

# Základy pravděpodobnosti a matematické statistiky

## 8. Úvod do matematické statistiky



# **8. Úvod do matematické statistiky**

# Náhodný vektor

Uvažujme zobrazení  $\vec{X} : \Omega \rightarrow \mathbb{R}^n$  - náhodný vektor

$$\vec{X} = (X_1(\omega), X_2(\omega), \dots, X_n(\omega)) = (X_1, X_2, \dots, X_n)$$

**Pravděpodobnostní charakteristiky náhodného vektoru:**

- sdružená distribuční funkce

$$F(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$$

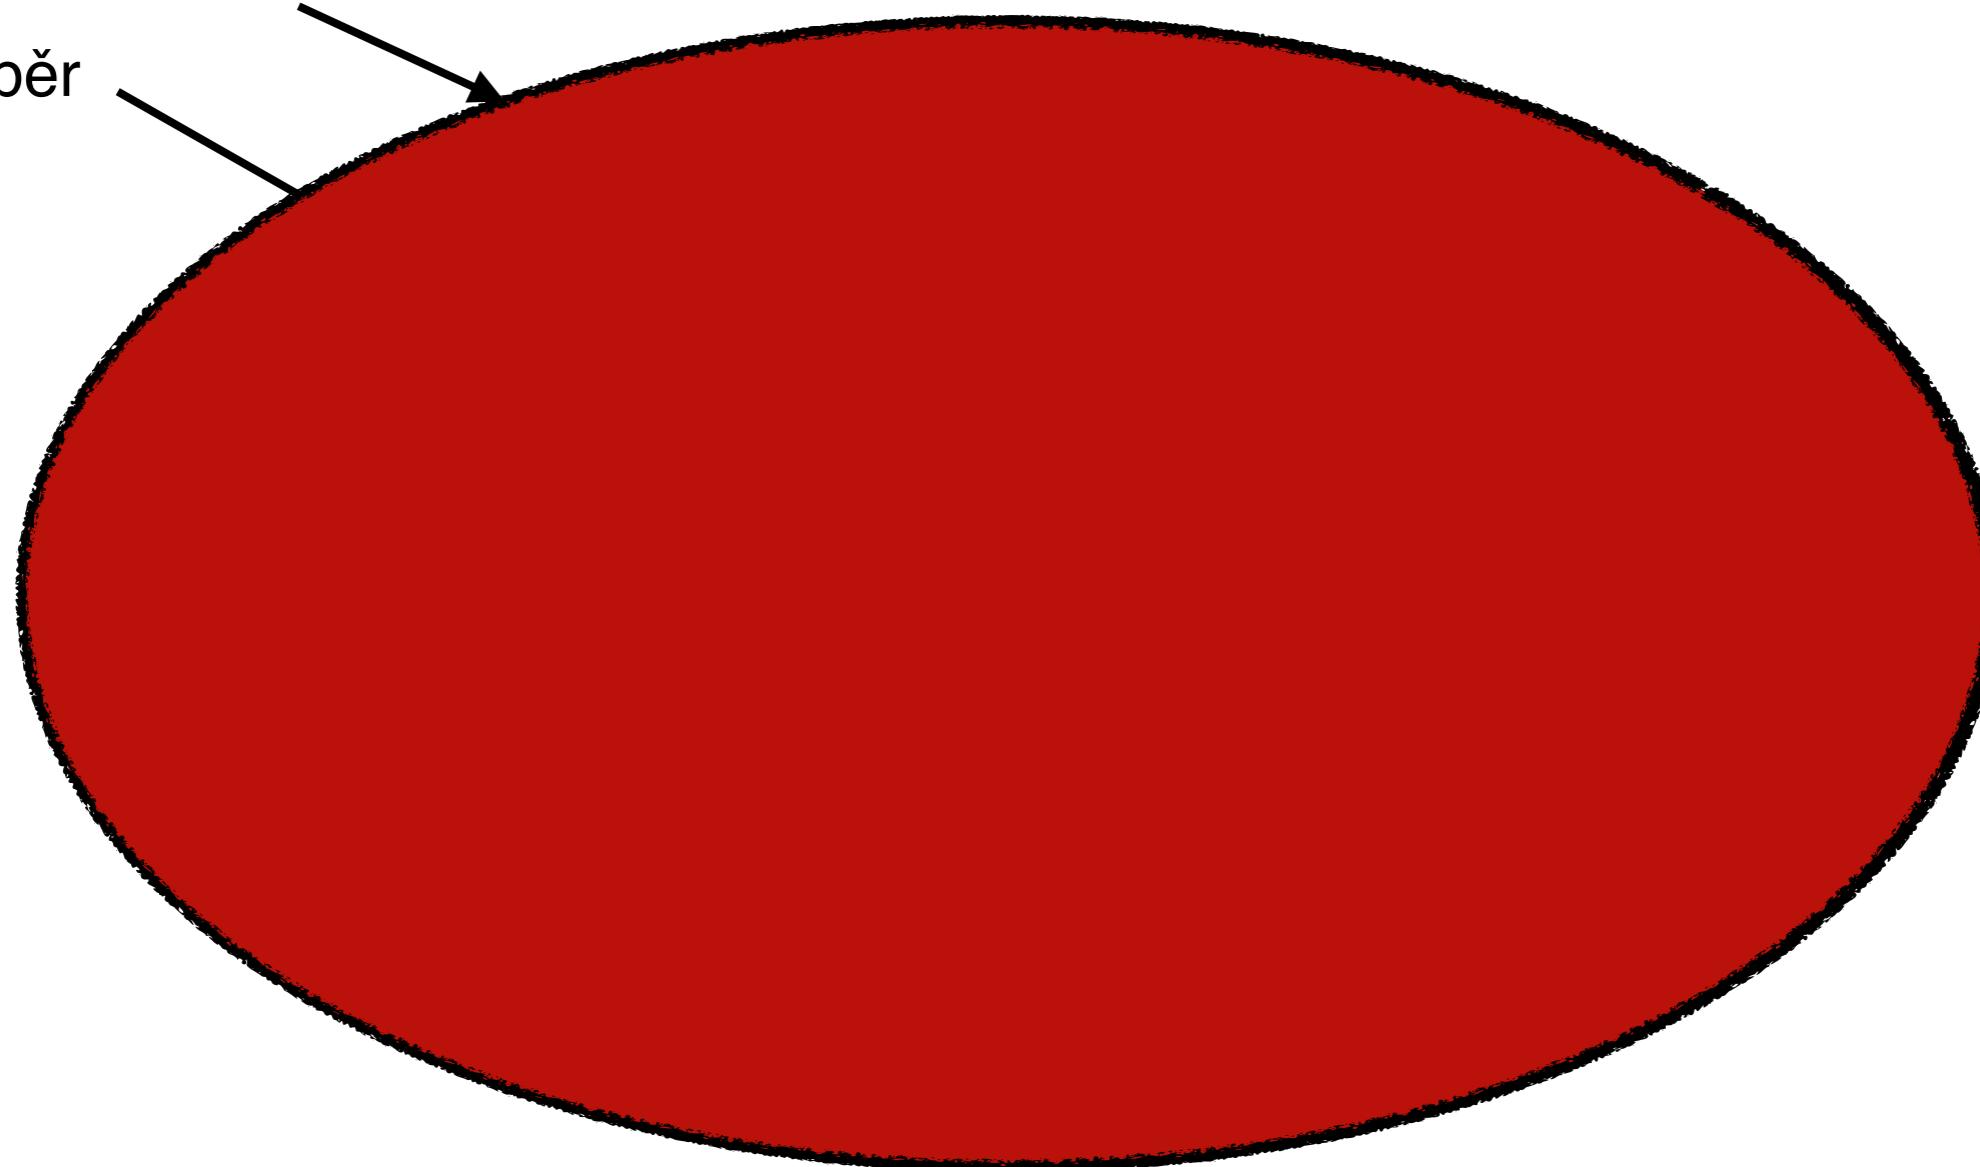
$$\lim_{x_n \rightarrow \infty} F(x_1, x_2, \dots, x_n) = F(x_1, x_2, \dots, x_{n-1})$$

$$\lim_{x_n \rightarrow -\infty} F(x_1, x_2, \dots, x_n) = 0$$



# Statistická indukce

- Základní soubor - nositel sledovaného znaku (veličiny)
- Výběr



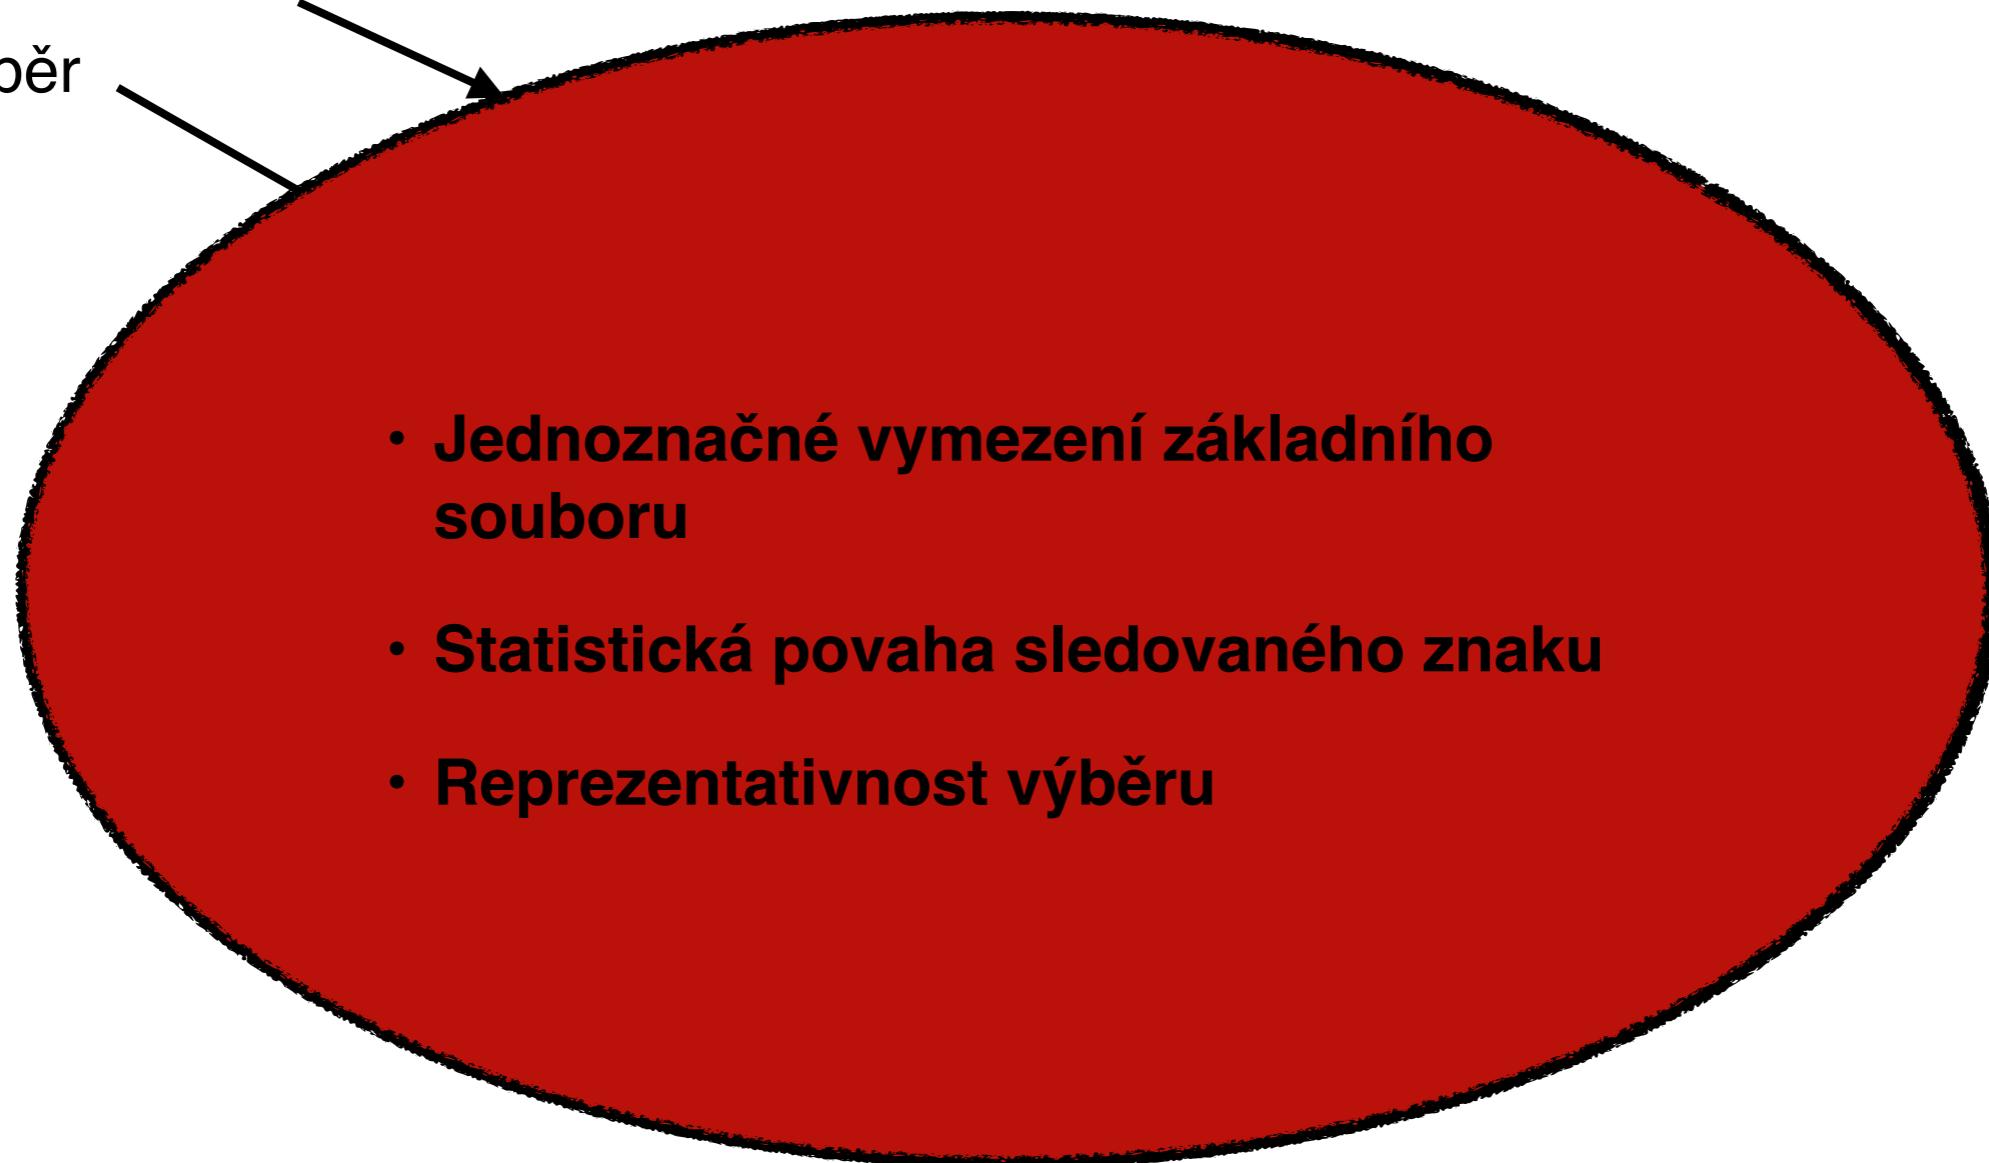
- Pozorování výběru  
(měření sledovaného znaku) => Zjištění vlastností výběru
- Zobecnění na celý základní soubor



# Statistická indukce

- Základní soubor - nositel sledovaného znaku (veličiny)

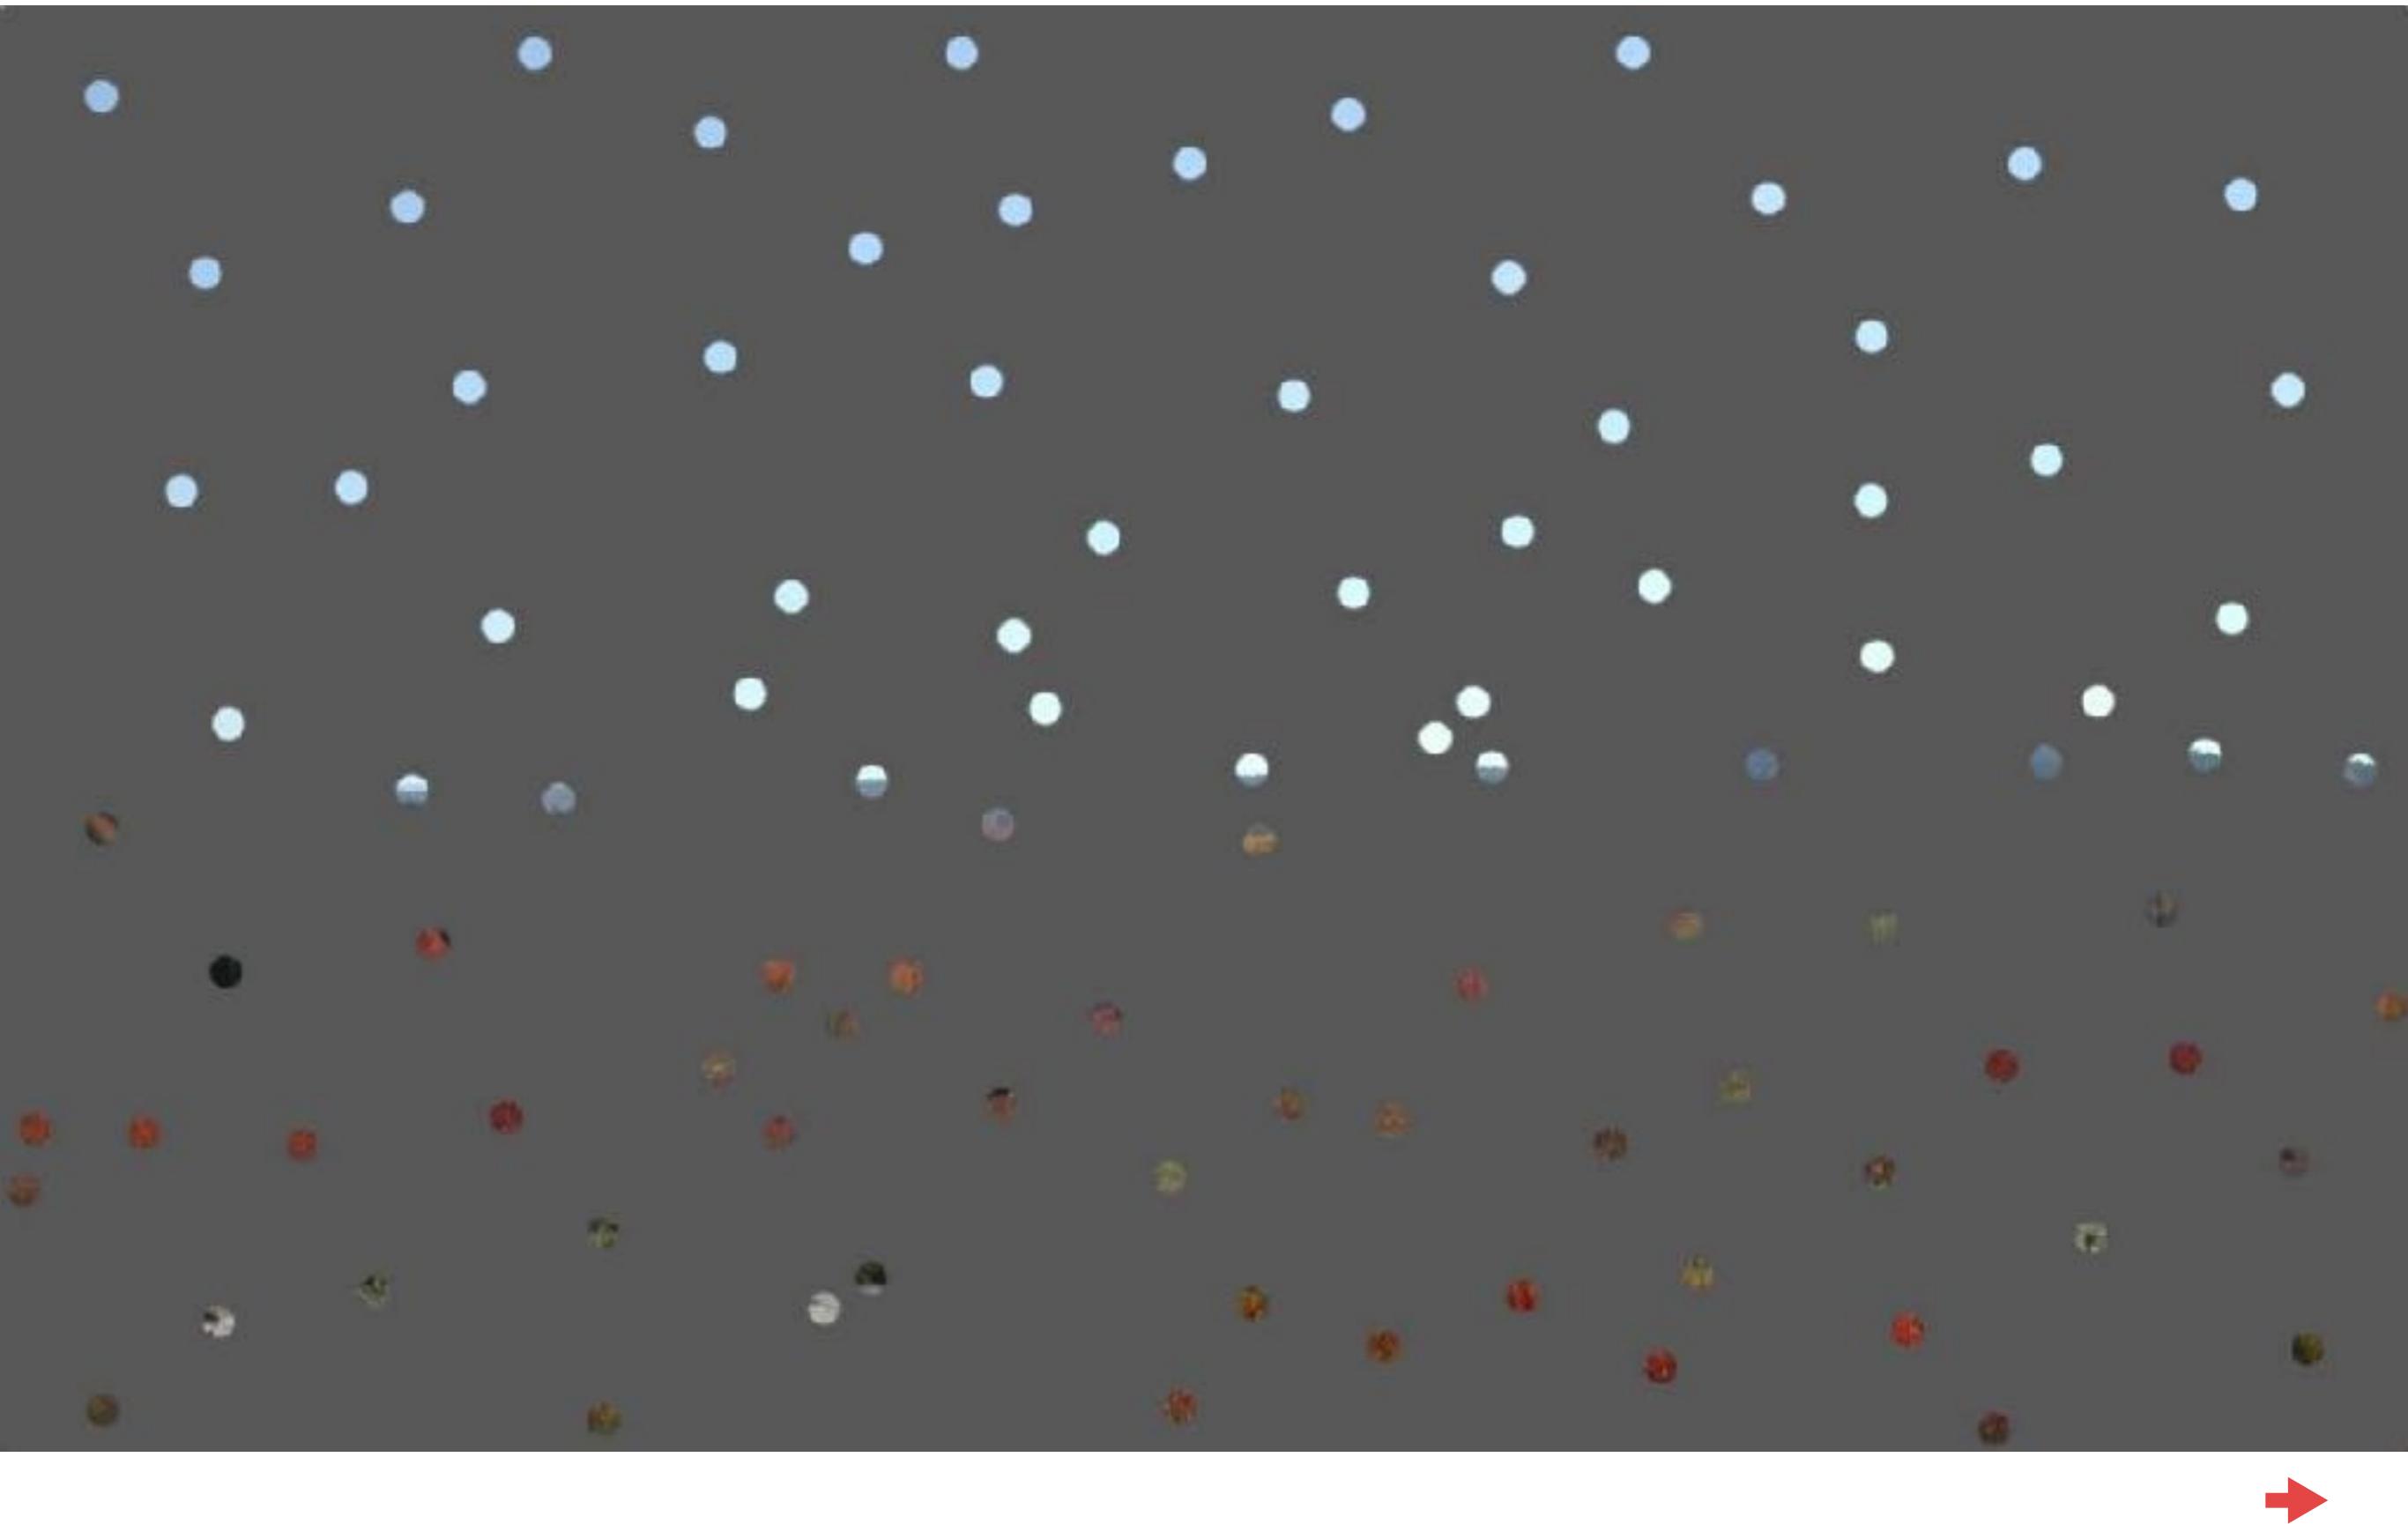
- Výběr



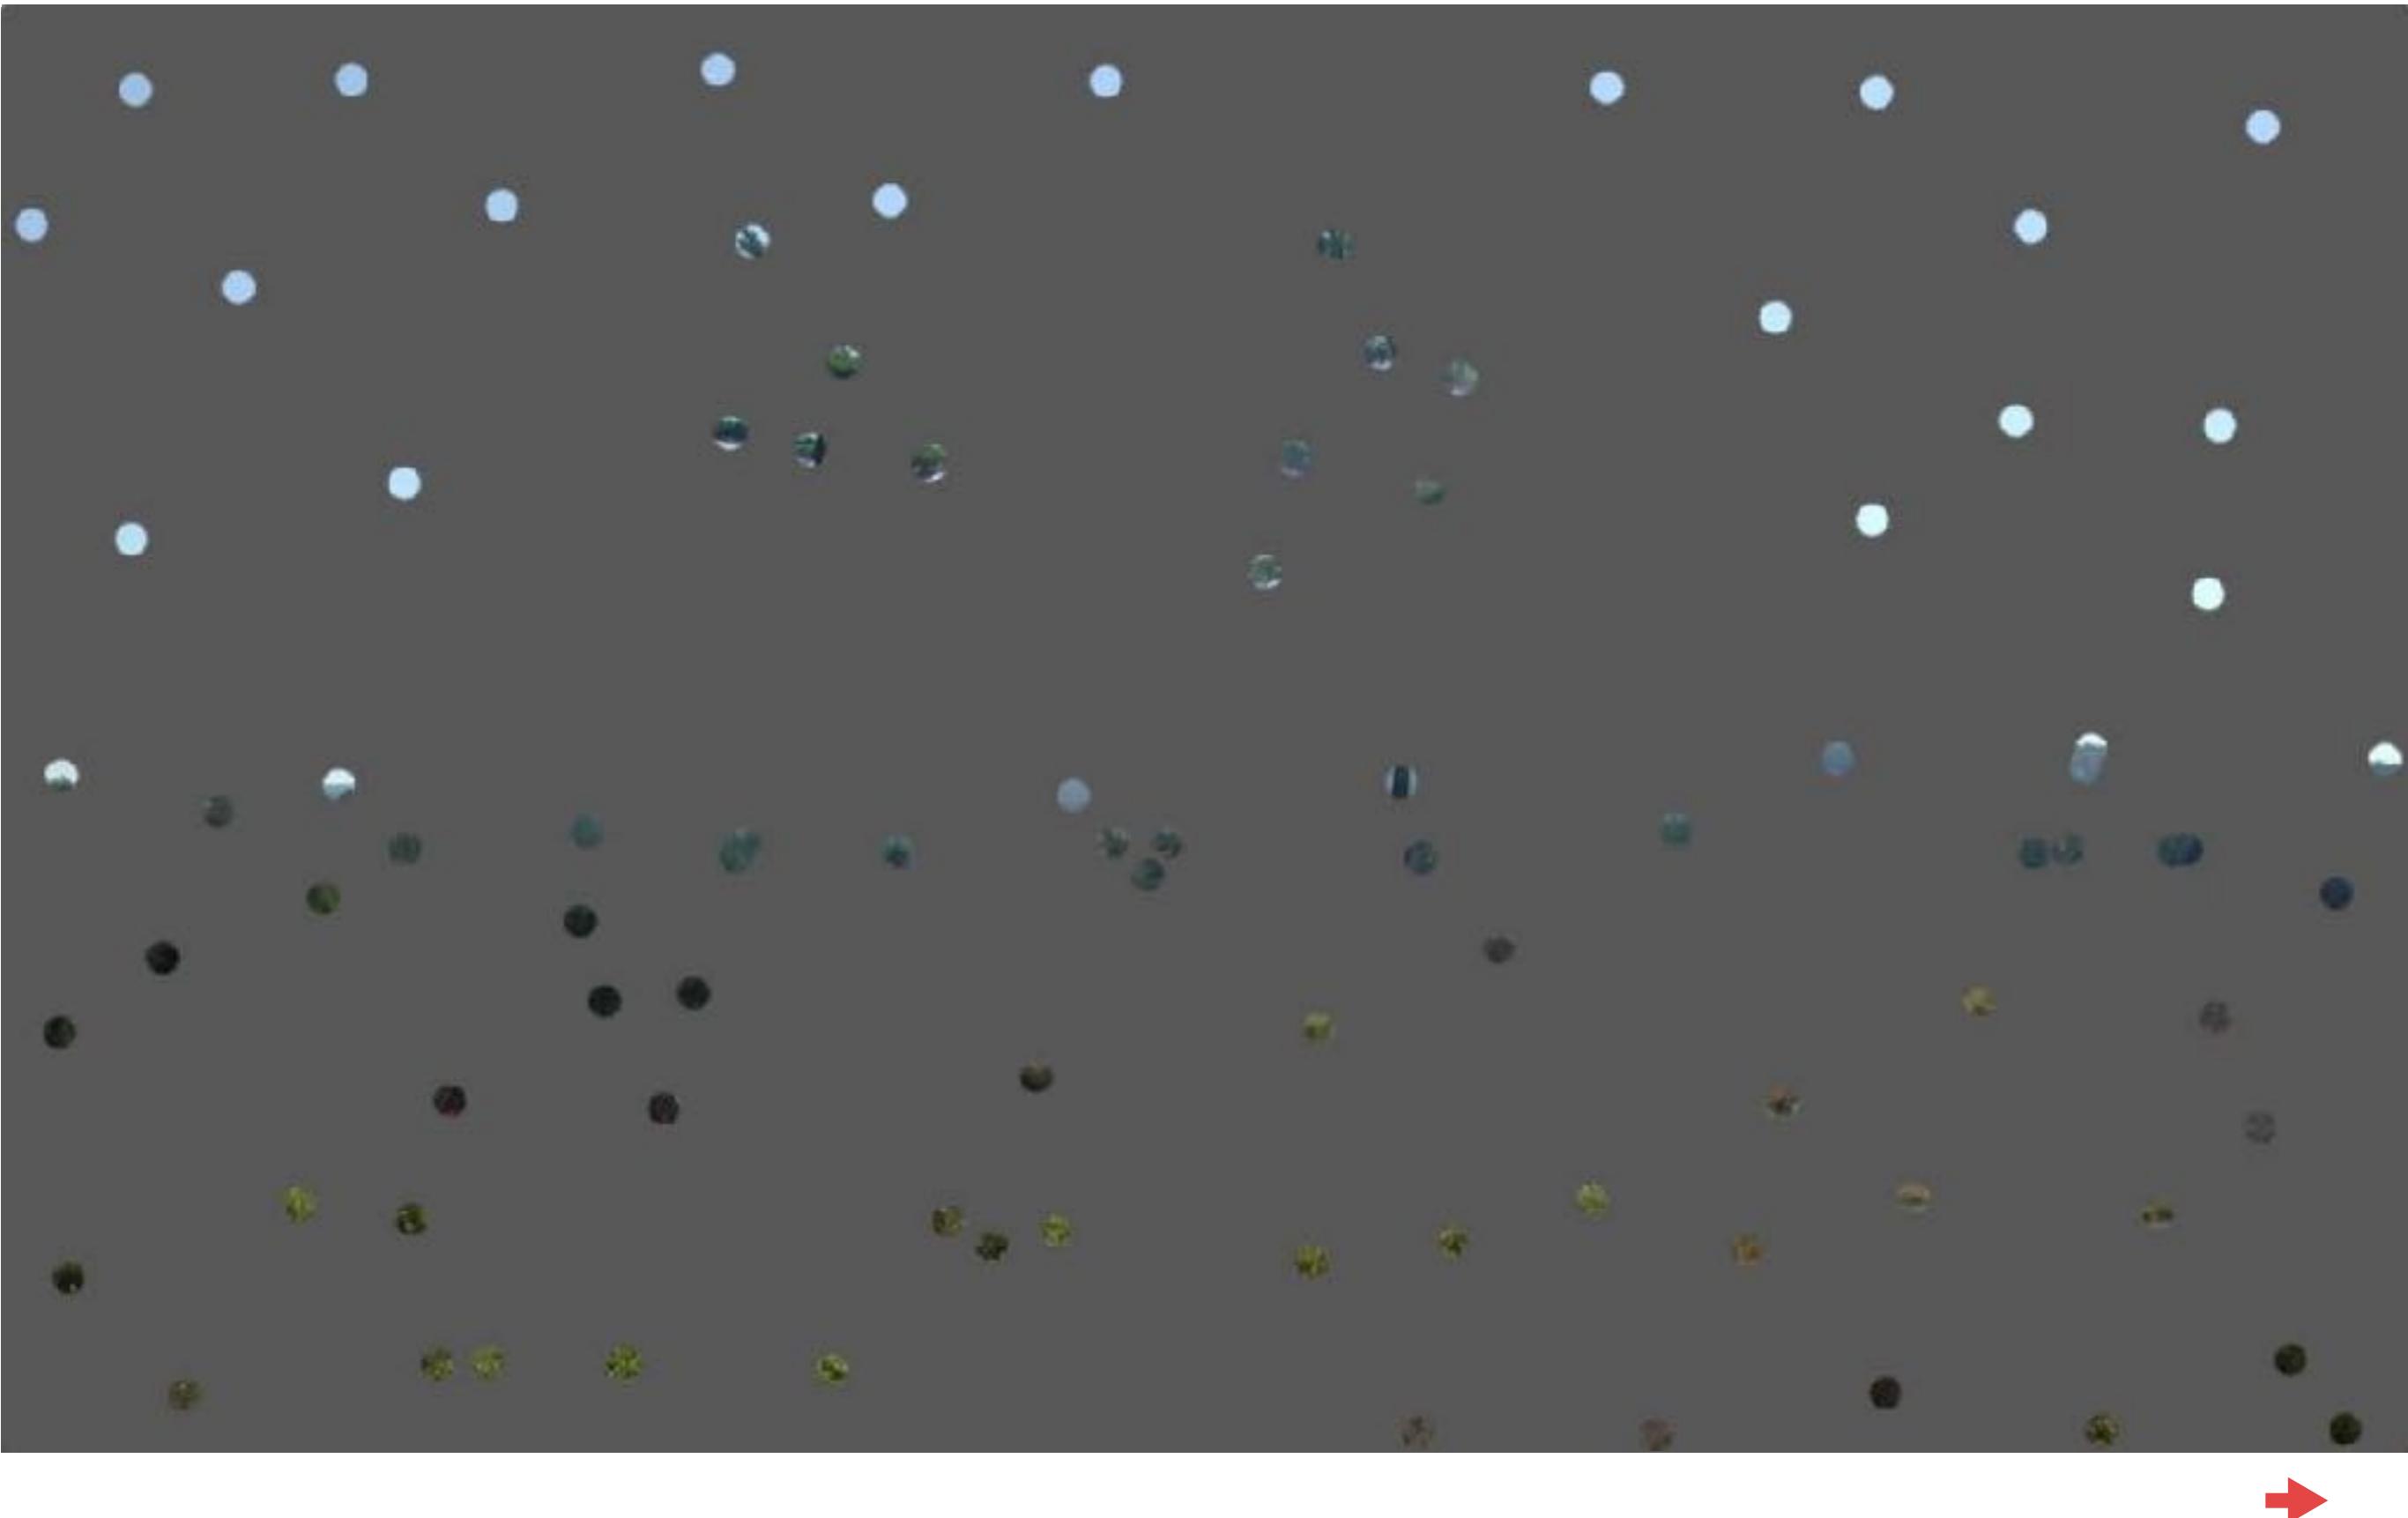
- Pozorování výběru  
(měření sledovaného znaku) => Zjištění vlastností výběru
- Zobecnění na celý základní soubor



# Statistická indukce



# Statistická indukce



# Statistická indukce



# Statistická indukce

Tedy vždy musíme vycházet z :

- náhodného výběru  $X_1, X_2, \dots, X_n$
- a jeho pozorování  $x_1, x_2, \dots, x_n$ .

náhodné veličiny

reálná čísla

| Pravděpodobnostní charakteristiky                           | Výběrové charakteristiky   |
|---|--|
| Střední hodnota<br>$E(X) = \int_{-\infty}^{\infty} xf(x)dx$ | Výběrový průměr<br>$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$              |
| Momenty<br>$\mu_k(X) = E(X - E(X))^k$                       | Výběrové momenty<br>$m_k(X) = \sum_{i=1}^n (x_i - \bar{X})^k$            |
| Rozptyl<br>$var(X) = E(X - E(X))^2$                         | Výběrový rozptyl<br>$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2$ |
| Kvantity<br>$\tilde{x}_{100\alpha}$                         | Výběrové kvantity<br>$X_{([np]+1)}$                                      |



# Statistické charakteristiky

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$  výběru  $X_1, X_2, \dots, X_n$ .

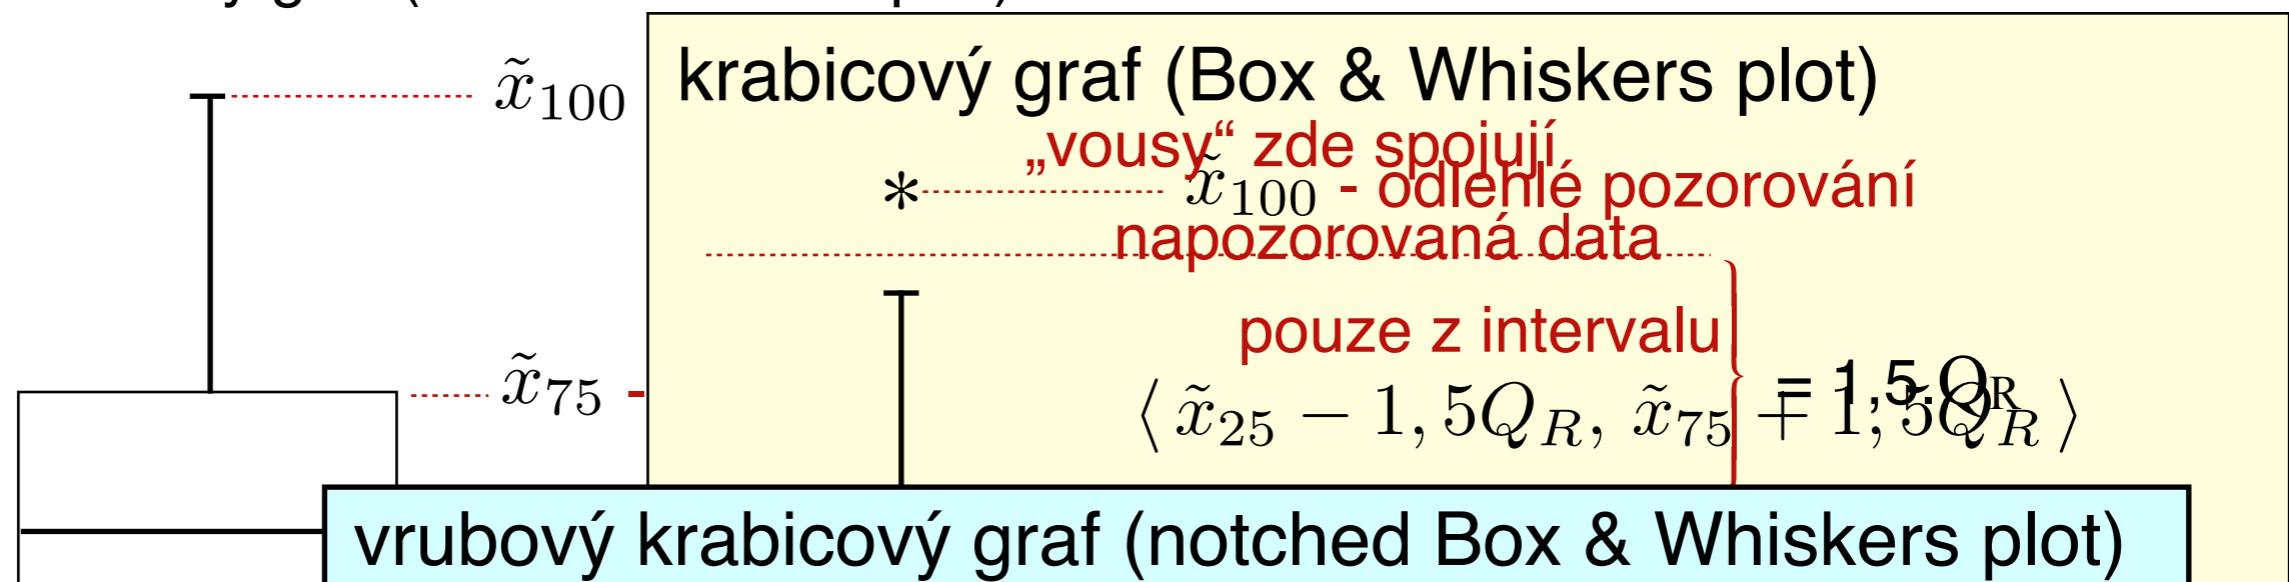
- *Uspořádaný výběr:*  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$  vznikne z původního výběru  $X_1, X_2, \dots, X_n$  uspořádáním podle velikosti pozorovaných hodnot  $x_1, x_2, \dots, x_n$ .
- *Pořadová statistika:*  $X_{(k)}$  je náhodná veličina  $X_m$ , která je  $k$ -tá v pořadí podle velikosti pozorovaných hodnot  $x_1, x_2, \dots, x_n$ . Index  $k$  nazýváme *pořadím veličiny*  $X_m$  a zapisujeme to  $R_m = k$ .
- Statistika  $X_{(1)}$  se nazývá minimum,  $X_{(n)}$  je maximum
- medián  $\tilde{x}_{50}$ : je-li  $n$  liché, je roven  $X_{([n/2]+1)}$   
pro  $n$  sudé je roven  $(X_{(n/2)} + X_{(n/2+1)})/2$
- dolní kvartil  $\tilde{x}_{25}$ :  $X_{([n/4]+1)}$  resp.  $(X_{(n/4)} + X_{(n/4+1)})/2$
- horní kvartil  $\tilde{x}_{75}$ :  $X_{([3n/4]+1)}$  resp.  $(X_{(3n/4-1)} + X_{(3n/4)})/2$



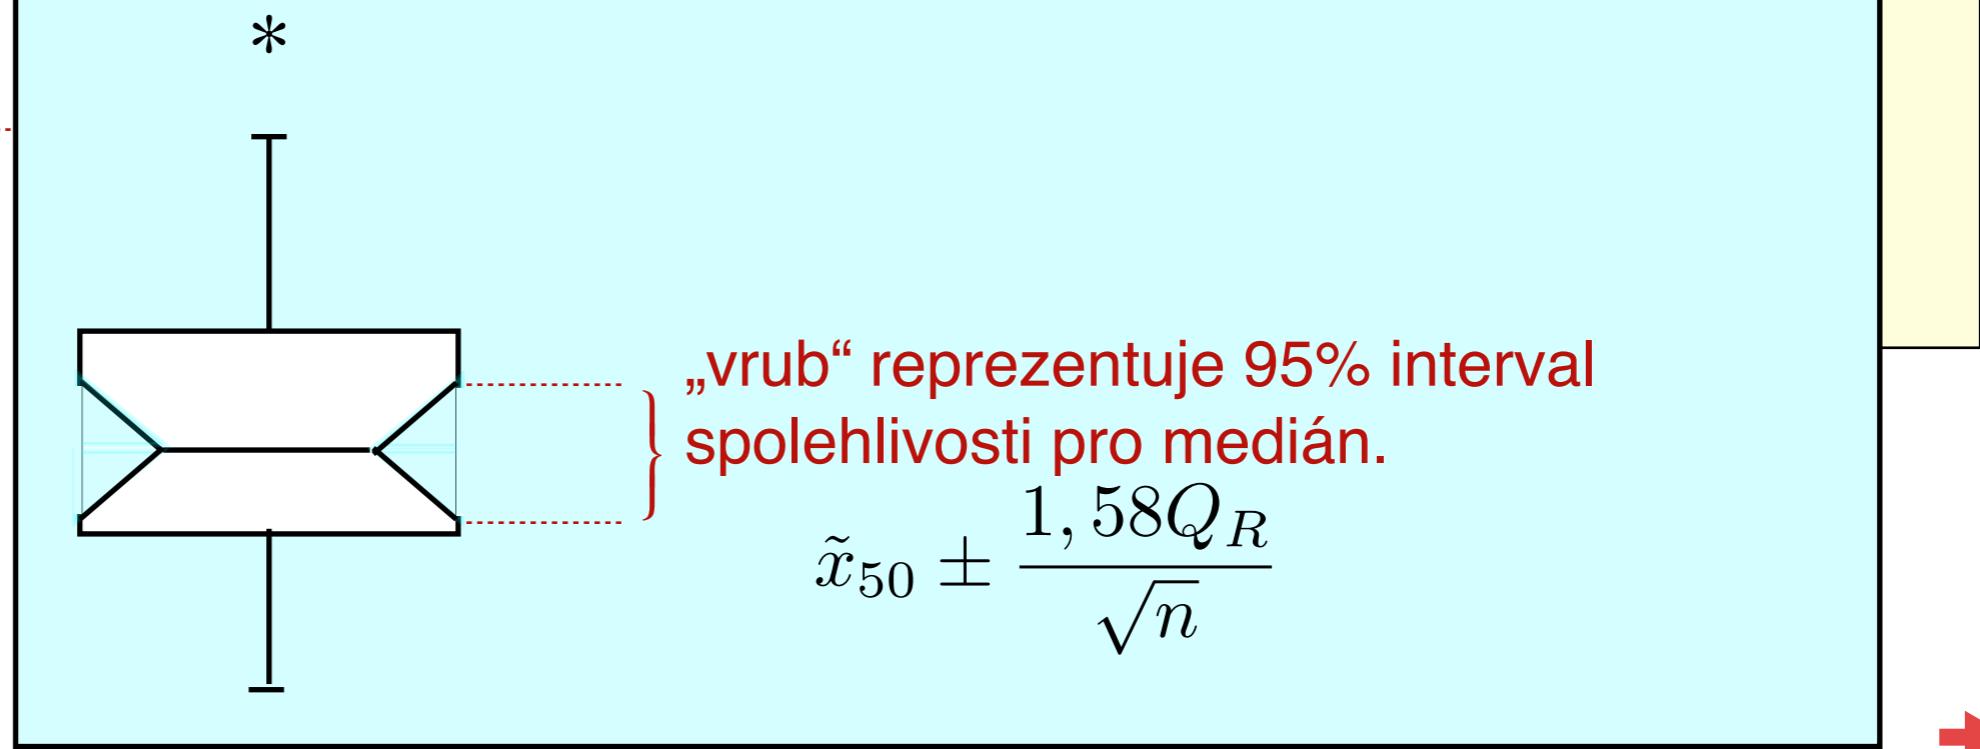
# Statistické charakteristiky

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$  výběru  $X_1, X_2, \dots, X_n$ .

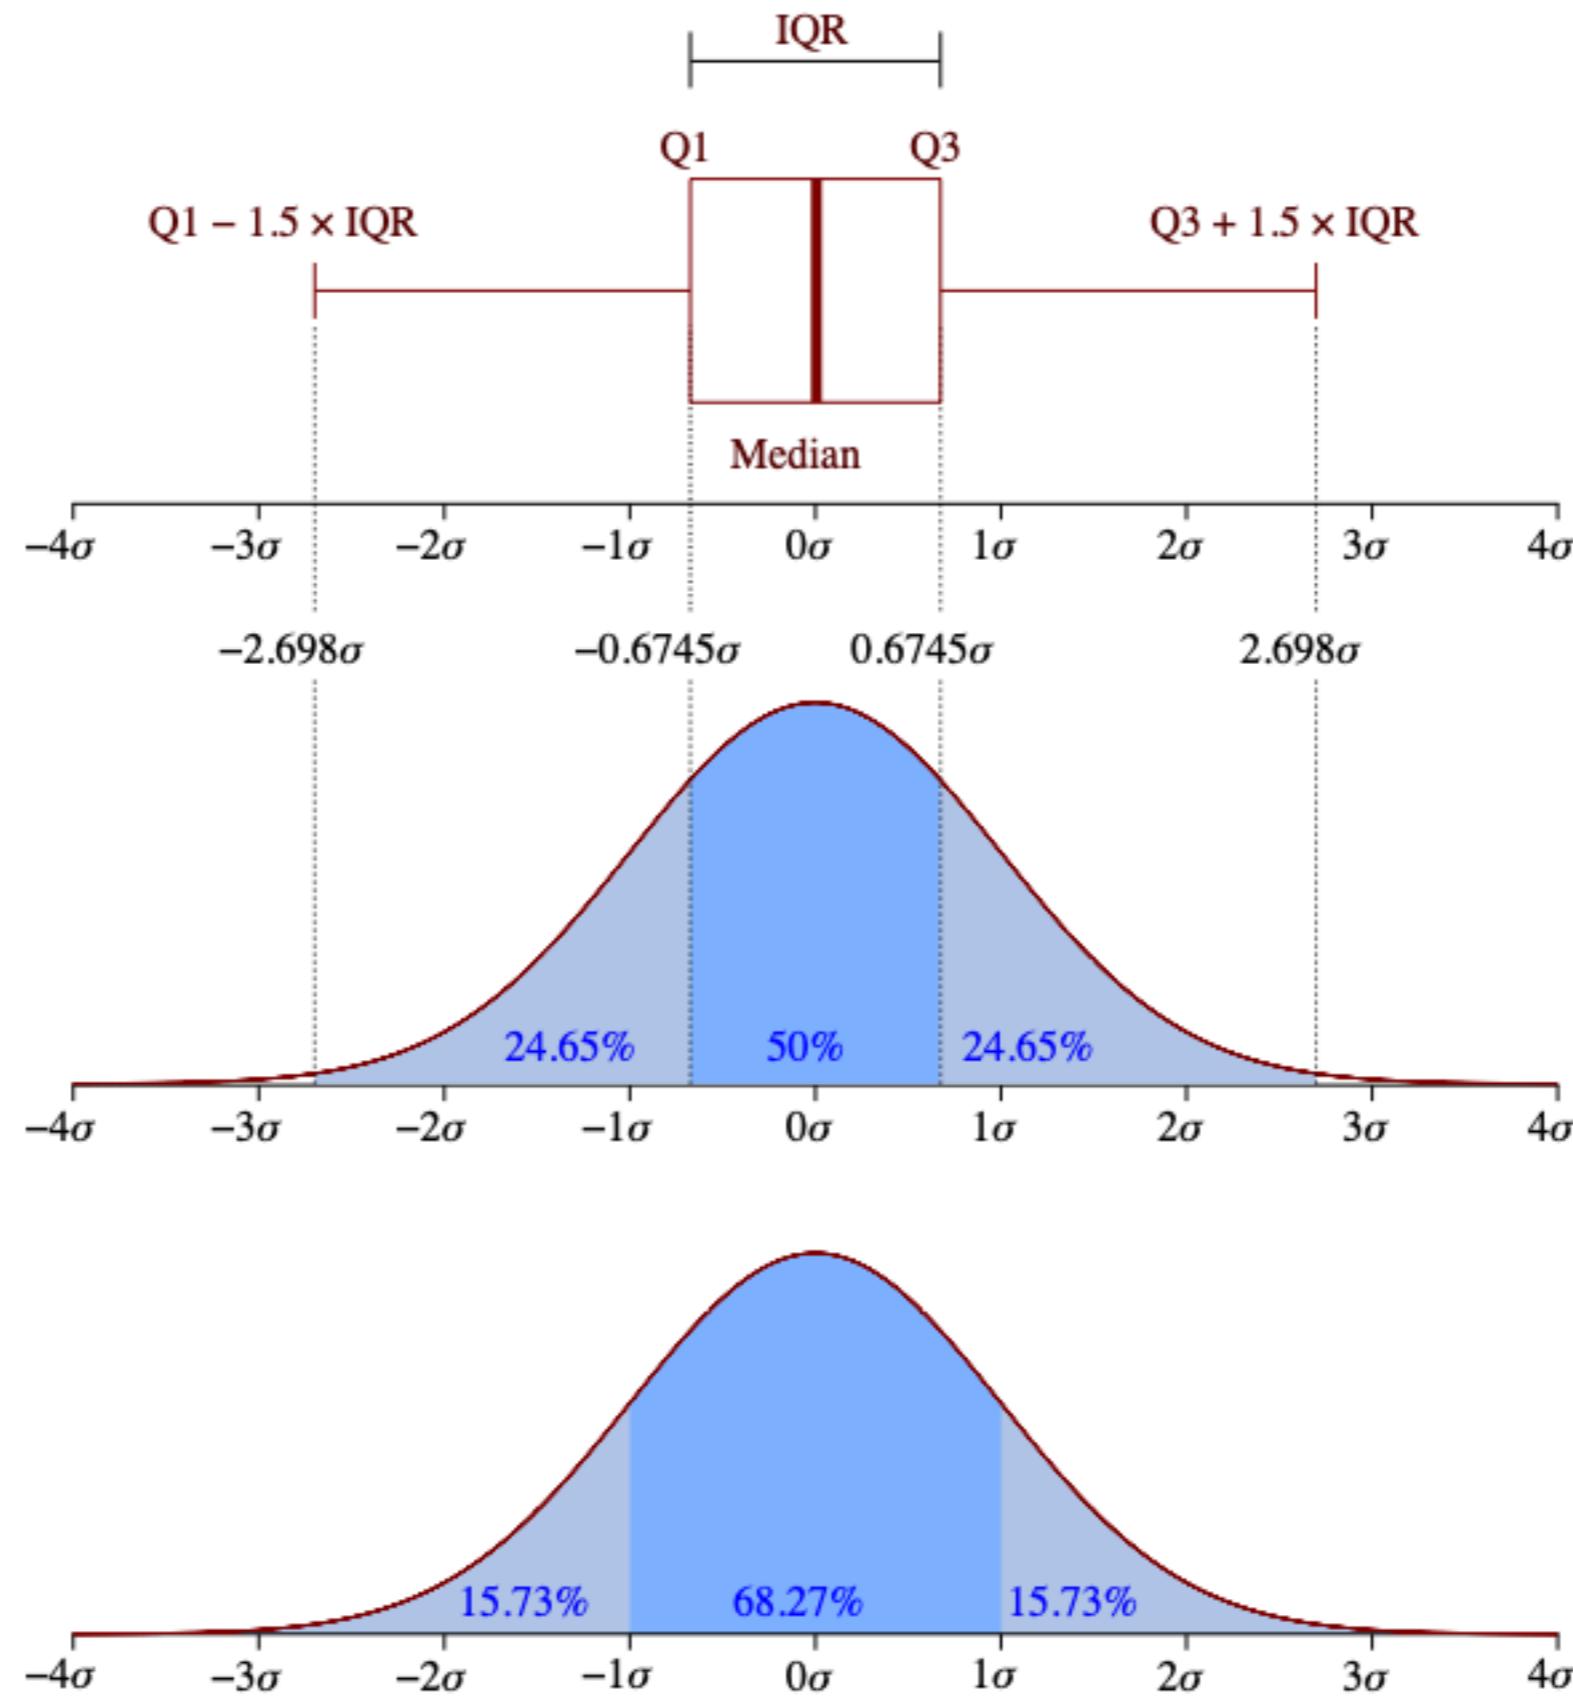
krabicový graf (Box & Whiskers plot)



vrubový krabicový graf (notched Box & Whiskers plot)

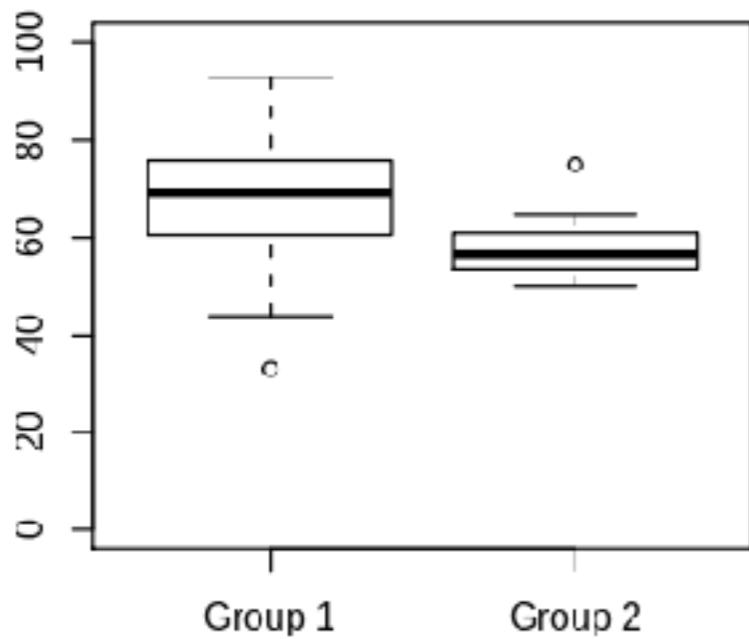


# Statistické charakteristiky

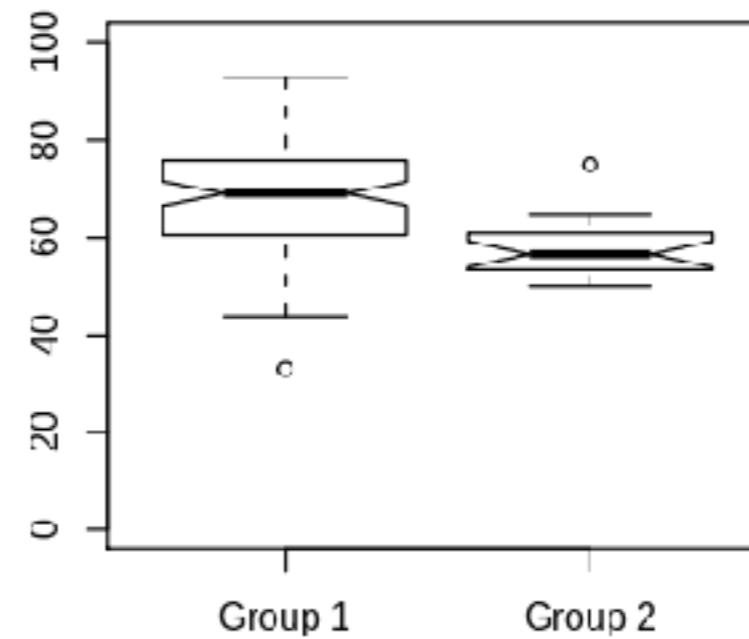


# Statistické charakteristiky

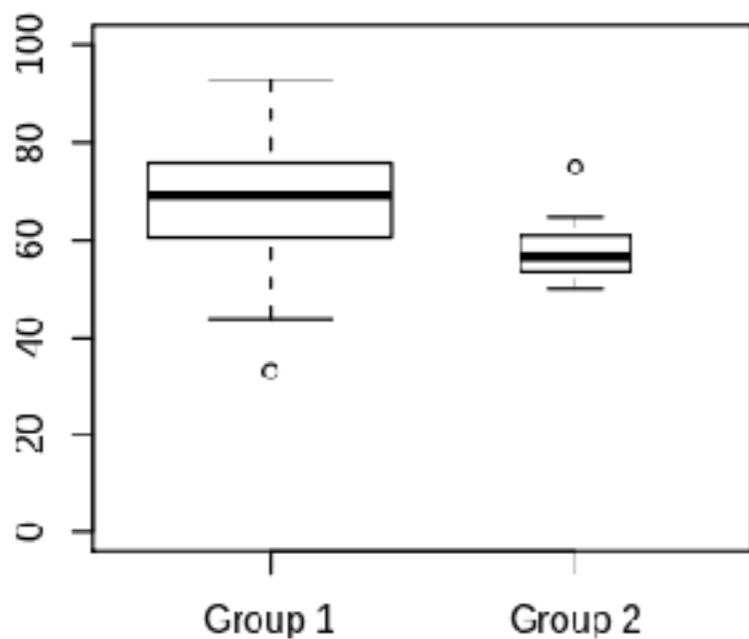
**Traditional Box Plot**



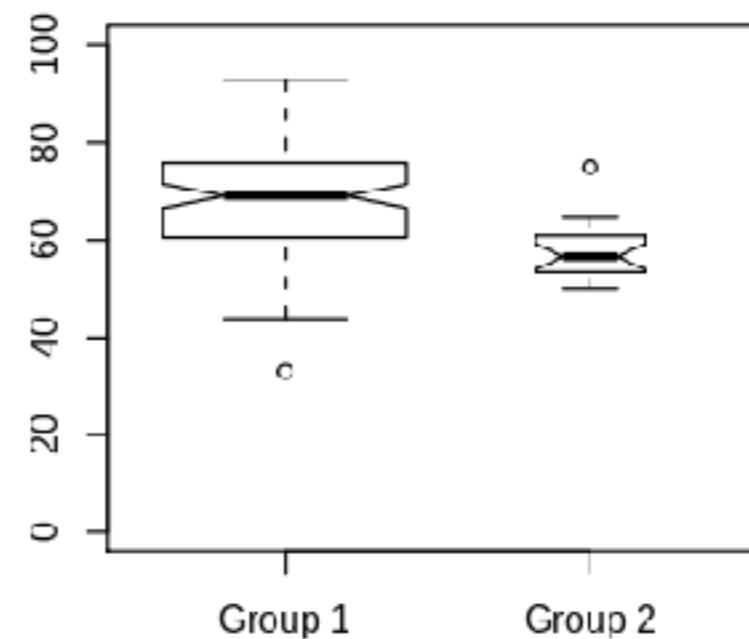
**Notched Box Plot**



**Variable Width Box Plot**



**Variable Width Notched Box Plot**



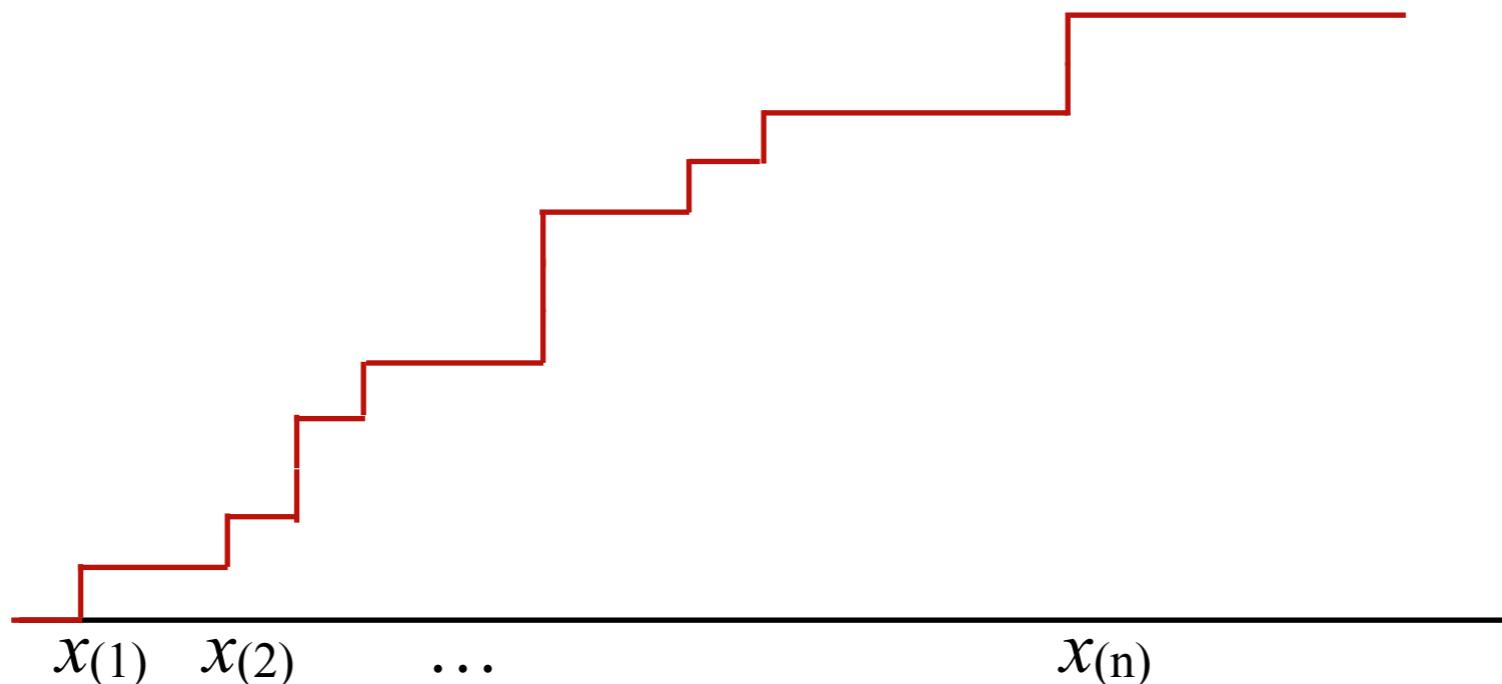
# Statistické charakteristiky

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$  výběru  $X_1, X_2, \dots, X_n$ .

*Empirická distribuční funkce:*

vycházíme z uspořádaného výběru:  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ . Potom  $F_n(x_{(i)}) = \frac{i}{n}$

a tedy  $F_n(x) = \frac{\max\{k : X_{(k)} \leq x\}}{n}, \quad x \in \mathbf{R}$



# Statistické charakteristiky

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$  výběru  $X_1, X_2, \dots, X_n$ .

- Výběrová střední hodnota (výběrový průměr):  $\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$
- Výběrové momenty:  $m_k(X) = \sum_{i=1}^n (x_i - \bar{X})^k$
- Výběrový rozptyl:  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2$  a výběrová směrodatná odchylka  $s$

Za předpokladu, že náhodný výběr je nezávislý a je z normálního rozdělení, t.j.  $X_1, X_2, \dots, X_n$  jsou i.i.d. a  $X_k \sim N(\mu, \sigma^2)$ ,  $k = 1, 2, \dots, n$ , lze určit rozdělení pravděpodobnosti některých charakteristik:

- Pokud je  $\mu$  a  $\sigma^2$  známé, má výběrový průměr  $\bar{X}_n$  rozdělení  $N(\mu, \sigma^2/n)$
- Pokud  $\mu$  a  $\sigma^2$  neznáme, má veličina  $T = (X - \bar{X})/s$  tzv. Studentovo neboli  $t$ -rozdělení  $t(n-1)$
- Veličina  $S^2 = (n-1).s^2/\sigma^2$  má  $\chi^2(n-1)$  rozdělení (o  $n-1$  stupních volnosti)



# Statistické charakteristiky

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$  výběru  $X_1, X_2, \dots, X_n$ .

Další důležité výběrové charakteristiky:

- Výběrová šikmost (skewness):  $Skew(X) = \frac{m_3(X)}{m_2^{3/2}(X)}$
- Výběrová špičatost (kurtosis):  $Kurt(X) = \frac{m_4(X)}{m_2^2(X)} - 3$

pro  $X \sim N(\mu, \sigma^2)$  je  $E(Skew(X)) = 0$   $var(Skew(X)) = \frac{6(n-2)}{(n+1)(n+3)}$

$$E(Kurt(X)) = -\frac{6}{n+1} \quad var(Kurt(X)) = \frac{24n(n-2)(n-3)}{(n+1)^2(n+3)(n+5)}$$

Máme-li dostatečný počet pozorování (řádově stovky), mají statistiky

$$T_3 = \frac{S_{kew}^{norm}}{\sqrt{Var(S_{kew}^{norm})}} \quad T_4 = \frac{K_{urt}^{norm} - E(K_{urt}^{norm})}{\sqrt{Var(K_{urt}^{norm})}}$$

přibližně standardní normální rozdělení pravděpodobnosti.



# Frekvenční analýza - analýza četnosti

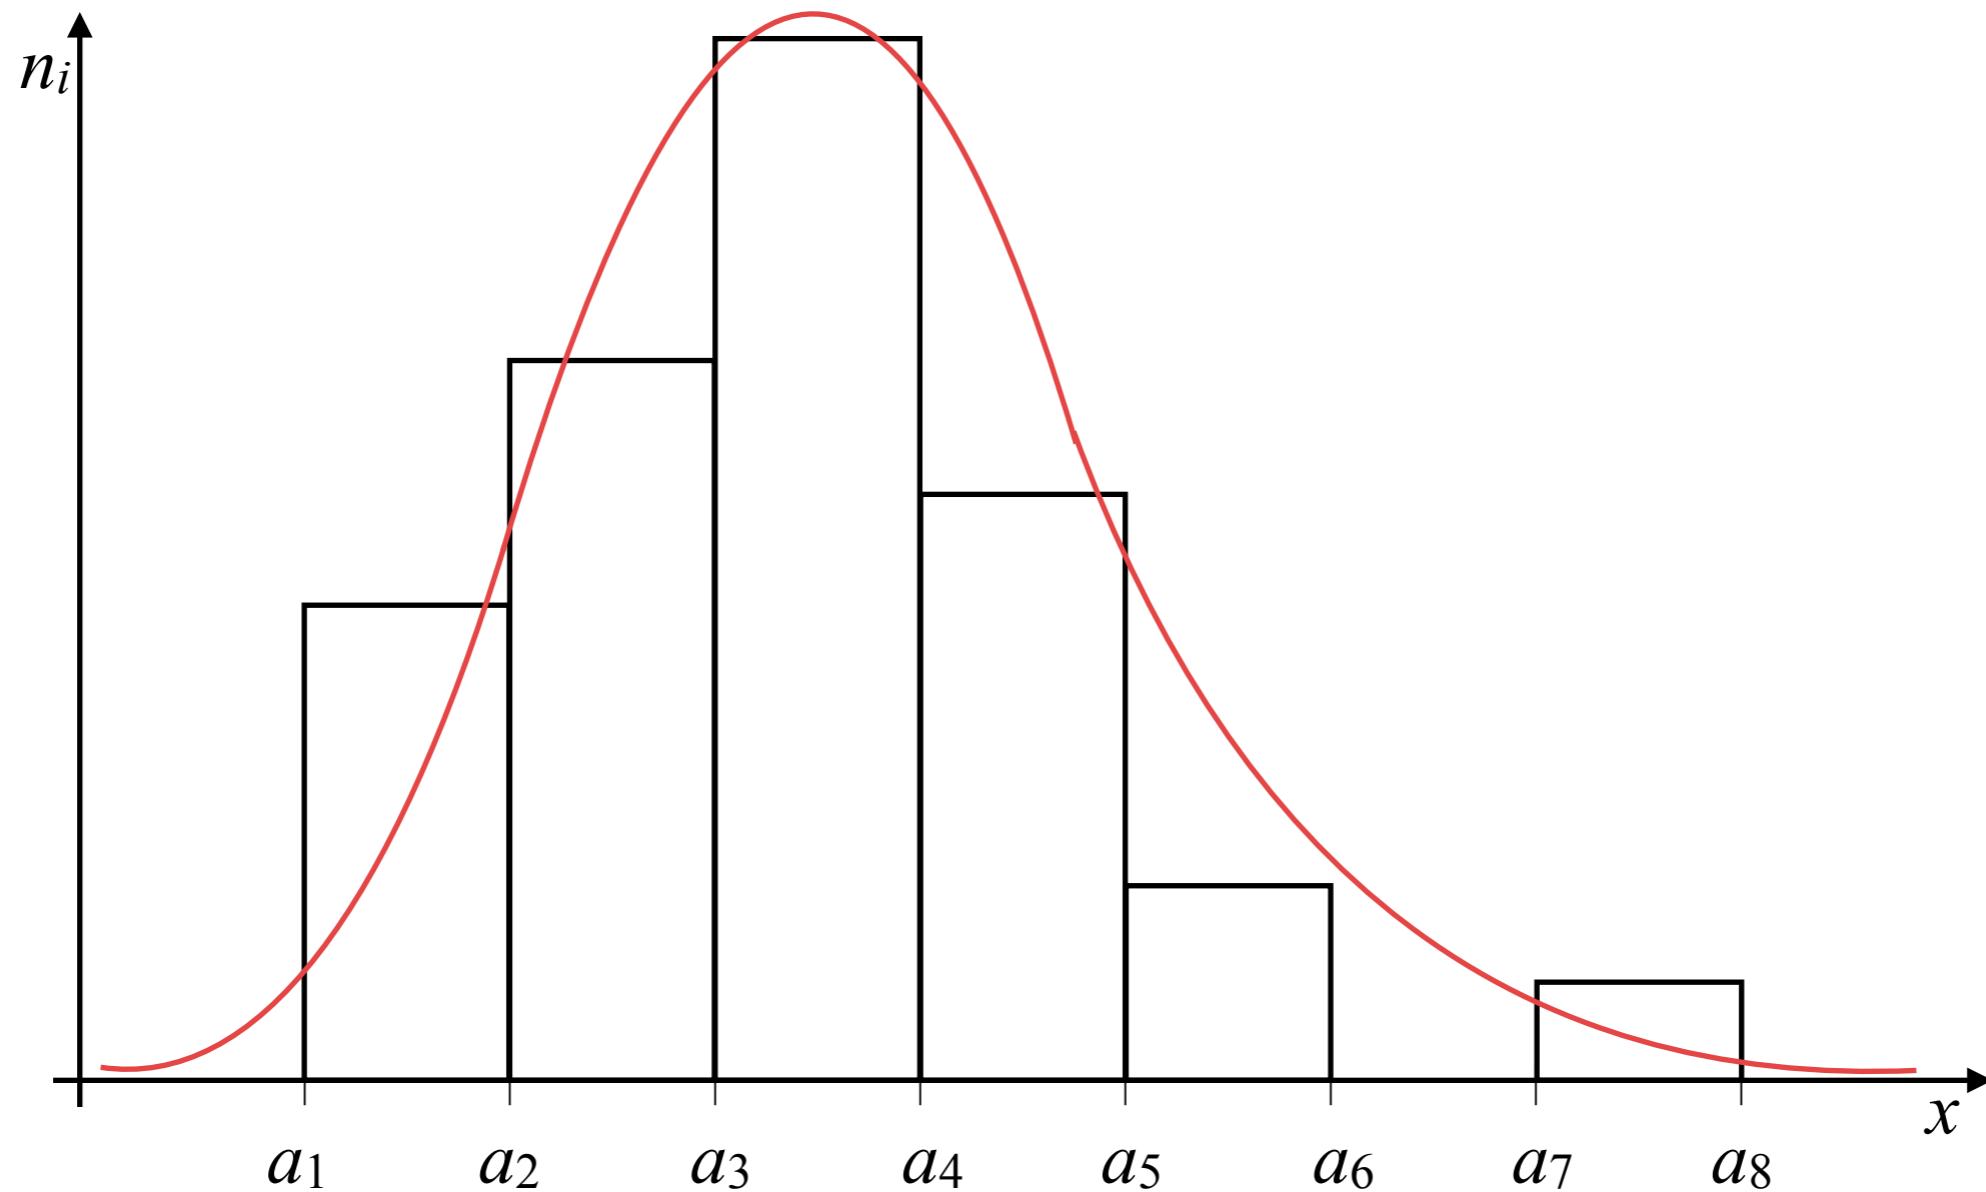
Máme pozorování  $x_1, x_2, \dots, x_n$  náhodného ýběru  $X_1, X_2, \dots, X_n$ .

| pořadí třídy | třídní intervaly | (prosté) absolutní četnosti | (prosté) relativní četnosti | kumulativní četnosti     | kumulativní relativní četnosti |
|--------------|------------------|-----------------------------|-----------------------------|--------------------------|--------------------------------|
| 1            | $a_2 - a_1$      | $n_1$                       | $f_1 = n_1/n$               | $c_1 = n_1$              | $d_1 = c_1/n$                  |
| 2            | $a_3 - a_2$      | $n_2$                       | $f_2 = n_2/n$               | $c_2 = n_1 + n_2$        | $d_2 = c_2/n$                  |
| :            | :                | :                           | :                           | $c_j = \sum_{i=1}^j n_i$ | :                              |
| $k$          | $a_k - a_{k-1}$  | $n_k$                       | $f_k = n_k/n$               | $c_k = n$                | $d_k = c_k/n = 1$              |



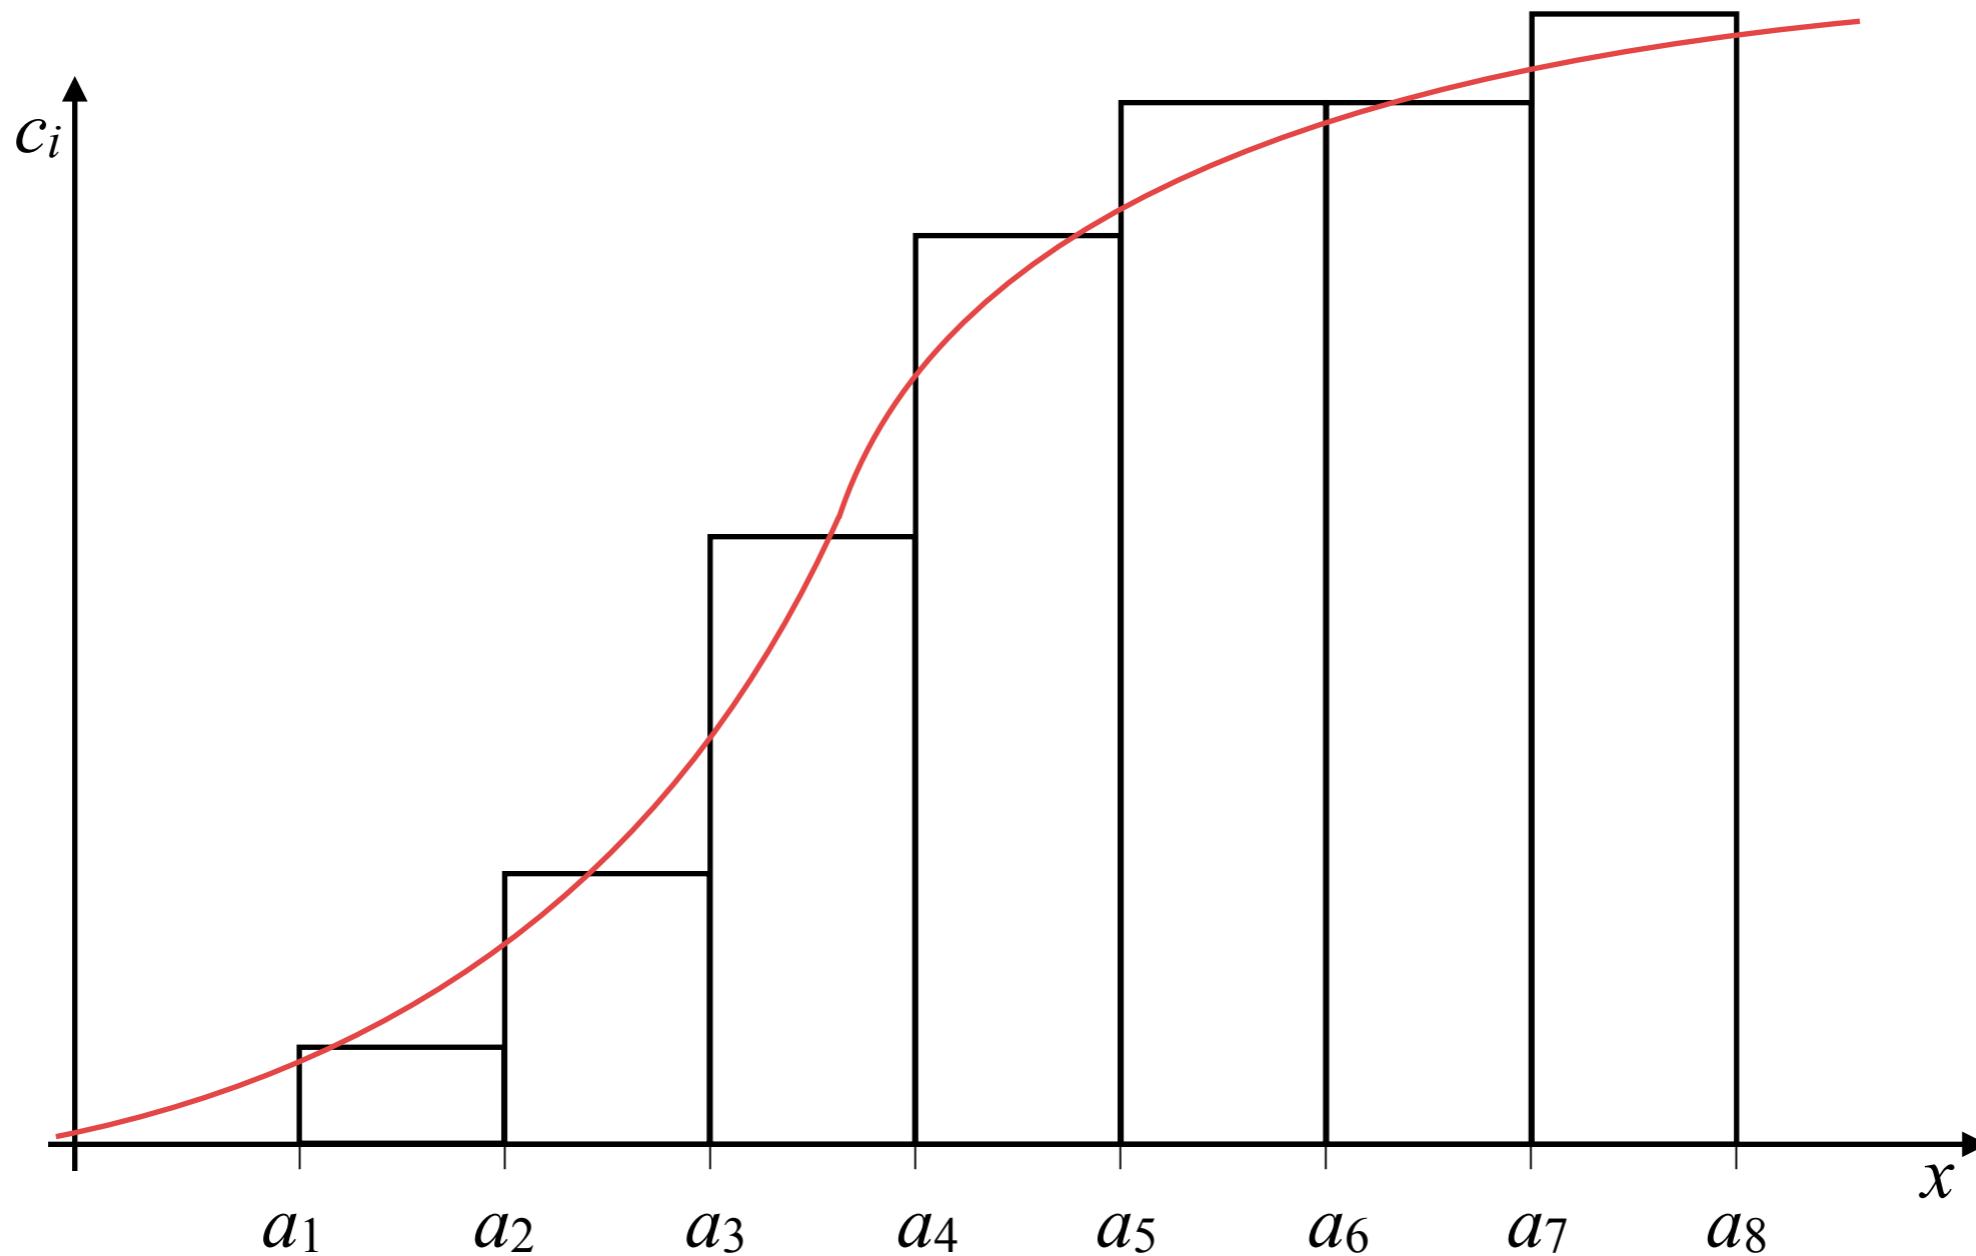
# Frekvenční analýza - histogram četností

Máme pozorování  $x_1, x_2, \dots, x_n$  náhodného ýběru  $X_1, X_2, \dots, X_n$ .

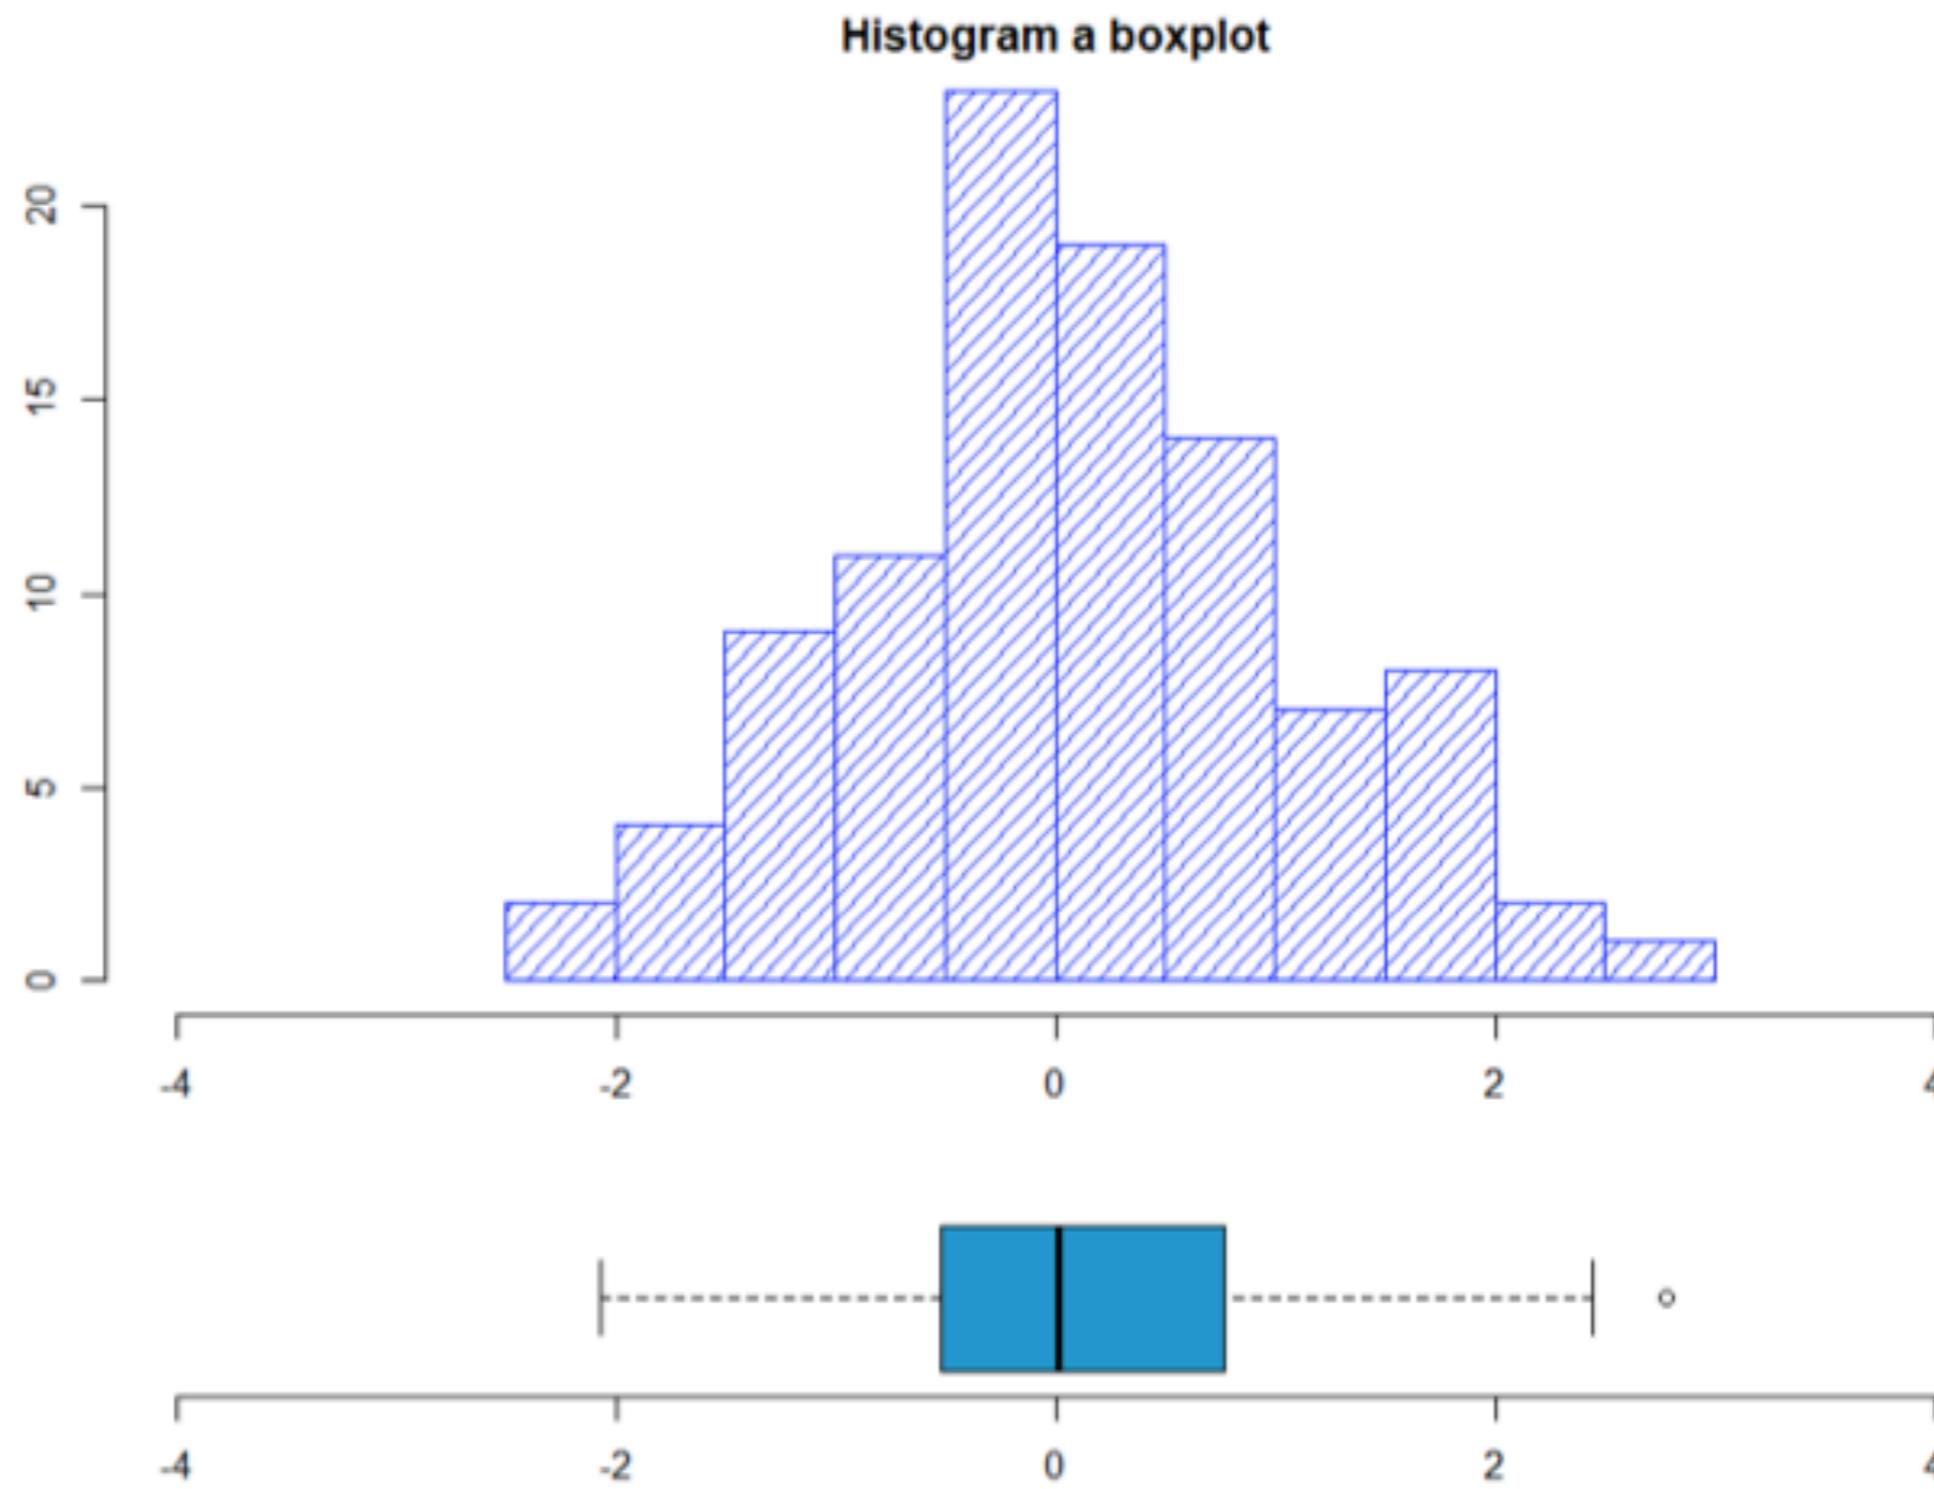


# Frekvenční analýza - histogram četností

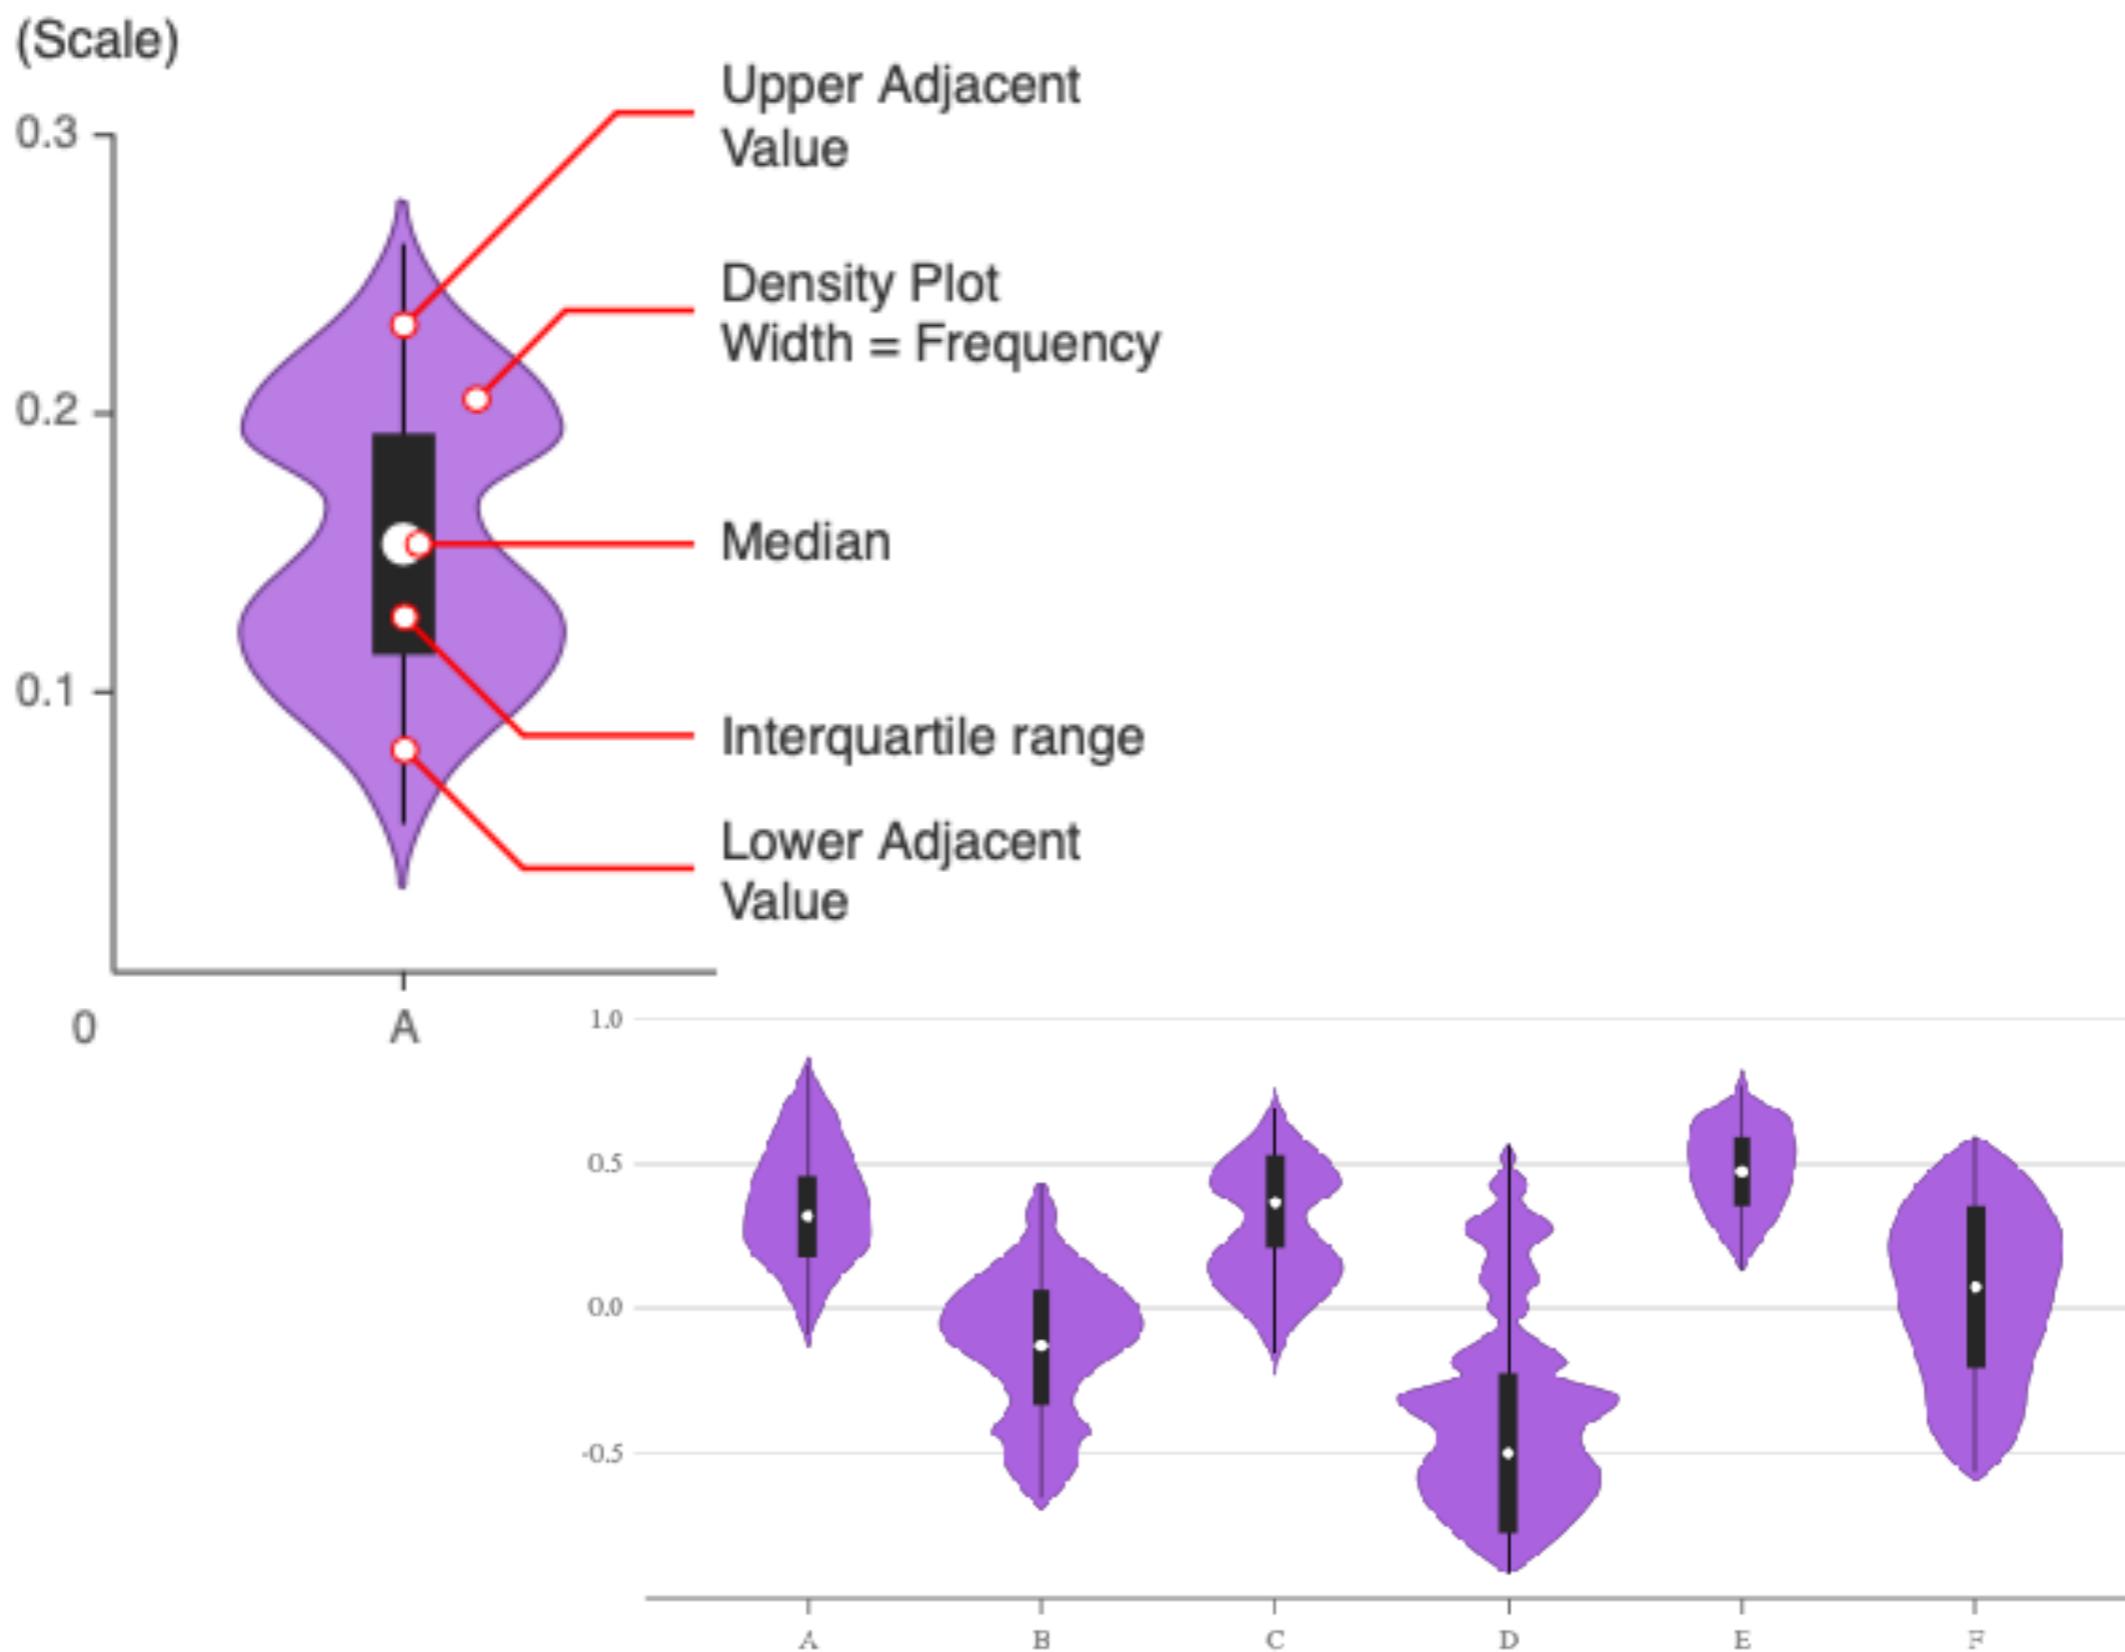
Máme pozorování  $x_1, x_2, \dots, x_n$  náhodného ýběru  $X_1, X_2, \dots, X_n$ .



# Frekvenční analýza - histogram četností

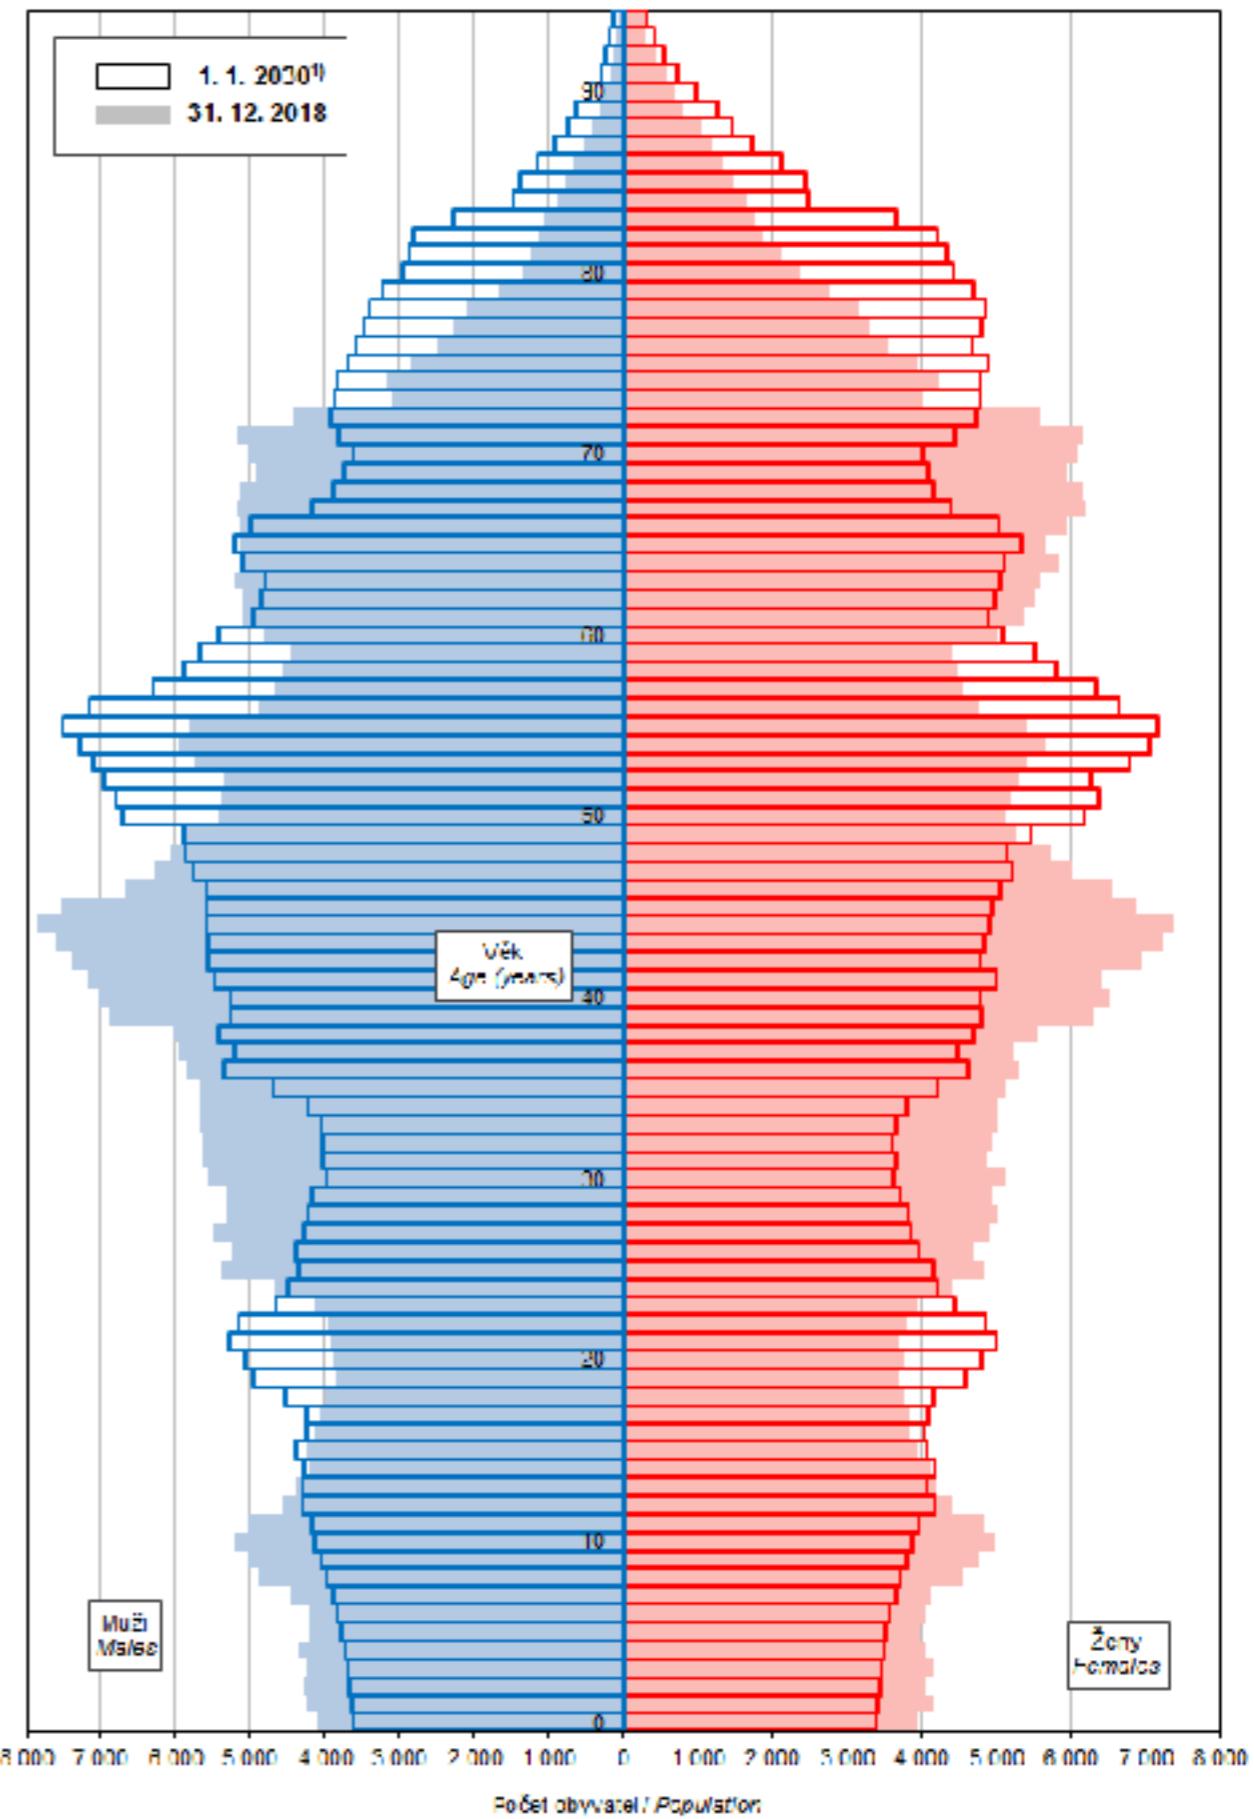


# Frekvenční analýza - huoslový graf



# Frekvenční analýza - dvourozměrný histogram

Věkové složení obyvatelstva Ústeckého kraje k 31. 12. 2018 a k 1. 1. 2030  
Age distribution of the population in the Ústecký Region as at 31 December 2018 and 1 January 2030

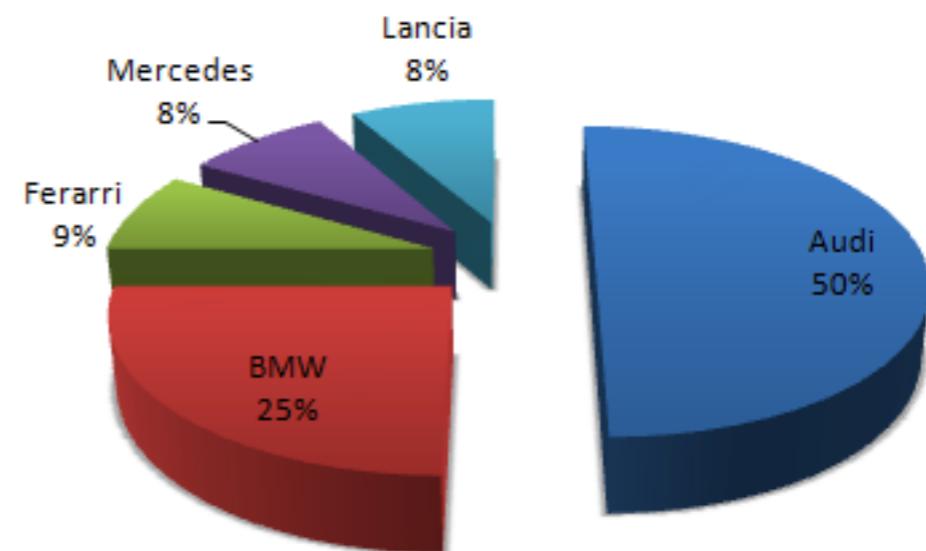
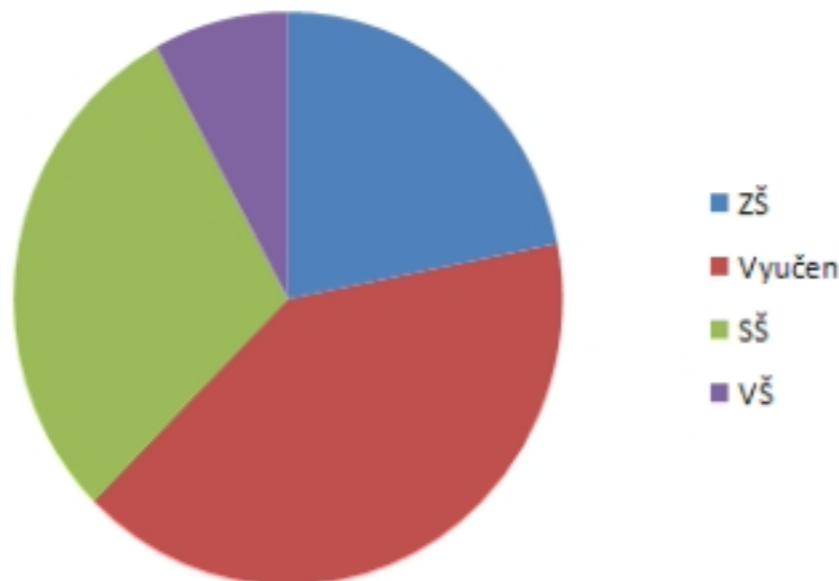


<sup>1)</sup> Zdroj: Projekce obyvatelstva v krajích ČR do roku 2070

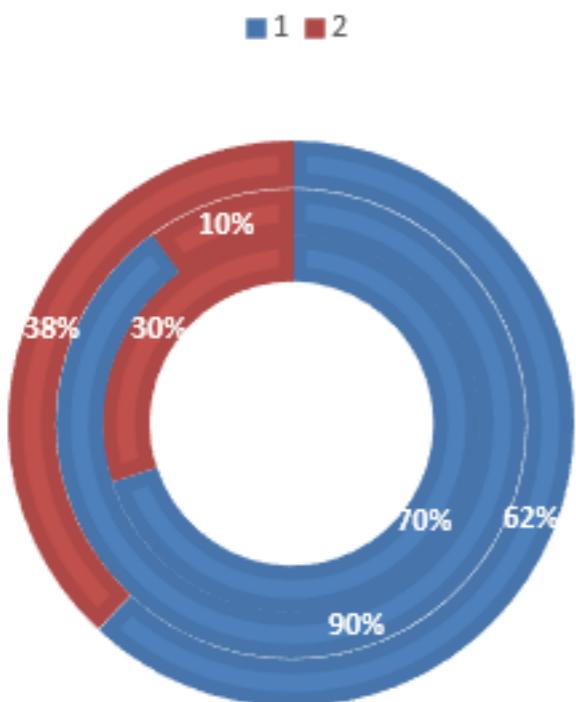
<sup>2)</sup> Source: CSO publication "Projekce obyvatelstva v krajích ČR do roku 2070" (Czech only)



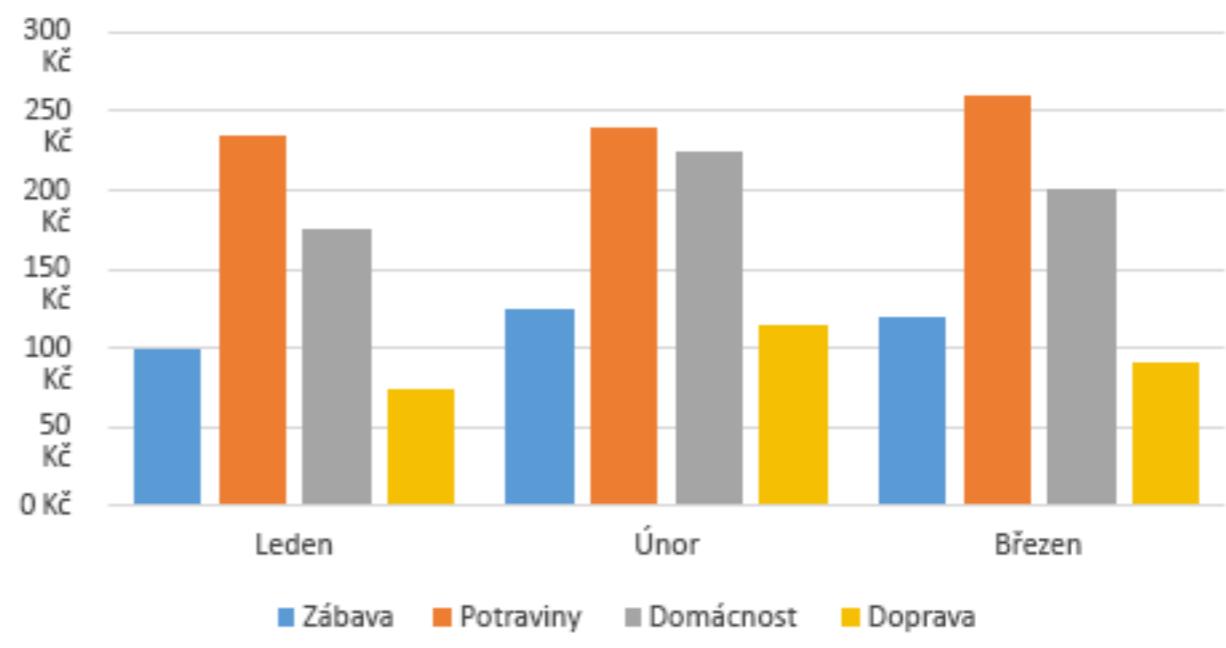
# Frekvenční analýza - kruhový graf



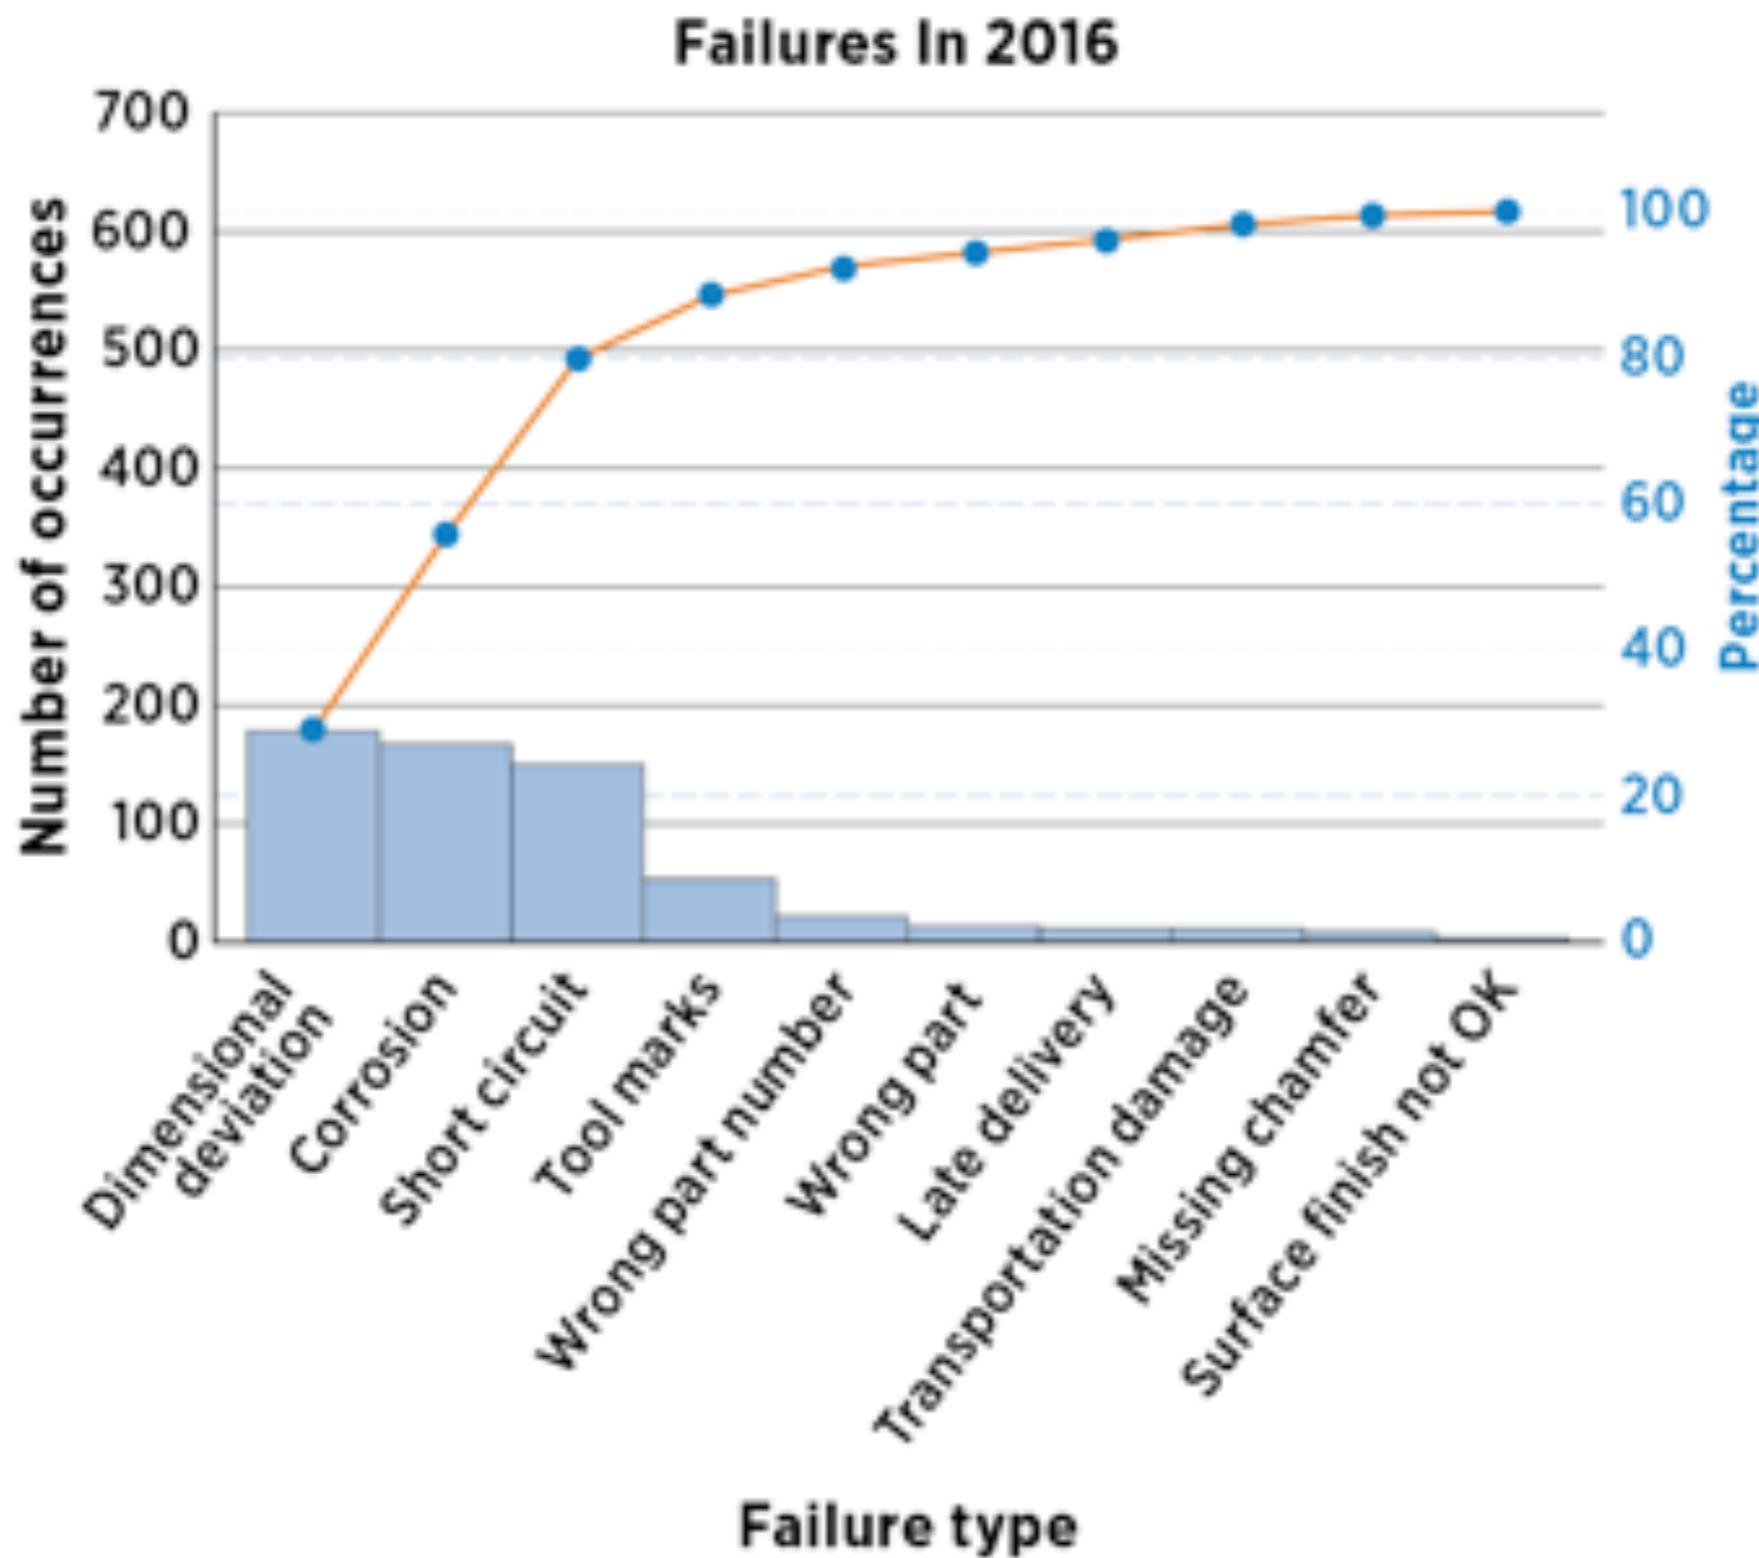
PRSTENCOVÝ GRAF – 3 HODNOTY



KONTINGENČNÍ GRAF



# Frekvenční analýza - Paretův graf



# Základní pojmy popisné statistiky

## Co je třeba znát a porozumět tomu:

- **Základní soubor (populace, universum):** množina objektů, na nichž provádíme statistické zkoumání; musí být přesně specifikována
- **Výběr (ze základního souboru):**  $n$ -tice náhodných veličin  $X_1, X_2, \dots, X_n$  odpovídající nezávislým pozorováním vybraných objektů základního souboru na nichž pozorujeme nějakou veličinu  $X$  reprezentující určitou měřitelnou (a přesně danou) vlastnost všech objektů základního souboru.
- **Rozsah výběru** je počet objektů  $n$  zahrnutých do výběru.
- **Reprezentativnost výběru** je vlastnost výběru, zaručující rovnoměrné zastoupení charakteristických vlastností objektů základního souboru.
- **Náhodný výběr** vznikne tehdy, když každý objekt základního souboru má stejnou pravděpodobnost být zahrnut do výběru.
- **Realizace výběru:** je množina naměřených (napozorovaných ) číselných hodnot  $x_1, x_2, \dots, x_n$  veličin z výběru.



# Základní pojmy popisné statistiky

## Co je třeba znát a porozumět tomu:

- **Uspořádaný výběr:**  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$  vznikne z původního výběru  $X_1, X_2, \dots, X_n$  upořádáním podle velikosti pozorovaných hodnot  $x_1, x_2, \dots, x_n$ .
- **Pořadová statistika:**  $X_{(k)}$  je náhodná veličina  $X_m$ , která je  $k$ -tá v pořadí podle velikosti pozorovaných hodnot  $x_1, x_2, \dots, x_n$ .
- **Pořadí  $m$ -tého pozorování veličiny  $X_m$  ve výběru:** pokud  $X_m = X_{(k)} \Rightarrow R_m = k$ .
- $X_{(1)}$  se nazývá **(výběrové) minimum**,  $X_{(n)}$  je **(výběrové) maximum**
- **medián** je prostřední hodnota ve výběru: je-li  $n$  liché, je roven  $X_{([n/2]+1)}$  pro  $n$  sudé je roven  $(X_{(n/2)} + X_{(n/2+1)})/2$
- **dolní kvartil:**  $X_{([n/4]+1)}$  resp.  $(X_{(n/4)} + X_{(n/4+1)})/2$
- **horní kvartil:**  $X_{([3n/4]+1)}$  resp.  $(X_{(3n/4-1)} + X_{(3n/4)})/2$
- **Výběrový modus** je nejčastější hodnota, která se vyskytuje v realizaci výběru. Tato hodnota nemusí existovat.



# Základní pojmy popisné statistiky

## Co je třeba znát a porozumět tomu:

- **Výběrový průměr** nahrazuje neznámou střední hodnotu veličiny  $X$ :

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

- **Výběrový rozptyl** je charakteristika odpovídající rozptylu náhodné veličiny  $X$

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

- **Výběrová směrodatná odchylka**  $s$  je druhou odmocninou z výběrového rozptylu

- **Výběrový index šikmosti** je výběrovou variantou indexu šikmosti a je mírou symetrie pozorované veličiny  $X$

$$Skew(X) = \frac{m_3(X)}{m_2^{3/2}(X)}$$

- **Výběrový index špičatosti** je výběrovou variantou indexu špičatosti a je mírou soustředění hodnot pozorované veličiny  $X$  kolem průměru.

- $Kurt(X) = \frac{m_4(X)}{m_2^2(X)} - 3$



# Základní pojmy popisné statistiky

## Co je třeba znát a porozumět tomu:

- **Třídní intervaly** rozdělují maximální rozsah pozorovaných hodnot náhodné veličiny (od minima do maxima) na  $k$  stejných dílů.
- **(prostá absolutní) četnost  $i$ -té třídy** je počet pozorování náhodné veličiny  $X$  v  $i$ -té třídě,  $i = 1, \dots, k$ .
- **(prostá) relativní četnost  $i$ -té třídy** je poměr počtu pozorování náhodné veličiny  $X$  v  $i$ -té třídě ku rozsahu výběru  $n$ ,  $i = 1, \dots, k$ .
- **kumulativní (absolutní) četnost  $i$ -té třídy** je počet pozorování náhodné veličiny  $X$  od minima až do  $i$ -té třídy včetně,  $i = 1, \dots, k$ .
- **kumulativní relativní četnost  $i$ -té třídy** je součet relativních četností pozorování náhodné veličiny  $X$  až do  $i$ -té třídy včetně,  $i = 1, \dots, k$ .
- **Histogram četností** je grafické zobrazení četností ve formě sloupkového grafu. Relativní četnosti lze zobrazovat i ve formě kruhového (koláčového) grafu. Existuje celá řada variant.



# Základní pojmy popisné statistiky

## Co je třeba znát a porozumět tomu:

- **Krabicový diagram** je grafické zobrazení rozdělení pozorovaných hodnot pomocí pěti (Tukey's) charakteristik: minima, dolního kvartilu, mediánu, horního kvartilu a maxima.
- **Empirická distribuční funkce** je grafické zobrazení realizace výběru formou grafu po částech konstantní funkce. Vychází z uspořádaného výběru:  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ . Potom

$$F_n(x_{(i)}) = \frac{i}{n} \quad \text{a tedy} \quad F_n(x) = \frac{\max\{k : X_{(k)} \leq x\}}{n}, \quad x \in \mathbf{R}$$



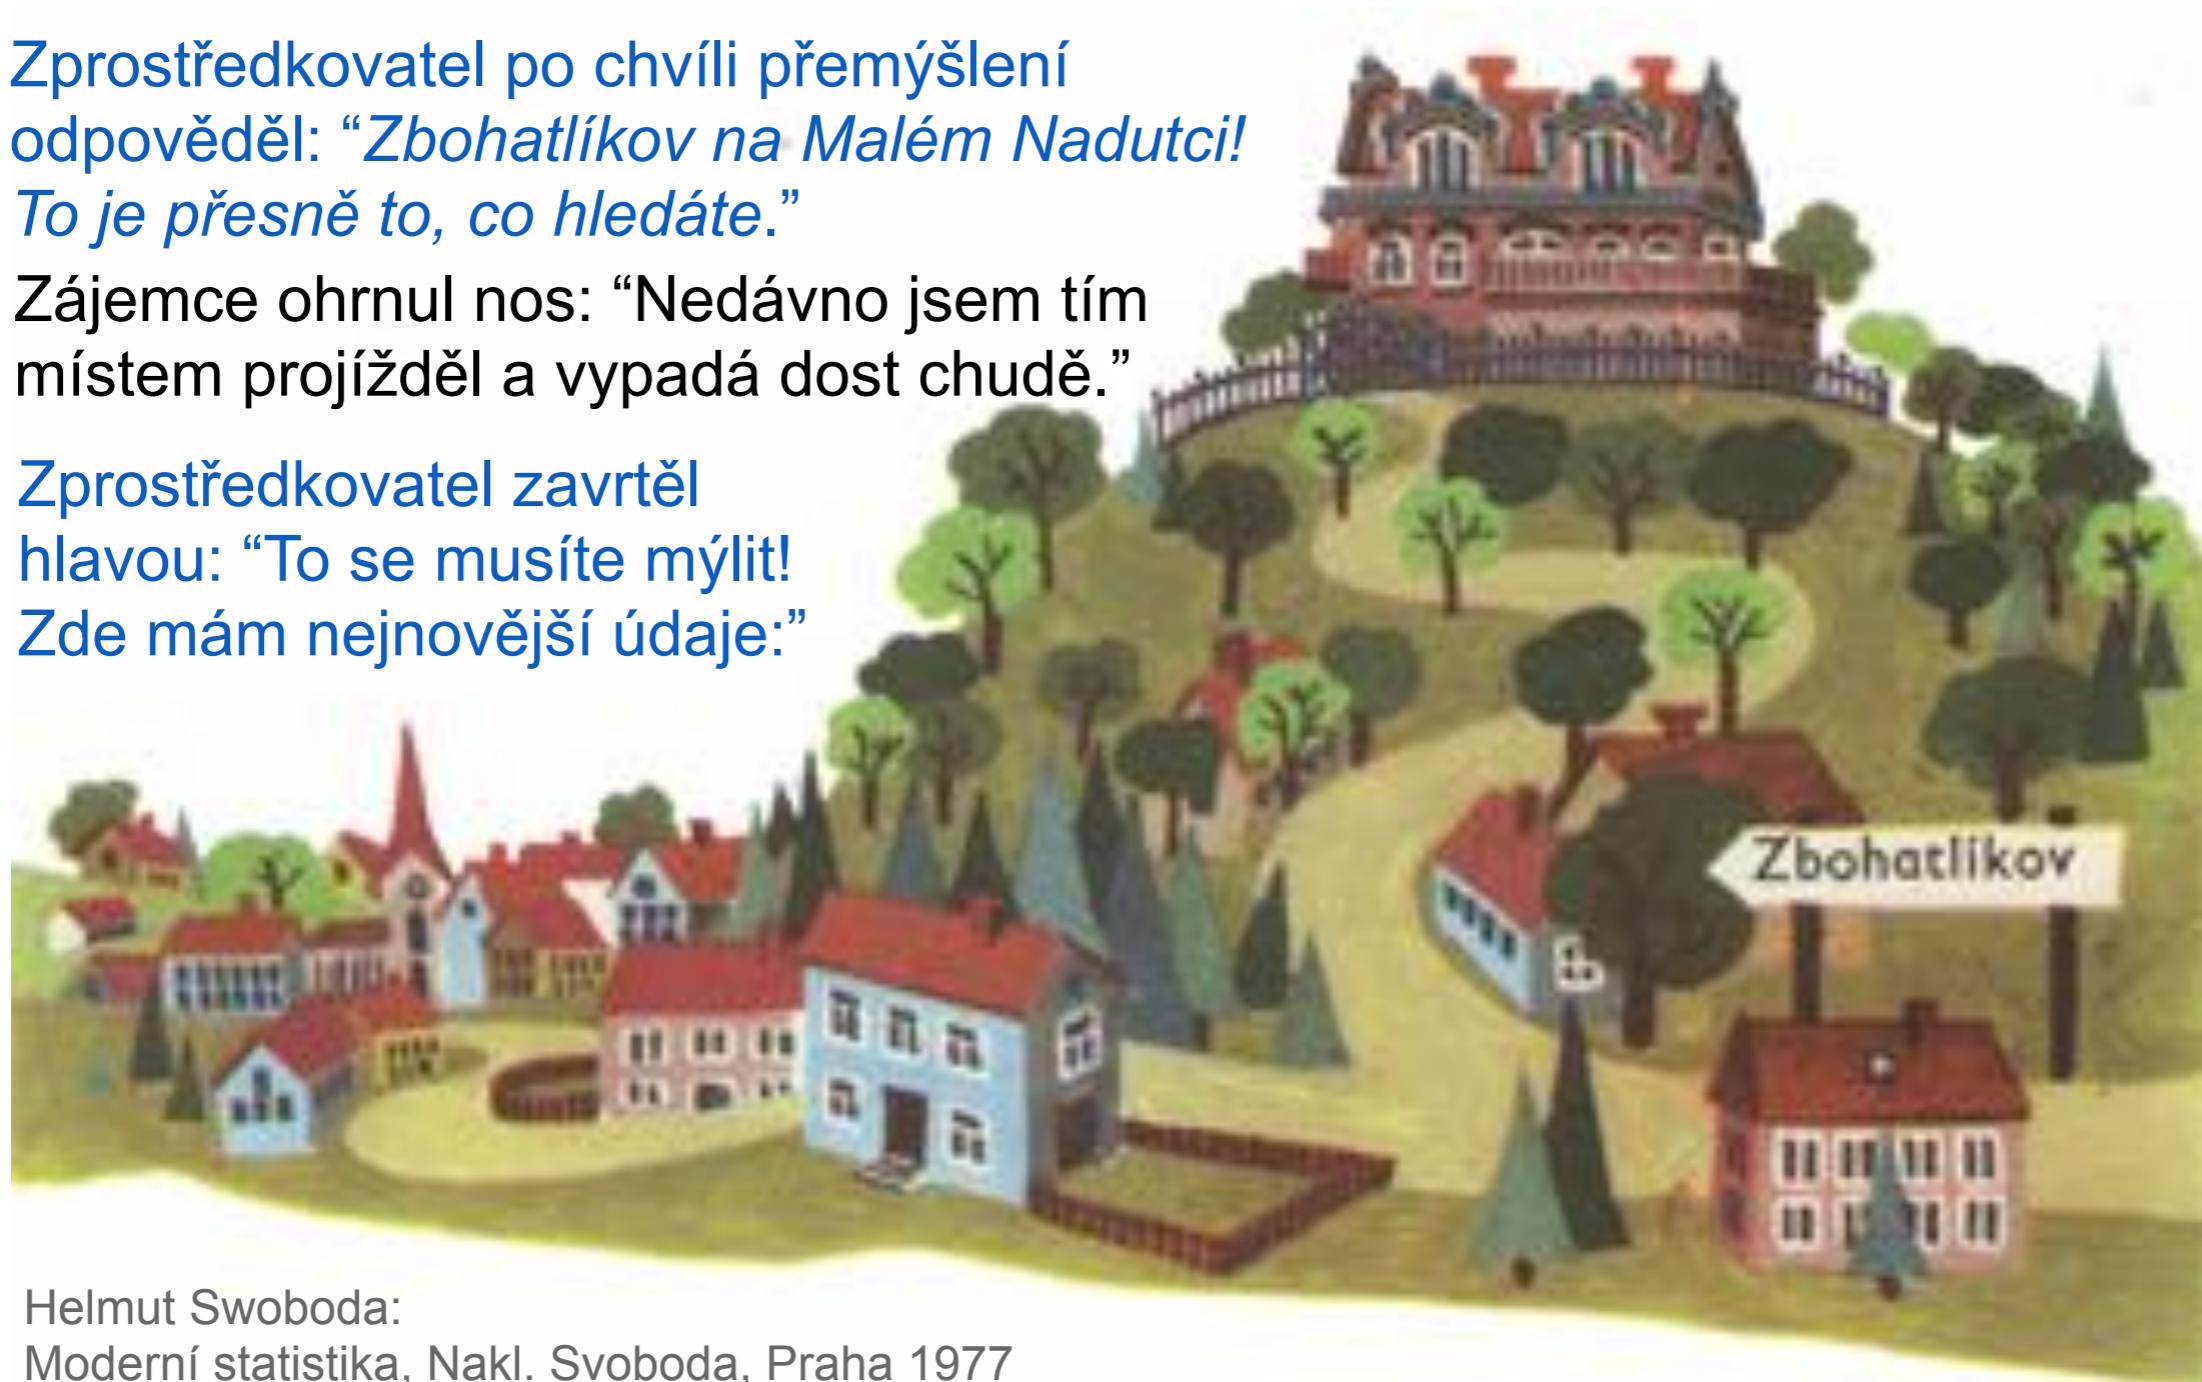
# Pohádka o Zbohatlíkově

V jedné malé rozvinuté zemi, na kraji Evropské unie, přišel mladý podnikatel do realitní kanceláře a řekl: “*Chtěl bych pozemek na venkově, s lesem, loukami, ne příliš daleko od města, v pěkné krajině, za kterou by se člověk nemusel stydět. Samozřejmě že cenově výhodný.*”

Zprostředkovatel po chvíli přemýšlení odpověděl: “*Zbohatlíkov na Malém Nadutci! To je přesně to, co hledáte.*”

Zájemce ohrnul nos: “Nedávno jsem tím místem projízděl a vypadá dost chudě.”

Zprostředkovatel zavrtěl hlavou: “To se musíte mýlit!  
Zde mám nejnovější údaje:”



Helmut Swoboda:  
Moderní statistika, Nakl. Svoboda, Praha 1977



# Pohádka o Zbohatlíkově

- Zprostředkovatel tvrdí:

***Průměrný roční příjem ve Zbohatlíkově činí 82.320 tolarů.***

- Kupec zašel za známým ředitelem banky:

*roční příjem více než poloviny obyvatel je 29.000 tolarů a více.*

- To je podivné! Co řekne okresní úřad?:

*Dosti chudé místo, prostřední (typický) příjem je kolem 29.000 tolarů.*

- Vrátil se k řediteli banky pro nové informace:

*Nejsilněji zastoupená příjmová kategorie je od 10.000 do 20.000 tolarů*

*Nejčetnější příjem je poměrně přesně 18.000 tolarů.*

- Rozhněvaný kupec jede za učitelem Počtářem, kam ho poslali. Ten tvrdí, že situace je neutěšená:

*Více než polovina rodin má příjem menší než 30.000 tolarů.*

*68% rodin nedosáhne ani na polovinu průměrného příjmu.*

*Příjem na hlavu není u většiny lidí ani 7.500 tolarů ročně.*

*80% obyvatel má ročně méně než 21.000 tolarů na hlavu.*

**Kdo z nich lže?**



# Pohádka o Zbohatlíkově

Údaje o ročním příjmu 25 rodin ze Zbohatlíkova, n je počet členů domácnosti:

| roční příjem | n |
|--------------|---|--------------|---|--------------|---|--------------|---|
| 1,200.000    | 3 | 60.000       | 1 | 45.000       | 2 | 29.000       | 3 |
| 150.000      | 5 | 51.000       | 3 | 42.000       | 2 | 26.000       | 4 |
| 86.000       | 4 | 49.000       | 4 | 38.000       | 4 | 24.000       | 4 |
| 37.000       | 3 | 20.000       | 7 | 14.000       | 1 | 18.000       | 4 |
| 35.000       | 5 | 18.000       | 3 | 13.000       | 4 | 16.000       | 3 |
| 32.000       | 3 | 18.000       | 8 | 11.000       | 1 | 16.000       | 2 |
|              |   |              |   |              |   | 10.000       | 2 |

Zkusíme “stem&leaf” diagram:

0 | 000000000000000000001112  
1 | 2

Nic moc!



# Pohádka o Zbohatlíkově

Údaje o ročním příjmu 25 rodin ze Zbohatlíkova, n je počet členů domácnosti:

| roční příjem | n |
|--------------|---|--------------|---|--------------|---|--------------|---|
| 1,200.000    | 3 | 45.000       | 2 | 29.000       | 3 | 18.000       | 4 |
| 150.000      | 5 | 42.000       | 2 | 26.000       | 4 | 16.000       | 3 |
| 86.000       | 4 | 38.000       | 4 | 24.000       | 4 | 16.000       | 2 |
| 60.000       | 1 | 37.000       | 3 | 20.000       | 7 | 14.000       | 1 |
| 51.000       | 3 | 35.000       | 5 | 18.000       | 3 | 13.000       | 4 |
| 49.000       | 4 | 32.000       | 3 | 18.000       | 8 | 11.000       | 1 |
|              |   |              |   |              |   | 10.000       | 2 |

Zkusíme “stem&leaf” diagram:

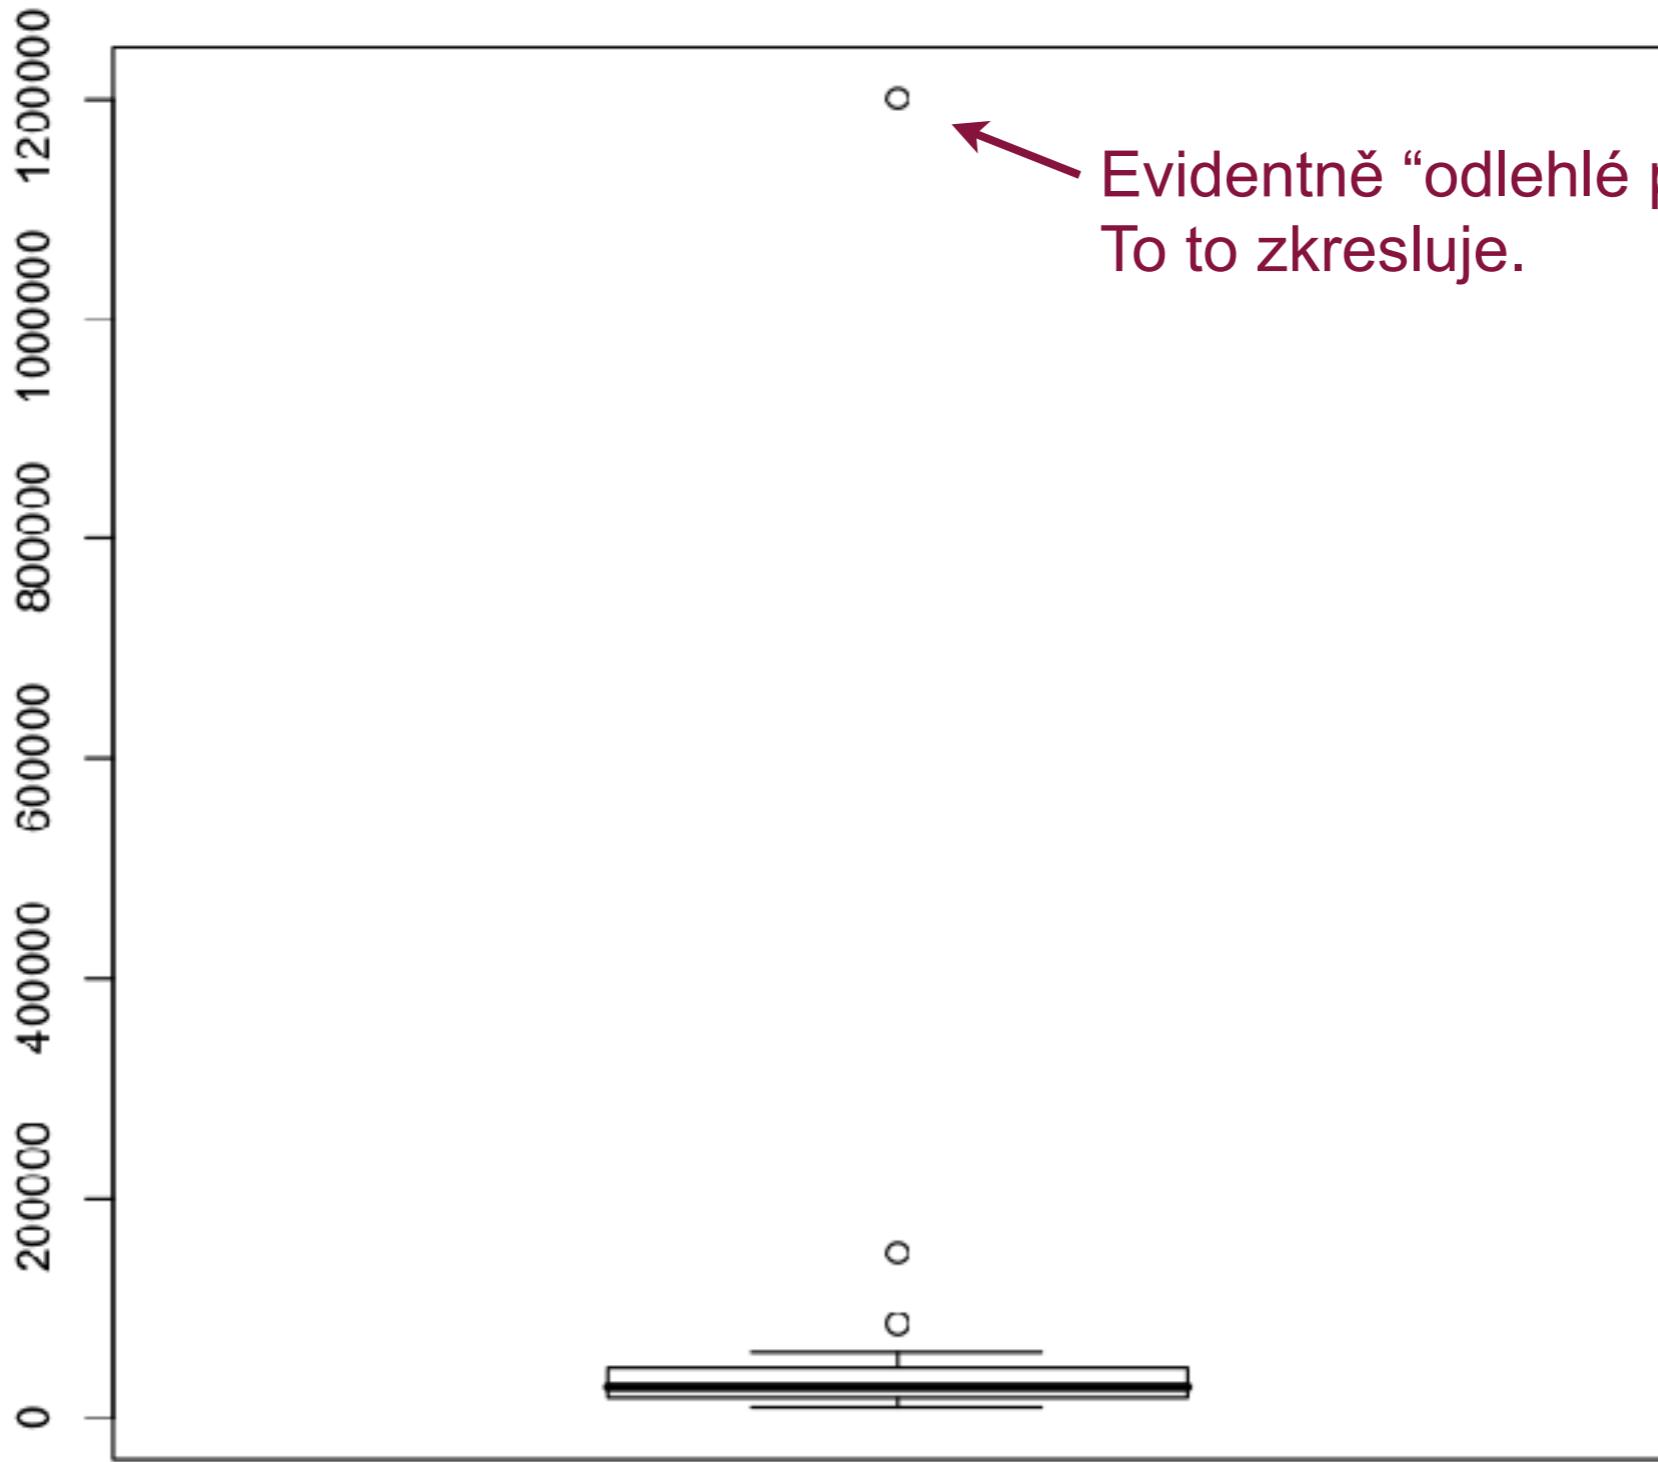
0 | 000000000000000000001112  
1 | 2

Nic moc!



# Pohádka o Zbohatlíkově

... a co “Box&Whiskers” diagram?



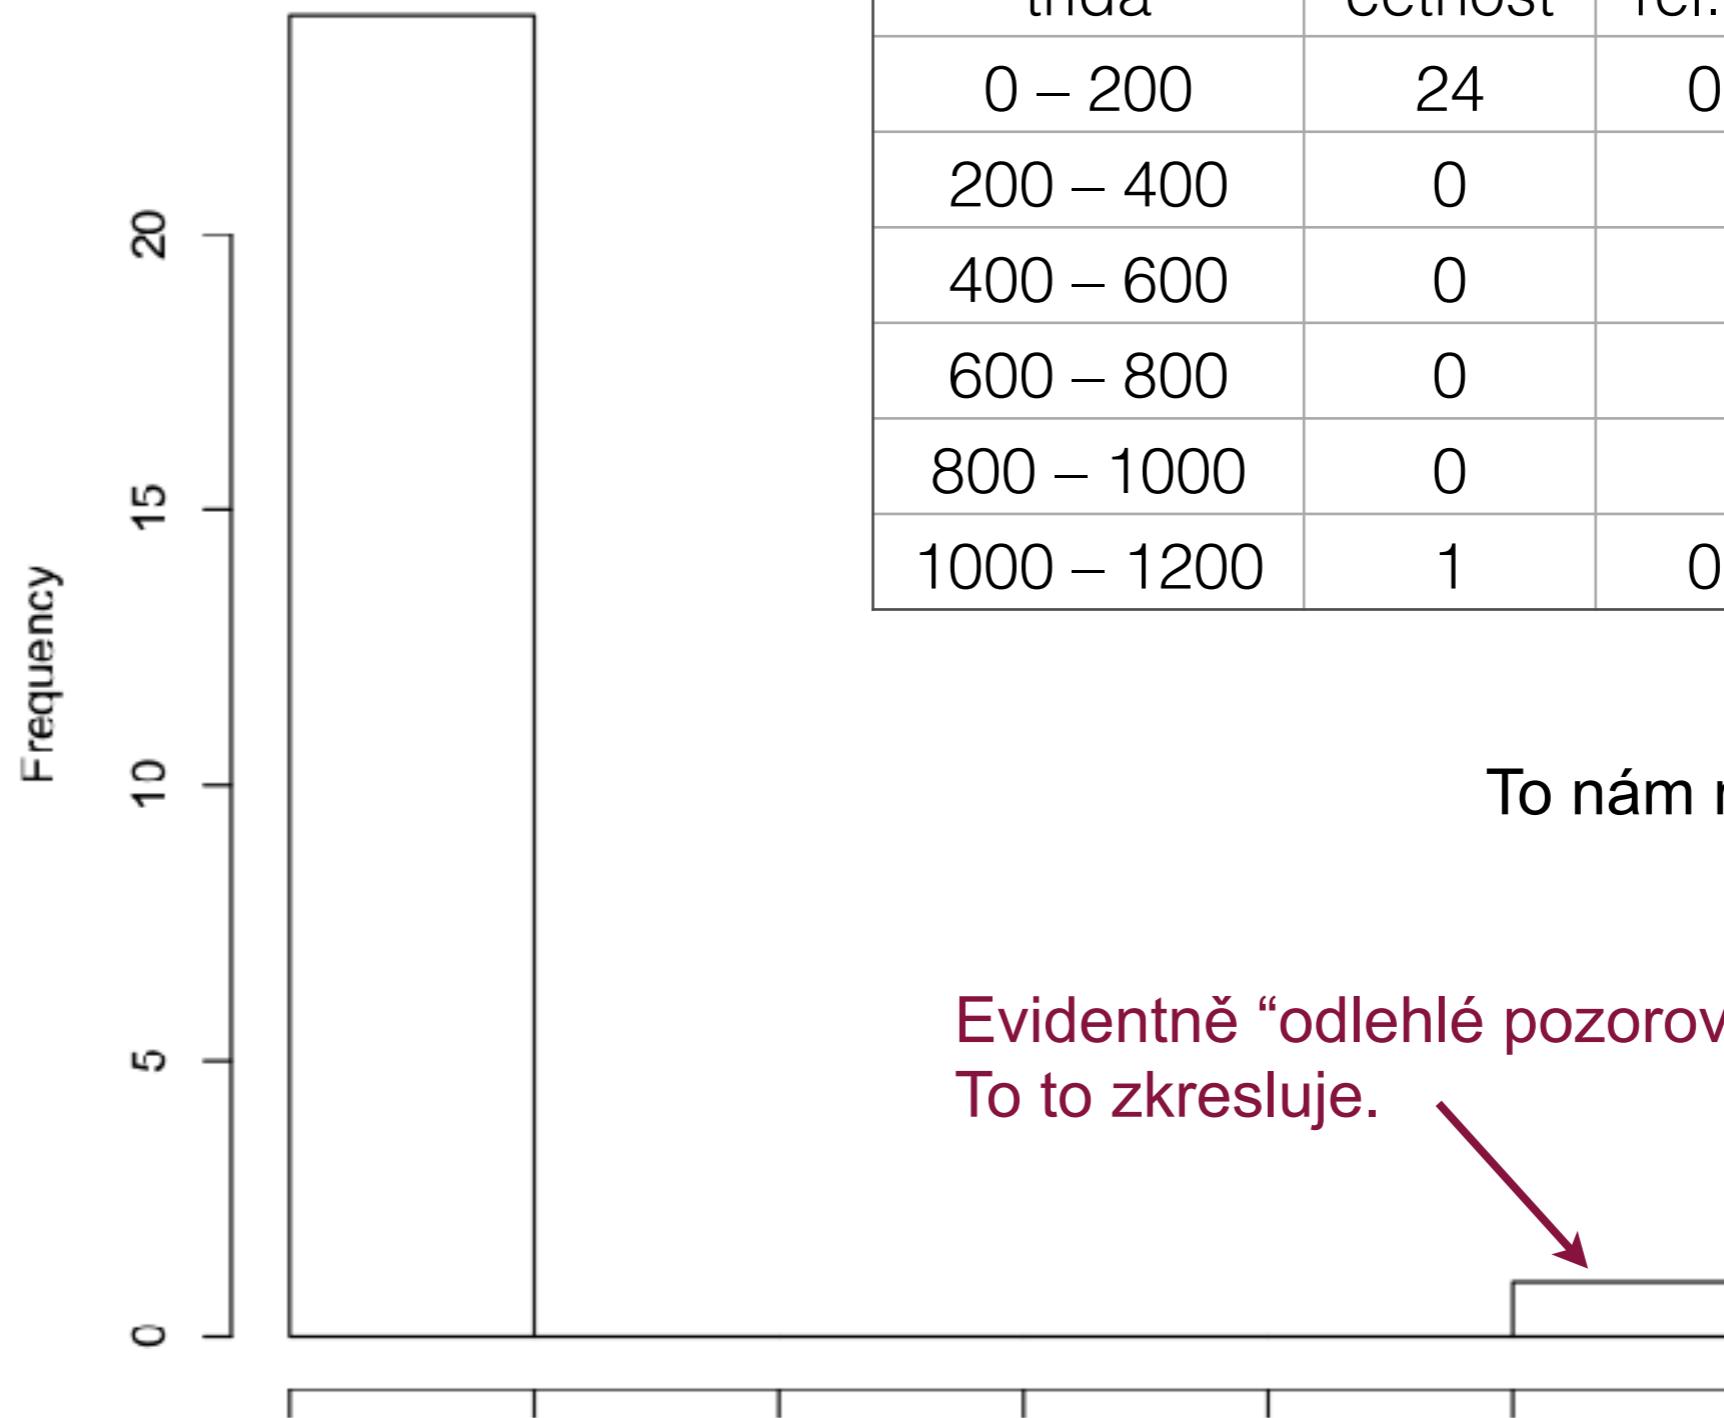
Evidentně “odlehlé pozorování.  
To to zkresluje.

Nicméně, medián  
je opravdu 29.000



# Pohádka o Zbohatlíkově

stejně dopadne i histogram:



To nám nic neukáže.

Evidentně “odlehlé pozorování.  
To to zkresluje.”



# Pohádka o Zbohatlíkově

Údaje o ročním příjmu 25 rodin ze Zbohatlíkova, n je počet členů domácnosti:

| roční příjem | n | roční příjem | n | roční příjem | n |        |   |
|--------------|---|--------------|---|--------------|---|--------|---|
| 1,200.000    | 3 | 60.000       | 1 | 45.000       | 2 | 29.000 | 3 |
| 150.000      | 5 | 51.000       | 3 | 42.000       | 2 | 26.000 | 4 |
| 86.000       | 4 | 49.000       | 4 | 38.000       | 4 | 24.000 | 4 |
| 37.000       | 3 | 20.000       | 7 | 14.000       | 1 | 18.000 | 4 |
| 35.000       | 5 | 18.000       | 3 | 13.000       | 4 | 16.000 | 3 |
| 32.000       | 3 | 18.000       | 8 | 11.000       | 1 | 16.000 | 2 |
|              |   |              |   |              |   | 10.000 | 2 |

Odstraníme na chvíli extrémní (odlehlou) hodnotu :

0 | 11112222223334444

0 | 55569

1 |

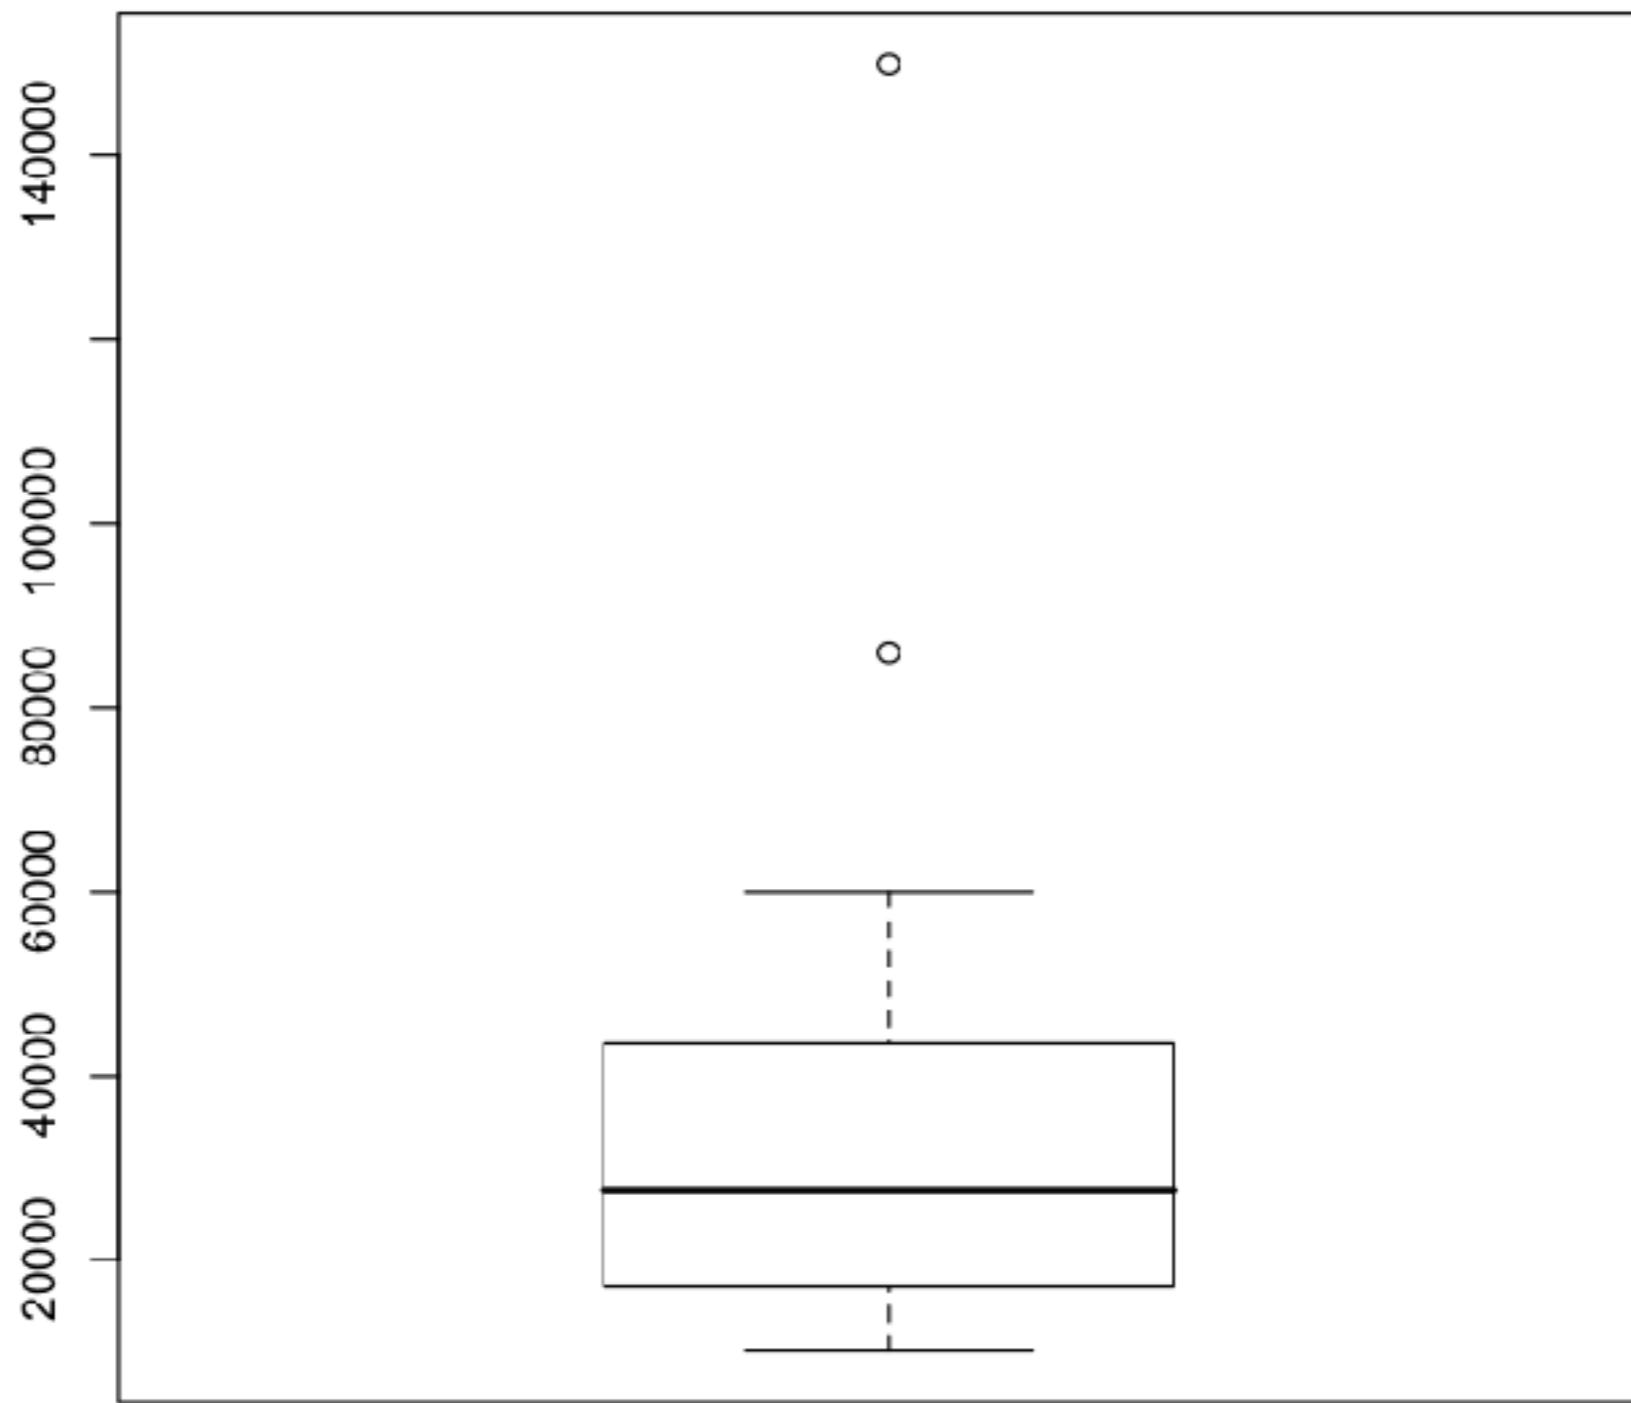
1 | 5

To už je trochu lepší!



# Pohádka o Zbohatlíkově

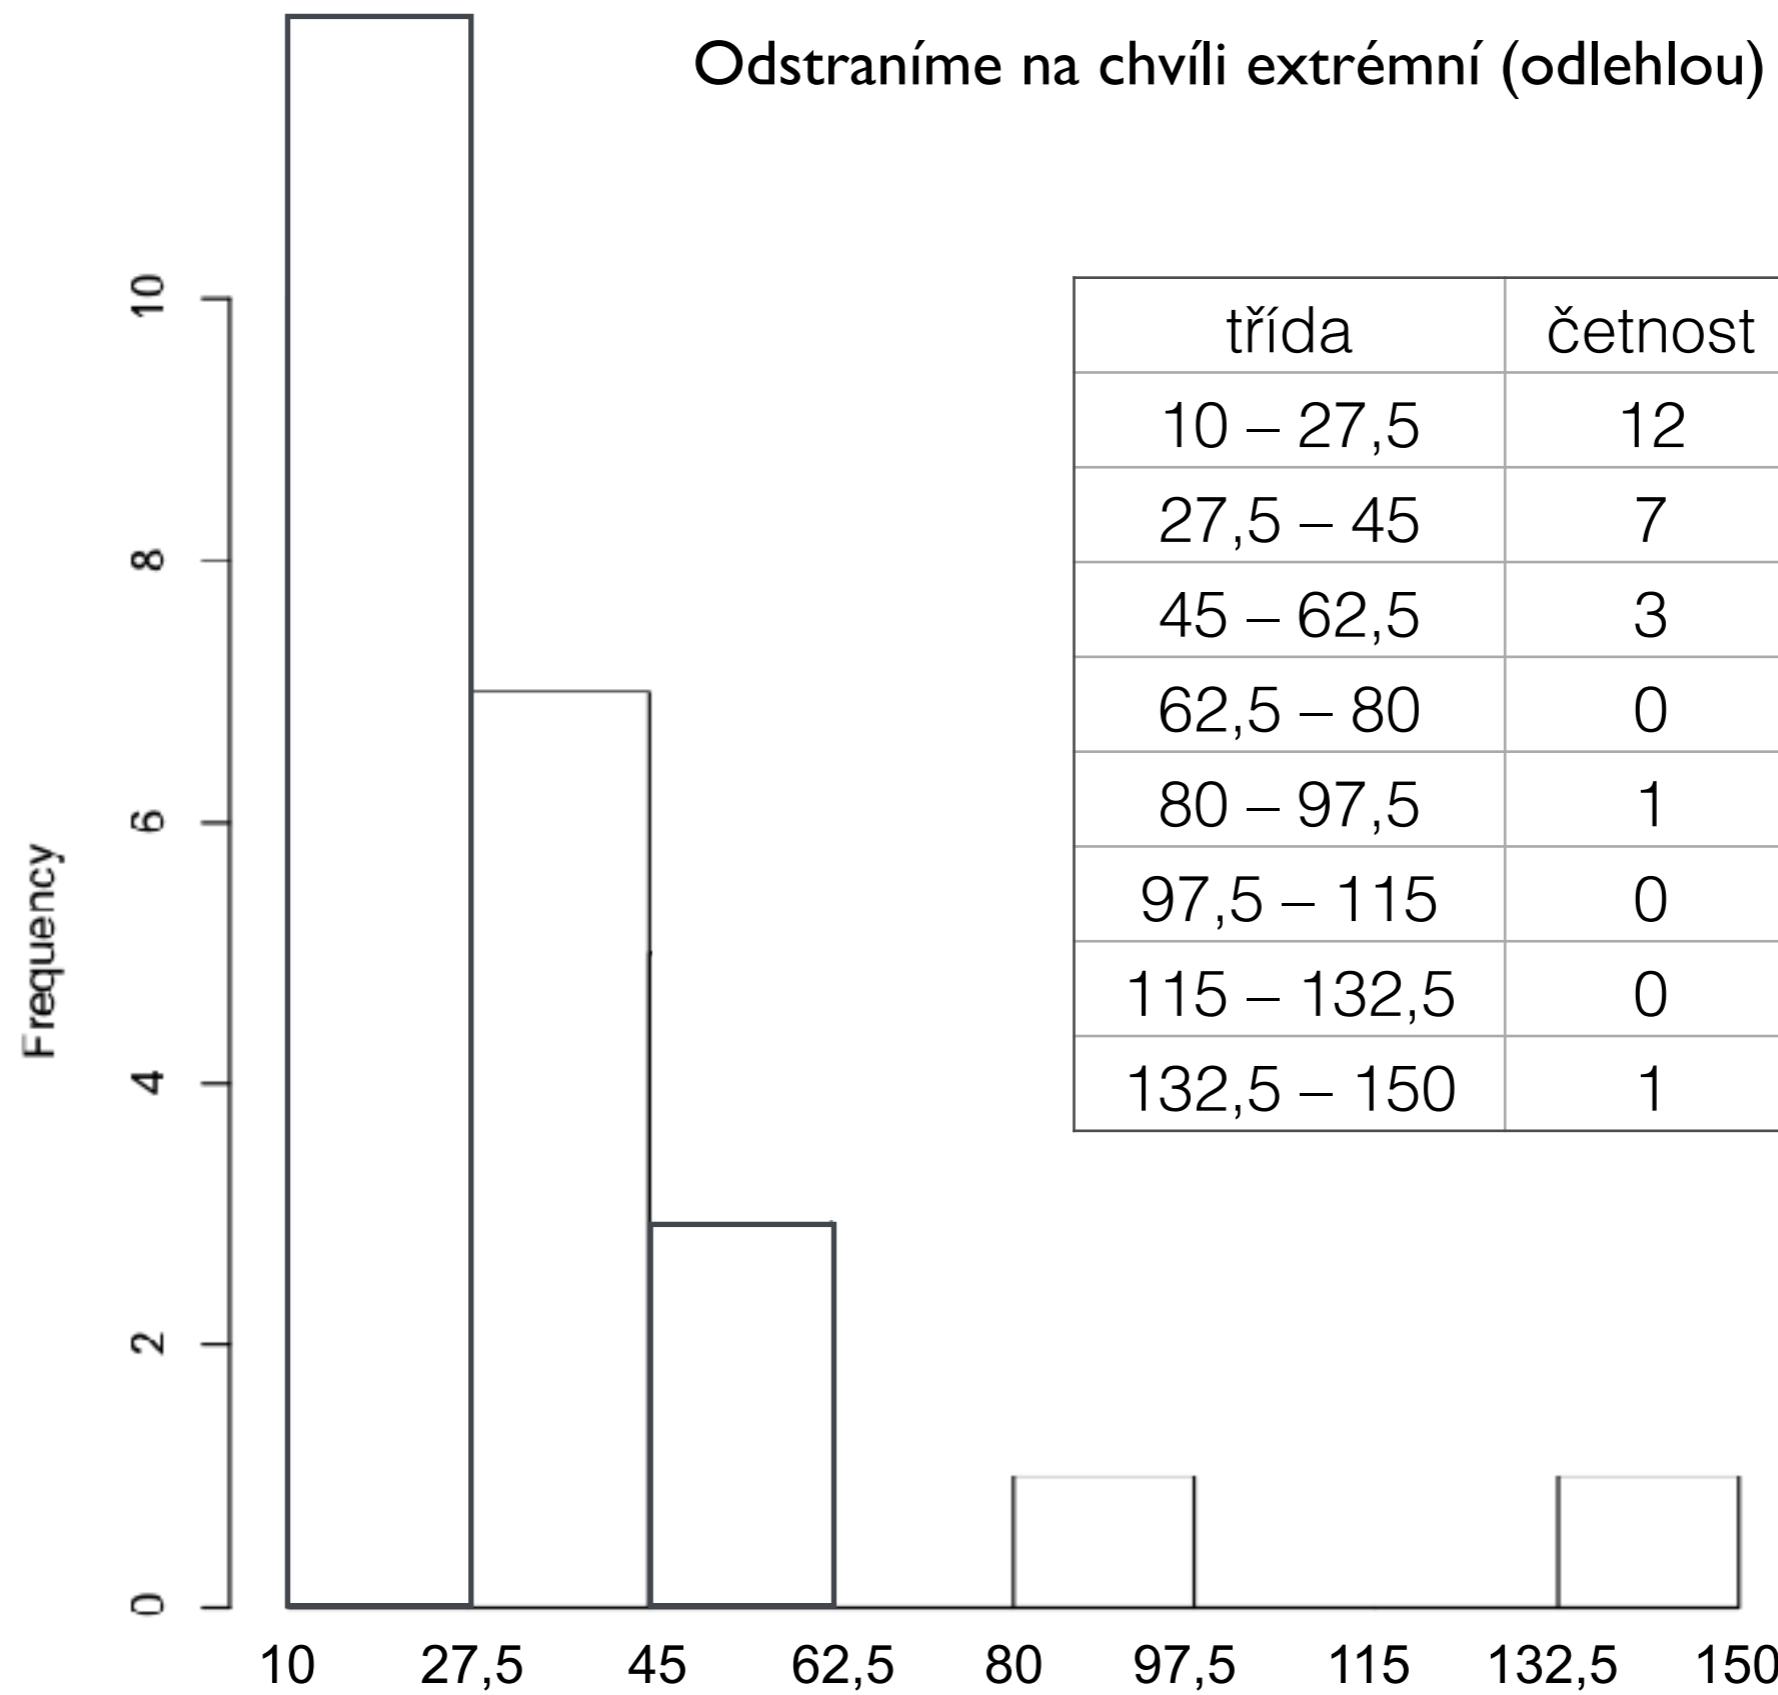
Odstraníme na chvíli extrémní (odlehlou) hodnotu :



$$X_{med} = 29.000$$



# Pohádka o Zbohatlíkově



# Pohádka o Zbohatlíkově

Údaje o ročním příjmu 25 rodin ze Zbohatlíkova, n je počet členů domácnosti:

| roční příjem | n | roční příjem | n | roční příjem | n |        |   |
|--------------|---|--------------|---|--------------|---|--------|---|
| 1,200.000    | 3 | 60.000       | 1 | 45.000       | 2 | 29.000 | 3 |
| 150.000      | 5 | 51.000       | 3 | 42.000       | 2 | 26.000 | 4 |
| 86.000       | 4 | 49.000       | 4 | 38.000       | 4 | 24.000 | 4 |
| 37.000       | 3 | 20.000       | 7 | 14.000       | 1 | 18.000 | 4 |
| 35.000       | 5 | 18.000       | 3 | 13.000       | 4 | 16.000 | 3 |
| 32.000       | 3 | 18.000       | 8 | 11.000       | 1 | 16.000 | 2 |
|              |   |              |   |              |   | 10.000 | 2 |

Odstraníme na chvíli dvě extrémní (odlehlé) hodnoty :

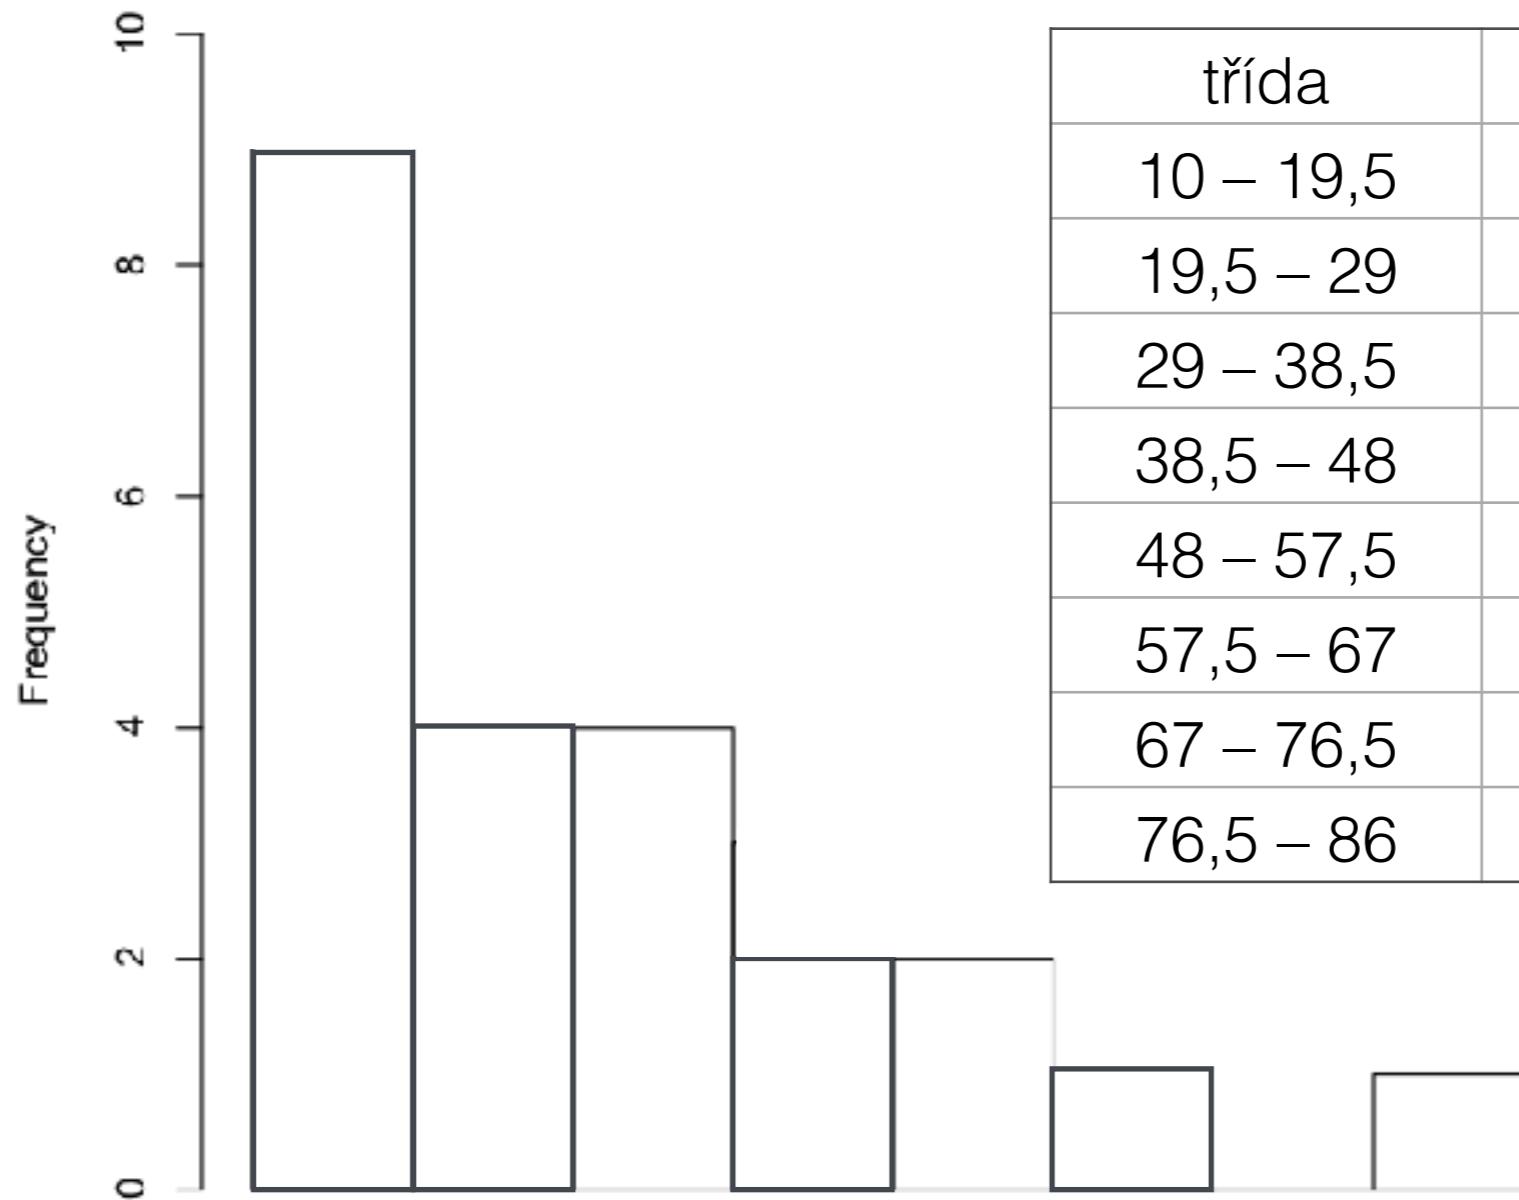
0 | 013466888  
2 | 04692578  
4 | 2591  
6 | 0  
8 | 6

Nejčetnější hodnota  
je 18.000 tolarů



# Pohádka o Zbohatlíkově

Odstraníme na chvíli dvě extrémní (odlehlé) hodnoty:



| třída     | četnost | rel.četn. |
|-----------|---------|-----------|
| 10 – 19,5 | 9       | 0,39      |
| 19,5 – 29 | 4       | 0,175     |
| 29 – 38,5 | 4       | 0,175     |
| 38,5 – 48 | 2       | 0,087     |
| 48 – 57,5 | 2       | 0,087     |
| 57,5 – 67 | 1       | 0,043     |
| 67 – 76,5 | 0       | 0         |
| 76,5 – 86 | 1       | 0,043     |

Nejsilněji zastoupená třída je od 10.000 do 20.000 tolarů



# Pohádka o Zbohatlíkově

Příjmy na hlavu (83):

400.000, 400.000, 400.000, 30.000, 30.000, 30.000, 30.000, 30.000, 30.000, 21.500, 1.500,  
21.500, 21.500, 12.333, 12.333, 12.333, 7.000, 7.000, 7.000, 7.000, 7.000,  
10.666, 10.666, 10.666, 9.666, 9.666, 9.666, 6.500, 6.500, 6.500, 6.500,  
6.000, 6.000, 6.000, 6.000, 60.000, 17.000, 12.250, 12.250, 12.250, 12.250,  
2.857, 2.857, 2.857, 2.857, 2.857, 2.857, 2.857, 6.000, 6.000, 6.000,  
2.250, 2.250, 2.250, 2.250, 2.250, 2.250, 2.250, 2.250, 4.500, 4.500,  
4.500, 4.500, 5.333, 5.333, 5.333, 8.000, 8.000, 22.500, 22.500, 21.000,  
21.000, 9.500, 9.500, 9.500, 9.500, 14.000, 3.250, 3.250, 3.250, 3.250,  
11.000, 5.000, 5.000

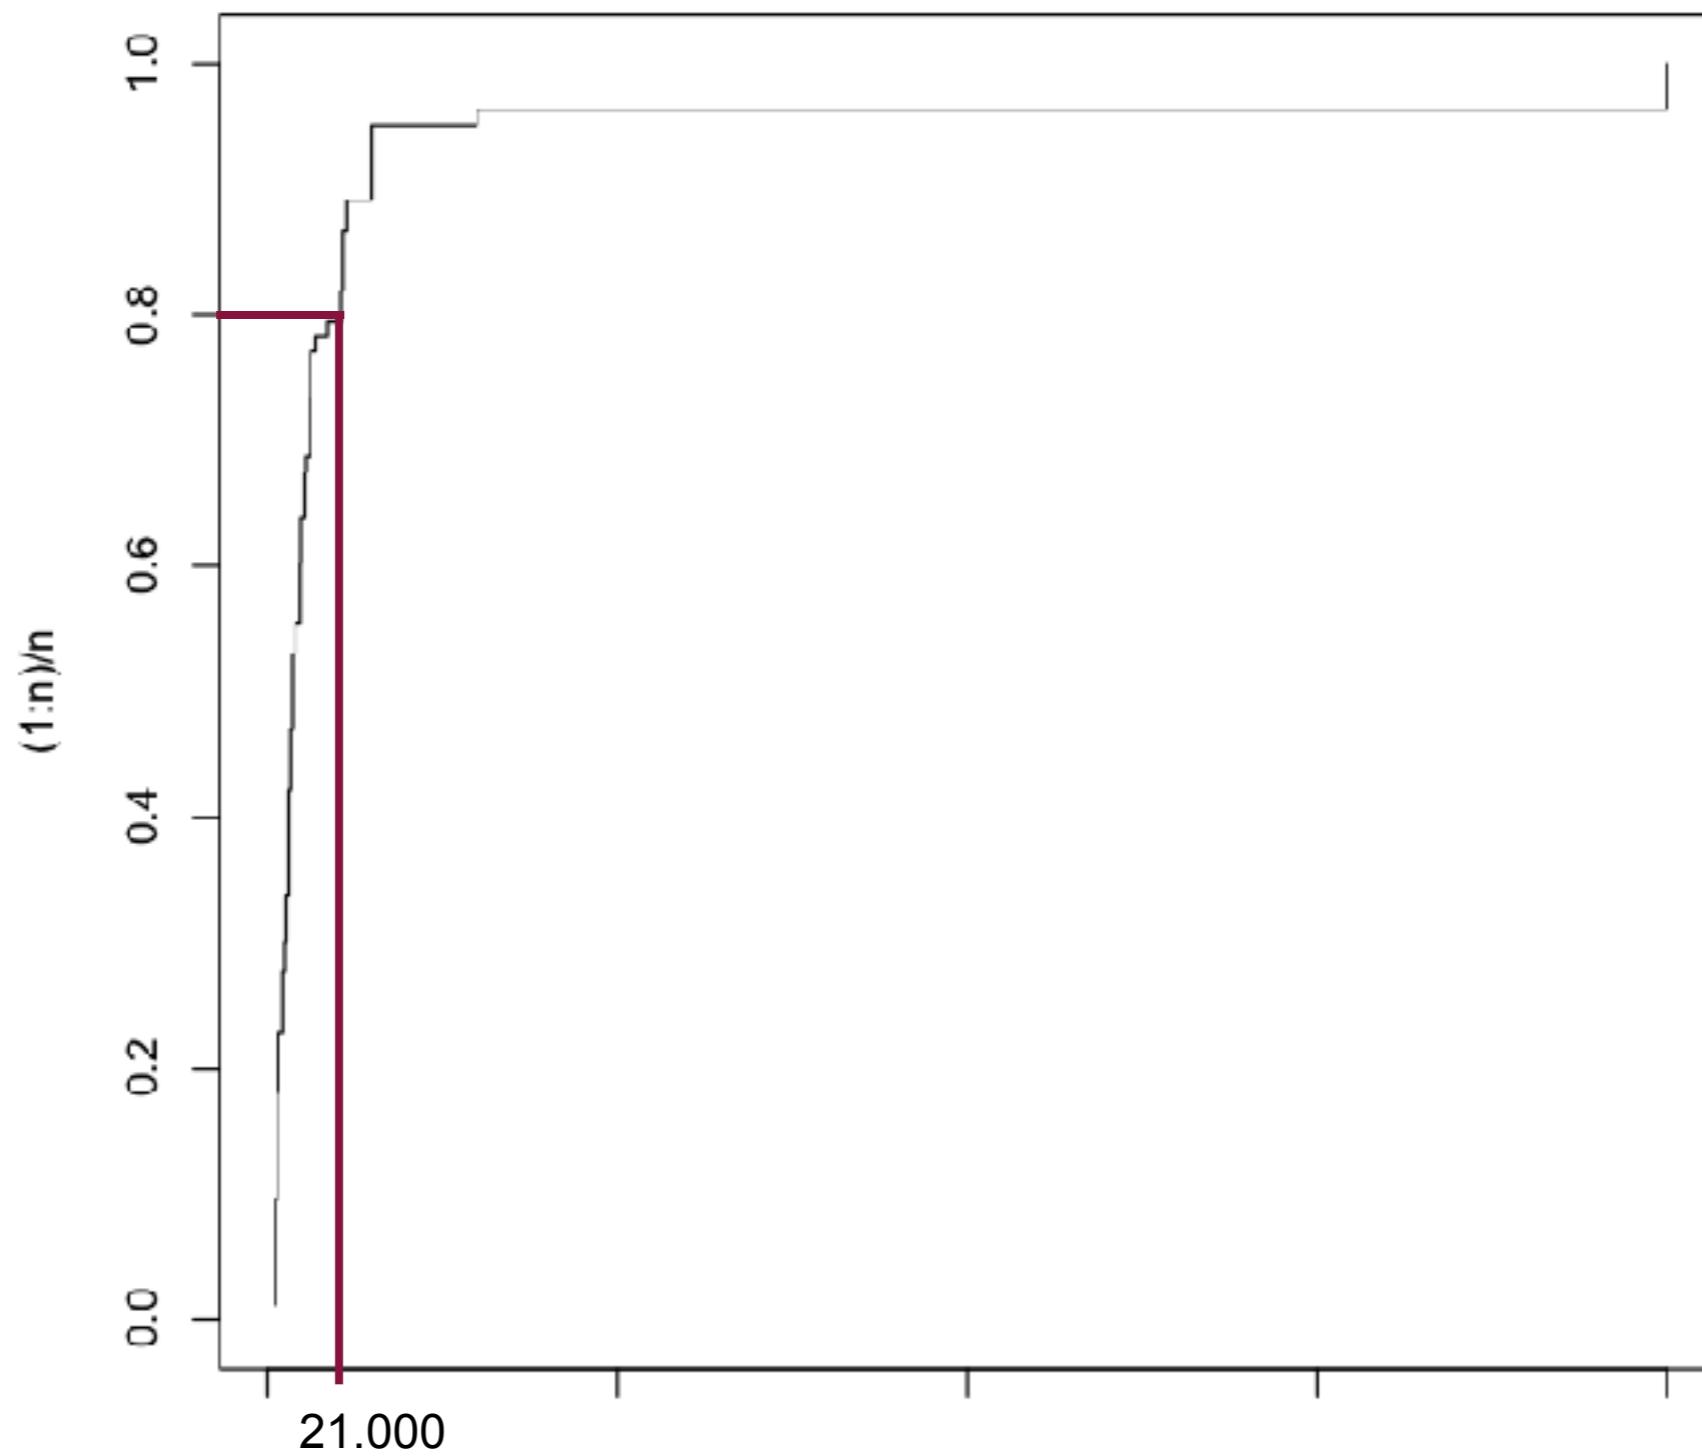
Uspořádané příjmy na hlavu: 80% je 66,4 lidí

|         |         |         |        |        |        |        |        |        |        |        |
|---------|---------|---------|--------|--------|--------|--------|--------|--------|--------|--------|
| 2.250   | 2.250   | 2.250   | 2.250  | 2.250  | 2.250  | 2.250  | 2.250  | 2.250  | 2.857  | 2.857  |
| 2.857   | 2.857   | 2.857   | 2.857  | 2.857  | 3.250  | 3.250  | 3.250  | 3.250  | 3.250  | 4.500  |
| 4.500   | 4.500   | 4.500   | 5.000  | 5.000  | 5.333  | 5.333  | 5.333  | 6.000  | 6.000  | 6.000  |
| 6.000   | 6.000   | 6.000   | 6.000  | 6.000  | 6.500  | 6.500  | 6.500  | 6.500  | 7.000  |        |
| 7.000   | 7.000   | 7.000   | 7.000  | 8.000  | 8.000  | 9.500  | 9.500  | 9.500  | 9.500  | 9.500  |
| 9.666   | 9.666   | 9.666   | 10.666 | 10.666 | 10.666 | 11.000 | 12.250 | 12.250 | 12.250 |        |
| 12.250  | 12.333  | 12.333  | 12.333 | 14.000 | 17.000 | 21.000 | 21.000 | 21.500 | 21.500 |        |
| 21.500  | 21.500  | 22.500  | 22.500 | 30.000 | 30.000 | 30.000 | 30.000 | 30.000 | 30.000 | 60.000 |
| 400.000 | 400.000 | 400.000 |        |        |        |        |        |        |        |        |

80% lidí má menší roční příjem než 20.000 tolarů

# Pohádka o Zbohatlíkově

Empirická distribuční funkce:



# Pohádka o Zbohatlíkově

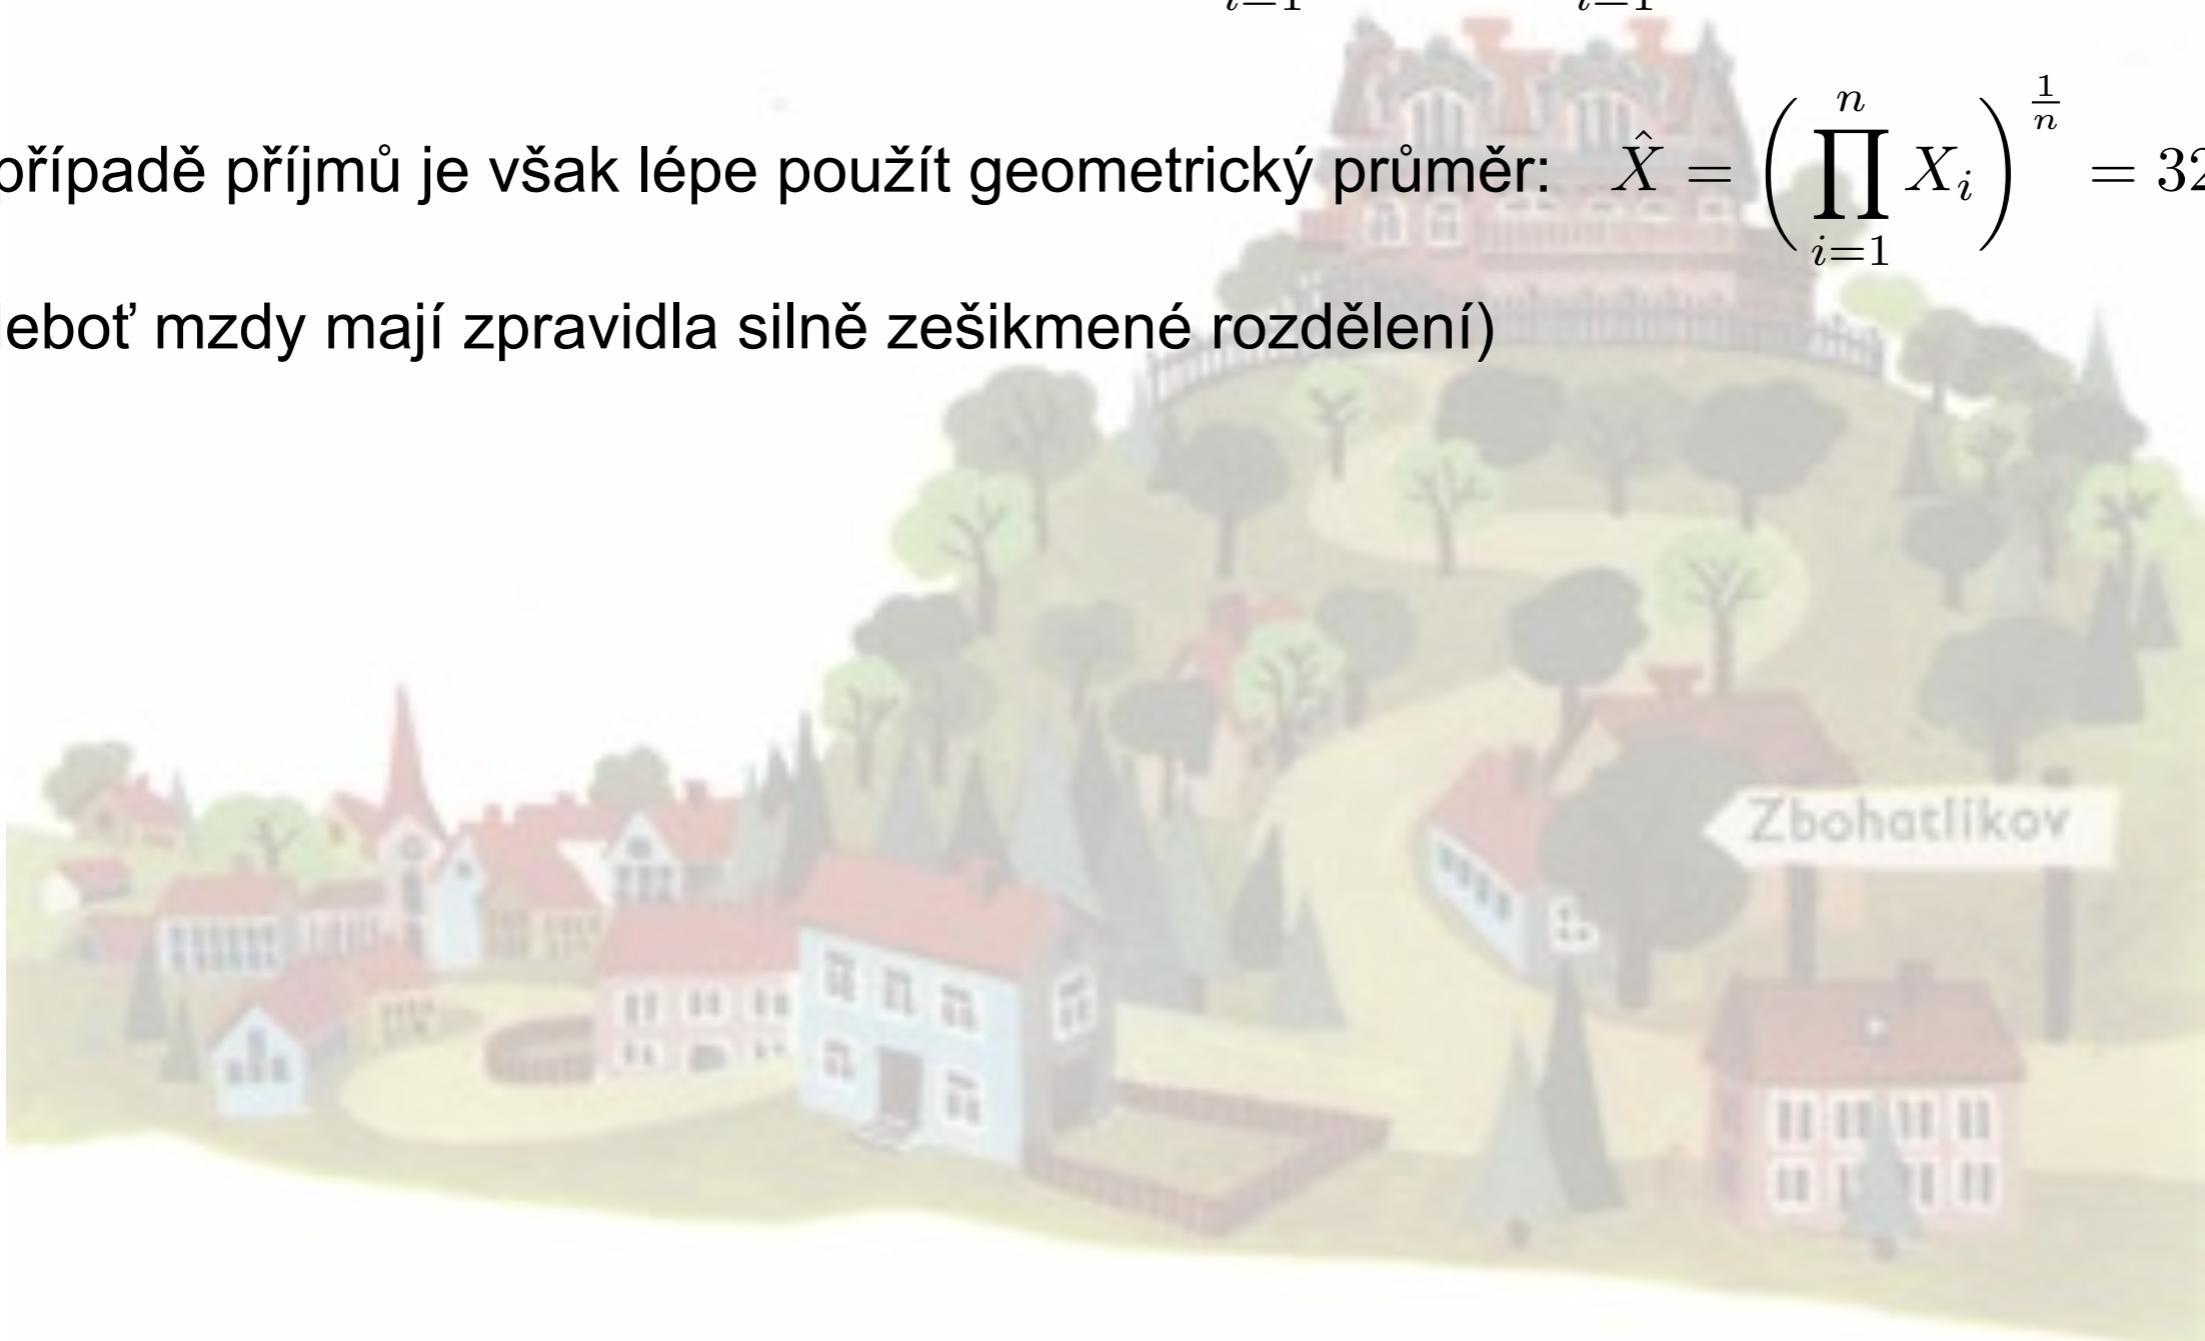
Lhal tedy zprostředkovatel?

Nelhal, neboť:

- ✓ Výběrový průměr je opravdu  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{25} \sum_{i=1}^{25} X_i = \mathbf{82.320}$

V případě příjmů je však lépe použít geometrický průměr:  $\hat{X} = \left( \prod_{i=1}^n X_i \right)^{\frac{1}{n}} = 32.730$

(Neboť mzdy mají zpravidla silně zešikmené rozdělení)



# Pohádka o Zbohatlíkově

Lhal tedy zprostředkovatel?

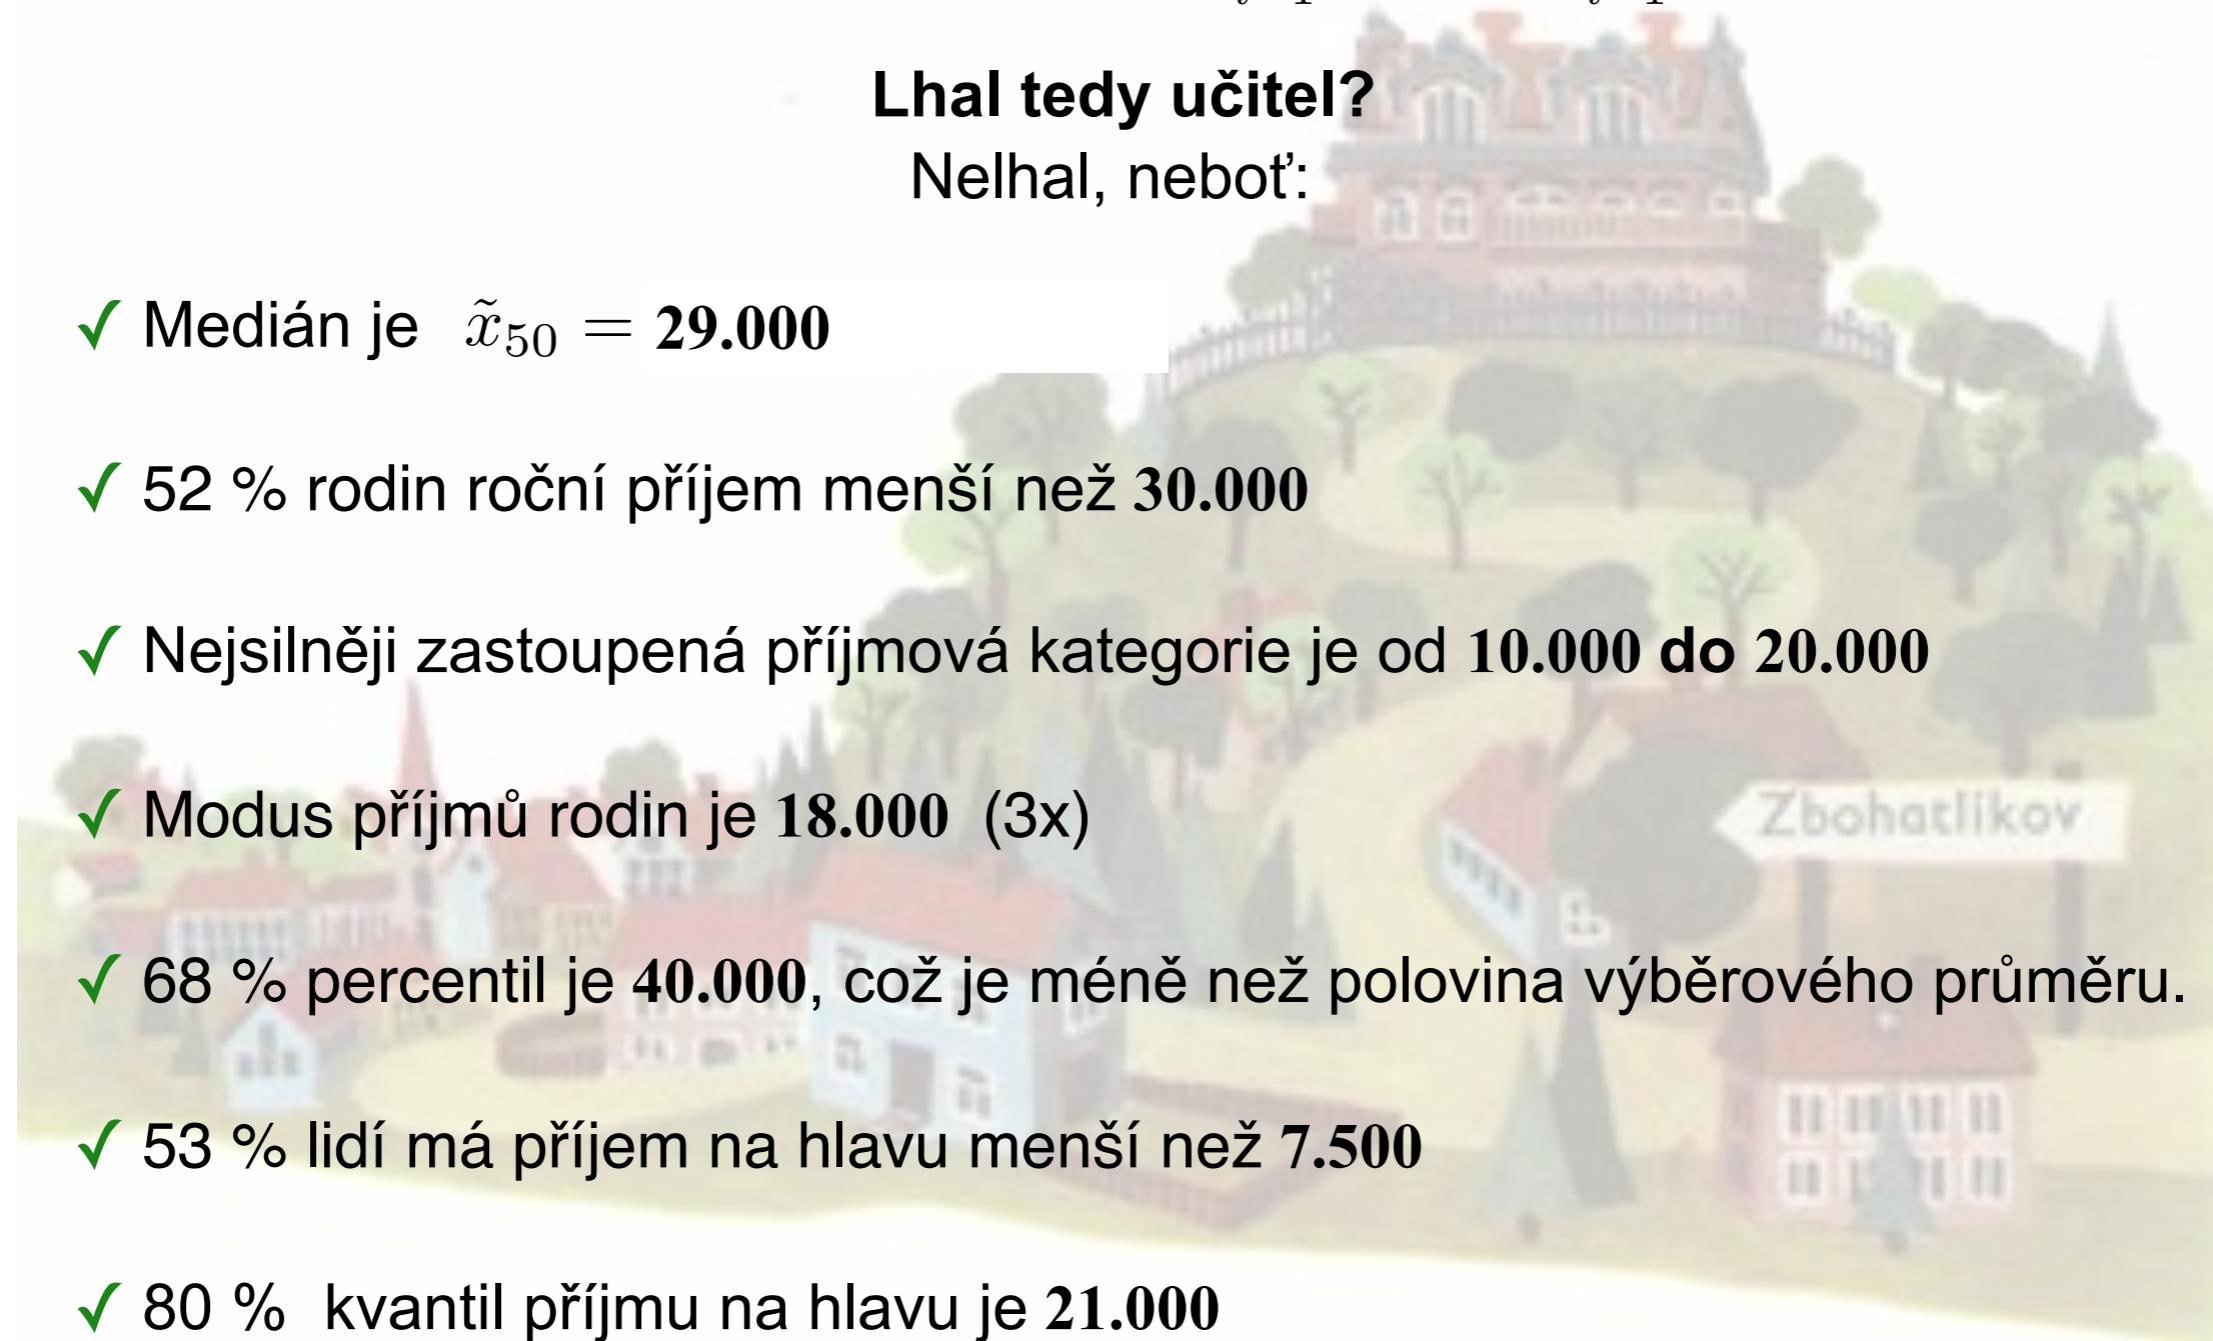
Nelhal, neboť:

- ✓ Výběrový průměr je opravdu  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{25} \sum_{i=1}^{25} X_i = \mathbf{82.320}$

Lhal tedy učitel?

Nelhal, neboť:

- ✓ Medián je  $\tilde{x}_{50} = \mathbf{29.000}$
- ✓ 52 % rodin roční příjem menší než **30.000**
- ✓ Nejsilněji zastoupená příjmová kategorie je od **10.000 do 20.000**
- ✓ Modus příjmů rodin je **18.000** (3x)
- ✓ 68 % percentil je **40.000**, což je méně než polovina výběrového průměru.
- ✓ 53 % lidí má příjem na hlavu menší než **7.500**
- ✓ 80 % kvantil příjmu na hlavu je **21.000**



**... a písnička na závěr ...**

