

# Vzorkovací schémata v částicovém filtru

David Coufal

KPMS MFF UK, ÚI AV ČR

david.coufal@cs.cas.cz

*ROBUST 2016*

*Kurzovní, Jeseníky, 13. září 2016*

## Agenda

- filtrační úloha
- částicový filtr
- vzorkovací schémata
- vlastnosti vzorkovacích schémat

## Signál

- necht'  $\{X_t, t = 0, 1, \dots\}$  je **Markovský řetězec** se spojitou množinou stavů  $X_t \in \mathbb{R}^{n_x}$ ,  $n_x \in \mathbb{N}$ .
- pravděpodobnostní chování MŘ je dáno **specifikací počátečního rozdělení**  $X_0$  pomocí příslušné hustoty  $p_0$
- **množinou přechodových jader**  $K_{t-1}(dx_t|x_{t-1})$  s hustotami  $K_{t-1}(x_t|x_{t-1})$  pro  $t = 1, \dots, T$ .

## Pozorování


- **observační proces**  $\{Y_t, t = 1, 2, \dots\}$ ,  $Y_t \in \mathbb{R}^{n_y}$   
určen pomocí funkce  $h_t$  na základě hodnot signálu  
a dále se předpokládá zašumění aditivním šumem  
formálně je observační proces definován:

$$Y_t = h_t(X_t) + V_t, \quad t > 0$$

$V_t$  je šum, tj. náhodná veličina o známé hustotě  $g_t$ .

## Úloha filtrace

- evoluce signálu a observačního procesu:



- **filtrační úloha** spočívá ve stanovení podmíněného rozdělení  $P_{X_t|Y_{1:t}}$  aktuálního stavu signálu  $X_t$  na základě pozorované historie  $Y_1 = y_1, \dots, Y_t = y_t$
- speciálně pouze stanovení **momentů** tohoto podmíněného rozdělení  $\int f(X_t) dP_{X_t|Y_{1:t}}$

## 1D - Gaussovský lineární proces

- 1D - Gaussovský lineární signál/observační proces

$$X_t = aX_{t-1} + b + cW_t, \quad Y_t = hX_t + gV_t, \quad t \geq 1.$$

- $a, b, c, h, g$  reálné parametry,  $c, g > 0$
- $X_0, W_1, V_1, W_2, V_2, \dots$  1D - normálně rozdělené n.v.
- $X_0 \sim \mathcal{N}(\mu_0, \sigma_0^2)$ , ostatní i.i.d.  $\sim \mathcal{N}(0, 1)$
- $\{X_t, t \geq 0\}$  Gaussovský Markovský řetězec

## 1D - Gaussovský proces, filtrační úloha

- **filtrační rozdělení** - podmíněná rozdělení:  $P_{X_t|Y_{1:t}}$
- rozdělení jsou **normální**, tj. určená odpovídajícími momenty (int. charakteristikami):

$$\hat{\mu}_t = \mathbb{E}[X_t | Y_{1:t}]$$

$$\hat{\sigma}_t^2 = \mathbb{E}[(X_t - \mu_t)^2 | Y_{1:t}]$$

- analytické řešení ve formě rekurenčních rovnic

## 1D - Kalmánův filtr

- 1D - Kalmánův filtr

$$\hat{\mu}_t = \frac{g^2}{v^2}b + \frac{c^2}{v^2}h\mathbf{y}_t + \frac{g^2}{v^2}a \frac{\hat{\sigma}_{t-1}^2 ah(\mathbf{y}_t - bh) + v^2 \hat{\mu}_{t-1}}{h^2 \hat{\sigma}_{t-1}^2 a^2 + v^2},$$

$$\hat{\sigma}_t^2 = \frac{g^4}{v^2}a^2 \frac{\hat{\sigma}_{t-1}^2}{h^2 \hat{\sigma}_{t-1}^2 a^2 + v^2} + \frac{g^2 c^2}{v^2}$$

pro  $v^2 = c^2 h^2 + g^2$ ,  $\hat{\mu}_0 = \mu_0$ ,  $\hat{\sigma}_0 = \sigma_0$



## Filtrační rozdělení

- sdružené rozdělení signálu a pozorování má tvar

$$p(x_{0:t}, y_{1:t}) = p_0(x_0) \prod_{k=1}^t g_k(y_k|x_k) K_{k-1}(x_k|x_{k-1}).$$

kde  $g_k(y_k|x_k) = g_k(y_t - h_t(x_t))$ .

- filtrační hustota - odpovídá podmíněné hustotou  $p(x_{0:t}|y_{1:t})$

$$p(x_t|y_{1:t}) = \frac{\int p(x_{0:t}, y_{1:t}) dx_{0:t-1}}{\int p(x_{0:t}, y_{1:t}) dx_{0:t}}$$

- filtrační rovnice

$$p(x_t|y_{1:t-1}) = \int K_{t-1}(x_t|x_{t-1}) p(x_{t-1}|y_{1:t-1}) dx_{t-1},$$
$$p(x_t|y_{1:t}) = \frac{g_t(y_t|x_t) p(x_t|y_{1:t-1})}{\int g_t(y_t|x_t) p(x_t|y_{1:t-1}) dx_t}, \quad t \in \mathbb{N}$$

## Částicový filtr

- sekvenčně generuje empirické míry aproximující filtrační rozdělení

$$\hat{\pi}_t^n(dx) \approx P_{X_t|Y_{1:t}} = p(x_t|y_{1:t}) dx_t$$

- aproximující empirická míra má tvar váženého součtu Dirakových měr založeném na nosiči  $\{w(\bar{x}_t^i), \bar{x}_t^i\}_{i=1}^n$

$$\hat{\pi}_t^n(dx_t) = \sum_{i=1}^n w(\bar{x}_t^i) \delta_{\bar{x}_t^i}(dx_t), \quad \sum_{i=1}^n w(\bar{x}_t^i) = 1$$

- **resampling**: uniformě vážená verze empirické míry založená na nosiči  $\{1/n, x_t^i\}_{i=1}^n$ , který vzniká z  $\{w(\bar{x}_t^i), \bar{x}_t^i\}_{i=1}^n$

$$\pi_t^n(dx_t) = \frac{1}{n} \sum_{i=1}^n \delta_{x_t^i}(dx_t)$$

## Částicový filtr - algoritmus

- **0. deklarace:**

$n$  - počet vzorků,

$T$  - výpočetní horizont,

$p_0(x_0)$  - hustota počátečního rozdělení  $\pi_0 \sim X_0$ ,

$K_{t-1}(x_t|x_{t-1})$ ,  $t = 1, \dots, T$ , - podmíněné přechodové hustoty

- **1. inicializace:**

$t = 0$ ,

vzorkování  $\{\bar{x}_0^i \sim p_0(dx_0)\}_{i=1}^n$ ,

sestavení emp. míry  $\hat{\pi}_0^n(dx_0) = \frac{1}{n} \sum_{i=1}^n \delta_{\bar{x}_0^i}(dx_0)$ ,

přiřazení  $\pi_0^n(dx_0) = \hat{\pi}_0^n(dx_0)$ , i.e.,  $\{x_0^i = \bar{x}_0^i\}_{i=1}^n$ .

- **2. importance sampling:**

$t = t + 1,$

vzorkování  $\{\bar{x}_t^i \sim K_{t-1}(dx_t | x_{t-1}^i)\}_{i=1}^n,$

pro  $i = 1:n$  výpočet vah

$$\tilde{w}(\bar{x}_t^i) = \frac{g_t(\mathbf{y}_t - h_t(\bar{x}_t^i))}{\sum_i g_t(\mathbf{y}_t - h_t(\bar{x}_t^i))},$$

sestavení emp. míry  $\hat{\pi}_t^n(dx_t) = \sum_{i=1}^n \tilde{w}(\bar{x}_t^i) \delta_{\bar{x}_t^i}(dx_t).$

- **3. resampling**

převzorkování  $\{1/n, x_t^i\}_{i=1}^n$  z  $\{w(\bar{x}_t^i), \bar{x}_t^i\}_{i=1}^n$

a sestavení emp. míry  $\pi_t^n(dx_t) = \frac{1}{n} \sum_{i=1}^n \delta_{x_t^i}(dx_t).$

- **4.** pokud  $t = T$  konec, jinak návrat do kroku 2.

## Konvergence částicového filtru

**Věta.** Nechť  $\pi_t^n$ ,  $t \geq 1$  je posloupnost empirických měr generovaných částicovým filtrem a  $\pi_t$ ,  $t \geq 0$  je posloupnost příslušných teoretických distribucí. Pak, pro všechna  $t \geq 1$  a  $f \in \mathcal{C}_b$  platí

$$\mathbb{E}[|\pi_t^n f - \pi_t f|^2] \leq \frac{c_t^2 \|f\|_\infty^2}{n}.$$

**Důkaz.** Doucet et. al. *SMC Methods in Practice*, Springer 2001.

## Multinomiální resampling

- výchozí stav  $\{w_i, \bar{x}_i\}_{i=1}^n$ , odpovídá empirické míře  $\hat{\pi}_t^n(dx)$
- výběr z vrácením z  $\{\bar{x}_i\}_{i=1}^n$  s pravděpodobnostmi  $\{p_i = w_i\}$  získáme nový soubor  $\{x_i\}_{i=1}^n$ , konstruujeme

$$\pi_t^n(dx) = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}(dx)$$

- hodnoty duplikací  $(N_1, \dots, N_n) \sim \mathcal{M}(n, w_1, \dots, w_n)$
- vlastnosti pro  $f \in \mathcal{C}_b$

$$\begin{aligned} \mathbb{E} \left[ \int f(x) \pi_t^n(dx) \right] &= \mathbb{E} \left[ \frac{1}{n} \sum_{i=1}^n f(x_i) \right] = \sum_{i=1}^n w_i f(x_i) = \int f(x) \hat{\pi}_t^n(dx) \\ \text{Var} \left[ \frac{1}{n} \sum_{i=1}^n f(x_i) \right] &= \frac{1}{n} \left\{ \sum_{i=1}^n w_i f^2(x_i) - \left( \sum_{i=1}^n w_i f(x_i) \right)^2 \right\} \end{aligned}$$

## Residuální resampling

- výchozí stav  $\{w_i, \bar{x}_i\}_{i=1}^n$ , odpovídá empirické míře  $\hat{\pi}_t^n(dx)$

$$1. R = \sum_{i=1}^n \lfloor nw_i \rfloor$$

$$2. \bar{w}_i = \frac{nw_i - \lfloor nw_i \rfloor}{n - R}$$

$$3. (\bar{N}_1, \dots, \bar{N}_n) \sim \mathcal{M}(n - R, \bar{w}_1, \dots, \bar{w}_n)$$

$$4. N_i = \lfloor nw_i \rfloor + \bar{N}_i \Rightarrow \{x_i\}_{i=1}^n$$

- vlastnosti pro  $f \in \mathcal{C}_b$

$$\mathbb{E} \left[ \frac{1}{n} \sum_{i=1}^n f(x_i) \right] = \int f(x) \hat{\pi}_t^n(dx)$$
$$\text{Var} \left[ \frac{1}{n} \sum_{i=1}^n f(x_i) \right] = \frac{1}{n} \left\{ \sum_{i=1}^n w_i f^2(x_i) - \left( \sum_{i=1}^n \frac{\lfloor nw_i \rfloor}{n} f^2(x_i) - \frac{n - R}{n} \sum_{i=1}^n \bar{w}_i f(x_i) \right) \right\}$$

## Stratifikovaný resampling

- výchozí stav  $\{w_i, \bar{x}_i\}_{i=1}^n$ , odpovídá empirické míře  $\hat{\pi}_t^n(dx)$

1.  $D_{inv}(u) = i$  jestliže  $u \in (\sum_{j=1}^{i-1} w_j, \sum_{j=1}^i w_j]$

2.  $(0, 1] = (0, 1/n] \cup \dots \cup (\{n-1\}/n, 1]$

3.  $U^i \sim R(\{n-1\}/n, 1]$

4.  $x_i = x_{D_{inv}(U_i)}$  pro  $i = 1, \dots, n$

- vlastnosti pro  $f \in \mathcal{C}_b$

$$\mathbb{E} \left[ \frac{1}{n} \sum_{i=1}^n f(x_i) \right] = \int f(x) \hat{\pi}_t^n(dx)$$

$$\text{Var} \left[ \frac{1}{n} \sum_{i=1}^n f(x_i) \right] = \frac{1}{n} \left\{ \sum_{i=1}^n w_i f^2(x_i) - \left( \sum_{i=1}^n n \int_{(i-1)/n}^{i/n} f(x_{D_{inv}(u)}) du \right)^2 \right\}$$



## Závěrečné poznámky

- reziduání a stratifikovaný sampling **mají menší rozptyl** než standardní multinomiální verze
- konvergence filtru pro všechny tři verze
- jádrové **odhady filtračních hustot?**
- **konvergence jádrových odhadů** hustot filtračních rozdělání  
(*D. Coufal. Kernel methods in particle filtering, to appear in Kybernetika*)
- **rychlost konvergence** v závislosti na verzi resamplingu

Děkuji za pozornost !!!