

# Skalární skórová funkce

Zdeněk Fabián  
Ústav informatiky AVČR Praha

ROBUST  
2016

## Prototypy a transformovaná rozdělení na $\mathbb{R}$

- $Y$  má na  $\mathbb{R}$  rozdělení  $G(G_\theta)$  s hustotou  $g(y)$   
 $\eta : \mathbb{R} \rightarrow \mathbb{R}$  hladká rostoucí,  $\Rightarrow \eta^{-1}$  taky

Transformovaná r.v.  $X = \eta^{-1}(Y)$  má distribuční funkci

$$F(x) = G(\eta(x))$$

a hustotu

$$f(x) = g(\eta(x))\eta'(x)$$

## Prototypy a transformovaná rozdělení na $\mathbb{R}$

- $Y$  má na  $\mathbb{R}$  rozdělení  $G(G_\theta)$  s hustotou  $g(y)$

$\eta : \mathbb{R} \rightarrow \mathbb{R}$  hladká rostoucí,  $\Rightarrow \eta^{-1}$  taky

Transformovaná r.v.  $X = \eta^{-1}(Y)$  má distribuční funkci

$$F(x) = G(\eta(x))$$

a hustotu

$$f(x) = g(\eta(x))\eta'(x)$$



$$f(x) = \frac{1}{\sqrt{2\pi}} \frac{1}{\sqrt{1+x^2}} e^{-\frac{1}{2}(\sinh^{-1} x)^2} \quad g(y) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2}$$

## Prototypy a transformovaná rozdělení na $\mathbb{R}$

- $Y$  má na  $\mathbb{R}$  rozdělení  $G(G_\theta)$  s hustotou  $g(y)$

$\eta : \mathbb{R} \rightarrow \mathbb{R}$  hladká rostoucí,  $\Rightarrow \eta^{-1}$  taky

Transformovaná r.v.  $X = \eta^{-1}(Y)$  má distribuční funkci

$$F(x) = G(\eta(x))$$

a hustotu

$$f(x) = g(\eta(x))\eta'(x)$$



$$f(x) = \frac{1}{\sqrt{2\pi}} \frac{1}{\sqrt{1+x^2}} e^{-\frac{1}{2}(\sinh^{-1} x)^2} \quad g(y) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2}$$

- Nesymetrie:  $g(y)$  je hustota *prototypu* transformovaného  $F$

# Skórová funkce prototypu



$$S_G(y) = -\frac{g'(y)}{g(y)}$$

# Skórová funkce prototypu



$$S_G(y) = -\frac{g'(y)}{g(y)}$$

- popisuje vliv  $y \in \mathbb{R}$  vzhledem ke 'středu'  $G$   
pro  $g(y - \mu)$  (*třída Ia*) platí

$$\frac{\partial}{\partial \mu} \log g(y - \mu) = S_G(y - \mu)$$

# Skórová funkce prototypu



$$S_G(y) = -\frac{g'(y)}{g(y)}$$

- popisuje vliv  $y \in \mathbb{R}$  vzhledem ke 'středu'  $G$   
pro  $g(y - \mu)$  (*třída Ia*) platí

$$\frac{\partial}{\partial \mu} \log g(y - \mu) = S_G(y - \mu)$$

- popisuje vliv  $y \in \mathbb{R}$  vzhledem ke 'středu'  $G$  i prototypu s  $\theta$   
bez parametru polohy, 'středem' je mód  $y^* : S_G(y^*; \theta) = 0$

$$g(y) = \frac{1}{B(p, q)} \frac{e^{py}}{(e^y + 1)^{p+q}} \quad S_G(y) = \frac{qe^y - p}{e^y + 1}$$

## Tabulka: typy skórových funkcí

Typ	$S_G(y)$	$g(y)$	rozdělení	$ES_G^2$
NE	$\frac{e^y - e^{-y}}{2}$	$\frac{1}{2K_0(1)} e^{-\cosh y}$	-	1.43
■ NG	$y$	$\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2}$	normal	1
ON	$e^y - 1$	$e^y e^{-e^y}$	Gumbel	1
NO	$1 - e^{-y}$	$e^{-y} e^{-e^{-y}}$	extreme value	1
OO	$\frac{e^y - 1}{e^y + 1}$	$\frac{e^y}{(1+e^y)^2}$	logistic	1/3
OR	$\frac{2y}{1+y^2}$	$\frac{1}{\pi} \frac{1}{1+y^2}$	Cauchy	1/2

Skórové momenty:  $ES_G^2$  je (zobec.) Fisherova informace pro mód,  $ES_G^3$  charakt. nesymetrie,  $ES_G^4$  'placatosti'

## Tabulka: typy skórových funkcí

Typ	$S_G(y)$	$g(y)$	rozdělení	$ES_G^2$
NE	$\frac{e^y - e^{-y}}{2}$	$\frac{1}{2K_0(1)} e^{-\cosh y}$	-	1.43
■ NG	$y$	$\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2}$	normal	1
ON	$e^y - 1$	$e^y e^{-e^y}$	Gumbel	1
NO	$1 - e^{-y}$	$e^{-y} e^{-e^{-y}}$	extreme value	1
OO	$\frac{e^y - 1}{e^y + 1}$	$\frac{e^y}{(1+e^y)^2}$	logistic	1/3
OR	$\frac{2y}{1+y^2}$	$\frac{1}{\pi} \frac{1}{1+y^2}$	Cauchy	1/2

Skórové momenty:  $ES_G^2$  je (zobec.) Fisherova informace pro mód,  $ES_G^3$  charakt. nesymetrie,  $ES_G^4$  'placatosti'

### ■ Momentové rovnice

$$\frac{1}{n} \sum_{i=1}^n S_G^k(y_i; \theta) = ES_G^k(\theta), \quad k = 1, \dots$$

# Transformovaná rozdělení

- Budě  $\mathcal{X} \subseteq \mathbb{R}$  otevřený interval a  $F(x) = G(\eta(x))$  na  $\mathcal{X}$

# Transformovaná rozdělení

- Budě  $\mathcal{X} \subseteq \mathbb{R}$  otevřený interval a  $F(x) = G(\eta(x))$  na  $\mathcal{X}$
- I: Proč by pro rozdělení na polopřímce nebo intervalu neměla existovat obdoba skórové funkce prototypu, t.j. reálná (skalární) skórová funkce (vlivová funkce vzhledem k nějakému 'středu'). Protože  $S(x) = -\frac{f'(x)}{f(x)}$  pro tato rozdělení nefunguje, musí být definovaná jiným vzorcem, který se jako v případě prototypů shoduje pro nějakou klasifikaci s jejich Fisherovým skórem pro nějaký parametr

# Transformovaná rozdělení

- Budě  $\mathcal{X} \subseteq \mathbb{R}$  otevřený interval a  $F(x) = G(\eta(x))$  na  $\mathcal{X}$
- I: Proč by pro rozdělení na polopřímce nebo intervalu neměla existovat obdoba skórové funkce prototypu, t.j. reálná (skalární) skórová funkce (vlivová funkce vzhledem k nějakému 'středu'). Protože  $S(x) = -\frac{f'(x)}{f(x)}$  pro tato rozdělení nefunguje, musí být definovaná jiným vzorcem, který se jako v případě prototypů shoduje pro nějakou klasifikaci s jejich Fisherovým skórem pro nějaký parametr
- II. Transformované  $F$  na  $\mathbb{R}$  poznáme a na  $\mathcal{X} \neq \mathbb{R}$  jsou všechna transformovaná

## Obdoba skórové funkce prototypu: t-skór

- $\eta(x) : \mathcal{X} \rightarrow \mathbb{R}$ . Definujeme t-skór (transformation-based score) transformovaného rozdělení  $F$  jako

$$T_F(x) = S_G(\eta(x))$$

## Obdoba skórové funkce prototypu: t-skór

- $\eta(x) : \mathcal{X} \rightarrow \mathbb{R}$ . Definujeme t-skór (transformation-based score) transformovaného rozdělení  $F$  jako

$$T_F(x) = S_G(\eta(x))$$

- Ukáže se, že když  $f(x) = g(\eta(x))\eta'(x)$ ,

$$T_F(x) = -\frac{1}{f(x)} \frac{d}{dx} [g(\eta(x))] = -\frac{1}{f(x)} \frac{d}{dx} \left[ \frac{1}{\eta'(x)} f(x) \right]$$

## Obdoba skórové funkce prototypu: t-skór

- $\eta(x) : \mathcal{X} \rightarrow \mathbb{R}$ . Definujeme t-skór (transformation-based score) transformovaného rozdělení  $F$  jako

$$T_F(x) = S_G(\eta(x))$$

- Ukáže se, že když  $f(x) = g(\eta(x))\eta'(x)$ ,

$$T_F(x) = -\frac{1}{f(x)} \frac{d}{dx} [g(\eta(x))] = -\frac{1}{f(x)} \frac{d}{dx} \left[ \frac{1}{\eta'(x)} f(x) \right]$$

- a je dokázáno, že pro rozdělení s transformovaným parametrem polohy  $\tau = \eta^{-1}(\mu)$  (rozdělení *třídy Ia*)

$$\frac{\partial}{\partial \tau} \log f(x; \tau) = \text{konst.} \times T_F(x; \tau)$$

## t-skór rozdělení log-gamma

- $\mathcal{X} = (1, \infty)$        $f(x) = \frac{c^\alpha}{\Gamma(\alpha)} (\log x)^{\alpha-1} \frac{1}{x^{c+1}}$

## t-skór rozdělení log-gamma

- $\mathcal{X} = (1, \infty)$        $f(x) = \frac{c^\alpha}{\Gamma(\alpha)} (\log x)^{\alpha-1} \frac{1}{x^{c+1}}$

- Položme  $\eta'(x) = \frac{1}{x \log x}$ ,  $\eta(x) = \log \log x$ ,

$$T_{1F}(x) = -\frac{1}{f(x)} \frac{d}{dx} [x \log x f(x)] = c \log x - \alpha$$

a momentové rovnice

$$\sum_{i=1}^n (c \log x_i - \alpha) = 0 \quad \quad \frac{1}{n} \sum_{i=1}^n (c \log x_i - \alpha)^2 = \alpha$$

## t-skór rozdělení log-gamma

- $\mathcal{X} = (1, \infty)$        $f(x) = \frac{c^\alpha}{\Gamma(\alpha)} (\log x)^{\alpha-1} \frac{1}{x^{c+1}}$

- Položme  $\eta'(x) = \frac{1}{x \log x}$ ,  $\eta(x) = \log \log x$ ,

$$T_{1F}(x) = -\frac{1}{f(x)} \frac{d}{dx} [x \log x f(x)] = c \log x - \alpha$$

a momentové rovnice

$$\sum_{i=1}^n (c \log x_i - \alpha) = 0 \quad \quad \frac{1}{n} \sum_{i=1}^n (c \log x_i - \alpha)^2 = \alpha$$

- Zvolme  $\eta(x) = \log(x - 1)$ ,

$$T_{2F}(x) = -\frac{1}{f(x)} \frac{d}{dx} [(x-1)f(x)] = c - \frac{(\alpha-1)(x-1)}{\log x} - \frac{c+1}{x}$$

Pro  $\alpha = 1$  se  $f(x)$  i  $T_{2F}$  redukuje na hustotu a t-skór Pareta

# Smysl má uvažovat dva druhy t-skórů

- t-skór přirozený: když je ve vzorci pro hustotu 'viditelné'  $\eta(x)$  nebo  $\eta'(x)$

# Smysl má uvažovat dva druhy t-skórů

- t-skór přirozený: když je ve vzorci pro hustotu 'viditelné'  $\eta(x)$  nebo  $\eta'(x)$
- t-skór univerzální: založený na log-transformacích (Johnsonovy transformace)

$$\eta(x) = \begin{cases} \log(x - a) & \mathcal{X} = (a, \infty) \\ \log \frac{(x - a)}{(b - x)} & \mathcal{X} = (a, b) \end{cases}$$

Takto lze interpretovat většinu prakticky používaných rozdělení:

$$f(x) = e^{-x} = xe^{-x} \frac{1}{x}$$
$$T_F(x) = -\frac{1}{f(x)} \frac{d}{dx} [xf(x)] = e^x \frac{d}{dx} [xe^{-x}] = x - 1$$

## Přirozený t-skór: pro momentové odhady

- Buď  $\theta = (\theta_1, \theta_2)$ . Protože  $T_F(x) = S_G(\eta(x))$  a  $ET_F^k = ES_G^k$ , momentové rovnice

$$\sum_{i=1}^n S_G(\eta(x_i); \theta) = 0 \quad \frac{1}{n} \sum_{i=1}^n S_G^2(\eta(x_i); \theta) = ES_G^2$$

jsou invariantní vůči transformacím proměnné (6 tříd rozdělení z Tabulky)

## Přirozený t-skór: pro momentové odhady

- Budě  $\theta = (\theta_1, \theta_2)$ . Protože  $T_F(x) = S_G(\eta(x))$  a  $ET_F^k = ES_G^k$ , momentové rovnice

$$\sum_{i=1}^n S_G(\eta(x_i); \theta) = 0 \quad \frac{1}{n} \sum_{i=1}^n S_G^2(\eta(x_i); \theta) = ES_G^2$$

jsou invariantní vůči transformacím proměnné (6 tříd rozdělení z Tabulky)

- Když  $S_F$  je omezená nebo 'huberovsky oříznutá', estimátor je robustní pro všechny parametry

## Přirozený t-skór: pro momentové odhady

- Buď  $\theta = (\theta_1, \theta_2)$ . Protože  $T_F(x) = S_G(\eta(x))$  a  $ET_F^k = ES_G^k$ , momentové rovnice

$$\sum_{i=1}^n S_G(\eta(x_i); \theta) = 0 \quad \frac{1}{n} \sum_{i=1}^n S_G^2(\eta(x_i); \theta) = ES_G^2$$

jsou invariantní vůči transformacím proměnné (6 tříd rozdělení z Tabulky)

- Když  $S_F$  je omezená nebo 'huberovsky oříznutá', estimátor je robustní pro všechny parametry
- Protože  $T_F(x; \hat{\theta}) = S_G(\eta(x); \hat{\theta})$  je reálná funkce, lze ji např. použít v korelační a regresní analýze

# Univerzální t-skór: Skórová funkce rozdělení SFD



$$S_F(x) = \eta'(x^*) T_F(x)$$

kde  $\eta(x)$  je Johnsonova transformace a  $x^*$  je těžiště:  
řešení rovnice

$$T_F(x) = 0$$

( $x^*$  je obraz módu prototypu).

# Univerzální t-skór: Skórová funkce rozdělení SFD



$$S_F(x) = \eta'(x^*) T_F(x)$$

kde  $\eta(x)$  je Johnsonova transformace a  $x^*$  je těžiště: řešení rovnice

$$T_F(x) = 0$$

( $x^*$  je obraz módu prototypu).



- $ES_F^2$  zobecněná Fisherova informace (vzhledem k  $x^*$ )

Variabilita rozdělení: skórová variance

$$\omega^2 = \frac{1}{ES_F^2}$$

Numerické charakteristiky rozdělení:  $x^*(\theta), \omega(\theta) = \sqrt{\omega^2(\theta)}$

## Rozdělení na $(0, \infty)$ s týmž $\omega$




## Kam jsme došli

K danému  $F$  na intervalu  $\mathcal{X} \subseteq \mathbb{R}$  umíme jednoznačně přiřadit sfd  $S_F(x)$ , jejíž hodnota popisuje relativní vliv  $x \in \mathcal{X}$  na střed  $x^*$  of  $F$ .

# Popis náhodné veličiny $X$ s rozdělením $F$ na $\mathcal{X} \subseteq \mathbb{R}$

$F(x)$	cdf
$f(x)$	pdf
$S(x)$	sfd
$x^* : S(x) = 0$	těžiště
$S^2(x)$	informační funkce
$w(x) = \frac{dS(x)}{dx}$	vahová funkce
$ES^2$	střední (Fisherova) informace
$\omega^2 = 1/ES^2$	skórová variance
$\frac{S(x)}{ES^2} = \omega^2 S(x)$	influence function
$\frac{S^2(x)}{[ES^2]^2}$	uncertainty function



# Metrika ve výběrovém prostoru $\mathcal{X}$

$$\begin{aligned} S_F(x) & \quad \text{sfd} \\ w_F(x) = \frac{dS_F(x)}{dx} & \quad \text{vahová funkce} \\ \omega_F = 1/\sqrt{ES_F^2} & \end{aligned}$$

Vzdálenost  $x_1, x_2 \in \mathcal{X}$

$$\rho_F(x_1, x_2) = \omega_F \int_{x_1}^{x_2} w_F(x) dx = \omega_F |S_F(x_2) - S_F(x_1)|$$

$$S_F(x) \Leftrightarrow f(x)$$

$$(\mathcal{X}, F) \Leftrightarrow (\mathcal{X}, \rho_F)$$

# Centrální limitní věta pro sfd

$$S_F(x)$$

sfd

$$x^* : S_F(x) = 0$$

těžiště

$$w_F(x) = \frac{dS_F(x)}{dx}$$

vahová funkce

$$ES_F^2$$

střední (Fisherova) informace

$$\omega^2 = 1/ES_F^2$$

skórová variance

$X_1, \dots, X_n$  iid podle  $F$

Central limit theorem:  $\bar{S} = \frac{1}{n} \sum_{i=1}^n S_F(X_i) \rightarrow \mathcal{N}(0; \omega^2/n)$

Výběrové těžiště:

$$\hat{x}^* = S_F^{-1}(\bar{S}) \rightarrow \mathcal{N}(x^*; [(S_F^{-1}(\bar{S}))']^2 \omega^2/n)$$

Odhady pro rozdílné modely jdou porovnávat pomocí

$$\hat{x}^* = x^*(\hat{\theta}), \hat{\omega}^* = \omega(\hat{\theta})$$

# Skórový průměr

Někdy je výběrové těžiště známou statistikou:

rozdělení	$\hat{x}^*$
normální, gamma, beta	$\bar{x}$
lognormální	$\bar{x}_{Geom}$
Weibull ( $c$ const.)	$\frac{1}{n}(\sum x_i^c)^{1/c}$
Pareto and jiná heavy-tailed	$\bar{x}_{Harm}$
beta-prime	$\sum \frac{x_i}{x_i+1} / \sum \frac{1}{x_i+1}$

## Reference:

Fabián, Z. (2001). Induced cores and their use in robust parametric estimation. *Communication in Statistics, Theory-Methods* 30, 537-556.

Fabián, Z. (2010). Score moment estimators. In Lechavilier, Y., Saporta, G.(Eds.), Proc. of conf. COMPSTAT, Physica-Verlag, pp.975-982.

Fabián Z. (2016). Score function of distribution and revival of the moment method. *Communication in Statistics, Theory-Methods* 45,4, 1118-1136.



## SFD rozdělení na intervalu

Př. Useknutá exponenciela  $\mathcal{X} = (0, 1)$ ,  $f(x) = b e^{-\lambda x}$

Johnsonova transformace  $\eta(x) = \log \frac{x}{1-x}$ ,  $\eta'(x) = \frac{1}{x(1-x)}$  Pišme

$$f(x) = bx(1-x)e^{-\lambda x} \frac{1}{x(1-x)},$$


takže

$$T_F(x) = -e^{\lambda x} \frac{d}{dx} [x(1-x)e^{-\lambda x}] = (2+\lambda)x - \lambda x^2 - 1$$


Pak  $x^*$  :  $T_F(x^*) = 0$ ,

$$S_F(x) = \frac{1}{x^*(1-x^*)} T_F(x)$$

truncated exponential: densities



score functions



## Vztah $\omega_F$ a diferenciální entropie

$$h_F = - \int f(x) \log f(x) dx$$

$F$	$e^{h_F}$	$\omega_F$
normal	$\sqrt{2\pi e}\sigma$	$\sigma$
Cauchy	$4\pi\sigma$	$\sqrt{2}\sigma$
exponential	$e\tau$	$\tau$
lognormal	$\sqrt{2\pi e} \tau/c$	$\tau/c$
Weibull	$e^{(1+\epsilon(1-1/c))} \tau/c$	$\tau/c$
uniform <sub>(a,b)</sub>	$b-a$	$\frac{\sqrt{3}}{4}(b-a)^2$