

# Odhady parametrů základního souboru

# Úvodní poznámky

- **Základní soubor** můžeme popsat jeho parametry, např. střední hodnota  $\mu$ , rozptyl  $\sigma^2$  atd. Při praktických úlohách ovšem zpravidla nelze vyšetřit celou populaci, provádíme tzv. **náhodný výběr** z populace. Náhodný výběr popisujeme rovněž jeho parametry, např. výběrový průměr  $\bar{x}$ , výběrový rozptyl  $s^2$  atd.

# Úvodní poznámky

- Parametry populace jsou konstantní, parametry náhodného výběru jsou ovšem náhodné proměnné (provedením jiného náhodného výběru získáme jiné hodnoty parametrů) řídící se **výběrovým rozdělením**. Známe-li pro konkrétní výběrovou charakteristiku její výběrové rozdělení, jsem potom schopni odhadnout parametr celé populace.

# Úvodní poznámky

- Rozlišujeme dva typy odhadů:
  - 1) **Bodový odhad** – parametr populace aproximujeme jedním číslem.
  - 2) **Intervalový odhad** – parametr populace aproximujeme intervalem, ve kterém jeho hodnota leží s určitou pravděpodobností.

# Vlastnosti bodového odhadu

- Mějme náhodný výběr  $x_1, x_2, \dots, x_n$  pocházejícího z rozdělení pravděpodobnosti definovaného distribuční funkcí  $F(x, \theta)$ , kde  $\theta$  je neznámý parametr. Bodový odhad parametru  $\theta$  budeme značit  $\hat{\theta}$ .

# Vlastnosti bodového odhadu

- Dobrý bodový odhad musí splňovat určité vlastnosti:
  - 1) **Nestrannost** (nevychýlenost, nezkreslenost).
  - 2) **Vydatnost** (eficience).
  - 3) **Konzistence**.
  - 4) **Dostatečnost**.

# Vlastnosti bodového odhadu

- Odhad je nestranný, pokud se jeho střední hodnota rovná hledanému parametru, tedy:

$$E\hat{\theta} = \theta.$$

- Slabší formou nestrannosti je **asymptotická nestrannost**, odhad je asymptoticky nestranný, pokud:

$$\lim_{n \rightarrow \infty} E\hat{\theta} = \theta.$$

- Např. výběrový průměr je nestranným odhadem střední hodnoty.

# Vlastnosti bodového odhadu

- Máme-li dva nestranné odhady, potom vybereme ten s menším rozptylem, tato vlastnost se nazývá vydatnost.
- Nestranný odhad, jehož rozptyl je nejmenší ze všech nestranných odhadů, se nazývá **nejlepší nestranný odhad**.
- Např. výběrový průměr je nejlepším nestranným odhadem střední hodnoty.



# Vlastnosti bodového odhadu

- Odhad je konzistentní, pokud se s rostoucím rozsahem výběru zpřesňuje, musí tedy platit:

$$\lim_{n \rightarrow \infty} E\hat{\theta} = \theta \text{ a } \lim_{n \rightarrow \infty} D\hat{\theta} = 0.$$

- Např. výběrový průměr je konzistentním odhadem střední hodnoty.

# Vlastnosti bodového odhadu

- Odhad je dostatečný, pokud obsahuje veškerou informaci o sledovaném parametru, kterou výběrový soubor poskytuje.
- Výběrový průměr je dostatečným odhadem střední hodnoty.

# Konstrukce bodových odhadů

- Pro konstrukci bodových odhadů existuje více metod, my se budeme zabývat **metodou maximální věrohodnosti**.

# Metoda maximální věrohodnosti

- Necht' náhodný výběr pochází z diskrétního rozdělení pravděpodobnosti definovaného pravděpodobnostní funkcí s neznámým parametrem  $\theta$ . **Věrohodnostní funkce** je potom definována jako sdružená pravděpodobnostní funkce  $n$  nezávislých proměnných se stejným diskrétním rozdělením:

$$L(x_1, \dots, x_n, \theta) = p(x_1, \theta) \cdot \dots \cdot p(x_n, \theta) = \prod_{i=1}^n p(x_i, \theta).$$

# Metoda maximální věrohodnosti

- Pochází-li výběr ze spojitého rozdělení s neznámým parametrem  $\theta$ , je věrohodnostní funkce definována jako sdružená hustota pravděpodobnosti  $n$  nezávislých proměnných se stejným spojitým rozdělením:

$$L(x_1, \dots, x_n, \theta) = f(x_1, \theta) \cdot \dots \cdot f(x_n, \theta) = \prod_{i=1}^n f(x_i, \theta).$$

# Metoda maximální věrohodnosti

- Jelikož je věrohodnostní funkce neznámého parametru  $\theta$ , je nyní úkolem najít  $\hat{\theta}$  tak, aby se maximalizovala hodnota věrohodnostní funkce, tedy:

$$L(x_1, \dots, x_n, \hat{\theta}) = \max_{\theta} \{L(x_1, \dots, x_n, \theta)\}.$$

- Při praktických výpočtech se místo věrohodnostní funkce pracuje s jejím přirozeným algoritmem.

# Metoda maximální věrohodnosti

- Podmínku optimality můžeme tedy vyjádřit ve tvaru:

$$\frac{\partial \ln L(x_1, \dots, x_n, \theta)}{\partial \theta} = 0.$$

- Řešením této rovnice (v případě více neznámých parametrů řešením soustavy rovnic) získáme odhady neznámého parametru, resp. parametrů.

# Metoda maximální věrohodnosti

- **Př. 1:** Je dán výběr  $x_1, x_2, \dots, x_n$  pocházející z Poissonova rozdělení. Metodou maximální věrohodnosti odhadněte parametr  $\lambda$ .
- Poissonovo rozdělení je definováno pravděpodobnostní funkcí ve tvaru:

$$p(X = x_i) = \frac{\lambda^{x_i}}{x_i!} \cdot e^{-\lambda} \text{ pro } x_i = 0, 1, 2, \dots \text{ a } \lambda > 0.$$



# Metoda maximální věrohodnosti

- Pro věrohodnostní funkci můžeme psát:

$$L(x_1, \dots, x_n, \lambda) = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} \cdot e^{-\lambda}.$$

- Věrohodnostní funkci zlogaritmujeme a dále upravujeme:

$$\begin{aligned} \ln L(x_1, \dots, x_n, \lambda) &= \ln \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} \cdot e^{-\lambda} = \sum_{i=1}^n \ln \left( \frac{\lambda^{x_i}}{x_i!} \cdot e^{-\lambda} \right) = \\ &= \sum_{i=1}^n (\ln \lambda^{x_i} + \ln e^{-\lambda} - \ln x_i!) = \sum_{i=1}^n (x_i \cdot \ln \lambda - \lambda \cdot \ln e - \ln x_i!) = \end{aligned}$$

# Metoda maximální věrohodnosti

$$= \sum_{i=1}^n x_i \cdot \ln \lambda - \sum_{i=1}^n \lambda - \sum_{i=1}^n \ln x_i! = \ln \lambda \cdot \sum_{i=1}^n x_i - n \cdot \lambda - \sum_{i=1}^n \ln x_i!.$$

- Upravený logaritmus věrohodnostní funkce derivujeme podle neznámého parametru  $\lambda$  a vyhledáme extrém:

$$\frac{\partial L(x_1, \dots, x_n, \lambda)}{\partial \lambda} = \frac{1}{\lambda} \cdot \sum_{i=1}^n x_i - n = 0$$

# Metoda maximální věrohodnosti

- Získanou rovnicí upravujeme:

$$\frac{1}{\lambda} \cdot \sum_{i=1}^n x_i - n = 0,$$

$$\sum_{i=1}^n x_i = n \cdot \lambda \Rightarrow \hat{\lambda} = \frac{1}{n} \cdot \sum_{i=1}^n x_i = \bar{x}.$$

- Na závěr ověříme, zda nalezený extrém je maximum:

$$\frac{\partial^2 L(x_1, \dots, x_n, \lambda)}{\partial \lambda^2} = -\frac{1}{\lambda^2} \cdot \sum_{i=1}^n x_i < 0, \text{ jedná se tedy o maximum.}$$

# Metoda maximální věrohodnosti

- **Př. 2:** Je dán výběr  $x_1, x_2, \dots, x_n$  pocházející z exponenciálního rozdělení. Metodou maximální věrohodnosti odhadněte parametr  $\mu$ .
- Exponenciální rozdělení je definováno hustotou pravděpodobnosti ve tvaru:  
$$f(x_i) = \mu \cdot e^{-\mu \cdot x_i} \text{ pro } x_i > 0 \text{ a } \mu > 0.$$

# Metoda maximální věrohodnosti

- Pro věrohodnostní funkci můžeme psát:

$$L(x_1, \dots, x_n, \mu) = \prod_{i=1}^n \mu \cdot e^{-\mu \cdot x_i}.$$

- Věrohodnostní funkci zlogaritmujeme a dále upravujeme:

$$\begin{aligned} \ln L(x_1, \dots, x_n, \mu) &= \ln \prod_{i=1}^n \mu \cdot e^{-\mu \cdot x_i} = \sum_{i=1}^n \ln(\mu \cdot e^{-\mu \cdot x_i}) = \\ &= \sum_{i=1}^n (\ln \mu + \ln e^{-\mu \cdot x_i}) = \sum_{i=1}^n (\ln \mu - \mu \cdot x_i \cdot \ln e) = \sum_{i=1}^n \ln \mu - \sum_{i=1}^n \mu \cdot x_i = \\ &= n \cdot \ln \mu - \mu \cdot \sum_{i=1}^n x_i. \end{aligned}$$

# Metoda maximální věrohodnosti

- Upravený logaritmus věrohodnostní funkce derivujeme podle neznámého parametru  $\mu$  a vyhledáme extrém:

$$\frac{\partial nL(x_1, \dots, x_n, \mu)}{\partial \mu} = \frac{n}{\mu} - \sum_{i=1}^n x_i = 0.$$

# Metoda maximální věrohodnosti

- Získanou rovnici upravujeme:

$$\frac{n}{\mu} - \sum_{i=1}^n x_i = 0,$$

$$\frac{n}{\mu} = \sum_{i=1}^n x_i \Rightarrow \hat{\mu} = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}}.$$

- Ověříme, zda nalezený extrém je maximum:

$$\frac{\partial^2 L(x_1, \dots, x_n, \mu)}{\partial \mu^2} = -\frac{n}{\mu^2} < 0, \text{ jedná se tedy o maximum.}$$

# Intervalové odhady

- Hledaný parametr aproximujeme intervalem (nazývá se **interval spolehlivosti**, resp. **konfidenční interval**), ve kterém jeho hodnota leží s určitou pravděpodobností – **spolehlivost odhadu**.
- Spolehlivost odhadu označujeme  $1 - \alpha$ , kde  $\alpha$  se nazývá **hladina významnosti**, zpravidla se volí  $\alpha = 0,05$  nebo  $0,01$ .
- S rostoucí spolehlivostí odhadu roste i šířka intervalu spolehlivosti.



# Intervalové odhady

- Označme dolní mez konfidenčního intervalu  $T_d$  a horní mez  $T_h$ .
- Rozlišujeme 3 druhy intervalů spolehlivosti:

1) Levostranný interval spolehlivosti:

$$P(\theta > T_d) = 1 - \alpha,$$

2) Pravostranný interval spolehlivosti:

$$P(\theta < T_h) = 1 - \alpha,$$

3) Oboustranný interval spolehlivosti:

$$P(\theta < T_d) = P(\theta > T_h) = \frac{\alpha}{2} \Rightarrow P(T_d < \theta < T_h) = 1 - \alpha.$$

# Intervalový odhad střední hodnoty

- Předpokladem je, že náhodný výběr pochází z normálního rozdělení.
- Mohou vzniknout dva případy:
  - 1) Známe směrodatnou odchylku  $\sigma$  normálního rozdělení, ze kterého pochází náhodný výběr.
  - 2) Neznáme směrodatnou odchylku  $\sigma$  normálního rozdělení, ze kterého pochází náhodný výběr.

# Intervalový odhad střední hodnoty

- ad 1) Mějme náhodný výběr o rozsahu  $n$  a s průměrem  $\bar{x}$  pocházející z normálního rozdělení se známým rozptylem  $\sigma^2$ .
- Víme, že pro náhodnou proměnnou  $Z$  platí:

$$Z = \frac{\bar{x} - \mu}{\sigma} \cdot \sqrt{n} \rightarrow N(0,1),$$

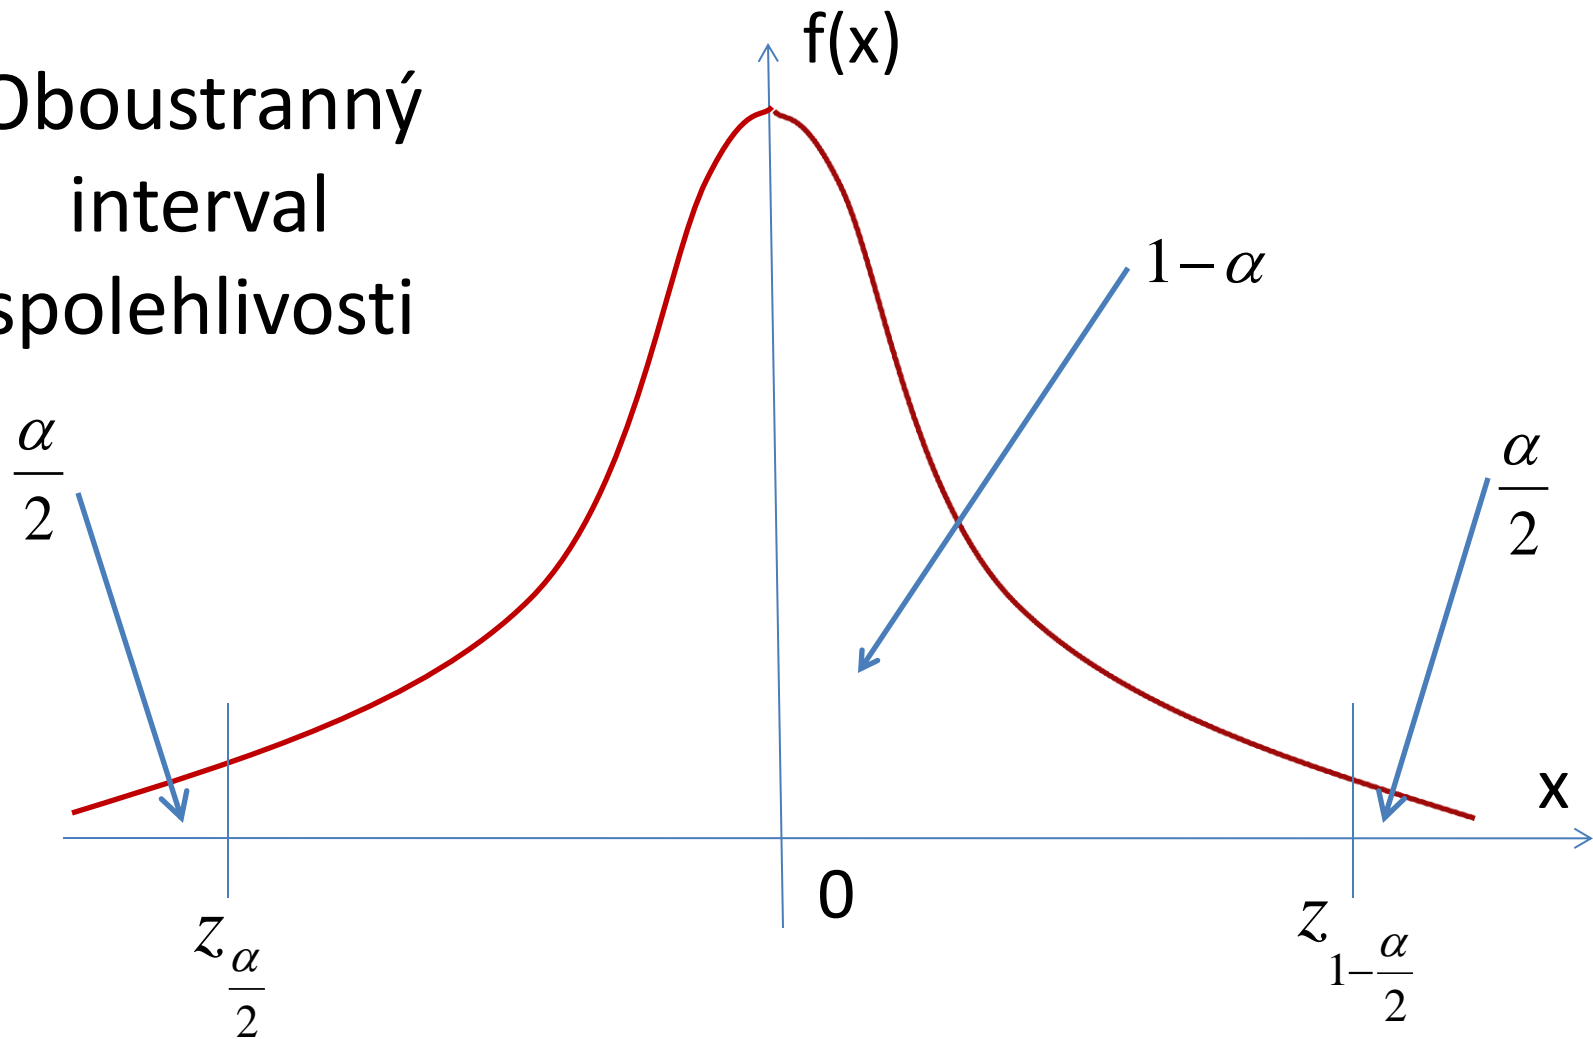
takto definovaná náhodná proměnná se tedy řídí normovaným rozdělením pravděpodobnosti.

# Intervalový odhad střední hodnoty

- Odvodíme si nyní oboustranný interval spolehlivosti pro střední hodnotu. Označme  $100 \cdot \frac{\alpha}{2}$  %-ní kvantil normovaného rozdělení jako  $z_{\frac{\alpha}{2}}$  a  $100 \cdot \left(1 - \frac{\alpha}{2}\right)$  %-ní kvantil jako  $z_{1 - \frac{\alpha}{2}}$ .

# Intervalový odhad střední hodnoty

Oboustranný  
interval  
spolehlivosti



# Intervalový odhad střední hodnoty

- Na základě obrázku můžeme psát:

$$P\left(z_{\frac{\alpha}{2}} < Z < z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha.$$

- Dosadíme a postupně upravujeme:

$$P\left(z_{\frac{\alpha}{2}} < \frac{\bar{x} - \mu}{\sigma} \cdot \sqrt{n} < z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha,$$

$$P\left(\frac{\sigma}{\sqrt{n}} \cdot z_{\frac{\alpha}{2}} < \bar{x} - \mu < \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha,$$

# Intervalový odhad střední hodnoty

$$P\left(\frac{\sigma}{\sqrt{n}} \cdot z_{\frac{\alpha}{2}} - \bar{x} < -\mu < \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}} - \bar{x}\right) = 1 - \alpha,$$

$$P\left(\bar{x} - \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}} < \mu < \bar{x} - \frac{\sigma}{\sqrt{n}} \cdot z_{\frac{\alpha}{2}}\right) = 1 - \alpha,$$

$$P\left(\bar{x} - \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}} < \mu < \bar{x} + \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha.$$

---

pozn. Jelikož je normované rozdělení souměrné, platí mezi kvantily vztah:

$$z_{\frac{\alpha}{2}} = -z_{1-\frac{\alpha}{2}}.$$

# Intervalový odhad střední hodnoty

- Vidíme tedy, že dolní mez konfidenčního intervalu stanovíme dle vztahu:

$$T_d = \bar{x} - \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}}$$

a horní mez podle vztahu:

$$T_h = \bar{x} + \frac{\sigma}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}}$$



# Intervalový odhad střední hodnoty

- Příslušnou hodnotu kvantilu normovaného rozdělení získáme buď z tabulek nebo s využitím funkce Excelu `NORMSINV`:

$$z_{1-\frac{\alpha}{2}} = \text{NORMSINV}\left(1 - \frac{\alpha}{2}\right).$$

# Intervalový odhad střední hodnoty

- V případě levostranného intervalu spolehlivosti získáme dolní hranici podle vztahu:

$$T_d = \bar{x} - \frac{\sigma}{\sqrt{n}} \cdot z_{1-\alpha}$$

v případě pravostranného intervalu získáme horní hranici podle vzorce:

$$T_h = \bar{x} + \frac{\sigma}{\sqrt{n}} \cdot z_{1-\alpha} \cdot$$

# Intervalový odhad střední hodnoty

- ad 2) Mějme náhodný výběr o rozsahu  $n$  a s průměrem  $\bar{x}$  pocházející z normálního rozdělení s neznámým rozptylem.


- Víme, že platí:

$$T_{n-1} = \frac{\bar{x} - \mu}{s} \cdot \sqrt{n} \rightarrow t_{n-1},$$

testová statistika se tedy řídí Studentovým rozdělením pravděpodobnosti s  $n - 1$  stupni volnosti.

# Intervalový odhad střední hodnoty

Oboustranný  
interval  
spolehlivosti



# Intervalový odhad střední hodnoty

- Na základě obrázku můžeme psát:

$$P\left(t_{\frac{\alpha}{2};n-1} < T_{n-1} < t_{1-\frac{\alpha}{2};n-1}\right) = 1 - \alpha.$$

- Dosazením a analogickými úpravami (Studentovo rozdělení je rovněž souměrné) získáme konečný vztah:

$$P\left(\bar{x} - \frac{s}{\sqrt{n}} \cdot t_{1-\frac{\alpha}{2};n-1} < \mu < \bar{x} + \frac{s}{\sqrt{n}} \cdot t_{1-\frac{\alpha}{2};n-1}\right) = 1 - \alpha.$$

# Intervalový odhad střední hodnoty

- Vidíme tedy, že dolní mez konfidenčního intervalu stanovíme dle vztahu:

$$T_d = \bar{x} - \frac{s}{\sqrt{n}} \cdot t_{1-\frac{\alpha}{2}; n-1}$$

a horní mez podle vztahu:

$$T_h = \bar{x} + \frac{s}{\sqrt{n}} \cdot t_{1-\frac{\alpha}{2}; n-1}.$$

# Intervalový odhad střední hodnoty

- Příslušnou hodnotu kvantilu Studentova rozdělení získáme buď z tabulek nebo s využitím funkce Excelu `TINV`:

$$t_{1-\frac{\alpha}{2}; n-1} = TINV(\alpha; n-1).$$

# Intervalový odhad střední hodnoty

- V případě levostranného intervalu spolehlivosti získáme dolní hranici podle vztahu:

$$T_d = \bar{x} - \frac{s}{\sqrt{n}} \cdot t_{1-\alpha; n-1}$$

v případě pravostranného intervalu získáme horní hranici podle vzorce:

$$T_h = \bar{x} + \frac{s}{\sqrt{n}} \cdot t_{1-\alpha; n-1}.$$

- Příslušný kvantil pomocí Excelu získáme:

$$t_{1-\alpha; n-1} = TINV(2\alpha; n-1).$$



# Intervalový odhad střední hodnoty

- V případě, když neznáme směrodatnou odchylku normálního rozdělení, ze kterého pochází náhodný výběr, ale máme výběr velkého rozsahu (tj.  $n \geq 30$ ), můžeme Studentovo rozdělení aproximovat normovaným rozdělením, pro výpočet konfidenčního intervalu můžeme použít první vztahy ( $\sigma = s$ ).