

# Lokalizace v týmu robotů


Miroslav Kulich

Intelligent and Mobile Robotics Group  
Gerstner Laboratory for Intelligent Decision Making and Control  
Czech Technical University in Prague


28/02/2014

## Lokalizace v týmu robotů

- Každý se lokalizuje samostatně
  - Odhad maximální věrohodnosti (maximum likelihood estimation)
  - Částicový filtr
  - Rozšířený Kalmanův filtr
- 
- Mluvíme o lokalizaci, tj. mapa prostředí je známa.
  - Existují i metody SLAM pro tým robotů, ale těmi se zabývat nebudeme.



# Odhad maximální věrohodnosti



## Vstup:

- Množina měření:  $O = \{o\}$ , kde  $o = (\mu, \Sigma, r_a, t_a, r_b, t_b)$ ,  $\mu$  je změřená pozice robotu  $r_b$  v čase  $t_b$  relativně k robotu  $t_a$  v čase  $t_a$ .
  - Odometrie:  $o = (\mu, \Sigma, r_a, t_a, r_a, t_b)$
  - Měření:  $o = (\mu, \Sigma, r_a, t_a, r_b, t_b)$

## Výstup:

- Množina odhadů pozic:  $H = \{h\}$ , kde  $h = (\hat{q}, r, t)$ ,  $\hat{q}$  je odhad pozice robotu  $r$  v čase  $t$ .

## Odhad maximální věrohodnosti

- Chceme nalézt množinu pozic  $H$ , která maximalizuje pp. množiny měření  $O$ , tj. maximalizuje  $P(O|H)$ .
- Předpokládáme, že měření jsou nezávislá:

$$P(O|H) = \prod_{o \in O} P(o|H)$$

- Po logaritmování **minimalizujeme**:

$$U(O|H) = \sum_{o \in O} U(o|H),$$

kde  $U(O|H) = -\log P(O|H)$  a  $U(o|H) = -\log P(o|H)$

- Předpokládáme normální rozložení pro nejistotu měření:


$$U(o|H) = \frac{1}{2}(\mu - \hat{\mu})^T \Sigma (\mu - \hat{\mu})$$

- Model pohybu:  $\hat{\mu} = \Gamma(\hat{q}_a, \hat{q}_b)$
- Minimalizace standardními numerickými technikami (gradientní, steepest descent)

# Odhad maximální věrohodnosti

## Praktické poznámky

- Dimenze problému roste lineárně s  $H$  a každý krok optimalizačního procesu roste lineárně s  $O$ .
- Pro snížení složitosti aplikujeme:
  - Neuvažujeme stará měření.
  - Vyřadíme podobná měření.
  - Omezíme frekvenci, s kterou jsou generovány pozice.



# Částicový filtr

- Rozšíření standardního částicového filtru.
- Integrace *detekce* - jeden robot „vidí“ druhý.
- Naivní přístup: stavový prostor zahrnuje pozice všech robotů:

$$x_t = x_t^1 \times x_t^2 \dots x_t^N$$

- Dimenze roste lineárně s počtem robotů a počet distribucí  $x_t$  pak exponenciálně.
- Faktorizace:

$$p(x_t^1, x_t^2, \dots, x_t^N | d^{(t)}) = p(x_t^1 | d^{(t)}) \cdot p(x_t^2 | d^{(t)}) \cdot \dots \cdot p(x_t^N | d^{(t)})$$

- Každý robot si udržuje pouze svou vlastní pozici a pouze pokud robot detekuje jiný robot, dochází k výměně informací.
- Je to pouze aproximace, pozice robotů nejsou nezávislé!

# Částicový filtr

- Předpokládáme následující data:
  - Odometrie - integrace pohybu

$$Bel(x_t^n) = \int p(x_t^n | x_{t-1}^n, u_t^n) Bel(x_{t-1}^n)$$

- Sensorické měření

$$Bel(x_t^n) = p(z | x_t^n) Bel(x_t^n)$$

- Detekce jednoho robotu druhým

# Částicový filtr

Odvození vztahu pro detekci

- Robot  $R_n$  detekuje měřením  $r_t^m$  robot  $R_m$ .

$$\begin{aligned} Bel(x_t^n) &= p(x_t^n | d_{(t)}^n) \\ &= p(x_t^n | d_{(t-1)}^n) p(x_t^n | d_t^m) \\ &= p(x_t^n | d_{(t-1)}^n) \int p(x_t^n | x_t^m, r_t^m) p(x_t^m | d_{(t-1)}^m) \end{aligned}$$

- Což vede k následujícímu vztahu:

$$Bel(x_t^n) = Bel(x_{t-1}^n) \int p(x_t^n | x_t^m, r_t^m) Bel(x_t^m) dx_t^m$$

- Aktualizace pozice  $m$ -tého robotu se provede symetricky.





# Částicový filtr

## Implementace

- Rozšíření částicového filtru pro více robotů není přímočaré – neumíme násobit dvě množiny vzorků ve vztahu

$$Bel(x_t^n) = Bel(x_{t-1}^n) \int p(x_t^n | x_t^m, r_t^m) Bel(x_t^m) dx_t^m$$

- Idea: transformace množiny vzorků pro  $m$  do tzv. stromu hustot (*density tree*):
  - Rekurzivní dělení prostoru podle nejdelší dimenze.
  - Hustota uzlu (listu) je suma vah vzorků dělená objemem uzlu.
  - Váha každého vzorku pro  $R_n$  je násobena hustotami.



# Částicový filtr

## Problémy

- Frekvence detekce je vysoká  $\rightsquigarrow$  jedna detekce se integruje hodně krát.
- Je nutná identifikace robotů.
- False-positive detekce - roboty se „vidí“ relativně málo, pak i malé procento false-positive hraje velkou roli.
- Pouze pozitivní informace - negativní informace lze obecně zahrnout, ale je to výpočetně náročné.
- Zpožděná integrace - pokud je velká nejistota v určení pozice obou robotů, pak lze s integrací detekce počkat. Je ale nutno udržovat informaci o všech akcích a měřeních.

## Rozšířený Kalmanův filtr

- Konfigurace  $i$ -tého robotu  $X_i = (x_i, y_i, \theta_i)$
- Chceme odhadovat stav

$$X = (X_1, X_2, \dots, X_N)$$

- Kovarianční matice:

$$\Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} & \dots & \Sigma_{1N} \\ \Sigma_{21} & \Sigma_{22} & \dots & \Sigma_{2N} \\ \dots & \dots & \dots & \dots \\ \Sigma_{N1} & \Sigma_{N2} & \dots & \Sigma_{NN} \end{pmatrix}$$

# Rozšířený Kalmanův filtr

## Korekce (integrace měření)

$$K = \Sigma H^T (H \Sigma H^T + Q)^{-1}$$

$$\mu = \mu + K(z - h(\mu))$$

$$\Sigma = (E - KH)\Sigma$$

- Funkce detekce ( $i$ -tý robot „vidí“  $j$ -tý)

$$z = h(X_i, X_j) + w$$

- Jakobián  $H$ :

$$H = (0, \dots, 0, H_i, 0, \dots, 0, H_j, 0, \dots, 0),$$

- z toho

$$H \Sigma H^T + Q = H_i \Sigma_{ii} H_i^T + H_i \Sigma_{ij} H_j^T + H_j \Sigma_{ji} H_i^T + H_j \Sigma_{jj} H_j^T + Q = P_{zz}$$

$$\mu_l = \mu_l + (\Sigma_{li} H_i^T + \Sigma_{lj} H_j^T) P_{zz}^{-1} (z - h(\mu_i, \mu_j))$$

$$\Sigma_{lf} = \Sigma_{lf} - (\Sigma_{li} H_i^T + \Sigma_{lj} H_j^T) P_{zz}^{-1} (H_i \Sigma_{if} + H_j \Sigma_{jf})$$

## Rozšířený Kalmanův filtr

- Vzdálenost:

$$h_d(X_i, Y_i) = \sqrt{\Delta x^2 + \Delta y^2}$$

$$H_i^d = \left( \frac{-\Delta x}{\sqrt{\Delta x^2 + \Delta y^2}}, \frac{-\Delta y}{\sqrt{\Delta x^2 + \Delta y^2}}, 0 \right)$$

$$H_j^d = \left( \frac{\Delta x}{\sqrt{\Delta x^2 + \Delta y^2}}, \frac{\Delta y}{\sqrt{\Delta x^2 + \Delta y^2}}, 0 \right)$$

- Relativní směr:

$$h_b(X_i, Y_i) = \arctan \left( \frac{-\sin \theta_i \Delta x + \cos \theta_i \Delta y}{\cos \theta_i \Delta x + \sin \theta_i \Delta y} \right)$$

$$H_i^b = \left( \frac{\Delta y}{\Delta x^2 + \Delta y^2}, \frac{-\Delta x}{\Delta x^2 + \Delta y^2}, -1 \right)$$

$$H_j^b = \left( \frac{-\Delta y}{\Delta x^2 + \Delta y^2}, \frac{\Delta x}{\Delta x^2 + \Delta y^2}, 0 \right)$$

# Rozšířený Kalmanův filtr

- Relativní orientace:

$$h_o(X_i, Y_i) = \theta_j - \theta_i$$

$$H_i^o = (0, 0, -1)$$

$$H_j^o = (0, 0, 1)$$

$$\Delta x = x_j - x_i$$

$$\Delta y = y_j - y_i$$