

# Lokalizace v mobilní robotice


Miroslav Kulich

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

28/02/2014


# Lokalizace

- Lokalizace je problém **určení pozice robotu**
  - relativně vzhledem k počáteční pozici robotu
  - v daném systému souřadnic (ve známé mapě)
- Pozice je uvažována včetně natočení! tj.  $(x, y, \phi)$ , příp.  $(x, y, z, roll, pitch, yaw)$



## Proč je lokalizace těžká?

- Polohu nelze měřit žádným senzorem => pozice je vypočtena ze sensorických dat
- Ale senzory jsou nepřesné!
- Příkazy jsou prováděny nepřesně
- Jedno sensorické měření k určení polohy nestačí



zdroj: <http://probabilisticrobotics.org>

# Taxonomie

- **Lokální** (kontinuální, „position tracking“)
  - Počáteční pozice je známa
  - Korekce odometrických chyb
  - Omezená chyba
  - Unimodální distribuce (Gaussian)
- **Globální** (absolutní, „lost robot problem“)
  - Počáteční pozice není známa
  - Neomezená chyba
  - Unimodální distribuce nestačí
- **Unesený robot** („kidnapped robot problem“)
  - Detekce a oprava chyby
  - Vhodné pro testování

# Taxonomie

- **Statické prostředí**
  - Robot je jediný, co se pohybuje
  - Pozice robotu je jediná proměnná „Hezké matematické“ vlastnosti
- **Dynamické prostředí**
  - Objekty a/nebo jiné roboty se pohybují
  - Objekty: lidé, světlo (pro kamery), dveře, ...
  - Dva přístup řešení
    - Pohyb objektů lze modelovat => tvoří část stavového popisu úlohy
    - Data o pohyblivých objektech jsou filtrována

# Taxonomie


- **Pasivní lokalizace**

- Lokalizační modul pouze sleduje, co se děje - nemá vliv na řízení robotu
- Lokalizace je vedlejší produkt jiné úlohy

- **Aktivní lokalizace**


- Robot je řízen za účelem lepšího určení polohy
- Dává lepší výsledky ...
- ... ale ne vždy jde použít
- Střídání cílů: chvíli se lokalizuje, chvíli se řeší primární úloha
- Cíl se generuje jako kompromis

# Pasivní lokalizace



zdroj: <http://probabilisticrobotics.org>

# Aktivní lokalizace



zdroj: <http://probabilisticrobotics.org>




# Taxonomie

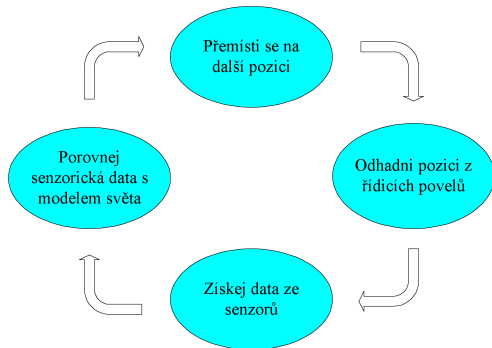
- **Jeden robot**
  - Klasický problém
  - Není nutná žádná komunikace, vše v jednom
- **Více robotů**
  - Každý robot se lokalizuje samostatně (tváří se, že ostatní neexistují)
  - Ale pokud jsou roboty schopny se navzájem detekovat, je to lepší
  - Lokalizace sebe sama v mapě druhého robotu Znáš svoji polohu, polohu druhého robotu a naši relativní pozici => optimalizace („gumičky“)

# My se budeme zabývat

- Terestriální robot pohybující se na rovné horizontální ploše (2D)
- Snímána je jen jedna rovina prostředí
- Většina objektů je statická a detekovatelná senzory
- Používáme senzory měřící vzdálenost
- Pasivní lokalizace
- Jeden robot
- Lokální, globální i nakopnutý robot




# Kontinuální lokalizace




- Poloha se hledá pouze v nejbližším okolí odhadnuté pozice
- Vyžaduje se vyšší přesnost
- Vstup: lokální a globální mapa (scan)
- Výstup: transformace minimalizující míru nesouladu map

# Ukázka



# Kontinuální lokalizace

- Existuje spousta metod lišících se datovou reprezentací map (scanů)
- Vždy se však jedná o optimalizaci vzhledem k danému kritériu nesouladu map
- Metody:
  - Lokalizace na mřížkách
  - Histogramy
  - Lokalizace s geometrickými primitivy (point-to-line, line-to-line, Houghova transformace)



# Iterative Closest Point (ICP)

(Lu, Milios)

- Iterativní
  - aktuální scan se proloží lomenou čarou
  - naleznou se korespondující body (nejmenší vzdálenost)
  - spočítá se transformace metodou nejmenších čtverců

$$E_{dist}(T_x, T_y, \omega) = \sum_i^n |R_\omega P + T - P'|$$


- Má analytické řešení

$$T_x = \bar{x}' - (\bar{x} \cos(\bar{\omega}) - \bar{y} \sin(\bar{\omega}))$$

$$T_y = \bar{y}' - (\bar{x} \sin(\bar{\omega}) + \bar{y} \cos(\bar{\omega}))$$

$$\bar{\omega} = \arctan \frac{\sum_{i=1}^n (x_i - \bar{x})(y'_i - \bar{y}') - \sum_{i=1}^n (y_i - \bar{y})(x'_i - \bar{x}')}{\sum_{i=1}^n (x_i - \bar{x})(y'_i - \bar{y}') + \sum_{i=1}^n (y_i - \bar{y})(x'_i - \bar{x}')}$$


- Konverguje pomalu, špatné v rotační složce



# Iterative Matching Range Point (IMRP)

(Lu, Milios)

- Postup stejný jako u ICP, pouze jiné pravidlo korespondence
- Předpokládáme, že posunutí je nulové  $\Rightarrow |P| \approx |P'|$  a  $\tilde{\phi}phi + \omega$
- Velikost okolí pro hledání korespondencí se postupně zmenšuje
- Zpočátku pomalejší konvergence než u ICP, ale pak rychlejší
- IMRP se snaží chybu posunutí řešit otočením  $\Rightarrow$  nestabilita




# Iterative Dual Correspondence (IDC)

(Lu, Milios)


- Kombinace obou pravidel: posunutí z ICP, otočení z IMRP
- **Algoritmus**
  - Pro každý bod  $P_i$  z aktuálního scanu:
    - Použij pravidlo nejbližšího bodu pro nalezení korespondujícího bodu  $P'$
    - Použij pravidlo MRP pro nalezení korespondujícího bodu  $P''$
    - Spočítej metodou nejmenších čtverců ( $\omega_1, T_1$ ) z korespondencí ( $P, P'$ )
    - Spočítej metodou nejmenších čtverců ( $\omega_2, T_2$ ) z korespondencí ( $P, P''$ )
    - Hledaná korespondence je ( $\omega_2, T_1$ )
  - Přechozí kroky opakuj, dokud postup nekonverguje

**Vylepšení:** Po nalezení párů se z následující optimalizace vyloučí odlehlé bodové páry







## Lokalizace ve 3D



# Correlative Scan Matching

(Edwin B. Olson)


- Hodnotící funkce je typicky velmi komplikovaná s množstvím lokálních minim.
- Počáteční odhad pozice (odometrie) může být velmi nepřesný.
- ICP nalézá pouze lokální optimum
- Vstup: dva scany
- Cíl: určit globální optimum



# Correlative Scan Matching

## Tvorba vyhledávací tabulky

- Pro každý bod v mapě se spočítá pravděpodobnost, že odpovídá měření referenčního scanu.



# Correlative Scan Matching

## Algoritmus

- Brutální síla
  - Pro každou pozici scanu (včetně orientace) se spočítá korelace.
  - Vybere se pozice s největší korelací .
- Výpočet 2D řezů
  - Spoustu času se tráví transformací scanu.
  - Idea: otočení se provede ve vnější smyčce, v ostatních se již jen posouvá.

# Correlative Scan Matching

## Algoritmus

- Více-úrovnové vyhledávání
  - Dvě vyhledávací tabulky: s nízkým (NVT) a vysokým (VVT) rozlišením.
  - Hodnota bunky v NVT je maximem odpovídajících buněk VVT.
  - To zajišťuje, že hodnota NVT je nejméně tak velká jako ve VVT.
  - Algoritmus
    - Spočítej korespondence pro NVT.
    - Najdi nejlepší buňku  $NVT_B$  v NVT, která dosud nebyla zpracována.
    - Pokud její hodnota je menší, než nejlepší dosud nalezená skonči.
    - Najdi buňku s nejlepší hodnotou v VVT, která odpovídá  $NVT_B$
    - Pokud je nalezená hodnota lepší než aktuální maximum, nastav maximum na tuto hodnotu.

# Correlative Scan Matching


## Výsledky

PC: Intel Core2 6600 @ 2.4 Ghz

	ICP	ICL	Hill- Climb	Correlative (Naive)	Correlative (2D Slices)	Correlative (Multi-Res)	Correlative (GPU 7600GS)	Correlative (GPU GTX260)
0.5 m, 20 deg	56 ms	64 ms	1.1 ms	246 ms	27 ms	8.4 ms	98 ms	26 ms
2.0 m, 40 deg	99 ms	105 ms	1.3 ms	7512 ms	692 ms	20.8 ms	1563 ms	289 ms
4.0 m, 90 deg	145 ms	174 ms	1.0 ms	65282 ms	5029 ms	86.1 ms	13166 ms	2012 ms

## Lehký úvod do teorie pravděpodobnosti



- Idea: explicitní reprezentace nejistoty pomocí kalkulu teorie pravděpodobnosti
- $p(X=x)$  pravděpodobnost, že náhodná proměnná  $X$  nabývá hodnoty  $x$
- $0 \leq p(x) \leq 1$
- $p(\text{true}) = 1, p(\text{false}) = 0$
- $p(A \vee B) = p(A) + p(B) - p(A \wedge B)$



# Diskrétní a spojitá náhodná veličina

- **Diskrétní:**  $X$  je spočetná, tj.  
 $X = x_1, x_2, \dots, x_n$
- **Spojitá:**  $X$  nabývá nespočetně mnoha hodnot (z intervalu)
- $p$  se nazývá **hustota pravděpodobnosti**
- Různá rozložení
- Nejznámější: **Normální** (Gausián)



- $$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$





## Vícerozměrné normální rozložení

$$p(x) = \frac{1}{\sqrt{2\pi|\Sigma|}} e^{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)}$$



- Vlastní čísla a vlastní vektory kovarianční matice definují elipsy.

## Sdružená a podmíněná pravděpodobnost

- $p(X = x \text{ a } Y = y) = p(x, y)$
- Pokud  $X$  and  $Y$  jsou **nezávislé**, potom

$$p(x, y) = p(x)p(y)$$

- $p(x|y)$  je pravděpodobnost  $x$  za **předpokladu**  $y$

$$p(x|y) = p(x, y)/p(y)$$

$$p(x, y) = p(x|y)p(y)$$

- Pokud  $X$  a  $Y$  jsou **nezávislé**, potom

$$p(x|y) = p(x)$$

# Teorém úplné pravděpodobnosti

## Diskrétní případ

$$\sum_x p(x) = 1$$

$$p(x) = \sum_y p(x, y)$$


$$p(x) = \sum_y p(x|y)p(y)$$

## Spojitéý případ

$$\int_x p(x) dx = 1$$

$$p(x) = \int_y p(x, y) dy$$

$$p(x) = \int_y p(x|y)p(y) dy$$



## Bayesův vzorec

$$p(x, y) = p(x|y)p(y) = p(y|x)p(x)$$

$\Rightarrow$

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} = \frac{\textit{likelihood} \cdot \textit{prior}}{\textit{evidence}}$$


$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} = \eta p(y|x)p(x)$$

$$\eta = p(y)^{-1} = \frac{1}{\sum_x p(y|x)p(x)}$$

## Příklad - odhad stavu

- Robot naměří  $z$
- Jaká je pravděpodobnost  $p(open|z)$ ?
- $p(open|z)$  je **diagnostika**
- $p(z|open)$  je **příčina**
- Většinou je jednodušší získat **příčinu** (počítání frekvencí)
- Bayesův vzorec umožňuje z příčiny spočítat důsledek:

$$p(open|z) = \frac{p(z|open)p(open)}{p(z)}$$



## Příklad - otevřené dveře

- $p(z|open) = 0.6$   $p(z|\neg open) = 0.3$
- $p(open) = p(\neg) = 0.5$

$$p(open|z) = \frac{p(z|open)p(open)}{p(z|open)p(open) + p(z|\neg open)p(\neg open)}$$

$$p(open|z) = \frac{0.6 \cdot 0.5}{0.6 \cdot 0.5 + 0.3 \cdot 0.5} = \frac{2}{3} = 0.67$$

- Po naměření  $z$  se jistota otevření dveří zvýší.

## Příklad - druhé měření

- $p(z_2|open) = 0.5$   $p(z_2|\neg open) = 0.6$
- $p(open|z_1) = \frac{2}{3}$

$$\begin{aligned} p(open|z_2z_1) &= \frac{p(z_2|open)p(open|z_1)}{p(z_2|open)p(open|z_1) + p(z_1|\neg open)p(\neg open|z_1)} \\ &= \frac{\frac{1}{2} \cdot \frac{2}{3}}{\frac{1}{2} \cdot \frac{2}{3} + \frac{3}{5} \cdot \frac{1}{3}} = \frac{5}{8} = 0.625 \end{aligned}$$

- $z_2$  snižuje pravděpodobnost, že jsou dveře otevřené.

# Akce

- Svět je dynamický
  - robot se hýbe,
  - jiné objekty v prostředí se hýbou
  - a čas prostě plyne (květiny rostou).
- Akce se nikdy nestane tak, jak byla naplánována.
- Na rozdíl od měření akce obvykle zvýší míru nejistoty.
- Pro integraci akce  $u$  do aktuální „víry“ použijeme podmíněnou pravděpodobnost



$$p(x|u, x')$$

- Tento výraz specifikuje pravděpodobnost ( hustotu pravděpodobnosti) stavu  $x$ , pokud provedeme akci  $u$  ve stavu  $x'$ .



## Pokračování příkladu - zavíráme dveře

$p(x|u, x')$  pro  $u = \text{„zavři dveře“}$



zdroj: <http://probabilisticrobotics.org>

$$p(x, u) = \sum_{x'} p(x|u, x')p(x')$$

Pokud jsou dveře otevřené, akce „zavři dveře“ je úspěšná v 90% případech.

## Pokračování příkladu - zavíráme dveře

$$\begin{aligned} p(\text{closed}|u) &= \sum_{x'} p(\text{closed}|u, x')p(x') \\ &= p(\text{closed}|u, \text{open})p(\text{open}) \\ &+ p(\text{closed}|u, \text{closed})p(\text{closed}) \\ &= \frac{9}{10} \cdot \frac{5}{8} + \frac{1}{1} \cdot \frac{3}{8} = \frac{15}{16} \end{aligned}$$

$$\begin{aligned} p(\text{open}|u) &= \sum_{x'} p(\text{open}|u, x')p(x') \\ &= p(\text{open}|u, \text{open})p(\text{open}) \\ &+ p(\text{open}|u, \text{closed})p(\text{closed}) \\ &= \frac{1}{10} \cdot \frac{5}{8} + \frac{0}{1} \cdot \frac{3}{8} = \frac{1}{16} \\ &= 1 - p(\text{closed}|u) \end{aligned}$$