

MAP MAKING USING PARTICLE FILTERS

Petr Izrael

Bachelor Degree Programme (3), FIT BUT

E-mail: xizrae00@stud.fit.vutbr.cz

Supervised by: Jaroslav Rozman

E-mail: rozmanj@fit.vutbr.cz

ABSTRACT

This document describes basics of automatic map making based on odometry and sensor data of a robot. This task is also known as SLAM (Simultaneous Localization and Mapping). Described approach can use both data from laser scanner and sonar to create a two-dimensional map of explored environment. The use of particle filters and grid-based maps for this problem is today one of the most popular solution.

PODĚKOVÁNÍ

Tato práce vznikla částečně za podpory grantu VUT FIT, FIT-S-10-1 a specifického výzkumu MSM0021630528.

1 ÚVOD

Tato práce má za cíl vysvětlit základy automatické tvorby map prostředí pomocí částicových filtrů a laserového scanneru nebo sonaru. Tvorba map prostředí je úkol určený pro pohyblivého (mobilního) robota a je také znám pod názvem Simultánní lokalizace a mapování (SLAM), protože úkolem robota není pouze mapovat své okolí, ale také musí být schopen v postupně vytvářené mapě určit svojí polohu, aby poznal, kde přesně nově zmapované prostory navazují na původní mapu.

2 ROZBOR

2.1 MŘÍŽKOVÉ MAPY S PRAVDĚPODOBNOSTÍ OBSAZENOSTI

Jeden bod v mřížce odpovídá skutečné dvourozměrné ploše o velikosti dané rozlišením mapy. Bod v mřížce nabývá hodnoty od 0 do 1. Tato hodnota určuje pravděpodobnost, že odpovídající reálný prostor je obsazen. Pokud charakter mapovaného prostředí není vůbec znám, všechny body inicializujeme hodnotou 0,5. Cílem mapování je přiblížit pravděpodobnost obsazenosti co největšího počtu bodů mapy ke krajním hodnotám (0 resp. 1). (Tato část byla volně převzata z [2])

2.2 LOKALIZACE ROBOTY - BAYESŮV FILTR

Svou pozici robot nemůže určit pouze pomocí odometrie, která je sama o sobě pouze velice přibližným ukazatelem polohy. Namísto toho se využívá pravděpodobnostního přístupu, při kterém se pracuje s pravděpodobnostním rozložením pozice nad všemi možnými pozicemi robota. Přístup pomocí částicových filtrů vychází z tzv. rekurzivního Bayesova filtru [1]:

$$bel(x_t) \propto p(z_t|x_t) \int p(x_t|x_{t-1}, u_t) bel(x_{t-1}) dx_{t-1} \quad (1)$$

x_t značí pozici robota v čase t . z_t a u_t označuje měření sensorů a řídicí data v čase t . Za řídicí data můžeme považovat rozdíl dvou po sobě jdoucích dat odometrie. Popisuje se jimi tedy změna pozice robota. $bel(x_t)$ odpovídá výrazu $p(x_t|z_{1..t}, u_{1..t})$. Jedná se o zkratku z anglického slova belief (víra) a označuje souhrně znalost o pozici robota, tedy pravděpodobnostní rozložení pozice. Jak je vidět, pro reálnou implementaci výše zmíněného algoritmu je nutno vyřešit několik problémů:

1. Způsob, jakým budeme reprezentovat rozdělení pravděpodobnosti pozice robota $bel(x_t)$, tedy znalosti o vlastní pozici.
2. Výpočet $p(x_t|x_{t-1}, u_t)$ - tj. implementaci pohybového modelu robota
3. Výpočet $p(z_t|x_t)$ - tj. implementaci modelu sensorů

2.3 MONTE CARLO LOKALIZACE

Monte Carlo lokalizace je zažitý název pro lokalizační algoritmus, využívající částicových filtrů pro vyřešení prvního problému výše uvedeného seznamu. [1] Pomocí částicového filtru můžeme pozici robota reprezentovat množinou vážených částic. Každá částice představuje jednu hypotetickou pozici, které je přiřazena váha, určující pravděpodobnost, že se pozice částice blíží skutečné pozici robota. V praxi se používají až stovky částic (ale i desetitisíce, pokud o počáteční poloze nemáme žádné znalosti).

Základní algoritmus MCL Lokalizace pracuje v nekonečné smyčce ve třech fázích, akce v každé fázi se aplikuje na všech M částic [1]:

1. **Predikce** - Náhodné vzorkování nové částice x_t využitím řídicích dat, předchozí polohy částice a pohybového modelu robota. Jinými slovy vzorkování z hustoty pravděpodobnosti $p(x_t|x_{t-1}, u_t)$.
2. **Korekce** - Každé částici je přiřazena váha, která určuje pravděpodobnost, že částice odpovídá realné pozici. Zde se využívá měření sensorů, které se porovnávají s dosud vytvořenou mapou.
3. **Převzorkování** - Částice s nízkým váhovým ohodnocením se vypustí, naopak částice s vysokou pravděpodobností se znásobí. Převzorkování se nemusí provádět vždy, ale jen pokud jsou váhy významného množství částic blízké nule.

2.4 MAPOVÁNÍ

Rozšířením MCL lokalizace tak, že jedna částice představuje kromě možné polohy také jednu možnou mapu získáme jednoduchý, ale výpočetně velmi náročný SLAM algoritmus (viz algoritmus 1, s úpravami převzato z [1]).

Algoritmus 1: Základní SLAM s využitím částicových filtrů (jedna iterace)

Vstup: Množina částic χ_{t-1}, u_t, z_t

for $k = 1$ to M **do**

```
     $x_t^{[k]} = \text{sample\_motion\_model}(u_t, x_{t-1}^{[k]})$   
     $w_t^{[k]} = \text{measurement\_model\_map}(z_t, x_t^{[k]}, m_{t-1}^{[k]})$   
     $m_t^{[k]} = \text{updated\_occupancy\_grid}(z_t, x_t^{[k]}, m_{t-1}^{[k]})$   
     $\tilde{\chi}_t = \tilde{\chi}_t + \langle x_t^{[k]}, m_t^{[k]}, w_t^{[k]} \rangle$ 
```

end

return $\chi_t = \text{resample}(\tilde{\chi}_t)$

Funkce **sample_motion_model** využívá model popisující chybu odometrie (viz predikční fáze MCL algoritmu). V praxi se často využívá pro popis chyby odometrie gaussový šum. V zájmu snížení celkového počtu částic je vhodné, aby byl model popsán co nejpřesněji, případně se mohou využít i úplně jiné metody pro aktualizaci částic, založené např. na scan-matchingu [3].

Funkce **measurement_model_map** odpovídá fázi korekce MCL algoritmu. Pro každou částici se v této funkci vypočítá pravděpodobnost získaného měření pomocí dosud zkonstruované mapy a techniky zvané ray casting.

Funkce **updated_occupancy_grid** aktualizuje dané částici její mapu na základě nového měření. Pravděpodobnost obsazenosti v místech, které odpovídají změřené vzdálenosti, stoupne, kdežto pravděpodobnost v místech, které jsou blíže, klesne.

Funkce **resample** slouží pro převzorkování množiny částic a byla přiblížena v předchozí sekci.

3 ZÁVĚR

Simultánní lokalizace a mapování je velmi složitý problém a jeho vyřešení se obecně považuje za jeden z velkých úspěchů současné robotiky. Cílem projektu je vhodně upravit základní algoritmus tak, aby bylo možné v rozumném čase rekonstruovat přesné mapy z různých datových sad (výpis měření odometrie a senzorů - dostupné např. na <http://cres.usc.edu/radishrepository/view-all.php>).

REFERENCE

- [1] Thrun, S.; Burgard, W.; Fox, D.: Probabilistic Robotics. MIT Press, 2005, iISBN 978-0-262-20162-9.
- [2] Siegwart, R.; Nourbakhsh, I. R.: Introduction to Autonomous Mobile Robots. MIT Press, 2004, iISBN 978-0-262-19502-7.
- [3] Grisetti G.; Stachniss C.; Burgard, W.: Improving Grid-based SLAM with Rao-Blackwellized Particle Filters by Adaptive Proposals and Selective Resampling, 2005.