

# ML odhad zpoždění dálkoměrného signálu

–  
verze: 20090902

## 1 Popis úlohy

*ML (Maximum Likelihood) odhad* = nejvěrohodnější odhad

*značení*: vektor parametrů:  $\mathbf{P}$ , vektor měření:  $\mathbf{X}$  (předpokládáme dimenzi  $N$ ), vektor odhadu parametrů:  $\hat{\mathbf{P}}$

k odhadu potřebuji znát hustotu pravděpodobnosti vektoru měřených hodnot  $\mathbf{X}$  podmíněnou znalostí hledaných parametrů  $\mathbf{P}$ :  $p_{\mathbf{X}}(\mathbf{x}|\mathbf{P})$  resp.  $\Pr(\mathbf{X} = \mathbf{x}|\mathbf{P})$

*ML odhad* je dán výrazem:

$$\hat{\mathbf{P}}_{ML} = \arg \max_{\check{\mathbf{P}}} p_{\mathbf{X}}(\mathbf{x}|\check{\mathbf{P}}) \quad (1)$$

$$\hat{\mathbf{P}}_{ML} = \arg \max_{\check{\mathbf{P}}} \Pr(\mathbf{X} = \mathbf{x}|\check{\mathbf{P}})$$

*věrohodnostní funkce*  $\Lambda(\mathbf{P})$ : až na (pro odhad) nevýznamné konstanty je rovna podmíněné hustotě pravděpodobnosti  $p_{\mathbf{X}}(\mathbf{x}|\mathbf{P})$ , ML odhad se pak hledá jako maximum věrohodnostní funkce

$$\hat{\mathbf{P}}_{ML} = \arg \max_{\check{\mathbf{P}}} \Lambda(\check{\mathbf{P}})$$

## 2 Odhad zpoždění dálkoměrného signálu v šumu


### 2.1 Model signálu

Předpokládáme měřený (zpracovávaný) signál ve tvaru

$$x(t) = Ac(t - \tau) + n(t),$$

kde  $c(t - \tau)$  je dálkoměrný (pseudonáhodný) signál s neznámým zpožděním  $\tau$ ,  $A$  je nenáhodná konstanta a  $n(t)$  je aditivní šum.

Dálkoměrný signál  $c(t)$  je deterministický signál, jehož autokorelační funkce se blíží autokorelační funkci bílého šumu – v hodnotě  $\tau = 0$  nabývá autokorelační funkce výrazného



**Obr. 1:** Autokorelační funkce  $\mathcal{R}_{c(t)}(t')$  dálkoměrného (pseudonáhodného) signálu  $c(t)$ , její vztah k autokorelační funkci  $\mathcal{R}_{c[k]}[k']$  odpovídající pseudonáhodné posloupnosti  $c[k]$

maxima. Protože je  $c(t)$  signál periodický, je periodická i jeho autokorelační funkce, viz obr. 1.

Dálkoměrný signál  $c(t)$  je odvozen z odpovídající pseudonáhodné posloupnosti  $c[k]$ . Jednotlivé hodnoty této posloupnosti – čipy – nabývají hodnoty z množiny  $\{-1, 1\}$ . Mezi  $c(t)$  a  $c[k]$  platí vztah

$$c(t) = \sum_{k=-\infty}^{\infty} c[k] h(t - kT_c),$$

kde  $T_c$  je doba trvání čipu a  $h(t)$  je obdélníkový modulační impulz s dobou trvání  $T_c$ . Posloupnost  $c[k]$  je periodická, její periodu označíme  $N_c$ . Potom je perioda signálu  $c(t)$  rovna hodnotě  $N_c T_c$ .

Autokorelační funkce  $\mathcal{R}_c(t') = \text{Av}\{c(t)c(t+t')\}$  dálkoměrného signálu  $c(t)$  a autokorelační funkce  $\mathcal{R}_c[k'] = \text{Av}\{s[k]s[k+k']\}$  pseudonáhodné posloupnosti  $c[k]$  je znázorněna na obr. 1.

O aditivním šumu  $n(t)$  budeme předpokládat, že je pásmově omezený bílý gaussovský šum na intervalu  $|\omega| < 2\pi B$ , kde  $B = f_{sa}/2$ . Na tomto intervalu necht' má šum spektrální výkonovou hustotu s hodnotou  $N_0/2$ , tedy

$$\mathcal{C}_{n(t)}(\omega) = \begin{cases} \frac{N_0}{2} & \text{pro } \omega \in (-2\pi B, 2\pi B), \\ 0 & \text{jinde.} \end{cases}$$

## 2.2 Odvození věrohodnostní funkce

Nejprve úlohu převedeme do diskretního času. Měřený signál  $x(t)$  vzorkujeme se vzorkovací kmitočtem  $f_{sa} = 1/T_{sa}$ , získáme  $x[k] = x(kT_{sa})$ . Hledaný parametr  $\tau$  v diskretním čase označíme jako  $m$ , jeho vztah k  $\tau$  je  $m = \text{round}(\tau/T_{sa})$ .

Získáváme model měřeného signálu v diskretním čase

$$x[k] = Ac[k - m] + n[k] \doteq Ac(kT_{sa} - mT_{sa}) + n(kT_{sa}) = x(kT_{sa}).$$

Vektor měření  $\mathbf{X}$  je reprezentován vzorky měřeného signálu  $x$ , tedy  $\mathbf{X} = (x[k_p], x[k_p + 1], \dots, x[k_p + N - 1])$ . Parametr, který je předmětem odhadu, je skalár  $P$  (ne vektor  $\mathbf{P}$  jako v obecném případě v kap. 1), tedy  $P = \tau \doteq mT_{sa}$ . Odhad parametru potom označíme jako  $\hat{P} = \hat{\tau} \doteq \hat{m}T_{sa}$ .

Zabývejme se dále odvozením podmíněné hustoty pravděpodobnosti  $p_{\mathbf{X}}(\mathbf{x}|m)$ , který potřebujeme pro ML odhad dle (1). Díky volbě  $B = f_{sa}/2$  jsou vzorky šumu  $n[k]$  nekorelované, autokorelační funkce takového šumu má tvar  $\mathcal{R}_{n[k]}[k'] = f_{sa} \frac{N_0}{2} \delta[k']$  a rozptyl vzorků šumu je  $\text{var}\{n[k]\} = \mathcal{R}_{n[k]}[0] = f_{sa} \frac{N_0}{2}$ . Protože (dle předpokladu) má  $n[k]$  normální (Gaussovo) rozdělení s nulovou střední hodnotou, bude pro hustotu pravděpodobnosti jednoho vzorku  $x[k]$  platit

$$p_{x[k]}(x[k]|m) = \frac{1}{\sqrt{\pi f_{sa} N_0}} \exp\left(-\frac{1}{f_{sa} N_0} (x[k] - Ac[k - m])^2\right). \quad (2)$$

Díky nezávislosti  $n[k]$  budou statisticky nezávislé i vzorky signálu  $x[k]$ . Sdružená hustota pravděpodobnosti vektoru  $\mathbf{X}$  je pak dána součinem jednotlivých hustot (2), tedy

$$\begin{aligned} p_{\mathbf{X}}(\mathbf{x}|m) &= \prod_{k=k_p}^{k_p+N-1} p_{x[k]}(x[k]|m) = \\ &= \frac{1}{(\pi f_{sa} N_0)^{\frac{N}{2}}} \exp\left(-\frac{1}{f_{sa} N_0} \sum_{k=k_p}^{k_p+N-1} (x[k] - Ac[k - m])^2\right). \end{aligned} \quad (3)$$

Pro ML odhad zpoždění  $\hat{m}$  pak platí

$$\hat{m}_{ML} = \arg \max_{\hat{m}} p_{\mathbf{X}}(\mathbf{x}|\hat{m}). \quad (4)$$

Hustota pravděpodobnosti (3) je pro odhad dle (4) zbytečně moc složitá. Výraz hustoty (3) dále zjednodušíme, jednotlivé úpravy provádíme tak, aby neměly vliv na hledání  $\arg \max\{\cdot\}$  daného výrazu. Nejprve odstraníme nevýznamnou konstantu  $1/(\pi f_{sa} N_0)^{\frac{N}{2}}$ . Dále, vzhledem k monotónnosti exponenciály lze  $\exp(\cdot)$  rovněž odstranit a to i včetně

konstanty  $\frac{1}{f_{sa}N_0}$ . Díky znaménku  $-$  uvnitř  $\exp(\cdot)$  přecházíme z  $\arg \max\{\cdot\}$  na  $\arg \min\{\cdot\}$ . ML odhad lze pak přepsat na tvar

$$\hat{m}_{ML} = \arg \min_{\tilde{m}} \sum_{k=k_p}^{k_p+N-1} (x[k] - Ac[k - \tilde{m}])^2. \quad (5)$$

Tvar ML odhadu (5) představuje celkem logický závěr: hledáme takový parametr  $\tilde{m}$ , který minimalizuje chybovou energii mezi přijatým signálem  $x[k]$  a modelem užitečné části signálu  $Ac[k - \tilde{m}]$ .

Výraz lze ale ještě dále upravit

$$(x[k] - Ac[k - \tilde{m}])^2 = x^2[k] + A^2 \underbrace{c^2[k - \tilde{m}]}_1 - 2Ax[k]c[k - \tilde{m}]. \quad (6)$$

Protože na parametru  $\tilde{m}$  závisí jen poslední člen, lze odhad přepsat na následující tvar (znaménko  $-$  před posledním členem změní opět  $\arg \min$  na  $\arg \max$ )

$$\hat{m}_{ML} = \arg \max_{\tilde{m}} \sum_{k=k_p}^{k_p+N-1} x[k]c[k - \tilde{m}] = \arg \max_{\tilde{m}} \mathcal{R}_{x,c}[-\tilde{m}] \arg \max_{\tilde{m}} \Lambda(\tilde{m}),$$

tj. hledáme takový argument  $\tilde{m}$ , při kterém vzájemná korelační funkce signálů  $x[k]$  a  $c[k]$  nabývá svého maxima.