

# Přednáška XI.

## Asociace ve čtyřpolní tabulce a základy korelační analýzy

- ➔ Relativní riziko a poměr šancí
- ➔ Princip korelace dvou náhodných veličin
- ➔ Korelační koeficienty – Pearsonův a Spearmanův
- ➔ Korelace a kauzalita



evropský  
sociální  
fond v ČR



EVROPSKÁ UNIE  
MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání  
pro konkurenceschopnost



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

# Opakování – Testování hypotéz o podílech

- ➔ V čem se liší konstrukce intervalů spolehlivosti a testování hypotéz při rozhodování o podílech (zastoupení „úspěchů“ v náhodném výběru)?

# Opakování – Fisherův exaktní test

➔ Jak funguje Fisherův exaktní test?

Veličina $X$	Veličina $Y$		Celkem
	$Y = 1$	$Y = 2$	
$X = 1$	$a$	$b$	$a + b$
$X = 2$	$c$	$d$	$c + d$
Celkem	$a + c$	$b + d$	$n$

# Opakování – Chí-kvadrát test dobré shody

- ➔ Lze použít chí-kvadrát test dobré shody na testování normality dat?
- ➔ Pokud ano, jak?

# 1. Vyhádření rizik ve čtyřpolní tabulce

# Motivace

- ➡ Sledujeme souvislost věku matky a výskytu náhlého úmrtí kojence (SIDS).

Výsledky dány v tabulce:

SIDS	Věk matky		
	Do 25 let	25 a více let	Celkem
Ano	29	15	44
Ne	7301	11241	18542
Celkem	7330	11256	18586

- ➡ Pomocí Pearsonova chí-kvadrát nebo Fisherova exaktního testu můžeme rozhodovat o závislosti/nezávislosti dvou sledovaných veličin. Testy ale neumožňují tento vztah kvantifikovat.
- ➡ **Má-li to smysl a chceme-li kvantifikovat (rozhodovat o těsnosti této závislosti) můžeme použít tzv. relativní riziko a poměr šancí.**

# Relativní riziko = Relative risk

- ➔ Výpočet relativního rizika (RR) umožňuje srovnat pravděpodobnosti výskytu sledovaného jevu ve dvou různých skupinách.
- ➔ 1. skupina – **experimentální nebo skupina s expozicí určitému faktoru**
- ➔ 2. skupina – **kontrolní nebo skupina bez expozice**

$$RR = \frac{\text{Pravděpodobnost výskytu jevu v 1. skupině (experimentální)}}{\text{Pravděpodobnost výskytu jevu ve 2. skupině (kontrolní)}} = \frac{P_1}{P_0}$$

Sledovaný jev	Skupina		Celkem
	Experimentální	Kontrolní	
Ano	$a$	$b$	$a + b$
Ne	$c$	$d$	$c + d$
Celkem	$a + c$	$b + d$	$n$

$$\rightarrow RR = \frac{P_1}{P_0} = \frac{\frac{a}{a+c}}{\frac{b}{b+d}}$$

# Příklad – relativní riziko

👉 Sledujeme souvislost věku matky a výskytu náhlého úmrtí kojence (SIDS).

Výsledky dány v tabulce:

SIDS	Věk matky		
	Do 25 let	25 a více let	Celkem
Ano	29	15	44
Ne	7301	11241	18542
Celkem	7330	11256	18586

$$RR = \frac{P_1}{P_0} = \frac{\frac{a}{b}}{\frac{b+d}{a+c}} = \frac{\frac{29}{15}}{\frac{15+11241}{29+7301}} = 2,97$$

Riziko výskytu SIDS u dětí matek ve věku do 25 je téměř třikrát vyšší než u dětí matek rodících ve vyšším věku.

# Poměr šancí = Odds ratio

- ➔ Poměr šancí (OR) je další charakteristikou, která umožňuje srovnat výskyt sledovaného jevu ve dvou různých skupinách.
- ➔ 1. skupina – **experimentální nebo skupina s expozicí určitému faktoru**
- ➔ 2. skupina – **kontrolní nebo skupina bez expozice**

$$OR = \frac{\frac{\text{Pravděpodobnost výskytu jevu v 1. skupině (experimentální)}}{1 - \text{Pravděpodobnost výskytu jevu v 1. skupině (experimentální)}}}{\frac{\text{Pravděpodobnost výskytu jevu ve 2. skupině (kontrolní)}}{1 - \text{Pravděpodobnost výskytu jevu ve 2. skupině (kontrolní)}}} = \frac{O_1}{O_0} = \frac{\frac{P_1}{1-P_1}}{\frac{P_0}{1-P_0}}$$

Sledovaný jev	Skupina		
	Experimentální	Kontrolní	Celkem
Ano	$a$	$b$	$a + b$
Ne	$c$	$d$	$c + d$
Celkem	$a + c$	$b + d$	$n$

$$\rightarrow OR = \frac{\frac{P_1}{1-P_1}}{\frac{P_0}{1-P_0}} = \frac{\frac{a}{c}}{\frac{b}{d}}$$

# Příklad – odds ratio

👉 Sledujeme souvislost věku matky a výskytu náhlého úmrtí kojence (SIDS).

Výsledky dány v tabulce:

SIDS	Věk matky		
	Do 25 let	25 a více let	Celkem
Ano	29	15	44
Ne	7301	11241	18542
Celkem	7330	11256	18586

$$OR = \frac{\frac{P_1}{1-P_1}}{\frac{P_0}{1-P_0}} = \frac{\frac{a}{c}}{\frac{b}{d}} = \frac{\frac{29}{7301}}{\frac{15}{11241}} = 2,98$$

„Šance“ na výskyt SIDS u dětí matek ve věku do 25 je téměř třikrát vyšší než u dětí matek rodících ve vyšším věku.

# Grafické srovnání $RR$ a $OR$

$$RR = \frac{\frac{6}{10}}{\frac{3}{10}} = 2$$

*OR* =

$$\begin{array}{c}
 \text{Red people} \\
 \hline
 6 \\
 \\ 
 \text{Blue people} \\
 \hline
 4 \\
 \\ 
 \text{Orange people} \\
 \hline
 3 \\
 \\ 
 \text{Total people} \\
 \hline
 7
 \end{array}
 = \frac{6}{7} = 3.5$$



## Výskyt sledovaného jevu



# Umělý příklad – pití slazených nápojů

👉 Sledujeme vliv pití slazených nápojů na výskyt zubního kazu. Výsledky dány v tabulce:


Zubní kaz	Pití slazených nápojů		
	Ano	Ne	Celkem
Ano	34	19	53
Ne	16	31	47
Celkem	50	50	100

$$RR = \frac{\frac{a}{b}}{\frac{b+d}{b+d}} = \frac{\frac{34}{19}}{\frac{19+31}{19+31}} = 1,79$$

$$OR = \frac{\frac{a}{b}}{\frac{d}{d}} = \frac{\frac{34}{19}}{\frac{16}{31}} = 3,47$$

# Srovnání $RR$ a $OR$

- ➔ Hodnoty, jakých může nabývat  $RR$  i  $OR$ , souvisí s četností výskytu sledované události v kontrolní (referenční) skupině.



# Výhody a nevýhody $RR$ a $OR$

➔ Nevýhoda  $OR$ :

- ➔ obtížná interpretace.


➔ Výhoda i nevýhoda  $RR$ :

- ➔ nezajímá ho samotná pravděpodobnost výskytu jevu, ale pouze jejich podíl → korektní použití RR je však pouze v případě, že pravděpodobnost výskytu jevu v kontrolní skupině je reprezentativní (není ovlivněna výběrem sledovaných subjektů).

# Prospektivní a retrospektivní studie


## ▶ Prospektivní studie

- ▶ U některých subjektů je rizikový faktor přítomen a u jiných ne → sledujeme v čase, zda se vyskytne událost.



## ▶ Retrospektivní studie

- ▶ U některých subjektů se událost vyskytla a u jiných ne → zpětně hodnotíme, zda se liší s ohledem na nějaký rizikový faktor.



# Použití *RR* a *OR*

- ➔ **Prospektivní studie** – u některých subjektů je rizikový faktor přítomen a u jiných ne → sledujeme, zda se vyskytne událost.
- ➔ Zjištěná pravděpodobnost výskytu události v kontrolní skupině je reprezentativní, neboť prospektivně zařazujeme všechny pacienty  
→ **korektní použití *RR*.**
  
- ➔ **Retrospektivní studie** – u některých subjektů se událost vyskytla a u jiných ne → zpětně hodnotíme, zda se liší s ohledem na nějaký rizikový faktor.
- ➔ Zjištěná pravděpodobnost výskytu události v kontrolní skupině není reprezentativní, neboť ji ovlivňujeme zpětným výběrem skupin subjektů.  
→ **nekorektní použití *RR*.**  
→ **korektní použití *OR*.**

# Srovnávané skupiny

- ➔ Pomocí  $RR$  i  $OR$  můžeme srovnat pravděpodobnosti výskytu sledovaného jevu ve dvou různých skupinách:
- ➔ **1. skupina s pravděpodobností výskytu události  $P_1$ :**
  - ➔ experimentální skupina – např. léčená novou léčbou
  - ➔ riziková skupina – např. hypertonici
  - ➔ skupina s expozicí určitému faktoru – např. horníci
- ➔ **2. skupina s pravděpodobností výskytu události  $P_0$ :**
  - ➔ kontrolní skupina
  - ➔ skupina bez expozice

# Intervalové odhady

- RR i OR jsou variabilní stejně jako četnosti v kontingenční tabulce – bodový odhad je tak vhodné doplnit  $100(1-\alpha)\%$  intervalem spolehlivosti.
- Lze ukázat, že pro nepříliš malé hodnoty  $a, b, c, d$  má přirozený logaritmus RR ( $\ln RR$ ) i přirozený logaritmus OR ( $\ln OR$ ) normální rozdělení.
- Pak platí:

$$SE(\ln RR) = \sqrt{\frac{1}{a} - \frac{1}{a+c} + \frac{1}{b} - \frac{1}{b+d}}$$

$$SE(\ln OR) = \sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}}$$

- 100(1- $\alpha$ )% IS pro přirozené logaritmy:

$$(d^*, h^*) = \ln RR \pm z_{1-\alpha/2} SE(\ln RR)$$

$$(d^*, h^*) = \ln OR \pm z_{1-\alpha/2} SE(\ln OR)$$

- 100(1- $\alpha$ )% IS pro RR a OR:

$$(d^{RR}, h^{RR}) = (\exp(d^*), \exp(h^*))$$

$$(d^{OR}, h^{OR}) = (\exp(d^*), \exp(h^*))$$

# Příklad – intervalové odhady

👉 Sledujeme souvislost věku matky a výskytu náhlého úmrtí kojence (SIDS):

SIDS	Věk matky		
	Do 25 let	25 a více let	Celkem
Ano	29	15	44
Ne	7301	11241	18542
Celkem	7330	11256	18586

$$RR = \frac{29/(29+7301)}{15/(15+11241)} = 2,97$$

$$OR = \frac{29/7301}{15/11241} = 2,98$$

👉 Logaritmická transformace:

$$SE(\ln RR) = \sqrt{\frac{1}{29} - \frac{1}{29+7301} + \frac{1}{15} - \frac{1}{15+11241}} = 0,317$$

$$SE(\ln OR) = \sqrt{\frac{1}{29} + \frac{1}{15} + \frac{1}{7301} + \frac{1}{11241}} = 0,318$$



$$(d^*, h^*) = 1,089 \pm 1,96 * 0,317 = (0,47; 1,71)$$

$$(d^*, h^*) = 1,092 \pm 1,96 * 0,318 = (0,47; 1,72)$$

👉 Zpětná transformace:

$$(d^{RR}, h^{RR}) = (\exp(d^*), \exp(h^*)) = (1,60; 5,53)$$

$$(d^{OR}, h^{OR}) = (\exp(d^*), \exp(h^*)) = (1,60; 5,58)$$

# Další způsoby vyjádření rozdílu rizika

## ➔ Relativní redukce rizika (RRR)

$$RRR = 1 - RR = 1 - \frac{\text{Redakce rizika}}{\text{Riziko bez léčby}} = 1 - \frac{10 - 7}{10} = 1 - 0.3 = 30\%$$

The diagram consists of two rows of ten stylized human figures each. The top row has three red figures at the top, with a horizontal line above them. The bottom row has seven black figures at the top, with a horizontal line above them.

## ➔ Absolutní redukce rizika (ARR)

$$ARR = \frac{\text{Redakce rizika}}{\text{Riziko bez léčby}} = \frac{\text{S léčbou}}{\text{Bez léčby}} = \frac{5}{10} - \frac{3}{10} = 0.2 = 20\%$$

The diagram consists of two rows of ten stylized human figures each. The top row has five red figures at the top, with a horizontal line above them. The bottom row has three red figures at the top, with a horizontal line above them.

# Další způsoby vyjádření rozdílu rizika

- Počet pacientů, které je potřeba léčit, abychom zabránili výskytu jedné události – „**number needed to treat**“ (NNT).

ARR = 20% → Pro snížení počtu událostí o 20 je třeba léčit 100 pacientů.



$$\text{NNT} = \frac{1}{0,2} = \frac{100}{20} = 5 \quad \text{NNT} = \text{Pro snížení počtu událostí o 1 je třeba léčit 5 pacientů.}$$

# Absolutní vs. relativní četnost

- ➡ Vyjádření výsledků v relativní formě (procento) má často příjemnou interpretaci, ale může být zavádějící.
  - ➡ Relativní vyjádření účinnosti by mělo být vždy doprovázeno absolutním vyjádřením účinnosti.
- ➡ **Příklad:** Srovnání účinnosti léčiva ve smyslu prevence CMP u kardiáků.
- Studie 1: Výskyt CMP ve skupině A je 12 %, ve skupině B je 20 %.  
Relativní změna v účinnosti = **40 %**; absolutní změna = **8 %**.
- Studie 2: Výskyt CMP ve skupině A je 0,9 %, ve skupině B je 1,5 %.  
Relativní změna v účinnosti = **40 %**; absolutní změna = **0,6 %**.
- ➡ Výsledkem je rozdílný přínos léčby při stejné relativní účinnosti.

# NNT a absolutní vs. relativní četnost

➔ **Příklad:** Srovnání účinnosti léčiva ve smyslu prevence CMP u kardiáků.

Studie 1: Výskyt CMP ve skupině A je 12 %, ve skupině B je 20 %.

Relativní změna v účinnosti = **40 %**; absolutní změna = **8 %**.

$$\rightarrow \text{NNT} = \frac{1}{0,08} = \frac{100}{8} = 12,5 \quad \text{NNT = Pro snížení počtu událostí o 1 je třeba léčit 13 pacientů.}$$

Studie 2: výskyt CMP ve skupině A je 0,9 %, ve skupině B je 1,5 %.

Relativní změna v účinnosti = **40 %**; absolutní změna = **0,6 %**.

$$\rightarrow \text{NNT} = \frac{1}{0,006} = \frac{100}{0,6} = 166,7 \quad \text{NNT = Pro snížení počtu událostí o 1 je třeba léčit 167 pacientů.}$$


## 2. Hodnocení vztahu dvou spojitých veličin – základy korelace

# Proč hodnotit vztah dvou spojитých veličin?

- ➔ Zatím jsme se zabývali spojitou veličinou v jedné skupině, spojitou veličinou ve více skupinách, diskrétní veličinou v jedné skupině, diskrétní veličinou ve více skupinách, dvěma diskrétními veličinami v jedné skupině.
  
- ➔ Teď se chceme zabývat dvěma spojitými veličinami v jedné skupině:
  1. **Chceme zjistit, jestli mezi nimi existuje vztah** – např. jestli vyšší hodnoty jedné veličiny znamenají nižší hodnoty jiné veličiny.
  2. **Chceme predikovat hodnoty jedné veličiny na základě znalosti hodnot jiných veličin.**
  3. **Chceme kvantifikovat vztah mezi dvěma spojitými veličinami** – např. pro použití jedné veličiny na místo druhé veličiny.

# Jak hodnotit vztah dvou spojitéch veličin?

- ➔ Nejjednodušší formou je bodový graf (x-y graf).
- ➔ Vztah výšky a váhy studentů Biostatistiky pro matematické biology – jaro 2010:



# Korelace

- ➔ **Korelační koeficient** – kvantifikuje míru vztahu mezi dvěma spojitými veličinami ( $X$  a  $Y$ ).
- ➔ Standardní metodou je výpočet Pearsonova korelačního koeficientu ( $r$ ).
  - ➔ Nabývá hodnot od -1 do 1.
  - ➔ Hodnota  $r$  je kladná, když vyšší hodnoty  $X$  souvisí s vyššími hodnotami  $Y$ , a naopak je záporná, když nižší hodnoty  $X$  souvisí s vyššími hodnotami  $Y$ .
  - ➔ Charakterizuje linearitu vztahu mezi  $X$  a  $Y$  – jinak řečeno variabilitu kolem lineárního trendu.
  - ➔ Hodnoty 1 nebo -1 získáme, když body x-y grafu leží na přímce.



# Pearsonův korelační koeficient ( $r$ )

- ➔ Předpokládáme realizaci dvourozměrného náhodného vektoru o rozsahu  $n$ :

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix} \quad (\text{máme dvojice hodnot, které patří k sobě – charakterizují } i\text{-tý subjekt})$$


- ➔ Pearsonův korelační koeficient:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{(n-1) s_x s_y}$$


- ➔ kde  $\bar{x}$  a  $\bar{y}$  jsou výběrové průměry,  $s_x$  a  $s_y$  jsou výběrové směrodatné odchyly.




# Pearsonův korelační koeficient ( $r$ )




$$r = 1,0$$



$$r = -0,9$$




$$r = 0,4$$



$$r = 0,05$$

# Příklad – Pearsonův korelační koeficient ( $r$ )

➡ Vztah výšky a váhy studentů Biostatistiky pro matematické biology – jaro 2010:



$$r = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{(n-1) s_x s_y}$$

$$\sum_{i=1}^n x_i y_i = 148\,929$$

$$n \bar{x} \bar{y} = 148\,417,2$$

$$s_x = 5,3$$


$$s_y = 12,5$$

$$r = \frac{148\,929 - 148\,417,2}{(13-1)*5,3*12,5} = 0,64$$

# Problémy s výpočtem $r$


- ➡ Pearsonův korelační koeficient lze vypočítat na jakýchkoliv datech.
- ➡ Pokud však budeme chtít jakkoliv rozhodovat o vlastnostech  $r$  (interval spolehlivosti, testování hypotéz), musíme učinit předpoklad o normalitě hodnocených veličin.

Více skupin




$$r = 0,93 \\ p < 0,001$$

Nelineární vztah



$$r = 0,63 \\ p < 0,001$$

Velikost výběru



$$r = 0,23 \\ p = 0,019$$



# Interval spolehlivosti pro $r$

- ➔ Výběrové rozdělení koeficientu  $r$  není normální, pro výpočet IS je třeba ho transformovat:


$$w = \frac{1}{2} \ln \frac{1+r}{1-r}$$

- ➔ Veličina  $w$  má normální rozdělení se standardní chybou přibližně:  $SE(w) = 1/\sqrt{n-3}$
- ➔  $100(1-\alpha)\%$  IS pro  $w$  má tvar:  $(d^*, h^*) = w \pm z_{1-\alpha/2} / \sqrt{n-3}$
- ➔  $100(1-\alpha)\%$  IS pro  $r$  pak dostaneme zpětnou transformací:

$$(d, h) = \left( \frac{\exp(2d^*) - 1}{\exp(2d^*) + 1}, \frac{\exp(2h^*) - 1}{\exp(2h^*) + 1} \right)$$

# Příklad – interval spolehlivosti pro $r$

► Vztah výšky a váhy studentů Biostatistiky pro matematické biology – jaro 2010:



$$r = 0,64$$

$$w = \frac{1}{2} \ln \frac{1+0,64}{1-0,64} = 0,758$$

$$SE(w) = 1/\sqrt{10} = 0,316$$

$$(d^*, h^*) = w \pm z_{1-\alpha/2} SE(w) = (0,138; 1,377)$$

$$(d, h) = \left( \frac{\exp(2d^*) - 1}{\exp(2d^*) + 1}, \frac{\exp(2h^*) - 1}{\exp(2h^*) + 1} \right)$$

$$(d, h) = (0,14; 0,88)$$

# Test hypotézy $H_0: r = 0$


- ➔ Předpokládáme realizaci dvourozměrného náhodného vektoru o rozsahu  $n$ :

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix} \quad \text{Předpokládáme normalitu } X \text{ i } Y!$$

- ➔ Za platnosti nulové hypotézy má statistika  $T = r \sqrt{\frac{n-2}{1-r^2}}$   $t$  rozdělení pravděpodobnosti s  $n - 2$  stupni volnosti.
- ➔ Pro oboustrannou alternativu zamítáme  $H_0$  na hladině významnosti  $\alpha = 0,05$ , když hodnota testové statistiky přesáhne v absolutní hodnotě kvantil  $t_{1-\alpha/2}^{(n-2)}$
- ➔ Tuto testovou statistiku nelze použít pro testování hypotézy  $H_0 : r = r_0 \neq 0$

# Příklad – test hypotézy $H_0: r = 0$

➡ Vztah výšky a váhy studentů Biostatistiky pro matematické biology – jaro 2010:



$$r = 0,64$$

$$T = r \sqrt{\frac{n-2}{1-r^2}} = 0,64 \sqrt{\frac{13-2}{1-0,64^2}} = 2,76$$

$$H_1: r \neq 0 \quad \longrightarrow \quad t_{1-\alpha/2}^{(n-2)} = t_{0,975}^{(11)} = 2,20$$

$$T = 2,76 > 2,20 = t_{0,975}^{(11)}$$

➡ Zamítáme  $H_0: r = 0$ .

# Spearmanův korelační koeficient ( $r_s$ )

- ➡ Pearsonův korelační koeficient je náhodný k odlehlym hodnotám a obecně odchylkám od normality. **Spearmanův korelační koeficient** stejně jako řada dalších neparametrických metod **pracuje pouze s pořadími** pozorovaných hodnot.

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix}$$

- ➡ Máme náhodný výběr rozsahu  $n$ :
- ➡ Definujeme:  
 $x_{ri}$  – pořadí  $x_i$  mezi hodnotami  $x$ ;  $y_{ri}$  – pořadí  $y_i$  mezi hodnotami  $y$ ;  $d_i = x_{ri} - y_{ri}$ .

- ➡ Spearmanův korelační koeficient:

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}$$

- ➡ Vyskytují-li se shodné hodnoty, doporučuje se použití Pearsonova korelačního koeficientu na pořadích.
- ➡ Hodnoty  $r_s$  se pohybují stejně jako u  $r$  od -1 do 1.

# Příklad – Spearmanův korelační koeficient ( $r_s$ )

↳ Vztah výšky a váhy studentů Biostatistiky pro matematické biology – jaro 2010:

Student	Výška $x_i$	Pořadí výška	Váha $y_i$	Pořadí váha	Rozdíl $d_i$	$d_i^2$
1	175	10	69	10	0	0
2	166	1	55	3	-2	4
3	170	4	67	8	-4	16
4	169	2,5	52	1	1,5	2,25
5	188	13	90	12,5	0,5	0,25
6	175	10	53	2	8	64
7	176	12	57	4,5	7,5	56,25
8	171	5	57	4,5	0,5	0,25
9	173	6,5	68	9	-2,5	6,25
10	175	10	73	11	-1	1
11	173	6,5	62	6	0,5	0,25
12	174	8	90	12,5	-4,5	20,25
13	169	2,5	63	7	-4,5	20,25

# Příklad – Spearmanův korelační koeficient ( $r_s$ )

💡 V souboru je hodně shodných hodnot → lépe použít Pearsonovo  $r$  na pořadí.

Student	Pořadí výška	Pořadí váha	Rozdíl $d_i$	$d_i^2$
1	10	10	0	0
2	1	3	-2	4
3	4	8	-4	16
4	2,5	1	1,5	2,25
5	13	12,5	0,5	0,25
6	10	2	8	64
7	12	4,5	7,5	56,25
8	5	4,5	0,5	0,25
9	6,5	9	-2,5	6,25
10	10	11	-1	1
11	6,5	6	0,5	0,25
12	8	12,5	-4,5	20,25
13	2,5	7	-4,5	20,25

$$r = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{(n-1) s_x s_y}$$

$$\sum_{i=1}^n x_i y_i = 721,5$$

$$n \bar{x} \bar{y} = 637$$

$$s_x = 3,86$$

$$s_y = 3,88$$

$$r = \frac{721,5 - 637}{(13-1)*3,86*3,88} = 0,47$$


$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} = 1 - \frac{6 * 191}{13(13^2 - 1)} = 0,48$$

# Jak to, že nám $r$ a $r_s$ vyšly různě?

👉 Původní hodnoty:  $r = 0,64$

👉 Pořadí:  $r = 0,47$

$r_s = 0,48$



# IS pro $r_s$ a test hypotézy $H_0: r_s = 0$

- ➡ Výběrové rozdělení  $r_s$  je pro výběry s  $n > 10$  stejné jako výběrové rozdělení  $r$ , proto je možné pro konstrukci  $100(1-\alpha)\%$  IS použít metodu pro Pearsonův koeficient.
- ➡ Pro větší vzorky,  $n > 30$ , je možné použít pro ověření hypotézy  $H_0: r_s = 0$  stejnou testovou statistiku jako v případě  $r$ :


$$T = r_s \sqrt{\frac{n-2}{1-r_s^2}} \sim t^{(n-2)}$$

# Poznámka o $r^2$

- ➔ Korelace dvou náhodných veličin se často interpretuje pomocí druhé mocniny Pearsonova korelačního koeficientu:  $r^2$ .
- ➔ Hodnota  $r^2$  vyjadřuje, kolik % své variability sdílí jedna veličina s druhou, jinak řečeno, kolik % variability jedné veličiny může být predikováno pomocí té druhé.
- ➔ S hodnotou  $r^2$  se setkáte v lineárních modelech.

# Klíčové principy – zkreslení

- ➔ Pojem **zavádějící faktor** – pro zavádějící faktor současně platí, že
  - ➔ přímo nebo nepřímo ovlivňuje sledovaný následek,
  - ➔ je ve vztahu se studovanou expozicí ,
  - ➔ není mezikrokem mezi expozicí a následkem.



# 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



evropský  
sociální  
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání  
pro konkurenceschopnost



UNIVERSITAS  
MASARYKIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tomáš Pavlík



Biostatistika