

# **Základy biostatistiky 2003/2004**

(poslední úprava 11. května 2004)

## **statistika:**

- **popisná** (data stručně popsát, něco z dat „vydolovat“)
- **induktivní** (tvrdit něco nového, zobecnit na větší soubor, záleží na interpretaci)

## **příklady dat:**

- **výšky** (výška desetiletých chlapců/dívek)
- **děti** (pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku)
- **kojení** (hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice)

**znak** - vlastnost měřená na objektu (statistiké jednotce): délka, barva, . . .  
možná **měřítka**:

- **nominální** (porodnice, pohlaví) seznam všech rozlišitelných hodnot, **faktor**
- **ordinální** (vzdělání matky, . . . , stupeň bolesti) hodnoty nominálního uspořádány, **uspořádaný faktor**
- **intervalové** (rok narození, teplota v °C) stejně vzdálenosti sousedních hodnot, o kolik se liší?
- **poměrové** (hmotnost, výška, věk) srovnání se zvolenou jednotkou, kolikrát je větší?

číselné **veličiny** (zápis hodnot znaků):

- **spojité**: intervalové, poměrové (ordinální) měřítko
- **diskrétní**: četnosti hodnot v nominálním nebo ordinálním měřítku

## Popisné statistiky

**statistika:** též funkce pozorovaných hodnot

$x_1, x_2, \dots, x_n$  zjištěné hodnoty

$x_1^*, x_2^*, \dots, x_m^*$  možné hodnoty (různé)  
 $n_1, n_2, \dots, n_m$  **četnosti** hodnot

$$n_1 + n_2 + \dots + n_m = \sum_{j=1}^m n_j = n$$

$\frac{n_1}{n}, \frac{n_2}{n}, \dots, \frac{n_m}{n}$  - relativní četnosti

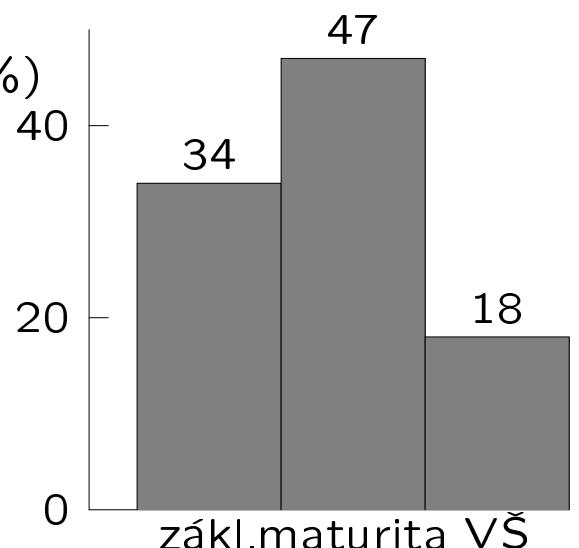
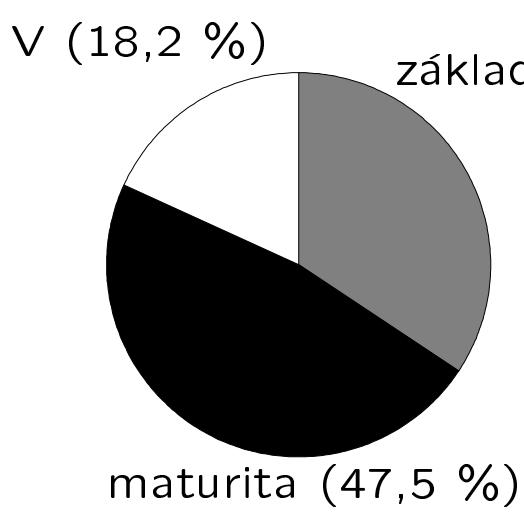
$$N_j = \sum_{i=1}^j n_i \quad \text{**kumulativní četnosti**}$$

kumulativní četnosti - nutno aspoň ordinální měřítko

**histogram:** grafické znázornění četností  
plocha (výška) obdélníku úměrná četnosti  
(relativní četnosti – jiné měřítko)  
podobně **výsečový diagram**

příklad **kojení** (vzdělání matky):

vzděl.	zákl.	maturita	VŠ	celkem
$x_j^*$	1	2	3	
$n_j$	34	47	18	99
$n_j/n$	0,343	0,475	0,182	1,000
$n_j/n$	34,3 %	47,5 %	18,2 %	100 %
$N_j$	34	81	99	



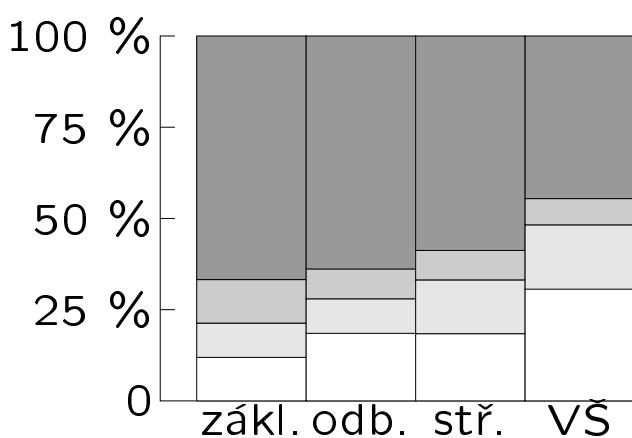
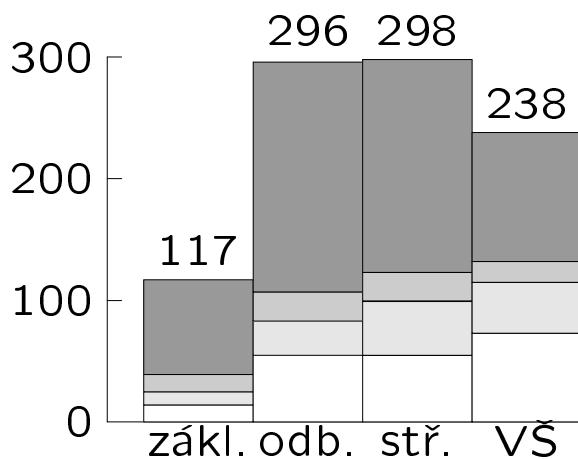
dvojice znaků – (není totéž co dva znaky!)  
možnost porovnání či zkoumání závislosti  
(kontingenční tabulka)  
v procentech v dané skupině (pro danou hodnotu jednoho znaku)

### příklad **kouření u mužů**

vzdělání	zákl.	odb.	mat.	VŠ	celkem
nekuřák	14	55	55	73	197
bývalý kuřák	11	28	44	42	125
kuřák	14	24	24	17	79
silný kuřák	78	189	175	106	548
celkem	117	296	298	238	949

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	12,0%	18,6%	18,5%	30,7%	20,6%
bývalý kuřák	9,4%	9,5%	14,8%	17,6%	13,2%
kuřák	12,0%	8,1%	8,1%	7,1%	8,3%
silný kuřák	66,7%	63,9%	58,7%	44,5%	57,8%
celkem	100%	100%	100%	100%	100%

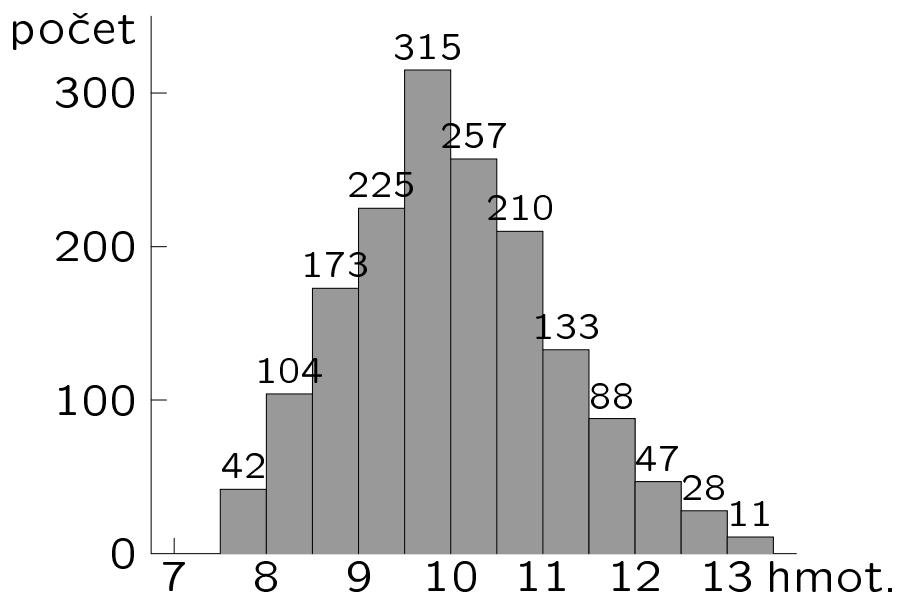


(zdola: nekuřák, bývalý kuřák, kuřák, silný kuřák)

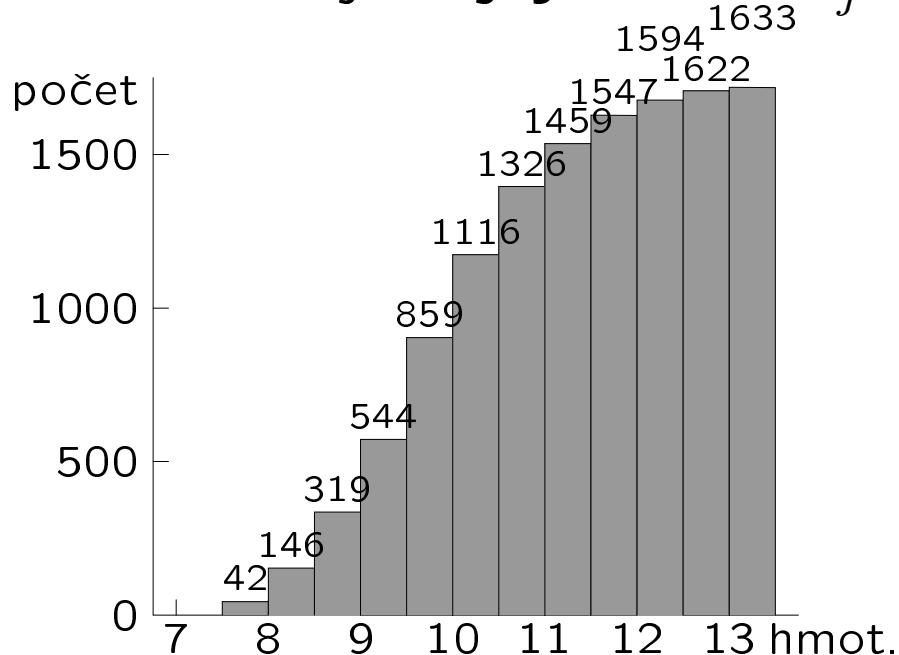
histogram u **spojité** veličiny – **třídění**: všechny hodnoty z daného intervalu  $(t_{j-1}, t_j]$  nahradíme prostřední hodnotou  $x_j^* = (t_{j-1} + t_j)/2$

## hmotnost dětí (příklad **děti**)

$j$	$x_j^*$	$t_j$	$n_j$	$n_j/n$	$N_j$	$N_j/n$
1	7750	8000	42	0,026	42	0,026
2	8250	8500	104	0,063	146	0,089
3	8750	9000	173	0,106	319	0,195
4	9250	9500	225	0,138	544	0,333
5	9750	10000	315	0,193	859	0,526
6	10250	10500	257	0,157	1116	0,683
7	10750	11000	210	0,129	1326	0,812
8	11250	11500	133	0,081	1459	0,893
9	11750	12000	88	0,054	1547	0,947
10	12250	12500	47	0,029	1594	0,976
11	12750	13000	28	0,017	1622	0,992
12	13250	$\infty$	11	0,007	1633	1,000

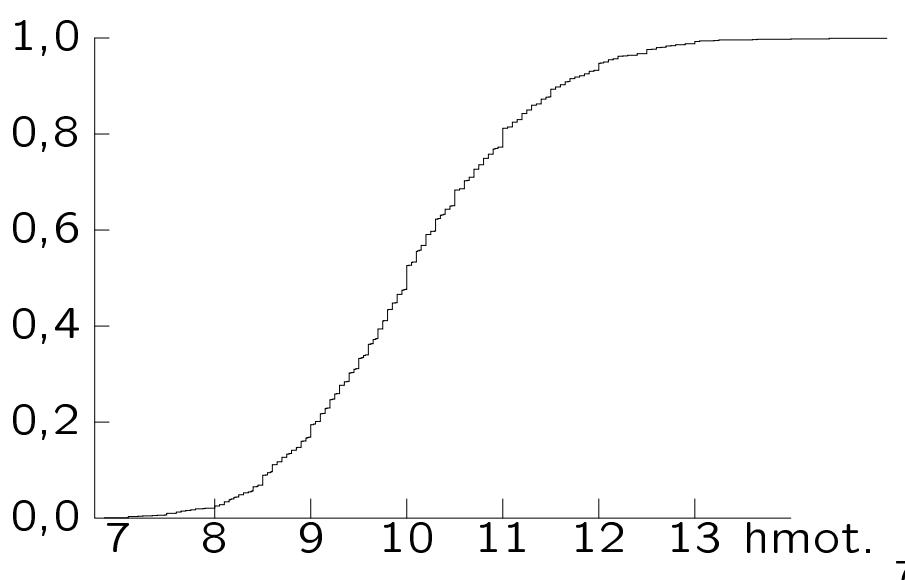


**kumulativní** četnosti ukazují vždy podíl dětí, jejichž hmotnost je **nejvýše** rovna  $t_j$



**empirická distribuční funkce:** relativní četnost hodnot, které jsou nejvýše  $x$

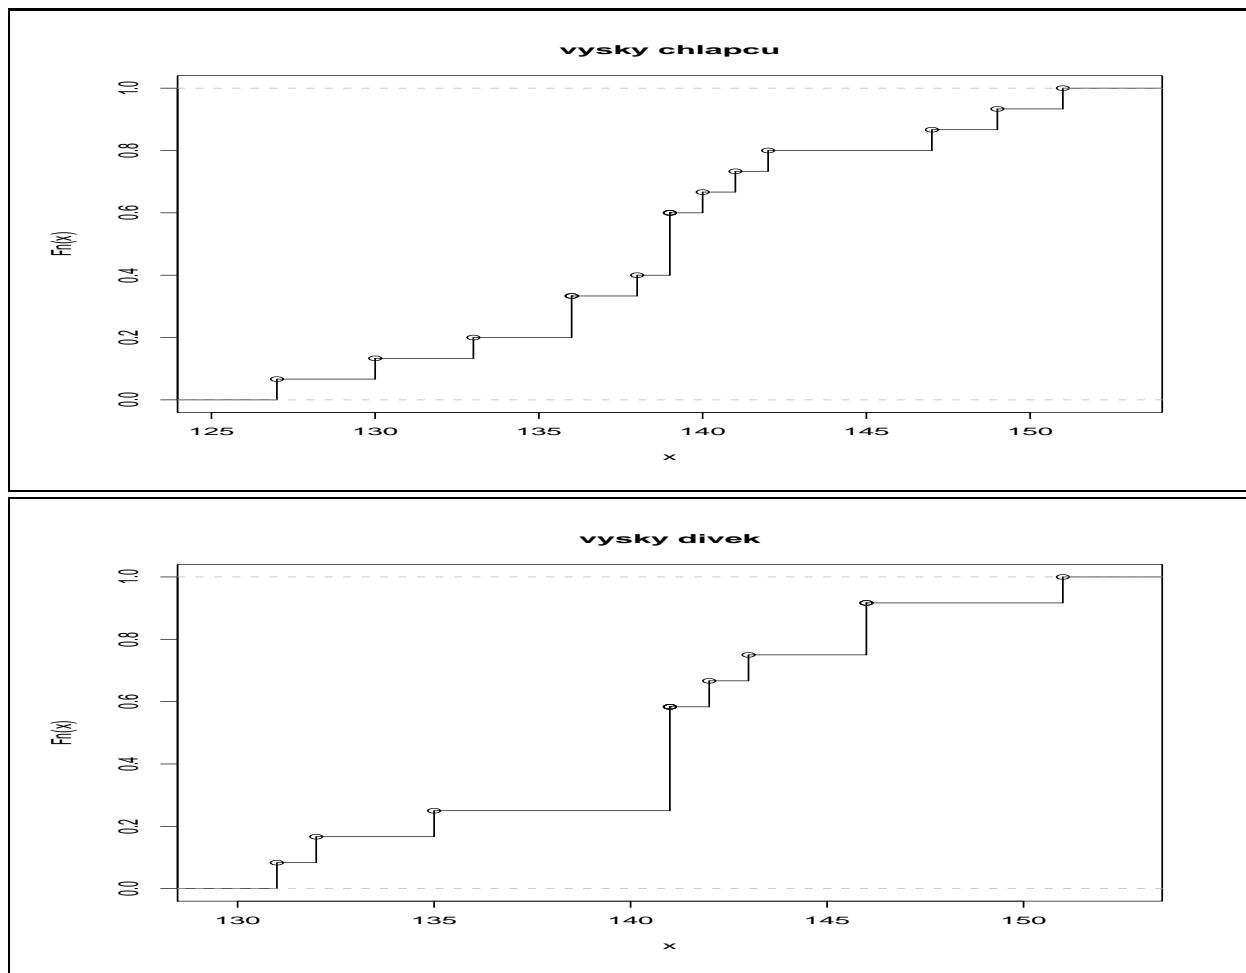
$$F_n(x) = \frac{\text{počet } (x_i \leq x)}{n}$$



$x$  – výšky desetiletých hochů

$y$  – výšky desetiletých dívek

$i$	1	2	3	4	5	6	7	8
$x_i$	130	140	136	141	139	133	149	151
$y_i$	135	141	143	132	146	146	151	141
$i$	9	10	11	12	13	14	15	
$x_i$	139	136	138	142	127	139	147	
$y_i$	141	131	142	141				



## uspořádaný seznam hodnot

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

**pořadí** na které místo se dané pozorování v uspořádaném seznamu dostane (při shodě průměrné pořadí)

**míry polohy:**  $\mu(a + bX) = a + b\mu(X)$

- **průměr**

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- **medián** (dolní a horní polovina hodnot)

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & n \text{ liché} \\ \frac{1}{2} \left( x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)} \right) & n \text{ sudé} \end{cases}$$

- **minimum, maximum**

$$x_{\min} = x_{(1)}$$

$$x_{\max} = x_{(n)}$$

- **variační průměr**

$$\frac{1}{2} \left( x_{(1)} + x_{(n)} \right) = \frac{1}{2} (x_{\min} + x_{\max})$$

- **$p$ -tý percentil** (dolních  $100p$  % hodnot)

$$r = [(n+1)p] \quad \text{celá část } (n+1)p$$

$$q = (n+1)p - r \quad \text{zlomková část } (n+1)p$$

$$x_p = (1-q)x_{(r)} + qx_{(r+1)}$$

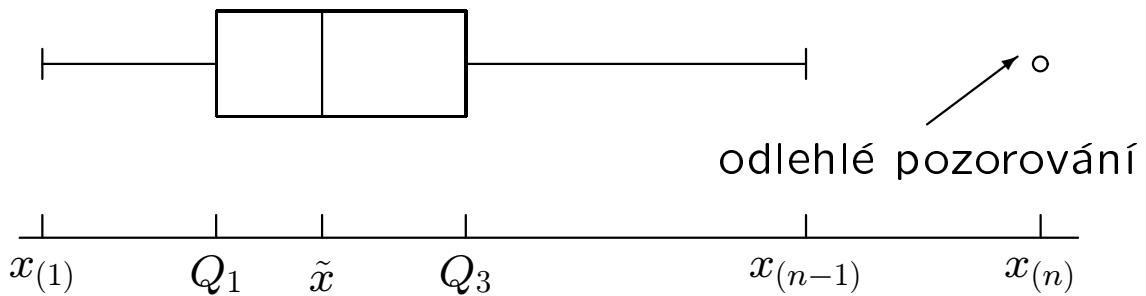
- **dolní kvartil** (oddělí dolní čtvrtinu)

$$Q_1 = x_{1/4}$$

- **horní kvartil** (oddělí dolní tři čtvrtiny)

$$Q_3 = x_{3/4}$$

krabicový diagram



## výšky dívek

$j$	1	2	3	4	5	6	7	8
$y_j^*$	131	132	135	141	142	143	146	151
$n_j$	1	1	1	4	1	1	2	1
poř.	1	2	3	5,5	8	9	10,5	12

$$\bar{y} = \frac{1}{12} (131 + 132 + \dots + 151) = 140,83$$

$$\tilde{y} = \frac{1}{2} (y_{(6)} + y_{(7)}) = \frac{1}{2} (141 + 141) = 141$$

$$r = [(12+1)/4] = 3 \quad q = (12+1)/4 - 3 = 1/4$$

$$Q_1 = \frac{3}{4}y_{(3)} + \frac{1}{4}y_{(4)} = 0,75 \cdot 135 + 0,25 \cdot 141 = 136,5$$

$$Q_3 = 0,25 \cdot 143 + 0,75 \cdot 146 = 145,25$$

$$s_y^2 = \frac{1}{11} ((131 - 140,83)^2 + \dots + (151 - 140,83)^2) \\ \doteq 33,788$$

$$s_y = \sqrt{33,788} \doteq 5,813$$

$$R = 151 - 131 = 20$$

$$R_Q = 145,25 - 136,5 = 8,75$$

vztah mužů ke kouření (základní vzdělání):

$$H = - \left( \frac{14}{117} \log \frac{14}{117} + \dots + \frac{78}{117} \log \frac{78}{117} \right) = 1,000689$$

ostatní kategorie: 1,025939; 1,109783; 1,217334

## míry variability (měřítka)

$$\sigma(a + bX) = b\sigma(X) \quad (b > 0)$$

- **směrodatná odchylka**

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

- **rozptyl**  $s_x^2$  (nesplňuje vztah)
- **rozpětí**  $R = x_{\max} - x_{\min}$
- **kvartilové rozpětí**  $R_Q = Q_3 - Q_1$
- **variační koeficient**  
porovnání variability při různých úrovních

$$V_x = \frac{s_x}{\bar{x}}$$

- **entropie** (nejistota nominální)

$$H = - \sum_{j=1}^m \frac{n_j}{n} \log \frac{n_j}{n}$$

(nezávisí na označení hodnot)

**z-skór** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}$$

platí  $\bar{z} = 0, s_z = 1 \Rightarrow$

vyšetřováním  $z$  hodnotíme jiné vlastnosti, na poloze a variabilitě nezávislé

- **šikmost**

$$g_1 = \frac{1}{n} \sum_{i=1}^n z_i^3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3$$

- **špičatost**

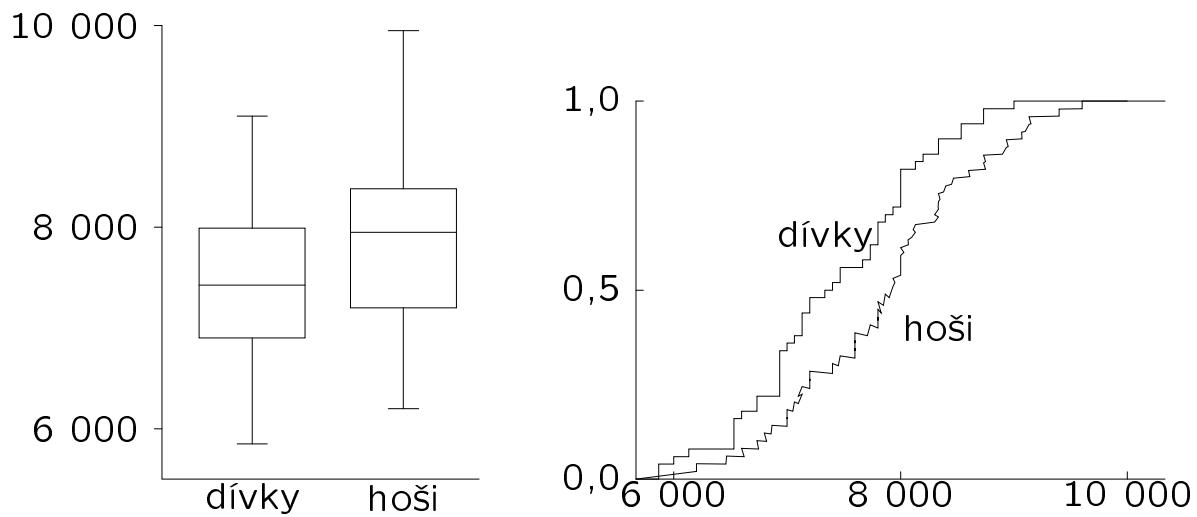
$$g_2 = \frac{1}{n} \sum_{i=1}^n z_i^4 - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3$$

(někdy bez odečítání 3)

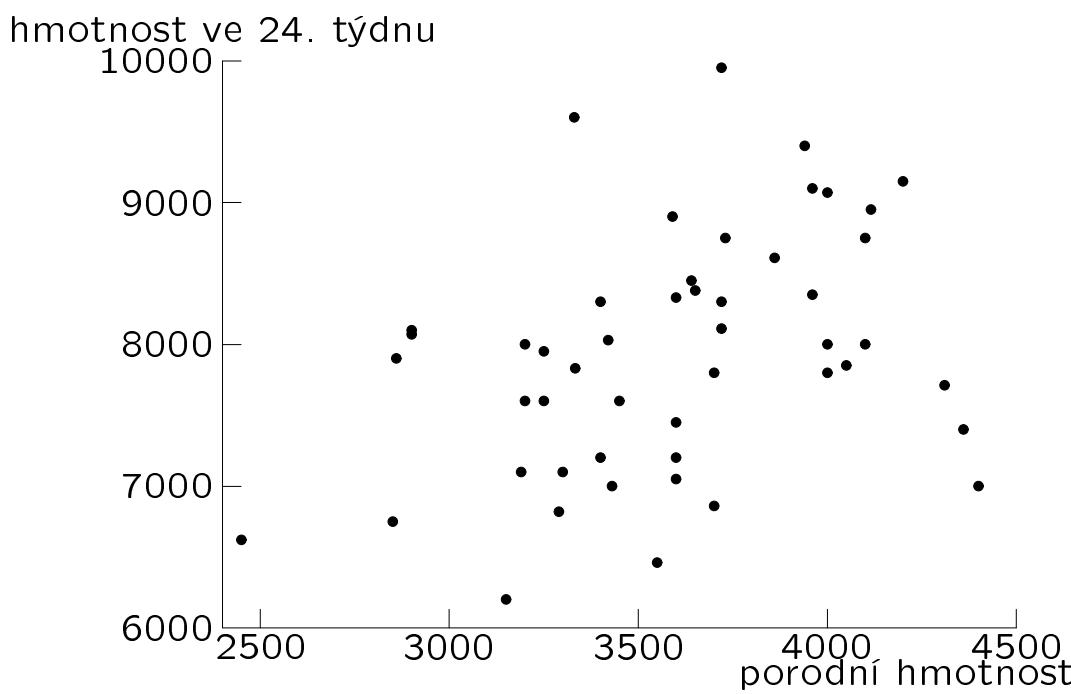
$g_1, g_2$  se používají k posouzení normality

## další grafická znázornění

- srovnání souborů dat

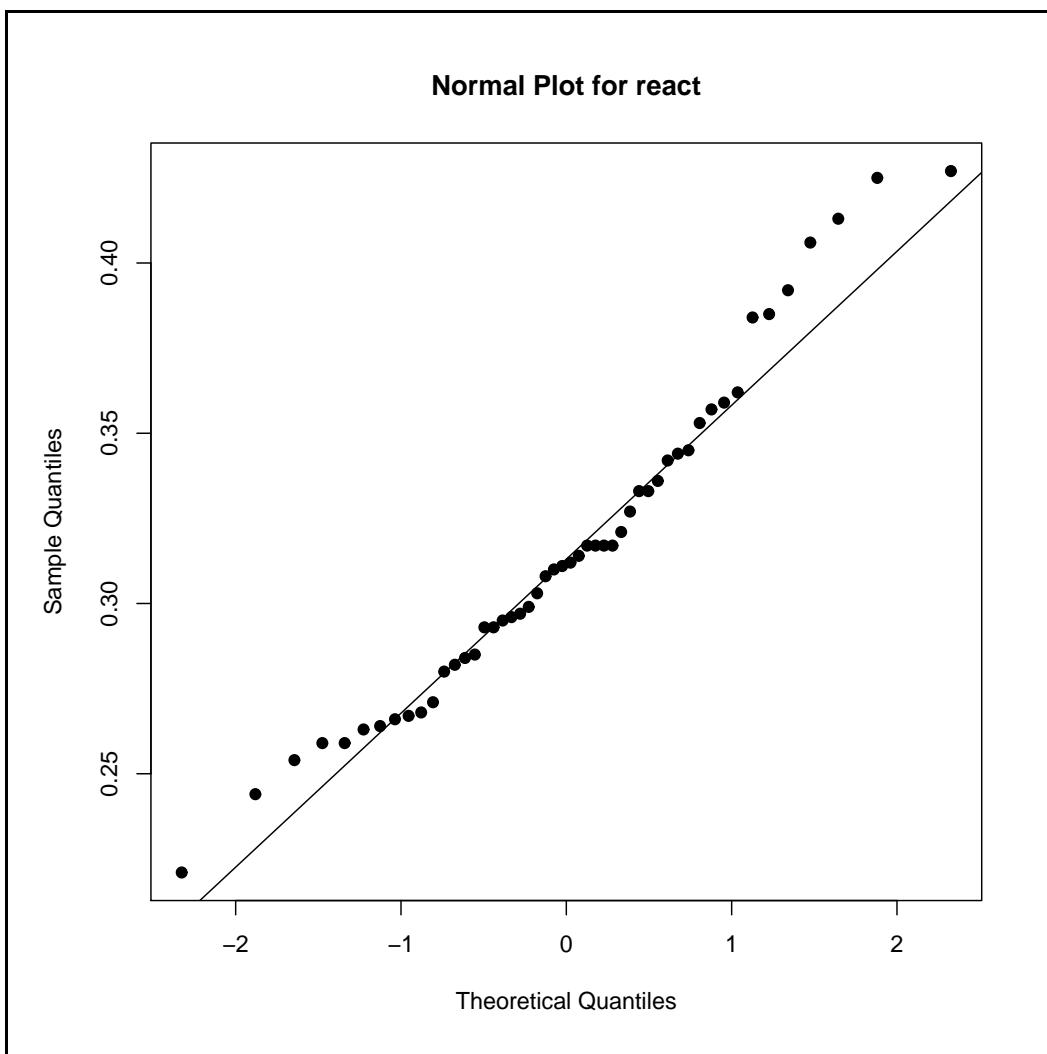


- závislost spojitéch veličin (bodový diagram)

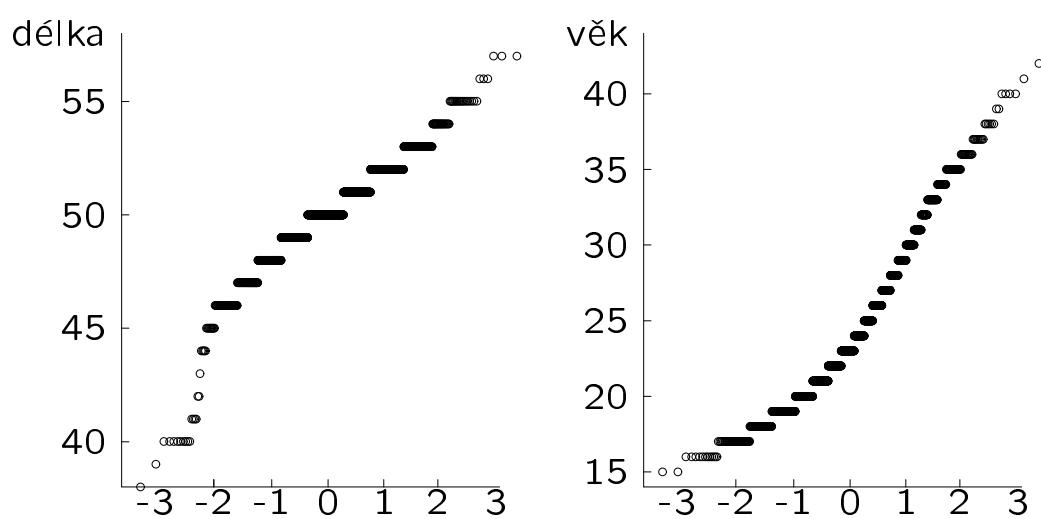
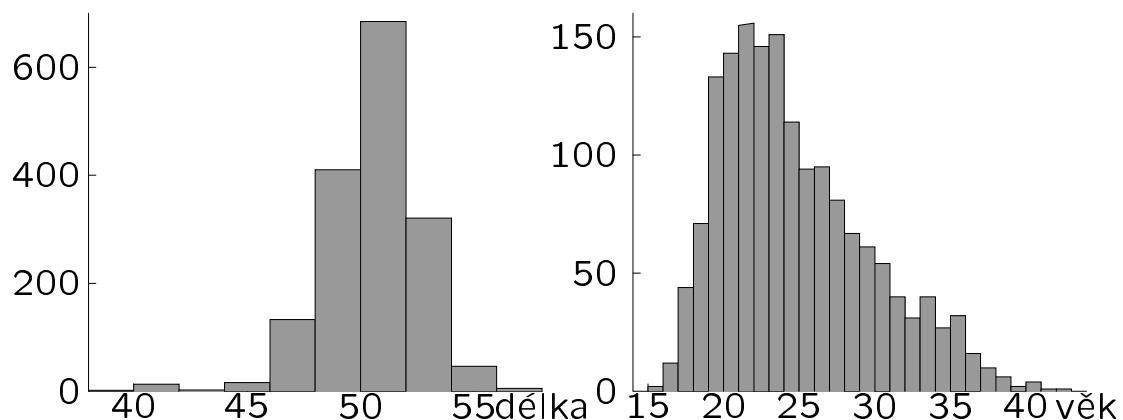
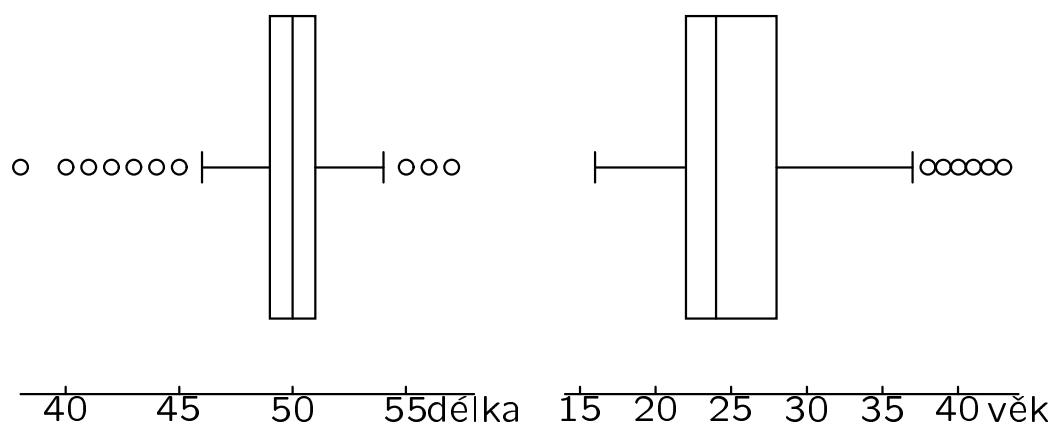


## další grafická znázornění

- normální diagram
  - k ověřování předpokladu **normálního** rozdělení (častý předpoklad)
  - srovnání bodů s přímkou



$$g_1 = 0,521, \quad g_2 = -0,321$$



$$g_1 = -0,893, g_2 = 3,511$$

$$g_1 = 0,760, g_2 = 0,013$$

## Náhodné jevy

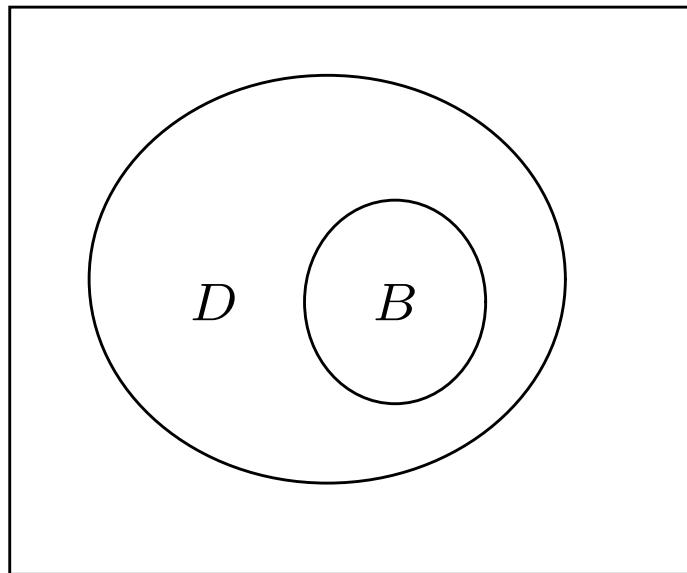
- **náhodný pokus** výsledek nejistý, při opakování stabilita frekvence možných výsledků
- **náhodný jev** tvrzení o výsledku náhodného pokusu, podmnožiny množiny  $\Omega$
- **jistý jev**  $\Omega$  nastává vždy
- **nemožný jev**  $\emptyset$  nenastává nikdy
- **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- **jev opačný**:  $\overline{D} \Leftrightarrow$  neplatí  $D$
- **průnik jevů**  $B \cap D$  nastaly oba jevy
- **sjednocení jevů**  $D \cup B$  nastal aspoň jeden
- **neslučitelné jevy**  $B \cap D = \emptyset$

## Pravděpodobnost $P(B)$

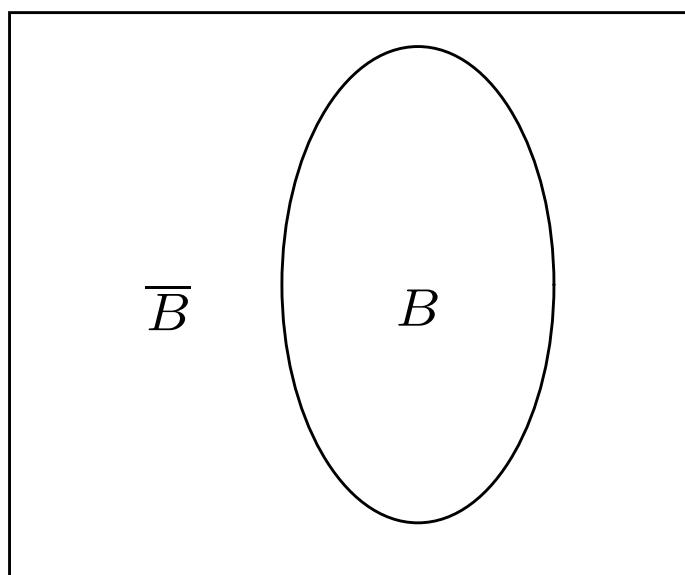
- objektivní číselné vyjádření „naděje“, že nastane  $B$
- modelový protějšek relativní četnosti
- vlastnosti psti
  - $0 \leq P(B) \leq 1$
  - $P(\Omega) = 1, P(\emptyset) = 0$
  - $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$
  - $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - $B \subset D \Rightarrow P(B) \leq P(D)$
  - $P(\overline{B}) = 1 - P(B)$
- **klasická definice psti:**  $m$  stejně pravděpodobných elementárních jevů,  $m_B$  příznivých  $B$

$$P(B) = \frac{m_B}{m}$$

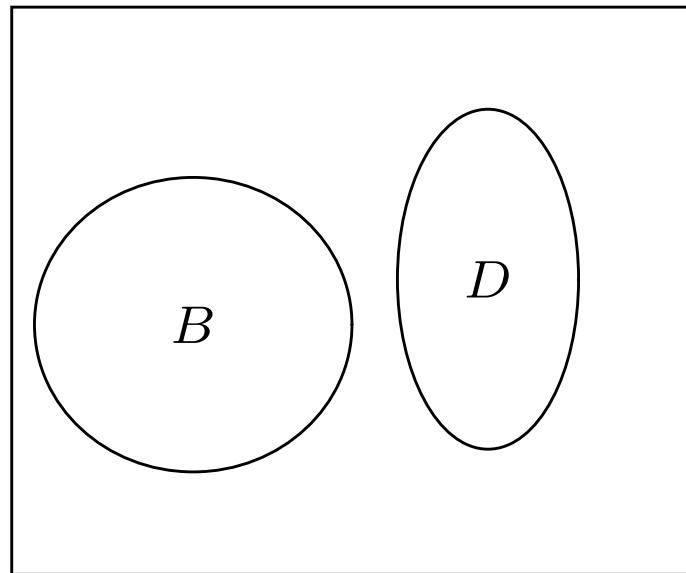
$$B \subset D \Rightarrow \mathsf{P}(B) \leq \mathsf{P}(D)$$



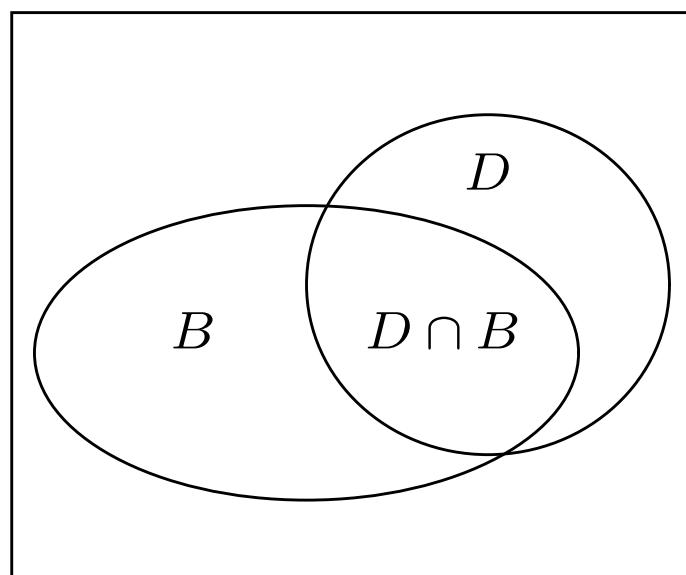
$$\mathsf{P}(\overline{B}) = 1 - \mathsf{P}(B)$$



$$B \cap D = \emptyset \Rightarrow \mathsf{P}(B \cup D) = \mathsf{P}(B) + \mathsf{P}(D)$$



$$\mathsf{P}(B \cup D) = \mathsf{P}(B) + \mathsf{P}(D) - \mathsf{P}(B \cap D)$$



příklad **rodina**: tři sourozenci, celkem 8 elementárních jevů  $\omega_1, \dots, \omega_8$

$\omega_i$	$D$	$B$	$B \cap D$	$B \cup D$	$C$
$(m, m, m)$					+
$(f, m, m)$	+	+	+	+	+
$(m, f, m)$		+		+	+
$(f, f, m)$	+			+	+
$(f, f, f)$	+			+	
$(m, f, f)$					
$(f, m, f)$	+			+	
$(m, m, f)$		+		+	

$D$  nejmladší je dívka,  $P(D) = 4/8 = 1/2$

$B$  v rodině je jediná dívka,  $P(B) = 3/8$

$B \cap D$  jediná dívka je nejmladší,  $P(B \cap D) = 1/8$

$$P(B \cup D) = P(B) + P(D) - P(B \cap D) = \frac{3}{8} + \frac{4}{8} - \frac{1}{8} = \frac{6}{8}$$

$C$  nejstarší je hoch,  $P(C) = 4/8 = 1/2$

Když víme, že nejstarší je hoch ( $C$ ), jaká je pak pst, že nejmladší je dívka ( $D$ )?

$2/4 = 1/2$

**stejně**, jako když jsme nic nevěděli  
pst jevu  $D$  **nezávisí** na tom, zda platí  $C$

**nezávislost:**  $pst$  jevu  $D$  nezávisí na tom, zda  $B$  nastal či nenastal:  $D, B$  **nezávislé jevy podmíněná  $pst$**  ( $pst$   $D$  za podmínky  $B$ )

$$\boxed{P(D|B) = \frac{P(D \cap B)}{P(B)} = \frac{m_{D \cap B}}{m_B} = \frac{m_{D \cap B}/m}{m_B/m}}$$

**nezávislost**  $D, B$

$$P(D \cap B) = P(D)P(B)$$

**příklad rodina:**

$$P(B \cap D) = \frac{1}{8} \neq \frac{3}{8} \cdot \frac{4}{8} = P(B)P(D) \Rightarrow B, D$$
 závislé

$$P(B|D) = \frac{P(B \cap D)}{P(D)} = \frac{1/8}{4/8} = \frac{1}{4}$$

$$P(B|\bar{D}) = \frac{P(B \cap \bar{D})}{P(\bar{D})} = \frac{2/8}{4/8} = \frac{1}{2}$$

$$P(B) = \frac{3}{8}$$

## **HWE** (zákon Hardyův-Weinbergův)

- diploidní populace
- na daném lokusu dvě alely:  $A, a$
- prst alely  $A$  v populaci  $p$
- prst alely  $a$  v populaci  $q = 1 - p$
- nezávislé sdružování alel znamená

$$P(AA) = P(A)P(A) = p^2$$

$$P(aa) = P(a)P(a) = q^2$$

$$P(Aa) = P(A)P(a) + P(a)P(A) = 2pq$$

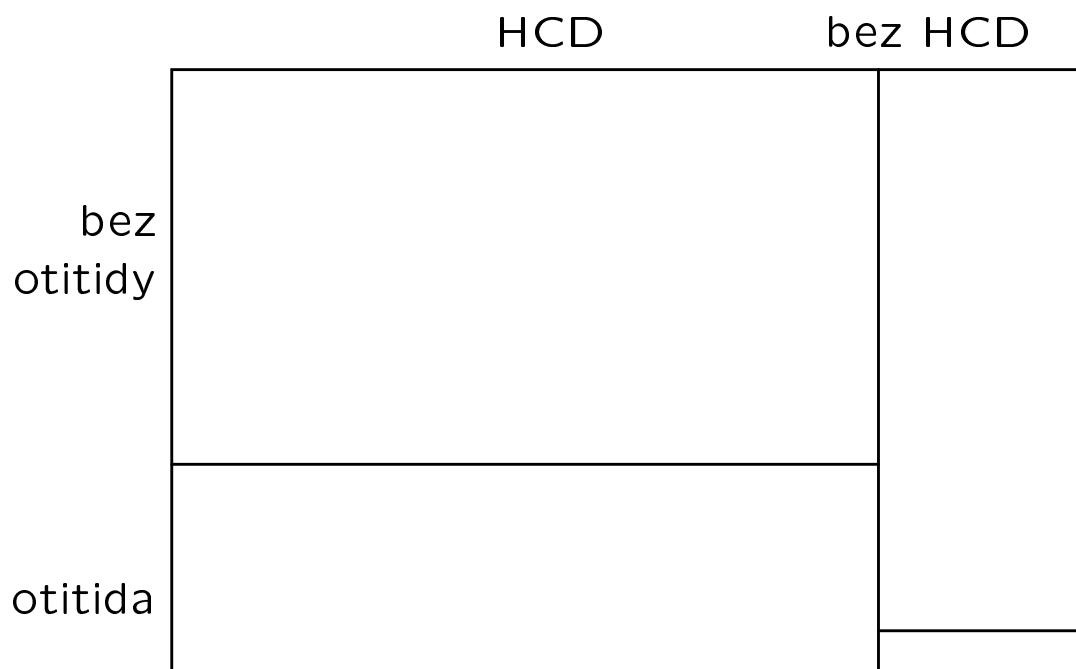
## děti (otitidy a záněty HCD)

	HCD	bez HCD	celkem
bez otitidy	5168	2088	7256
otitida	2747	163	2910
celkem	7915	2251	10166

	HCD	bez HCD	celkem
bez otitidy	0,508	0,205	0,714
otitida	0,270	0,016	0,286
celkem	0,779	0,221	1,000

podmíněno HCD

	HCD	bez HCD	celkem
bez otitidy	0,653	0,928	0,714
otitida	0,347	0,072	0,286
celkem	1,000	1,000	1,000



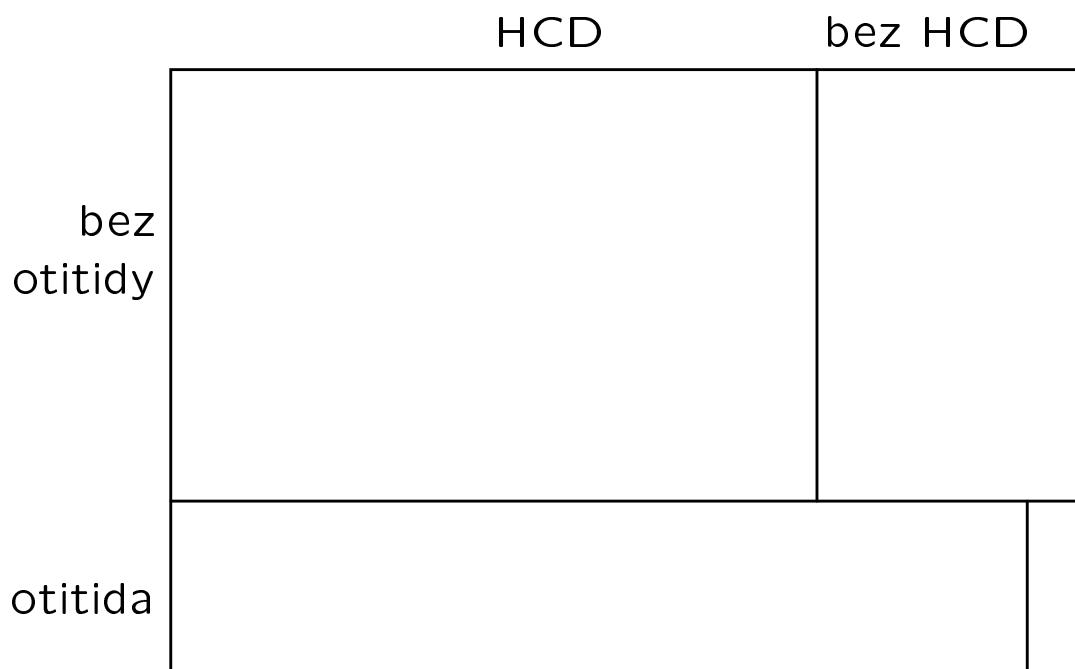
## děti (otitidy a záněty HCD)

	HCD	bez HCD	celkem
bez otitidy	5168	2088	7256
otitida	2747	163	2910
celkem	7915	2251	10166

	HCD	bez HCD	celkem
bez otitidy	0,508	0,205	0,714
otitida	0,270	0,016	0,286
celkem	0,779	0,221	1,000

podmíněno otitudou

	HCD	bez HCD	celkem
bez otitidy	0,712	0,288	1,000
otitida	0,944	0,056	1,000
celkem	0,779	0,221	1,000



předpoklad:

- $H_1, \dots, H_k$  neslučitelné
- sjednocení  $H_1, \dots, H_k$  – jev jistý

vzorec **pro úplnou pst**

$$\mathsf{P}(C) = \sum_{j=1}^k \mathsf{P}(C|H_j) \mathsf{P}(H_j)$$

**Bayesův vzorec**

$$\mathsf{P}(H_i|C) = \frac{\mathsf{P}(C|H_i) \mathsf{P}(H_i)}{\mathsf{P}(C)}$$

$$\mathsf{P}(H_i|C) = \frac{\mathsf{P}(C|H_i) \mathsf{P}(H_i)}{\sum_{j=1}^k \mathsf{P}(C|H_j) \mathsf{P}(H_j)}$$

$H_1, \dots, H_k$  – hypotézy

$\mathsf{P}(H_1), \dots, \mathsf{P}(H_k)$  – apriorní psti

$\mathsf{P}(H_1|C), \dots, \mathsf{P}(H_k|C)$  – aposteriorní psti

příklad **děti**  $C$  – otitida  
 $H_j$  – výskyt zánětu HCD

$H_j$	$P(H_j)$	$P(C H_j)$	součin
bez HCD	0,221	0,072	0,016
jednou HCD	0,223	0,276	0,061
opakovaně HCD	0,555	0,376	0,208
součet	1,000		0,286

$$P(C) = 0,286$$

$$P(H_3|C) = \frac{0,376 \cdot 0,555}{0,286} = 0,728$$

pst opakovaného zánětu HCD u otitid

		$P(H_3 C) = 0,728$
--	--	--------------------

pst opakovaného zánětu HCD u všech

		$P(H_3) = 0,555$
--	--	------------------

pst opakovaného zánětu HCD u NEotitid

		$P(H_3 \bar{C}) = 0,485$
--	--	--------------------------

## příklad: senzitivita, specificita testu

- $D, \overline{D}$  – nemocná/zdravá osoba
- $P, \overline{P}$  – pozitivní/negativní výsledek testu
- $P(P|D)$  – **senzitivita** testu (0,98)
- $P(\overline{P}|\overline{D})$  – **specificita** testu (0,99)
- $P(D)$  – **incidence** nemoci (apriorní pst) (0,001)

$$P(D|P) = \frac{P(P|D)P(D)}{P(P|D)P(D) + P(P|\overline{D})P(\overline{D})}$$

$$= \frac{0,98 \cdot 0,001}{0,98 \cdot 0,001 + 0,01 \cdot 0,999}$$
$$= \frac{0,00098}{0,01097} = 0,089$$

$$P(\overline{D}|\overline{P}) = \frac{0,99 \cdot 0,999}{0,99 \cdot 0,999 + 0,02 \cdot 0,001}$$
$$= 0,99998$$

## náhodná veličina

- číselně vyjádřený výsledek náhodného pokusu
- každému elementárnímu jevu přiřadíme reálné číslo
- **diskrétní rozdělení**
  - možné hodnoty  $x^*$
  - pravděpodobnosti  $P(x_j^*)$  (pstní funkce)
- **spojité rozdělení**
  - interval možných hodnot
  - hustota  $f(x)$

## Příklad rodina

### náhodná veličina – počet děvčat

$\omega_i$	$x_i$	$x_i - \mu_X$	$(x_i - \mu_X)^2$	$x_j^*$
$(m, m, m)$	0	-1,5	2,25	0
$(m, m, f)$	1	-0,5	0,25	
$(m, f, m)$	1	-0,5	0,25	1
$(f, m, m)$	1	-0,5	0,25	
$(f, f, m)$	2	0,5	0,25	
$(f, m, f)$	2	0,5	0,25	2
$(m, f, f)$	2	0,5	0,25	
$(f, f, f)$	3	1,5	2,25	3
součet	12	0,0	6,00	

$j$	$x_j^*$	$m_j$	$P(X = x_j^*)$
1	0	1	1/8
2	1	3	3/8
3	2	3	3/8
4	3	1	1/8
součet		8	8/8

## distribuční funkce

$$F_X(x) = \mathbf{P}(X \leq x)$$

- diskrétní rozdělení  $F(x) = \sum_{t \leq x} \mathbf{P}(X = t)$
- spojité rozdělení  $F(x) = \int_{-\infty}^x f(t) dt$   
zřejmě pak:

$$f(x) = \frac{dF(x)}{dx}$$

- vlastnosti distribuční funkce

$$0 \leq F(x) \leq 1$$

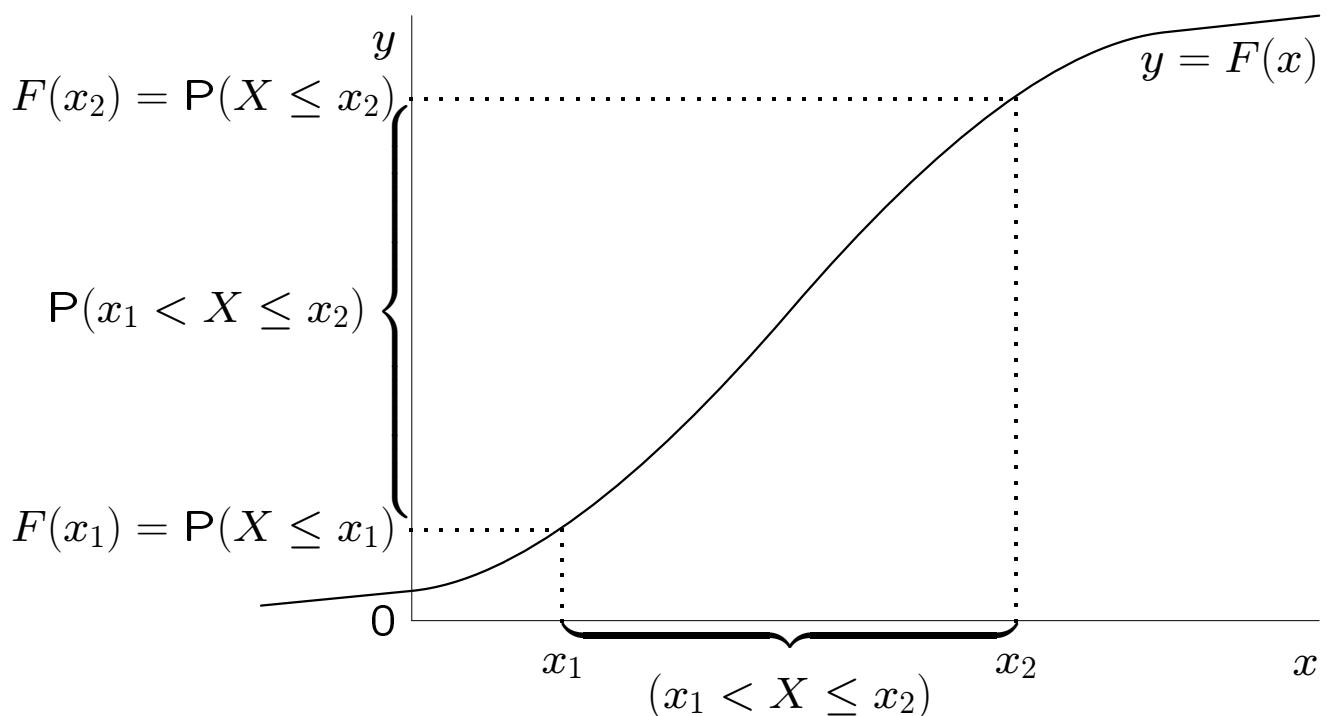
neklesající:  $x_1 < x_2 \Rightarrow F(x_2) \geq F(x_1)$

$$\mathbf{P}(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

$$\mathbf{P}(X \leq x_2) = \mathbf{P}(X \leq x_1) + \mathbf{P}(x_1 < X \leq x_2)$$

$$F(x_2) = F(x_1) + \mathbf{P}(x_1 < X \leq x_2)$$

## geometrický význam distribuční funkce

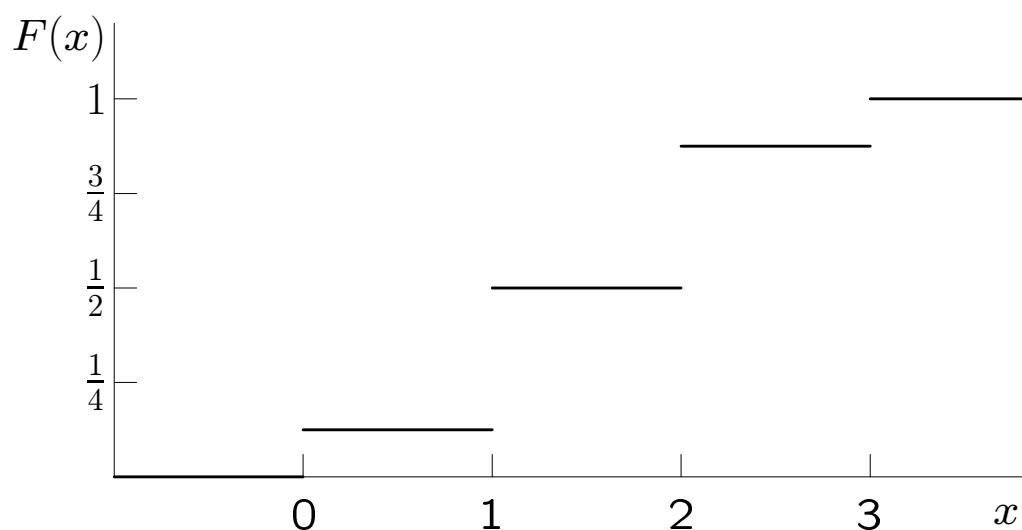


$$\mathsf{P}(X \leq x_2) = \mathsf{P}(X \leq x_1) + \mathsf{P}(x_1 < X \leq x_2)$$

$$F(x_2) = F(x_1) + \mathsf{P}(x_1 < X \leq x_2)$$

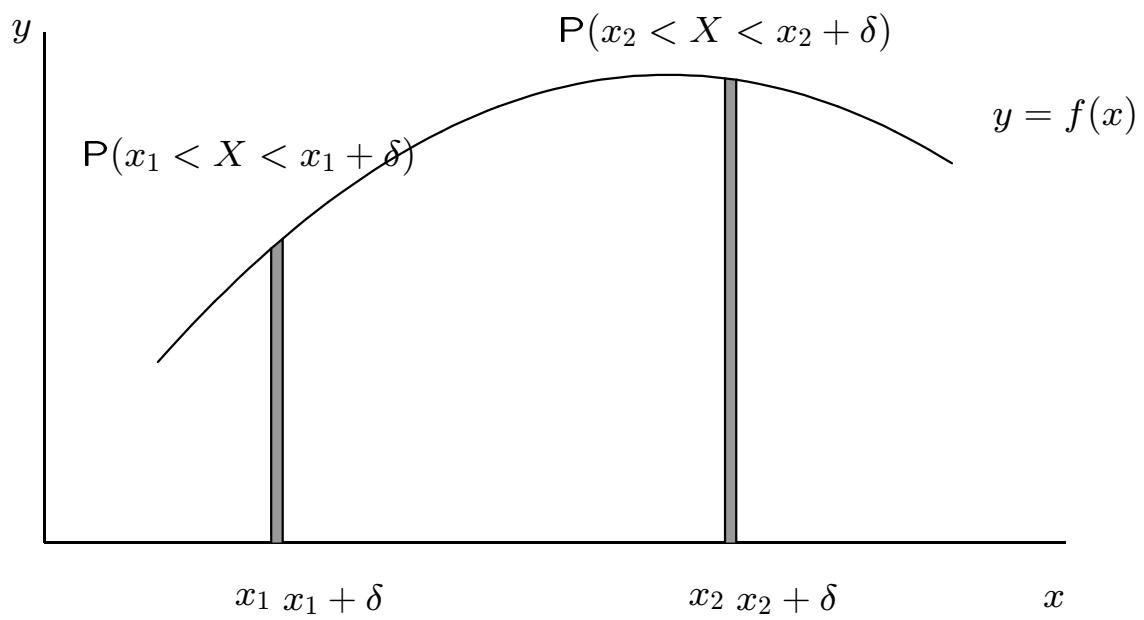
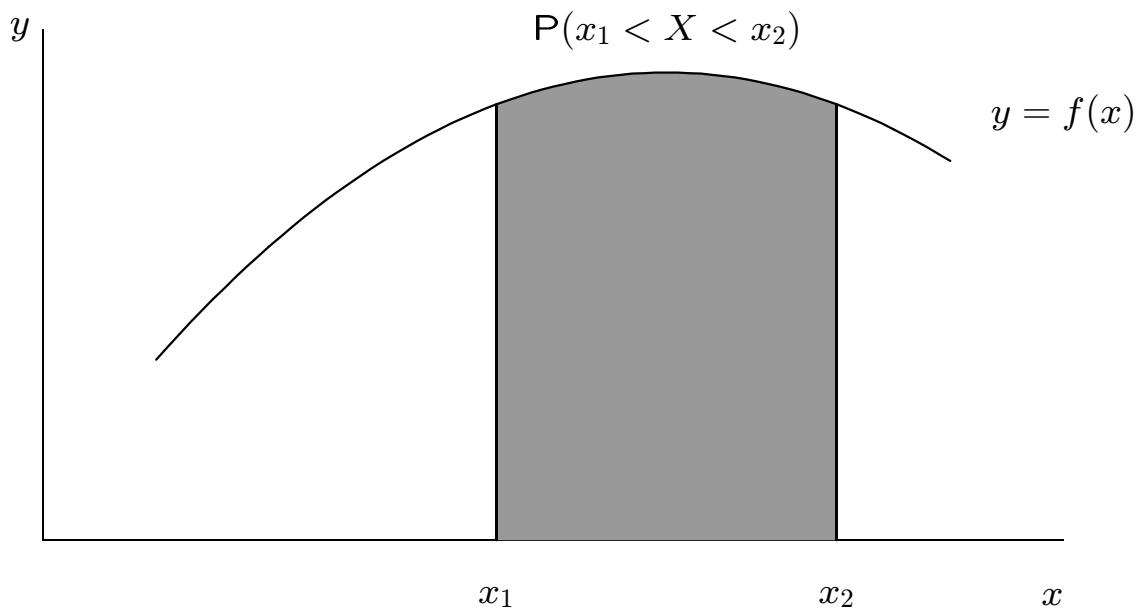
příklad pro **diskrétní** rozdělení  
rozdělení počtu děvčat  $X$

$j$	$x_j^*$	$m_j$	$\mathsf{P}(X = x_j^*)$	$F_X(x_j^*)$
1	0	1	$1/8$	$1/8$
2	1	3	$3/8$	$4/8$
3	2	3	$3/8$	$7/8$
4	3	1	$1/8$	$8/8$
součet		8	$8/8$	

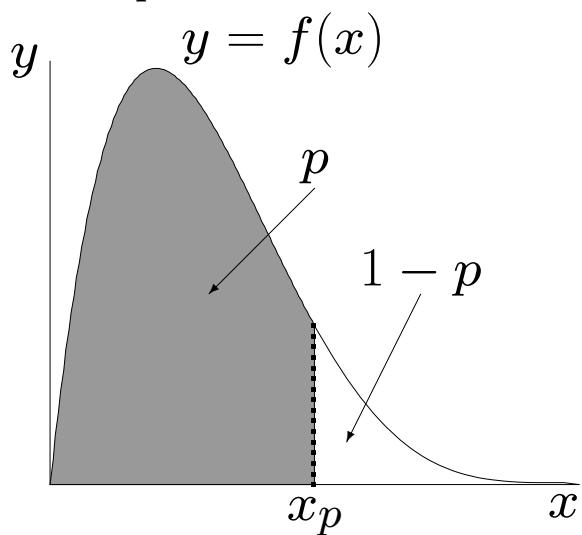
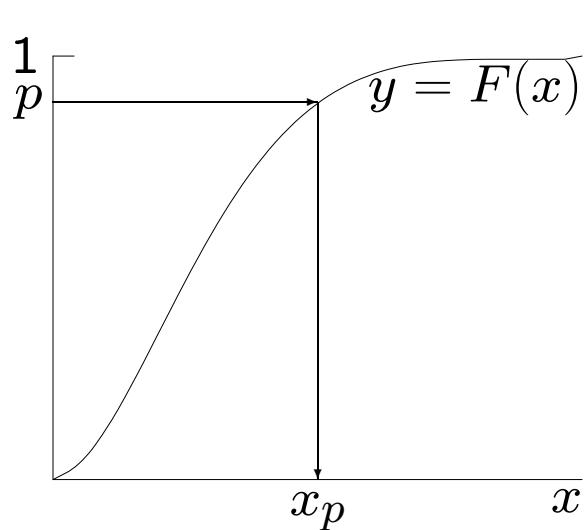


význam hustoty spojitého rozdělení:

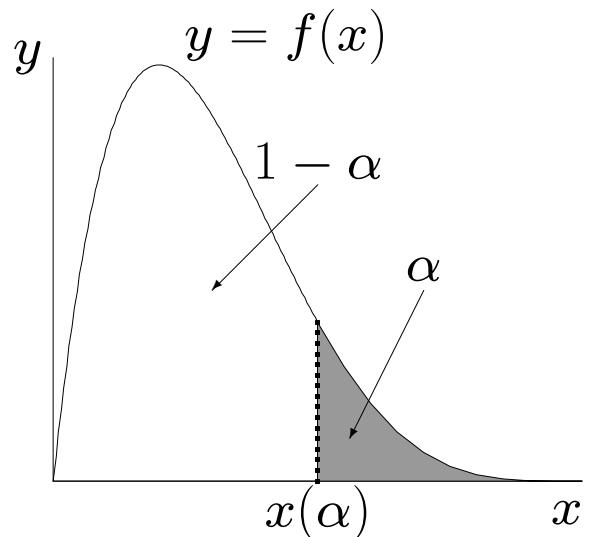
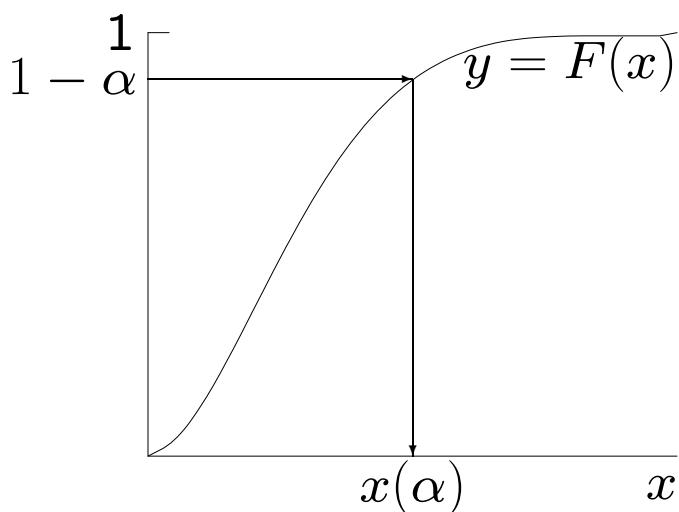
$$f(x) \geq 0$$
$$\int_{-\infty}^{\infty} f(x) dx = 1$$



**$p$ -kvantil  $x_p$**



**kritická hodnota  $x(\alpha)$**



$$\begin{aligned} x_{1-\alpha} + x(\alpha) &= 1 \\ x_p + x(1-p) &= 1 \end{aligned}$$

## střední hodnota $\mu$

- míra polohy, **populační průměr**
- vážený průměr možných hodnot
- diskrétní:  $\mu_X = \sum_j x_j^* \mathbb{P}(X = x_j^*)$
- spojité  $\mu_X = \int_{-\infty}^{\infty} x f(x) dx$
- metoda výpočtu se značí  $\mathbb{E} X$

### příklad **rodina**

$j$	$m_j$	$x_j^*$	$\mathbb{P}(X = x_j^*)$	$x_j^* \cdot \mathbb{P}(X = x_j^*)$
1	1	0	0,125	0,000
2	3	1	0,375	0,375
3	3	2	0,375	0,750
4	1	3	0,125	0,375
součet			1,000	1,500

$$\begin{aligned}\mu_X &= 0 \cdot \frac{1}{8} + 1 \cdot \frac{3}{8} + 2 \cdot \frac{3}{8} + 3 \cdot \frac{1}{8} \\ &= 0 \cdot 0,125 + 1 \cdot 0,375 + 2 \cdot 0,375 + 3 \cdot 0,125 \\ &= 1,5\end{aligned}$$

## **rozptyl $\sigma^2$ (σ směr. odchylka)**

- míra variability, **populační rozptyl**
- velikost kolísání kolem střední hodnoty
- metoda výpočtu se značí  $\text{var } X$
- pomocí střední hodnoty

$$\sigma^2 = \mathbb{E} (X - \mu_X)^2 = \mathbb{E} X^2 - \mu^2$$

- diskrétní      $\sigma^2 = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$

$j$	$x_j^*$	$p_j$	$x_j^* - \mu_X$	$(x_j^* - \mu_X)^2$	$(x_j^* - \mu_X)^2 p_j$
1	0	0,125	-1,5	2,25	0,28150
2	1	0,375	-0,5	0,25	0,09375
3	2	0,375	0,5	0,25	0,09375
4	3	0,125	1,5	2,25	0,28150
$\sum$		1,000	0,0		0,75000

$$\begin{aligned}
 \sigma_X^2 &= (0 - 1,5)^2 \cdot 0,125 + (1 - 1,5)^2 \cdot 0,375 \\
 &\quad + (2 - 1,5)^2 \cdot 0,375 + (3 - 1,5)^2 \cdot 0,125 \\
 &= 0,75 \\
 \sigma_X &= \sqrt{0,75} = 0,866025
 \end{aligned}$$

## **sdružené rozdělení:**

zajímáme se o **společné** chování dvojice  
(trojice,...) náhodných veličin, tedy chování  
**náhodného vektoru**

### Příklad **rodina**

$X$  počet děvčat v rodině s třemi dětmi

$Y$  počet děvčat mezi dvěma staršími dětmi

$Z$  počet hochů v rodině s třemi dětmi

$\omega_i$	$x_i$	$y_i$	$z_i$
$(m, m, m)$	0	0	3
$(m, m, f)$	1	1	2
$(m, f, m)$	1	1	2
$(f, m, m)$	1	0	2
$(f, f, m)$	2	1	1
$(f, m, f)$	2	1	1
$(m, f, f)$	2	2	1
$(f, f, f)$	3	2	0

rozdělení náhodného vektoru  $(X, Y)$

proč nemá smysl uvažovat **vektor**  $(X, Z)$ ?

**sdružené rozdělení:**

popisuje **společné chování** veličin pomocí jejich **sdruženého** rozdělení:

$$\boxed{\mathsf{P}(X = x_i^*, Y = y_j^*) \text{ resp. } f_{X,Y}(x, y)}$$

**marginální** rozdělení – chování jedné veličiny

$$\boxed{\mathsf{P}(X = x_i^*) = \sum_j \mathsf{P}(X = x_i^*, Y = y_j^*), \forall x_i^*}$$

**kovariance** vyjadřuje závislost náh. veličin:

$$\boxed{\sigma_{X,Y} = \mathsf{E} (X - \mu_X)(Y - \mu_Y)}$$

označení metody výpočtu:  $\text{cov}(X, Y)$

zřejmě platí  $\boxed{\text{cov}(X, X) = \text{var } X}$

**nezávislost** náhodných veličin:

$$\boxed{\mathsf{P}(X = x_i^*, Y = y_j^*) = \mathsf{P}(X = x_i^*)\mathsf{P}(Y = y_j^*), \forall (x_i^*, y_j^*)}$$

$X, Y$  – nezávislé  $\Rightarrow \boxed{\sigma_{X,Y} = 0}$

(nikoliv obráceně)

## Příklad **rodina**

$X$  počet děvčat v rodině s třemi dětmi

$Y$  počet děvčat mezi dvěma staršími dětmi

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	0,125	0	0	0,125
1	0,125	0,250	0	0,375
2	0	0,250	0,125	0,375
3	0	0	0,125	0,125
celkem	0,250	0,500	0,250	1,000

$$\mu_X = 0 \cdot 0,125 + 1 \cdot 0,375 + 2 \cdot 0,375 + 3 \cdot 0,125 = 1,5$$

$$\mu_Y = 0 \cdot 0,250 + 1 \cdot 0,500 + 2 \cdot 0,250 = 1$$

$X, Y$  – závislé, např.  $0,25 \cdot 0,125 \neq 0,125$

výpočet kovariance  $\sigma_{XY} = \text{cov}(X, Y)$ :

$$\begin{aligned} \sigma_{XY} &= (0 - 1,5) \cdot (0 - 1) \cdot 0,125 \\ &\quad + (1 - 1,5) \cdot (0 - 1) \cdot 0,125 \\ &\quad + (1 - 1,5) \cdot (1 - 1) \cdot 0,250 \\ &\quad + (2 - 1,5) \cdot (1 - 1) \cdot 0,250 \\ &\quad + (2 - 1,5) \cdot (2 - 1) \cdot 0,125 \\ &\quad + (3 - 1,5) \cdot (2 - 1) \cdot 0,125 \\ &= 0,5 \end{aligned}$$

**střední hodnota**  $X$  (mean value)

$$\begin{aligned}\mu_X &= \mathbb{E} X \\ &= \sum_j x_j^* \mathsf{P}(X = x_j^*) \\ &= \int_{-\infty}^{\infty} x f_X(x) dx\end{aligned}$$

střední hodnota  $Y = g(X)$

$$\begin{aligned}\mu_Y &= \mathbb{E} g(X) \\ &= \sum_j g(x_j^*) \mathsf{P}(X = x_j^*) \\ &= \int_{-\infty}^{\infty} g(x) f_X(x) dx\end{aligned}$$

**rozptyl**  $X$  (variance, (standard deviation) $^2$ )

$$\begin{aligned}\sigma_X^2 &= \text{var } X = \mathbb{E} (X - \mu_X)^2 \\ &= \sum_j (x_j^* - \mu_X)^2 \mathsf{P}(X = x_j^*) \\ &= \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx\end{aligned}$$

**kovariance**  $X$  a  $Y$  (covariance)

$$\begin{aligned}\sigma_{X,Y} &= \text{cov}(X, Y) = \mathbb{E} (X - \mu_X)(Y - \mu_Y) \\ &= \sum_{i,j} (x_i^* - \mu_X)(y_j^* - \mu_Y) \mathsf{P}(X = x_i^*, Y = y_j^*) \\ &= \int_{-\infty}^{\infty} (x - \mu_X)(y - \mu_Y) f_{X,Y}(x, y) dx dy\end{aligned}$$

vlastnosti populačního průměru a rozptylu

$$\begin{aligned}\mu_{\alpha+\beta X} &= \alpha + \beta \mu_X, \\ \sigma_{\alpha+\beta X}^2 &= \beta^2 \sigma_X^2, \\ \sigma_{\alpha+\beta X} &= |\beta| \sigma_X, \\ \mu_{X+Y} &= \mu_X + \mu_Y, \\ \sigma_{X+Y}^2 &= \sigma_X^2 + \sigma_Y^2 + 2\sigma_{XY}.\end{aligned}$$

ukázka důkazu:

$$\begin{aligned}\mu_{\alpha+\beta X} &= \mathbb{E}(\alpha + \beta X) \\ &= \sum_i (\alpha + \beta x_i^*) \mathbb{P}(X = x_i^*) \\ &= \sum_i \alpha \mathbb{P}(X = x_i^*) + \sum_i \beta x_i^* \mathbb{P}(X = x_i^*) \\ &= \alpha \sum_i \mathbb{P}(X = x_i^*) + \beta \sum_i x_i^* \mathbb{P}(X = x_i^*) \\ &= \alpha + \beta \mathbb{E} X = \alpha + \beta \mu_X\end{aligned}$$

jsou-li  $X, Y$  **nezávislé**, pak

$$\begin{aligned}\sigma_{XY} &= 0 \\ \sigma_{X+Y}^2 &= \sigma_X^2 + \sigma_Y^2\end{aligned}$$

**normování** náhodné veličiny  $X$

$$\begin{aligned}Z &= \frac{X - \mu_X}{\sigma_X} && \text{bezrozměrné!} \\ \Rightarrow \quad \mu_Z &= 0 \quad \sigma_Z &= 1\end{aligned}$$

vlastnosti nezávislé na  $\mu_X, \sigma_X^2$ :  
 (populační) **korelační koeficient**  
 (correlation coefficient)

$$\begin{aligned}\rho_{XY} &= \text{cov} \left( \frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y} \right) \\ &= \frac{\sigma_{XY}}{\sigma_X \sigma_Y}\end{aligned}$$

(populační) **šikmost** náhodné veličiny  $X$   
 (skewness)

$$\begin{aligned}\gamma_1 &= \mathbb{E} \left( \frac{X - \mu_X}{\sigma_X} \right)^3 \\ &= \frac{\mathbb{E} (X - \mu_X)^3}{\sigma_X^3}\end{aligned}$$

(populační) **špičatost** náhodné veličiny  $X$   
 (kurtosis, někdy se neodečítá 3)

$$\begin{aligned}\gamma_2 &= \mathbb{E} \left( \frac{X - \mu_X}{\sigma_X} \right)^4 - 3 \\ &= \frac{\mathbb{E} (X - \mu_X)^4}{\sigma_X^4} - 3\end{aligned}$$

## Důležitá diskrétní rozdělení

### alternativní (nula-jedničkové) rozdělení

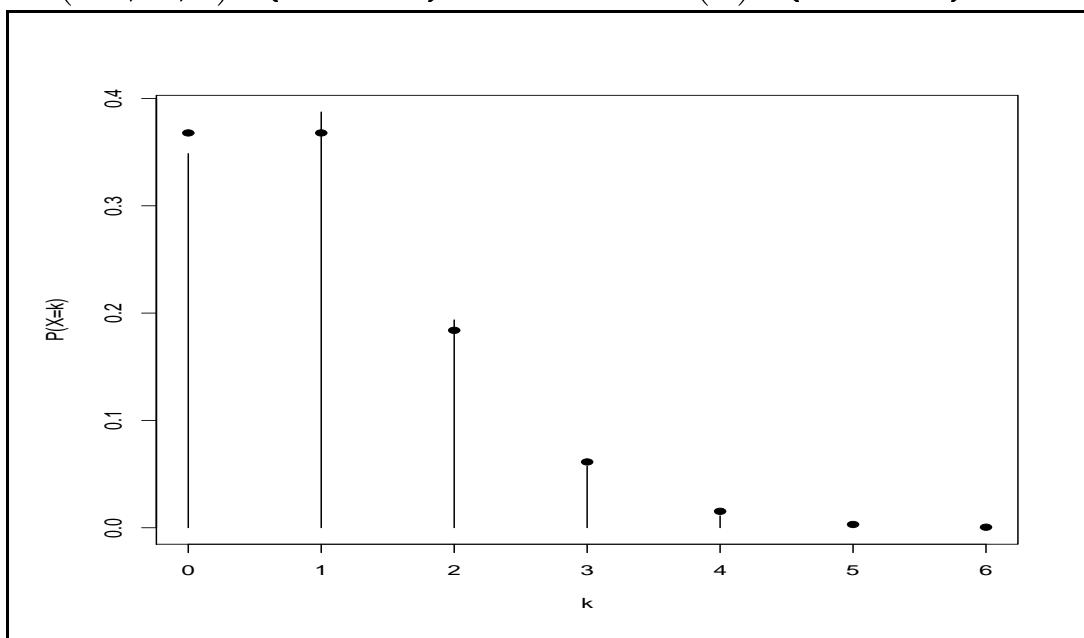
- *zdar* nebo *nezdar*
- $P(X = 1) = \pi, P(X = 0) = 1 - \pi, (0 < \pi < 1)$
- $E X = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- $\text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

### binomické rozdělení $Y \sim \text{bi}(n, \pi)$

- $n$  **nezávislých** pokusů
- $P(\text{zdar}) = \pi, P(\text{nezdar}) = 1 - \pi, (0 < \pi < 1)$
- $Y$  je počet zdarů v těchto pokusech
- $P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$
- $Y = \sum_{i=1}^n X_i, X_i - \text{zda zdar v } i\text{-tém pokusu}$
- $E Y = E (\sum_{i=1}^n X_i) = \sum_{i=1}^n E X_i = n\pi$
- $\text{var } Y = \text{var} (\sum_{i=1}^n X_i) = \sum_{i=1}^n \text{var } X_i$   
 $= n\pi(1 - \pi) \quad (\text{nezávislost } X_i!)$

## Poissonovo rozdělení $X \sim \text{Po}(\lambda)$

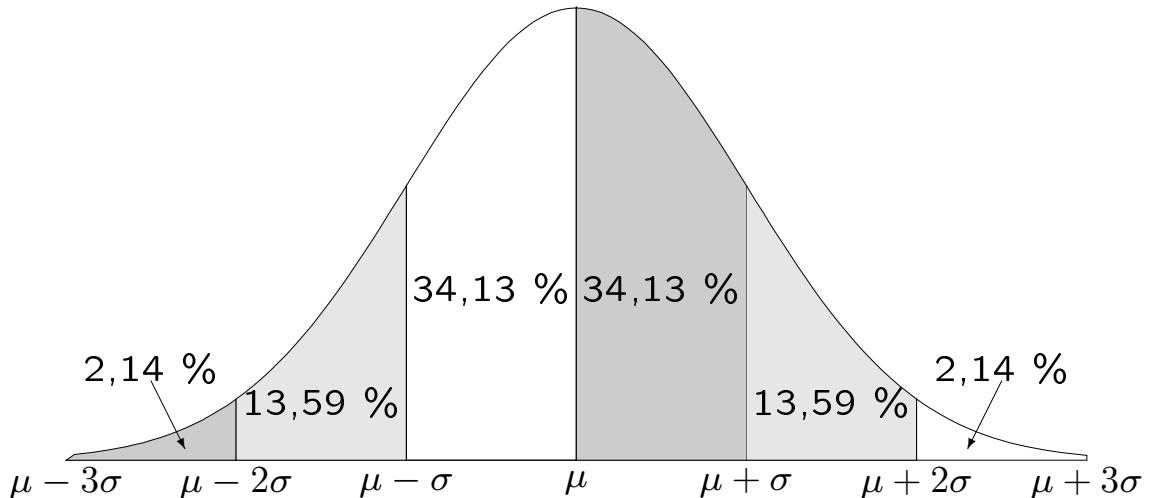
- zákon vzácných (řídkých) jevů
- kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu . . .
- $\mathbb{P}(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$
- $\mathbb{E} X = \lambda, \text{ var } X = \lambda$
- pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  approximovat pomocí rozdělení  $\text{Po}(n\pi)$
- $\text{bi}(10, 0,1)$  (hůlky) vers.  $\text{Po}(1)$  (tečky)



**normální (Gaussovo) rozdělení**  $X \sim N(\mu, \sigma^2)$

- $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ ,

- $E X = \mu, \text{ var } X = \sigma^2$



- $N(0, 1)$ :  $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, \Phi(x) = \int_{-\infty}^x \varphi(t) dt$

- $X \sim N(\mu, \sigma^2)$ , pak

$$P(a < X < b) = \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right)$$

- $V$  má **logaritmicko-normální** rozdělení:

$$\ln V \sim N(\mu, \sigma^2)$$

- approximace binomického rozdělení  $bi(n, \pi)$  pomocí  $N(n\pi, n\pi(1 - \pi))$  ( $n\pi(1 - \pi) > 9$ )

- kritické hodnoty normálního rozdělení

$$Z \sim N(0, 1) : \quad P(Z > z(\alpha)) = \alpha$$

ze symetrie platí  $P(|Z| > z(\alpha/2)) = \alpha$

- kritické hodnoty Studentova  $t$  rozdělení

$$T \sim t(k) : P(|T| > t_k(\alpha)) = \alpha$$

$\alpha$	0,10	0,05	0,01
$z(\alpha/2)$	1,645	1,960	2,576
$t_{100}(\alpha)$	1,660	1,984	2,626
$t_{20}(\alpha)$	1,725	2,086	2,845
$t_5(\alpha)$	2,015	2,571	4,032

- kritické hodnoty Fisherova  $F$  rozdělení

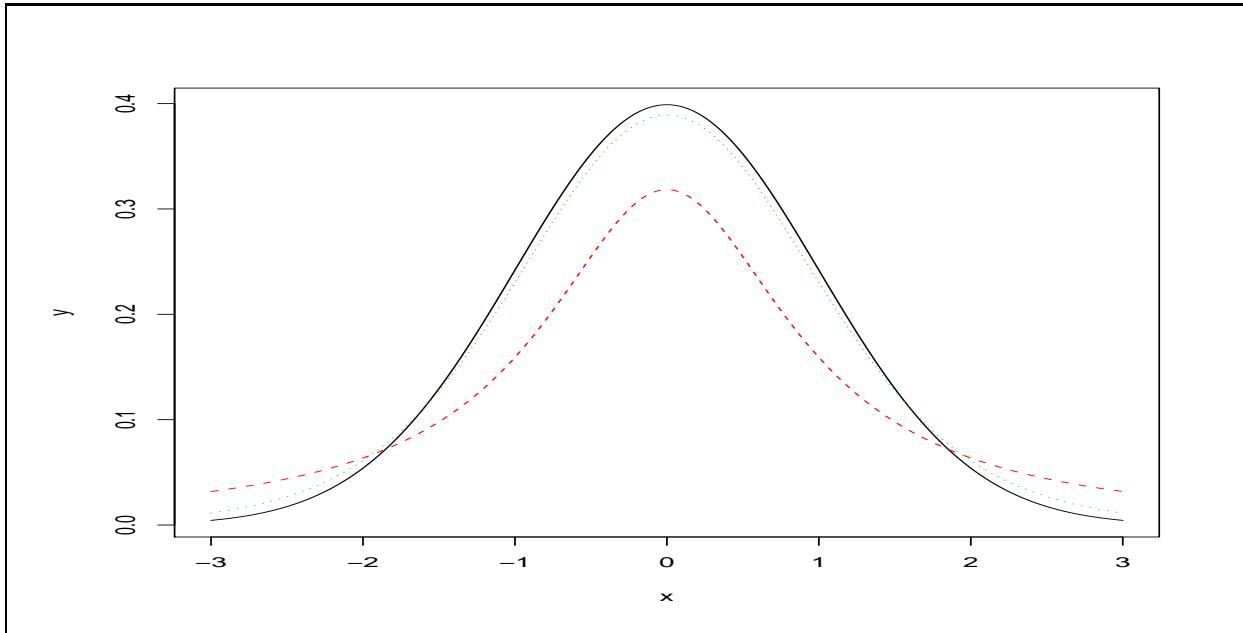
$$F \sim F(k, m) : P(F > F_{k,m}(\alpha)) = \alpha$$

- kritické hodnoty rozdělení chí-kvadrát

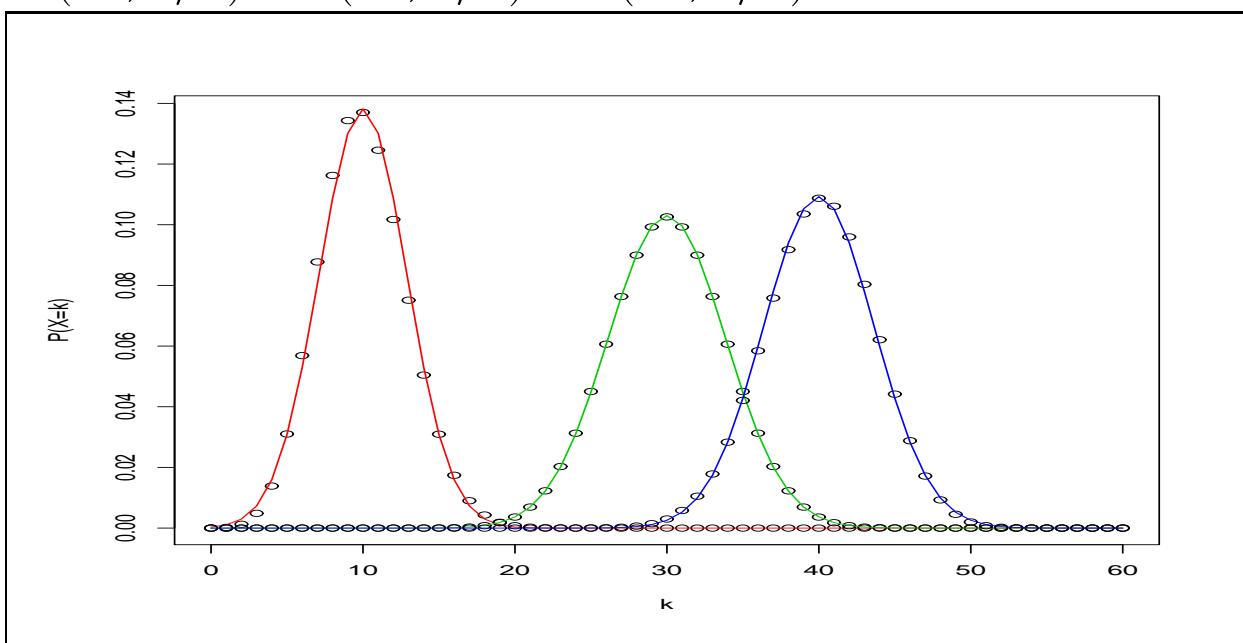
$$X^2 \sim \chi^2(k) : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

$$\chi_1^2(0,05) = 1,960^2 = 3,841$$

srovnání normálního a Studentova rozdělení  
čárkovaně  $t(1)$ , tečkováně  $t(10)$ ,  
plná čára  $N(0, 1)$ )



srovnání binomického a normálního rozdělení  
 $bi(60, 1/6)$ ,  $bi(60, 3/6)$ ,  $bi(60, 4/6)$



# **populace – výběr**

- **populace (základní soubor)**

soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  
⇒ rozdělení náhodné veličiny

- **výběr**

náhodně vybraná část populace, kterou vyšetřujeme, vzorek populace

- **náhodný výběr**

nezávislé náhodné veličiny se stejným rozdělením (naměřené na výběru)

- **parametr**

neznámé číslo popisující nějaký rys populace, charakteristika rozdělení náh. vel.

- **statistika**

funkce náhodného výběru

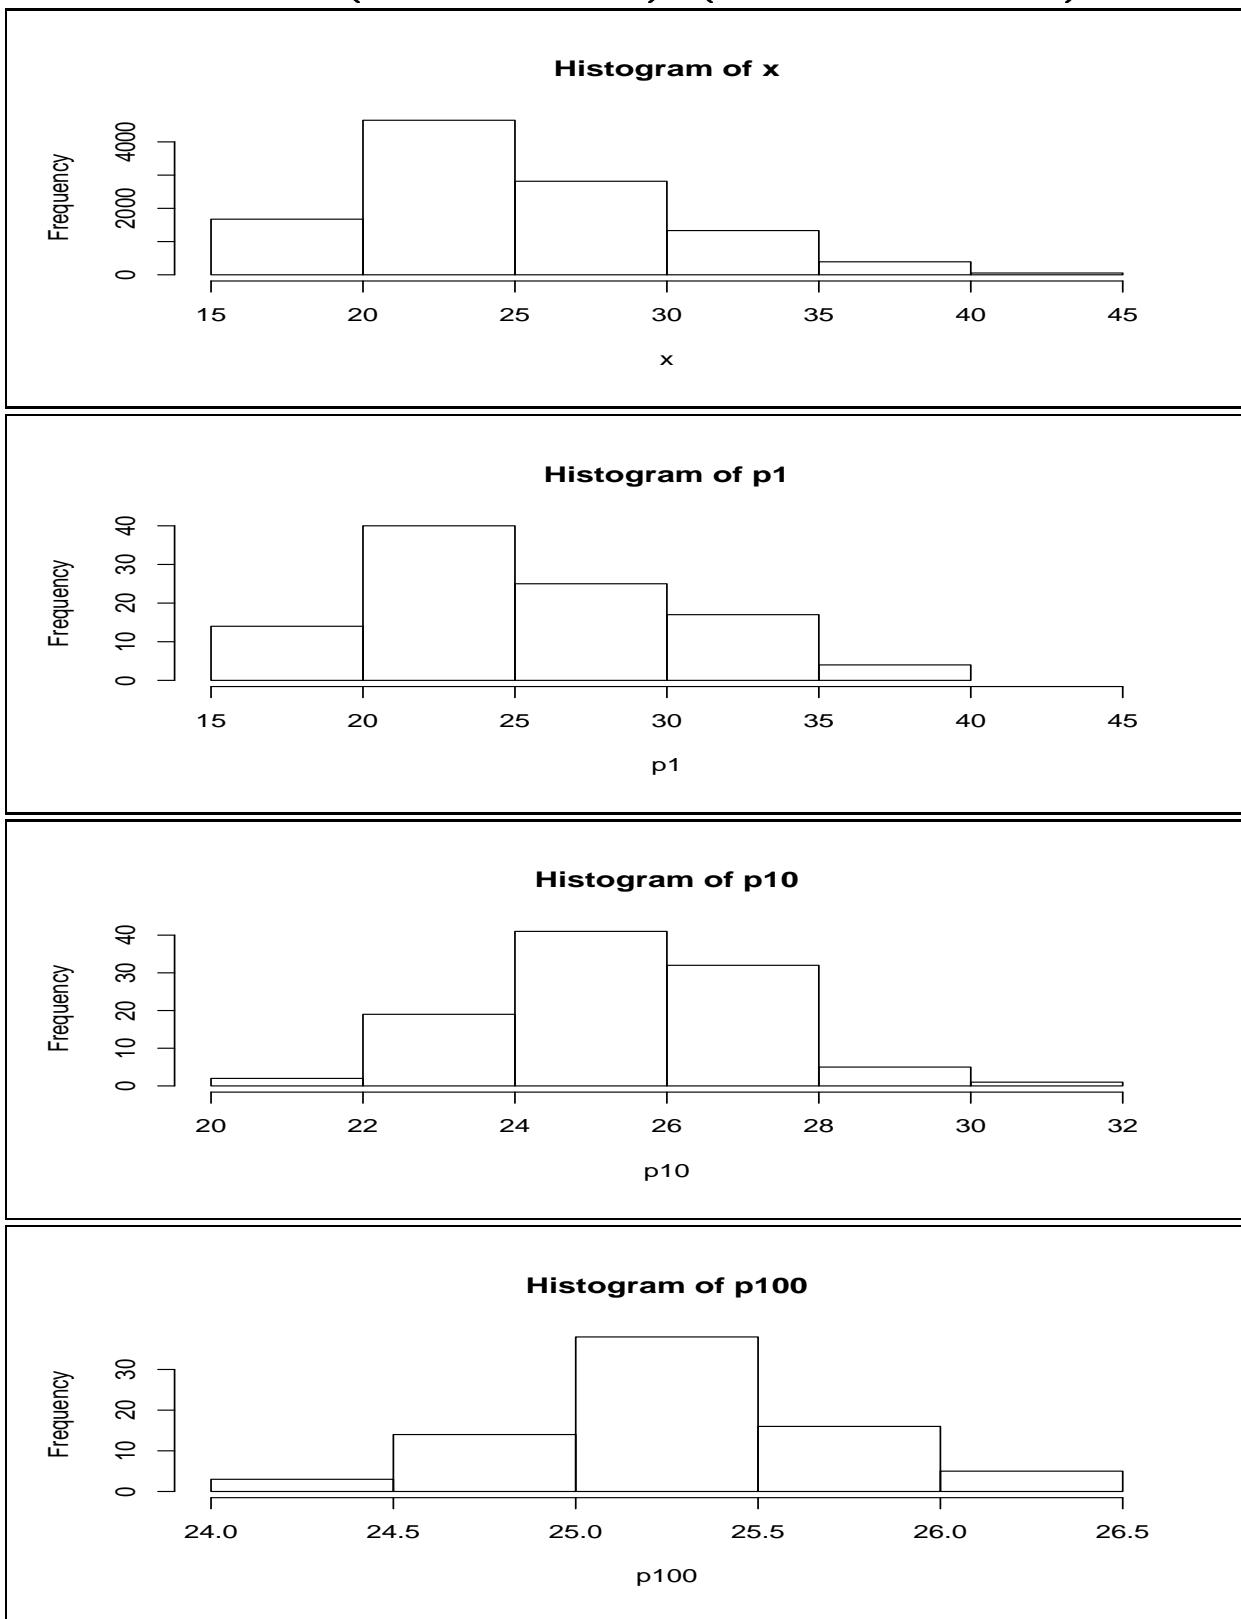
- **odhad**

statistika použitá k odhadu parametru

- $X_1, \dots, X_n$  nezávislé, stejné rozdělení  
 $\mathbb{E} X_i = \mu$  populační průměr  
 $\text{var } X_i = \sigma^2$  populační rozptyl
- $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  výběrový průměr
- $\mathbb{E} \bar{X} = \mu$  výběrový průměr  
je **nestranným** odhadem populačního
- $\text{var } \bar{X} = \frac{\sigma^2}{n}$   
 $= (\text{S.E.}(\bar{X}))^2$   
 $n$ -krát ménší, než u jednoho pozorování!
- u **normálního** rozdělení:  $X_i \sim N(\mu, \sigma^2)$   
 $Z = \frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}} = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$
- **interval spolehlivosti** pro  $\mu$ :  
 $(\bar{X} - \text{S.E.}(\bar{X})z(\alpha/2), \bar{X} + \text{S.E.}(\bar{X})z(\alpha/2))$   
 $\left(\bar{X} - \frac{\sigma}{\sqrt{n}}z(\alpha/2), \bar{X} + \frac{\sigma}{\sqrt{n}}z(\alpha/2)\right)$
- požadujeme int. spolehlivosti šířky  $2c\sigma$ :

$$n \geq \left( \frac{z(\alpha/2)}{c} \right)^2$$

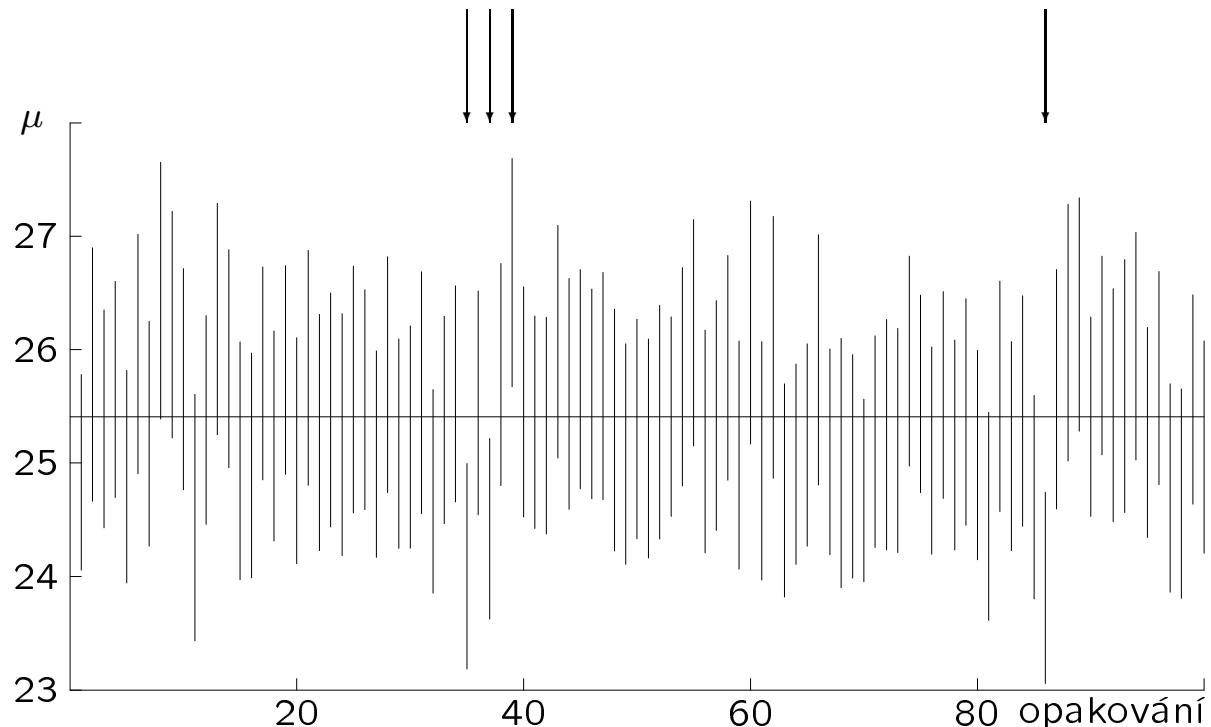
## příklad děti (věk matek) (100 průměrů)



průměrný věk matek v opak. výběrech:

rozsah výběru $n$	průměr průměrů	směr. odch. průměrů	šíkmost průměrů	špičatost průměrů
1	26,42	5,182	0,529	-0,679
10	25,56	1,475	0,140	-0,771
100	25,30	0,529	0,027	-0,303
1000	25,40	0,158	-0,040	-0,284
populace	$\mu = 25,40$	$\sigma = 4,943$	$\gamma_1 = 0,773$	$\gamma_2 = 0,192$

95% intervaly spolehlivosti ( $n = 100$ ):



# statistické rozhodování

- **nulová hypotéza  $H_0$**   
tvrzení o populaci (parametru), o jehož platnosti chceme rozhodnout (zamítnout)
- **alternativní hypotéza  $H_1$  (alternativa)**  
zbývající možnost (k  $H_0$ )  
často „vědecká hypotéza“
- **kritický obor**  
možné výsledky pokusu, kdy  $H_0$  zamítáme
- **obor přijetí**  
možné výsledky pokusu, kdy  $H_0$  nezamítáme
- **chyba prvního druhu**  
rozhodnutí zamítnout  $H_0$ , když platí  $H_0$   
falešně prokázat „vědeckou hypotézu“
- **chyba druhého druhu**  
rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$
- **hladina testu  $\alpha$**  (zpravidla 5 %, 1 %)  
maximální dovolená prst chyby prvního druhu

rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout (reject)	chyba 1. druhu $(\leq \alpha)$	správné rozhodnutí $(1 - \beta)$
$H_0$ nezamítnout (accept)	správné rozhodnutí $(\geq 1 - \alpha)$	chyba 2. druhu $(\beta)$

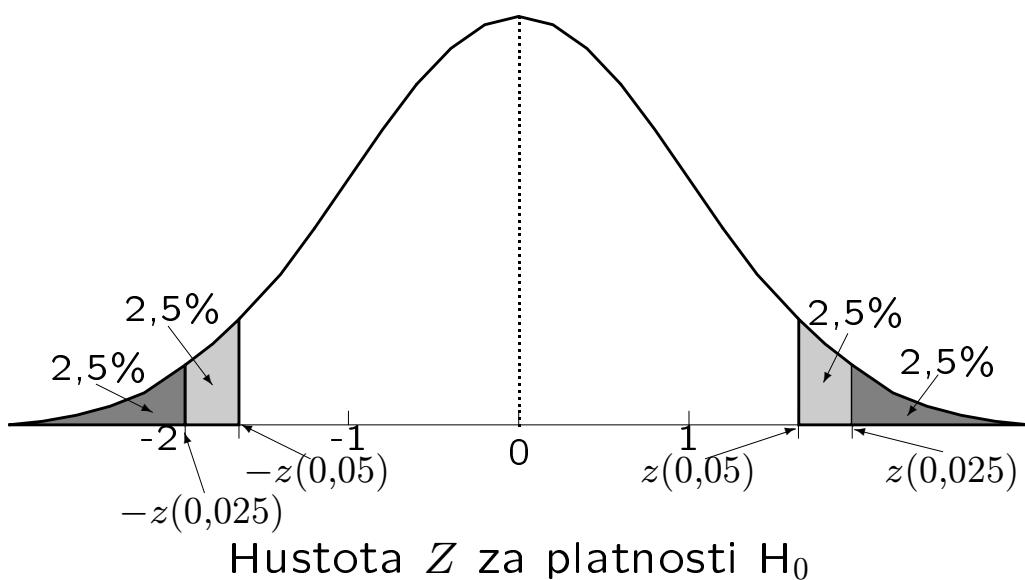
- hladina testu  $\alpha$  se volí před pokusem (aby nezávisela na jeho výsledku)
- **síla testu**  $1 - \beta$   
pravděpodobnost zamítnutí neplatné  $H_0$   
prokážeme platnou „vědeckou hypotézu“
- kritický obor zpravidla popsán pomocí statistiky (např.  $|T| \geq t_{n-1}(\alpha)$ )
- **dosažená hladina testu**  $p$  (**p-hodnota**)  
za platnosti  $H_0$  určená pravděpodobnost, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$  (nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout),  
např.  $p = P(|T| \geq t)$ , kde  $t$  je skutečně realizovaná hodnota statistiky  $T$
- $H_0$  se **zamítá**, když  $p \leq \alpha$

rozhodování o populačním průměru normálního rozdělení se známým rozptylem

- $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**
- $\sigma > 0$  známe
- $H_0 : \mu = \mu_0$  (dané číslo)
- platí-li  $H_0$ , pak

$$Z = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

- $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  
 $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$
- $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$
- $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$



příklad **výšky** desetiletých hochů ([cm])

130	140	136	141	139
133	149	151	139	136
138	142	127	139	147

$$\sigma = 6,4 \text{ (známo z dřívějška)}, \quad \alpha = 0,05$$

$$H_0 : \mu = 136,1 \text{ (před 10 lety)}, \quad H_1 : \mu \neq 136,1$$

$$\bar{x} = \frac{1}{15} (130 + 140 + \dots + 147) = 139,133$$

$$z = \frac{139,133 - 136,1}{6,4} \sqrt{15} = 1,835$$

$$|z| < z(0,05/2) = 1,960$$

$\Rightarrow H_0$  nelze na 5% hladině zamítnout

$$\text{ale } |z| \geq z(0,10/2) = 1,645$$

$\Rightarrow H_0$  se na 10% hladině zamítá

$\implies p$ -hodnota mezi 5 % a 10 %

$$p = P(|Z| \geq 1,835) = 0,067$$

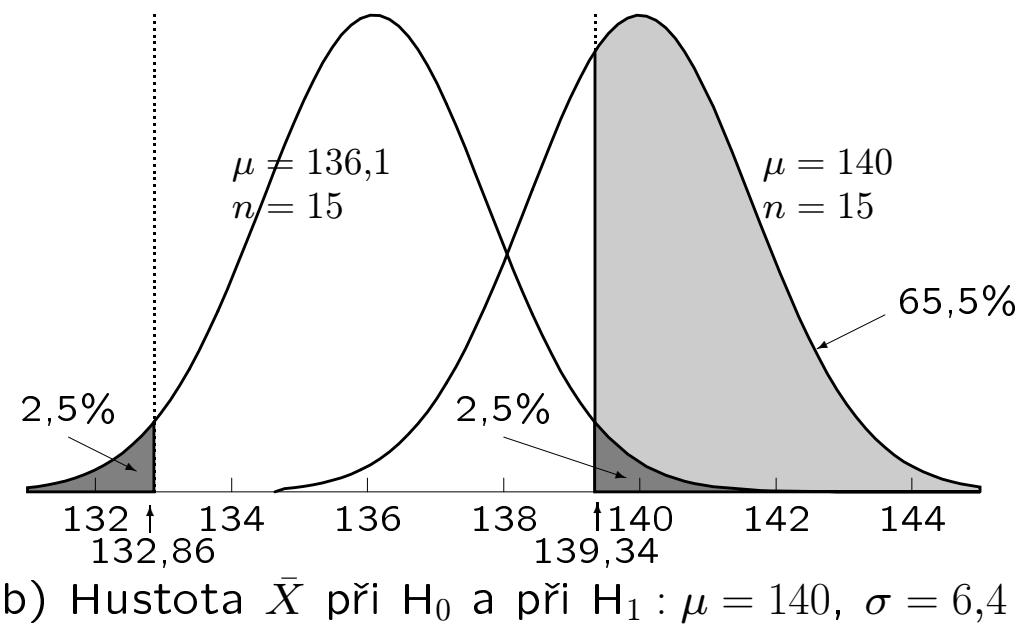
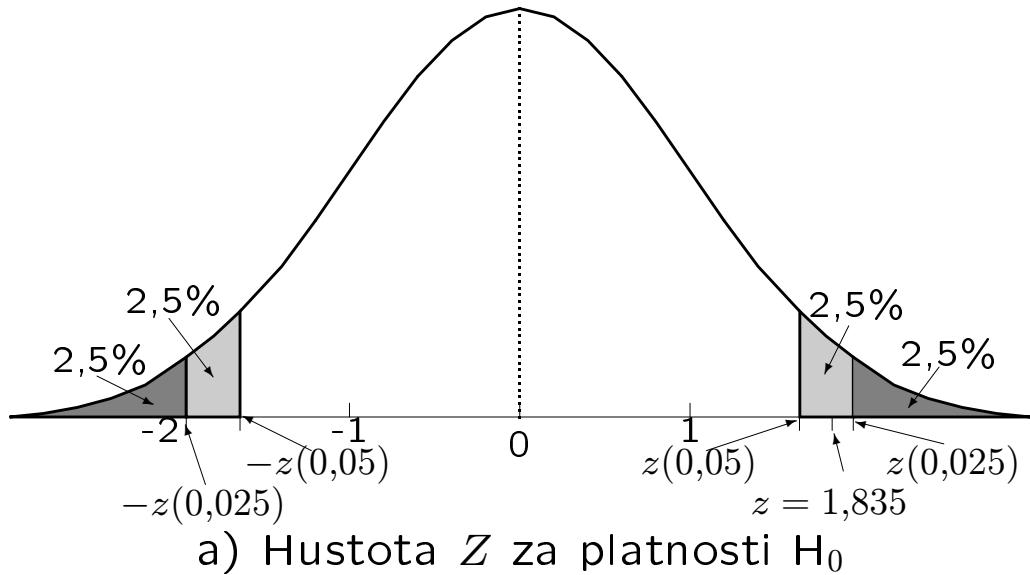
dosažená hladina ( $p$ -hodnota) je 6,7 %

**jednostranná alternativa** (zvoleno předem!):

$$H_1 : \mu > 136,1: z \geq 1,645 \quad \text{na 5 \% zamítnout}$$

$$p = P(Z \geq 1,835) = 0,033 (< 0,05)$$

## výšky desetiletých hochů

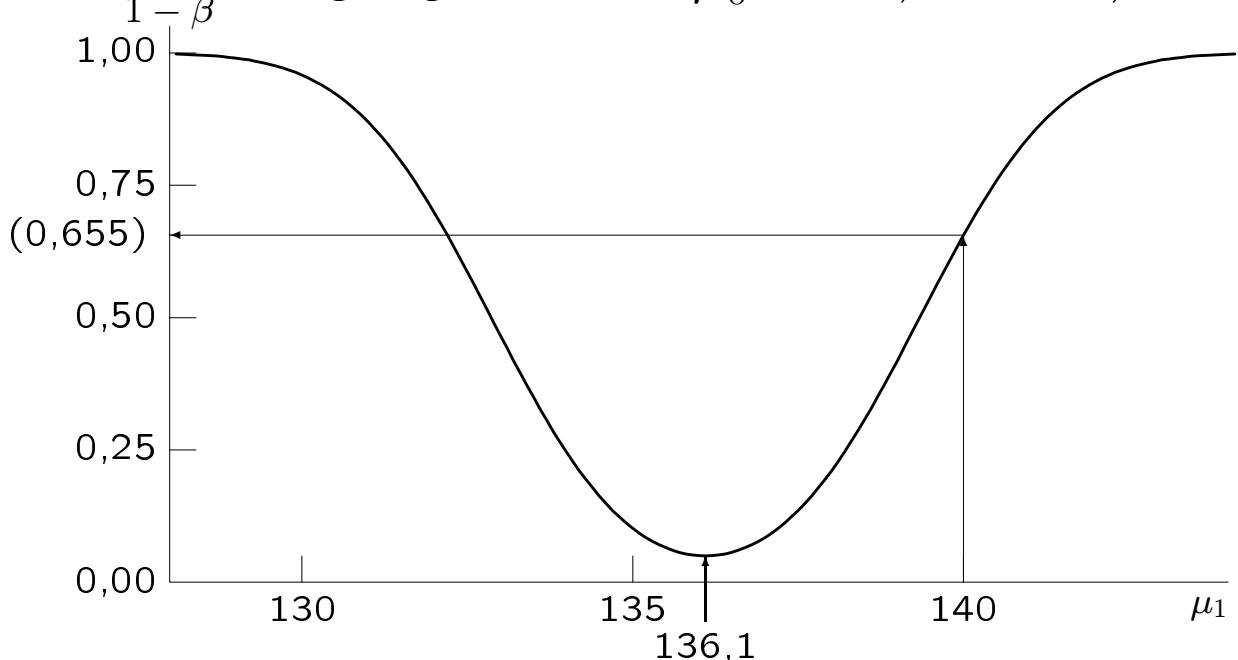


$$\begin{aligned} S.E.(\bar{X}) &= \sqrt{\frac{6,4^2}{15}} = 1,6525 \Rightarrow 136,1 - 1,6525 \cdot 1,96 = 132,86 \\ &\Rightarrow 136,1 + 1,6525 \cdot 1,96 = 139,34 \end{aligned}$$

## **síla testu** $1 - \beta$

pravděpodobnost, že zamítneme nulovou hypotézu, když testovaný parametr je roven ...  
(závisí na skutečné hodnotě parametru)

příklad **výšky**,  $n = 15$ ,  $\mu_0 = 136,1$ ,  $\sigma = 6,4$



**volba rozsahu výběru:** pro  $\mu_1$  požadujeme sílu  $1 - \beta$ :

$$n \geq \left( \frac{z(\alpha/2) + z(\beta)}{\mu_1 - \mu_0} \right)^2 \sigma^2$$

aby pro  $\mu_1 = 140$  byla síla 90 % ( $z(0,1) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,96 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 28,3$$

## jednovýběrový $t$ test

- $n$  nezávislých pozorování  $X_1, \dots, X_n$
- stejné normální rozdělení  $N(\mu, \sigma^2)$
- $H_0 : \mu = \mu_0$   
(populační průměr roven dané konstantě)
- nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- statistika

$$T = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})}$$

- $H_1 : \mu \neq \mu_0$  zamítat při  $|T| \geq t_{n-1}(\alpha)$
- $H_1 : \mu > \mu_0$  zamítat při  $T \geq t_{n-1}(2\alpha)$
- $H_1 : \mu < \mu_0$  zamítat při  $T \leq -t_{n-1}(2\alpha)$
- interval spolehlivosti pro  $\mu$

$$\left( \bar{X} - \frac{S}{\sqrt{n}} t_{n-1}(\alpha), \bar{X} + \frac{S}{\sqrt{n}} t_{n-1}(\alpha) \right)$$

případ neznámého rozptylu ( $H_1 : \mu \neq 136,1$ )

$$\begin{aligned}
\sum_{i=1}^n (x_i - \bar{x})^2 &= \sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2 \\
&= 130^2 + \dots + 147^2 - 15 \cdot 139,133^2 \\
&= 601,733 \\
s^2 &= \frac{601,733}{15 - 1} \\
&= 42,981 = 6,556^2 \\
t &= \frac{139,133 - 136,1}{6,556} \sqrt{15} \\
&= 1,792 \\
p &= P(|T| \geq 1,792) = 0,0948 \quad (9,48 \%)
\end{aligned}$$

95% interval spolehlivosti ( $t_{14}(0,05) = 2,145$ ):

$$\left( 139,133 - \frac{6,556}{\sqrt{15}} \cdot 2,145, \quad 139,133 + \frac{6,556}{\sqrt{15}} \cdot 2,145 \right) \\
(135,5, \quad 142,8)$$

**jednostranná alternativa**  $H_1 : \mu > 136,1$ :

$$\begin{aligned}
t \geq t_{14}(2 \cdot 0,05) &= 1,761 \quad \text{zamítnout } H_0 (\alpha = 5\%) \\
t < t_{14}(2 \cdot 0,01) &= 2,624 \quad \text{nezamítnout } H_0 (\alpha = 1\%) \\
p = P(T > t) &= 0,0474 \quad (4,74 \%)
\end{aligned}$$

## párové testy

- $(U_1, V_1), \dots, (U_n, V_n)$  **nezávislé** dvojice (možná závislých) náhodných veličin
- výhodná je těsná závislost uvnitř dvojic
- $X_i = U_i - V_i$  (označení rozdílů)  
 $X_1, \dots, X_n$  mají **stejné** rozdělení
- **párový  $t$  test**
  - **normální** rozdělení:  $X_i \sim N(\mu, \sigma^2)$
  - $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
  - $T = \frac{\bar{X}}{S.E.(\bar{X})} = \frac{\bar{X}}{S} \sqrt{n} = \frac{\bar{U} - \bar{V}}{S.E.(\bar{U} - \bar{V})}$
  - $H_0 : \mu = 0$  (pak je  $\mu_U = \mu_V$ )
  - ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
  - ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
  - ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$
  - jednovýběrový  $t$  test pro  $X_i = U_i - V_i$

**příklad:** výšky rodičů (zároveň pozorování!)

- $U$  – výška otce,  $V$  – výška matky
- $\alpha = 0,05$ ,  $H_0 : \mu_U - \mu_V = 0$
- $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- $\bar{x} = 2,293$ ,  $s_X = s_{U-10-V} = s_{U-V} = 8,144$
- $t = \frac{2,293}{8,144} \sqrt{99} = 2,801$
- $t_{98}(0,05) = 1,9845 \quad \Rightarrow \text{zamítout}$
- $p = P(|T| \geq t) = 0,0061 \quad (0,61\%)$
- 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :  
$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right)$$
$$(10,67; 13,92)$$
- 99% interval spolehlivosti:  $(10,14; 14,44)$

- **znaménkový test**

- stačí znát znaménka rozdílů  $U_i - V_i$
- pozorování s  $U_i = V_i$  se zpravidla vyneschají
- $Y$  – počet kladných znamének  $U_i - V_i$
- $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $Y \sim \text{bi}(n, 1/2)$
- $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- **párový Wilcoxonův test**

- nutné **symetrické** rozdělení  $U_i - V_i$
- vyloučíme případy  $U_i = V_i$
- určíme pořadí  $R_i^+$  hodnot  $|U_i - V_i|$
- $W$  součet pořadí, kde  $U_i > V_i$

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

**příklad** rozdíly dvou metod učení nazepaměť:

$$5, -1, 2, 3, -1, 4, 3, -3$$

- $H_0$  : populační medián rozdílu = 0
- znaménkový test

$$y = 5$$

$$n = 8$$

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 0,7237$$

- Wilcoxonův test  
(předpokládáme symetrii)

$u_i - v_i$	5	-1	2	3	-1	4	3	-3
$r_i^+$	8	1,5	3	5	1,5	7	5	5

$$w = 8 + 3 + 5 + 7 + 5 = 28$$

$$z = \frac{28 - 8 \cdot 9/4}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{10}{\sqrt{51}} = 1,4$$

$$p = 0,1614$$

## pst výskytu jevu (binomické rozdělení)

- $n$  **nezávislých** opakování dílčího pokusu
  - v každém „zdaru“ s pstí  $\pi$
  - počet zdarů  $Y \sim \text{bi}(n, \pi)$
  - odhad  $\pi$ :  $\hat{\pi} = \frac{Y}{n}$  (relativní četnost)  

$$\mathbb{E} \hat{\pi} = \pi, \quad \text{var } \hat{\pi} = \frac{\pi(1-\pi)}{n} = (\text{S.E.}(\hat{\pi}))^2$$
  - intervalový odhad pro  $\pi$  (přibližný)
- $$\left( \hat{\pi} - \sqrt{\frac{\hat{\pi}(1-\hat{\pi})}{n}} z(\alpha/2), \hat{\pi} + \sqrt{\frac{\hat{\pi}(1-\hat{\pi})}{n}} z(\alpha/2) \right)$$
- $H_0 : \pi = \pi_0$ :
- $$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1-\pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})}$$
- $H_1 : \pi \neq \pi_0$ : zamítnout  $|Z| \geq z(\alpha/2)$
  - $H_1 : \pi > \pi_0$ : zamítnout  $Z \geq z(\alpha)$
  - $H_1 : \pi < \pi_0$ : zamítnout  $Z \leq -z(\alpha)$

## příklad **kalous**

z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou

$Y$  – počet „zdaru“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou  $\Rightarrow Y$  má **binomické rozdělení**

za  $H_0 : \pi = 1/2$  (myši se neliší)  $Y \sim bi(50, 1/2)$

**alternativní hypotéza:**  $H_1 : \pi > 1/2$ :

**kritický obor:** velká hodnota  $Y$  (velké  $\hat{\pi}$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = 0,0118$$

s opravou na spojitost (NCSS):

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = 0,0169$$

**dosažená hladina:** za  $H_0$  počítaná pst, že dostaneme výsledek aspoň tolik odporující nulové hypotéze, jako ve skutečném pokusu:

$$\begin{aligned} p &= P(Y \geq 33) \\ &= \sum_{k=33}^{50} \binom{50}{k} 0,5^k (1-0,5)^{50-k} \\ &= 0,0164 \\ &= P(Y > 32) \quad (\text{NCSS, Prob. Calc.}) \end{aligned}$$

## dvouvýběrový $t$ test

- $n_X$  nezávislých pozorování  $X$
- $n_Y$  nezávislých pozorování  $Y$
- tyto výběry **nezávislé**
- rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné  
(odhady  $S_X^2, S_Y^2$  podobné, lze ověřit)
- normální rozdělení v obou výběrech  
(lze ověřit pro velká  $n_X, n_Y$ ,  
jinak podle zkušenosti)
- společný odhad rozptylu

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- statistika

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

- $H_0 : \mu_X = \mu_Y$  zamítnout ve prospěch alternativy  $H_1 : \mu_X \neq \mu_Y$ :

$$|T| \geq t_{n_X + n_Y - 2}(\alpha)$$

- Welchův test při pochybách o shodě rozptylů (modifikace  $T$ )

příklad **výšky** dětí (opět [cm])

hoši:  $n_x = 15, \bar{x} = 139,133, s_x^2 = 42,981$

dívky:  $n_y = 12, \bar{y} = 140,833, s_y^2 = 33,788$

$H_0$ : shodné populační průměry,  $H_1$ : neshodné

$$\begin{aligned}s^2 &= \frac{14}{25} 42,981 + \frac{11}{25} 33,788 \\ &= 38,936\end{aligned}$$

odhad S.E.( $\bar{X} - \bar{Y}$ ):

$$\sqrt{38,936 \frac{15+12}{15 \cdot 12}} = \sqrt{5,8404} = 2,4167$$

$$\begin{aligned}t &= \frac{139,133 - 140,833}{\sqrt{38,936}} \sqrt{\frac{15 \cdot 12}{15 + 12}} \\ &= \frac{-1,7}{2,4167} = -0,703\end{aligned}$$

$$|t| < t_{25}(0,05) = 2,0595 \Rightarrow$$

na 5% hladině nezamítat

$$p = 0,488$$

95% int. spol. pro rozdíl popul. průměrů:

$$(-1,700 - 2,4167 \cdot 2,0595, -1,700 + 2,4167 \cdot 2,0595)$$

$$(-6,7, 3,3)$$

nula je intervalu pokryta

- test **Mannův-Whitneyův**  
(dvouvýběrový Wilcoxonův)
  - nahradí pozorování jejich pořadími
  - dva nezávislé výběry rozsahu  $n_X, n_Y$
  - spojitá rozdělení
  - hypotéza: rozdělení jsou stejná, pak jsou výběry „dobře promíchané“
  - určí pořadí všech (promíchaných)
  - kritický obor: různá průměrná pořadí
  - $W_X$  součet pořadí hodnot  $X$
$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$
  - shodu zamítne pokud  $|Z| \geq z(\alpha/2)$   
(přibližný test)
  - citlivý vůči posunutí,  
méně vůči nestejné variabilitě

## dvouvýběrový Wilcoxonův (Mann-Whitney)

hoši	dívky	pořadí
127		1
130	131	2
	132	3
133	135	4
		5
136    136		6
138		7,5
139    139    139		9
140		11
141	141    141    141    141	13
142	142	16
	143	19,5
	146    146	21
147		22,5
149		24
151	151	25
		26,5

$$w_x = 1 + 2 + 5 + 2 \cdot 7,5 + 9 + 3 \cdot 11 + 13 + 16 + 19,5 + 24 + 25 + 26,5 = 189$$

$$w_y = 3 + 4 + 6 + 4 \cdot 16 + 19,5 + 21 + 2 \cdot 22,5 + 26,5 = 189$$

$$z = \frac{189 - 15 \cdot (15 + 12 + 1)/2}{\sqrt{15 \cdot 12(15 + 12 + 1)/12}} = -1,025$$

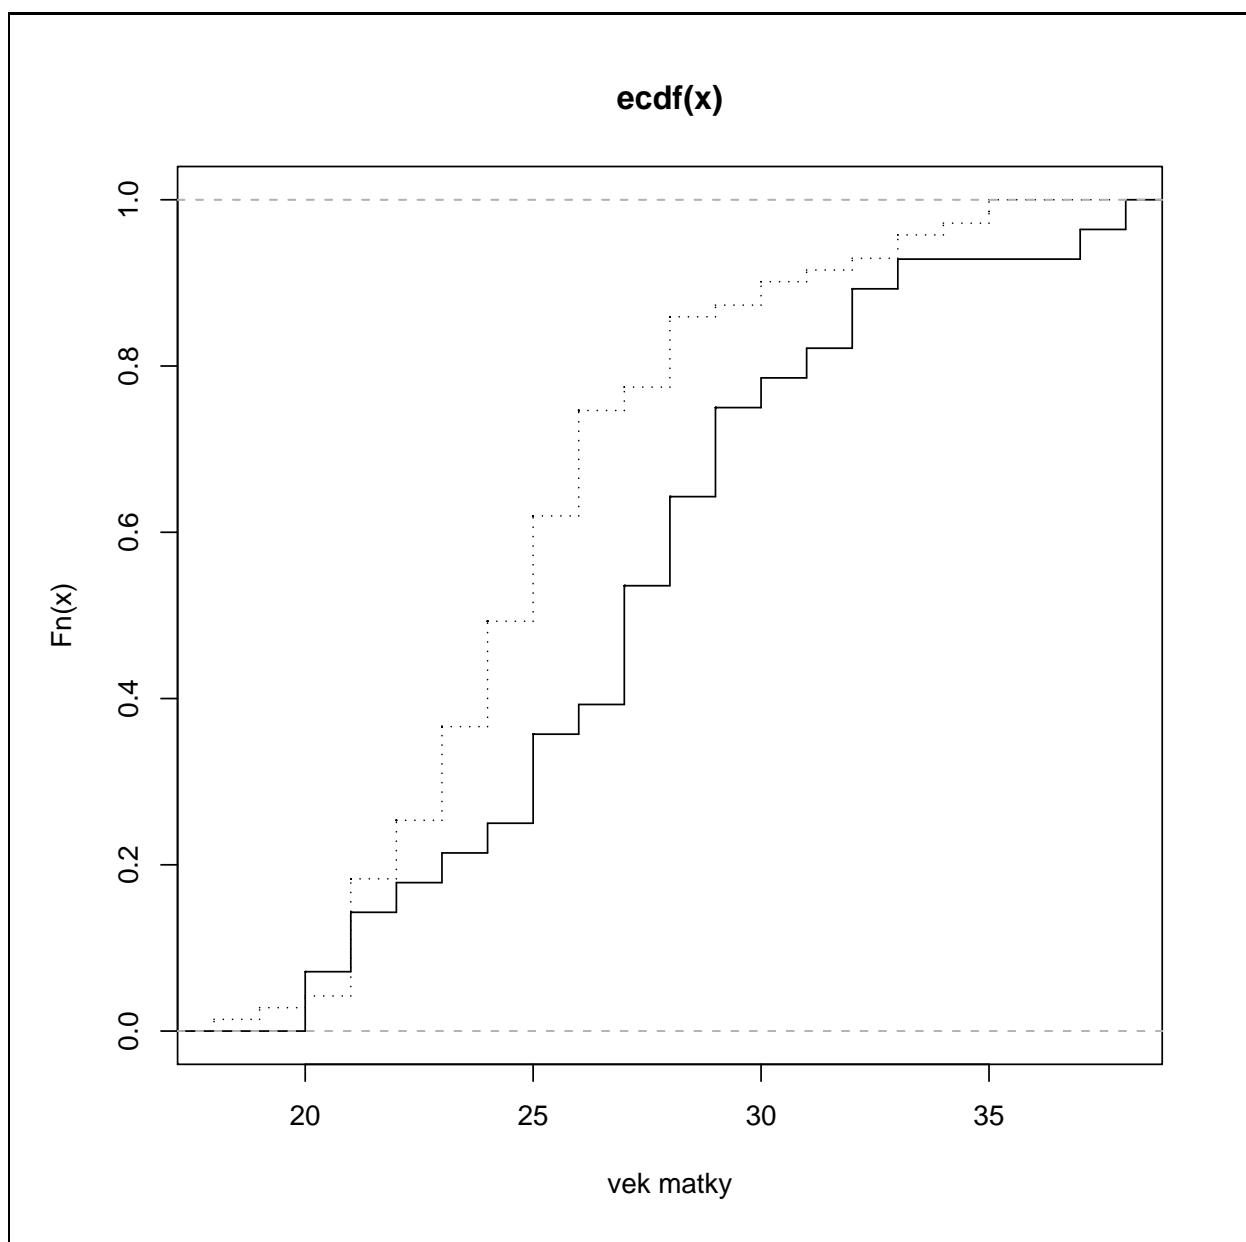
$$p = 0,3055$$

NCSS:  $z = -1,029$  (korekce na shody)

$$p = 0,3036$$

přesně:  $p = 0,3149$

- test **Kolmogorovův-Smirnovův**
  - porovná empirické distribuční funkce
  - citlivý vůči všem neshodám
  - věk matky, kojí v 24. týdnu  
 $D = 0,354,$        $p = 0,95 \%$ (NCSS)



## permutační testy - dva výběry

- $H_0$  : identické rozdělení v obou populacích
- příklad **hnojení**
  - $x$ : 50,45,42,54 (klasicky)
  - $y$ : 59,56,58,51,52 (nové)
  - $H_0$  stejné výnosy
  - $H_1$  výnosy jsou nestejné
- porovnejme průměry:

$$\bar{x} - \bar{y} = 47,75 - 55,2 = -7,45$$

- celkem  $\binom{9}{4} = 126$  permutací – možnosti, kolikrát vybrat 4 hodnoty  $x$  z 9 hodnot
  - mezi nimi jsou 4 takové, že rozdíl průměrů nejvýše  $-7,45$ , což je 3,17 %
  - při oboustranné alternativě další dvě kombinace, kdy rozdíl aspoň  $7,45$ , což je 1,59 % permutací, celkem

$$p = \frac{4 + 2}{126} = \frac{6}{126} = 0,0476 \quad (4,76 \%)$$

$x$				$y$					$\bar{x} - \bar{y}$	$w_x$
50	45	42	54	59	56	58	51	52	-7,45	
3	2	1	6	9	7	8	4	5		10
*	*	*	*						* -8,80	10
*	*	*	*						* -8,35	11
*	*	*	*						* -7,90	12
*	*	*	*						-7,45	12
*	*	*	*						-7,00	13
*	*	*	*						* -6,55	14
*	*	*	*	*					-6,55	13
*	*	*	*	*					-6,10	14
*	...								...	
*	*	*	*	*					*	-0,70
*	*	*	*	*	*	*	*	*	-0,25	20
*	*	*	*	*					*	-0,25
*	*	*	*	*					*	21
*	*	*	*	*					*	-0,25
*	*	*	*	*					*	20
*	*	*	*	*					*	-0,25
*	*	*	*	*					*	18
*	*	*	*	*					*	-0,25
*	*	*	*	*					*	20
*	*	*	*	*					*	-0,25
*	*	*	*	*					*	19
*	*	*	*	*					0,20	21
*	*	*	*	*					0,20	21
*	...								...	
*	*	*	*	*	*	*	*	*	6,50	27
*	*	*	*	*	*	*	*	*	6,95	28
*	*	*	*	*	*	*	*	*	6,95	27
*	*	*	*	*	*	*	*	*	7,40	28
*	*	*	*	*	*	*	*	*	7,85	29
*	*	*	*	*	*	*	*	*	8,75	30

$$\begin{aligned}
p_{\text{perm}} &= \frac{4+2}{126} = 0,0476 & p_W &= \frac{4+4}{126} = 0,0635 \\
t &= -2,5238 & p &= 0,0396
\end{aligned}$$

## **permutační testy** - jeden výběr příklad **učení nazpaměť**

- $H_0$  : rozdělení je symetrické kolem nuly
- rozdíly dvou metod učení nazpaměť:  
 $5, -1, 2, 3, -1, 4, 3, -3$  průměr = 1,5
- pokud jsou obě metody ekvivalentní, pak mají rozdíly náhodná znaménka
- případnou nulu lze předem vyloučit
- pro znaménka celkem  $2^8 = 256$  možností
- ideál pro průměr 0
- v 27 případech průměr aspoň 1,5,  
v 27 případech průměr nejvýše -1,5
- dosažená hladina je rovna pravděpodobnosti, že aspoň stejně tak daleko od hypotézy, jako skutečná data

$$p_{\text{perm}} = \frac{27 + 27}{256} = \frac{54}{256} = 0,2109 \quad (21,09 \%)$$

	data								$\bar{x}$	$w$
$x$	5	-1	2	3	-1	4	3	-3		
$r$	8	1,5	3	5	1,5	7	5	5		
1	-5	-1	-2	-3	-1	-4	-3	-3	<b>-2,75</b>	<b>0</b>
2	-5	-1	-2	-3	1	-4	-3	-3	<b>-2,50</b>	<b>1,5</b>
3	-5	1	-2	-3	-1	-4	-3	-3	<b>-2,50</b>	<b>1,5</b>
4	-5	-1	2	-3	-1	-4	-3	-3	<b>-2,25</b>	<b>3</b>
5	-5	1	-2	-3	1	-4	-3	-3	<b>-2,25</b>	<b>3</b>
					...					
18	-5	1	-2	-3	-1	-4	-3	3	<b>-1,75</b>	<b>6,5</b>
19	5	-1	-2	-3	-1	-4	-3	-3	<b>-1,50</b>	<b>8</b>
					...					
23	-5	-1	-2	-3	1	4	-3	-3	<b>-1,50</b>	8,5
24	-5	1	-2	3	1	-4	-3	-3	<b>-1,50</b>	<b>8</b>
25	-5	1	-2	-3	-1	4	-3	-3	<b>-1,50</b>	8,5
26	-5	1	-2	-3	1	-4	3	-3	<b>-1,50</b>	<b>8</b>
27	-5	1	-2	-3	1	-4	-3	3	<b>-1,50</b>	<b>8</b>
28	5	-1	-2	-3	1	-4	-3	-3	-1,25	9,5
					...					
229	-5	1	2	3	-1	4	3	3	1,25	26,5
230	5	-1	2	3	-1	4	3	-3	<b>1,50</b>	<b>28</b>
231	5	-1	2	3	-1	4	-3	3	<b>1,50</b>	<b>28</b>
232	5	-1	2	3	1	-4	3	3	<b>1,50</b>	27,5
233	5	-1	2	-3	-1	4	3	3	<b>1,50</b>	<b>28</b>
234	5	1	2	3	-1	-4	3	3	<b>1,50</b>	27,5
235	5	1	-2	3	1	4	3	-3	<b>1,50</b>	<b>28</b>
236	5	1	-2	3	1	4	-3	3	<b>1,50</b>	<b>28</b>
237	5	1	-2	-3	1	4	3	3	<b>1,50</b>	<b>28</b>
238	-5	1	2	3	1	4	3	3	<b>1,50</b>	<b>28</b>
239	5	-1	2	3	1	4	3	-3	<b>1,75</b>	<b>29,5</b>
					...					
255	5	1	2	3	-1	4	3	3	<b>2,50</b>	<b>34,5</b>
256	5	1	2	3	1	4	3	3	<b>2,75</b>	<b>36</b>

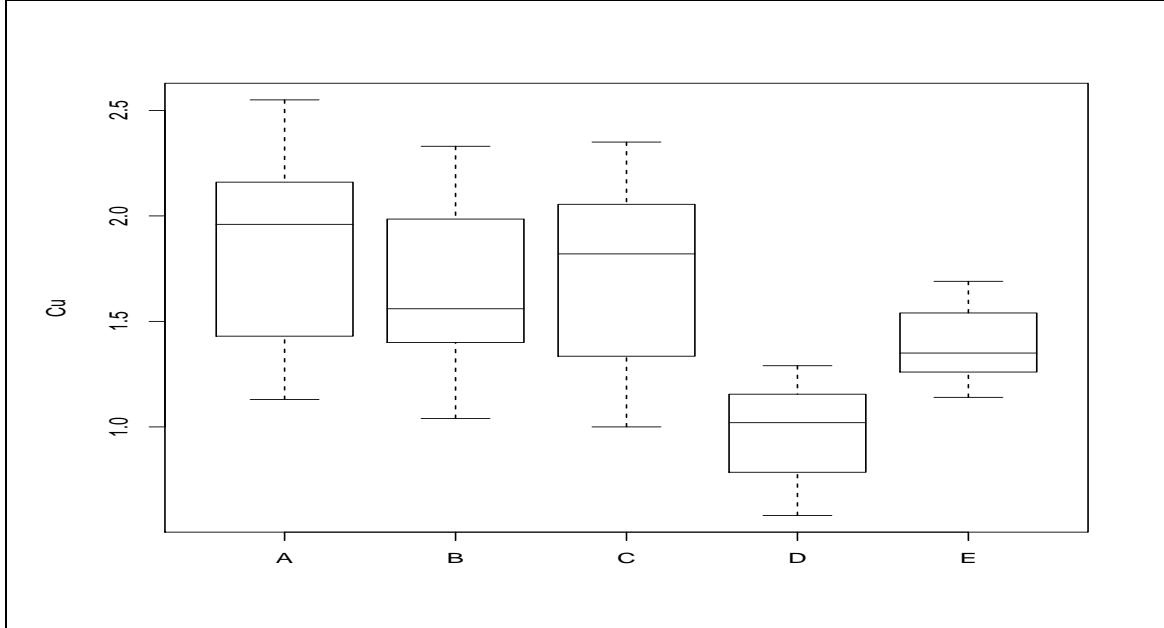
$$p_{\text{perm}} = \frac{27+27}{256} = 0,2109$$

$$p_W = \frac{25+25}{256} = 0,1953$$

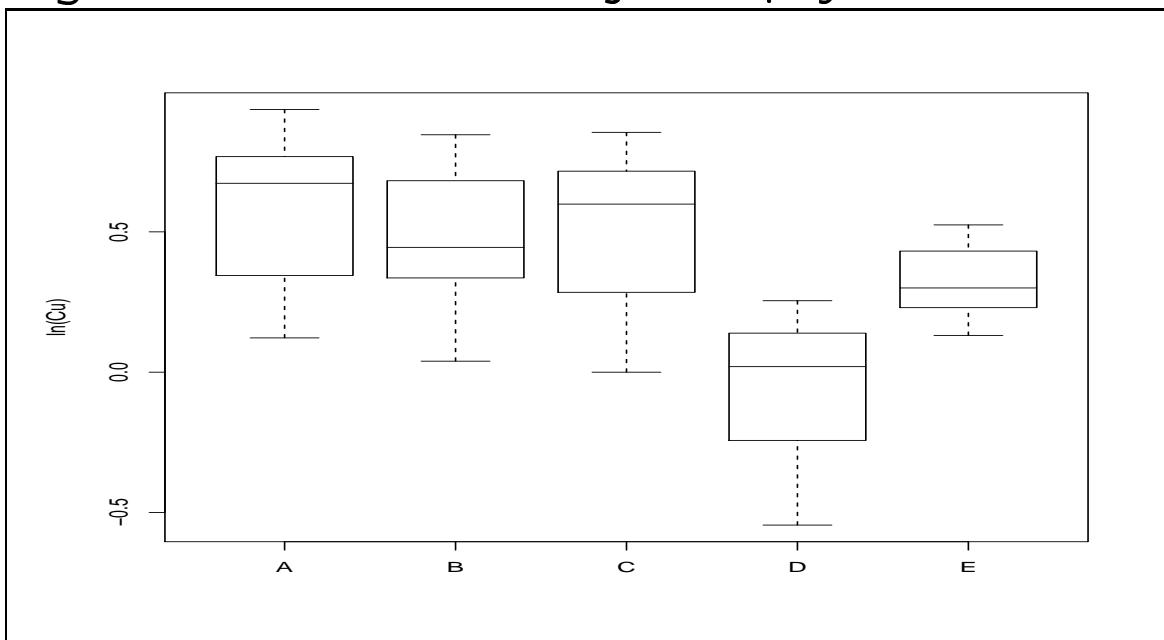
$$t = 1,5$$

$$p = 0,1773$$

**příklad: játra** pět míst na řece, vždy vyloveno po 7 rybách, zjišťována koncentrace mědi v játrech  
liší se tato místa svým znečištěním?



logaritmování stabilizuje rozptyl:



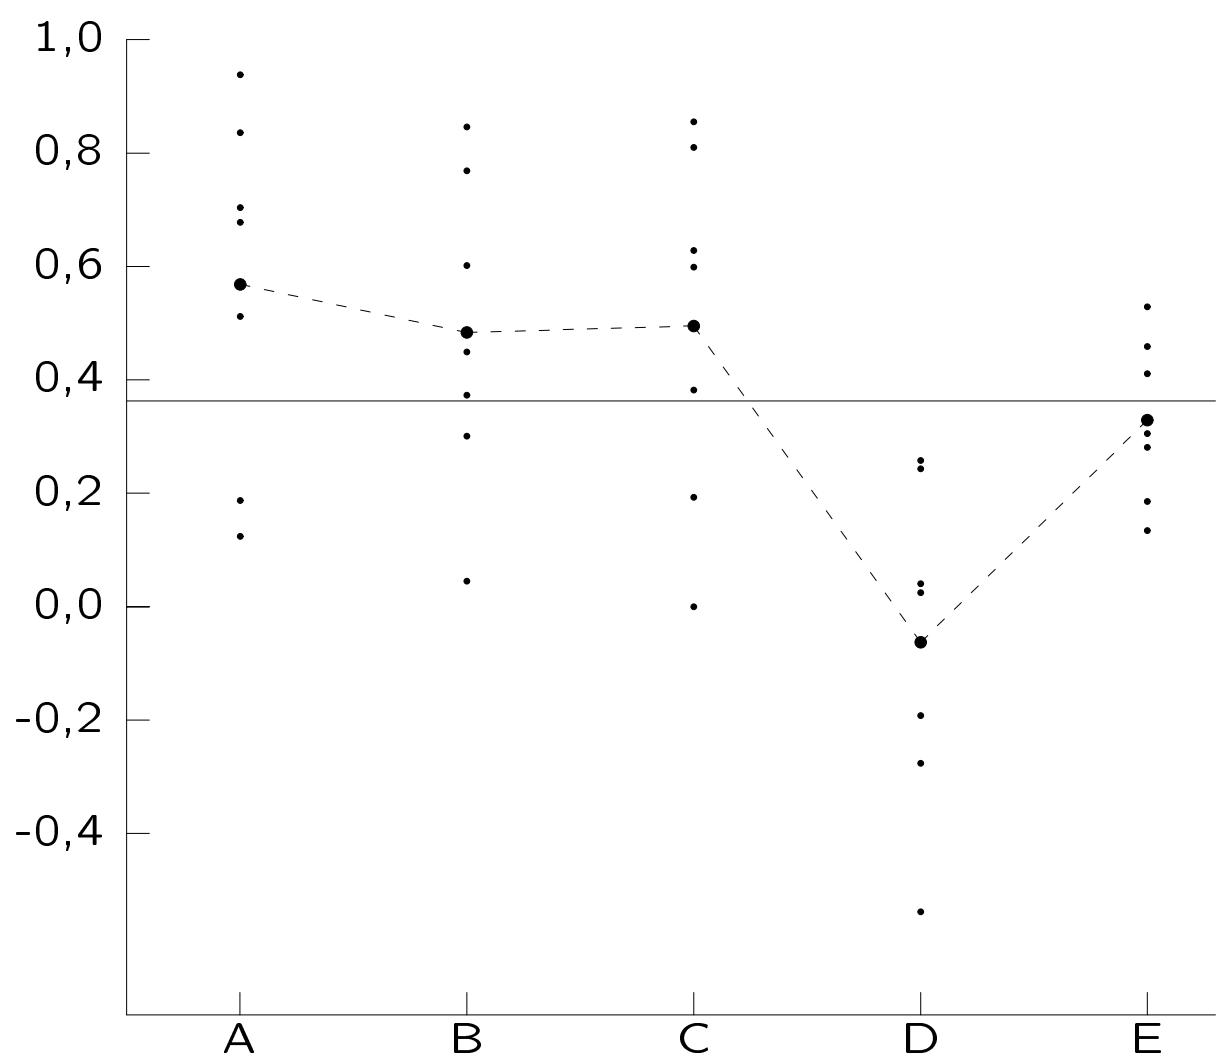
## analýza rozptylu jednoduchého třídění

- $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$   
 $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$   
...  
 $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$
- **nezávislé** výběry  
(shodné rozptyly, normální rozdělení)
- $H_0 : \mu_1 = \dots = \mu_k \quad (= \mu)$   
 $H_1 : \text{neplatí } H_0$
- rozklad součtu čtverců  
 $\sum \sum (Y_{it} - \bar{Y}_{\bullet\bullet})^2 =$   
 $\sum n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum \sum (Y_{it} - \bar{Y}_{i\bullet})^2$   
(celková variabilita) = (mezi) + (uvnitř)

$$\begin{aligned} S_T &= S_A + S_e \\ f_T &= f_A + f_e \\ (n-1) &= (k-1) + (n-k) \end{aligned}$$

- $H_0$  zamítout, je-li

$$F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$



- **model** (měření = úroveň + chyba)

$$\begin{aligned}
 Y_{it} &= \mu_i + E_{it} \quad 1 \leq t \leq n_i, \quad 1 \leq i \leq k \\
 &= \mu + (\mu_i - \mu) + E_{it} \quad E_{it} \text{ nezávislé} \\
 &= \mu + \alpha_i + E_{it} \quad E_{it} \sim N(0, \sigma^2)
 \end{aligned}$$

- **reparametrisace** ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- **mnohonásobná srovnání**

(které dvojice  $\mu_i$  (resp.  $\alpha_i$ ) se liší?)

$$|\bar{Y}_{i\bullet} - \bar{Y}_{j\bullet}| \geq q_{k,n-k}(\alpha) \sqrt{\frac{S^2}{2} \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}$$

$$S^2 = \frac{S_e}{f_e} = \frac{\sum \sum (Y_{it} - \bar{Y}_{i\bullet})^2}{n - k}$$

(nutnost zachovat zvolenou hladinu testu)

- **ověření** shody rozptylů

- Leveneův test
- Bartlettův test (normalita!)

## tabulka analýzy rozptylu

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry reziduální	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

## příklad játra

variab.	$S$	$f$	$S/f$	$F$	$p$
místa	1,796	4	0,4490	5,862	0,0013
rezid.	2,285	30	0,0762		
celk.	4,081	34			

místo	počet	průměr	efekt	směr. odchylka
A	7	0,569	0,206	0,312
B	7	0,484	0,121	0,279
C	7	0,496	0,133	0,318
D	7	-0,063	-0,426	0,290
E	7	0,329	-0,034	0,144
celkem	35	0,363	0,000	0,104

$$q_{5,30}(0,05) \sqrt{\frac{0,0762}{2} \left( \frac{1}{7} + \frac{1}{7} \right)} = 4,10 \cdot 0,104 = 0,426$$

$-0,063 + 0,426 = 0,363 \Rightarrow$  na 5% hladině se liší místo D od každého z míst A, B, C

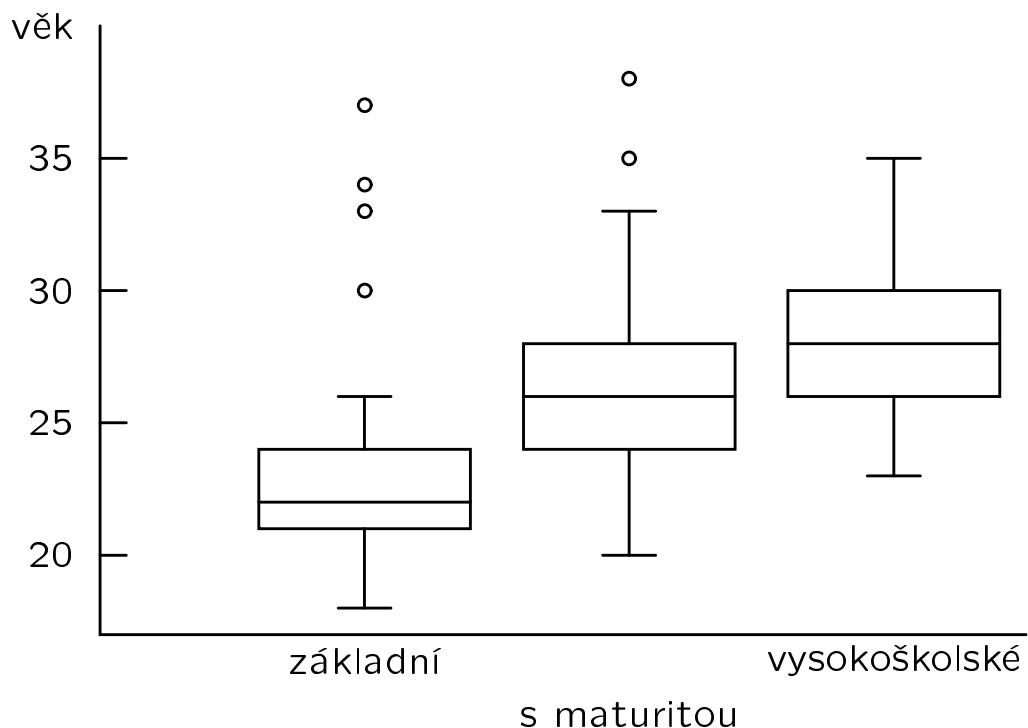
## Kruskalův-Wallisův text

- zobecnění dvouvýběrového Wilcoxonova testu  
(pořadí místo původních hodnot)
- předpoklady:
  - $k$  nezávislých výběrů
  - spojitá rozdělení
  - $H_0$ : rozdělení jsou stejná
- $T_i$  - součet pořadí v  $i$ -tém výběru

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

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

## příklad **kojení** (věk matek podle vzdělání)



vzděl.	$n_i$	prům. věk	stř. chyba	souč. poř.	prům. poř.
zákl.	34	23,412	0,638	1025	30,15
mat.	47	26,278	0,543	2618	55,70
VŠ	18	28,50	0,877	1307	72,61
celk.	99	25,697		4 950	50

$$Q = \frac{12}{99 \cdot 100} \left( \frac{1025^2}{34} + \frac{2618^2}{47} + \frac{1307^2}{18} \right) - 3 \cdot 100 = 29,25$$

$$\chi_2^2(0,05) = 5,99 \qquad p < 0,0001$$

## náhodné bloky

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

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

**aditivní** vliv, symbolicky  $A + B$

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

$$S_T = S_A + S_B + S_e$$

- vliv dvou **faktorů**  
(A – náhodný, B – pevný)

## příklad **diety**

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

- váhové přírůstky za danou dobu
  - $r = 4$  ošetření (pevné efekty)
  - $k = 5$  vrhů (náhodné efekty)

- tabulka ANOVA

variab.	$S$	$f$	$S/f$	$F$	$p$
vrhy	91,932	4	22,983	22,26	<0,0001
dieta	23,332	3	7,774	7,53	0,0043
rezid.	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- nesprávně jednoduché třídění ANOVA kdybychom zapomněli na závislost některých pozorování způsobenou náhodnými bloky (vrhy):

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

$$F = \frac{23,332/3}{104,320/16} = 1,193, \quad p = 0,344$$

## Friedmanův test

- 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
- $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- určí pořadí v rámci každého bloku (řádku)
- za hypotézy v každém řádku náhodná permutace čísel  $1, \dots, r$ , tedy součty ve sloupcích (pro ošetření) podobné
- 

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

- zamítat  $H_0$  : pro  $Q \geq \chi^2_{r-1}(\alpha)$

## příklad **diety**

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

- $k = 5, r = 4$
- $Q = \frac{12}{5 \cdot 4 \cdot 5} \left( 9^2 + 7^2 + 17^2 + 17^2 \right) - 3 \cdot 5 \cdot 6 = 9,96$
- $Q > \chi_3^2(0,05) = 7,8147, \quad p = 0,0189$

## dvojné třídění s interakcemi

- vliv dvou faktorů, nemusí být aditivní

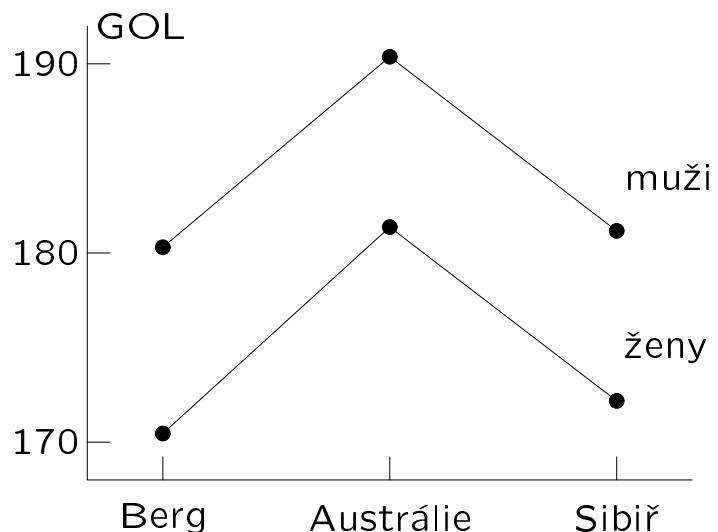
$$\begin{aligned} Y_{ijt} &= \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \\ E_{ijt} &\sim N(0, \sigma^2) \end{aligned}$$

- 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)
- rozklad součtu čtverců – obecně složitější
- testy
  - $H_{AB} : \gamma_{ij} = 0$  (aditivita)
  - $H_A : \alpha_i = 0$  (faktor A nemá vliv)
  - $H_B : \beta_j = 0$  (faktor B nemá vliv)

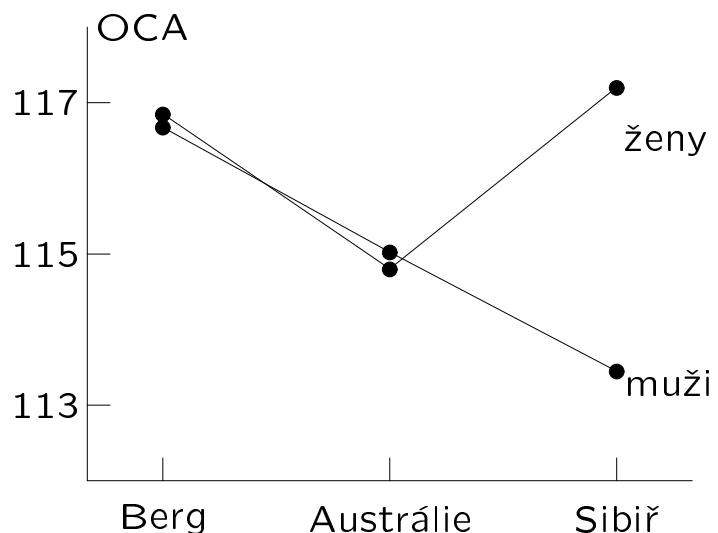
příklad **Howells**:

lebky exhumované na třech místech (A)  
rozlišované podle pohlaví (B)

- největší délka mozkovny ( $p_{AB} = 0,8872$ )



- týlní úhel ( $p_{AB} = 0,0222$ )



příklad **Howells** největší délka mozkovny (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

tabulka ANOVA

var.	$S$	$f$	$S/f$	$F$	$p$
místa	5242,1	2	2621,1	65,2	<0,0001
pohl.	5170,8	1	5170,8	128,6	<0,0001
inter.	9,6	2	4,8	0,1	0,8872
rezid.	9410,6	234	40,2		
celk.	19833,2	239			

## příklad **Howells** týlní úhel (OCA)

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

tabulka ANOVA

var.	$S$	$f$	$S/f$	$F$	$p$
místa	150,908	2	75,454	3,05	0,0493
pohl.	91,267	1	91,267	3,69	0,0560
inter.	191,608	2	95,804	3,87	0,0222
rezid.	5789,550	234	24,742		
celk.	6223,333	239			

- **pevné** efekty

- úrovně faktoru volí experimentátor
- při opakovaném pokusu je lze zvolit stejně
- vypovídáme o konkrétních úrovních faktoru
- $H_0$ : nulové efekty

- **náhodné** efekty

- úrovně faktoru volí příroda
- při opakovaném pokusu jsou jiné
- vypovídáme o populaci možných úrovní faktoru
- $H_0$ : nulová variabilita efektu
- testy obecně závisí na charakteru efektu
- doporučují se **vyvážené** modely
- modely analýzy rozptylu:  
závislost **spojité** (metrické) veličiny na  
**nominální(ch)**

## porovnání populačních měr polohy

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

## **vyšetřování závislostí**

nezávisle proměnná(é)	závisle proměnná	
<b>spojitá</b>	<b>spojitá</b>	<b>nominální</b>
	regrese korelace	(logistická regrese)
<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

- **korelace**

- měří **sílu** (těsnost) **vzájemné** závislosti **spojitych** veličin
- lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
- k **porovnávání síly** (těsnosti) závislosti v několika populacích
- **symetrická** vlastnost v  $X, Y$

- **regrese**

- udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
- **nesymetrická** vlastnost
- lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
- umožňuje **předpovídat** hodnotu  $Y$  pro zvolenou hodnotu  $x$

## korelační koeficient

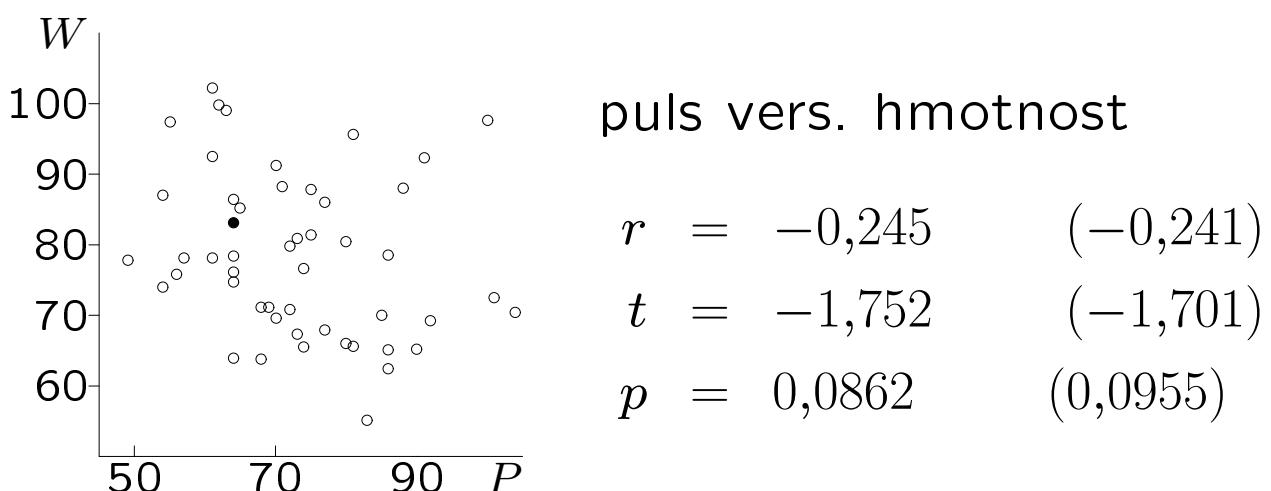
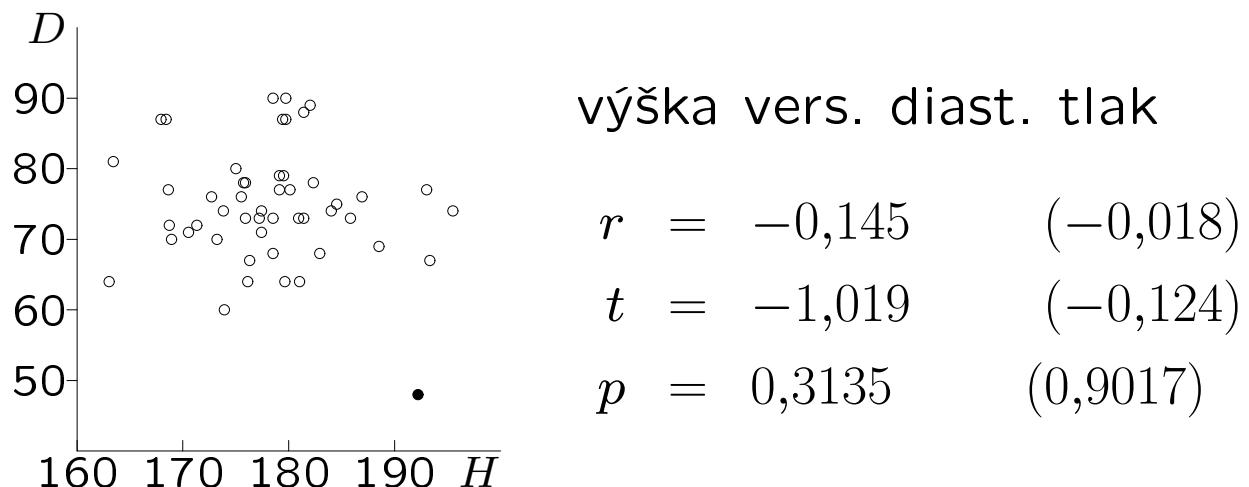
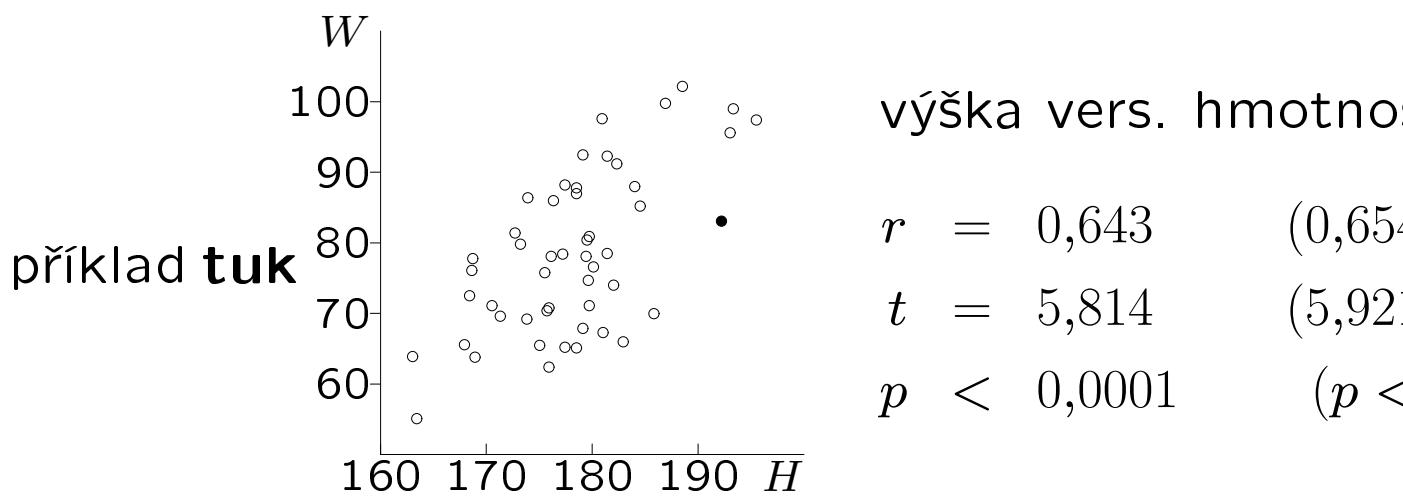
- (populační) korelační koeficient  $\rho_{XY}$ 
  - $|\rho_{XY}| \leq 1$
  - pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - měří sílu **lineární** závislosti
- (výběrový) korelační koeficient  $r_{xy}$ 
  - pro test nutno **normální** rozdělení

$$r_{XY} = \frac{S_{XY}}{\sqrt{S_X^2 S_Y^2}} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

$$S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

- $H_0 : \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:
$$T = \frac{r}{\sqrt{1 - r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$
- **Spearmanův** korelační koeficient
  - měří sílu **monotonní** závislosti
  - založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

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



## Fisherova $Z$ transformace

$$Z = \frac{1}{2} \log \frac{1+r}{1-r} \sim N\left(\frac{1}{2} \log \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$$

- příklad **děti**: porodní délka, hmotnost
  - dívky:  $r_1 = 0,5687$ ,  $n_1 = 51$

$$z_1 = \frac{1}{2} \log \frac{1+0,5687}{1-0,5687} = 0,6456$$

- hoši:  $r_2 = 0,5967$ ,  $n_2 = 49$ ,  $z_2 = 0,6880$
- test shody

$$z^* = \frac{0,6456 - 0,6880}{\sqrt{\frac{1}{51-3} + \frac{1}{49-3}}} = -0,2055.$$

srovnej se  $z(0,05/2) = 1,960$ ,  $p = 0,8376$

- 95% interval spolehlivosti pro  $\rho_1$

$$\left(0,6456 - \frac{1,960}{\sqrt{51-3}}, \quad 0,6456 + \frac{1,960}{\sqrt{51-3}}\right)$$

$$(0,363, \quad 0,929)$$

$$\left(\frac{e^{2 \cdot 0,363} - 1}{e^{2 \cdot 0,363} + 1}, \quad \frac{e^{2 \cdot 0,929} - 1}{e^{2 \cdot 0,929} + 1}\right)$$

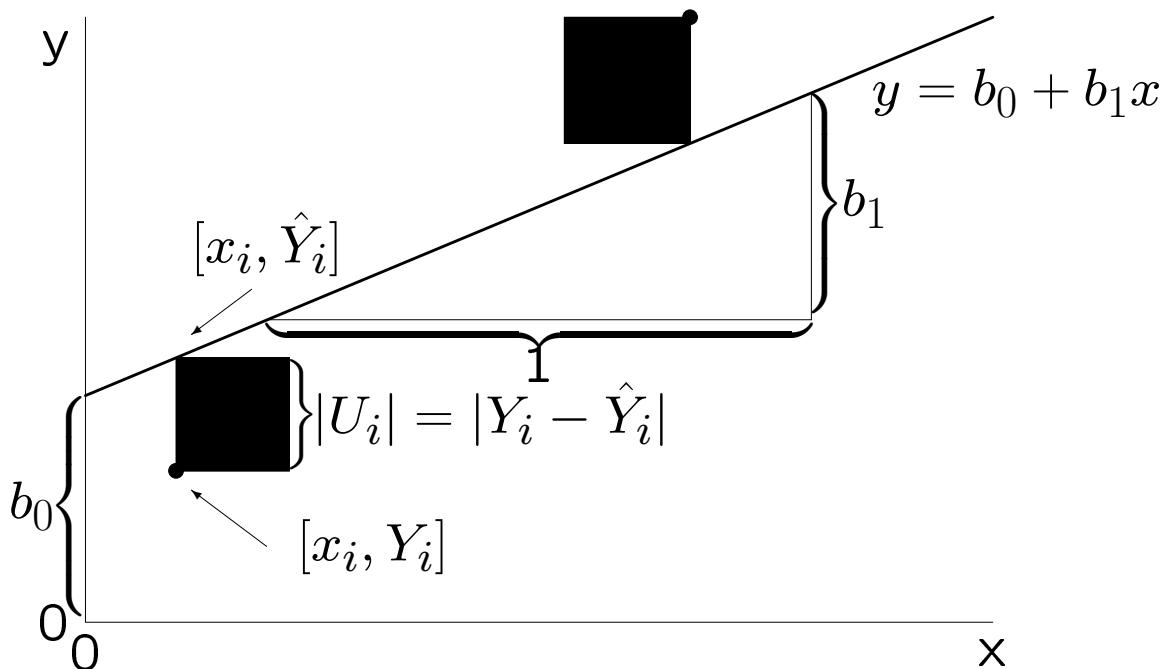
$$(0,348, \quad 0,730)$$

## regrese (původ pojmu)

- tendence (návrat) k průměrnosti
  - F. Galton (1886): Family likeness in stature. Proc. Roy. Soc. XL, 42
  - F. Galton (1886): Regression towards mediocrity in hereditary stature. Journ. Anthropol. Inst. XV, 246
- uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů těchto otců bude rovna průměrné výšce **všech** synů
- uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- uvažujme otce o 10 cm **nížší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nížší**, než průměrná výška generace synů

## regresní přímka

- odhadovaná závislost:  $\mathbb{E} Y = \beta_0 + \beta_1 x$
- k daným  $x_1, \dots, x_n$  zjistíme  $Y_1, \dots, Y_n$ 
  - **nezávislá** pozorování
  - **stejný** rozptyl  $\sigma^2$
  - **normální** rozdělení (pro testy)
- $b_0, b_1$  – odhaduji metodou **nejmenších čtverců**:  
minimalizovat 
$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$



- odhad závislosti  $E Y = \beta_0 + \beta_1 x$

$$\hat{Y} = b_0 + b_1 x$$

- $b_1$  – odhad směrnice  $\beta_1$ , odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
  - reziduum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1 x_i)$
  - reziduální součet čtverců:
- $$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2 = \sum_{i=1}^n U_i^2$$
- reziduální rozptyl

$$S^2 = \frac{S_e}{n - 2}$$

- **koeficient determinace** (podíl variabilitu  $Y$  vysvětlené uvažovanou závislostí)

$$R^2 = 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2}$$

- nezávislost  $E Y$  na  $x$  znamená  $H_0 : \beta_1 = 0$

$$T = \frac{b_1}{S.E.(b_1)} \quad |T| \geq t_{n-2}(\alpha)$$

**příklad** závislost procenta tuku FAT na výšce HEIGHT u mladých mužů

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
HEIGHT	0,379	0,138	2,742	0,0086

předpověď:  $\hat{Y}_i = -53,870 + 0,379x_i$ ,  
 tedy  $\widehat{\text{FAT}} = -53,870 + 0,379 \cdot \text{HEIGHT}$   
 (na každý centimetr výšky v průměru  
 0,379 procentního hodu)

varia- bilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	362,54	1	362,54	7,519	0,0086
rezid.	2314,41	48	48,22		
celk.	2676,95	49	(54,63)		

$$R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$$

## mnohonásobná lineární regrese

- závislost na dvou nezávisle proměnných
- pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- $Y_1, \dots, Y_n$  jsou **nezávislé** náhodné veličiny
- stejný rozptyl  $\sigma^2$
- normální rozdělení  $Y_i$  pro dané  $x_i, v_i$
- střední hodnoty  $Y_i$  vysvětleny pomocí  $x_i, v_i$

$$\mathbb{E} Y_i = \beta_0 + \beta_1 x_i + \beta_2 v_i$$

- $b_0, b_1, b_2$  – odhad parametrů  $\beta_0, \beta_1, \beta_2$
- $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- $U_i$  – **reziduum**

$$\begin{aligned} U_i &= Y_i - \hat{Y}_i \\ &= Y_i - (b_0 + b_1 x_i + b_2 v_i) \end{aligned}$$

- **rozklad variability**  $S_T = S_R + S_e$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = S_R + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

- **koeficient determinace**  $R^2$

(podíl celkové variability, který se podařilo vysvětlit závislostí  $Y$  na  $x, v$ )

$$R^2 = \frac{S_R}{S_T} = 1 - \frac{S_e}{S_T}$$

uvažujeme závislost  $\boxed{\mathbb{E} Y = \beta_0 + \beta_1 x + \beta_2 v}$

- $H_0 : \beta_2 = 0$  (k vysvětlení  $Y$  stačí  $x$ )

$$T_2 = \frac{b_2}{\text{S.E.}(b_2)}, \quad \text{zamítat pro } |T_2| \geq t_{n-3}(\alpha)$$

- $H_0 : \beta_1 = 0$  (k vysvětlení  $Y$  stačí  $v$ )

$$T_1 = \frac{b_1}{\text{S.E.}(b_1)}, \quad \text{zamítat pro } |T_1| \geq t_{n-3}(\alpha)$$

- $H_0 : \beta_1 = \beta_2 = 0$  (nezáv. ani na  $x$  ani na  $v$ )

$$F = \frac{S_R/2}{S_e/(n-3)} \geq F_{2,n-3}(\alpha)$$

## příklad závislost FAT na HEIGHT a WEIGHT

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
HEIGHT	-0,262	0,110	-2,376	0,0216
WEIGHT	0,624	0,0690	9,050	<0,0001

- při **stejné výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku

varia-bilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

$$R^2 = \frac{1833,11}{2676,95} = 1 - \frac{843,85}{2676,95} = 0,685$$

## $\chi^2$ testy

- pro znaky v **nominálním** měřítku
- **příklady**
  - počty osob s krevními skupinami A, B, AB, 0 mezi  $n$  osobami
  - počty dětí narozených v jednotlivých měsících v Praze
  - počty matek se základním, středním, vysokoškolským vzděláním
- **multinomické** rozdělení
  - v dílčím pokusu  $k$  možných výsledků  $A_1, \dots, A_k$  (neslučitelné, spojení jev jistý)
  - $\pi_j$  je pst, že vyjde  $A_j$       ( $\sum \pi_j = 1$ )
  - $n$  **nezávislých** dílčích pokusů
  - $N_j$  – počet dílčích pokusů, kdy  $A_j$
  - $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
  - samotné  $N_j$  má binomické rozdělení
- **pravděpodobnost**  $N_1 = n_1, \dots, N_k = n_k$

$$\frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

- hlavní vlastnost (pokud  $n\pi_j \geq 5$  pro  $\forall j$ )

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j}$$

má přibližně rozdělení  $\chi^2(k - 1)$

- **test shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
 (pravděpodobnosti dány **jednoznačně**)
  - platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $n\pi_j^0$ :

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$$

- $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$
- $N_j$  – **experimentální** četnost
- $n\pi_j^0$  – **teoretická** četnost
- statistika  $X^2$  porovnává experimentální a teoretické četnosti

## příklad **měsíce**

počty studentů biologie narozených v jednotlivých měsících

**hypotéza:**

dětí se rodí během roku **rovnoměrně**

měsíc	$n_j$	$n\pi_j^0$	přínos
1	11	9,43	0,2623
2	9	8,52	0,0276
3	13	9,43	1,3539
4	11	9,12	0,3861
5	8	9,43	0,2161
6	5	9,12	1,8635
7	10	9,43	0,0348
8	6	9,43	1,2461
9	13	9,12	1,6473
10	8	9,43	0,2161
11	8	9,12	0,1383
12	9	9,43	0,0194
celkem	111	111,00	7,4115

$$X^2 = 7,4115 < \chi^2_{12-1}(0,05) = 19,675 \quad p = 0,765$$

## složená nulová hypotéza

- příklad antigen: souvisí výskyt antigenu A s jistou nemocí?
- četnosti fenotypů  $n_1 = 18$ ,  $n_2 = 17$ ,  $n_3 = 6$
- model pro fenotypy AA, Aa, aa

$$\mathsf{P}(AA) \equiv \pi_1(\theta) = \theta^2$$

$$\mathsf{P}(Aa) \equiv \pi_2(\theta) = 2\theta(1 - \theta)$$

$$\mathsf{P}(aa) \equiv \pi_3(\theta) = (1 - \theta)^2$$

- odhad  $\theta$  minimalizací

$$\begin{aligned}\ell(\theta) &= \log(\mathsf{P}(N_1 = n_1, N_2 = n_2, N_3 = n_3)) \\ &= \log \left( c_1 \left( \theta^2 \right)^{n_1} (2\theta(1 - \theta))^{n_2} \left( (1 - \theta)^2 \right)^{n_3} \right) \\ &= c_2 + (2n_1 + n_2) \log \theta + (n_2 + 2n_3) \log(1 - \theta) \\ \hat{\theta} &= \frac{1}{2} + \frac{N_1 - N_3}{2n} \quad \left( = 0,5 + \frac{18 - 6}{82} = 0,646 \right)\end{aligned}$$

- zamítat pokud ( $q$  počet složek  $\theta$ )

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi(\hat{\theta}))^2}{n\pi(\hat{\theta})} \geq \chi^2_{k-1-q}(\alpha)$$

- antigen:  $\chi^2 = 0,355$ ,  $p = 0,551$

## kontingenční tabulka

- nominální znak s hodnotami  $A_1, \dots, A_r$
- nominální znak s hodnotami  $B_1, \dots, B_c$
- $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$
- **marginální četnosti**

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- **nezávislost** znaků: pro všechna  $i, j$

$$\mathbf{P}(A_i \cap B_j) = \mathbf{P}(A_i)\mathbf{P}(B_j)$$

- teoretické četnosti (protějšek  $N_{ij}$ )

$$o_{ij} = n \cdot \widehat{\mathbf{P}(A_i)} \cdot \widehat{\mathbf{P}(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- $H_0$  : znaky jsou **nezávislé**

$$X^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- nezávislost se zamítá pro  $X^2 \geq \chi^2_{(r-1)(c-1)}(\alpha)$
- musí být  $o_{ij} \geq 5 \ \forall (i, j)$

## příklad **Baden**

barva očí	barva vlasů				celkem
	světlá	hnědá	černá	ryšavá	
modrá	1 768	807	189	47	2 811
šedá/zelená	946	1 387	746	53	3 132
hnědá	115	438	288	16	857
celkem	2 829	2 632	1 223	116	6 800

- barva očí  $r = 3$
- barva vlasů  $c = 4$
- $n = 6800$
- $o_{11} = 2811 \cdot 2829 / 6800 = 1169$
- $o_{12} = 2811 \cdot 2632 / 6800 = 1088$
- $o_{13} = \dots$
- $o_{34} = 116 \cdot 857 / 6800 = 14,62 \geq 5$

$$\begin{aligned}
 \chi^2 &= \frac{(1768 - 1169)^2}{1169} + \frac{(807 - 1088)^2}{1088} + \dots \\
 &= 1073,5 \\
 &> \chi^2_6(0,05) = 12,5916 \\
 p &< 0,0001
 \end{aligned}$$

závislost je na každé rozumné hladině  
**prokázána**

- test **homogeneity**
  - hodnoty znaku  $B_1, \dots, B_c$
  - $r$  **nezávislých** výběrů z různých populací
  - $H_0$ : populace se **neliší**
  - dál stejně jako pro nezávislost
- příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742$$

- $\chi^2_3(0,05) = 7,815$   $p = 0,008$
- nejmenší teoretická četnost:  
 $353 \cdot 63/717 = 31,02 > 5$

## McNemarův test (test symetrie)

- **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- **hypotéza:** pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- hypotézu zamítнемe při  $X^2 \geq \chi^2_{k(k-1)/2}(\alpha)$
- výrazy ve jmenovateli kladné!
- nezávisí na počtu objektů, kdy vyšly oba výsledky stejně

## příklad **stromy**

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- stav týchž stromů ve dvou sezónách
- celkem 100 stromů

$$\chi^2 = \frac{(3 - 7)^2}{3 + 7} + \frac{(3 - 1)^2}{3 + 1} + \frac{(11 - 15)^2}{11 + 15} = 3,215$$

- $\chi^2_3(0,05) = 7,8147$   $p = 0,3597$
- rozdíl mezi sezónami jsme neprokázali

## čtyřpolní tabulka

$a$	$b$	$a + b$
$c$	$d$	$c + d$
$a + c$	$b + d$	$n$

- speciální případ kontingenční tabulky pro  
 $r = c = 2$
- test nezávislosti/homogeneity

$$X^2 = \frac{n(ad - bc)^2}{(a+c)(b+d)(a+b)(c+d)}$$

zamítá se pro  $X^2 \geq \chi_1^2(\alpha) = z(\alpha/2)^2$

- **Yatesova korekce**

$$X_Y^2 = \frac{n(|ad - bc| - n/2)^2}{(a+c)(b+d)(a+b)(c+d)}$$

- **Fisherův faktoriálový (exaktní) test**
  - počítá přímo dosaženou hladinu  $p$
  - malé četnosti nevadí

## příklad **hraboš**

<i>Frenkelia spp.</i>	<i>Sarcocystis spp.</i>		celkem
	+	-	
+	4	27	31
-	11	473	484
celkem	15	500	515

- souvisí spolu nákazy dvěma cizopasníky?
- nulová hypotéza: **nezávislost**

$$\chi^2 = \frac{515(4 \cdot 473 - 11 \cdot 27)^2}{15 \cdot 500 \cdot 31 \cdot 484} = 11,643$$

$p = 0,0006$

- **ale:**  $15 \cdot 31 / 515 = 0,9 < 5$
- **Yates:**  $\chi^2 = 8,187$   $p = 0,0042$
- **Fisherův test:**  $p = 0,0092$
- na 5% hladině závislost **prokázána**
- **vyskytuje se cizopasníci se stejnou pestí?**

McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,0094$$

## **jak použijeme statistiku**

- co o problému zjistili jiní? (přečti, sepiš)
- co chceš zjistit?
  - zformuluj otázku (to určí možné statistické metody)
  - zformuluj nulovou a alternativní hypotézu
- zvol hladinu testu  $\alpha$
- zvol rozsah výběru (požadovaná přesnost, délka int. spolehlivosti, síla testu)
- poříd' data
  - proved' měření (podrobné záznamy!)
  - převeď do elektronické formy (kódování)
  - vyčisti data (grafy, popisné statistiky, . . . )
- proved' výpočty, kresli grafy
- použij výsledky a grafy, interpretuj

## dvojí původ dat

- **plánovaný** (organizovaný) **pokus**
  - aktivně zasahujeme
  - fixujeme okolnosti (stálá teplota, světelný režim)
  - nastavujeme úrovně zvoleného faktoru (dva živné roztoky)
  - jedincům náhodně přiřazujeme ošetření
  - zjistíme-li rozdíl, známe jeho příčinu
- **šetření** (sledování dění)
  - pouze sledujeme, nezasahujeme
  - rozdělení do skupin nemůžeme ovlivnit
  - rozdíl mezi skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem
  - příklad: plánované těhotenství na vzdálení matky, matoucí je věk matky

# jaké úlohy řešíme

- **popsat stav**

- poloha  
(průměr, medián, kvartily, . . .)
- variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
- závislost (korelační koeficient, Spearmanův korelační koeficient)
- tvar rozdělení (šikmost, špičatost)

- **prokázat vliv ošetření**

- změna polohy ( $t$  testy, ANOVA)
- změna variability (Levene,  $F$  test, Bartlettův test)
- jiná změna (Kolmogorov-Smirnov)

- **prokázat závislost**

- obě spojité (korelační koeficient)
- spojitá na kvalitativními (ANOVA)
- obě kvalitativní (kontingenční tabulka)

- **popsat závislost** spojitych – regrese

## výběr metody

- jakou úlohu řešíme?
- jsou výběry nezávislé?
  - z organizace pokusu
- lze předpokládat normální rozdělení?
  - ze zkušenosti
  - lze ověřovat (ve skupinách pozorování, z reziduí)
  - lze soudit z grafu (normální diagram)
- je rozptyl stálý?
  - lze ověřovat (ve skupinách pozorování, z reziduí)
  - lze soudit z grafu (rozptylový diagram)

## volba nulové a alternativní hypotézy

- $H_0$  zjednodušuje model
  - populace se neliší (výběry se liší jen náhodně)
  - veličiny jsou nezávislé
  - $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- $H_1$  je opak nulové hypotézy
  - zpravidla obsahuje tvrzení, které chceme dokázat
  - pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
- pouze zamítnutím  $H_0$  něco dokazujeme

## **některé další modely a metody**

- **diskriminační analýza**

- na každém objektu měříme několik spojitéhých veličin
- známe příslušnost objektů ke skupinám
- DA dá rozhodovací pravidlo pro přiřazování dalších objektů do skupin
- například podle kosterních nálezů určovat pohlaví

- **shluková analýza**

- na každém objektu měříme několik spojitéhých veličin
- konstruujeme skupiny navzájem blízkých (podobných) objektů
- vzniklé skupiny se snažíme interpretovat

## příklad z archeologie (Thurzo 1979)

- trojí pohřebiště (avarško-slovanská, slovanská, maďarská)
- měříme šířku tváře (zy-zy) a míru 8a (sagitální průměr středu diafýzy tibie)
- průměry:

pohřebiště	rozsah	šířka	míra 8a
slovanské	39	122,410	25,615
maďarské	27	127,963	30,471

- varianční matice

$$S = \begin{pmatrix} 25,631 & -0,724 \\ -0,724 & 6,937 \end{pmatrix}$$

- korelační koeficient  $r = -0,054$
- $t$  testy:  $t_1 = -4,381$ ,  $t_2 = -7,380$

## **rozhodovací pravidlo (DA)**

- rozhodujeme mezi dvěma pohřebišti
- stejné pesti obou populací
- ke slovanským přiřadí, když

$$0,237 \text{ šířka} + 0,726 \text{ míra } 8a < 50,069$$

- k maďarským když

$$0,237 \text{ šířka} + 0,726 \text{ míra } 8a > 50,069$$

- špatně zařazeno:
  - pouze 7 z 39 slovanských (17,9 %)
  - pouze 3 z 27 maďarských (11,1 %)
- při očekávaném poměru 4:1 ve prospěch slovanské populace bude ke slovanským pohřebištím přiřazena žena, když

$$0,237 \text{ šířka} + 0,726 \text{ míra } 8a < 51,446$$

## **rozlišení pohřebišť (shluky)**

- každé pohřebiště a pohlaví charakterizujeme průměrnou hodnotou čtyř veličin (ještě výška a délka lebky (g-op))
- pro těchto šest čtveric se spočítá **vzdálenost**
- postupně se vytvářejí skupinky nejbližších, pak jejich vzdálenost
- grafické znázornění – **dendrogram**
- vzdálenost (nepodobnost)
  - euklidovská
  - Mahalanobisova (uváží závislosti)
  - 1-korelační koeficient
- vzdálenost skupin
  - těžiště
  - nejbližší prvky
  - nejvzdálenější prvky