

SLAM - Současná Lokalizace A Mapování


Miroslav Kulich

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


5/12/2012

SLAM - Současná Lokalizace A Mapování


- Úloha stavby modelu prostředí, zatímco se současně určuje pozice robotu relativně k takto budovanému modelu.
- O hodně těžší než samostatná lokalizace nebo mapování.
- Problém slepice a vejce: k lokalizaci potřebujeme mapu \times znalost pozice je nutná ke stavbě mapy.
- Mějme: řízení robotu, sensorická měření.
- Odhadujeme: mapu (příznakovou, mřížka obsazenosti), cestu robotu.
- Stav: $\langle x, y, \theta, map \rangle$
- Mapa:
 - Příznaková: $\langle l_1, l_2, \dots, l_n \rangle$
 - Grid: $\langle c_{11}, c_{12}, \dots, c_{1n}, \dots, c_{mn} \rangle$



Struktura SLAM pro příznakovou mapu




Proč je SLAM těžký problém?




- V reálném světě je korespondence mezi měřením a ladmarkem neznámá (musíme ji určit).
- Určení špatné asociace může mít katastrofické následky.
- Chyba určení pozice souvisí se správným určením asociace.

Problém určení asociací



- Asociace dat spočívá v přiřazení pozorování ladmarkům.
- Obecně existuje pro n měření a m landmarků **???** možných přiřazení.
- "Data association" nebo "assignment problem"

Problém určení asociací



- Asociace dat spočívá v přiřazení pozorování landmarkům.
- Obecně existuje pro n měření a m landmarků $\binom{m}{n}$ možných přiřazení.
- "Data association" nebo "assignment problem"



SLAM

Full SLAM

- Odhad celé cesty a mapy
- $p(x_{1:t}, m | z_{1:t}, u_{1:t})$

Online SLAM

- item Odhad aktuální pozice a mapy
- $$p(x_t, m | z_{1:t}, u_{1:t}) = \int \int \dots \int p(x_{1:t}, m | z_{1:t}, u_{1:t}) dx_1 dx_2 \dots dx_{t-1}$$
- Integrace se typicky provádí vždy jedna v čase



Techniky generování konzistentní mapy

- Scan matching
- EKF-SLAM
- Fast-SLAM
- Pravděpodobnostní mapování s jednou mapou a posterior pozic
- Graph-SLAM
- Sparse Extended Information Filters (SEIFs)
- RAT-SLAM, ...

Scan matching

- Maximalizace víry v i -tou pozici a v mapu relativně k $(i - 1)$ -té pozici a mapě.

$$\hat{x}_t = \arg \max_{x_t} \left\{ p(z_t | x_t, \hat{m}^{[t-1]}) p(x_t | u_{t-1}, \hat{x}_{t-1}) \right\}$$

- Vytvářej mapu $\hat{m}^{[t]}$ mapováním se známou pozicí s tím, že známe pozice a pozorování.

EKF-SLAM

- Příznaková mapa (počet landmarků < 1000)
- Stav:
 $s_t = (x_t, m)^T = (x, y, \theta, l_{1,x}, l_{1,y}, l_{2,x}, l_{2,y}, \dots, l_{n,x}, l_{n,y})^T$
- Předpokládáme znalost asociace
- Uvažuje se pouze pozitivní informace
- PDF je reprezentována hodně-dimenzionálním Gausiánem (3+2n)

$$\text{Bel}(x_t, m_t) = \begin{pmatrix} x \\ y \\ \theta \\ l_1 \\ l_2 \\ \vdots \\ l_n \end{pmatrix}, \quad \begin{pmatrix} \sigma_x^2 & \sigma_{xy} & \sigma_{x\theta} & \sigma_{xl_1} & \sigma_{xl_2} & \dots & \sigma_{xl_n} \\ \sigma_{xy} & \sigma_y^2 & \sigma_{y\theta} & \sigma_{yl_1} & \sigma_{yl_2} & \dots & \sigma_{yl_n} \\ \sigma_{x\theta} & \sigma_{y\theta} & \sigma_\theta^2 & \sigma_{\theta l_1} & \sigma_{\theta l_2} & \dots & \sigma_{\theta l_n} \\ \sigma_{xl_1} & \sigma_{yl_1} & \sigma_{\theta l_1} & \sigma_{l_1 l_1}^2 & \sigma_{l_1 l_2} & \dots & \sigma_{l_1 l_n} \\ \sigma_{xl_2} & \sigma_{yl_2} & \sigma_{\theta l_2} & \sigma_{l_1 l_2} & \sigma_{l_2}^2 & \dots & \sigma_{l_2 l_n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ \sigma_{xl_n} & \sigma_{yl_n} & \sigma_{\theta l_n} & \sigma_{l_n l_1} & \sigma_{l_n l_2} & \dots & \sigma_{l_n}^2 \end{pmatrix}$$

- Matice K (zesílení) je/není? řídka:

EKF-SLAM


- Příznaková mapa (počet landmarků < 1000)
- Stav:

$$s_t = (x_t, m)^T = (x, y, \theta, l_{1,x}, l_{1,y}, l_{2,x}, l_{2,y}, \dots, l_{n,x}, l_{n,y})^T$$
- Předpokládáme znalost asociace
- Uvažuje se pouze pozitivní informace
- PDF je reprezentována hodně-dimenzionálním Gausiánem $(3+2n)$


$$Bel(x_t, m_t) = \begin{pmatrix} x \\ y \\ \theta \\ l_1 \\ l_2 \\ \vdots \\ l_n \end{pmatrix}, \begin{pmatrix} \sigma_x^2 & \sigma_{xy} & \sigma_{x\theta} & \sigma_{xl_1} & \sigma_{xl_2} & \dots & \sigma_{xl_n} \\ \sigma_{xy} & \sigma_y^2 & \sigma_{y\theta} & \sigma_{yl_1} & \sigma_{yl_2} & \dots & \sigma_{yl_n} \\ \sigma_{x\theta} & \sigma_{y\theta} & \sigma_\theta^2 & \sigma_{\theta l_1} & \sigma_{\theta l_2} & \dots & \sigma_{\theta l_n} \\ \sigma_{xl_1} & \sigma_{yl_1} & \sigma_{\theta l_1} & \sigma_{l_1}^2 & \sigma_{l_1 l_2} & \dots & \sigma_{l_1 l_n} \\ \sigma_{xl_2} & \sigma_{yl_2} & \sigma_{\theta l_2} & \sigma_{l_1 l_2} & \sigma_{l_2}^2 & \dots & \sigma_{l_2 l_n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ \sigma_{xl_n} & \sigma_{yl_n} & \sigma_{\theta l_n} & \sigma_{l_n l_1} & \sigma_{l_n l_2} & \dots & \sigma_{l_n}^2 \end{pmatrix}$$

- Matice K (zesílení) není řádká: měření landmarku zlepšuje znalost o pozici landmarku i robotu.


EKF-SLAM




EKF-SLAM



EKF-SLAM




Když asociace nejsou známy



Bylo pozorování generováno modrým nebo červeným landmarkem?

Když asociace nejsou známy



Bylo pozorování generováno modrým nebo červeným landmarkem?

$$p(\text{observation} | \text{red}) = 0.3 \quad p(\text{observation} | \text{blue}) = 0.7$$

- Dva přístupy:
 - Vezmi nejpravděpodobnější možnost.
 - Vezmi náhodnou možnost váženě podle podmíněných pravděpodobností měření.
- Jestliže pravděpodobnost je příliš malá, generuj nový landmark.
- Každé měření je zpracováváno samostatně: jeden landmark může korespondovat s více měřeními.





EKF-SLAM

- EKF-SLAM je online: předchozí pozice jsou „schovány“ v kovarianční matici.
- Inicializace landmarků:
 - Do nuly: $(0, 0, 0)$
 - Na první měření landmarku:

$$\begin{pmatrix} \mu_{j,x} \\ \mu_{j,y} \end{pmatrix} = \begin{pmatrix} \mu_{t,x} \\ \mu_{t,y} \end{pmatrix} + \begin{pmatrix} r_t^i \cos(\phi_t^i + \mu_{j,\phi}) \\ r_t^i \sin(\phi_t^i + \mu_{j,\phi}) \end{pmatrix}$$

- Sensory měřící pouze směr (kamera): integrace více měření.
- Filtrace chybných měření (outliers): provizorní seznam landmarků.
- Pravděpodobnost existence landmarku: poměr log odds
- Numerická nestabilita: inicializace odhadu nového landmarku.

EKF-SLAM: příklad



Lokalizace vs. SLAM

- Částicový filtr může být použit k řešení obou problémů.
- Lokalizace: stavový prostor $\langle x, y, \theta \rangle$.
- SLAM: stavový prostor $\langle x, y, \theta, \text{mapa} \rangle$.
 - pro mapy příznaků: $\text{mapa} = \langle l_1, l_2, \dots, l_n \rangle$
 - pro mřížky: $\text{mapa} = \langle c_{1,1}, c_{1,2}, \dots, c_{1,n}, c_{2,1}, \dots, c_{n,m} \rangle$

Lokalizace vs. SLAM

- Částicový filtr může být použit k řešení obou problémů.
- Lokalizace: stavový prostor $\langle x, y, \theta \rangle$.
- SLAM: stavový prostor $\langle x, y, \theta, \text{mapa} \rangle$.
 - pro mapy příznaků: $\text{mapa} = \langle l_1, l_2, \dots, l_n \rangle$
 - pro mřížky: $\text{mapa} = \langle c_{1,1}, c_{1,2}, \dots, c_{1,n}, c_{2,1}, \dots, c_{n,m} \rangle$
- **Problém:** Počet částic reprezentujících posterior roste exponenciálně s dimenzí stavového prostoru!

Závislosti

Jak omezit dimenzi stavového prostoru

- Lze nalézt závislost mezi dimenzemi stavového prostoru?
- Pokud ano, jsme schopni tuto závislost použít k zjednodušení stavového prostoru?

Závislosti

Jak omezit dimenzi stavového prostoru

- Lze nalézt závislost mezi dimenzemi stavového prostoru?
- Pokud ano, jsme schopni tuto závislost použít k zjednodušení stavového prostoru?
- V kontextu SLAMu
 - Mapa závisí na pozicích robotu.
 - Umíme stavět mapu, pokud jsou pozice známy.

Rozklad posteriorní pravděpodobnosti (landmarky)

Pozice Mapa Měření Akce

$p(x_{1:t}, l_{1:m} | z_{1:t}, u_{0,t-1}) =$


$p(x_{1:t} | z_{1:t}, u_{0,t-1}) p(l_{1:m} | x_{1:t}, z_{1:t})$

SLAM posterior Posterior cesty Pozice landmarků

Pomůže tento rozklad řešit náš problém?

Faktorizace byla představena v roce 1999 Robin Murphy.

Mapování s landmarky



Díky

znalosti pozice robotu se pozice landmarků stávají na sobě nezávislými!

Rozklad posteriorní pravděpodobnosti

$$\begin{aligned} p(x_{1:t}, l_{1:m} | z_{1:t}, u_{0,t-1}) \\ &= p(x_{1:t} | z_{1:t}, u_{0,t-1}) p(l_{1:m} | x_{1:t}, z_{1:t}) \\ &= p(x_{1:t} | z_{1:t}, u_{0,t-1}) \prod_{i=1}^m p(l_i | x_{1:t}, z_{1:t}) \end{aligned}$$

Posterior cesty × Podmíněně nezávislé pozice landmarků


Rao-Blackwellizace

$$\begin{aligned} p(x_{1:t}, l_{1:m} | z_{1:t}, u_{0,t-1}) \\ = p(x_{1:t} | z_{1:t}, u_{0,t-1}) \prod_{i=1}^m p(l_i | x_{1:t}, z_{1:t}) \end{aligned}$$

- Tato faktorizace se jmenuje Rao-Blackwellizace
- V okamžiku, kdy budeme druhou část vztahu umět počítat efektivně, budeme moci použít částicový filtr.


FastSLAM

- Rao-Blackwellizovaný částicový filtr založený na příznakové mapě (Montemerlo et al., 2002)
- Každý landmark je reprezentovaný rozšířeným Kalmanovým filtrem velikosti 2×2 .
- Každá částice tedy zahrnuje M EKF.



Asociace dat s více hypotézami

- Asociace je prováděna pro každou částici zvlášť.




Výsledky - Victoria Park

- Délka trajektorie: 4 km
- Chyba pozice < 5 m RMS
- 100 částic


Modrá=GPS

Žlutá=FastSLAM




Data: University of Sydney

Výsledky - Asociace dat




Výsledky - Přesnost




FastSLAM - závěr

- FastSLAM je fullSLAM a online SLAM.
- Složitost $O(nm)$ může být zlepšena na $O(n \log m)$.
- Neznámé korespondence: podobně jako v EKF-SLAM (pro každou částici zvlášť).
- Model pohybu nekorresponduje s požadovanou distribucí \Rightarrow vzorkování s ohledem na sensorický model.
- Umí uvažovat také negativní informaci.



FastSLAM - lepší návrh vzorkování

Návrh vzorků se adaptuje na strukturu prostředí



SLAM na mřížce

- Můžeme řešit SLAM problém, pokud nemáme předdefinované landmarky?
- Můžeme použít idee FastSLAMu pro stavbu mřížky obsazenosti?
- Stejně jako pro landmarky, mapa závisí na pozicích robotu během sensorického měření.
- Pokud jsou tyto pozice známy, je mapování jednoduché („mapování se známými pozicemi“).

Rao-Blackwellizace

Pozice Mapa Měření Akce

$$p(x_{1:t}, m | z_{1:t}, u_{0,t-1}) =$$

↑
SLAM posterior

$$p(x_{1:t} | z_{1:t}, u_{0,t-1}) p(m | x_{1:t}, z_{1:t})$$

↑
Posterior cesty

↑
Mapování se známými pozicemi

Rao-Blackwellizace


$$p(x_{1:t}, m | z_{1:t}, u_{0,t-1}) = p(x_{1:t} | z_{1:t}, u_{0,t-1}) p(m | x_{1:t}, z_{1:t})$$

- Pro lokalizaci použij částicový filtr.
- Použij odhad pozice z MCL a aplikuj mapování se známými pozicemi.

FastSLAM na mřížce

Algoritmus

- for $k = 1$ to m
 - Vyber částici z předchozí generace.
 - Modifikuje částici dle modelu pohybu.
 - Spočítej váhu podle modelu senzoru.
 - Aktualizuj mapu příslušnou k částici.



FastSLAM se zlepšenou odometrií

- Scan-matching poskytuje lokálně konzistentní korekci pozice.
- Scan-matchingem korigované krátké sekvence odometrie se použijí jako vstup FastSLAMu.
- Je potřeba menší počet částic, neboť vstupní chyba je malá.

[Haehnel et al., 2003]

Závěr

- Myšlenky FastSLAMu lze relativně snadno aplikovat na mřížky obsazenosti.
- Využití přesných senzorických měření vede k dobrým odhadům a vysoce efektivním filtrům.
- Tento postup je podobný scan-matchingu pro každou částici.
- Počet částic a převzorkování může být významně redukováno.
- Vylepšená verze FastSLAMu na mřížce může být použita pro rozlehlejší prostředí v reálném čase, protože potřebuje o řád méně částic.