz nám roste také pravděpodobnost získání falešně pozitivního výsledku, tedy pravděpodobnost toho, že se při našem testování zmýlíme a ukážeme na statisticky významný rozdíl tam, kde ve skutečnosti žádný neexistuje (chyba I. druhu).

➔ Máme tři testy, v každém 95% pravděpodobnost, že neuděláme chybu I. druhu.

➔ Pro všechny tři testy to tedy znamená:  $0,95 \times 0,95 \times 0,95 = 0,857$ .

➔ **Pravděpodobnost, že neuděláme chybu I. druhu nám celkově klesla na 0,857.**

➔ **Pravděpodobnost, že uděláme chybu I. druhu nám celkově stoupla na 0,143.**

# Analýza rozptylu

→ Lepší volbou je:

**B. Musíme použít vhodný test pro více než dvě srovnávané skupiny.**

→ Analýza rozptylu (ANOVA = „ANalysis Of VAriance“) je statistickou metodou, která umožňuje testovat rozdíl v průměrech více než dvou skupin. Přitom se jedná o jeden test.

→ Více než dvě skupiny mohou být dány přirozeně (např. sledujeme rozdíl mezi věkovými kategoriemi) nebo uměle (např. sledujeme rozdíl v účinnosti několika typů léčby).

## 2. Princip výpočtu



# Náhodné výběry a hypotéza

→ Máme  $k$  nezávislých realizací náhodného výběru rozsahu:  $n_1, n_2, \dots, n_k$ .

→ Předpoklady:  $Y_{1j} \sim N(\mu_1, \sigma^2)$

$$Y_{2j} \sim N(\mu_2, \sigma^2)$$

⋮

$$Y_{kj} \sim N(\mu_k, \sigma^2)$$



Normalita hodnot všech  $k$  výběrů



Homogenita rozptylů všech  $k$  výběrů

→ Hypotézy:

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_k$$

$H_1$  : nejméně jedno  $\mu_i$  je odlišné od ostatních

# Příklady – hypotézy

## 1. Liší se účinnost dvou různých dávek léčiva XYZ od placebo?

Střední hodnota účinnosti placebo, XYZ v dávce 1 a XYZ v dávce 2:  $\mu_P, \mu_{XYZ_1}, \mu_{XYZ_2}$

$$H_0 : \mu_P = \mu_{XYZ_1} = \mu_{XYZ_2}$$

$H_1$  : nejméně jedno  $\mu$  je odlišné od ostatních

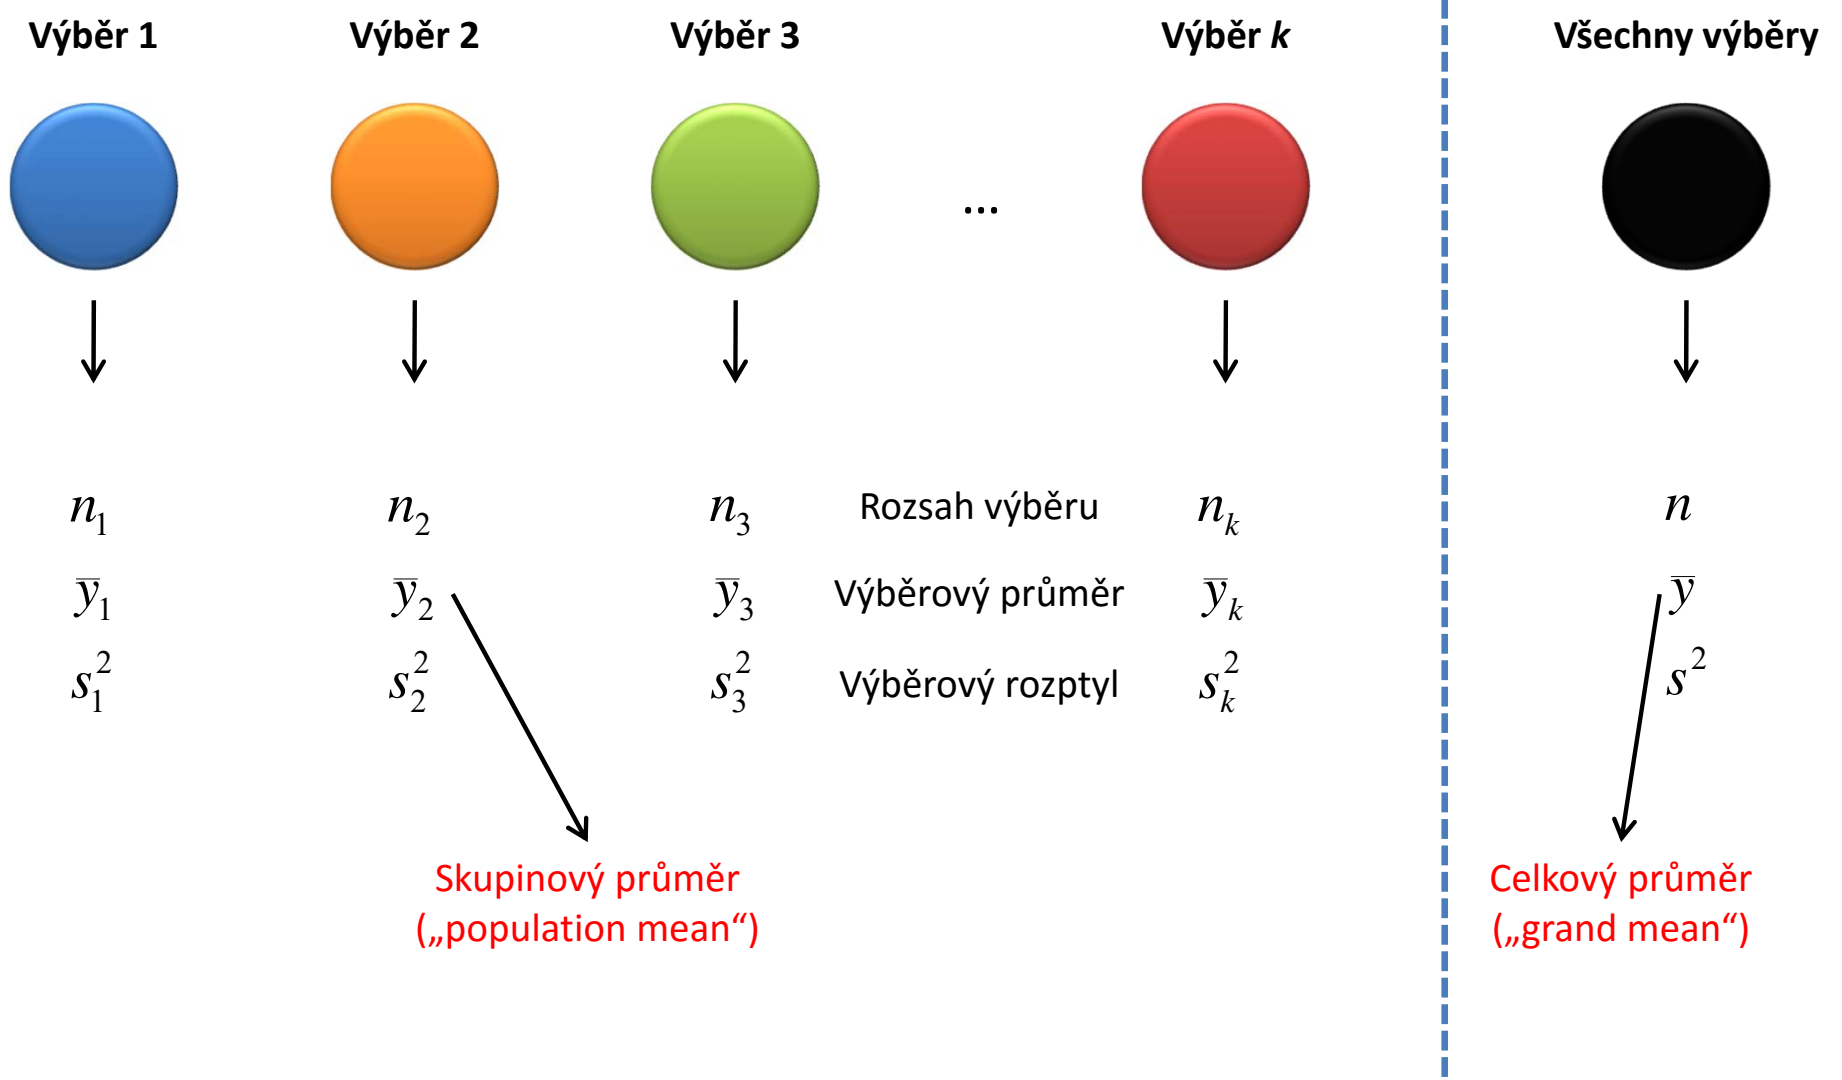
## 2. Liší se AML, ALL, CML a CLL v aktivitě vybraných genů?

Střední hodnota exprese genu  $g$  u AML, ALL, CML, CLL:  $\theta_{AML}^g, \theta_{ALL}^g, \theta_{CML}^g, \theta_{CLL}^g$


$$H_0 : \theta_{AML}^g = \theta_{ALL}^g = \theta_{CML}^g = \theta_{CLL}^g$$

$H_1$  : nejméně jedno  $\theta^g$  je odlišné od ostatních

# Pozorované hodnoty



# Příklad – CHOPN



$$n_1 = 9$$

$$\bar{y}_1 = 8,9 \text{ kPa}$$

$$s_1 = 3,5 \text{ kPa}$$

$$n_2 = 12$$

$$\bar{y}_2 = 6,6 \text{ kPa}$$

$$s_2 = 2,9 \text{ kPa}$$

$$n_3 = 27$$

$$\bar{y}_3 = 5,4 \text{ kPa}$$

$$s_3 = 2,5 \text{ kPa}$$

Celkový průměr („grand mean“)

$$n = 48$$

$$\bar{y} = 6,4 \text{ kPa}$$

$$s = 3,0 \text{ kPa}$$

# Značení

→ Součty:

$$Y_{i\cdot} = \sum_{j=1}^{n_i} Y_{ij}$$

$$Y_{\cdot\cdot} = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}$$

→ Průměry:

$$\bar{y}_{i\cdot} = Y_{i\cdot} / n_i$$

$$\bar{y}_{\cdot\cdot} = Y_{\cdot\cdot} / n$$

Skupinový průměr  
(„population mean“)

Celkový průměr  
(„grand mean“)

→ Celková variabilita v souboru:

$$S_T = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{y}_{\cdot\cdot})^2$$

Stupně volnosti:  $df_T = n - 1$

→ Variabilita v rámci skupin (reziduální součet čtverců):

$$S_e = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{y}_{i\cdot})^2$$

Stupně volnosti:  $df_e = n - k$

→ Variabilita mezi skupinami (příslušná sledovanému vlivu = proměnné):

$$S_A = \sum_{i=1}^k n_i (\bar{y}_{i\cdot} - \bar{y}_{\cdot\cdot})^2$$

Stupně volnosti:  $df_A = k - 1$

# Vztahy mezi odhady variability

→ Platí:

$$Y_{ij} - \bar{y}_{..} = (Y_{ij} - \bar{y}_{i.}) + (\bar{y}_{i.} - \bar{y}_{..})$$


→ Dále se dá ukázat, že platí:

$$S_T = S_e + S_A$$

→ Tedy platí, že celková variabilita se dá rozložit na variabilitu v rámci skupin a variabilitu mezi skupinami:

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{y}_{..})^2 =$$

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{y}_{i.})^2 + \sum_{i=1}^k n_i (\bar{y}_{i.} - \bar{y}_{..})^2$$



# Umělý příklad

| Léčba | Pozorovaná hodnota         | Skupinový průměr | Skupinový průměr – celkový průměr | Pozorovaná hodnota – skupinový průměr | Pozorovaná hodnota – celkový průměr |
|-------|----------------------------|------------------|-----------------------------------|---------------------------------------|-------------------------------------|
| 1     | 10                         | 12               | -4                                | -2                                    | -6                                  |
| 1     | 12                         | 12               | -4                                | 0                                     | -4                                  |
| 1     | 14                         | 12               | -4                                | 2                                     | -2                                  |
| 2     | 19                         | 20               | 4                                 | -1                                    | 3                                   |
| 2     | 20                         | 20               | 4                                 | 0                                     | 4                                   |
| 2     | 21                         | 20               | 4                                 | 1                                     | 5                                   |
| 3     | 14                         | 16               | 0                                 | -2                                    | -2                                  |
| 3     | 16                         | 16               | 0                                 | 0                                     | 0                                   |
| 3     | 18                         | 16               | 0                                 | 2                                     | 2                                   |
|       | <b>Celkový průměr = 16</b> |                  | <b>Součet čtverců = 96</b>        | <b>Součet čtverců = 18</b>            | <b>Součet čtverců = 114</b>         |
|       |                            |                  | <b>Stupně volnosti = 2</b>        | <b>Stupně volnosti = 6</b>            | <b>Stupně volnosti = 8</b>          |

# Jak testuje $t$ -test pro dva výběry?

→ Nulová hypotéza:

$$H_0 : \mu_1 = \mu_2$$

→ Testová statistika:

$$T = \frac{\bar{X} - \bar{Y}}{s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2)$$

**Rozdíl (variabilita) mezi výběry**

**Variabilita uvnitř výběrů**

→

$$T = \frac{\text{Rozdíl (variabilita) mezi výběry}}{\text{Variabilita uvnitř výběrů}}$$



# Princip analýzy rozptylu

→ Princip analýzy rozptylu je stejný, tedy ANOVA srovnává pozorovanou variabilitu mezi výběry s pozorovanou variabilitou uvnitř výběrů. Na rozdíl od  $t$ -testu však pracuje s výběrovými rozptyly.

→ Testová statistika analýzy rozptylu:

$$F = \frac{\text{Odhad rozptylu založený na výběrových průměrech}}{\text{Odhad rozptylu založený pozorovaných hodnotách}}$$

$$F = \frac{\frac{\sum_{i=1}^k n_i (\bar{y}_{i\cdot} - \bar{y}_{\cdot\cdot})^2}{k-1}}{\frac{\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{y}_{i\cdot})^2}{n-k}} = \frac{S_A / df_A}{S_e / df_e}$$

**Za platnosti  $H_0$  platí:**

$$F \sim F(k-1, n-k)$$

# Výsledek dle platnosti nulové hypotézy

- Za předpokladu rovnosti rozptylů jednotlivých výběrů představuje člen ve jmenovateli statistiky  $F$  výběrový odhad  $\sigma^2$ .
- Za platnosti  $H_0$  představuje i člen v čitateli statistiky  $F$  výběrový odhad  $\sigma^2$ .
- **Platí-li nulová hypotéza, čítecel statistiky  $F$  (počítaný na základě výběrových průměrů) bude zhruba stejný jako její jmenovatel (počítaný na základě pozorovaných hodnot).**
- **Neplatí-li nulová hypotéza, čítecel statistiky  $F$  bude větší než jmenovatel.**
- **Samotné rozhodnutí o platnosti  $H_0$  je tak založeno na srovnání průměrných čtverců  $S_A / df_A$  a  $S_e / df_e$ .**

# Výsledek analýzy rozptylu


➔ Výsledné počty se standardně zaznamenávají do tzv. tabulky analýzy rozptylu:

| Variabilita    | Součet čtverců | Počet stupňů volnosti | Průměrný čtverec | F statistika  | p-hodnota    |
|----------------|----------------|-----------------------|------------------|---------------|--------------|
| Mezi skupinami | $S_A = 96$     | $df_A = k - 1 = 2$    | $MS_A = 48$      | <b>F = 16</b> | <b>0,004</b> |
| Uvnitř skupin  | $S_e = 18$     | $df_e = n - k = 6$    | $MS_e = 3$       |               |              |
| Celkem         | $S_T = 114$    | $df_T = n - 1 = 8$    |                  |               |              |

➔ Nulovou hypotézu zamítneme/nezamítneme buď na základě srovnání výsledné p-hodnoty se zvolenou hladinou významnosti testu  $\alpha$ , nebo srovnáním výsledné F statistiky s kritickou hodnotou (kvantilem) rozdělení  $F(k - 1, n - k)$  příslušnou zvolené hladině významnosti testu  $\alpha$ .

# Výsledek umělého příkladu

$$F_{1-\alpha}^{(k-1, n-k)} = F_{0,95}^{(2,6)} = 5,14 \quad F = 16$$




Na hladině významnosti  $\alpha = 0,05$  zamítáme  $H_0$  o rovnosti středních hodnot.


# 3. Předpoklady analýzy rozptylu a jejich ověření

# Předpoklady analýzy rozptylu

- **Nezávislost jednotlivých pozorování** – sice téměř automatický předpoklad, nicméně je třeba se nad ním alespoň zamyslet.
- **Normalita pozorovaných hodnot obou náhodných výběrů** – velmi silný předpoklad. **Nutno otestovat nebo alespoň graficky ověřit** (histogram, box plot).
- **Stejný rozptyl náhodné veličiny v obou srovnávaných skupinách** – také silný předpoklad. Opět **nutno otestovat nebo alespoň graficky ověřit** (histogram, box plot).

# Testování shody rozptylů

- ➔ **Grafické ověření** – histogram, box plot. 
- ➔ **Levenův test** – často používaný, nevyžaduje předpoklad normality původních hodnot.
- ➔ **Bartlettův test** – velkou nevýhodou je předpoklad normality původních hodnot.



# Levenův test

→ Jeho výhodou je, že **nevyžaduje předpoklad normality původních hodnot.**

→ **Jedná se o analýzu rozptylu na hodnotách**  $Z_{ij} = |Y_{ij} - \bar{y}_i|$

→ Označme  $\bar{z}_{i\cdot} = \frac{1}{n_i} \sum_{j=1}^{n_i} Z_{ij}$  a  $\bar{z}_{\cdot\cdot} = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} Z_{ij}$

→ Testová statistika: 
$$W = \frac{\sum_{i=1}^k n_i (\bar{z}_{i\cdot} - \bar{z}_{\cdot\cdot})^2}{k-1} \bigg/ \frac{\sum_{i=1}^k \sum_{j=1}^{n_i} (Z_{ij} - \bar{z}_{i\cdot})^2}{n-k}$$

Při rovnosti rozptylů opět platí:

$$F \sim F(k-1, n-k)$$

→ Používá se také jeho robustní varianta s použitím absolutních odchylek od mediánu místo od průměru:  $Z_{ij} = |Y_{ij} - \tilde{y}_i|$



# Příklad – Levenův test u CHOPN dat

- Sledujeme plicní funkce u pacientů s chronickou obstrukční plicní nemocí (CHOPN) ve stadiu II, III a IV.
- **Levenův test probíhá stejně jako jednoduchá ANOVA** – opět srovnáváme průměrné čtverce – reziduální a příslušné sledovaným faktorům.

| Variabilita    | Součet čtverců | Počet stupňů volnosti | Průměrný čtverec | F statistika | p-hodnota |
|----------------|----------------|-----------------------|------------------|--------------|-----------|
| Mezi skupinami | $S_A = 5,30$   | $df_A = k - 1 = 2$    | $MS_A = 2,65$    | $F = 1,13$   | 0,331     |
| Uvnitř skupin  | $S_e = 105,35$ | $df_e = n - k = 45$   | $MS_e = 2,34$    |              |           |
| Celkem         | $S_T = 110,65$ | $df_T = n - 1 = 47$   |                  |              |           |



- Na hladině významnosti  $\alpha = 0,05$  nezamítáme  $H_0$  o rovnosti rozptylů.

# Hodnocení normality dat



- ➔ **Hodnocení normality je klíčovým postupem v biostatistice. Testy nejsou vždy nejlepším nástrojem! Vždy je důležité se podívat i očima!**
- ➔ **Zamítnutí normality rozdělení** neznamena jenom výběr příslušného testu, **ALE může indikovat odlehlé a nelogické hodnoty v souboru dat.**
- ➔ Pokud o sledované veličině prokazatelně víme, že v cílové populaci nabývá normální rozdělení (např. výška lidské postavy), ale v daném souboru normální rozdělení nepotvrdíme, pak s naším náhodným výběrem není něco v pořádku – např. není reprezentativní.

# Grafické metody – box plot a histogram

➔ Normální  
rozdělení





➔ Log-normální  
rozdělení





# Grafické metody – box plot a histogram

➔ Normální  
rozdělení  
s odlehlými  
hodnotami




➔ Rovnoměrně  
spojité  
rozdělení






# Grafické metody – Q-Q plot

- Q-Q plot proti sobě zobrazuje kvantily pozorovaných hodnot a kvantily teoretického rozdělení pravděpodobnosti (zde normálního rozdělení).
- V případě shody leží všechny body na přímce.
- Normální rozdělení:



# Grafické metody – Q-Q plot

1. Log-normální rozdělení:
2. Normální rozdělení s odlehlými hodnotami:
3. Rovnoměrně spojité rozdělení



# Testy pro ověření normality dat

- ➔ **Shapirův-Wilkův test** – v podstatě se jedná o proložení seřazených hodnot regresní přímkou vzhledem k očekávaným hodnotám normálního rozdělení. Má tedy přímý vztah k Q-Q plotu – vyhodnocuje, jak moc se Q-Q plot liší od ideální přímky. **Doporučován pro menší vzorky, může být „moc“ přísný pro velké vzorky.**
- ➔ **Kolmogorovův-Smirnovův test** – založen na srovnání výběrové distribuční funkce s teoretickou distribuční funkcí odpovídající normálnímu rozdělení. K-S test hodnotí maximální vzdálenost mezi těmito dvěma distribučními funkcemi. V praxi se používá korekce dle Lillieforse.

# Příklad – Shapirův-Wilkův test u CHOPN dat

→ Sledujeme plicní funkce u pacientů s chronickou obstrukční plicní nemocí (CHOPN) ve stadiu II, III a IV.

→ Test pro všechna stadia:

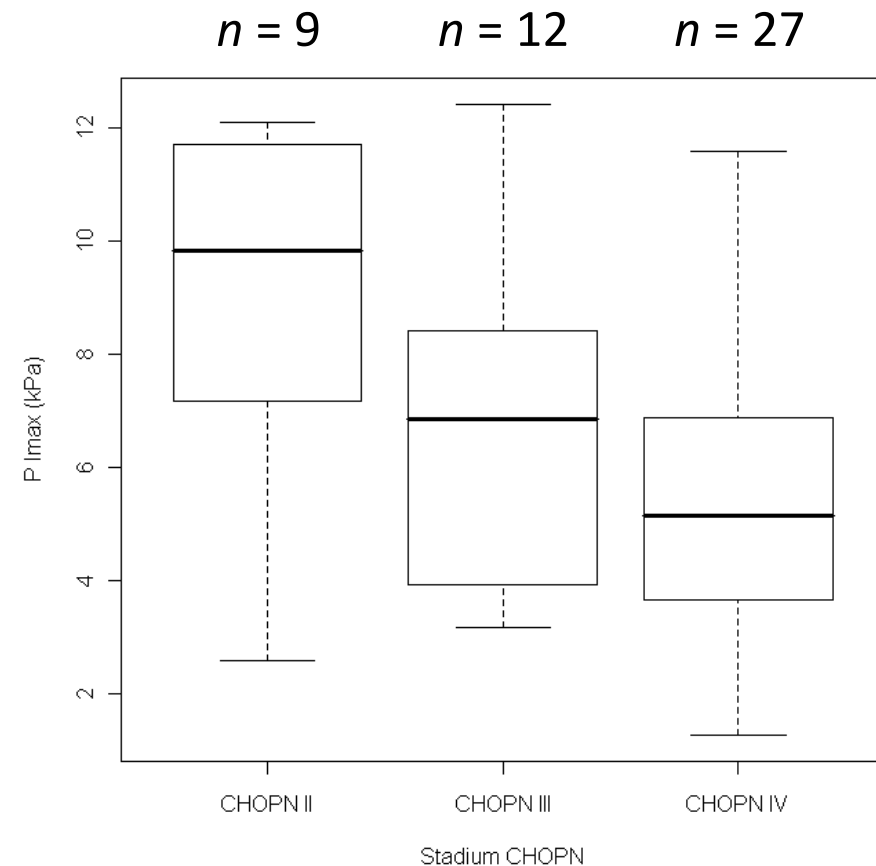
$p = 0,073$  (to nás nezajímá)

→ Stadium II:  $p = 0,090$

→ Stadium III:  $p = 0,247$

→ Stadium IV:  $p = 0,815$

→  $H_0$  o normalitě dat nezamítáme na hladině  $\alpha = 0,05$ .







# Příklad – Shapirův-Wilkův test u CHOPN dat

- Srovnáme výsledky S-W testu s Q-Q ploty pro jednotlivé kategorie.
- Vzhledem k malým velikostem souborů lze odchylky od normality dat tolerovat.


**Stadium II ( $n = 9$ )**  
 **$p = 0,090$**



**Stadium III ( $n = 12$ )**  
 **$p = 0,247$**



**Stadium IV ( $n = 27$ )**  
 **$p = 0,815$**



# Příklad – analýza rozptylu u CHOPN dat

- ➔ Liší se pacienti s CHOPN (stadium II, III, IV) v maximálním inspiračním tlaku (P<sub>I</sub>max)?
- ➔ Máme ověřenu homogenitu rozptylů i přibližnou normalitu dat → ANOVA.

| Variabilita    | Součet čtverců | Počet stupňů volnosti | Průměrný čtverec | F statistika | p-hodnota |
|----------------|----------------|-----------------------|------------------|--------------|-----------|
| Mezi skupinami | $S_A = 80,54$  | $df_A = k - 1 = 2$    | $MS_A = 40,27$   | $F = 5,10$   | 0,010     |
| Uvnitř skupin  | $S_e = 355,50$ | $df_e = n - k = 45$   | $MS_e = 7,90$    |              |           |
| Celkem         | $S_T = 436,04$ | $df_T = n - 1 = 47$   |                  |              |           |

- ➔ Kritická hodnota pro  $\alpha = 0,05$   $F_{(k-1, n-k)} = 3,20$ .
- ➔ **Na hladině významnosti  $\alpha = 0,05$  zamítáme  $H_0$  o rovnosti středních hodnot.**

# Co dělat, když nejsou splněny předpoklady?

➔ Máme dvě možnosti:

1. **Zkusit data transformovat** – např. logaritmická transformace by měla pomoci s normalizací rozdělení a stabilizací rozptylu u log-normálních dat.
2. **Použít neparametrické testy** – např. Kruskalův-Wallisův test nevyžaduje předpoklad normality, pracuje stejně jako neparametrický Mannův-Whitneyův test.

# Kruskalův – Wallisův test

- ➔ Jedná se o zobecnění neparametrického Mannova – Whitneyho testu.
- ➔ Netestuje shodu parametrů, ale stejné distribuční funkce srovnávaných souborů (klíčový je zde předpoklad nezávislosti pozorovaných dat).

$$H_0 : F(x) = F(y) = F(z) = \dots$$

- ➔ Pro výpočet opět seřadíme všechna pozorování podle velikosti (jako by byly z jednoho vzorku) a přiřadíme jednotlivým hodnotám jejich pořadí.
- ➔ **Pointa Kruskalova – Wallisova testu:** za platnosti  $H_0$  jsou spojená data dobře promíchaná a průměrná pořadí v jednotlivých souborech jsou podobná.

# Kruskalův – Wallisův test

→ Označme  $T_i$  součet pořadí v  $i$ -té skupině:  $T_i = \sum_{j=1}^{n_i} R_{ij}$

→ Počet skupin:  $k$ , Celkem pozorování:  $n = n_1 + n_2 + \dots + n_k$ .

→ **Testová statistika:** 
$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

→ Nulovou hypotézu  $H_0$  zamítáme na hladině významnosti, když je testová statistika větší nebo rovna kritické hodnotě chí-kvadrát rozdělení:  $Q \geq \chi_{k-1}^2(\alpha)$

→ Pro malé velikosti souboru je třeba srovnat statistiku  $Q$  s tabulkami pro Kruskalův-Wallisův test.

# 4. Násobné testování podskupin

# Korekce na násobné srovnání výběrů

- Zamítneme-li analýzou rozptylu nulovou hypotézu o celkové rovnosti středních hodnot, má smysl se ptát, jaké skupiny se od sebe nejvíce liší.
- Toto srovnání lze provést pomocí testů pro dva výběry, ale je nutné korigovat výslednou hladinu významnosti testu, abychom se vyhnuli chybě I. druhu.
- Nejjednodušší metoda: **Bonferroniho procedura** - korekce hladiny významnosti:  $\alpha^* = \alpha/m$ , kde  $m$  je počet provedených testů. Ekvivalentně lze vynásobit  $p$ -hodnotu počtem provedených testů. Nevýhodou je, že je konzervativní pro velké  $m$ , tedy počet provedených testů.
- Pro analýzu rozptylu: **Tukeyho a Scheffého post hoc testy**.
- Pro neparametrický K-W test: **metoda dle Steela a Dwasse**.

# Příklad – korekce u CHOPN dat

➔ ANOVA na hladině významnosti  $\alpha = 0,05$  zamítla  $H_0$  o rovnosti středních hodnot Plmax. Jaké skupiny se od sebe nejvíce liší?

➔ Bonferroniho procedura

| Stadium | III   | IV    |
|---------|-------|-------|
| II      | 0,398 | 0,009 |
| III     | -     | 0,571 |

➔ Tukeyho post hoc test

| Stadium | III   | IV    |
|---------|-------|-------|
| II      | 0,186 | 0,008 |
| III     | -     | 0,433 |

➔ Scheffého post hoc test

| Stadium | III   | IV    |
|---------|-------|-------|
| II      | 0,214 | 0,011 |
| III     | -     | 0,466 |

➔ Zde nám všechny tři analýzy vyšly stejně, ale obecně to neplatí!



# Poděkování...

Rozvoj studijního oboru „Matematická biologie“ PŘF MU Brno je finančně podporován prostředky projektu ESF č. CZ.1.07/2.2.00/07.0318 „Víceoborová inovace studia Matematické biologie“ a státním rozpočtem České republiky



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ