

Bodové procesy interagujících úseček

Markéta Zikmundová

Ústav matematiky
Fakulta chemicko inženýrská
Vysoká škola chemicko-technologická v Praze

15.září 2016

Motivace



Proces interagujících úseček

Uvažujme bodový proces úseček μ daný hustotou p vzhledem k Poissonovu procesu η ,

$$f(\mathbf{y}|\mathbf{x}) = c_{\mathbf{x}}^{-1} \exp(\mathbf{x} \cdot T(U_{\mu})), \quad (1)$$

kde U_{μ} je sjednocení úseček \mathbf{y} procesu μ .

Příklad. ($n = 3$.)

$$T(U_{\mu}) = (N(U_{\mu}), L(U_{\mu}), I(U_{\mu})),$$

kde

N. . . počet průsečíků

L. . . celková délka U_{μ}

I. . . počet izolovaných úseček.

A $\mathbf{x} = (x_1, x_2, x_3) \in (-\infty, 0) \times \mathbb{R} \times (-\infty, 0)$.

Časoprostorové rozšíření

Uvažujme nyní, že parametr $\mathbf{x}_{1:T}$ se vyvíjí v čase jako realizace markovského procesu $\mathbf{X}_{1:T}$ s

$$\mathbf{X}_t = \mathbf{X}_{t-1} + \gamma_t, \quad t = 1, \dots, T,$$

kde

γ_t i.i.d. Gaussovské $\mathcal{N}(\mathbf{a}, \sigma^2 I_d)$,

I_d ...jednotková matice $d \times d$,

$\theta = (\mathbf{a}, \mathbf{x}_0, \sigma^2)$, $\mathbf{a} \in \mathbb{R}^3$, $\mathbf{x}_0 \in \mathbb{R}^3$, $\sigma^2 > 0$.

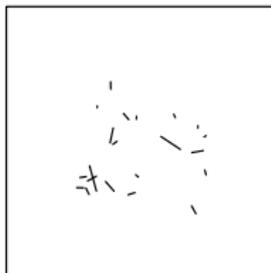
Kromě časové závislosti budeme uvažovat i prostorovou závislost (tj. některé úsečky z realizace v čase $t - 1$ se budou vyskytovat i v realizaci v čase t).

Takový proces můžeme nasimulovat pomocí Metropolisova–Hastingsova algoritmu s návrhovým rozdělením

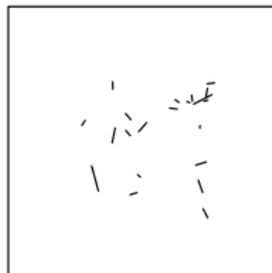
$$Prop_t = (1 - \beta) \cdot Prop^{(RP)} + \beta \cdot Prop_{t-1}^{(emp)}, \quad \beta \in (0, 1).$$

Cíl: Odhadnout parametry rozdělení \mathbf{x}_t a parametr β pomocí
částicového filtru

cas1



cas2



cas3



Částicový filtr

- Sekvenční Monte Carlo metoda
- Slouží k odhadu hustoty $p(\mathbf{x}_t|\mathbf{y}_{1:t})$
- Založen na Importance samplingu

$N > 0 \dots$ počet částic

Označme $\mathbf{X}_{0:t} = (\mathbf{X}_0, \dots, \mathbf{X}_t)$, $x_{0:t} = (\mathbf{x}_0, \dots, \mathbf{x}_t)$

Přechodová hustota

$$p(\mathbf{x}_t|\mathbf{x}_{t-1}) = \mathcal{N}(a + t_{t-1}, \sigma^2 I)$$

$p(\mathbf{x}_0) \dots$ počáteční rozdělení.

$$f(\mathbf{y}_k|\mathbf{x}_t) = c_{\mathbf{x}_t} \exp(\mathbf{x}_t G(U_y))$$

Algoritmus PF

- Vyber $\mathbf{x}_0 \sim p(\mathbf{x})$, polož $t = 1$.
 - Vyber $\mathbf{X}_1^k \sim q_\theta(\cdot | \mathbf{y}_1)$.
 - Spočti a znormuj váhy

$$w_1(\mathbf{X}_1^k) = \frac{p_\theta(\mathbf{X}_1^k | \mathbf{x}_0) f(\mathbf{y}_1 | \mathbf{X}_1^k)}{q_\theta(\mathbf{X}_1^k | \mathbf{y}_1)},$$

- V čase $t = 2, \dots, T$:
 - vyber $A_{t-1}^k \sim \mathcal{F}(\cdot | \tilde{w}_{t-1})$,
 - vyber $\mathbf{X}_t^k \sim q_\theta(\cdot | \mathbf{y}_t, \mathbf{X}_{t-1}^{A_{t-1}^k})$ a polož $\mathbf{X}_{1:t}^k = (\mathbf{X}_{1:t-1}^{A_{t-1}^k}, \mathbf{X}_t^k)$,
 - spočti a znormuj váhy

$$w_t(\mathbf{X}_{1:t}^k) = \frac{p_\theta(\mathbf{X}_t^k | \mathbf{X}_{t-1}^{A_{t-1}^k}) f(\mathbf{y}_t | \mathbf{X}_t^k)}{q_\theta(\mathbf{X}_t^k | \mathbf{y}_t, \mathbf{X}_{t-1}^{A_{t-1}^k})}.$$

Algoritmus II (PMMH):

[Andrieu, Doucet, Holenstein, 2010]

Inicializace: $i = 0$,

- zvol $\theta(0)$ libovolně,
- Spuště (SMC) algoritmus I zaměřený na $p_{\theta(0)}(\mathbf{x}_{1:T}|\mathbf{y}_{1:T})$, vyber $\mathbf{X}_{1:T} \sim \hat{p}_{\theta(0)}(\cdot|\mathbf{y}_{1:T})$ a nechtě $\hat{p}_{\theta(0)}(\mathbf{y}_{1:T})$ značí věrohodnostní odhad

Pro iteraci $i \geq 1$:

- vyber $\theta^* \sim q(\cdot|\theta(i-1))$,
- spuště SMC algoritmus I zaměřený na $p_{\theta^*}(\mathbf{x}_{1:T}|\mathbf{y}_{1:T})$,
- vyber $\mathbf{X}_{1:T}^* \sim \hat{p}_{\theta^*}(\cdot|\mathbf{y}_{1:T})$ a nechtě $\hat{p}_{\theta^*}(\mathbf{y}_{1:T})$ značí věrohodnostní odhad,

- s pravděpodobností

$$1 \wedge \frac{\hat{p}_{\theta^*}(\mathbf{y}_{1:T})p(\theta^*)}{\hat{p}_{\theta(i-1)}(\mathbf{y}_{1:T})p(\theta(i-1))} \frac{q(\theta(i-1)|\theta^*)}{q(\theta^*|\theta(i-1))}$$

polož $\theta(i) = \theta^*$, $\mathbf{X}_{1:T}(i) = \mathbf{X}_{1:T}^*$ a $\hat{p}_{\theta(i)}(\mathbf{y}_{1:T}) = \hat{p}_{\theta^*}(\mathbf{y}_{1:T})$, jinak polož

$\theta(i) = \theta(i-1)$, $\mathbf{X}_{1:T}(i) = \mathbf{X}_{1:T}(i-1)$ a $\hat{p}_{\theta(i)}(\mathbf{y}_{1:T}) = \hat{p}_{\theta(i-1)}(\mathbf{y}_{1:T})$.

Odhad $p_{\theta}(\mathbf{y}_{1:T})$:

$$\hat{p}_{\theta}(\mathbf{y}_{1:T}) := \hat{p}_{\theta}(\mathbf{y}_1) \prod_{t=2}^T \hat{p}_{\theta}(\mathbf{y}_t | \mathbf{y}_{1:t-1}),$$

$$\hat{p}_{\theta}(\mathbf{y}_t | \mathbf{y}_{1:t-1}) = \frac{1}{N} \sum w_t(X_{1:t}^k).$$

Částicový filtr - omezení

- Předpoklad: Pozorování $\{Y_t\}$ jsou podmíněně nezávislé při daném $\{X_t\}$.

Částicový filtr - omezení

- Předpoklad: Pozorování $\{Y_t\}$ jsou podmíněně nezávislé při daném $\{X_t\}$.
- Zjemnění: Proces $\{Y_t\}$ je Markovský řetězec při daném $\{X_t\}$.

Částicový filtr - omezení

- Předpoklad: Pozorování $\{Y_t\}$ jsou podmíněně nezávislé při daném $\{X_t\}$.
- Zjemnění: Proces $\{Y_t\}$ je Markovský řetězec při daném $\{X_t\}$.

$$\begin{aligned}
 p(\mathbf{x}_{1:T} | \mathbf{y}_{1:T}) &\propto p(\mathbf{x}_{1:T}, \mathbf{y}_{1:T}) \\
 &= p(\mathbf{x}_1) \prod_{t=2}^T p(\mathbf{x}_t | \mathbf{x}_{t-1}) \prod_{t=2}^T f(\mathbf{y}_{1:t} | \mathbf{x}_{1:t}) \\
 &= p(\mathbf{x}_1) \prod_{t=2}^T p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{y}_1 | \mathbf{x}_1) \prod_{t=2}^T p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{t-1})
 \end{aligned}$$

Simulace

Simulace

Běží

Simulace

Běží ...a ještě dlouho budou

