

TESTY HYPOTÉZ O PARAMETRU OBECNÉHO EXPONENCIÁLNÍHO MODELU

Lucie Fajfrová

Klíčová slova: Stochastické procesy, Rényiho vzdálenosti, exponenciální model.

Abstrakt: Příspěvek se věnuje problému testování hypotéz o parametru v rodinách stochastických procesů, které lze popsat hustotou exponenciálního typu vzhledem k nějaké referenční míře. Zaměříme se na testové statistiky odvozené z informačních vzdáleností nazývaných Rényiho. Cílem příspěvku je především ilustrovat problematiku na příkladech známých procesů.

1 Definice a motivace

Klasické výsledky o exponenciálních rodinách pravděpodobnostních rozdělení můžeme nalézt v řadě monografií, jmenujme například [1], [2]. Tyto knihy se věnují standardnímu statistickému parametrickému modelu s nezávislými pozorováními pocházejícími z rozdělení tzv. exponenciálního typu. Poznamenejme, že mezi tato rozdělení patří například normální, lognormální, gamma, beta, Weibullovo či Maxwellovo, z diskretních pak jmenujme Poissonovo, negativně binomické či multinomické. Podle definice: rodina $\{P_\theta : \theta \in \Theta\}$ pravděpodobnostních rozdělení na $\{\mathcal{X}, \mathcal{A}\}$ lišících se v parametru θ z nějaké otevřené $\Theta \subseteq \mathbb{R}^k$ se nazývá *exponenciální rodina*, jestliže existuje σ -konečná míra μ , vůči níž je každá P_θ absolutně spojitá s hustotou $f_\theta = \frac{dP_\theta}{d\mu}$ mající tvar

$$f_{\theta,t}(x) = \exp\{\theta^T T(x) - C(\theta)\} \quad \forall x \in \mathcal{X}.$$

Přirozeným rozšířením takového modelu jsou exponenciální rodiny stochastických procesů majících nezávislé stacionární přírůstky. Stochastický proces $(X_t : t \in \mathbb{R}^+)$ s nezávislými a stacionárními přírůstky, jehož trajektorie jsou zprava spojitě a mají konečné limity zleva (dále jen *càdlàg* trajektorie), nazýváme *Lévyho proces*. Lévyho procesy jsou ze statistického pohledu důkladně studovány v knize [4]. Sami autoři v souvislosti s Lévyho procesy hovoří o *přirozených exponenciálních rodinách procesů*, nazývejme je v dalším tedy také tak.

Definice 1.1 *Bud' $\Theta \subseteq \mathbb{R}^k$ otevřená. Rodina pravděpodobnostních měr na kanonickém filtrovaném prostoru $(\mathcal{X}, \mathcal{A}, (\mathcal{F}_t)_{t \geq 0})$ (tzn. \mathcal{X} je množina càdlàg funkcí $\varphi : \mathbb{R}^+ \rightarrow \mathbb{R}$) se nazývá přirozená exponenciální rodina procesů, jestliže existuje σ -konečná míra μ na $\{\mathcal{X}, \mathcal{A}\}$ taková, že pro každé $\theta \in \Theta$*

$$P_\theta \ll \mu \ll \mathcal{F}_t \quad \forall t \geq 0$$

a hustota $f_\theta = \frac{dP_{\theta,t}}{d\mu_t}$ má při označení $P_{\theta,t} = P_\theta \ll \mathcal{F}_t$, $\mu_t = \mu \ll \mathcal{F}_t$ tvar

$$f_{\theta,t}(X_t) = \exp\{\theta^T T(X_t) - t\kappa(\theta)\} \quad \forall t > 0, \quad (1)$$

kde $\mathbb{X}_t \in \mathfrak{X}_t = \mathfrak{X} \upharpoonright_{\mathcal{F}_t}$ značí trajektorii do času t , na rozdíl od X_t označujícího hodnotu trajektorie přímo v čase t . $T = (T_1, \dots, T_k)$ jsou zobrazení z \mathbb{R} do \mathbb{R} .

Z následujících příkladů uvidíme, že typ exponenciální rodiny procesů určuje především funkce κ z (1). Vzhledem k tomu, že

$$\kappa(\theta) = \frac{1}{t} \ln \mathbb{E}_\theta \exp\{\theta^T T(X_t)\}, \quad (2)$$

kde \mathbb{E}_θ symbolizuje střední hodnotu vzhledem k míře P_θ , budeme tuto funkci κ nazývat *kumulantová funkce*.

Typickým příkladem přirozené exponenciální rodiny je jednak rodina Wienerových procesů s driftem $\theta \in \mathbb{R}$, zastupující procesy se spojitými trajektoriemi, a jednak rodina Poissonových procesů s intenzitou $\lambda > 0$, která zastupuje skokové procesy. První jmenovanou rodinu zkonstruujeme následovně. Uvažujme jako referenční míru μ rozdělení obyčejného Wienerova procesu $(W_t)_{t \geq 0}$ a definujme rodinu $\{P_\theta : \theta \in \mathbb{R}\}$ pomocí hustot (1), kde za kumulantovou funkci uvažujeme $\kappa(\theta) = \frac{\theta^2}{2}$ a $T(X_t) = X_t$. Pomocí Laplaceovy transformace lze ukázat, že potom pro každé $\theta \in \mathbb{R}$ je P_θ rozdělní procesu $X_t = \theta t + W_t, t \geq 0$. Referenční míra je tedy přímo P_0 .

Podobně můžeme postupovat u rodiny Poissonových procesů. Uvažujme nejprve změnu parametru λ , odpovídajícího intenzitě, na parametr $\theta = \ln \lambda$ probíhající všechna reálná čísla. Jako referenční zvolíme rozdělení Poissonova procesu s intenzitou $\lambda = 1$. Opět definujme rodinu $\{P_\theta : \theta \in \mathbb{R}\}$ pomocí hustot (1), kde tentokrát za kumulantovou funkci zvolíme $\kappa(\theta) = e^\theta - 1$, $T(X_t) = X_t$. Lze ukázat, že potom pro každé $\theta \in \mathbb{R}$ je P_θ rozdělní Poissonova procesu s intenzitou $\lambda = e^\theta$.

Majíce data pocházející z přirozené exponenciální rodiny procesů do nějakého času $t > 0$, můžeme testovat hypotézy o parametru θ . Klasickým nástrojem je maximálně věrohodný odhad parametru θ odvozený v [4]. Citujme zde stručně tento důležitý výsledek:

Mějme přirozenou exponenciální rodinu dle definice 1.1. Je-li $\text{dom } \kappa \subseteq \mathbb{R}$ otevřená, pak maximálně věrohodný odhad (MLE) $\hat{\theta}_t$ parametru θ založený na pozorování do času t existuje a je dán předpisem $\hat{\theta}_t = \kappa^{-1}\left(\frac{T(X_t)}{t}\right)$ právě tehdy, když $\frac{T(X_t)}{t} \in \text{int}(\text{co}(\text{supp } T(X_t)))$. Zde κ^{-1} značí inverzi k derivaci kumulantové funkce. Navíc pak při P_θ

$$\hat{\theta} \xrightarrow{t \rightarrow \infty} \theta \quad \text{s.j.} \quad \& \quad \sqrt{t}(\hat{\theta} - \theta) \xrightarrow{t \rightarrow \infty} N(0, (\ddot{\kappa}(\theta))^{-1}) \quad \text{v distribuci} \quad (3)$$

a testová statistika podílem věrohodností $Q_t = \frac{L_t(\theta_0)}{\sup_{\theta \in \Theta} L_t(\theta)}$ pro test jednoduché hypotézy $H : \theta = \theta_0$ má následující asymptotické rozdělení při P_{θ_0}

$$-2 \ln Q_t \xrightarrow{t \rightarrow \infty} \chi_k^2 \quad \text{v distribuci,} \quad (4)$$

kde χ_k^2 značí náhodnou veličinu s χ^2 rozdělením s k stupni volnosti a $L_t(\theta) = \exp\{\theta^T T(X_t) - t\kappa(\theta)\}$ je věrohodnostní funkce.

Pro statistiku zobecněným podílem věrohodností $Q_t^* = \frac{L_t(\theta_t^*)}{\sup_{\theta \in \Theta} L_t(\theta)}$ pro test složené hypotézy $H : h(\theta) = 0$ platí $-2 \ln Q_t^* \xrightarrow{t \rightarrow \infty} \chi_{k-m}^2$ v distribuci, při P_θ , pro všechna $\theta : h(\theta) = 0$. Zde θ_t^* je zúžený maximálně věrohodný odhad, maximalizující $L_t(\theta)$ přes množinu $\{\theta : h(\theta) = 0\}$ a funkce $h : \mathbb{R}^k \rightarrow \mathbb{R}^m$, pro nějaké $1 \leq m < k$, je dvakrát diferencovatelná a h má plnou hodnotu.

Obecnější přístup k problému testování hypotéz zvolili autoři článků [5], [6]. K testování použili statistiky odvozené z různých informačních vzdáleností. Jako nejzajímavější se ukázaly tzv. Rényiho vzdálenosti. Pro rodinu $\{P_\theta : \theta \in \Theta\}$ pravděpodobnostních rozdělení procesů s dominující mírou μ a pro konstantu $a \in \mathbb{R} \setminus \{0, 1\}$ je Rényiho vzdálenost $D_{a,t}$ mezi rozděleními $P_{\theta_1,t}$ a $P_{\theta_0,t}$ do času t daná vztahem

$$D_{a,t}(\theta_1, \theta_0) = \frac{1}{a(a-1)} \ln \int_{\mathfrak{X}_t} \left(\frac{dP_{\theta_1,t}}{d\mu_t} \right)^a \left(\frac{dP_{\theta_0,t}}{d\mu_t} \right)^{1-a} d\mu. \quad (5)$$

Rényiho vzdálenost pro $a = 1$ je speciální případ nazývaný Kullbackova vzdálenost:

$$K_t(\theta_1, \theta_0) = D_{1,t}(\theta_1, \theta_0) = \int_{\mathfrak{X}_t} \frac{dP_{\theta_1,t}}{d\mu_t} \ln \frac{dP_{\theta_1,t}/d\mu_t}{dP_{\theta_0,t}/d\mu_t} d\mu$$

a pro $a = 0$ jde o inverzní Kullbackovu vzdálenost $D_{0,t}(\theta_1, \theta_0) = K_t(\theta_0, \theta_1)$.

Článek [6] se věnuje užití Rényiho vzdáleností pro statistiku právě přirozených exponenciálních rodin procesů, viz definice 1.1. Ukázalo se totiž, že Rényiho vzdálenosti D_a mají v těchto modelech jednoduchý tvar, platí

$$\begin{aligned} D_{1,t}(\theta_1, \theta_0) &= t \left(\kappa(\theta_1) (\theta_1 - \theta_0) + \kappa(\theta_0) - \kappa(\theta_1) \right) \\ D_{a,t}(\theta_1, \theta_0) &= \frac{t}{a(a-1)} \left(\kappa(\theta_a) - a\kappa(\theta_1) - (1-a)\kappa(\theta_0) \right), \end{aligned}$$

kde $\theta_a = a\theta_1 + (1-a)\theta_0$. Vztahy snadno ověříme dosazením (1) do předpisů pro $D_{a,t}$. Pro testování jednoduché hypotézy $H : \theta = \theta_0$ lze užít testovou statistiku $2D_{a,t}(\hat{\theta}_t, \theta_0)$ odvozenou z Rényiho vzdálenosti mezi rozděleními s hypotetickým parametrem θ_0 a maximálně věrohodným odhadem $\hat{\theta}_t$ parametru z pozorování do času t . Věta 2 v [6] pak říká, že v přirozených exponenciálních modelech má pro každé $a \in \mathbb{R}$ tato testová statistika asymptoticky χ^2 rozdělení s k stupni volnosti, tedy při P_{θ_0}

$$2D_{a,t}(\hat{\theta}_t, \theta_0) \xrightarrow{t \rightarrow \infty} \chi_k^2 \quad \text{v distribuci.} \quad (6)$$

Poznamenejme, že testová statistika $2D_{1,t}(\hat{\theta}_t, \theta_0)$ odvozená od Kullbackovy vzdálenosti odpovídá statistice $-2 \ln Q_t$ odvozené z podílu věrohodností, viz (4). Zmíňme také, že výsledek (6) lze opět zobecnit - užitím zúženého maximálně věrohodného odhadu - také pro složenou hypotézu $H : h(\theta) = 0$. Pak

$$T_{a,t} = 2D_{a,t}(\hat{\theta}_t, \theta_t^*) \xrightarrow{t \rightarrow \infty} \chi_{k-m}^2 \quad \text{v distribuci, při } P_\theta, \forall \theta : h(\theta) = 0, \quad (7)$$

kde h a θ_t^* jsou jak v předchozím. Lze nalézt v [7].

Význam použití Rényiho statistik je mimo jiné v tom, že můžeme na základě nějaké optimalizace vycházející z výpočtu přesné síly a hladiny testů pro jednotlivé řady a vybrat statistiku pro daný model nejvhodnější.

Účelem tohoto příspěvku je jednak přiblížit použití Rényiho statistik na konkrétním příkladě přirozené exponenciální rodiny procesů (sekce 2) a jednak pokusit se rozšířit tuto metodu testování na širší třídu exponenciálních rodin procesů, zahrnující mnohem více než jen Lévyho procesy (sekce 3).

2 Přirozené exponenciální modely

V této části se soustředíme na konkrétní příklad přirozené exponenciální rodiny. Uvažujme dvourozměrný náhodný proces (X_t, Y_t) se spojitým časem, kde $X_t = \exp(\zeta t + W_t)$ je geometrický Brownův pohyb a Y_t na něm nezávislý Poissonův proces s intenzitou $\lambda = e^\eta$. Jak vypadá hustota rodiny Poissonových procesů jsme již zmínili dříve a tvar hustoty rodiny geometrického Brownova pohybu vyplývá z faktu, že proces X_t je Itôův difúzní proces, konkrétně řešení rovnice $dX_t = (\zeta + \frac{1}{2})X_t dt + X_t dW_t$, $X_0 = 1$, a pro takové je tvar hustoty znám, viz [3]. Tedy

$$f_{(\zeta, \eta), t} = \exp\left(\zeta \ln(X_t) + \eta Y_t - t\left(\frac{\zeta^2}{2} + e^\eta - 1\right)\right)$$

je hustota rozdělení procesu (X_t^ζ, Y_t^η) vzhledem k referenční míře $P_{0,t} \times Q_{0,t}$, což je rozdělení procesu (X_t^0, Y_t^0) . Testovat bychom chtěli hypotézu, že drift ζ je roven intenzitě λ , tj. $H : \zeta - e^\eta = 0$.

Ze zmíněných výsledků pro přirozené rodiny vyplývá, že odhad metodou maximální věrohodnosti má být ve tvaru

$$(\hat{\zeta}, \hat{\eta}) = \left(\frac{\ln(X_t)}{t}, \ln\left(\frac{Y_t}{t}\right)\right).$$

Jde ovšem pouze o tzv. asymptoticky maximálně věrohodný odhad, neboť podle klasické teorie o exponenciálních rodinách MLE parametru v Poissonově procesu neexistuje z důvodu, že $Q_{\eta,t}(Y_t = 0) > 0$. Nicméně tato pravděpodobnost jde do 0, když $t \rightarrow \infty$.

Rényiho statistika řádu a má tvar

$$T_{a,t} = t(e^{\eta_t^*} - \hat{\zeta}_t)^2 + \frac{2t}{a(a-1)} \left[\exp(\eta_t^* + a(\hat{\eta}_t - \eta_t^*)) - ae^{\hat{\eta}_t} - (1-a)e^{\eta_t^*} \right]$$

pro $a \neq 1, 0$, kde $\eta_t^* = \operatorname{argmax}\{\zeta \ln(X_t) + \eta Y_t - t(\frac{\zeta^2}{2} + e^\eta - 1) : \zeta = e^\eta\}$, a

$$T_{1,t} = t(e^{\eta_t^*} - \hat{\zeta}_t)^2 + 2t[e^{\hat{\eta}_t}(\hat{\eta}_t - \eta_t^* - 1) + e^{\eta_t^*}].$$

Z výsledků článku [7] shrnutých v (7) plyne, že asymptotické rozdělení těchto statistik je χ_1^2 .

Majíce data do nějakého času t z této rodiny, uvažujme test hypotézy H s asymptotickou hladinou α_0 . Pro rozhodnutí o platnosti hypotézy pak použijeme tu testovou statistiku $T_{a,t}$, pro níž srovnání přesných hladin testu $\alpha = \alpha(\alpha_0, \theta_0, a) = P_{\theta_0,t}(T_{a,t} > \chi_1^2(1 - \alpha_0))$ a přesných sil testu $\beta = \beta(\alpha_0, \theta_1, a) =$

$P_{\theta_{1,t}}(T_{a,t} > \chi_1^2(1-\alpha_0))$ vyjde lépe v následujícím smyslu. Nejprve zvolíme konečnou množinu A všech řadů, pro něž chci toto srovnání provést. Vhodným způsobem také zvolíme konečnou množinu parametrů θ_0 zastupujících hypotézu a množinu parametrů θ_1 zastupujících alternativu. Pokud nelze přímo vypočítat α a β pro tyto hodnoty, lze použít simulaci. V tomto případě bylo použito 5 hodnot parametru z hypotézy, v okolí každé 8 hodnot z alternativy, a pro každé $\theta = (\zeta, \eta)$ z této množiny bylo nasimulováno 10^4 realizací n.v. $Z_{50} \sim N(0, 50)$ a n.v. $Y_{50} \sim Po(50e^\eta)$, z nichž se určila hladina α , respektive síla β , pro $t = 50$. Metodou 'relative inefficiency', která je popsána v [5], vyšla porovnáním těchto hodnot jako nejlepší Rényiho statistika řádu $a = 0.5$.

3 Zakřivené exponenciální modely

Definice 3.1 *Bud' $\Theta \subseteq \mathbb{R}^k$ otevřená. Rodina pravděpodobnostích měr na kanonickém filtrovaném prostoru $(\mathcal{X}, \mathcal{A}, (\mathcal{F}_t)_{t \geq 0})$ se nazývá obecná exponenciální rodina procesů, jestliže hustota $f_\theta = \frac{dP_{\theta,t}}{dP_{0,t}}$ má (při stejném značení jako v definici 1.1) tvar:*

$$f_{\theta,t} = \exp\{\theta^T A_t - \kappa(\theta)S_t\} \quad \forall t > 0, \quad (8)$$

kde $\kappa : \Theta \rightarrow \mathbb{R}$ je nějaká funkce pouze parametru, $A_t = (A_t^{(1)}, \dots, A_t^{(k)})$ jsou \mathcal{F}_t -adaptované stochastické procesy s càdlàg trajektoriemi a S_t je neklesající stochastický proces takový, že $S_0 = 0$ a $\lim_{t \rightarrow \infty} S_t = +\infty$ s.j. $(P_\theta) \forall \theta \in \Theta$.

Rodiny procesů z definice 3.1 jsou speciálním případem tzv. *zakřivených exponenciálních rodin*. Je-li však S_t nenáhodné, dostáváme se zpět k přirozeným rodinám procesů. Proto budeme-li chtít zdůraznit, že jde o rodinu takto nedegenerovanou, tedy že S_t je náhodné, budeme hovořit o rodině *zakřivené*.

Ač na první pohled by se mohl zdát rozdíl mezi definicemi 1.1 a 3.1 malý, o opaku svědčí jednak množství procesů, které nám druhou definicí přibyly, a jednak řada nových problémů, které je nyní potřeba řešit.

Mezi obecné exponenciální rodiny procesů patří například všechny Itôovy difusní procesy, jestliže příslušná stochastická diferenciální rovnice

$$dX_t^\theta = a_t(X_t^\theta)dt + \theta b_t(X_t^\theta)dt + c_t(X_t^\theta)dW_t$$

má pro danou počáteční podmínku jediné (silné) řešení $(X_t^\theta : t \geq 0)$ pro každé $\theta \in \Theta$. Odvození přesného tvaru exponenciální hustoty pro Itôovy difusní procesy může čtenář nalézt v [3].

Příklad 3.2 *Ornstein-Uhlenbeckův proces je řešením rovnice*

$$dX_t = \theta X_t dt + dW_t.$$

Uvažujme-li počáteční podmínku $X_0 = 0$, potom explicitní vyjádření procesu je $X_t = \int_0^t e^{\theta(t-s)} dW_s$. Jde o exponenciální rodinu danou souborem hustot:

$$\frac{dP_{\theta,t}}{dP_{0,t}} = \exp\left\{\frac{\theta}{2}(X_t^2 - t) - \frac{\theta^2}{2} \int_0^t X_s^2 ds\right\}$$

pro každé $t > 0$, kde P_0 je rozdělení Wienerova procesu.

Další velikou skupinou procesů, které jsou pokryty definicí 3.1, jsou čítací (skokové) procesy. Tím míníme zprava spojitý proces N_t , který nabývá celých čísel a jehož na čase závislá intenzita λ_t má tvar $\lambda_t = \lambda H_t$, kde H_t je do času t adaptovaný pozitivní proces s konečnou střední hodnotou pro každé $t > 0$. Intenzitou myslíme intenzitu ve smyslu Markovského procesu se stavy v \mathbb{Z} , který se v jednom kroku může změnit pouze o jedničku. Označíme-li $\theta = \ln \lambda$, rodina procesů N_t je zadaná hustotou

$$\frac{dP_{\theta,t}}{dP_{0,t}} = \exp\{\theta(N_t - N_0) - (e^\theta - 1) \int_0^t H_s ds\},$$

kde P_0 je rozdělení daného čítacího procesu s parametrem 0, tj. s intenzitou $\lambda = 1$. Speciálním degenerovaným případem je jistě Poissonův proces s $H_t \equiv 1$. Dalším speciálním případem, tentokrát již zakřivené exponenciální rodiny, je *jednoduchý proces zrodu*, kde $H_t = N_{t-}$. Budeme se tímto procesem zabývat detailně později.

Vraťme se nyní k tomu, o které vlastnosti z přirozených exponenciálních rodin jsme přišli a které nám zůstaly zachovány. Uvědomme si nejprve, že mnoho vlastností v přirozených rodinách plynulo z faktu, že kumulantovou funkci bylo možné vyjádřit vztahem (2), což v zakřivených rodinách možné není. Jedním ze způsobů, jak s těmito rodinami dále pracovat, je nahlédnout, že vhodnou náhodnou časovou transformací lze obecnou exponenciální rodinu převést na přirozenou. Jen stručně uvedme, že jde o transformaci definovanou časem zastavení $\tau_u = \inf\{t : S_t > u\}$ a pokud definujeme filtraci $(\mathcal{F}_{\tau_u})_{u \geq 0}$ σ -algebr do času zastavení τ_u , pak lze ukázat, že

$$\frac{dP_{\theta,\tau_u}}{dP_{0,\tau_u}} = \exp\{\theta^\top A_{\tau_u} - \kappa(\theta)u\},$$

kde $P_{\theta,\tau_u} = P_\theta \upharpoonright_{\mathcal{F}_{\tau_u}}$. Pro více detailů odkážme čtenáře do [4], kde je také jako důsledek této transformace odvozen následující výsledek pro maximálně věrohodný odhad parametru θ v obecném exponenciálním modelu. Cítujeme:

Věta 3.3 (Theorem 5.2.1-2 v [4]) *Bud' κ v (8) taková, že dom κ je otevřená podmnožina \mathbb{R}^k , a nechť $S_t > 0 \forall t > 0$ P_θ -s.j. $\forall \theta \in \Theta$, kde Θ je otevřená. Pak*

- MLE $\hat{\theta}_t$ založený na pozorování do času t existuje a je dán jednoznačně vztahem $\hat{\theta}_t = \kappa^{-1}\left(\frac{A_t}{S_t}\right)$ právě tehdy, když $\frac{A_t}{S_t} \in \text{int}(\text{co}(\text{supp } A_{\tau_1}))$,
- $\hat{\theta} \xrightarrow{t \rightarrow \infty} \theta$ s.j. (P_θ) pro všechny $\theta \in \Theta$,
- jestli existuje pro každé $\theta \in \Theta$ rostoucí, kladná nenáhodná funkce $\varphi_\theta(t)$, že

$$\frac{S_t}{\varphi_\theta(t)} \xrightarrow{t \rightarrow \infty} Y_\theta \quad \text{v pravděpodobnosti, při } P_\theta,$$

a že $P_\theta(Y_\theta > 0) > 0$, kde Y_θ je nějaká n.v. s rozdělením F_θ , potom při P_θ

$$\left(\sqrt{S_t}(\hat{\theta} - \theta), \frac{S_t}{\varphi_\theta(t)}\right) \xrightarrow{t \rightarrow \infty} N(0, (\kappa(\theta))^{-1}) \times F_\theta \quad \& \quad -2 \ln Q_t \xrightarrow{t \rightarrow \infty} \chi_k^2$$

v distribuci, za podmínky $\{Y_\theta > 0\}$, kde Q_t je jako v (4).

Nějaký analogický výsledek v obecných exponenciálních modelech výsledkům (6) a (7) v přirozených modelech pro testování pomocí Rényiho statistik

zatím k dispozici není. Problém je v nalezení vhodného tvaru Rényiho vzdáleností (5), které pro obecný exponenciální model (8) mají mít tvar:

$$D_{1,t}(\theta_1, \theta_0) = \int_{\mathfrak{X}_t} \left(A_t(\theta_1 - \theta_0) - S_t(\kappa(\theta_1) - \kappa(\theta_0)) \right) dP_{\theta_1,t} \quad (9)$$

$$\text{a pro } a \neq 1, 0: D_{a,t}(\theta_1, \theta_0) = \quad (10)$$

$$\frac{1}{a(a-1)} \ln \int_{\mathfrak{X}_t} \exp \left\{ A_t \left(a\theta_1 + (1-a)\theta_0 \right) - S_t \left(a\kappa(\theta_1) + (1-a)\kappa(\theta_0) \right) \right\} dP_{0,t}.$$

Věnujme se ve zbytku tomuto problému v konkrétním příkladě zakřivené exponenciální rodiny, a to rodiny jednoduchých procesů zrodu.

Příklad 3.4 *Bud' $(X_t)_{t \geq 0}$ jednoduchý proces zrodu a necht' $X_0 = 1$. To znamená, že $X_t \in \{1, 2, \dots\}$ značí velikost populace v čase t , jestliže v čase 0 populace čítala jediného jedince, který má dát po exponenciálním čase se střední hodnotou $1/\lambda$ život novému jedinci. Přičemž každý jedinec této populace se bude chovat stejně a jejich chování bude navzájem nezávislé. Při parametrizaci $\theta = \ln \lambda \in \mathbb{R}$ je rodina jednoduchých procesů zrodu zakřivenou exponenciální rodinou s hustotami do času t :*

$$f_{\theta,t} = \exp \left\{ \theta(X_t - 1) - (e^\theta - 1) \int_0^t X_s ds \right\}$$

vzhledem k referenční míře $P_{0,t}$, rozdělení procesu zrodu s intenzitou $\lambda = 1$.

Odvoďme tvar Rényiho vzdáleností speciálně pro proces zrodu. Zafixujme $t > 0$. Začneme se snadnější Kullbackovou vzdáleností, která (dle (9)) má tvar $D_{1,t}(\theta, \theta_0) = (\mathbb{E}_\theta X_t - 1)(\theta - \theta_0) - \mathbb{E}_\theta \int_0^t X_s ds (e^\theta - e^{\theta_0})$. Vidíme, že stačí znát $\mathbb{E}_\theta X_t \forall t > 0$, tedy střední počet jedinců v čase t v populaci s intenzitou zrodu $\lambda = e^\theta$. Lze odvodit, že $\mathbb{E}_\theta X_t = \exp\{te^\theta\}$ a tedy

$$D_{1,t}(\theta, \theta_0) = (\exp\{te^\theta\} - 1)(e^{\theta_0 - \theta} + \theta - \theta_0 - 1). \quad (11)$$

Rényiho vzdálenost pro $a \neq 1, 0$ má podle (10) mít tvar $D_{a,t}(\theta, \theta_0) =$

$$\frac{1}{a(a-1)} \ln \mathbb{E}_{a\theta + (1-a)\theta_0} \exp \left\{ - \int_0^t X_s ds \left(ae^\theta + (1-a)e^{\theta_0} - e^{a\theta + (1-a)\theta_0} \right) \right\}.$$

Označíme-li si

$$\nu = \nu(a, \theta, \theta_0) = ae^\theta + (1-a)e^{\theta_0} - e^{a\theta + (1-a)\theta_0},$$

potom potřebujeme znát $\mathbb{E}_{\theta_a} \exp \left\{ -\nu \int_0^t X_s ds \right\}$, kde $\theta_a = a\theta + (1-a)\theta_0$. Lze odvodit, že tato střední hodnota je konečná pro všechna $t > 0$ právě tehdy, když $\nu \geq 0$, a potom

$$\mathbb{E}_{\theta_a} \exp \left\{ -\nu \int_0^t X_s ds \right\} = \frac{e^{\theta_a} + \nu}{e^{\theta_a} + \nu \exp\{t(e^{\theta_a} + \nu)\}}.$$

Vzhledem k tomu, že $\nu \geq 0$ právě tehdy, když $a \in [0, 1]$, má dále smysl zabývat se pouze Rényiho vzdálenostmi pro $a \in [0, 1]$. Pro $a \in (0, 1)$ pak:

$$D_{a,t}(\theta, \theta_0) = \frac{1}{a(1-a)} \ln \left(1 + \nu(a, \theta, \theta_0) \frac{\exp\{t(ae^\theta + (1-a)e^{\theta_0})\} - 1}{ae^\theta + (1-a)e^{\theta_0}} \right). \quad (12)$$

Lemma 3.5 Rényiho statistiky $T_{a,t} = 2D_{a,t}(\hat{\theta}_t, \theta_0)$ odvozené z (11) a (12) mají pro každé $a \in [0, 1]$ Fisher-Snedecorovo $F(1, 2)$ rozdělení, tj. vzhledem k rozdělení P_{θ_0} procesu zrodu

$$T_{a,t} \xrightarrow{t \rightarrow \infty} F(1, 2) \quad \text{v distribuci.}$$

Důkaz. Metodou Taylorova rozvoje pro funkci $f(\theta) := D_{a,t}(\theta, \theta_0)$ v bodě θ_0 zjistíme, že $D_{a,t}(\theta, \theta_0) = \frac{1}{2}\psi_{a,t}(\theta)(\theta - \theta_0)^2$, kde $\psi_{a,t}(\cdot)$ jsou spojitě funkce takové, že $\psi_{a,t}(\theta_0) = \exp\{te^{\theta_0}\} - 1$ pro každé $a \in [0, 1], t > 0$. A vzhledem k tomu, že proces $S_t = \int_0^t X_s ds$, kde X_s je proces zrodu s intenzitou $\lambda = e^\theta$, se při $t \rightarrow \infty$ chová následovně (lze zjistit z Laplaceovy transformace):

$$\lambda e^{-t\lambda} S_t = e^\theta \exp\{-te^\theta\} S_t \xrightarrow{t \rightarrow \infty} \chi_2^2 \quad \text{s.j.}(P_\theta),$$

použitím věty 3.3 obdržíme: $2D_{a,t}(\hat{\theta}_t, \theta_0) \xrightarrow{t \rightarrow \infty} F(1, 2)$ v distribuci při P_{θ_0} . \square

Závěrem tedy můžeme říct, že Rényiho statistiky, pokud je umíme spočítat, půjdou alespoň pro hodnoty řádu a z intervalu $[0, 1]$ použít i v zakřivených exponenciálních modelech pro testy hypotéz, s toutéž výhodou jako v přirozených exponenciálních modelech.

Reference

- [1] Barndorff-Nielsen O.E. (1978) *Information and Exponential Families*. J.Wiley, Gluchester.
- [2] Brown L.D. (1986) *Fundamentals of Statistical Exponential Families of Stochastic Processes*. Lectures Notes Vol.9. Inst. of Math. Statistics, Hayward, California.
- [3] Liptser R.Sh., Shiryaev A.N. (1989) *Statistika slučajnych procesov*. Springer, New York.
- [4] Küchler U., Sørensen M. (1997) *Exponential Families of Stochastic Processes*. Springer, Berlin.
- [5] Morales D., Pardo L., Vajda I. (1997) *Some new statistics for testing hypothesis in parametric models*. Journal of Multivariate Analysis, **62**, 137–168.
- [6] Morales D., Pardo L., Vajda I. (1999) *Rényi stistics in directed families of exponential experiments*. Statistics, **34**, 151–174.
- [7] Morales D., Pardo L., Pardo M.C., Vajda I. (2004) *Rényi stistics for testing composite hypothesis in general exponential models*. Statistics, **38**, No.2, 133–147.

Poděkování: Tato práce byla podporována grantem GA ČR 201/06/1323 a výzkumným centrem MŠMT ČR 1M0572.

Adresa: ÚTIA AV ČR, Pod vodárenskou věží 4, 18208 Praha 8

E-mail: fajfrova@utia.cas.cz