

ODHADY S MINIMÁLNÍ VZDÁLENOSTÍ PRO GAUSSOVSKÉ PROCESY

Jiří MICHÁLEK¹

ÚTIA ČAV

Abstract. The paper presents a close connection between maximum likelihood estimates and minimum I-divergence estimates of unknown parameters in Gaussian families and studies the asymptotic behaviour of the likelihood ratio maximum.

Резюме: Автор показывает интересное соотношение между оценками максимального правдоподобия и оценками с минимальной I-дивергенцией для гауссовских последовательностей и процессов.

1. ÚVOD

Problém, kterým se budeme v práci zabývat, přiblížíme na následujícím příkladu. Necht' X_1, X_2, \dots, X_n je prostý náhodný výběr z $N(\mu, \sigma^2)$, kde parametr $\theta = (\mu, \sigma^2) \in \Theta = R_1 \times R_1^+$ je neznámý. Lze snadno ukázat, že

$$(1) \quad \max_{\theta \in \Theta} \ln \frac{f(x_1, \dots, x_n, \theta)}{f(x_1, \dots, x_n, \theta_0)} = \frac{n}{2} \left(\frac{\bar{x} - \mu_0}{\sigma_0} \right)^2 + \frac{n}{2} \left(\frac{s^2}{\sigma_0^2} - \ln \frac{s^2}{\sigma_0^2} - 1 \right),$$

kde $f(x_1, \dots, x_n, \theta) = \prod_{i=1}^n g(x_i, \mu, \sigma^2)$, $g(\cdot, \mu, \sigma^2) \sim N(\mu, \sigma^2)$ a $\theta_0 = (\mu_0, \sigma_0^2)$. Tento výraz napravo v rovnosti (1) lze ale vyjádřit daleko zajímavějším způsobem, a to jako

$$\max_{\theta \in \Theta} \ln \frac{f(x_1, \dots, x_n, \theta)}{f(x_1, \dots, x_n, \theta_0)} = \frac{n}{2} I(N(\bar{x}, s^2) : N(\mu_0, \sigma_0^2)),$$

kde $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ a $I(P : Q)$ je Kullback–Leiblerova I-divergence mezi dvěma pravděpodobnostními mírami P, Q daná vztahem

$$I(P : Q) = \int_{\mathcal{X}} f_P(x) \ln \frac{f_P(x)}{f_Q(x)} d\nu(x),$$

$f_P = \frac{dP}{d\nu}$, $f_Q = \frac{dQ}{d\nu}$ a ν je libovolná σ -konečná dominující míra vůči dvojici (P, Q) . Tím se ihned naskytá otázka, zdali tento vztah mezi maximem věrohodnostního poměru a I-divergencí platí obecně či za jakých podmínek, a co z toho vztahu vyplývá.

2. EXPONENCIÁLNÍ RODINA

Hustota exponenciální rodiny $f(x, \theta)$, $\theta \in \Theta$ (parametrický prostor) vůči dominantní míře $\mu(\cdot)$ má obecný tvar

$$f(x, \theta) = c(\theta) h(x) e^{\tau(\theta)T(x)},$$

¹Tato práce je podporována grantem GA ČR 201/96/0415.

kde θ nechť je pro jednoduchost jednorozměrný parametr. Maximálně věrohodný odhad (dále jen MLE) $\hat{\theta}_n$ počítaný na základě pozorování (x_1, x_2, \dots, x_n) musí (za předpokladů existence patričních derivací) splňovat vztah

$$\frac{1}{n} \sum_{j=1}^n T(x_j) = \frac{-1}{C(\hat{\theta}_n)} C'(\hat{\theta}_n) \frac{1}{\tau'(\hat{\theta}_n)}.$$

Odhad $\hat{\theta}_n$ existuje právě tehdy, když

$$\frac{1}{n} \sum_{j=1}^n T(x_j) \in \text{Range}_{\theta \in \Theta} \{\pi(\theta)\},$$

kde

$$\pi(\theta) = -[\ln C(\theta)]' \frac{1}{\tau'(\theta)} \quad \text{při} \quad \tau'(\theta) \neq 0 \text{ na } \Theta.$$

Protože platí silný zákon velkých čísel, pak lze snadno vidět, že

$$\lim_{n \rightarrow \infty} P \left\{ \frac{1}{n} \sum_{j=1}^n T(x_j) \in \text{Range}_{\theta \in \Theta} \{\pi(\theta)\} \right\} = 1.$$

Důležité ale je, že lze psát

$$\frac{1}{n} \sum_{j=1}^n \ln f(x_j, \theta) = -I(\hat{\theta}_n : \theta) + H(\hat{\theta}_n),$$

kde $H(\theta) = E_{\theta} \{\ln f(x, \theta)\}$ (pokud ovšem existuje). Z tohoto ale ihned plyne, že

$$\max_{\theta \in \Theta} \left\{ \frac{1}{n} \sum_{j=1}^n \ln f(x_j, \theta) \right\} = -\min_{\theta \in \Theta} \{I(\hat{\theta}_n : \theta)\} + H(\hat{\theta}_n) = H(\hat{\theta}_n),$$

a tedy lze tvrdit, že MLE $\hat{\theta}_n$ je též odhadem s minimální I -divergencí. Protože $\{\hat{\theta}_n\}$ je superkonsistentní, tj. $\hat{\theta}_n \rightarrow \theta_*$ s.j., pak

$$\max_{\theta \in \Theta} \frac{1}{n} \sum_{j=1}^n \ln f(x_j, \theta) \xrightarrow{n \rightarrow \infty} H(\theta_*) \quad \text{s.j.}$$

Zcela obdobně lze ukázat, že

$$\max_{\theta \in \Theta} \frac{1}{n} \sum_{j=1}^n \ln \frac{f(x_j, \theta)}{f(x_j, \theta_0)} = I(\hat{\theta}_n : \theta),$$

z čehož vyplývá, že

$$\lim_{n \rightarrow \infty} \max_{\theta \in \Theta} \frac{1}{n} \sum_{j=1}^n \ln \frac{f(x_j, \theta)}{f(x_j, \theta_0)} = I(\theta_* : \theta) \quad \text{s.j.},$$

kde θ_* je skutečná hodnota parametru θ .

3. ZÁVISLÁ POZOROVÁNÍ – DISKRÉTNÍ ČAS

Zatím jsme uvažovali pouze nezávislá pozorování. Nyní se budeme zabývat závislým pozorováním, a to případem autoregrese s gaussovskými pozorováními. Máme tedy model

$$x_{i+1} + \sum_{k=1}^p a_k x_{i-k+1} = \sigma_0 e_{i+1}, \quad e_{i+1} \sim N(0, 1).$$

Označme $\mathbf{a} = (1, a_1, a_2, \dots, a_p)^T$, $\mathbf{b} = (1, b_1, b_2, \dots, b_p)^T$, $\sigma_0^2 > 0$, $\sigma_1^2 > 0$. Lze snadno spočítat, že

$$(2) \quad \max_{(\mathbf{b}, \sigma_1^2)} \ln \frac{f(x_1, \dots, x_n, \mathbf{b}, \sigma_1^2)}{f(x_1, \dots, x_n, \mathbf{a}, \sigma_0^2)} = \frac{n}{2} \left(\frac{\mathbf{a}^T \widehat{\mathbf{R}} \mathbf{a}}{\sigma_0^2} - \ln \frac{(\widehat{\sigma}_1)^2}{\sigma_0^2} - 1 \right),$$

kde $f(x_1, \dots, x_n, \mathbf{b}, \sigma_1^2)$ je sdružená hustota veličin x_1, x_2, \dots, x_n při parametrech (\mathbf{b}, σ_1^2) , dále $\widehat{\sigma}_1^2 = \widehat{\mathbf{b}}^T \widehat{\mathbf{R}} \widehat{\mathbf{b}}$, kde

$$\widehat{\mathbf{R}} = \left\{ \widehat{R}_{ij} \right\}_{i,j=0}^p, \quad \widehat{R}_{ij} = \frac{1}{n} \sum_{k=1}^n x_{k-i} x_{k-j}$$

a $\widehat{\mathbf{b}}$ je MLE pro parametr $\mathbf{b} = (1, b_1, b_2, \dots, b_p)^T$. Ihned nás napadne, co je výraz na pravé straně rovnosti (2)? Kdybychom namísto matice $\widehat{\mathbf{R}}$ použili Toeplitzovy matice

$$\widehat{\mathbf{T}} = \left\{ \widehat{T}_{ij} \right\}_{i,j=0}^p, \quad \widehat{T}_{ij} = \frac{1}{n} \sum_{k=1}^n x_k x_{k+|i-j|},$$

pak výraz

$$\frac{\mathbf{a}^T \widehat{\mathbf{T}} \mathbf{a}}{\sigma_0^2} - \ln \frac{(\widehat{s}_1)^2}{\sigma_0^2} - 1, \quad \text{kde } (\widehat{s}_1)^2 = \widetilde{\mathbf{b}}^T \widehat{\mathbf{T}} \widetilde{\mathbf{b}}$$

a $\widetilde{\mathbf{b}} = (1, \widetilde{b}_1, \widetilde{b}_2, \dots, \widetilde{b}_p)^T$ jsou známé Yule–Walkerovy odhady autoregresních koeficientů, by nebyl nic jiného nežli

$$\frac{n}{2} \overline{T} \left((\widetilde{\mathbf{b}}, (\widehat{s}_1)^2) : (\mathbf{a}, \sigma_0^2) \right),$$

kde

$$\overline{T} \left((\mathbf{b}, \sigma_1^2) : (\mathbf{a}, \sigma_0^2) \right) = \frac{1}{4\pi} \int_{-\pi}^{\pi} \left(\frac{\varphi(\mathbf{b}, \sigma_1^2)(\lambda)}{\varphi(\mathbf{a}, \sigma_0^2)(\lambda)} - \ln \frac{\varphi(\mathbf{b}, \sigma_1^2)(\lambda)}{\varphi(\mathbf{a}, \sigma_0^2)(\lambda)} - 1 \right) d\lambda,$$

kde $\varphi(\mathbf{b}, \sigma_1^2)$ a $\varphi(\mathbf{a}, \sigma_0^2)$ jsou příslušné spektrální hustoty, pokud náš autoregresní model bude stacionární. Tento výraz je tzv. asymptotická rychlost I -divergence mezi dvěma stacionárními autoregresními gaussovskými mírami (blíže viz [1]). Odtud snadno plyne následující

Věta 1. Za předpokladu stacionarity v gaussovském autoregresním modelu platí

$$\lim_{n \rightarrow \infty} \frac{1}{n} \max_{(\mathbf{b}, \sigma_1^2)} \ln \frac{f(x_1, \dots, x_n, \mathbf{b}, \sigma_1^2)}{f(x_1, \dots, x_n, \mathbf{a}, \sigma_0^2)} = \frac{1}{2} \bar{I}((\mathbf{b}_*, \sigma_*^2) : (\mathbf{a}, \sigma_0^2)), \quad \text{s.j.},$$

kde $(\mathbf{b}_*, \sigma_*^2)$ jsou skutečné hodnoty parametrů.

Důkaz. Je notoricky známo, že maximálně věrohodné odhady parametrů (\mathbf{b}, σ_1^2) jsou superkonsistentní, tj.

$$(\mathbf{b}_n, \hat{\sigma}_1^2) \xrightarrow[n \rightarrow \infty]{} (\mathbf{b}_*, \sigma_*^2) \text{ s.j.}$$

Dále je známo, že

$$\hat{R}_{ij} \xrightarrow[n \rightarrow \infty]{} R_{ij} \text{ s.j.}$$

taktéž, kde $\mathbf{R} = \{R_{ij}\}$ je kovariační toeplitzovská matice autoregresní posloupnosti. Použitím známých vztahů mezi \mathbf{R} a odpovídající spektrální hustotou plynoucích z Fourierovy analýzy již snadno dokážeme tvrzení věty.

Nyní se obrátíme k obecnému případu gaussovské stacionární posloupnosti s nulovou střední hodnotou. Pak sdružená hustota pozorování (x_1, x_2, \dots, x_n) má tvar

$$f_n(x_1, \dots, x_n) = \frac{1}{(2\pi)^{n/2} |\mathbf{R}_n|^{1/2}} \exp \left\{ -\frac{1}{2} \mathbf{x}^T \mathbf{R}_n^{-1} \mathbf{x} \right\},$$

kde \mathbf{R}_n je příslušná kovariační matice, což znamená, že její logaritmus má tvar

$$L_n(\mathbf{x}) = -\frac{1}{2} \{ n \ln 2\pi + \ln |\mathbf{R}_n| - \mathbf{x}^T \mathbf{R}_n^{-1} \mathbf{x} \}.$$

Problém je v tom, že explicitní vyjádření pro $L_n(\mathbf{x})$ bývá velice těžkopádné, a tudíž případný výpočet MLE neznámého parametru θ je nesnadný a obvykle je možno získat ho pouze numericky.

V polovině padesátých let přišel Whittle, viz [2], s myšlenkou nahradit logaritmus věrohodnostního poměru vhodným výrazem $\tilde{L}_n(\mathbf{x})$, pro který by platilo

$$n^{-1/2} (L_n(\mathbf{x}) - \tilde{L}_n(\mathbf{x})) \xrightarrow[n \rightarrow \infty]{\text{slabě}} 0,$$

přičemž odhady parametru θ získané maximalizací $\tilde{L}_n(\mathbf{x})$ by byly snadněji dostupné. Výraz $\tilde{L}_n(\mathbf{x})$ se nazývá principiální částí věrohodnostního poměru a o jeho použití při konstrukci odhadů pro gaussovské stacionární posloupnosti viz monografii [3]. Vhodný tvar pro $\tilde{L}_n(\mathbf{x})$ lze totiž v případě stacionárních gaussovských posloupností najít jako

$$\tilde{L}_n(\mathbf{x}) = -\frac{n}{2} \left(\ln 2\pi + \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln(2\pi\varphi(\lambda)) d\lambda + \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{I_n(\lambda, \mathbf{x})}{\varphi(\lambda)} d\lambda \right),$$

kde

$$I_n(\lambda, \mathbf{x}) = \frac{1}{2\pi n} \left| \sum_{j=1}^n x_j e^{-ij\lambda} \right|^2$$

je periodogram. Snadno lze ukázat, že

$$\tilde{L}_n(\mathbf{x}) = -\frac{n}{2} \left(\text{konst} + \frac{1}{2\pi} \int_{-\pi}^{\pi} \left(\frac{\tilde{\varphi}(\lambda, \mathbf{x})}{\varphi(\lambda)} \right) - 1 \right) d\lambda + \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln \tilde{\varphi}(\lambda, \mathbf{x}) d\lambda,$$

kde $\tilde{\varphi}(\lambda, \mathbf{x})$ je spektrální hustota odvozená od výběrových momentů.

Bude-li nyní $\varphi(\lambda) = \varphi(\lambda, \theta)$, kde $\theta \in \Theta$ je konečněrozměrný parametr, pak je vidět, že odhady $\tilde{\theta}_n$ získané maximalizací principiální části $\tilde{L}_n(\mathbf{x})$ věrohodnostního poměru jsou vlastně odhady minimalizující asymptotickou rychlost I -divergence, neboť

$$\tilde{\theta}_n = \arg \max_{\theta \in \Theta} \tilde{L}_n(\mathbf{x}) = \arg \min_{\theta \in \Theta} \bar{I}(\tilde{\varphi}(\lambda, \mathbf{x}) : \varphi(\lambda, \theta)).$$

Ve výše uvažovaném případě autoregresního modelu, když $\varphi(\lambda, \theta)$ odpovídá autoregresnímu modelu, pak výše popsané odhady autoregresních koeficientů jsou Yule–Walkerovy odhady (viz [4]).

4. ZÁVISLÁ POZOROVÁNÍ – SPOJITÝ ČAS

Nyní se budeme zabývat stochastickými procesy, které jsou zadány na intervalu $\langle 0, T \rangle$ a jsou vesměs gaussovské.

Nejjednodušší případ je následující jednoduchý regresní model pro gaussovský proces $\{x(t), t \in \langle 0, T \rangle\}$ se střední hodnotou

$$E_{\alpha}\{x(t)\} = \alpha \varphi(t), \quad \varphi(\cdot) \neq 0 \quad \text{na } \langle 0, T \rangle$$

a kovariační funkcí $\text{cov}_{\alpha}(x(s), x(t)) = \text{cov}_0(x(s), x(t))$. Pak (viz [5]) buď odpovídající gaussovské míry $\{P_{\alpha}\}$, $\alpha \in R_1$ jsou navzájem absolutně spojitě, tj. $P_{\alpha} \sim P_0$ a nebo jsou singulární. V regulárním případě lze psát

$$\frac{dP_{\alpha}}{dP_0}(x(\cdot)) = \exp \left\{ \alpha v - \frac{1}{2} \alpha^2 E_0\{v^2\} \right\},$$

kde $v = \hat{\alpha} E_0\{v^2\}$, přičemž $\hat{\alpha}$ je MLE parametru α . Je pak snadno vidět, že

$$\max_{\alpha \in R_1} \left\{ \ln \frac{dP_{\alpha}}{dP_0}(x(\cdot)) \right\} = I(P_{\alpha} : P_0),$$

kde $I(P_{\alpha} : P_0) = \frac{1}{2} \alpha^2 E_0\{v^2\}$. Odtud opět ihned vidíme, že MLE parametru α je rovněž odhad minimalizující $I(P_{\alpha} : P_0)$.

Velice širokou třídou procesu užitečných jak z teoretického, tak i praktického hlediska jsou gaussovské autoregresní procesy stacionárního typu, se

střední hodnotou nula pro jednoduchost, které mají spektrální hustotu

$$\varphi(\lambda) = \frac{\sigma^2}{2\pi} \frac{1}{\left| \sum_{k=0}^p a_{n-k} (i\lambda)^k \right|^2},$$

kde $a_0 = 1$ a charakteristický polynom $P(z) = \sum_{k=0}^p a_{n-k} z^k$ splňuje podmínku stacionarity. Odpovídající Radon–Nikodymova hustota vůči míře Q , která je generována gaussovským procesem $\{y(t), t \in \langle 0, T \rangle\}$ se střední hodnotou nula a s nezávislými přírůstky, kde $(p-1)$ ní derivace splňuje

$$E \left\{ dy^{(p-1)}(t)^2 \right\} = \sigma^2 dt,$$

(blíže viz [6]), má pak tvar

$$\begin{aligned} \frac{dP_a}{dQ} &= |\{D_{jk}\}|^{1/2} \exp \left\{ -\frac{1}{2} a_1 T - \frac{1}{2} \sum_{k=0}^{p-1} A_{p-k} \int_0^T (x^{(k)}(t))^2 dt - \right. \\ &\quad \left. \frac{1}{4} \sum_{\substack{j+k \\ \text{sudé}}} \sum_{k=0}^p \left[x^{(j)}(0) x^{(k)}(0) + x^{(j)}(T) x^{(k)}(T) \right] D_{jk}, \right. \end{aligned}$$

kde $\{D_{jk}\}$ jsou prvky inverzní matice ke kovarianční matici náhodných veličin $(x(0), x^{(1)}(0), \dots, x^{(p-1)}(0))$.

Dále platí vztah

$$\sum_{k=0}^p A_{p-k} \lambda^{2k} = \left| \sum_{k=0}^n a_{p-k} (i\lambda)^k \right|^2.$$

Pro $p > 1$ je nemožné explicitně spočítat MLE pro (a_1, a_2, \dots, a_p) . Proto se opět uvažuje o principiální části Radon–Nikodymovy derivace tím, že se zanedbají členy řádu $o(T)$ pro $T \rightarrow \infty$. Po zanedbání těchto členů se získá systém lineárních rovnic pro parametry (a_1, a_2, \dots, a_p) snadno řešitelný, blíže viz ([7, 8]). Ukážeme v následujícím, že tyto odhady lze získat i jiným přístupem. A to buď A) momentovou metodou a nebo B) minimalizací vhodné asymptotické rychlosti I -divergence.

A) Označme

$$\widehat{R}_k = \frac{1}{T} \int_0^T |x^{(k)}(t)|^2 dt, \quad k = 0, 1, \dots, p-1.$$

Uvažujme zobrazení $\mathbf{T} = \{T_k(\cdot)\}_{k=0}^{p-1}$, kde

$$T_k(a_1, \dots, a_p) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \frac{\lambda^{2k} d\lambda}{\left| \sum_{k=0}^p a_{n-k} (i\lambda)^k \right|^2}.$$

Lze ukázat, že zobrazení \mathbf{T} je jednojednoznačné zobrazení definované na otevřené podmnožině stacionarity parametrického prostoru,

kterým je míněna oblast stacionarity. Díky konvergenci ve smyslu s. j.

$$\widehat{R}_k \xrightarrow{T \rightarrow \infty} R_k = E \left\{ |x^{(k)}(0)|^2 \right\}$$

lze ukázat, že s pravděpodobností blíží se 1 při $T \rightarrow \infty$ existují odhady $(\tilde{a}_1, \tilde{a}_2, \dots, \tilde{a}_p) = \mathbf{T}^{-1}(\widehat{R}_0, \widehat{R}_1, \dots, \widehat{R}_{p-1})$. Pak lze ukázat, že principiální část $PP \ln \frac{dP_a}{dQ}$ Radon–Nikodymovy derivace získaná zanedbáním členů řádu $o(T)$ při $T \rightarrow \infty$ splňuje vztah

$$\frac{1}{T} \ln PP \frac{dP_a}{dQ}(x(\cdot)) = -\frac{1}{2} \bar{I}(\tilde{\varphi}(\cdot) : \varphi_a(\cdot)),$$

kde $\tilde{\varphi}(\cdot)$ je spektrální hustota odvozená od výběrových charakteristik $(\widehat{R}_0, \widehat{R}_1, \dots, \widehat{R}_{p-1})$ pomocí vztahu

$$\widehat{R}_k = \int_{-\infty}^{+\infty} \lambda^{2k} \tilde{\varphi}(\lambda) d\lambda.$$

Výraz pro asymptotickou rychlost I -divergence mezi dvěma gaussovskými stacionárními mírami se střední hodnotou nula je vyjádřen jako

$$\bar{I}(P : Q) = \frac{1}{4\pi} \int_{-\infty}^{+\infty} \left(\frac{\varphi_P(\lambda)}{\varphi_Q(\lambda)} - \ln \frac{\varphi_P(\lambda)}{\varphi_Q(\lambda)} - 1 \right) d\lambda,$$

kde $\varphi_P(\cdot)$, $\varphi_Q(\cdot)$ jsou odpovídající spektrální hustoty. Z výše uvedeného plyne, že odhady autoregresních koeficientů (a_1, a_2, \dots, a_p) dané maximalizací principiální částí Radon–Nikodymovy derivace jsou odhady získané momentovou metodou, neboť jsme řešili systém rovnic

$$\widehat{R}_j = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \frac{\lambda^{2j} d\lambda}{\left| \sum_{k=0}^p a_{p-k} (i\lambda)^k \right|^2}, \quad j = 0, 1, \dots, p-1.$$

B) Nechť $\varphi_a(\cdot)$ je spektrální hustota pro AR-model s koeficienty (a_1, a_2, \dots, a_p) , nechť $\widehat{\varphi}(\cdot)$ je jiná hustota a uvažujme funkcionál tvaru

$$F(\varphi_a(\cdot)) = \frac{1}{4\pi} \int_{-\infty}^{+\infty} \left(\frac{\widehat{\varphi}(\lambda)}{\varphi_a(\lambda)} - \ln \frac{\widehat{\varphi}(\lambda)}{\varphi_a(\lambda)} - 1 \right) d\lambda$$

za předpokladu konečnosti $\int_{-\infty}^{+\infty} \lambda^{2p} \widehat{\varphi}(\lambda) d\lambda$.

Hledejme minimum tohoto funkcionálu přes všechny možné spektrální hustoty $\varphi_a(\cdot)$ autoregresního modelu. Tuto úlohu lze tedy chápat také takto: Mějme dán gaussovský stacionární proces $\{x(t), t \in \langle 0, T \rangle\}$, který má derivace až do řádu $(p-1)$ a chceme najít mezi všemi autoregresními gaussovskými procesy řádu p takový, který by byl co nejvíce podoben výchozímu procesu $\{x(t), t \in \langle 0, T \rangle\}$ v tom

smyslu, aby míra podobnosti byla maximální, tedy minimální vzdálenost měřená asymptotickou rychlostí I -divergence. Lze ukázat, že takové minimum existuje mezi autoregresními procesy p -tého řádu a je právě dáno výše popsanou metodou v bodě A). Za tímto účelem spočítejme rozdíl

$$\begin{aligned}
& 4\pi (F(\varphi_b(\cdot)) - F(\varphi_{\tilde{a}})) \\
&= \int_{-\infty}^{+\infty} \left(\frac{\hat{\varphi}(\lambda)}{\varphi_b(\lambda)} - \ln \frac{\hat{\varphi}(\lambda)}{\varphi_b(\lambda)} - 1 \right) d\lambda \\
&\quad - \int_{-\infty}^{+\infty} \left(\frac{\hat{\varphi}(\lambda)}{\varphi_{\tilde{a}}(\lambda)} - \ln \frac{\hat{\varphi}(\lambda)}{\varphi_{\tilde{a}}(\lambda)} - 1 \right) d\lambda \\
&= \int_{-\infty}^{+\infty} \left(\frac{1}{\varphi_b(\lambda)} - \frac{1}{\varphi_{\tilde{a}}(\lambda)} \right) \hat{\varphi}(\lambda) - \frac{\varphi_{\tilde{a}}(\lambda)}{\varphi_b(\lambda)} \\
&= \sum_{k=0}^n (B_{n-k} - \hat{A}_{n-k}) \hat{R}_k(0) + b_1 - \tilde{a}_1 \\
&= \int_{-\infty}^{+\infty} \frac{\varphi_{\tilde{a}}(\lambda)}{\varphi_b(\lambda)} - \ln \frac{\varphi_{\tilde{a}}(\lambda)}{\varphi_b(\lambda)} - 1 \geq 0
\end{aligned}$$

díky nezápornosti I -divergenční rychlosti. Tím je dokázáno, že $F(\varphi_b(\cdot)) \geq F(\varphi_{\tilde{a}}(\cdot))$ a jednoznačnost plyne z vlastností funkce $x - \ln x - 1$. ■

Na závěr uvedeme větu, jejíž důkaz bezprostředně plyne z vlastností stacionárních autoregresních gaussovských modelů.

Věta 2. Pro stacionární AR-gaussovský proces platí

$$\lim_{T \rightarrow \infty} \frac{1}{T} \max_{a \in \Theta_p} \ln \frac{dP_a(x(\cdot))}{dP_{a_0}(x(\cdot))} = \frac{1}{2} I(P_{a_*} : P_{a_0}),$$

kde Θ_p je parametrický prostor a a_* je správná hodnota autoregresních parametrů.

Důkaz. Věta plyne z vlastností superkonsistence maximálně věrohodných odhadů koeficientů (a_1, \dots, a_p) autoregresního gaussovského procesu a ze vztahu mezi Radon–Nikodymovou derivací $\frac{dP_a}{dP_{a_0}}$ a její principiální částí, neboť platí

$$\ln \frac{dP_a}{dP_{a_0}} = PP \ln \frac{dP_a}{dP_{a_0}} + o(T) \quad \text{při } T \rightarrow \infty.$$

Dále z předchozího víme, že $\frac{1}{T} PP \ln \frac{dP_a}{dP_{a_0}} = \frac{1}{2} I(\tilde{\varphi} : \varphi_a)$, kde spektrální hustota $\tilde{\varphi}(\cdot)$ je určena pomocí výběrových charakteristik $(\hat{R}_0, \hat{R}_1, \dots, \hat{R}_{p-1})$, které při $T \rightarrow \infty$ konvergují ke skutečným hodnotám R_0, R_1, \dots, R_{p-1} s. j.

LITERATURA

- [1] Michálek J. (1990), *Asymptotic Rényi's rate of Gaussian processes*. Prob. Control and Inf. Th. Vol. 10, **3**, 209 – 227.
- [2] Whittle P. (1952), *Estimation and information in time series analysis*. Skand. Aktuar. **35**, 48 – 60.
- [3] Dzhaparidze K. (1986), *Parameter Estimation and Hypothesis Testing in Spectral Analysis of Stationary Time Series*. Springer-Verlag, Heidelberg.
- [4] Michálek J. (1990), *Yule – Walker estimates and asymptotic I-divergence rate*. Probl. Control and Inf. Th. 5 – 6, **19**, 387 – 398.
- [5] Hájek J. (1960), *On a simple regression model in Gaussian processes*. Trans. of Second Prague Conference on Inf. Theory. Publishing House of Czechoslov. Academy of Sciences, Praha, 185 – 198.
- [6] Hájek J. (1962), *On linear statistical problems in stochastic processes*. Czechoslov. Math. Journal T 12 **87**, 404 – 444.
- [7] Pisarenko V. F. (1962), *On parameter estimation of a Gaussian stationary processes with a spectral density function*. Lithuanian Math. Journal 27 – 43. (rusky)
- [8] Rozanov I. A. (1962), *On the derivative of a Gaussian probability measure with respect to another one*. Teorija verojatnostej i prim. **7(1)**, 84 – 89. (rusky)