

Úvod do mobilní robotiky — AIL028

Lokalizace

Zbyněk Winkler

`zbynek.winkler at mff.cuni.cz`
`http://robotika.cz/articles/umor/cs`

22. listopadu 2007

Opakování z minula

Senzory související s pohybem

Modely kolových vozidel

Odometrie

Jak se vypořádat s nepřesnými vstupními daty?

Průměr

Inkrementální výpočet průměru

Plovoucí průměr délky k

Odhad plovoucího průměru

Kalmanův filter

Souvislost s inkrementálním odhadem průměru

Algoritmus aktualizace

Podmínky korektnosti

Monte Carlo Lokalizace

Co je to?


Slabiny MCL

Senzory související s pohybem


- ▶ Optické enkodéry
 - ▶ Absolutní
 - ▶ Relativní
- ▶ Potenciometry
- ▶ Magnetické, kapacitní, indukční
- ▶ Akcelerometry (MEMS)

Modely kolových vozidel

Diferenční řízení – tank



Tříkolka – Ackermanovo řízení



Odometrie

Dead Reconing

Akumulování relativní informace o změně pohybu:

$$\theta_i = \theta_{i-1} + \Delta\theta_i$$

$$x_i = x_{i-1} + \Delta F_i \cos(\theta_i)$$

$$y_i = y_{i-1} + \Delta F_i \sin(\theta_i)$$

Kde $[x_i, y_i, \theta_i]$ je pozice a orientace robota v čase i , $\Delta\theta_i$ je otočení a ΔF_i je posun dopředu.

Vypočítaná pozice začne být časem ovládána více chybou měření než vlastními údaji — je třeba se s tím nějak vypořádat.

Průměr

- ▶ asi první věc, co každého napadne
- ▶ definice:

$$\bar{x} = \frac{1}{n} \sum_{i=0}^n x_i$$

Průměr

- ▶ asi první věc, co každého napadne
- ▶ definice:

$$\bar{x} = \frac{1}{n} \sum_{i=0}^n x_i$$

- ▶ v jakých případech nám pomůže?

Průměr

- ▶ asi první věc, co každého napadne
- ▶ definice:

$$\bar{x} = \frac{1}{n} \sum_{i=0}^n x_i$$

- ▶ v jakých případech nám pomůže?
- ▶ co když nám data chodí postupně?

Průměr

- ▶ asi první věc, co každého napadne
- ▶ definice:

$$\bar{x} = \frac{1}{n} \sum_{i=0}^n x_i$$

- ▶ v jakých případech nám pomůže?
- ▶ co když nám data chodí postupně?
- ▶ co když si nemůžeme pamatovat úplně všechny hodnoty?

Průměr

- ▶ asi první věc, co každého napadne
- ▶ definice:

$$\bar{x} = \frac{1}{n} \sum_{i=0}^n x_i$$

- ▶ v jakých případech nám pomůže?
- ▶ co když nám data chodí postupně?
- ▶ co když si nemůžeme pamatovat úplně všechny hodnoty?
- ▶ co když vyžadujeme menší (konstantní) složitost?

Inkrementální výpočet průměru

► definice:

$$s_0 = 0$$

$$s_n = s_{n-1} + x_n$$

$$\bar{x}_n = s_n / n$$

Inkrementální výpočet průměru

- ▶ definice:

$$s_0 = 0$$

$$s_n = s_{n-1} + x_n$$

$$\bar{x}_n = s_n/n$$

- ▶ v jakých případech nám pomůže?

Inkrementální výpočet průměru

- ▶ definice:

$$s_0 = 0$$

$$s_n = s_{n-1} + x_n$$

$$\bar{x}_n = s_n/n$$

- ▶ v jakých případech nám pomůže?
- ▶ co když se odhadovaná hodnota mění? (roste/klesá/osciluje)

Plovoucí průměr délky k

► definice:

$$\begin{aligned}x_i, s_0 &= 0 && \text{pro } i < 0 \\s_n &= s_{n-1} - x_{n-k} + x_n \\ \bar{x}_n &= s_n/k\end{aligned}$$

Plovoucí průměr délky k

- ▶ definice:

$$\begin{aligned}x_i, s_0 &= 0 && \text{pro } i < 0 \\s_n &= s_{n-1} - x_{n-k} + x_n \\ \bar{x}_n &= s_n/k\end{aligned}$$

- ▶ v jakých případech nám pomůže?

Plovoucí průměr délky k

- ▶ definice:

$$\begin{aligned}x_i, s_0 &= 0 && \text{pro } i < 0 \\s_n &= s_{n-1} - x_{n-k} + x_n \\ \bar{x}_n &= s_n/k\end{aligned}$$

- ▶ v jakých případech nám pomůže?
- ▶ můžeme použít pro filtrování enkodérů?

Plovoucí průměr délky k

- ▶ definice:

$$\begin{aligned}x_i, s_0 &= 0 && \text{pro } i < 0 \\s_n &= s_{n-1} - x_{n-k} + x_n \\ \bar{x}_n &= s_n/k\end{aligned}$$

- ▶ v jakých případech nám pomůže?
- ▶ můžeme použít pro filtrování enkodérů?
 - ▶ zachovává integrál?

Plovoucí průměr délky k

- ▶ definice:

$$\begin{aligned}x_i, s_0 &= 0 && \text{pro } i < 0 \\s_n &= s_{n-1} - x_{n-k} + x_n \\ \bar{x}_n &= s_n/k\end{aligned}$$

- ▶ v jakých případech nám pomůže?
- ▶ můžeme použít pro filtrování enkodérů?
 - ▶ zachovává integrál?
- ▶ co když si nemůžeme/nechceme pamatovat k starých měření?

Odhad plovoucího průměru

- ▶ x_{n-k} nahradíme pomocí \bar{x}_{n-1} (nejlepší odhad, co máme)
- ▶ s_{n-1} nahradíme pomocí $\bar{x}_{n-1} \cdot k$ (ekvivalentní)

$$x_i, s_0 = 0 \quad \text{pro } i < 0$$

$$s_n = s_{n-1} - x_{n-k} + x_n$$

$$\bar{x}_n = s_n/k$$

$$\Downarrow$$

$$\bar{x}_n = (\bar{x}_{n-1} \cdot k - \bar{x}_{n-1} + x_n)/k$$

$$\Downarrow$$

$$\bar{x}_n = (\bar{x}_{n-1} \cdot (k - 1) + x_n)/k$$

Odhad plovoucího průměru

- ▶ x_{n-k} nahradíme pomocí \bar{x}_{n-1} (nejlepší odhad, co máme)
- ▶ s_{n-1} nahradíme pomocí $\bar{x}_{n-1} \cdot k$ (ekvivalentní)

$$\begin{aligned}
 x_i, s_0 &= 0 && \text{pro } i < 0 \\
 s_n &= s_{n-1} - x_{n-k} + x_n \\
 \bar{x}_n &= s_n/k \\
 &\Downarrow \\
 \bar{x}_n &= (\bar{x}_{n-1} \cdot k - \bar{x}_{n-1} + x_n)/k \\
 &\Downarrow \\
 \bar{x}_n &= (\bar{x}_{n-1} \cdot (k - 1) + x_n)/k
 \end{aligned}$$

- ▶ v praxi třeba $\bar{x} = (\bar{x} \cdot 3 + x) \ggg 2$ – jednoduché, rychlé

Souvislost s inkrementálním odhadem průměru

$$\begin{aligned}\bar{x}_n &= (\bar{x}_{n-1} \cdot (k-1) + x_n) / k \\ &= \frac{k-1}{k} \cdot \bar{x}_{n-1} + \frac{1}{k} \cdot x_n \\ &= \left(1 - \frac{1}{k}\right) \cdot \bar{x}_{n-1} + \frac{1}{k} \cdot x_n\end{aligned}$$

- ▶ $\left(1 - \frac{1}{k}\right)$ a $\frac{1}{k}$ zde působí jako určité váhy pro kombinaci předchozího průměru a nové hodnoty

Toto je základní myšlenka, které je celý Kalmanův filter založen!

Definice

Stavová rovnice

$$x_{k+1} = Fx_k + w_k$$

kde x_k je n dimenzionální stavový vektor, F je transformační matice a w_k šum/chyba stavu ($w_k \sim N(0, Q)$)

Rovnice měření

$$z_k = Hx_k + v_k$$

kde z_k je m dimenzionální vektor měření, H je $m \times n$ matice určující vztah mezi stavem a měřením a v_k je šum/chyba měření ($v_k \sim N(0, R)$)

Algoritmus aktualizace

Predikce stavu a chyby — pomocí stavové rovnice

$$\begin{aligned}x_{k+1}^- &= Fx_k \\ P_{k+1}^- &= FP_kF^T + Q\end{aligned}$$

Korekce pomocí měření — pomocí rovnice měření

$$\begin{aligned}z_k &= Hx_k + v_k \\ K_k &= P_k^- H^T (HP_k^- H^T + R)^{-1} \\ x_k &= x_k^- + K_k(z_k - Hx_k^-) \\ P_k &= (I - K_k H)P_k^-\end{aligned}$$

Podmínky korektnosti

- ▶ diskrétní, lineární model procesu (změny stavu)
- ▶ diskrétní, lineární model měření
- ▶ všechen šum má gaussovské rozdělení pravděpodobnosti

Monte Carlo Lokalizace

- ▶ Pozice reprezentovaná množinou vážených vzorků
- ▶ 3 fáze
 - ▶ pohyb (predikce)
 - ▶ měření (korekce)
 - ▶ převzorkování
- ▶ Jednoduché ohodnocovací funkce:
`double eval(Pozice p);`
- ▶ Zásadní výhoda - jednoduchá implementace

Slabiny MCL

- ▶ Není jedna pozice, tak podle čeho má robot jet?
- ▶ Možnost skokových změn
- ▶ Problém nastavení parametrů a ladění
- ▶ Manévry nezachycené v distribuční funkci (čelní náraz)