

Štatistická inferencia v exponenciálnej rodine založená na *I*-divergencii

ROBUST 2014

Vladimíra Sečkárová, Radka Sabolová, Milan Stehlík

22.1.2014

KPMS MFF UK, PRAHA
ÚTIA, PRAHA
IFAS JKU, LINZ

Kullbackova Leiblerova divergencia

Kullbackovu Leiblerovu divergenciu (KLD) [S. Kullback, R.A. Leibler (1951)]:

$$KLD(p||q) = \int_Y p(y) \ln \frac{p(y)}{q(y)} dy$$

- ▶ Y je spojitá náhodná veličina
- ▶ p, q sú pravdepodobnosťné hustoty

Vlastnosti KLD:

- ▶ nie je symetrická
- ▶ nezáporná
- ▶ minimum rovné nule nadobúda $\leftrightarrow p = q$ a.e.
- ▶ nie je zhora ohraničená

Kullbackova Leiblerova divergencia

Využitie:

- ▶ testovanie hypotetickej hodnoty parametru rozdelenia zrážkových úhrnov
S.V. Weijs, N. Van De Giesen (2011): *Accounting for Observational Uncertainty in Forecast Verification: An Information-Theoretical View on Forecasts, Observations, and Truth.*
- ▶ testovanie hypotetickej hodnoty parametru + asymptotické vlastnosti testovej štatistiky
A. Basu, A. Mandal, N. Martin, L. Pardo (2013): *Testing statistical hypotheses based on the density power divergence.*
- ▶ Bregmanova mocninná vzdialenosť (vzťah ku KLD)
A.L. Kisslinger, W. Stummer (2013): *Some Decision Procedures Based on Scaled Bregman Distance Surfaces.*

Exponenciálna rodina rozdelení

Y_1, \dots, Y_N - náhodný výber z rozdelenia patriaceho do exponenciálnej rodiny

Tvar pravdepodobnostnej hustoty rozdelenia patriaceho do exponenciálnej rodiny

$$h(\mathbf{y}|\theta) = \exp \{-\psi(\mathbf{y}) + T(\mathbf{y})^T \gamma(\theta) - \zeta(\gamma(\theta))\}$$

kde $\theta \in \Theta$, $T(\mathbf{y})$ je postačujúca štatistika

Podmienky regularity:

- ▶ výberový priestor je otvorenou množinou v R^N
- ▶ množina Θ je podmnožinou R^m , $m < N$
- ▶ zobrazenie $\gamma : \Theta \rightarrow R^k$ je dvakrát spojito diferencovateľné na $\text{int}(\Theta)$
- ▶ ... [Pázman 1993]

Podmienky hladkosti:

- ▶ Pre $\gamma \in R^k$ označme

$$\kappa(\gamma) = \ln \int_Y \exp \left\{ -\psi(\mathbf{y} + T(\mathbf{y}^\top \gamma)) \right\} d\mathbf{y}$$

Predpokladáme tiež, že množina

$$\Gamma = \left\{ \gamma \in R^k : \kappa(\gamma) < \infty \right\}$$

má neprázdné vnútro

- ▶ A tiež predpokladáme, že:

$$\{t(\mathbf{y} : \mathbf{y} \in Y)\} \subseteq \left\{ \frac{\partial \kappa(\gamma)}{\partial \gamma} : \gamma \in \text{int}(\Gamma) \right\}$$

Definícia I-divergencie

Majme súbor náhodných veličín Y_1, \dots, Y_N , $N < \infty$, ktoré

- ▶ nezávislé
- ▶ rozdelených podľa rozdelenia z exponenciálnej rodiny s pravdepodobnosťou hustotu tvaru:

$$h(y|\gamma) = \exp \{-\psi(y) + T(y)\gamma - \kappa(\gamma)\} \quad (1)$$

Ďalej budeme predpokladať:

$$\{t(\mathbf{y} : \mathbf{y} \in Y)\} \subseteq \{\mathbb{E}_\gamma[T(\mathbf{y})] : \gamma \in \text{int}(\Gamma)\}$$

V regulárnej exponenciálnej rodine máme podľa [Barndorff-Nielsen (1978)]:

$$\mathbb{E}_\gamma[T(\mathbf{y})] = \frac{\partial \kappa(\gamma)}{\partial \gamma}$$

Definícia I-divergencie

I-divergenciu potom definujeme ako

$$\begin{aligned}
 I_N(\mathbf{y}, \boldsymbol{\gamma}^*) &= KLD(h(\mathbf{y}|\hat{\boldsymbol{\gamma}}_{\mathbf{y}}) || h(\mathbf{y}|\boldsymbol{\gamma}^*)) \\
 &= \int_{\mathbf{y}} h(\mathbf{y}|\hat{\boldsymbol{\gamma}}_{\mathbf{y}}) \ln \frac{h(\mathbf{y}|\hat{\boldsymbol{\gamma}}_{\mathbf{y}})}{h(\mathbf{y}|\boldsymbol{\gamma}^*)} d\mathbf{y} \\
 &= \sum_{i=1}^N (T(y_i)\hat{\gamma}_i + \ln g(\hat{\gamma}_i)) - \sum_{i=1}^N (T(y_i)\gamma_i^* + \ln g(\gamma_i^*)).
 \end{aligned}$$

- ▶ $\hat{\boldsymbol{\gamma}}_{\mathbf{y}} = (\hat{\gamma}_1, \dots, \hat{\gamma}_N)^T$ - vektor maximálne vieročodných odhadov založených na $y_i, i = 1, \dots, N$
- ▶ $\boldsymbol{\gamma}^*$ vektor obsahujúci N zvolených hodnot
- ▶ Z podmienok na hladkosť sme využili vzťah

$$\frac{\partial \kappa(\boldsymbol{\gamma})}{\partial \boldsymbol{\gamma}} = T(\mathbf{y})$$

Rozklad I_N na R_N, S_N

Uvažujme maximálne vieročodný odhad $\hat{\gamma}_{MLE}$ založený na y_1, \dots, y_N
Definujme R_N, S_N

$$R_N = \sum_{i=1}^N (\hat{\gamma}_{MLE} T(y_i) + \ln(g(\hat{\gamma}_{MLE}))) - \sum_{i=1}^N (\gamma_0 T(y_i) + \ln(g(\gamma_0)))$$
$$S_N = \sum_{i=1}^N (T(y_i) \hat{\gamma}_i + \ln(g(\hat{\gamma}_i))) - \sum_{i=1}^N (T(y_i) \hat{\gamma}_{MLE} + \ln(g(\hat{\gamma}_{MLE})))$$

Vidíme, že

$$I_N = R_N + S_N$$

Interpretácia častí R_N , S_N

S_N reprezentuje testovú štatistiku testu pomerom viero hodností:

$$H_0 : \gamma_1 = \dots = \gamma_N \quad \text{vs.} \quad H_1 : \text{lubovoľné vhodné } \gamma, \quad \gamma \in \Gamma$$

R_N reprezentuje testovú štatistiku testu pomerom viero hodností:

$$H_0 : \gamma_1 = \dots = \gamma_N = \gamma_0 \quad \text{vs.} \quad H_1 : \gamma \neq \gamma_0.$$

Nezávislosť R_N, S_N

- ▶ Gamma rozdelenie: R_N, S_N sú nezávislé, odvodené v [Stehlík (2003)].
- ▶ Exponenciálne rozdelenie: je špeciálny prípad Gamma rozdelenia, R_N, S_N sú nezávislé.
- ▶ Pareto rozdelenie: použijeme vzťah

$$Y \sim \text{Pareto}(x_m, \alpha) \rightarrow X = \ln\left(\frac{Y}{x_m}\right) \sim \text{Exp}(\alpha)$$

Potom máme R_N, S_N nezávislé.

Úvod

- ▶ Y_1, \dots, Y_N nezávislé, $\text{Exp}(\gamma)$, kde $\gamma = (\gamma_1, \dots, \gamma_N)^T$
- ▶ hustota Y_i

$$h(y_i | \gamma_i) = \gamma_i e^{-\gamma_i y_i}, \quad y_i \geq 0$$

Úvod

- ▶ Y_1, \dots, Y_N nezávislé, $\text{Exp}(\gamma)$, kde $\gamma = (\gamma_1, \dots, \gamma_N)^T$
- ▶ hustota Y_i

$$h(y_i | \gamma_i) = \gamma_i e^{-\gamma_i y_i}, \quad y_i \geq 0$$

- ▶ *I*-divergencia

$$I_N(\mathbf{y}, \gamma^*) = \int_{\mathbf{y}} h(\mathbf{y} | \hat{\gamma}_{\mathbf{y}}) \ln \frac{h(\mathbf{y} | \hat{\gamma}_{\mathbf{y}})}{h(\mathbf{y} | \gamma^*)} d\mathbf{y}$$

Úvod

- ▶ Y_1, \dots, Y_N nezávislé, $\text{Exp}(\gamma)$, kde $\gamma = (\gamma_1, \dots, \gamma_N)^T$
- ▶ hustota Y_i

$$h(y_i | \gamma_i) = \gamma_i e^{-\gamma_i y_i}, \quad y_i \geq 0$$

- ▶ I-divergencia

$$I_N(\mathbf{y}, \gamma^*) = \int_{\mathbf{y}} h(\mathbf{y} | \hat{\gamma}_{\mathbf{y}}) \ln \frac{h(\mathbf{y} | \hat{\gamma}_{\mathbf{y}})}{h(\mathbf{y} | \gamma^*)} d\mathbf{y}$$

- ▶ pre exponenciálne rozdelené náhodné veličiny

$$I_N(\mathbf{y}, \gamma_0) = N \ln \sum_i y_i - \sum_i \ln y_i + \gamma_0 \sum_i y_i - N \ln(\gamma_0 \sum_i y_i) - N$$

Rozdelenie $I_N(y, \gamma_0)$

- ▶ pre $N \leq 4$, distribučná funkcia I_N je známa a je možné ju zapísat analyticky
- ▶ pre $N = 1$


$$F_1(x) = \begin{cases} \exp\{\gamma_0^{-1}\gamma W_0(-\exp\{-1-x\})\} - \exp\{\gamma_0^{-1}\gamma W_{-1}(-\exp\{-1-x\})\} \\ 0 \end{cases}$$


kde W_0, W_{-1} sú dve reálne vetvy Lambertovej W-funkcie


- ▶ Lambertova W-funkcia je riešením rovnice

$$z = W(z)e^{W(z)}$$

pre ľubovoľné z komplexné

Graf I_1 

QQ-plot $F_1(I_1(y, \gamma_0))$ pre $\gamma = \gamma_0 = 1$ 

QQ-plot $F_1(I_1(y, \gamma_0))$ pre $\gamma \neq \gamma_0$ 

Rozdelenie $I_N(y, \gamma_0)$ pre $N > 1$

- distribučná funkcia I_N odvodená analyticky pre $N \leq 4$, ale komplikovaná
- využijeme dekompozíciu $I_N = R_N + S_N$, asymptotické rozdelenie R_N a približné rozdelenie S_N , kde

$$R_N = \gamma_0 \sum_i y_i - N \ln(\gamma_0 \sum_i y_i) - N + N \ln N$$

$$S_N = N \ln \sum_i y_i - N \ln N - \sum_i \ln y_i$$

Rozdelenie $I_N(y, \gamma_0)$ pre $N > 1$

- ▶ distribučná funkcia I_N odvodená analyticky pre $N \leq 4$, ale komplikovaná
- ▶ využijeme dekompozíciu $I_N = R_N + S_N$, asymptotické rozdelenie R_N a približné rozdelenie S_N , kde

$$R_N = \gamma_0 \sum_i y_i - N \ln(\gamma_0 \sum_i y_i) - N + N \ln N$$


$$S_N = N \ln \sum_i y_i - N \ln N - \sum_i \ln y_i$$


- ▶ asymptoticky


$$R_N \sim \chi_1^2$$


- ▶ približne

$$S_N \sim \frac{1}{2} \left(1 + \frac{1 + \frac{1}{N}}{6} \right) \chi_{N-1}^2$$

QQ-plot pre $\hat{F}_{10}(I_{10}(y, \gamma_0))$, $\gamma = \gamma_0 = 1$ 

QQ-plot pre $\hat{F}_{10}(I_{10}(y, \gamma_0))$, $\gamma \neq \gamma_0$ 

QQ-plot pre $\hat{F}_{50}(I_{50}(y, \gamma_0))$, $\gamma = \gamma_0 = 1$ 

QQ-plot pre $\hat{F}_{50}(I_{50}(y, \gamma_0))$, $\gamma \neq \gamma_0$ 

Aproximácia hustoty MLE

- ▶ saddlepoint aproximácia hustoty postačujúcej štatistiky

$$q_T(t|\gamma) = (2\pi)^{-N/2} \prod_i \gamma_i \exp \{t_i \gamma_i + 1\}$$

- ▶ saddlepoint aproximácia hustoty MLE

$$q_T(\hat{\gamma}|\gamma) = (2\pi)^{-N/2} \prod_i \frac{\gamma_i}{\hat{\gamma}_i} \exp \left\{ 1 - \frac{\gamma_i}{\hat{\gamma}_i} \right\}$$

Referencie

- S. Kullback, R.A. Leibler (1951): On Information and Sufficiency, *Ann. Math. Statist.* 22(1) 79–86.
- S.V. Weijs, N. Van De Giesen (2011): Accounting for Observational Uncertainty in Forecast Verification: An Information-Theoretical View on Forecasts, Observations, and Truth, *Mon. Weather Rev.* 139 2156–2162.
- A. Basu, A. Mandal, N. Martin, L. Pardo (2013): Testing statistical hypotheses based on the density power divergence, *Ann Inst Stat Math* 65 319–348.
- A.L. Kisslinger, W. Stummer (2013): Some Decision Procedures Based on Scaled Bregman Distance Surfaces, in F. Nielsen, F. Barbaresco (Eds.): *GSI 2013, LNCS 8085* 479–486. Springer-Verlag

Referencie

O.E. Barndorff-Nielsen (1978): Information and exponential families in statistical theory. John Wiley & Sons, New York 111–115.

M. Stehlík (2003): Distributions of exact tests in the exponential family, Metrika 57 145–164.

M.S. Bartlett, D.G. Kendall (1946): The statistical analysis of variance-heterogeneity and the logarithmic transformation, Supplement to the Journal of the Royal Statistical Society 8(1) 128–138.

Ďakujeme za pozornosť.