



CEITEC

central european institute of technology

BRNO | CZECH REPUBLIC

Identifikace časově proměnných systémů jako statistický rozhodovací problém

6. září 2018

Ing. Jakub Dokoupil, Ph.D.



Normální, regresní model

$$y_k = h_k' \theta + e_k, \quad e_k \sim \mathcal{N}(0, r). \quad (1)$$



- $h_k \equiv [u_k, u_{k-1}, \dots, u_{k-n_u}, -y_{k-1}, \dots, -y_{k-n_y}]' \in \mathbb{R}^p$ je známý regresní vektor dat;
- $\theta \in \mathbb{R}^p$ je náhodný vektor neznámých parametrů modelu;
- e_k je normálně rozdělený, diskretní bílý šum se známou a konstantní variancí r







Bayesův vzorec - funkcionální rekurze



$$\underbrace{f(\theta | D_{1-n}^k, r)}_{\text{posteriorní fhp}} \propto \underbrace{f(y_k | h_k, \theta, r)}_{\text{parametrický model}} \underbrace{f(\theta | D_{1-n}^{k-1}, r)}_{\text{predikční fhp}}. \quad (2)$$



- $f(\theta | D_{1-n}^0, r)$ je apriorní fhp inicializující rekurzi;
- $D_{1-n}^k \equiv \{u_\gamma, y_\gamma\}_{\gamma=1-n}^k$ je množina vstupně-výstupních dat;
- $f(y_k | h_k, \theta, r) = \mathcal{N}(h_k' \theta, r)$;
- $f(\theta | D_{1-n}^{k-1}, r) = \mathcal{N}(\hat{\theta}_{k|k-1}, r P_{k|k-1})$



















Modifikovaný Bayesův vzorec - predikční fhp vzniká zploštěním posteriorní fhp



$$f(\theta_k | D_{1-n}^k, r) \propto f(y_k | h_k, \theta_k, r) f(\theta_{k-1} | D_{1-n}^{k-1}, r)^\lambda. \quad (3)$$

- $\lambda \in (0, 1)$ je faktor zapomínání;
- metoda předpokládá pomalé změny ve vývoji parametrů, tedy $\theta_{k+1} \approx \theta_k$









Parametrická rovnice modelu

$$y_k = g(h_k, \theta_k) + e_k, \quad e_k \sim \mathcal{N}(0, 1/d_k). \quad (4)$$

- $g(\cdot)$ je známá diferencovatelná funkce;
- $1/d_k$ je neznámou variancí;
- $\Theta_k \equiv \{\theta_k, d_k\}$ bude dále označovat uspořádanou množinu neznámých parametrů

Formální rovnice vývoje parametrů

$$\Theta_k = \Theta_{k-1}. \quad (5)$$

Externí informace popisující chování systému

$$\theta_0 = \alpha_k + w_k, \quad w_k \sim \mathcal{N}(0, \Xi_k^{-1}/d_k), \quad (6)$$

$$d_0 = \beta_k, \quad \beta_k \sim \mathcal{W}(\Sigma_{c;k}, \nu_{c;k}), \quad (7)$$

- $\alpha_k \in \mathbb{R}^p$ je známý vektor;
- Ξ_k je známou normalizovanou informační maticí vektoru $w_k \in \mathbb{R}^p$;
- $\mathcal{W}(\cdot)$ je Wishartova fhp s $\nu_{c;k}$ stupni volnosti;
- $\Pi_k \equiv \{\alpha_k, \Xi_k, \Sigma_{c;k}, \nu_{c;k}\}$

Parametrický model

$$f(y_k | h_k, \Theta_k) \simeq (2\pi/d_k)^{-1/2} \quad (8)$$
$$\times \exp \left[- \left[\theta'_k, 1 \right] \psi_{i,k} \psi'_{i,k} \left[\theta'_k, 1 \right]' d_k / 2 \right],$$

kde tvar pomocného vektoru $\psi_{i,k}$

$$\psi_{i,k} = \left[\zeta'_{i,k}, \quad -y_k + g_k(h_k, \hat{\theta}_{i,k}) - \zeta'_{i,k} \hat{\theta}_{i,k} \right]', \quad (9)$$
$$\zeta_{i,k} = \partial g_k(h_k, \theta_k) / \partial \theta_k |_{\theta_k = \hat{\theta}_{i,k}}$$

vychází z Taylorova rozvoje $g(h_k, \theta_k)$ v okolí $\hat{\theta}_{i,k}$.

Predikční fhp

$$f(\Theta_k | D_{1-n}^{k-1}, \Pi_{k-1}) = \mathcal{N}(\hat{\theta}_{k|k-1}, P_{\zeta; k|k-1}/d_k) \mathcal{W}(\Sigma_{k|k-1}, \nu_{k|k-1}) \quad (10)$$

$$\propto d_k^{(\nu_{k|k-1} + p - 2)/2} \exp \left[- [\theta'_k, 1] V_{k|k-1} [\theta'_k, 1]' d_k / 2 \right]$$

se statistikami $\hat{\theta}_{k|k-1}$, $P_{\zeta; k|k-1} = \begin{bmatrix} \lceil^{P_\zeta} U_{k|k-1} & \lceil^{P_\zeta} D_{k|k-1} \\ 0 & \Sigma_{k|k-1}^{-1} \end{bmatrix}$ a $\Sigma_{k|k-1}^{-1}$ generovanými dekompozicí matice $P_{k|k-1} \equiv V_{k|k-1}^{-1}$,

$$P_{k|k-1} = \underbrace{\begin{bmatrix} \lceil^{P_\zeta} U_{k|k-1} & \hat{\theta}_{k|k-1} \\ 0 & 1 \end{bmatrix}}_{\lceil^P U_{k|k-1}} \underbrace{\begin{bmatrix} \lceil^{P_\zeta} D_{k|k-1} & 0 \\ 0 & \Sigma_{k|k-1}^{-1} \end{bmatrix}}_{\lceil^P D_{k|k-1}} \left[\lceil^P U_{k|k-1} \right]' \quad (11)$$

Funkce hustoty pravděpodobnosti $f(\Theta_k | \Pi_k)$

$$f(\Theta_k | \Pi_k) \propto d_k^{(\nu_{c;k} \prod_{\gamma=0}^{k-1} \lambda_{\gamma+1|\gamma} + p - 2)/2} \quad (12)$$

$$\times \exp \left[- \begin{bmatrix} \theta'_k & 1 \end{bmatrix} V_{c;k} \prod_{\gamma=0}^{k-1} \lambda_{\gamma+1|\gamma} \begin{bmatrix} \theta'_k & 1 \end{bmatrix}' d_k/2 \right],$$

kde

$$V_{c;k} = \begin{bmatrix} [^{\Xi} L_k & 0] \\ -\alpha'_k & 1 \end{bmatrix} \begin{bmatrix} [^{\Xi} D_k & 0] \\ 0 & \Sigma_{c;k} \end{bmatrix} \begin{bmatrix} [^{\Xi} L_k & 0] \\ -\alpha'_k & 1 \end{bmatrix}' \quad (13)$$

Modifikovaný Bayesův vzorec pro $f(\Theta_k | D_{1-n}^k, \Pi_k)$

$$\begin{aligned} f(\Theta_k | D_{1-n}^k, \Pi_k) &= \mathcal{N}(\hat{\theta}_{k|k}, P_{\zeta; k|k}/d_k) \mathcal{W}(\Sigma_{k|k}, \nu_{k|k}) \\ &\propto \prod_{\kappa=k_1+1}^k f^{\prod_{\gamma=\kappa}^{k-1} \lambda_{\gamma+1|\gamma}}(y_\kappa | h_\kappa, \Theta_k) \\ &\quad \times \frac{f(\Theta_k | D_{1-n}^{k_1}, \Pi_{k_1}) f(\Theta_k | \Pi_{k_1})}{f(\Theta_k | \Pi_{k_1})}, \end{aligned} \quad (14)$$

kde volbou k_1 přepínáme mezi off-line ($k_1 = 0$) a on-line ($k_1 = k - 1$) strategií učení.

Aktualizace predikčních statistik

$$\nu_{k|k} = \nu_{k|k-1} + 1 + \underbrace{(\nu_{c;k} - \nu_{c;k-1}) \prod_{\gamma=0}^{k-1} \lambda_{\gamma+1|\gamma}}_{r_k}, \quad (15)$$

$$V_{k|k} = V_{k|k-1} + \psi_{i,k} \psi'_{i,k} + \underbrace{(V_{c;k} - V_{c;k-1}) \prod_{\gamma=0}^{k-1} \lambda_{\gamma+1|\gamma}}_{R_k}. \quad (16)$$

- volbou $r_k = \nu_{c;k} - \lambda_{k|k-1} \nu_{c;k-1}$ a $R_k = V_{c;k} - \lambda_{k|k-1} V_{c;k-1}$ odstraníme efekt zapomínání na tu část informace, která je dodávána externě

Vstupy do statistického rozhodování

Volba predikční fhp se uskutečňuje na bázi slučování dílčích predikčních alternativ. Tato úloha může být chápána jako statistický rozhodovací problém:

- v našem případě je parametrický prostor f_H^* tvořen dvojicí alternativ
 - $f_0(\Theta_{k+1}) \equiv \mathcal{N}(\hat{\theta}_{k|k}, P_{\zeta;k|k}/d_{k+1})\mathcal{W}(\Sigma_{k|k}, \nu_{k|k})$;
 - $f_1(\Theta_{k+1}) \propto d_{k+1}^{(p-2)/2}$;
- míra nesouladu mezi dvojicí fhp je ohodnocena Kullbackovou-Leiblerovou divergencí (KLD)

$$\mathcal{D}(f(\Theta) \| f_H(\Theta)) \equiv \int_{\Theta^*} f(\Theta) \ln \left(\frac{f(\Theta)}{f_H(\Theta)} \right) d\Theta; \quad (17)$$

Vstupy do statistického rozhodování

- nezáporné odhady ztrát $\varrho_H^* \equiv \{\varrho_0, \varrho_1\}$ poskytují zpětnou vazbu o přesnosti dosažené jednotlivými predikčními alternativami

$$\varrho_0 \equiv (1 + \rho) \mathcal{D}(f(\Theta_k | D_{1-n}^k, \Pi_k) \| f(\Theta_k | D_{1-n}^{k-1}, \Pi_{k-1})), \quad (18)$$

$$\varrho_1 \equiv \mathcal{D}(f(\Theta_k | D_{1-n}^k, \Pi_k) \| f_1(\Theta_k)), \quad (19)$$

kde $\rho \geq 0$ je uživatelem definovaný faktor;


- prvky vektoru pravděpodobností $\varphi \equiv [\varphi_0, \varphi_1]'$ jsou přidružené ke každé z přípustných realizací výrazu $\{f_H, \varrho_H\}$;



Vstupy do statistického rozhodování

Ztrátový funkcionál ohodnocující krok časové aktualizace je ve tvaru

$$\begin{aligned}\phi(f(\Theta_{k+1}), \varphi) &\equiv \mathcal{E}_{\{f_H, \varrho_H\}} [\mathcal{D}(f(\Theta_{k+1}) \| f_H(\Theta_{k+1})) - \varrho_H] \\ &= \sum_{i=0}^1 \varphi_i [\mathcal{D}(f(\Theta_{k+1}) \| f_i(\Theta_{k+1})) - \varrho_i].\end{aligned}\quad (20)$$



Optimální strategie zapomínání

Optimální strategie kombinující $f_0(\Theta_{k+1})$ a $f_1(\Theta_{k+1})$ s ohledem na normalizující omezení $\int_{\Theta^*} \hat{f}(\Theta_{k+1}) d\Theta_{k+1} = 1$ je dána

$$\hat{f}(\Theta_{k+1}) = \frac{f_0^{\varphi_0}(\Theta_{k+1}) f_1^{\varphi_1}(\Theta_{k+1})}{\int_{\Theta^*} f_0^{\varphi_0}(\Theta_{k+1}) f_1^{\varphi_1}(\Theta_{k+1}) d\Theta_{k+1}} = \arg \min_{f(\Theta_{k+1})} \phi(f(\Theta_{k+1}), \varphi). \quad (21)$$

Časová aktualizace statistik $\{\hat{\theta}_{k|k}, P_{\zeta;k|k}, \Sigma_{k|k}, \nu_{k|k}\}$

Mechanismus slučování se substitucí $\lambda_{k+1|k} \equiv \hat{\varphi}_0$ vede na aktualizaci

$$V_{k+1|k} = \lambda_{k+1|k} V_{k|k}, \quad (22)$$

$$\nu_{k+1|k} = \lambda_{k+1|k} \nu_{k|k}. \quad (23)$$

Automatické nastavování faktoru zapomínání

Hledání hodnoty parametru φ , který je maximem funkce

$$\hat{\varphi} = \arg \max_{\varphi} \min_{f(\Theta_{k+1})} \phi(f(\Theta_{k+1}), \varphi) \quad (24)$$

je ekvivalentní k hledání takového φ , který splňuje následující podmínky:

$$\mathcal{D}(\hat{f}(\Theta_{k+1}) \| f_i(\Theta_{k+1})) - \varrho_i = \mu, \quad \text{all } i \text{ such that } \varphi_i > 0 \quad (25)$$

$$\mathcal{D}(\hat{f}(\Theta_{k+1}) \| f_i(\Theta_{k+1})) - \varrho_i \leq \mu, \quad \text{all } i \text{ such that } \varphi_i = 0 \quad (26)$$



Výpočet faktoru zapomínání


Vyhodnotíme-li hodnotu faktoru zapomínání ($\lambda_{k+1|k} \equiv \hat{\varphi}_1$) podle uvedeného postupu, pak obdržíme výpočet

$$\begin{aligned} \lambda_{k+1|k}^{-1} = & 1 + \frac{\rho + 1}{p + 1} \left\{ \ln \left(\frac{|{}^{L}P_{\zeta} D_{k|k-1}|}{|{}^{L}P_{\zeta} D_{k|k}|} \right) \right. \\ & + \text{tr} (V_{\zeta; k|k-1} P_{\zeta; k|k} - I_p) + \nu_{k|k-1} \ln \left(\frac{\Sigma_{k|k}}{\Sigma_{k|k-1}} \right) \\ & - \nu_{k|k} (1 - \Sigma_{k|k-1} \Sigma_{k|k}^{-1}) \\ & + \frac{\nu_{k|k}}{\Sigma_{k|k}} (\hat{\theta}_{k|k} - \hat{\theta}_{k|k-1})' V_{\zeta; k|k-1} (\hat{\theta}_{k|k} - \hat{\theta}_{k|k-1}) \\ & \left. + (\nu_{k|k-1} - 1) \ln \left(\frac{\nu_{k|k-1}}{\nu_{k|k}} \right) + \frac{\nu_{k|k-1}}{\nu_{k|k}} + \nu_{k|k} - \nu_{k|k-1} - 1 \right\} \end{aligned} \quad (27)$$

Výpočet faktoru zapomínání - pokračování
doprovázený vztahem


$$V_{\zeta;k|k} = \underbrace{\lambda_{k|k-1} V_{\zeta;k-1|k-1}}_{V_{\zeta;k|k-1}} + \zeta_{M,k} \zeta'_{M,k} + R_{\zeta;k}, \quad (28)$$



kde $R_{\zeta;k}$ je submatice vnořená v prvních p řádcích a sloupcích matice R_k a $V_{\zeta;k|k} = P_{\zeta;k|k}^{-1}$.





Sledování náhle změny parametrů - Hammersteinuv model

- $y_k = -ay_{k-1} + \eta_1 u_{k-1} b + \eta_2 u_{k-1}^2 b + \eta_3 u_{k-1}^3 b + \varsigma + e_k$;
- $\theta_k = [a, \varsigma, \eta_1, \eta_2, \eta_3]'$ protože $b = 1 + a$;
- $\epsilon_k \equiv \|\theta_k - \hat{\theta}_{k|k}\|_2^2 \|\theta_k\|_2^{-2}$ je kritériem kvality odhadování;
- $e_k \sim \mathcal{N}(0, 10^{-4})$ a vstup u_k je rovnoměrně rozdělený na intervalu $[-2, 2]$;
- perioda vzorkování 1 s.












Sledování náhodné procházky parametrů - Hammersteinuv model



- $\theta_{k+1} = \theta_k + \bar{w}_k$, kde $\bar{w}_k \sim \mathcal{N}(0, \text{diag}[0, 0.1, 0.5, 0.5, 0.5])$.







Literatura

-  V. Peterka, “Bayesian approach to system identification,” in *Trends and Progress in System Identification*, P. Eykhoff, Ed. Oxford, U.K.: Pergamon, 1981, pp. 239–304.
-  J. Dokoupil, A. Voda, and P. Václavek, “Regularized extended estimation with stabilized exponential forgetting,” *IEEE Trans. Autom. Control*, vol. 62, no. 12, pp. 6513–6520, Dec. 2017.

