

# Příklady - Bodový odhad

15. října 2013

## Pražské metro

Přijdu v pražském metru na nástupiště a tam zjistím, že metro v mém směru jelo před 2:30 a metro v opačném směru před 4:20. Udělejte bodový odhad, jak dlouho budu čekat na metro.

### 1) Metoda momentů

Označím si:

$$X = 2 : 30 = 150s,$$

$$Y = 4 : 20 = 260s.$$

Předpokládejme, že metra jezdí v pravidelných intervalech po  $B$  sekundách. Pokud přijdu v náhodný okamžik, má doba, jakou budu čekat, rovnoměrné spojité rozdělení od 0 do  $B$ .

Odhaduji jeden parametr, bude mi tedy stačit první moment, tedy střední hodnota. Zjistím tedy střední hodnotu, jak dlouho bych čekal na metro a střední hodnotu z rovnoměrného spojitého rozdělení. Obojí porovnáme.

Podle zadání budu v jednom směru čekat  $x_1 = B - X$  a v druhém směru  $x_2 = B - Y$ . Střední hodnota těchto časů je:  $= \frac{B-X+B-Y}{2} = B - \frac{X+Y}{2} = B - \frac{150+260}{2} = B - 205$ .

Střední hodnota pro rovnoměrné rozdělení od 0 do  $B$  je:  $\mu = \frac{0+B}{2} = \frac{B}{2}$ .

Porovnáme:

$$\begin{aligned}\mu &= \bar{x} \\ \frac{B}{2} &= B - 205 \\ B &= 2B - 410 \\ B &= 410\end{aligned}$$

Máme tedy bodový odhad pro dobu, po jaké jezdí metra. Bodový odhad pro dobu, jakou budu čekat v prvním směru je tedy:  $T = B - X = 410 - 150 = 260$ .

Můžeme si všimnout, že nám vyšla stejná hodnota jako je  $Y$ . Není to náhoda, protože když příklad necháme v písmenkách  $X$  a  $Y$ , vyjde nám

$$\begin{aligned}\frac{B}{2} &= B - \frac{X+Y}{2} \\ B &= X+Y\end{aligned}$$

$$T = B - X = Y$$

Získáváme tedy poněkud paradoxní výsledek, že nejlepší bodový odhad doby, jakou budu čekat na metro, získám tak, že se podívám na hodiny v opačném směru.

Je tento podivný výsledek správně?

Ano, je. Musíme si ale uvědomit, že děláme bodový odhad, který nám nic neříká o přesnosti odhadu. A protože celou metodu nasazujeme jen na dva údaje, je odhad velmi, velmi nepřesný.

## 2) Metoda maximální věrohodnosti

Vyřešíme stejný příklad metodou maximální věrohodnosti. Pro rovnoměrné rozdělení se to dělá spíše úvahou než výpočtem, což si ukážeme.

Metra jezdí v pravidelných intervalech délky  $B$ . Pro dobu, před jakou odjelo metro, mám opět rovnoměrné rozdělení od 0 do  $B$ .

Znám dvě hodnoty pro doby, před jakou odjelo metro:

$$X = 2 : 30 = 150s,$$

$$Y = 4 : 20 = 260s.$$

Určitě chci, aby tyto hodnoty ležely v intervalu  $\langle 0, B \rangle$ . Pak bude hustota pravděpodobnosti pro obě hodnoty rovna:

$$f(150) = \frac{1}{B},$$

$$f(260) = \frac{1}{B}.$$

(Hustota pravděpodobnosti má tvar obdélníku. Jeho délka je  $B$ . Integrál přes def. obor musí být 1, takže výška obdélníku je  $\frac{1}{B}$ .)

Chci mít co největší věrohodnostní funkci, což je:  $V(B) = f(150) \cdot f(260) = \frac{1}{B} \cdot \frac{1}{B}$ . Proto musí být  $B$  co nejmenší. A přesto se obě hodnoty musí do intervalu vejít. To nejlépe udělám tak, že  $B$  bude rovno největší hodnotě z dat. Tedy  $B = \max(X_i) = 260$ .

Odhad pro dobu čekání je tedy  $260 - 150 = 110$ .

## Shrnutí a porovnání metod

Obě metody nám tedy dávají různé odhady. A mají také různé statistiky pro odhad parametru  $B$ :

$$B = X + Y,$$

$$B = \max(X_i).$$

Která z těchto statistik je lepší?

Soustředme se na druhou statistiku. Pokud bychom znali skutečnou hodnotu  $B$  a pak ji odhadovali největší hodnotou, která padla, pak bude odhad vždy menší než skutečná hodnota. Takže statistika nebude nestranná!!! (Bude tzv. „vychýlená“.) Takže to není dobrá statistika a dáme přednost první metodě momentů.

Udělejme si takové porovnání obou metod:

**Rovnoměrné rozdělení:** Lepší je metoda momentů.

**Exponenciální rozdělení:** Obě metody dávají stejné výsledky. Metoda momentů bývá jednodušší.

**Normální = Gaussovo rozdělení:** Metoda momentů je jednodušší a dává lepší výsledky.

**Složité několikarozměrné rozdělení:** Lepší je metoda maximální věrohodnosti.

## Normální = Gaussovo rozdělení

Naměřili jsme tato data: 2, 8, 8, 14. Předpokládáme, že tato data mají normální rozdělení. Jaké konkrétní Gaussové křivce nejlépe odpovídají?

### 1) Metoda maximální věrohodnosti

Tato metoda je poměrně pracná a pro normální rozdělení nedává příliš dobrý odhad pro rozptyl. Přesto jsem ji tu ukázal, abyste se s ní seznámili.

Gaussova křivka je dána parametry  $\mu$  a  $\sigma$ . Tyto parametry tedy odhadneme.

Hustota pravděpodobnosti normálního rozdělení je dána vzorcem:

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

Věrohodnostní funkce je tedy dána vzorcem:

$$\begin{aligned} V(\mu, \sigma) &= \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(2-\mu)^2}{2\sigma^2}} \cdot \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(8-\mu)^2}{2\sigma^2}} \cdot \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(8-\mu)^2}{2\sigma^2}} \cdot \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(14-\mu)^2}{2\sigma^2}} = \\ &= \left( \frac{1}{\sigma\sqrt{2\pi}} \right)^4 \cdot e^{-\frac{(2-\mu)^2+(8-\mu)^2+(8-\mu)^2+(14-\mu)^2}{2\sigma^2}} = \\ &= \frac{1}{4\pi^2} \cdot \sigma^{-4} \cdot e^{-\frac{1}{2} \cdot \sigma^{-2} \cdot [(2-\mu)^2+(8-\mu)^2+(8-\mu)^2+(14-\mu)^2]}. \end{aligned}$$

Hledáme maximum funkce, tedy body, v nichž jsou obě parciální derivace podle  $\mu$  i podle  $\sigma$  rovny 0.

Spočtěme první parciální derivaci:

$$\begin{aligned} \frac{\partial V}{\partial \mu} &= \frac{1}{4\pi^2} \cdot \sigma^{-4} \cdot e^{-\frac{1}{2} \cdot \sigma^{-2} \cdot [(2-\mu)^2+(8-\mu)^2+(8-\mu)^2+(14-\mu)^2]} \cdot \\ &\quad \cdot \left( -\frac{1}{2} \right) \cdot \sigma^{-2} \cdot [-2(2-\mu) - 2(8-\mu) - 2(8-\mu) - 2(14-\mu)] = \\ &= \frac{1}{4\pi^2} \cdot \sigma^{-6} \cdot e^{-\frac{1}{2} \cdot \sigma^{-2} \cdot [(2-\mu)^2+(8-\mu)^2+(8-\mu)^2+(14-\mu)^2]} \cdot [(2-\mu) + (8-\mu) + (8-\mu) + (14-\mu)]. \end{aligned}$$

Kdy se tento výraz rovná nule? Tehdy, když je nulová hranatá závorka napravo. Máme tedy rovnici:

$$\begin{aligned} [(2-\mu) + (8-\mu) + (8-\mu) + (14-\mu)] &= 0 \\ 32 - 4\mu &= 0 \\ \mu &= 8. \end{aligned}$$

Spočtěme ještě druhou parciální derivaci:

$$\frac{\partial V}{\partial \sigma} = \frac{1}{4\pi^2} \cdot \left[ -4\sigma^{-5} \cdot e^{-\frac{1}{2} \cdot \sigma^{-2} \cdot [(2-\mu)^2+(8-\mu)^2+(8-\mu)^2+(14-\mu)^2]} + \right.$$

$$\begin{aligned}
& +\sigma^{-4} \cdot e^{-\frac{1}{2} \cdot \sigma^{-2} \cdot [(2-\mu)^2 + (8-\mu)^2 + (8-\mu)^2 + (14-\mu)^2]} \cdot \\
& \cdot \left(-\frac{1}{2}\right) \cdot (-2\sigma^{-3}) \cdot \left[(2-\mu)^2 + (8-\mu)^2 + (8-\mu)^2 + (14-\mu)^2\right] = \\
= & \frac{1}{4\pi^2} \cdot e^{-\frac{1}{2} \cdot \sigma^{-2} \cdot [(2-\mu)^2 + (8-\mu)^2 + (8-\mu)^2 + (14-\mu)^2]} \cdot \sigma^{-7} \cdot \\
& \cdot \left[-4\sigma^2 + (2-\mu)^2 + (8-\mu)^2 + (8-\mu)^2 + (14-\mu)^2\right].
\end{aligned}$$

Kdy se tento výraz rovná nule? Když je nulová hranatá závorka na posledním řádku. Máme tedy:

$$\begin{aligned}
-4\sigma^2 + (2-\mu)^2 + (8-\mu)^2 + (8-\mu)^2 + (14-\mu)^2 &= 0 \\
-4\sigma^2 + (2-8)^2 + (8-8)^2 + (8-8)^2 + (14-8)^2 &= 0 \\
-4\sigma^2 + 36 + 0 + 0 + 36 &= 0 \\
\sigma^2 &= 18.
\end{aligned}$$

Hledané rozdělení je tedy:  $N(8, 18)$ .

Můžeme si všimnout, že získaný rozptyl je rozptyl, jako kdyby data byla základním souborem. To je chybička, která s rostoucím počtem dat mizí. Odhad rozptylu je vychýlený, proto dáme přednost metodě momentů.

## 2) Metoda momentů

Střední hodnota dat je:  $\bar{x} = 8$ .

Výběrový rozptyl dat je:  $s^2 = 24$ .

Střední hodnotu a rozptyl základního souboru odhadneme střední hodnotou a rozptylem výběrového souboru:

$$\begin{aligned}
\mu &= \bar{x} = 8, \\
\sigma^2 &= s^2 = 24.
\end{aligned}$$

Hledané rozdělení je:  $N(8, 24)$ .

Metoda je podstatně jednodušší a dává pro rozptyl správný výsledek.

## Příklady ke spočtení

1) Několik atomových jader zkoumaného prvku se rozpadlo po 8, 4, 12, 2, 19, 3 minutách. Odhadněte funkci, která udává pravděpodobnost, že se jádro v určitém čase rozpadne.

$$\text{Exponenciální rozdělení, } f(t) = \frac{1}{8} \cdot e^{-\frac{t}{8}}$$

2) Hmotnost myší má normální rozdělení. Získali jsme následující hmotnosti myší: 6, 12, 7, 10, 18, 9, 12, 10, 15. Odhadněte rozdělení hmotnosti myší.

$$\text{Metoda momentů, } f(m) \sim N(11; 14, 25)$$

3) Má tramvaj jezdí ráno v pravidelných intervalech. Zlý vandal ale strhl jízdní řád. Na tramvaj jsem minulý týden čekal 2, 14, 8, 11 a 5 minut. Odhadněte, v jakém intervalu jezdí tramvaj.

Metoda momentů, rovnoměrné spojitě rozdělení, 16 minut.

4) Jsem opravář na železniční trati. Ráno jsem zjistil, že musím provést opravu na 111., 123. a 89. kilometru. Odhadněte, jaký úsek trati mám na starosti.

Metoda momentů, rovnoměrné spojitě rozdělení, 75. až 139. kilometr.