

## TEORIE ODHADU

### Vlastnosti „dobrého“ bodového odhadu

Dobrý“ (věrohodný) odhad musí splňovat určité vlastnosti. Mezi základní vlastnosti věrohodných odhadů patří:

- nestrannost (nevychýlenost, nezkreslenost)
- efektivita (vydatnost,eficience), nestranný odhad, jehož rozptyl je nejmenší mezi všemi nestrannými odhady příslušného parametru, se nazývá **nejlepší nestranný odhad**
- konzistence

## Postačující statistika pro parametr $\Theta$

Důkaz toho, zda je určitý odhad efektivní (nejlepší nestranný), není vždy jednoduchý. Abychom našli odhad, který má nejmenší rozptyl, je vhodné nahrazení celého výběru jednou statistikou, a to takovou, která bude obsahovat „veškerou“ informaci o parametru  $\Theta$ .

Pokud je možné pomocí nějaké statistiky (může se jednat o vícerozměrnou statistiku) odhadnout neznámé parametry souvisejícího rozdělení, hovoříme o **postačující statistice**. Nejjednodušší postačující statistikou je podle definice samotný vektor náhodného výběru  $\underline{X} = (X_1, \dots, X_n)$ , taková postačující statistika však není příliš užitečná. Smysl má hledat takové postačující statistiky, které mají rozměr menší než  $n$ .

### Definice:

Reálnou funkci  $T_n(\underline{X})$  nazveme **postačující statistikou pro parametr  $\theta$** , jestliže sdružené rozdělení náhodného výběru  $\underline{X} = (X_1, \dots, X_n)$  podmíněné jevem  $T(\underline{X})=t$  není pro žádné  $t$  závislé na  $\Theta$ .

Jestliže pro parametrickou funkci  $\tau(\Theta)$  existují nestranné odhady, pak nejlepší z nich (ve smyslu minimálního rozptylu) je funkcí postačujících statistik a je určen jednoznačně.

Jednoduchý postup při hledání postačujících statistik nabízí věta o faktorizaci. Tato věta zároveň umožňuje rychle rozhodnout o tom, zda je určitá statistika postačující.

### **Věta o faktorizaci:**

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodný výběr z rozdělení  $f(x; \Theta)$ .  $T(X)$  je postačující statistikou pro parametr  $\Theta$  právě tehdy, jestliže sdružené rozdělení náhodného výběru je součinem dvou faktorů:

$$f(\underline{x}, \Theta) = g\{T(\underline{x}), \Theta\} \cdot h(\underline{x})$$

**DK:**

$$T(\underline{X}) \text{ je postačující pro } \theta \Leftrightarrow f(x, \theta) = g(T(x), \theta) \cdot h(x)$$

(ověřte!):

$$\Rightarrow P(\underline{X} = x) = P(\underline{X} = x | T(\underline{X}) = t) \cdot P(T(\underline{X}) = t) = h(x) \cdot g(t, \theta) \quad \text{e.b.d}$$

= předpokládáme, že  $P(T(\underline{X}) = t) > 0$

$$P(\underline{X} = x | T(\underline{X}) = t) = \frac{P(\underline{X} = x \cap T(\underline{X}) = t)}{P(T(\underline{X}) = t)} = \begin{cases} 1) \text{ vezmeme takové } x, \text{ že } T(x) = t \\ 2) \text{ vezmeme takové } x, \text{ že } T(x) \neq t \end{cases}$$

$$1) = \frac{P(\underline{X} = x)}{P(T(\underline{X}) = t)} = \frac{h(x) \cdot g(t, \theta)}{\sum_{x: T(x) = t} P(\underline{X} = x)} = \frac{h(x) \cdot g(t, \theta)}{g(t, \theta) \cdot \sum_{x: T(x) = t} h(x)} = \frac{h(x)}{\sum_{x: T(x) = t} h(x)}$$

$$2) = \frac{P(\underline{X} = x \cap T(\underline{X}) = t)}{P(T(\underline{X}) = t)} = 0 \quad \text{neboť } T(x) = t \text{ je množinový jev: } P(A \cap \emptyset) = 0 \\ \text{ jmenovatel } > 0 \text{ (předtím)}$$

## Řešený příklad

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodný výběr z Poissonova rozdělení. Dokažme, že  $T(X) = \sum_{i=1}^n X_i$  je postačující statistikou pro parametr  $\Theta$  Poissonova rozdělení ( $\Theta = \lambda t$ ).

$$f(x, \Theta) = \frac{\Theta^x}{x!} \cdot e^{-\Theta} \quad x = 0, 1, 2, \dots, \Theta > 0$$

*Sdružené rozdělení výběru má tvar:*

$$\begin{aligned} f(\underline{x}, \Theta) &= P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) = \prod_{i=1}^n P(X_i = x_i) = \prod_{i=1}^n \frac{\Theta^{x_i}}{x_i!} \cdot e^{-\Theta} = \\ &= e^{-n \cdot \Theta} \cdot \frac{\Theta^{\sum_{i=1}^n x_i}}{\prod_{i=1}^n x_i!} \end{aligned}$$

kde  $x_i = 0, 1, \dots, \quad i = 1, 2, \dots,$

*Sdružené rozdělení výběru můžeme faktorizovat, tj. můžeme jej zapsat jako součin dvou faktorů:*

$$f(\underline{x}, \Theta) = g(t, \Theta) \cdot h(x)$$

$$f(\underline{x}, \Theta) = e^{-n \cdot \Theta} \cdot \Theta^t \cdot \frac{1}{\prod_{i=1}^n x_i!},$$

kde  $g(t, \Theta) = e^{-n \cdot \Theta} \cdot \Theta^t; \quad h(x) = \frac{1}{\prod_{i=1}^n x_i!}$

$T(X) = \sum_{i=1}^n X_i$  je tedy postačující statistikou pro parametr  $\Theta$ .

## Sdružená pravděpodobnostní funkce u některých rozdělení:

Poissonovo rozdělení :  $P(x; \lambda) = \exp(\ln \lambda \sum x_i - n\lambda - \sum \ln(x_i!))$

a postačující statistikou pro parametr  $\lambda$  je výběrový úhrn  $\sum x_i$ .

Exponenciálního rozdělení je  $f(\mathbf{x}; \delta) = \exp\left[-n \ln \delta - \frac{1}{\delta} \sum x_i\right]$

a opět postačující statistikou pro parametr  $\delta$  je výběrový úhrn  $\sum x_i$

Normálního rozdělení  $N(0, \sigma^2)$ , které má hustotu

$$f(x_i; 0; \sigma^2) = \exp\left(-\frac{1}{2} \ln 2\pi - \frac{1}{2} \ln \sigma^2 - \frac{x_i^2}{2\sigma^2}\right)$$

a sdružená hustota  $f(\mathbf{x}; 0; \sigma^2) = \exp\left(-\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2\right)$

postačující statistikou pro parametr  $\sigma^2$  je tedy  $\sum x_i^2$

## Konstrukce efektivních odhadů

Praktický význam postačujících statistik pro výpočet efektivních (nejlepších nestranných) odhadů ukazuje následující věta:

### Rao-Blackwellova věta

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodný výběr z rozdělení  $f(\underline{x}; \Theta)$ . Nechť existuje postačující statistika  $T(\underline{X})$  pro parametr  $\Theta$ . Nechť  $\tau(\Theta)$  je reálná funkce parametru  $\Theta$  a  $T^*(\underline{X})$  je nestranný odhad této charakteristiky. Potom platí:

1. Pro funkci  $\tau(\Theta)$  existuje nestranný odhad  $\tilde{T}(\underline{X}) = \tilde{T}(T(\underline{X}))$ , který je funkcí postačující statistiky  $T(\underline{X})$ .
2. Nestranný odhad  $\tilde{T}(\underline{X})$  má rozptyl menší nebo roven rozptylu odhadu  $T^*(\underline{X})$ :
$$D(\tilde{T}(\underline{X})) \leq D(T^*(\underline{X})) \quad \text{pro všechna } \Theta$$
3.  $D(\tilde{T}(\underline{X})) = D(T^*(\underline{X})) \iff P(\tilde{T}(\underline{X}) = T^*(\underline{X})) = 1 \quad \text{pro všechna } \Theta$



## Pomocné tvrzení

Je-li  $(X, Y)$  spojitý náhodný vektor se sdruženou hustotou  $f(x,y)$ , definujeme podmíněnou střední hodnotu takto:

$$E(X|Y = y) = \int_{-\infty}^{\infty} x \cdot f(x|y) dx,$$

kde 
$$f(x|y) = \frac{f(x, y)}{f_Y(y)} = \frac{f(x, y)}{\int_{-\infty}^{\infty} f(x, y) dx}$$

Důležitou vlastností podmíněné střední hodnoty je, že:

$$\begin{aligned} E_Y[E(X|Y)] &= \int_{-\infty}^{\infty} E(X|Y) \cdot f_Y(y) dy = \int_{-\infty}^{\infty} f_Y(y) \int_{-\infty}^{\infty} x \cdot f(x|y) dx dy = \\ &= \int_{-\infty}^{\infty} f_Y(y) \int_{-\infty}^{\infty} x \cdot \frac{f(x, y)}{f_Y(y)} dx dy = \int_{-\infty}^{\infty} x \cdot f_X(x) dx = E(X), \end{aligned}$$

kde  $E_Y$  je střední hodnota vzhledem k náhodné veličině  $Y$ .

## Důkaz Rao-Blackwellovy věty:

ad1)

Nechť  $T^*(\underline{X})$  je libovolný nestranný odhad parametrické funkce  $\tau(\Theta)$  a  $T(\underline{X})$  je postačující statistika pro parametr  $\theta$ .

Položme:

$$\tilde{T}(t) = E\{T^*(X) | T(X) = t\}$$

Protože  $T(\underline{X})$  je postačující statistikou, funkce  $\tilde{T}(t)$  není funkcí  $\theta$ , tedy  $\tilde{T}(T(\underline{X}))$  je statistika.

Dokážeme, že  $\tilde{T}(T(\underline{X}))$  je nestranný odhad parametrické funkce  $\tau(\Theta)$ .

Pro každé  $\Theta$  platí:

$$E_T(\tilde{T}) = E_T\{E[T^*(\underline{X}) | T(\underline{X}) = t]\} = E(T^*(\underline{X})) = \tau(\Theta)$$

c.b.d.

(viz pomocné tvrzení)

ad2)

$$\begin{aligned}
 D_T(T^*(\underline{X})) &= E_T \left\{ [T^*(\underline{X}) - E(T^*(\underline{X}))]^2 \right\} = E_T \left\{ [T^*(\underline{X}) - \tau(\Theta)]^2 \right\} = \\
 &= E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)] + [\tilde{T}(t) - \tau(\Theta)] \right\}^2 \Big\} = \\
 &= E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)]^2 \right\} + 2E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)] \cdot [\tilde{T}(t) - \tau(\Theta)] \right\} + E_T \left\{ [\tilde{T}(t) - \tau(\Theta)]^2 \right\}
 \end{aligned}$$

Střední hodnotu součinu můžeme vyjádřit jako:

$$\begin{aligned}
 &[T^*(\underline{X}) - \tilde{T}(t)] \cdot [\tilde{T}(t) - \tau(\Theta)] \\
 E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)] \cdot [\tilde{T}(t) - \tau(\Theta)] \right\} &= E_T \left\{ E \left[ (T^*(\underline{X}) - \tilde{T}(t)) (\tilde{T}(t) - \tau(\Theta)) \mid t \right] \right\} = \\
 &= E_T \left\{ (\tilde{T}(t) - \tau(\Theta)) \cdot E \left[ (T^*(\underline{X}) - \tilde{T}(t)) \mid t \right] \right\} = \\
 &= E_T \left\{ (\tilde{T}(t) - \tau(\Theta)) \cdot 0 \right\} = 0
 \end{aligned}$$

protože  $E \{ T^*(X) \mid T(X) = t \} = \tilde{T}(t)$

Tedy:

$$\begin{aligned}
 D_T(T^*(\underline{X})) &= E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)]^2 \right\} + 2E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)] \cdot [\tilde{T}(t) - \tau(\Theta)] \right\} + E_T \left\{ [\tilde{T}(t) - \tau(\Theta)]^2 \right\} = \\
 &= E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)]^2 \right\} + 0 + D_T(\tilde{T}(t)) \\
 E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)]^2 \right\} \geq 0 &\quad \Rightarrow \quad D_T(T^*(\underline{X})) \geq D_T(\tilde{T}(t)) \quad \text{c.b.d.}
 \end{aligned}$$

ad3)

$$D_T(T^*(X)) \geq D_T(\tilde{T}(t)) \quad \Leftrightarrow \quad E_T \left\{ [T^*(\underline{X}) - \tilde{T}(t)]^2 \right\} = 0 \quad \Leftrightarrow \quad P\{T^*(\underline{X}) = \tilde{T}(t)\} = 1$$

Z Rao-Blackwellovy věty vyplývá, že při hledání nejlepších nestranných odhadů se můžeme omezit na odhady, které jsou funkcemi postačujících statistik. Tato věta nám ukazuje, jak v případě, že známe libovolný nestranný odhad, určit nestranný odhad, který je funkcí postačující statistiky.

### Řešený příklad

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodný výběr z Poissonova rozdělení:

$$f(x, \Theta) = \frac{\Theta^x}{x!} \cdot e^{-\Theta} \quad x = 0, 1, 2, \dots, \Theta > 0$$

Nalezněte nejlepší nestranný odhad parametrické funkce:  $\tau(\Theta) = e^{-\Theta}$

tj. pravděpodobnosti toho, že náhodná veličina  $X$  s Poissonovým rozdělením nabude hodnoty 0.

Hledáme nejlepší nestranný odhad parametrické funkce:  $\tau(\Theta) = e^{-\Theta}$

Vzhledem k tomu, že  $\tau(\Theta)$  je pravděpodobnost toho, že náhodná veličina  $X$  s Poissonovým rozdělením nabude hodnoty 0, nabízí se jako vhodný nestranný odhad funkce  $\tau(\Theta)$  relativní četnost nulových hodnot  $X_i$  ve výběru, tj.

$$T^*(\underline{X}) = T(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n Y_i,$$

kde:

$$\begin{aligned} Y_i &= 0 && \text{pro } X_i \geq 1 \\ Y_i &= 1 && \text{pro } X_i = 0, \quad i = 1, 2, \dots, n \end{aligned}$$

Už víme, že pro parametr  $\Theta$  je  $T(\underline{X}) = \sum_{i=1}^n X_i$  postačující statistikou.

Nejlepší nestranný (efektivní) odhad  $\tilde{T}(t)$  funkce  $\tau(\Theta)$  budeme hledat následujícím způsobem:

1. Najdeme střední hodnotu  $T^*(\underline{X})$  podmíněnou jevem  $T(\underline{X}) = \sum_{i=1}^n X_i = t$

$$\tilde{T}(t) = E\{T^*(\underline{X})|T(\underline{X}) = t\} = E\left\{\frac{1}{n} \sum_{i=1}^n Y_i \middle| \sum_{i=1}^n X_i = t\right\} = \frac{1}{n} \sum_{i=1}^n P\left\{Y_i = 1 \middle| \sum_{i=1}^n X_i = t\right\} =$$

$$= \frac{1}{n} \sum_{i=1}^n P\left\{X_i = 0 \middle| \sum_{i=1}^n X_i = t\right\} = P\left\{X_1 = 0 \middle| \sum_{i=1}^n X_i = t\right\}$$

2. Postačující statistiku  $T(\underline{X}) = \sum_{i=1}^n X_i$  můžeme zapsat ve tvaru:

$$T(\underline{X}) = X_1 + \sum_{i=2}^n X_i = X_1 + Z,$$

kde  $X_1$  a  $Z$  jsou nezávislé náhodné veličiny s Poissonovým rozdělením:

$$E_{\Theta}(X_1) = \Theta \quad E_{\Theta}(Z) = (n-1) \cdot \Theta$$

*Pak:*

$$\tilde{T}(t) = \frac{P_{\Theta}(X_1 = 0) \cdot P_{\Theta}(Z = t)}{P_{\Theta}(X_1 + Z = t)} = \frac{e^{-\theta - \theta(n-1)} \cdot \frac{[\theta \cdot (n-1)]^t}{t!}}{e^{-n\theta} \cdot \frac{(n\theta)^t}{t!}} = \left(\frac{n-1}{n}\right)^t$$

*Efektivním odhadem parametrické funkce  $\tau(\Theta) = e^{-\Theta}$  je odhad  $\tilde{T}(t) = \left(\frac{n-1}{n}\right)^{\sum_{i=1}^n x_i}$ .*

## Fisherova míra informace

Důležitým ukazatelem kvality odhadu je jeho rozptyl (připomeňme, že každý odhad je náhodnou veličinou). Vyhovuje-li rozdělení, jehož parametr odhadujeme, jistým obecným předpokladům, lze ukázat, že není možné zkonstruovat odhad s rozptylem menším než jistá hodnota, tzv. Raova-Cramerova hranice. Mezi odhady s požadovanou vlastností se tedy vždy snažíme nalézt odhad, jehož rozptyl je roven této hodnotě. Pokud se to podaří, hovoříme o **odhadu s minimálním rozptylem**. Ve statistické literatuře se často operuje s **nestranným odhadem s minimálním rozptylem**.

K libovolnému rozdělení  $f(\underline{x}, \Theta)$  a k libovolné parametrické funkci  $\tau(\Theta)$  budeme hledat takovou funkci  $C(\Theta)$ , aby libovolný nestranný odhad  $\tilde{T}(\underline{X})$ , který splňuje podmínky regularity, měl rozptyl větší než  $C(\Theta)$ . Funkce  $C(\Theta)$  tedy bude dolní mezí rozptylů pro všechny nestranné odhady parametrické funkce  $\tau(\Theta)$ .

Existují nestranné odhady, jejichž rozptyl je roven  $C(\Theta)$ . V některých případech je však tato hranice dosažitelná pouze asymptoticky (pro  $n \rightarrow \infty$ ).

Dříve než se pustíme do hledání funkce  $C(\Theta)$ , definujeme si některé pojmy.



## Definice:

Předpokládejme, že  $\Theta$  je jednorozměrný parametr. Říkáme, že **systém hustot**

$$\{f(x, \Theta), \Theta \in \Theta\}$$

je **regulární** právě když:

1.  $\Theta$  je neprázdná otevřená množina
2. Množina  $M = \{x: f(x, \Theta) > 0\}$  není funkcí  $\Theta$
3. Pro každé  $x \in M$  existuje konečná parciální derivace:

$$f'(x, \Theta) = \frac{\partial f(x, \Theta)}{\partial \Theta}$$

4. Pro každé  $\Theta \in \Theta$ ,

$$Z(X, \Theta) = \frac{\partial \ln f(X, \Theta)}{\partial \Theta} \text{ platí: } EZ = 0$$

$$\int_M \frac{\partial \ln f(x, \Theta)}{\partial \Theta} \cdot f(x, \Theta) dx = \int_M \frac{f'(x, \Theta)}{f(x, \Theta)} f(x, \Theta) dx = \int_M f'(x, \Theta) dx = 0$$

5.  $0 < DZ < \infty$  (konečný, kladný rozptyl)

$$\begin{aligned} DZ = I(\Theta) &= \int_M \left( \frac{\partial \ln f(x, \Theta)}{\partial \Theta} - EZ \right)^2 f(x, \Theta) dx = \int_M \left( \frac{\partial \ln f(x, \Theta)}{\partial \Theta} \right)^2 f(x, \Theta) dx \\ &= \int_M \left( \frac{f'(x, \Theta)}{f(x, \Theta)} \right)^2 f(x, \Theta) dx = \int_M \left( \frac{f'(x, \Theta)}{f(x, \Theta)} \right)^2 f(x, \Theta) dx \end{aligned}$$

Zjednodušeně často místo o regulárnosti systému hustot mluvíme o **regulárnosti rozdělení  $f(x, \Theta)$** .

## Řešený příklad

Dokažte, že hustota normálního rozdělení  $N(\Theta, 1)$  je regulární.

Hustota normálního rozdělení  $N(\Theta, 1)$ :

$$f(x, \Theta) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{(x-\Theta)^2}{2}} \quad \text{pro } \Theta \in R$$

ad1)  $\Theta \in R$ ,  $\Theta$  je neprázdná otevřená množina

ad2)  $M=R$ , Množina  $M=\{x: f(x, \Theta) > 0\}$  není funkcí  $\Theta$

$$\text{ad3) } \forall x \in R : f'(x, \Theta) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{(x-\Theta)^2}{2}} \cdot (x - \Theta) \quad \text{pro } \Theta \in R$$

$$\text{ad4) Pro každé } \Theta \in \Theta, Z(X, \Theta) = \frac{\partial \ln f(X, \Theta)}{\partial \Theta} \text{ platí: } EZ = 0$$

$$\begin{aligned}
\int_{-\infty}^{\infty} f'(x, \Theta) dx &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{(x-\Theta)^2}{2}} \cdot (x-\Theta) dx = \left| \begin{array}{l} t = x - \Theta \\ dt = dx \end{array} \right| = \frac{1}{\sqrt{2\pi}} \cdot \int_{-\infty}^{\infty} e^{-\frac{t^2}{2}} \cdot t dt = \\
&= \frac{1}{\sqrt{2\pi}} \cdot \left( \int_{-\infty}^0 e^{-\frac{t^2}{2}} \cdot t dt + \int_0^{\infty} e^{-\frac{t^2}{2}} \cdot t dt \right) = \frac{1}{\sqrt{2\pi}} \cdot (I_1 + I_2) = \frac{1}{\sqrt{2\pi}} \cdot (-1 + 1) \\
&= 0
\end{aligned}$$

kde:

$$I_1 = \int_{-\infty}^0 e^{-\frac{t^2}{2}} \cdot t dt = \left| \begin{array}{l} u = -\frac{t^2}{2} \\ du = -t dt \end{array} \right| = - \int_{-\infty}^0 e^u du = - \lim_{v \rightarrow (-\infty)} [e^u]_v^0 = -(1 - 0) = -1$$

$$I_2 = \int_0^{\infty} e^{-\frac{t^2}{2}} \cdot t dt = \left| \begin{array}{l} u = \frac{t^2}{2} \\ du = t dt \end{array} \right| = \int_0^{\infty} e^{-u} du = - \lim_{v \rightarrow (\infty)} [e^{-u}]_0^v = -(0 - 1) = 1$$

ad5) Pro každé  $\Theta \in \Theta$ ,  $Z(X, \Theta) = \frac{\partial \ln f(X, \Theta)}{\partial \Theta}$  platí:  $(0 < DZ < \infty)$

$$\begin{aligned} DZ = I(\Theta) &= \int_M \left( \frac{f'(x, \Theta)}{f(x, \Theta)} \right)^2 f(x, \Theta) dx = \int_{-\infty}^{\infty} (x - \Theta)^2 \cdot f(x, \Theta) dx = \\ &= \int_{-\infty}^{\infty} (x - EX)^2 \cdot f(x, \Theta) dx = DX = 1 \end{aligned}$$

*Hustota normálního rozdělení  $N(\Theta, 1)$  je tedy regulární.*

**Definice:**

Nechť náhodná veličina  $X$  má regulární rozdělení  $f(x, \Theta)$ . Integrál  $I(\Theta)$  definovaný v podmínce 5 v definici regulárního systému hustot nazýváme **Fisherovou mírou informace**:

$$I(\Theta) = \int_M \left( \frac{\partial \ln f(x, \Theta)}{\partial \Theta} \right)^2 f(x, \Theta) dx = \int_M \left( \frac{f'(x, \Theta)}{f(x, \Theta)} \right)^2 f(x, \Theta) dx$$

Fischerova míra informace je tedy střední hodnota náhodné veličiny definované jako:

$$\left( \frac{f'(X, \Theta)}{f(X, \Theta)} \right)^2$$

Můžeme ji tedy zapisovat také jako:

$$I(\Theta) = E \left\{ \left( \frac{f'(X, \Theta)}{f(X, \Theta)} \right)^2 \right\} = E \left\{ \left( \frac{\partial \ln f(X, \Theta)}{\partial \Theta} \right)^2 \right\}$$

Následující vlastnost Fisherovy míry informace je využitelná především při výpočtu informace v praktických příkladech.

**Věta:**

Nechť  $f(x, \Theta)$  je regulární hustota. Nechť pro všechna  $x$  a pro všechna  $\Theta$  existuje druhá derivace  $f(x, \Theta)$ :

$$f''(x, \Theta) = \frac{\partial^2 f(x, \Theta)}{\partial \Theta^2}$$

Nechť pro každé  $\Theta \in \Theta$  platí:

$$\int_M f''(x, \Theta) dx = 0$$

Potom:

$$I(\Theta) = - \int_M \frac{\partial^2 \ln f(x, \Theta)}{\partial \Theta^2} f(x, \Theta) dx$$

**Dk:**

$$\begin{aligned} \frac{\partial \ln f(x, \Theta)}{\partial \Theta} &= \frac{f'(x, \Theta)}{f(x, \Theta)} & \frac{\partial^2 \ln f(x, \Theta)}{\partial \Theta^2} &= \frac{f''(x, \Theta)f(x, \Theta) - f'(x, \Theta) \cdot f'(x, \Theta)}{f^2(x, \Theta)} = \\ & & &= \frac{f''(x, \Theta)}{f(x, \Theta)} - \left( \frac{f'(x, \Theta)}{f(x, \Theta)} \right)^2 \\ \left( \frac{f'(x, \Theta)}{f(x, \Theta)} \right)^2 &= \frac{f''(x, \Theta)}{f(x, \Theta)} - \frac{\partial^2 \ln f(x, \Theta)}{\partial \Theta^2} \end{aligned}$$

## Řešený příklad

Nechť náhodná veličina  $X$  má normální rozdělení  $N(\mu, \sigma^2)$ , kde  $\sigma^2$  známe. Určete míru informace o parametru  $\mu$ .

$$f(x, \mu) = \frac{1}{\sqrt{2\pi} \cdot \sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad \text{pro } x \in R$$

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

$$\frac{\partial(\ln f(x, \mu))}{\partial \mu} = \frac{(x-\mu)}{\sigma^2}$$

$$\begin{aligned} \underline{\underline{I(\mu)}} &= E \left\{ \left( \frac{\partial \ln f(x, \mu)}{\partial \mu} \right)^2 \right\} = E \left\{ \frac{(x-\mu)^2}{\sigma^4} \right\} = \frac{1}{\sigma^4} \cdot E \{ (x-\mu)^2 \} = \frac{1}{\sigma^4} \cdot DX = \frac{1}{\sigma^4} \cdot \sigma^2 = \\ &= \underline{\underline{\frac{1}{\sigma^2}}} \end{aligned}$$



## Řešený příklad

Nechť náhodná veličina  $X$  má Poissonovo rozdělení  $Po(\lambda)$ . Určete míru informace o parametru  $\lambda$ .

$$f(k, \lambda) = \frac{\lambda^k}{k!} \cdot e^{-\lambda} \quad k = 0, 1, \dots, \quad \lambda > 0$$

$$EX = DX = \lambda$$

Je zřejmé, že  $f(k, \lambda)$  je regulární hustota.

$$\ln f(k, \lambda) = \ln(\lambda)^k - \ln k! + \ln e^{-\lambda} = k \cdot \ln(\lambda) - \ln k! - \lambda$$

$$\frac{\partial(\ln f(k, \lambda))}{\partial \lambda} = \frac{k}{\lambda} - 1 = \frac{k - \lambda}{\lambda}$$

$$\underline{\underline{I(\lambda)}} = E \left\{ \left( \frac{\partial \ln f(k, \lambda)}{\partial \lambda} \right)^2 \right\} = E \left\{ \frac{(k - \lambda)^2}{\lambda^2} \right\} = \frac{1}{\lambda^2} \cdot E \{ (k - \lambda)^2 \} = \frac{1}{\lambda^2} \cdot DX = \frac{1}{\lambda^2} \cdot \lambda = \underline{\underline{\frac{1}{\lambda}}}$$

---

## Rao – Cramerova nerovnost

Popisuje vztah mezi Fisherovou mírou informace a dolní mezí rozptylu  $C(\Theta)$  nestranných odhadů dané parametrické funkce.

### Definice:

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodným výběrem, který má regulární rozdělení  $f(\underline{x}, \Theta)$ , jenž je funkcí jednoho reálného parametru. Necht'  $\tau(\Theta)$  je daná parametrická funkce taková, že její

$$\tau'(\Theta) = \frac{\partial \tau(\Theta)}{\partial \Theta}$$

existuje pro každé  $\Theta \in \Theta$ . **Nestranný odhad**  $T(\underline{X})$  ( $E(T) = \tau(\Theta)$ ) parametrické funkce  $\tau(\Theta)$  nazveme **regulárním** právě když pro každé  $\Theta \in \Theta$  platí:

$$\int_M T(\underline{x}) \cdot f'(\underline{x}, \Theta) d\underline{x} = \frac{\partial}{\partial \Theta} \int_M T(\underline{x}) \cdot f(\underline{x}, \Theta) d\underline{x} = \frac{\partial}{\partial \Theta} E(T(\underline{X})) = \frac{\partial \tau(\Theta)}{\partial \Theta} = \tau'(\Theta),$$

tzn. když jeho střední hodnotu  $\left( E(T(\underline{X})) = \int_M T(\underline{x}) \cdot f(\underline{x}, \Theta) d\underline{x} \right)$  můžeme derivovat podle  $\Theta$ .

$$\int_M T(\underline{x}) \cdot f'(\underline{x}, \Theta) dx = \int_M T(\underline{x}) \cdot \frac{f'(\underline{x}, \Theta)}{f(\underline{x}, \Theta)} \cdot f(\underline{x}, \Theta) d\underline{x} =$$

$$\int_M T(\underline{x}) \cdot \frac{\partial \ln f(\underline{x}, \Theta)}{\partial \Theta} f(\underline{x}, \Theta) d\underline{x} = \tau'(\Theta)$$

Následující věta pak udává dolní mez rozptylu nestranného odhadu dané parametrické funkce  $\tau(\Theta)$ .

### Rao – Cramerova věta

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodným výběrem, který má regulární rozdělení  $f(\underline{x}, \Theta)$ . Necht'  $\tau(\Theta)$  je daná parametrická funkce. Potom pro každý regulární nestranný odhad  $T(\underline{X})$  funkce  $\tau(\Theta)$  platí:

$$D(T(\underline{X})) \geq \frac{\{\tau'(\Theta)\}^2}{n \cdot I(\Theta)} = C(\Theta)$$

Odhad  $T(\underline{X})$ , jehož rozptyl je roven Rao – Cramerově dolní mezi rozptylu  $C(\Theta)$ , je efektivním odhadem.

Schwarzova nerovnost (Roz 79)

$f, g$  - reálne, def na množine  $M$ , integrovateľné

$$\Rightarrow \left( \int_M f \cdot g \, dx \right)^2 \leq \int_M f^2 \, dx \cdot \int_M g^2 \, dx$$

---

důsledek:  $[\text{cov}(X, Y)]^2 \leq D(X) \cdot D(Y)$

My:

$$\left[ \text{cov} \left( T(X), \frac{\partial \ln f(X, \theta)}{\partial \theta} \right) \right]^2 \leq D[T(X)] \cdot D \left\{ \frac{\partial \ln f(X, \theta)}{\partial \theta} \right\}$$

$$\text{ale } \text{cov} \left\{ T(X), \frac{\partial \ln f(X, \theta)}{\partial \theta} \right\} = E \left\{ [T(X) - \tau(\theta)] \cdot \left[ \frac{\partial \ln f(X, \theta)}{\partial \theta} - 0 \right] \right\}$$

$$= \int_M T(x) \cdot \frac{\partial \ln f(x, \theta)}{\partial \theta} \cdot f(x, \theta) \, dx - \tau(\theta) \cdot \int_M \frac{\partial \ln f(x, \theta)}{\partial \theta} \cdot f(x, \theta) \, dx$$

$$= \tau'(\theta)$$

regularit  
odborné

$$\text{cov}(X, Y) = E[(X - E(X))(Y - E(Y))]$$

↓ Schwarzova nerovnosť (Roz 7.9)

$f, g$  - reálne, def na množine  $M$ , integrovateľné

$$\Rightarrow \left( \int_M f \cdot g \, dx \right)^2 \leq \int_M f^2 \, dx \cdot \int_M g^2 \, dx$$

---

analogicky:  $[\text{cov}(X, Y)]^2 \leq D(X) \cdot D(Y)$

My:

$$\left[ \text{cov} \left( T(X), \frac{\partial \ln f(X, \theta)}{\partial \theta} \right) \right]^2 \leq D[T(X)] \cdot D \left\{ \frac{\partial \ln f(X, \theta)}{\partial \theta} \right\}$$

$$\text{ale } \text{cov} \left( T(X), \frac{\partial \ln f(X, \theta)}{\partial \theta} \right) = E \left\{ [T(X) - \tau(\theta)] \cdot \left[ \frac{\partial}{\partial \theta} \ln f(X, \theta) - 0 \right] \right\}$$

$$= \int_M T(x) \cdot \frac{\partial}{\partial \theta} \ln f(x, \theta) \cdot f(x, \theta) \, dx \stackrel{?}{=}$$

$$= \tau'(\theta)$$

regularit'  
odborne

$$\text{cov}(X, Y) = E[(X - EX)(Y - EY)]$$

### Řešený příklad

Necht'  $\underline{X} = (X_1, \dots, X_n)$  je náhodným výběrem z Poissonova rozdělení  $Po(\lambda)$ . Určete podle Rao – Cramerovy nerovnosti dolní mez rozptylu odhadu parametru  $\lambda$ .

Z předcházejícího řešeného příkladu víme, že Fisherova míra informace parametru  $\lambda$  je:

$$I(\lambda) = \frac{1}{\lambda}$$

Podle Rao – Cramerovy věty má každý regulární nestranný odhad parametru  $\lambda$  ( $\tau(\lambda) = \lambda$ ) dolní mez rozptylu

$$C(\lambda) = \frac{\{\tau'(\lambda)\}^2}{n \cdot I(\lambda)} = \frac{1}{n \cdot \frac{1}{\lambda}} = \frac{\lambda}{n}$$

Rozptyl nestranného odhadu  $T(\underline{X}) = \bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$  je  $D(T(\underline{X})) = D(\bar{X}) = \frac{\lambda}{n}$

Pro parametr  $\lambda$  tedy existuje nestranný odhad s rozptylem rovnajícím se Rao – Cramerově dolní mezí.

## Řešený příklad

Nechť  $\underline{X} = (X_1, \dots, X_n)$  je náhodným výběrem z normálního rozdělení  $N(\mu, \sigma^2)$ , kde  $\sigma^2$  známe. Určete pomocí Rao – Cramerovy nerovnosti dolní mez rozptylu odhadu parametru  $\mu$ .

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

Chceme najít Rao-Cramerovu dolní mez rozptylu:

$$C(\mu) = \frac{\{\tau'(\mu)\}^2}{n \cdot I(\mu)}$$

Z předcházejících řešených příkladů víme, že Fisherova míra informace pro parametr  $\mu$  je:

$$I(\mu) = \frac{1}{\sigma^2}$$

a příslušná parametrická funkce je:  $\tau(\mu) = \mu$

Proto:

$$C(\mu) = \frac{\{\tau'(\mu)\}^2}{n \cdot I(\mu)} = \frac{1}{n \cdot \frac{1}{\sigma^2}} = \frac{\sigma^2}{n}$$

Víme, že nejlepším nestranným (efektivním) odhadem střední hodnoty  $\mu$  je průměr ( $T(\underline{X}) = \bar{X}$ ). Měl by tedy mít rozptyl roven Rao – Cramerově dolní mezi rozptylu.

Podle centrální limitní věty můžeme průměr aproximovat normálním rozdělením  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , z čehož je zřejmé, že  $D(T(\underline{X})) = \frac{\sigma^2}{n} = C(\mu)$ . Čímž jsme dokázali, že průměr je efektivním odhadem střední hodnoty normálního rozdělení.



## Rayleighovo rozdělení – parametr $\Theta^2$

Rayleighovo rozdělení

$$F(x) = 1 - e^{-\frac{1}{2} \frac{x^2}{\Theta^2}} \quad f(x) = \frac{x}{\Theta^2} e^{-\frac{1}{2} \frac{x^2}{\Theta^2}} \quad x > 0$$

$n$ . výběr:  $(X) = (X_1, \dots, X_n)$

simult. hustota:  $f(x) = \Theta^{-2n} \prod_{i=1}^n x_i \cdot e^{-\frac{1}{2} \frac{x_i^2}{\Theta^2}}$

$$\ln f(x) = -n \ln \Theta^2 + \sum_{i=1}^n \ln x_i - \frac{1}{2} \sum_{i=1}^n \frac{x_i^2}{\Theta^2}$$

$$f(x) = e^{\ln f(x)} = e^{-n \ln \Theta^2 + \sum_{i=1}^n \ln x_i - \frac{1}{2\Theta^2} \sum_{i=1}^n x_i^2}$$

$$= e^{-n \ln \Theta^2 - \frac{1}{2\Theta^2} \sum_{i=1}^n x_i^2 + \sum_{i=1}^n \ln x_i}$$

$$= g\left(\sum_{i=1}^n x_i^2, \Theta^2\right) \cdot h(x)$$

$$\Rightarrow T(X) = \sum_{i=1}^n x_i^2 \text{ je postačující st. pro } \Theta^2$$

$$\text{MLE: } \frac{\partial \ln f(x)}{\partial \theta^2} = -n \cdot \frac{1}{\theta^2} + \frac{1}{2} \frac{1}{\theta^4} \sum_{i=1}^n x_i^2 = 0$$

$$\Rightarrow \hat{\theta}^2 = \frac{1}{2n} \sum_{i=1}^n x_i^2$$

Pokud  $E \hat{\theta}^2 = \theta^2 \Rightarrow$  maximally effective estimator  $\hat{\theta}^2$

$$\text{DK: } E \hat{\theta}^2 = \frac{1}{2n} E \left( \sum_{i=1}^n x_i^2 \right) = \frac{1}{2n} \sum_{i=1}^n E x_i^2 = \frac{1}{2n} \cdot n \cdot 2\theta^2 = \theta^2$$

$$E x^2 = \int_0^{\infty} \frac{x^3}{\theta^2} e^{-\frac{1}{2} \frac{x^2}{\theta^2}} dx = 2\theta^2$$

$$\text{subst. } \boxed{\begin{matrix} t = x^2 \\ \theta^2 \end{matrix}}$$

$$f(x|\theta) = \frac{1}{\theta} \cdot e^{-\frac{x}{\theta}}$$

Exp. rozd.

Seznamte  $J(\theta)$

$$J(\theta) = \int_0^{\infty} \left( \frac{f'}{f} \right)^2 \cdot f(x) dx = \int_0^{\infty} \frac{(f')^2}{f} dx =$$

$$= \frac{1}{\theta^4} \int_0^{\infty} (x-\theta)^2 \frac{1}{\theta} e^{-\frac{x}{\theta}} dx = \frac{1}{\theta^4} DX = \frac{\theta^2}{\theta^4} = \frac{1}{\theta^2}$$

$$f'(x) = e^{-\frac{x}{\theta}} \frac{x-\theta}{\theta^2}$$

Metoda MLE:  $\hat{\theta} = \frac{\sum_{i=1}^n x_i}{n} = \bar{X} = T(X)$

$$E\hat{\theta} = \theta \quad \wedge \quad \sum_{i=1}^n x_i \text{ je protocijiva}$$

$\Rightarrow$  efektivni  $\nabla$

Srinivas Rao-Cramer:

$$D T(X) \geq \frac{1}{n \cdot J(\theta)} = \frac{1}{n \cdot \frac{1}{\theta^2}} = \frac{\theta^2}{n}$$

$$\text{Jelikož } D(T(X)) = D \left( \frac{\sum_{i=1}^n x_i}{n} \right) = \frac{n \cdot \theta^2}{n^2} = \frac{\theta^2}{n}$$

**6.1. Exponenciální třída rozdělení pravděpodobnosti.** Nejlepší nestranné odhady – pokud vůbec pro danou parametrickou funkci nějaký nestranný odhad existuje – lze nejlépe konstruovat, když pozorovaná veličina  $X$  má rozdělení patřící do určité speciální třídy, totiž do tzv. exponenciální třídy rozdělení.

Říkáme, že veličina  $X$  má *rozdělení z exponenciální třídy* (nebo *rozdělení exponenciálního typu*), jestliže její hustota pravděpodobnosti  $f(x)$  [případně pravděpodobnostní funkce  $p(x) = P(X = x)$ , jde-li o rozdělení diskrétního typu] má tvar

$$(6.1.1) \quad f(x; \theta) = \exp \left[ \sum_{j=1}^k Q_j(\theta) U_j(x) + R(\theta) + V(x) \right]$$

a splňuje podmínky

$$(6.1.2) \quad \{x \mid f(x; \theta) > 0\} \text{ nezávisí na } \theta ;$$

$$(6.1.3) \quad \text{parametrický prostor } \Omega \text{ obsahuje } k\text{-rozměrný interval,}$$

**Většina rozdělení užitečných pro aplikace patří do exponenciální třídy!**

## Jednorozměrná hustota z exponenciální třídy:

$$f(x; \theta) = \exp \left[ \sum_{j=1}^k Q_j(\theta) U_j(x) + R(\theta) + V(x) \right]$$

## Sdružená (simultánní) hustota z exponenciální třídy:

$\underline{X} = (X_1, \dots, X_n)$  je náhodný výběr

Sdružená hustota pro  $n$  výběr z exp. třídy

$$f(\underline{x}, \Theta) = \exp \left[ \sum_{j=1}^k Q_j(\Theta) S_j(\underline{x}) + n R(\Theta) + V(\underline{x}) \right]$$

$$S_j = \sum_{i=1}^n U_j(x_i) \quad V(\underline{x}) = \sum_{i=1}^n V(x_i)$$

min. početný počet. ( $\rightarrow$  viz věta o faktorizaci)

$$f(\underline{x}, \Theta) = g\{T(\underline{x}), \Theta\} \cdot h(\underline{x})$$

## 6.2. Příklady

**6.2.1.** Poissonovo rozdělení patří do exponenciální třídy, neboť jeho pravděpodobnostní funkci (zde místo  $\theta$  označíme parametr rozdělení symbolem  $\lambda$ , jak jsme to činili v [24])

$$p(x; \lambda) = P(X = x) = \frac{\lambda^x}{x!} \exp(-\lambda), \quad x = 0, 1, \dots,$$

lze zapsat ve tvaru

$$p(x; \lambda) = \exp(x \ln \lambda - \lambda - \ln x!),$$

tj. ve tvaru (6.1.1), kde  $k = 1$ ,  $Q_1(\lambda) = \lambda$ ,  $U_1(x) = x$ ;  $\{x \mid p(x; \lambda) > 0\} = \{0, 1, \dots\}$ , tedy nezávisí na  $\lambda$ , a  $\Omega = (0, \infty)$ , tedy  $\Omega$  obsahuje jednorozměrný interval.

$$f(x; \theta) = \exp \left[ \sum_{j=1}^k Q_j(\theta) U_j(x) + R(\theta) + V(x) \right]$$

**6.2.2.** Logaritmicko-normální rozdělení patří do exponenciální třídy, neboť jeho hustotu

$$f(x; \mu, \sigma^2) = \frac{1}{\sigma x \sqrt{(2\pi)}} \exp \left[ -\frac{1}{2\sigma^2} (\ln x - \mu)^2 \right], \quad x > 0,$$

lze zapsat ve tvaru

$$f(x; \mu, \sigma^2) = \exp \left[ -\frac{1}{2\sigma^2} (\ln x)^2 + \frac{\mu}{\sigma^2} \ln x - \frac{\mu^2}{2\sigma^2} - \frac{1}{2} \ln \sigma^2 - \ln x - \ln \sqrt{(2\pi)} \right],$$

$$x > 0,$$

tj. ve tvaru (6.1.1) s

$$k = 2, \theta = (\mu, \sigma^2), Q_1(\theta) = -\frac{1}{2\sigma^2}, Q_2(\theta) = \frac{\mu}{\sigma^2}, U_1 = (\ln x)^2, U_2 = \ln x,$$

$$R(\theta) = -\frac{1}{2} \left( \frac{\mu^2}{\sigma^2} + \ln \sigma^2 \right) - \ln \sqrt{(2\pi)}, V(x) = -\ln x.$$

Parametrický prostor  $\Omega = \{(\mu, \sigma^2) \mid -\infty < \mu < \infty, \sigma^2 > 0\}$  je polorovina, množina  $\{x \mid f(x; \mu, \sigma^2) > 0\} = (0, \infty)$ , tedy nezávisí na  $(\mu, \sigma^2)$ .

$$f(x; \theta) = \exp \left[ \sum_{j=1}^k Q_j(\theta) U_j(x) + R(\theta) + V(x) \right]$$

**6.2.3.** Rovnoměrné rozdělení na intervalu  $(0, \theta)$  nepatří do exponenciální třídy; jeho hustota totiž je

$$f(x; \theta) = \frac{1}{\theta}, \quad 0 < x < \theta,$$

takže množina  $\{x \mid f(x; \theta) > 0\}$  závisí na  $\theta$ , a nesplňuje tedy podmínku (6.1.2).

**6.2.4.** Cauchyovo rozdělení nepatří do exponenciální třídy, neboť jeho hustota

$$f(x; \theta) = \frac{1}{\pi} [1 + (x - \theta)^2]^{-1} = \exp \{ -\ln \pi - \ln [1 + (x - \theta)^2] \}$$

**Nemá tvar níže**

$$f(x; \theta) = \exp \left[ \sum_{j=1}^k Q_j(\theta) U_j(x) + R(\theta) + V(x) \right]$$



## Vlastnosti ML odhadů (2 vlastnosti)

**6.11. Vlastnosti maximálně věrohodných odhadů.** Maximálně věrohodné odhady mají dvě důležité vlastnosti, pro které se jich používá tak často, přestože jejich výpočet je numericky náročný. První z těchto vlastností se týká výběrů jakéhokoliv rozsahu  $n$  a zní:

**6.11.1. Věta.** Jestliže rozdělení pozorované veličiny  $X$  patří do exponenciální třídy (6.1.1), pak maximálně věrohodné odhady  $\hat{\theta}_1, \dots, \hat{\theta}_k$  parametrů  $\theta_1, \dots, \theta_k$  jsou funkcemi minimálních postačujících statistik (6.3.2).

Důkaz. Má-li  $X$  hustotu (pravděpodobnostní funkci) tvaru (6.1.1), pak sdružená hustota náhodného výběru  $\mathbf{X} = (X_1, \dots, X_n)'$  je typu (6.3.1), logaritmus funkce věrohodnosti má pak tvar

$$(6.11.1) \quad \ln L(\theta) = \sum_{l=1}^k Q_l(\theta) S_l(\mathbf{x}) + n R(\theta) + V(\mathbf{x}),$$

věrohodnostní rovnice jsou

(6.11.2)

$$\sum_{l=1}^k S_l(\mathbf{x}) \frac{\partial Q_l(\theta)}{\partial \theta_j} \Big|_{\theta=\hat{\theta}} + n \frac{\partial R(\theta)}{\partial \theta_j} \Big|_{\theta=\hat{\theta}} = 0, \quad j = 1, \dots, k,$$

a jejich řešení závisí na  $\mathbf{x}$  jen prostřednictvím hodnot  $S_1(\mathbf{x}), \dots, S_k(\mathbf{x})$  minimálních postačujících statistik.

Z věty odst. 6.4 a věty odst. 6.10.1 pak přímo plyne důležitý důsledek.

↳ Rao-Blackwell

## Důsledek 1. vlastnosti

**6.11.2.** Jestliže pozorovaná náhodná veličina  $X$  má rozdělení z exponenciální třídy (6.1.1) a jestliže pro nějakou funkci  $T(\hat{\theta}_1, \dots, \hat{\theta}_k)$  maximálně věrohodných odhadů parametrů  $\theta_1, \dots, \theta_k$  platí

$$(6.11.3) \quad E[T(\hat{\theta}_1, \dots, \hat{\theta}_k)] = \tau(\theta) \quad \text{pro všechna } \theta \in \Omega,$$

pak  $T(\hat{\theta}_1, \dots, \hat{\theta}_k)$  je nejlepším nestranným odhadem funkce  $\tau(\theta)$  vektoru parametrů  $\theta$ .

**Druhá vlastnost následuje:**

*meg* **6.11.5. Věta.** Necht'  $\mathbf{X} = (X_1, \dots, X_n)'$  je náhodný výběr z rozdělení s hustotou (pravděpodobnostní funkcí)  $f(x; \theta)$  závislou na parametru  $\theta \in \Omega \subset \mathbf{E}^1$  splňující podmínky odst. 6.11.3. Necht' skutečná hodnota  $\theta_0$  parametru  $\theta$  je vnitřním bodem  $\Omega$  a necht' v okolí bodu  $\theta_0$  platí

$$(6.11.10) \quad - \int_M \frac{\partial^2 \ln f(x, \theta)}{\partial \theta^2} f(x, \theta) dx = \int_M \left[ \frac{\partial \ln f(x, \theta)}{\partial \theta} \right]^2 f(x, \theta) dx = J(\theta),$$

resp.

$$- \sum_M \frac{\partial^2 \ln f(x, \theta)}{\partial \theta^2} f(x, \theta) = \sum_M \left[ \frac{\partial \ln f(x, \theta)}{\partial \theta} \right]^2 f(x, \theta) = J(\theta).$$

*Pak náhodná veličina*

$$(6.11.11) \quad n^{1/2}(\hat{\theta} - \theta_0),$$

kde  $\hat{\theta}$  je kořen věrohodnostní rovnice, konverguje v distribuci (viz [24], odst. 26.2) k normálnímu rozdělení  $N[0, 1/J(\theta_0)]$ .

*Je-li  $\tau(\theta)$  diferencovatelná funkce na  $\Omega$ , pak náhodná veličina*

$$(6.11.12) \quad n^{1/2}[\tau(\hat{\theta}) - \tau(\theta_0)]$$

*konverguje v distribuci k normálnímu rozdělení  $N\{0, [\tau'(\theta_0)]^2/J(\theta_0)\}$ .*

## Důsledek druhé vlastnosti

Prakticky to znamená, že při velkých hodnotách  $n$  lze aproximovat rozdělení odhadu  $\hat{\theta}$  parametru  $\theta$  rozdělením  $N\{\theta, 1/[n J(\theta)]\}$  a rozdělení odhadu  $\tau(\hat{\theta})$  pro funkci  $\tau(\theta)$  parametru  $\theta$  rozdělením  $N\{\tau(\theta), [\tau'(\theta)]^2/[n J(\theta)]\}$ . Stručně říkáme, že maximálně věrohodný odhad  $\hat{\theta}$  je asymptoticky nestranný a jeho asymptotické rozdělení je normální s rozptylem  $1/[n J(\theta)]$ . Protože žádný nestranný odhad parametru  $\theta$  nemůže mít (za podmínek odst. 6.11.3) rozptyl menší než  $1/[n J(\theta)]$  (viz [1, 27]), říká se, že maximálně věrohodný odhad je asymptoticky eficientní.

# Aplikace 1

$$f(x, \theta) = \frac{1}{\theta} \cdot e^{-\frac{x}{\theta}}$$

Exp. rozd.

Sestavte  $I(\theta)$

$$\begin{aligned} I(\theta) &= \int_0^{\infty} \left( \frac{f'}{f} \right)^2 \cdot f(x) dx = \int_0^{\infty} \frac{(f')^2}{f} dx = \\ &= \frac{1}{\theta^4} \int_0^{\infty} (x-\theta)^2 \frac{1}{\theta} e^{-\frac{x}{\theta}} dx = \frac{1}{\theta^4} DX = \frac{\theta^2}{\theta^4} = \underline{\underline{\frac{1}{\theta^2}}} \end{aligned}$$
$$f'(x) = e^{-\frac{x}{\theta}} \frac{x-\theta}{\theta^2}$$

Metodou MLE:  $\hat{\theta} = \frac{\sum_{i=1}^n x_i}{n} = \bar{X} = T(X)$

$$E\hat{\theta} = \theta \quad \wedge \quad \sum_{i=1}^n x_i \text{ je充分统计量}$$

→ tedy je efektivní

**Tedy aplikace druhé vlastnosti:**

$$\sqrt{n} \cdot (\hat{\Theta} - \Theta) \approx N\left(0, \frac{1}{J(\Theta)}\right) \quad \text{kde} \quad \hat{\Theta} = \sum_{i=1}^n \frac{X_i}{n}$$

**a tudíž**

$$\hat{\Theta} \approx N\left(\Theta, \frac{1}{n \cdot J(\Theta)}\right) = N\left(\Theta, \frac{\Theta^2}{n}\right)$$

Tj. známe rozdělení odhadu, můžeme počítat intervalové odhady a další nejistoty okolo parametru  $\Theta$ !!

## Aplikace 2 - Rayleighovo rozdělení – parametr $\Theta^2$ (námět na projekt?)

Rayleighovo rozdělení

$$F(x) = 1 - e^{-\frac{1}{2} \frac{x^2}{\Theta^2}} \quad f(x) = \frac{x}{\Theta^2} e^{-\frac{1}{2} \frac{x^2}{\Theta^2}} \quad x > 0$$

MLE: 
$$\frac{\partial \ln f(x)}{\partial \Theta^2} = -n \cdot \frac{1}{\Theta^2} + \frac{1}{2} \frac{1}{\Theta^4} \sum_{i=1}^n x_i^2 = 0$$

$$\Rightarrow \hat{\Theta}^2 = \frac{1}{2n} \sum_{i=1}^n x_i^2$$

Pokud  $E \hat{\Theta}^2 = \Theta^2 \Rightarrow$  maximálně efektivní odhad  $\Theta^2$

**Tedy:** 
$$\sqrt{n} \cdot (\hat{\Theta}^2 - \Theta^2) \approx N\left(0, \frac{1}{J(\Theta^2)}\right) \quad \text{kde} \quad \hat{\Theta}^2 = \sum_{i=1}^n \frac{X_i^2}{2n}$$

**a tudíž** 
$$\hat{\Theta}^2 \approx N\left(\Theta^2, \frac{1}{n \cdot J(\Theta^2)}\right) \quad \text{tj. zase můžeme počítat nejistoty!!}$$



### Příklad 3

6.2.4. Cauchyovo rozdělení nepatří do exponenciální třídy, neboť jeho hustota

$$f(x; \theta) = \frac{1}{\pi} [1 + (x - \theta)^2]^{-1} = \exp \{ -\ln \pi - \ln [1 + (x - \theta)^2] \}$$

**Ale je regulární !**

Spočtěte  $J(\Theta)$

$$\underline{\underline{J(\Theta)}} = E \left\{ \left( \frac{\partial \ln f(x, \Theta)}{\partial \Theta} \right)^2 \right\} = \int_{-\infty}^{+\infty} \frac{4 \cdot (x - \Theta)^2}{[1 + (x - \Theta)^2]^2} \cdot f(x, \Theta) dx = \frac{4}{\pi} \int_{-\infty}^{+\infty} \frac{x^2}{[1 + x^2]^3} dx = \dots = \underline{\underline{\frac{1}{2}}}$$

$$Z = \frac{\partial \ln f(x, \Theta)}{\partial \Theta} = \frac{2 \cdot (x - \Theta)}{1 + (x - \Theta)^2}$$

Je-li  $\Theta^*$  MLE odhad  $\rightarrow$  potom  $\sqrt{n} \cdot (\Theta^* - \Theta) \approx N(0, 2)$

neboli  $\Theta^* \approx N\left(\Theta, \frac{2}{n}\right)$  a zase můžeme počítat intervalové odhady!!

# ZÁKLADY BAYESOVY INDUKCE

## Cíl:

- Metodu maximální věrohodnosti – opakování
- Základy Bayesovy indukce
- Apriorní a aposteriorní rozdělení
- Bayesův bodový a intervalový odhad

## Metoda maximální věrohodnosti - opakování

Nechť  $X_1, X_2, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x; \Theta)$ , kde tvar distribuční funkce je znám a  $\Theta$  je neznámý parametr. Obecně může distribuční funkce obsahovat více neznámých parametrů, které můžeme označit vektorově jako  $\underline{\Theta}$ . Problém bodového odhadu nyní spočívá v nalezení statistiky  $\hat{\Theta}(x)$ , jakožto funkce  $X_1, X_2, \dots, X_n$ , která by mohla být použita jako odhad  $\underline{\Theta}$ . Tato statistika bývá často označována jako **estimátor** a její realizace, řekněme  $\hat{\Theta}(x)$ , jako odhad. Necht'  $f(x; \underline{\Theta})$  je hustota pravděpodobnosti nebo pravděpodobnostní funkce náhodného výběru  $\underline{X}$  ( $X_1, X_2, \dots, X_n$ ).

### Definice:

Pokud je hustota pravděpodobnosti nebo pravděpodobnostní funkce  $f(x; \underline{\Theta})$  vyšetřovaná jako funkce  $\underline{\Theta}$ , nazveme ji **věrohodnostní funkcí** založenou na  $\underline{x} = (x_1, \dots, x_n)$  a označíme ji jako  $L(\underline{\Theta}; \underline{x})$ .

Jestliže  $X_1, X_2, \dots, X_n$  je množina nezávislých náhodných pozorování z rozdělení s hustotami  $f_i(x_i; \underline{\Theta})$ ,  $i = 1, \dots, n$ , pak věrohodnostní funkce může být získána jako:

$$L(\underline{\Theta}; x_1, \dots, x_n) = f_1(x_1; \underline{\Theta}) \cdot \dots \cdot f_n(x_n; \underline{\Theta})$$

## Definice:

Nechť  $L(\underline{\Theta}; \underline{X})$  je věrohodnostní funkce založena na náhodném výběru  $\underline{X} = (X_1, X_2, \dots, X_n)$  z rozdělení  $F(x; \underline{\Theta})$ , kde  $\underline{\Theta}$  je vektor neznámých parametrů, který nabývá hodnot z nějakého parametrického prostoru  $\Theta$ . Pokud  $\hat{\Theta} = \hat{\Theta}(\underline{X})$  je náhodný vektor, který maximalizuje  $L(\underline{\Theta}; \underline{X})$  vzhledem k  $\hat{\Theta} \in \Theta$ , potom  $\hat{\Theta}(\underline{X})$  budeme nazývat **maximálně věrohodný estimátor**  $\Theta$ .

Pro konkrétní realizaci náhodného výběru  $\underline{x} = (x_1, \dots, x_n)$  budeme  $\hat{\Theta}(\underline{x})$  nazývat jako **maximálně věrohodný odhad**  $\Theta$ . Pro tento odhad budeme používat zkratku MVO.

## Řešený příklad

### MVO pro parametr exponenciálního rozdělení

Nechť  $\underline{X} = (X_1, X_2, \dots, X_n)$  je náhodný výběr z exponenciálního rozdělení pravděpodobnosti.

Víme, že hustota pravděpodobnosti exponenciální náhodné veličiny má tvar:

$$f(x) = \lambda \cdot e^{-\lambda x}, \quad x > 0,$$

kde  $\lambda > 0$  je neznámý parametr.

Věrohodnostní funkce:

$$L(\lambda; \mathbf{x}) = \prod_{i=1}^n f(x_i) = \lambda^n e^{-\lambda \sum_{i=1}^n x_i}$$

Logaritmická věrohodnostní funkce:

$$L^*(\lambda; \mathbf{x}) = \ln \left( \lambda^n e^{-\lambda \sum_{i=1}^n x_i} \right) = \ln(\lambda^n) + \ln \left( e^{-\lambda \sum_{i=1}^n x_i} \right) = n \cdot \ln \lambda - \lambda \sum_{i=1}^n x_i$$

Nalezení maxima  $L^*(\lambda; \mathbf{x})$ :

$$\frac{dL^*(\lambda; \mathbf{x})}{d\lambda} = \frac{n}{\lambda} - \sum_{i=1}^n x_i \quad \frac{n}{\lambda} - \sum_{i=1}^n x_i = 0 \quad \Rightarrow \quad \hat{\lambda} = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}}$$

*MVO očekávané hodnoty exponenciálního rozdělení EX, označený jako  $\mu = \frac{1}{\lambda}$ , může být odvozen pomocí vlastnosti **invariance maximálně věrohodných odhadů**. Tato vlastnost říká [Nguyen H. T., Rogers G. S., 1989], že:*

*Pokud  $\hat{\Theta}$  je MVO parametru  $\Theta$ , pak  $g(\hat{\Theta})$  je MVO funkce parametru  $g(\Theta)$  za předpokladu, že  $g(\cdot)$  je prostá funkce.*



*Nyní je jasné, že MVO očekávané hodnoty exponenciálního rozdělení je  $\hat{\mu} = \bar{x}$ .*

# Úvod do Bayesovy indukce



Reverend Thomas Bayes v roce 1761 jistě netušil, že jeho teorém najde uplatnění v moderní matematice 21. století

## VĚTA BAYESOVA



$$P\{B_k|A\} = \frac{P\{A|B_k\}P\{B_k\}}{\sum_{i=1}^n P\{A|B_i\}P\{B_i\}} \quad P\{B_k|A\} = \frac{P\{B_k \cap A\}}{P\{A\}}$$

**Tedy srovnej:**

$$P\{B_k|A\} = \frac{P\{A|B_k\}P\{B_k\}}{\sum_{i=1}^n P\{A|B_i\}P\{B_i\}} \quad \text{versus} \quad \pi(\Theta|\underline{x}) = \frac{f(\underline{x}|\Theta) \cdot \pi(\Theta)}{\int_{\Theta} f(\underline{x}|\Theta) \cdot \pi(\Theta) d\Theta} \quad \text{pro } \Theta \in \Omega$$

V tomto přístupu se provádí statistická indukce o neznámém parametru podmíněně vzhledem k pozorovaným datům. Aby to bylo možné provést, je nezbytné udělit parametru  $\Theta$  status náhodné veličiny. Klíčová charakteristika v Bayesově přístupu spočívá v tom, že je nezbytné specifikovat pravděpodobnostní rozdělení  $\Theta$  ještě před pozorováním náhodného výběru. Toto rozdělení se nazývá **apriorní rozdělení pravděpodobnosti**.

Tedy parametr  $\Theta$ , který je předmětem našeho zájmu, je v Bayesově přístupu vyšetřován jako náhodná veličina. Jde-li o parametr náhodné veličiny  $X$  s distribuční funkcí  $F(x;\Theta)$ , pak vždy, když pracujeme s touto funkcí, musíme mít na mysli podmíněnou distribuční funkci  $F(x|\Theta)$ .



## Apriorní rozdělení

Uvažujme parametr  $\Theta$  náhodné veličiny  $X$  s distribuční funkcí  $F(x|\Theta)$ . Necht' doposud není k dispozici žádné pozorování této náhodné veličiny. Necht' je k dispozici jakási předběžná zkušenost, či apriorní znalost o této populaci nebo jiná informace, která umožní zkonstruovat subjektivní pravděpodobnostní rozdělení pro parametr  $\Theta$ . Takové rozdělení, které reflektuje nejistotu o hodnotě parametru z hlediska experimentátora ještě před pozorováním aktuálního výběru, se nazývá **apriorní rozdělení** parametru  $\Theta$ . Dále jej budeme označovat  $\pi(\Theta)$ .

Úloha najít apriorní rozdělení pro zkoumaný parametr je všeobecně velmi obtížná. V některých případech bývá dokonce velmi výhodné zvolit jako apriorní hustotu takovou funkci, která nemusí být ani integrovatelná, a přesto po implementaci Bayesových metod dává rozumné výsledky (někdy však také vede k nesmyslným výsledkům). Taková hustota bývá označována jako tzv. **nevlastní apriorní hustota**. Bayesovy metody lze použít i v případě, že není dostupná žádná informace o vyšetřovaném parametru. Taková apriorní rozdělení, označována jako **neurčitá**, byla velmi intenzivně studována [Jeffreys, 1961] a jsou základem Bayesových metod vyvinutých autory [Box and Tiao, 1973].

Neexistuje žádný obecný návod, jak by měla být specifikována neurčitá apriorní hustota. Jelikož jsou pod tíhou různých argumentů použity různé definice neurčitých apriorních rozdělání, setkáme se často s různými nevlastními apriorními rozděláními [Zellner, 1977]. Pro účely nalezení neurčitého apriorního rozdělání použijeme jednu z nejpopulárnějších metod, navrženou v [Jeffreys, 1961].

Nechť  $f(x|\Theta)$  je hustota pravděpodobnosti nebo pravděpodobnostní funkce pozorované náhodné veličiny  $X$ , kde vektor  $\Theta$  je vektor neznámých parametrů. Za neurčité apriorní rozdělání  $\pi(\Theta)$  lze vzít:

$$\pi(\Theta) = [I(\Theta)]^{1/2} = \sqrt{\det I(\Theta)},$$

Kde  $I(\Theta)$  je Fisherova informační matice (regulární rozdělání pro vektorový parametr).

$$I(\Theta) = -E\left(\frac{\partial^2}{\partial\Theta_i\partial\Theta_j} \ln f(X|\Theta)\right) = E\left(\frac{\partial \ln f(X|\Theta)}{\partial\Theta_i} \times \frac{\partial \ln f(X|\Theta)}{\partial\Theta_j}\right) = E(Z_i \times Z_j)$$

## Řešený příklad

Uvažujme exponenciální rozdělení s hustotou  $f(x|\lambda) = \lambda \cdot e^{-\lambda x}$ ,  $x > 0$ , kde  $\lambda > 0$  je parametr, pro který je nutno zkonstruovat apriorní hustotu. Úkolem je nalézt neurčitou apriorní hustotu pro parametr  $\lambda$  a pro jeho převrácenou hodnotu  $\mu$  ( $\mu = \frac{1}{\lambda}$ ).

$$I(\lambda) = -E\left(\frac{\partial^2}{\partial \lambda^2} \ln(\lambda \cdot e^{-\lambda x})\right) = -E\left(\frac{\partial^2}{\partial \lambda^2} [\ln(\lambda) - \lambda x]\right) = -E\left(-\frac{1}{\lambda^2}\right) = \frac{1}{\lambda^2}$$

Odtud vyplývá, že neurčitá (Jeffreysova) apriorní hustota pravděpodobnosti pro  $\lambda$  je nevlastní apriorní hustota, úměrná  $\frac{1}{\lambda}$  ( $= \left(\frac{1}{\lambda^2}\right)^{1/2}$ ):

$$\pi(\lambda) = \frac{1}{\lambda}$$

*Pokud nás bude zajímat apriorní rozdělení pro převrácenou hodnotu  $\lambda$ , tj.  $\mu$ , pak Fischerova matice bude:*

$$\begin{aligned}
 I(\mu) &= -E\left(\frac{\partial^2}{\partial\mu^2} \ln\left(\frac{1}{\mu} \cdot e^{-\frac{1}{\mu}X}\right)\right) = -E\left(\frac{\partial^2}{\partial\mu^2} \left[\ln\left(\frac{1}{\mu}\right) - \frac{1}{\mu}X\right]\right) = \\
 &= -E\left(\frac{\partial}{\partial\mu} \left(-\mu \frac{1}{\mu^2} + \frac{1}{\mu^2}X\right)\right) = -E\left(\frac{\partial}{\partial\mu} \left(-\frac{1}{\mu} + \frac{1}{\mu^2}X\right)\right) = -E\left(\frac{1}{\mu^2} - 2\frac{1}{\mu^3}X\right) = \\
 &= -\frac{1}{\mu^2} + \frac{2}{\mu^3} \cdot EX = -\frac{1}{\mu^2} + \frac{2}{\mu^3} \cdot \mu = \frac{1}{\mu^2}
 \end{aligned}$$

*Tedy neurčitá apriorní hustota pro očekávanou hodnotu exponenciálního rozdělení  $\mu$  je:*

$$\pi(\mu) = \left(\frac{1}{\mu^2}\right)^{1/2} = \frac{1}{\mu}$$


---

## Aposteriorní rozdělení

Nechť  $\underline{X}$  je náhodný vektor se sdruženou hustotou pravděpodobnosti nebo pravděpodobnostní funkcí  $f(\underline{x}|\underline{\Theta})$ . Necht'  $\pi(\underline{\Theta})$  je apriorní rozdělení náhodného vektoru  $\underline{\Theta}$ . Potom sdružené rozdělení  $\underline{X}$  a  $\underline{\Theta}$  může být nalezeno jako:

$$h(\underline{x}, \underline{\Theta}) = f(\underline{x}|\underline{\Theta}) \cdot \pi(\underline{\Theta})$$

Za předpokladu, že  $\underline{\Theta}$  je spojitý náhodný vektor, marginální rozdělení  $\underline{X}$  může být nalezeno jako:

$$g(\underline{x}) = \int_{\underline{\Theta}} h(\underline{x}; \underline{\Theta}) d\underline{\Theta}$$

A konečně podmíněné rozdělení  $\underline{\Theta}$  při realizaci  $\underline{X} = \underline{x}$  je:

$$\pi(\underline{\Theta}|\underline{x}) = \frac{h(\underline{x}; \underline{\Theta})}{g(\underline{x})} \quad \text{pro } \underline{\Theta} \in \Omega$$

Toto pravděpodobnostní rozdělení  $\underline{\Theta}$  se nazývá **aposteriorní rozdělení  $\underline{\Theta}$** . Toto podmíněné rozdělení parametru při daných datech  $\underline{x}$  je takto nazváno zejména proto, že odráží představu experimentátora o zkoumaném parametru poté, co byl pozorován náhodný výběr z příslušné populace. Tedy aposteriorní rozdělení kombinuje předběžnou informaci obsaženou v apriorním rozdělení s informací o  $\underline{\Theta}$  (obsaženou v datech – věrohodnostní funkce). Pokud budeme ignorovat konstantu úměrnosti, pak aposteriorní rozdělení může být zapsáno následovně:

$$\pi(\Theta|x) \propto f(x|\Theta) \cdot \pi(\Theta) \quad \text{pro } \Theta \in \Omega,$$

kde konstanta úměrnosti  $k$  může být nalezena tak, aby byla splněna normovací podmínka aposteriorní hustoty.

**Pozn.:**  $\propto$  označuje přímou úměrnost, tzn.  $\pi(\Theta|x) \propto f(x|\Theta) \cdot \pi(\Theta)$  je zkráceným zápisem rovnice:  $\pi(\Theta|x) = k \cdot f(x|\Theta) \cdot \pi(\Theta)$ ,  $k \in R$

Tedy:

aposteriorní rozdělení  $\propto$  (věrohodnostní funkce  $\times$  apriorní rozdělení)

Pokud aposteriorní rozdělení pravděpodobnosti patří do téže třídy rozdělení jako apriorní rozdělení, potom tuto třídu rozdělení nazýváme **přirozený konjugovaný systém rozdělení** pro rozdělení  $X$ . To znamená, že pokud apriorní rozdělení je konjugované vzhledem k apriornímu rozdělení, pak pro nalezení aposteriorního rozdělení potřebujeme aktualizovat pouze parametry apriorního rozdělení.

### Řešený příklad


Nechť  $X_1, \dots, X_n$  je náhodný výběr z exponenciálního rozdělení s parametrem  $\lambda$ . Úkolem je nalézt aposteriorní rozdělení pro  $\lambda$  za předpokladu, že apriorní rozdělení je:

a)  $\lambda \rightarrow \text{Gamma}(a; b)$ , tj.

$$\pi(\lambda) = \frac{\left(\frac{1}{b}\right)^a}{\Gamma(a)} \cdot \lambda^{a-1} \cdot e^{-\frac{\lambda}{b}}, \quad \text{kde } \Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx, \quad E\lambda = ab \quad \text{b) } \pi(\lambda) = \frac{1}{\lambda}$$

## Poznámka – opakování Gamma rozdělení: $Ga(k, \lambda)$

- Náhodnou veličinu s Gamma rozdělením si můžeme představit jako součet  $k$  nezávislých exponenciálních náhodných veličin ... pomůcka pro výpočet  $E(X)$  a  $D(X)$ .



Distribuční funkce:  $F(t) = P(T_k < t) =$

$$P\left(\sum_{i=1}^k X_i < t\right) = 1 - P(N_t < k) = 1 - \sum_{j=0}^{k-1} e^{-\lambda t} \cdot \frac{(\lambda t)^j}{j!} = 1 - e^{-\lambda t} \left[ \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!} \right]$$

Derivací  $F(t)$  dostaneme funkci hustoty pravděpodobnosti:



$$f(t) = \lambda e^{-\lambda t} \left[ \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!} \right] - e^{-\lambda t} \left[ \sum_{j=1}^{k-1} \frac{\lambda (\lambda t)^{j-1}}{(j-1)!} \right]$$

$$= \lambda^k e^{-\lambda t} \left[ \frac{t^{k-1}}{(k-1)!} \right]; \quad t > 0$$


$$T_k = X_1 + X_2 + X_3 + \dots + X_k$$

$$X_i \rightarrow E(\lambda)$$

$$ET_k = EX_1 + \dots + EX_k = \frac{1}{\lambda} + \dots + \frac{1}{\lambda} = \frac{k}{\lambda} \quad \dots \text{střední (očekávaná) hodnota}$$

$$DT_k = \dots = \frac{k}{\lambda^2} \quad \dots \text{rozptyl } T_k$$


Pokud  $k$  je celočíselné, toto rozdělení mívá označení jako Erlangovo.



Hustota pravděpodobnosti pro Gamma rozdělení,  $Ga(k, \lambda)$ .

## Intenzita poruch (hazardní funkce):

$$h(x) = \frac{f(x)}{1-F(x)} = \frac{\lambda}{(k-1)! \sum_{j=0}^{k-1} \frac{1}{(k-1-j)! (\lambda x)^j}}$$



Intenzita poruch Gamma rozdělení,  $\lambda=1$ ,  $\text{Ga}(k,1)$ .

## **$Ga(k, \lambda)$**

$$f(x) = \frac{\lambda^k}{\Gamma(k)} \cdot x^{k-1} e^{-\lambda \cdot x}, \quad \lambda > 0$$

**reparametrizace:**  $a = k, \quad b = \frac{1}{\lambda}$

$$f(x) = \frac{\left(\frac{1}{b}\right)^a}{\Gamma(a)} \cdot x^{a-1} e^{-\frac{x}{b}}, \quad \lambda > 0$$

je rozdělení  $\rightarrow$   **$Ga(a, b)$**   $a \in R$

A parametr  $\lambda$  bude v pozici náhodné veličiny, tedy jeho apriorní rozdělení bude:

$$f(\lambda) = \frac{\left(\frac{1}{b}\right)^a}{\Gamma(a)} \cdot \lambda^{a-1} e^{-\frac{\lambda}{b}} \propto \lambda^{a-1} e^{-\frac{\lambda}{b}} \quad \lambda > 0$$

A budeme ho označovat nejčastěji jako:  $\pi(\lambda) \propto \lambda^{a-1} e^{-\frac{\lambda}{b}} \quad \lambda > 0$

## Řešený příklad

Nechť  $X_1, \dots, X_n$  je náhodný výběr z exponenciálního rozdělení s parametrem  $\lambda$ . Úkolem je nalézt aposteriorní rozdělení pro  $\lambda$  za předpokladu, že apriorní rozdělení je:

a)  $\lambda \rightarrow \text{Gamma}(a; b)$ , tj.

$$\pi(\lambda) = \frac{\left(\frac{1}{b}\right)^a}{\Gamma(a)} \cdot \lambda^{a-1} \cdot e^{-\frac{\lambda}{b}}, \quad \text{kde } \Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx, \quad E\lambda = ab \quad \text{b) } \pi(\lambda) = \frac{1}{\lambda}$$

\*\*\*\*\*

Víme, že hustota pravděpodobnosti exponenciální náhodné veličiny má tvar:

$$f(x) = \lambda \cdot e^{-\lambda x}, \quad x > 0,$$

kde  $\lambda > 0$  je neznámý parametr.

Zkonstruujeme nejdříve věrohodnostní funkci:

$$L(\lambda; \mathbf{x}) = \prod_{i=1}^n f(x_i) = \lambda^n e^{-\lambda \sum_{i=1}^n x_i} = \lambda^n e^{-\lambda n \bar{x}},$$

kde  $\bar{x}$  je výběrový průměr.

*ada)* Pokud ignorujeme konstantu úměrnosti, apriorní rozdělení

$$\pi(\lambda) \propto \lambda^{a-1} \cdot e^{-\frac{\lambda}{b}}$$

aposteriorní rozdělení  $\propto$  (apriorní rozdělení  $\times$  věrohodnostní funkce):

$$\pi(\lambda) \propto \lambda^{a-1} \cdot e^{-\frac{\lambda}{b}} \cdot \lambda^n e^{-\lambda n \bar{x}} \Rightarrow \pi(\lambda|x) \propto \lambda^{n+a-1} \cdot e^{-\lambda \left( \frac{1}{b} + n \bar{x} \right)}$$

Lze snadno rozeznat, že se jedná o Gamma rozdělení:

$$(\lambda|x) \rightarrow \text{Gamma} \left( n + a; \frac{b}{nb\bar{x} + 1} \right)$$

*Protože apriorní i posteriorní rozdělení patří do téže třídy rozdělení, je evidentní, že tato třída (Gamma rozdělení) slouží jako přirozený konjugovaný systém pro parametr exponenciálního rozdělení.*

**adb)** *nevlastní apriorní rozdělení:*  $\pi(\lambda) = \frac{1}{\lambda}$

*posteriorní rozdělení*  $\propto \frac{1}{\lambda} \cdot \lambda^n e^{-\lambda n \bar{x}} \Rightarrow \pi(\lambda|x) \propto \lambda^{n-1} \cdot e^{-\lambda n \bar{x}}$ ,

*takže:*

$$(\lambda|x) \rightarrow \text{Gamma}\left(n; \frac{1}{nx}\right)$$

*a skutečnost, že apriorní rozdělení je nevlastní, zde nehraje významnou roli.*

## Řešený příklad, projekt

Nechť náhodná veličina  $X$  má Poissonovo rozdělení  $Po(\lambda)$ .

$$f(k, \lambda) = \frac{\lambda^k}{k!} \cdot e^{-\lambda} \quad k = 0, 1, \dots, \quad \lambda > 0$$

$$EX = DX = \lambda$$

$$\underline{\underline{I(\lambda)}} = E \left\{ \left( \frac{\partial \ln f(k, \lambda)}{\partial \lambda} \right)^2 \right\} = E \left\{ \frac{(k - \lambda)^2}{\lambda^2} \right\} = \frac{1}{\lambda^2} \cdot E \{ (k - \lambda)^2 \} = \frac{1}{\lambda^2} \cdot DX = \frac{1}{\lambda^2} \cdot \lambda = \underline{\underline{\frac{1}{\lambda}}}$$

Jeffreysova apriorní hustota:

$$\pi(\lambda) = [I(\lambda)]^{1/2} = \frac{1}{\sqrt{\lambda}} = \lambda^{-\frac{1}{2}}$$

Aplikuji věrohodnostní funkci a dostanu aposteriorní hustotu:

$$Ga\left(n, \frac{1}{\sum_1^n x_i + \frac{1}{2}}\right)$$

**Námět na projekt: Pokud apriorní je Gamma, jaká je aposteriorní hustota? Tvoří Gamma rozdělení přirozený konjugovaný systém?**



Konjugované apriorní hustoty vybraných jednoparametrických modelů:

Neznámý parametr:  $\theta$ , ostatní parametry jsou známé

Model	Rozdělení $x$	Konjug. rozdělení $\theta$
Normální	$\mathcal{N}(\theta, \sigma^2)$	$\mathcal{N}(\mu, \xi^2)$
Normální	$\mathcal{N}(\mu, \frac{1}{\theta})$	$\mathcal{G}(\alpha, \beta)$
Poissonovo	$\mathcal{P}(\theta)$	$\mathcal{G}(\alpha, \beta)$
Gama	$\mathcal{G}(\nu, \theta)$	$\mathcal{G}(\alpha, \beta)$
Binomické	$\mathcal{Bi}(n, \theta)$	$\mathcal{Be}(\alpha, \beta)$