

# Základy biostatistiky

(MD710P09)

ak. rok 2008/2009

Karel Zvára

karel.zvara@mff.cuni.cz

<http://www.karlin.mff.cuni.cz/~zvara>

katedra pravděpodobnosti a matematické statistiky MFF UK

(naposledy upraveno 21. dubna 2009)



## motivační příklad diety: váhové přírůstky za danou dobu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test

## motivační příklad diety: váhové přírůstky za danou dobu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test

## motivační příklad diety: váhové přírůstky za danou dobu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test

## motivační příklad diety: váhové přírůstky za danou dobu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test

# náhodné bloky

- ▶ zobecnění párových testů na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření nebo jeho násobek
  - ▶ ošetření se přiřadí uvnitř bloku náhodně (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2), \quad j = 1, \dots, r, \quad i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$

# náhodné bloky

- ▶ zobecnění párových testů na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření nebo jeho násobek
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2), \quad j = 1, \dots, r, \quad i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$

# náhodné bloky

- ▶ zobecnění párových testů na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření nebo jeho násobek
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2), \quad j = 1, \dots, r, \quad i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$



# náhodné bloky

- ▶ zobecnění párových testů na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření nebo jeho násobek
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2), \quad j = 1, \dots, r, \quad i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$

# náhodné bloky

- ▶ zobecnění párových testů na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření nebo jeho násobek
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2), \quad j = 1, \dots, r, \quad i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$

# náhodné bloky

- ▶ zobecnění párových testů na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření nebo jeho násobek
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2), \quad j = 1, \dots, r, \quad i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$

# náhodné bloky

## ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$  (ošetření  $B$  nemá vliv)
- ▶ případně  $H_A : \sigma_A^2 = 0$  (nulová variabilita mezi bloky)

## ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

## ▶ vliv dvou faktorů

- ▶  $A$  – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
- ▶  $B$  – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
- ▶ rozhodování zda  $A$  je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

## ▶ testované hypotézy

▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

## ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

## ▶ vliv dvou faktorů

- ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
- ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
- ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

## ▶ testované hypotézy

▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

## ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

## ▶ vliv dvou faktorů

- ▶  $A$  – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
- ▶  $B$  – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
- ▶ rozhodování zda  $A$  je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy
  - ▶  $H_B : \beta_1 = \dots = \beta_r = 0$  (ošetření  $B$  nemá vliv)
  - ▶ případně  $H_A : \sigma_A^2 = 0$  (nulová variabilita mezi bloky)
- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**
  - ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**

- ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci



# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**

- ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**

- ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy
  - ▶  $H_B : \beta_1 = \dots = \beta_r = 0$  (ošetření  $B$  nemá vliv)
  - ▶ případně  $H_A : \sigma_A^2 = 0$  (nulová variabilita mezi bloky)
- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**
  - ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

## příklad diety

## ▶ tabulka ANOVA

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

### ▶ tabulka ANOVA

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

### ▶ tabulka ANOVA

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

### ▶ tabulka ANOVA

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

### ▶ tabulka ANOVA

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů



## příklad diety

- ▶ kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	$S$	$f$	$S/f$	$F$	$p$
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- ▶ `[summary(aov(prirustek~Dieta,data=Mysi))]`
- ▶ porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

## příklad diety

- ▶ kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	$S$	$f$	$S/f$	$F$	$p$
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- ▶ `[summary(aov(prirustek~Dieta,data=Mysi))]`
- ▶ porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

## příklad diety

- ▶ kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	$S$	$f$	$S/f$	$F$	$p$
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- ▶ `[summary(aov(prirustek~Dieta,data=Mysi))]`
- ▶ porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

# Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu (neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojitě rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu (neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojitě rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu (neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu (neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojitě rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$



## Friedmanův test, zobecnění znaménkového testu (neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojitě rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu (neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## příklad diety

```
[friedman.test(prirustek~Dieta|Vrh,data=Mysi)]
```

vrh	dieta				prům.
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
prům.	8,56	8,06	10,28	10,58	9,370

vrh	dieta				
	A	B	C	D	
1	2	1	3	4	
2	1	2	4	3	
3	2	1	4	3	
4	3	1	2	4	
5	1	2	4	3	
součet	9	7	17	17	

$$k = 5$$

$$r = 4$$

$$Q = \frac{12}{5 \cdot 4 \cdot 5} (9^2 + 7^2 + 17^2 + 17^2) - 3 \cdot 5 \cdot 5 = 9,96$$

$$Q > \chi_3^2(0,05) = 7,8147$$

$$p = 0,0189$$

# dvojné třídění s interakcemi

opět **normální rozdělení**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$   
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$   
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \quad \sum_j \gamma_{ij} = 0$   
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

# dvojné třídění s interakcemi

opět **normální rozdělení**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$

- ▶  $\sum_i \alpha_i = 0$

**efekty** faktoru A odpovídající jeho  $k$  úrovním

- ▶  $\sum_j \beta_j = 0$

**efekty** faktoru B odpovídající jeho  $r$  úrovním

- ▶  $\sum_i \gamma_{ij} = 0, \quad \sum_j \gamma_{ij} = 0$

**interakce** vyjadřují neaditivitu obou faktorů

(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

# dvojné třídění s interakcemi

opět **normální rozdělení**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$   
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$   
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \quad \sum_j \gamma_{ij} = 0$   
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

# dvojné třídění s interakcemi

opět **normální rozdělení**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$

- ▶  $\sum_i \alpha_i = 0$

**efekty** faktoru A odpovídající jeho  $k$  úrovním

- ▶  $\sum_j \beta_j = 0$

**efekty** faktoru B odpovídající jeho  $r$  úrovním

- ▶  $\sum_i \gamma_{ij} = 0, \quad \sum_j \gamma_{ij} = 0$

**interakce** vyjadřují neaditivitu obou faktorů

(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

# dvojné třídění s interakcemi

opět **normální rozdělení**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$   
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$   
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \quad \sum_j \gamma_{ij} = 0$   
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )



## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (aditivita obou faktorů)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A
- ▶  $H_A : \alpha_i = 0$  (faktor A nemá vliv)
- ▶  $H_B : \beta_j = 0$  (faktor B nemá vliv)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (aditivita obou faktorů)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A
- ▶  $H_A : \alpha_i = 0$  (faktor A nemá vliv)
- ▶  $H_B : \beta_j = 0$  (faktor B nemá vliv)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (aditivita obou faktorů)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A
- ▶  $H_A : \alpha_j = 0$  (faktor A nemá vliv)
- ▶  $H_B : \beta_j = 0$  (faktor B nemá vliv)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (aditivita obou faktorů)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A
- ▶  $H_A : \alpha_j = 0$  (faktor A nemá vliv)
- ▶  $H_B : \beta_j = 0$  (faktor B nemá vliv)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (aditivita obou faktorů)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A
- ▶  $H_A : \alpha_j = 0$  (faktor A nemá vliv)
- ▶  $H_B : \beta_j = 0$  (faktor B nemá vliv)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

`[anova(lm(gol~Gender*Popul))]`

nebo

`[anova(lm(gol~Gender+Popul+Gender:Popul))]`



$$p_{AB} = 0,8872$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

`[anova(lm(gol~Gender*Popul))]`

nebo

`[anova(lm(gol~Gender+Popul+Gender:Popul))]`



$$p_{AB} = 0,8872$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

$[anova(lm(gol \sim Gender * Popul))]$

nebo

$[anova(lm(gol \sim Gender + Popul + Gender:Popul))]$



$$p_{AB} = 0,8872$$



## příklad Howells (GOL)

pohlaví	místo	$n_{ij}$	$\bar{y}_{ij}$	$s_{ij}$
M	Berg	40	180,300	7,293
F	Berg	40	170,450	6,641
M	Austrálie	40	190,375	5,555
F	Austrálie	40	181,375	6,632
M	Sibiř	40	181,175	6,468
F	Sibiř	40	172,175	5,228

variabilita	$S$	$f$	$S/f$	$F$	$p$
místa	5242,1	2	2621,1	65,2	<0,0001
pohlaví	5170,8	1	5170,8	128,6	<0,0001
interakce	9,6	2	4,8	0,1	0,8872
reziduální	9410,6	234	40,2		
celková	19833,2	239			


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

`[anova(lm(oca~Gender*Popul))]`

nebo

`[anova(lm(oca~Gender+Popul+Gender:Popul))]`



$$p_{AB} = 0,0222$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

`[anova(lm(oca~Gender*Popul))]`

nebo

`[anova(lm(oca~Gender+Popul+Gender:Popul))]`



$$p_{AB} = 0,0222$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

`[anova(lm(oca~Gender*Popul))]`

nebo

`[anova(lm(oca~Gender+Popul+Gender:Popul))]`



$$p_{AB} = 0,0222$$

## příklad Howells (OCA)

pohlaví	místo	$n_{ij}$	$\bar{y}_{ij}$	$s_{ij}$
M	Berg	40	116,675	5,567
F	Berg	40	116,850	5,682
M	Austrálie	40	115,025	4,382
F	Austrálie	40	114,800	4,286
M	Sibiř	40	113,450	4,782
F	Sibiř	40	117,200	4,973

variabilita	$S$	$f$	$S/f$	$F$	$p$
místa	150,908	2	75,454	3,05	0,0493
pohlaví	91,267	1	91,267	3,69	0,0560
interakce	191,608	2	95,804	3,87	0,0222
reziduální	5789,550	234	24,742		
celková	6223,333	239			

## porovnání populačních měř polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ - test	jednovýběrový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů



# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává jak závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává jak závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává jak závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti závisle proměnné  $Y$  na nezávisle proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává jak závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$



# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost (závislost  $Y$  na  $x \neq$  závislost  $X$  na  $y$ )
  - ▶ lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$

(zaveden na obr. 78)

- ▶  $|\rho_{XY}| \leq 1$
- ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
- ▶ měří sílu **lineární** závislosti

- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$   
(zaveden na obr. 78)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$

(zaveden na obr. 78)

- ▶  $|\rho_{XY}| \leq 1$
- ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
- ▶ měří sílu **lineární** závislosti

- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$

- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$   
(zaveden na obr. 78)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]



# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$   
(zaveden na obr. 78)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
  - ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$   
(zaveden na obr. 78)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
  - ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$   
(zaveden na obr. 78)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
  - ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(zavedení **výběrového** korelačního koeficientu)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$

(zaveden na obr. 78)

- ▶  $|\rho_{XY}| \leq 1$
- ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
- ▶ měří sílu **lineární** závislosti

- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 34)

$$r_{XY} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ odhaduje  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, **[correlation coefficient]**

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0: \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti
  - ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0: \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient

- ▶ měří sílu **monotonní** závislosti
- ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti
  - ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti
  - ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$



## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti
  - ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti
  - ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti nutno **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)


- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti
  - ▶ založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## závislost váhy na výšce u mužů

data: Policie

`[plot(weight~height)]``[cor.test(weight,height)]`

$$r = 0,648$$


$$t = 5,814$$

$$p < 0,001$$

## závislost váhy na pulsu u mužů

data: Policie

[plot(weight~pulse)]



[cor.test(pulse,weight)]

$$r = -0,245$$

$$t = -1,752$$

$$p = 8,6 \%$$