

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Metody lokalizace v mobilní robotice

RNDr. Miroslav Kulich, Ph.D. (ČVUT v Praze)

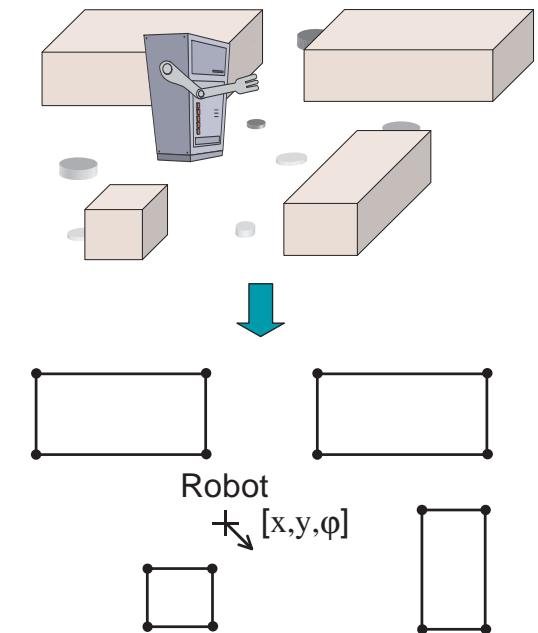
4. března 2011

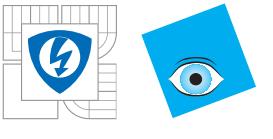
Tato prezentace je spolufinancována Evropským sociálním fondem a státním rozpočtem České republiky.



Lokalizace

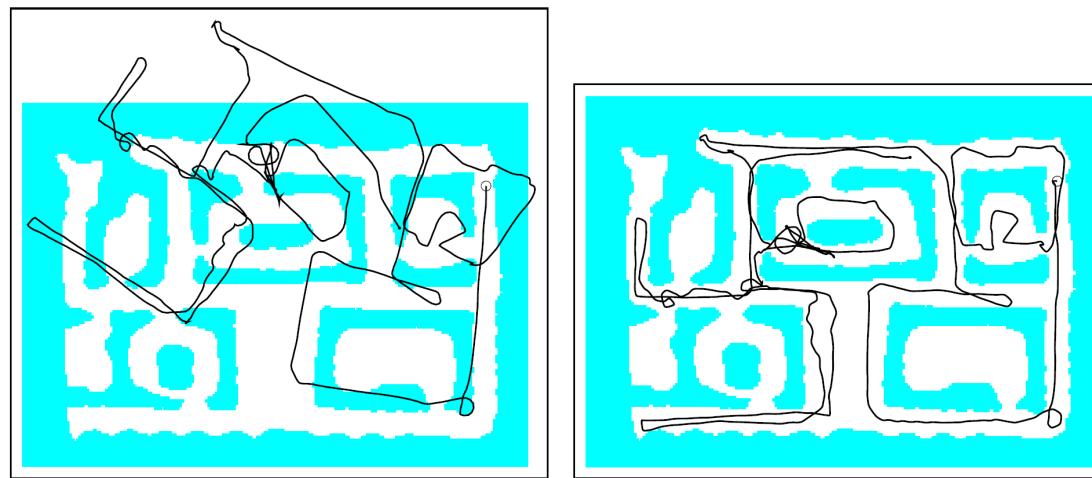
- Lokalizace je problém **určení pozice robotu**
 - relativně vzhledem k počáteční pozici robotu
 - v daném systému souřadnic (ve známé mapě)
- Pozice je uvažována včetně natočení!
tj. (x, y, ϕ) , příp. $(x, y, z, roll, pitch, yaw)$





Proč je lokalizace těžká?

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





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 jediné, co se pohybuje
 - Pozive 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

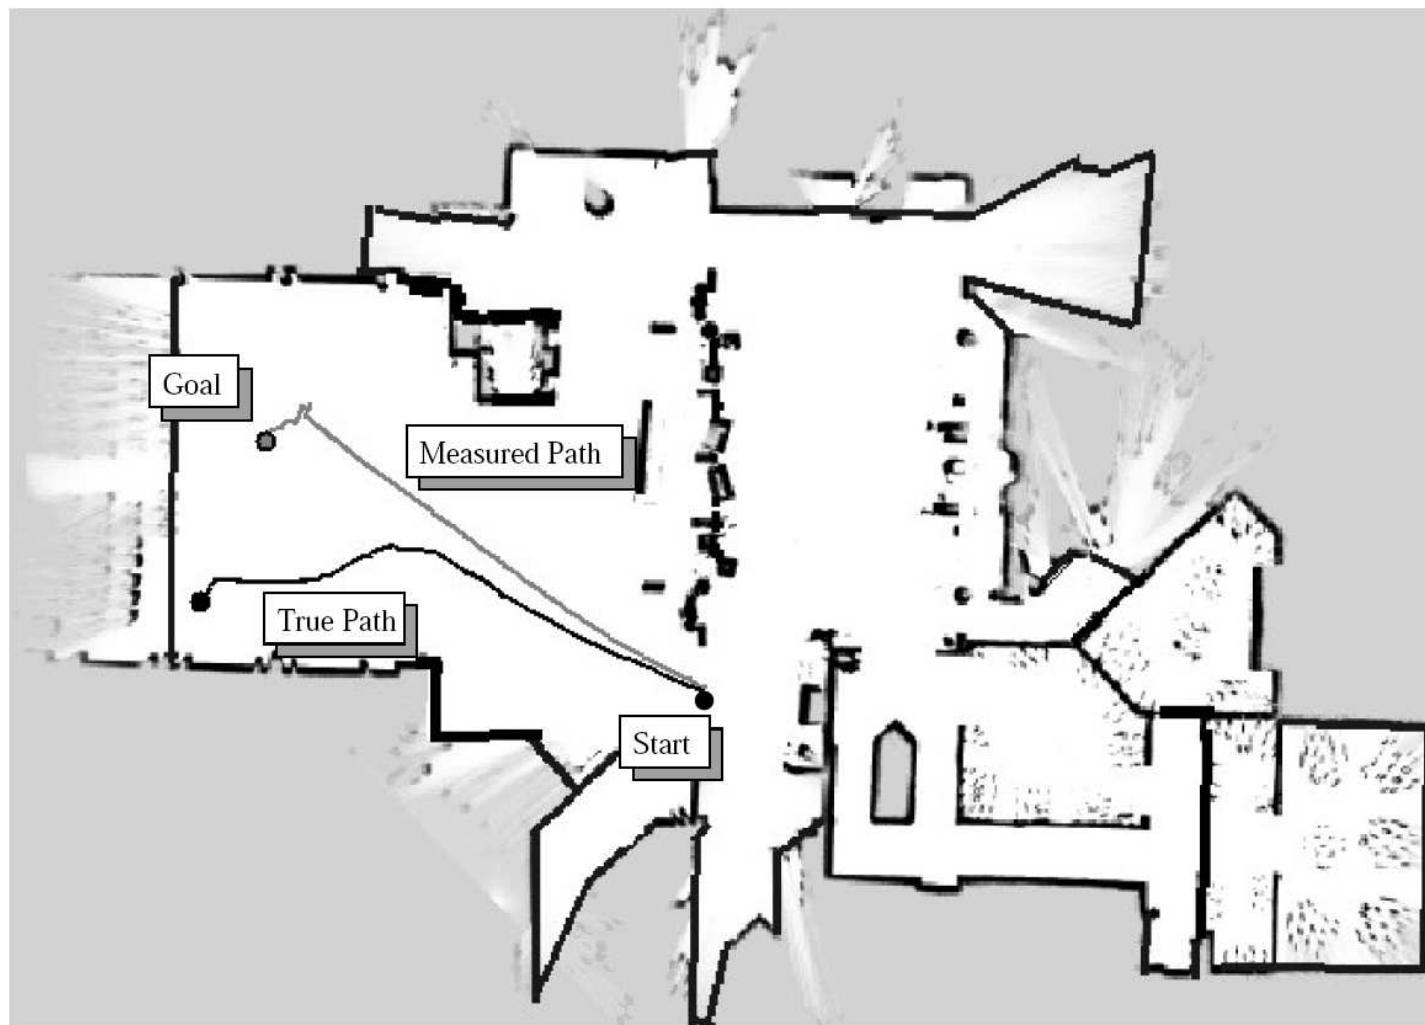


Taxonomie

- **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

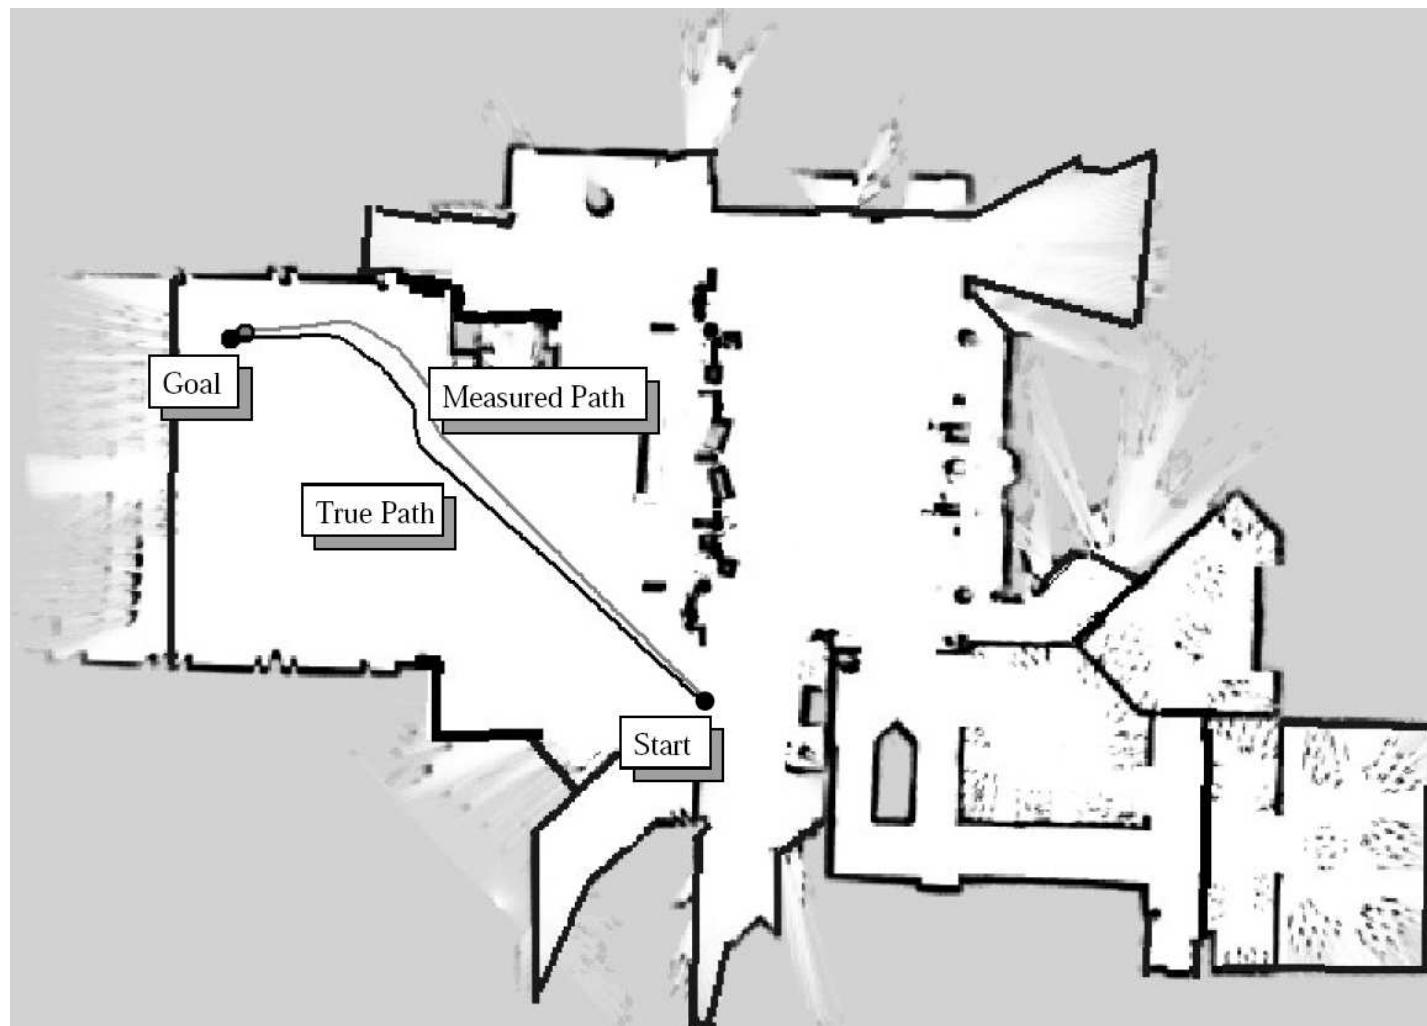


Pasivní lokalizace





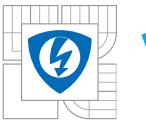
Aktivní lokalizace





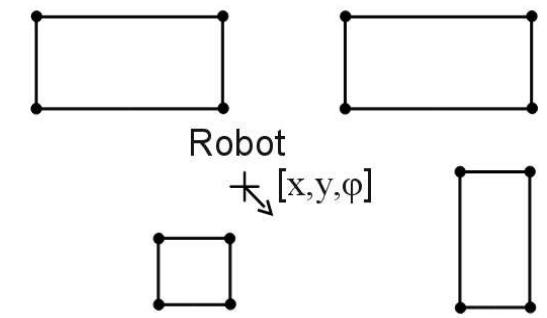
Taxonomie

- 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 detektovat, je to lepší
 - Lokalizace sebe sama v mapě druhého robota
 - Znám svoji polohu, polohu druhého robota a naši relativní pozici
=> optimalizace („gumičky“)



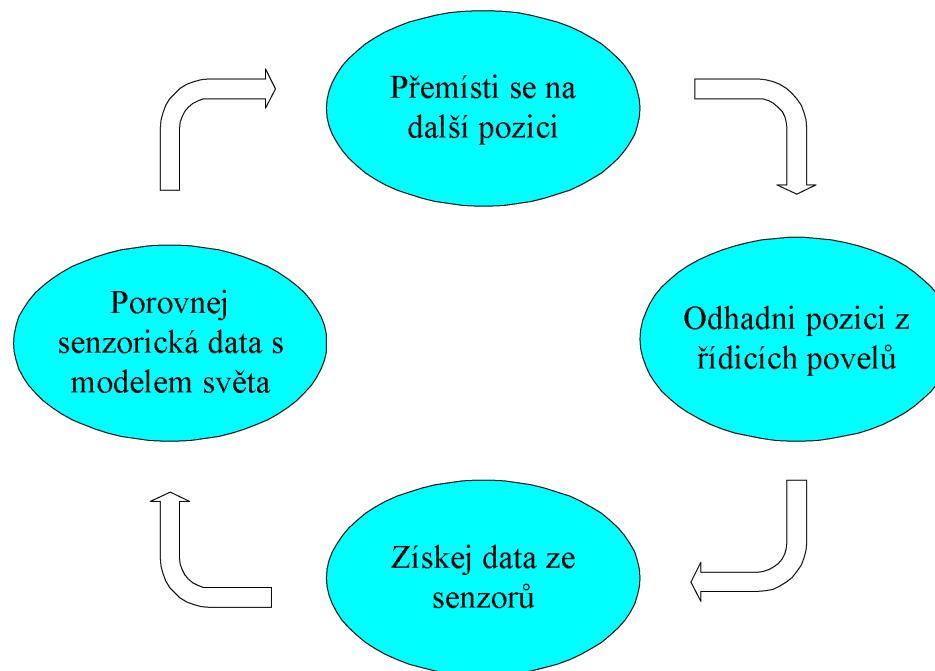
My se budeme zabývat

- 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

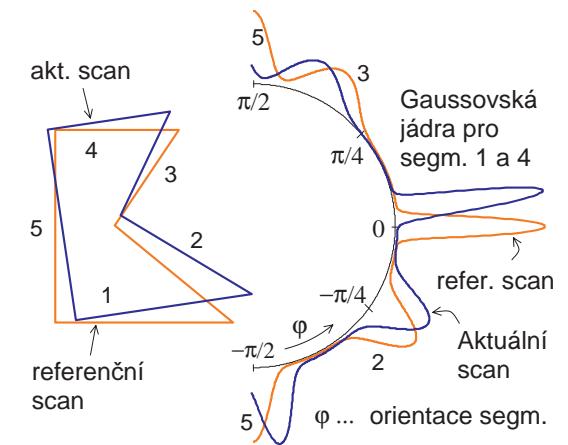
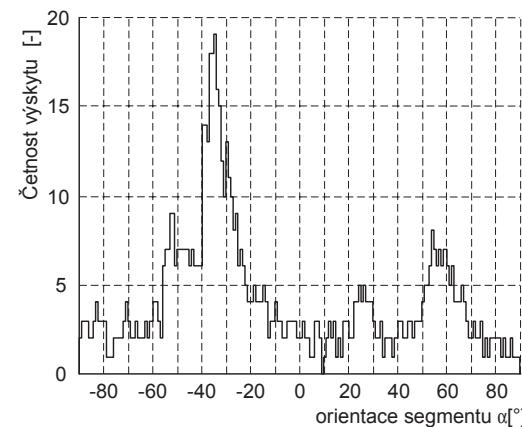
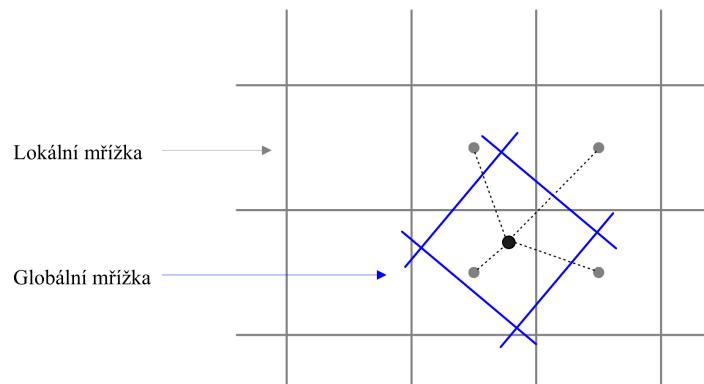


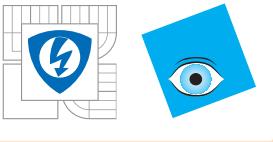
- Poloha se hledá pouze v nejbližším okolí odhadnuté pozice
- Vyžaduje se vyšší přesnost
- Vstup: lokální a globální mapa (scan)
- Výstup: transformace minimalizující míru nesouladu map



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)



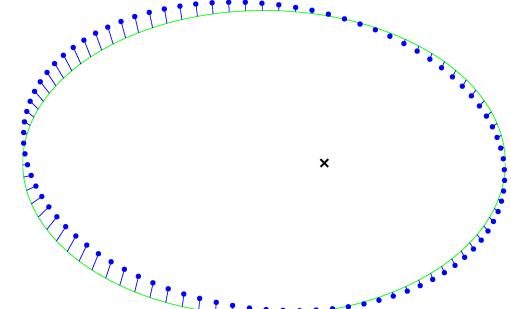


Iterative Closest Point (ICP)

- Iterativní

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

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



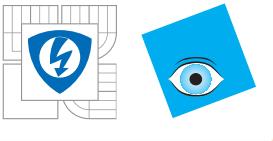
- Má analytické řešení

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

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

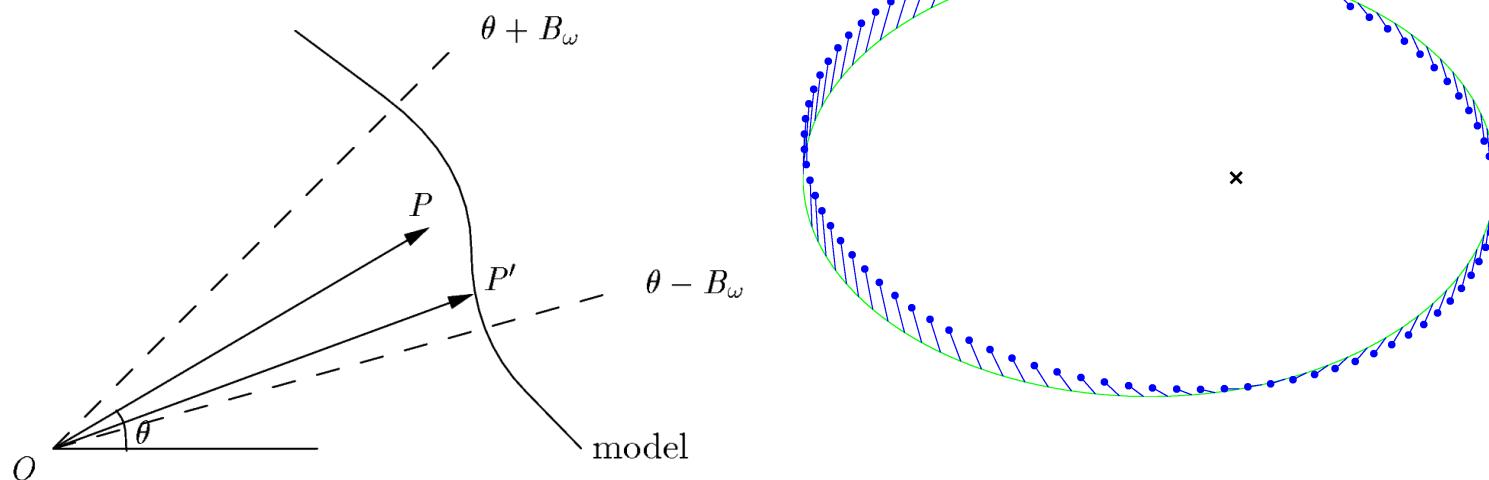
$$\bar{\omega} = \arctan \frac{\sum_{i=1}^n (x_i - \bar{x})(y'_i - \bar{y}') - \sum_{i=1}^n (y_i - \bar{y})(x'_i - \bar{x}')}{\sum_{i=1}^n (x_i - \bar{x})(y'_i - \bar{y}') + \sum_{i=1}^n (y_i - \bar{y})(x'_i - \bar{x}')}$$

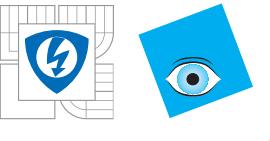
- Konverguje pomalu, špatné v rotační složce



Iterative Matching Range Point (IMRP)

- 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

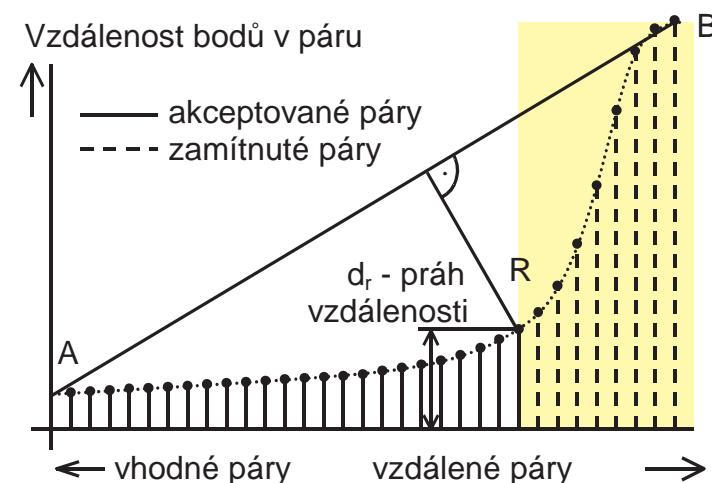


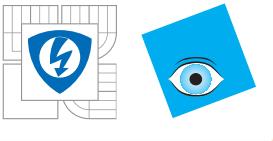


Iterative Dual Correspondence (IDC)

- Kombinace obou pravidel: posunutí z ICP, otočení z IMRP
- **Algoritmus**
 - Pro každý bod P_i z aktuálního scanu:
 - Použij pravidlo nejbližšího bodu pro nalezení kor. bodu P'
 - Použij pravidlo MRP pro nalezení korespondujícího bodu P''
 - Spočítej metodou nejmenších čtverců (ω_1, T_1) z kor. (P, P')
 - Spočítej metodou nejmenších čtverců (ω_2, T_2) z kor. (P, P'')
 - Hledaná korespondence je (ω_2, T_1)
 - Přechozí kroky opakuj, dokud postup nekonverguje

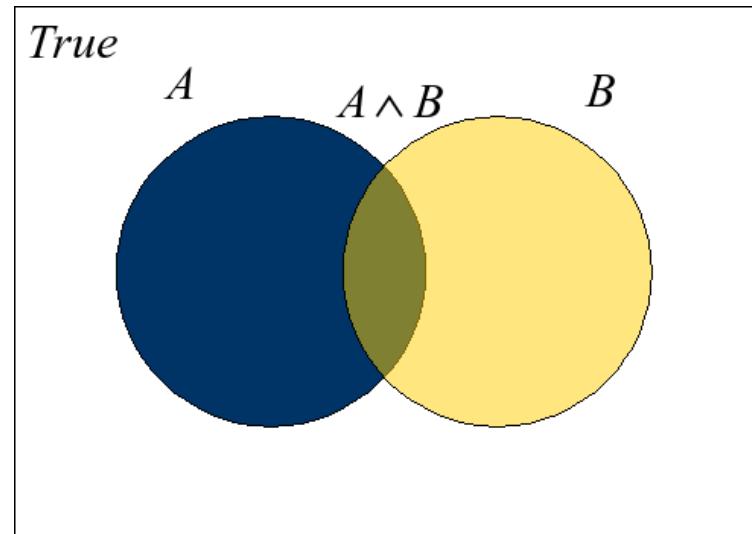
Vylepšení: Po nalezení páru se z následující optimalizace vyloučí odlehlé bodové páry

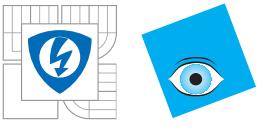




Lehký úvod do teorie pravděpodobnosti

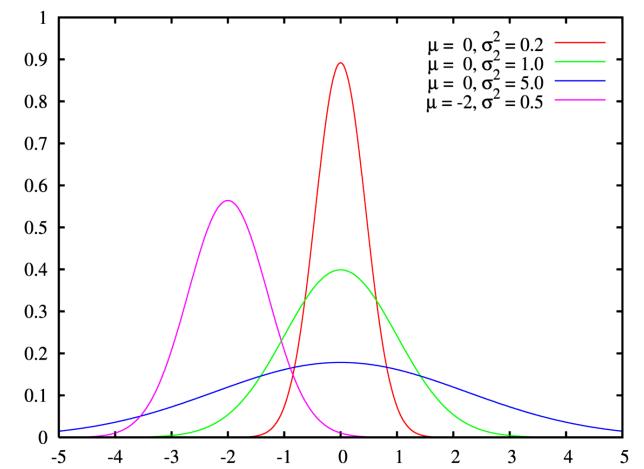
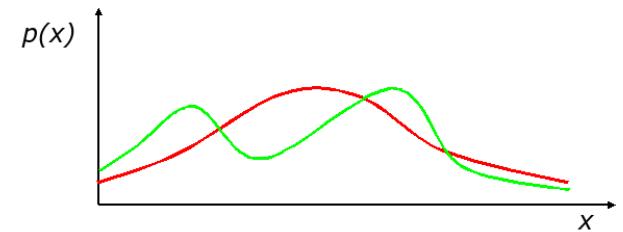
- Idea: explicitní reprezentace nejistoty pomocí kalkulu teorie pravděpodobnosti
- $p(X=x)$ pravděpodobnost, že náhodná proměnná X nabývá hodnoty x
- $0 \leq p(x) \leq 1$
- $p(true) = 1, p(false) = 0$
- $p(A \vee B) = p(A) + p(B) - p(A \wedge B)$





Diskrétní a spojité náhodná veličina

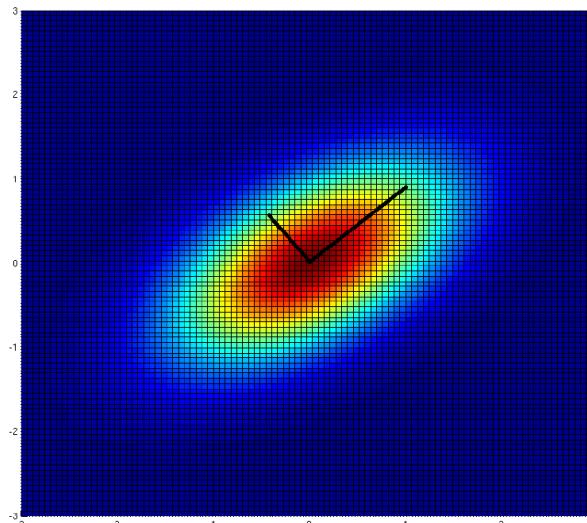
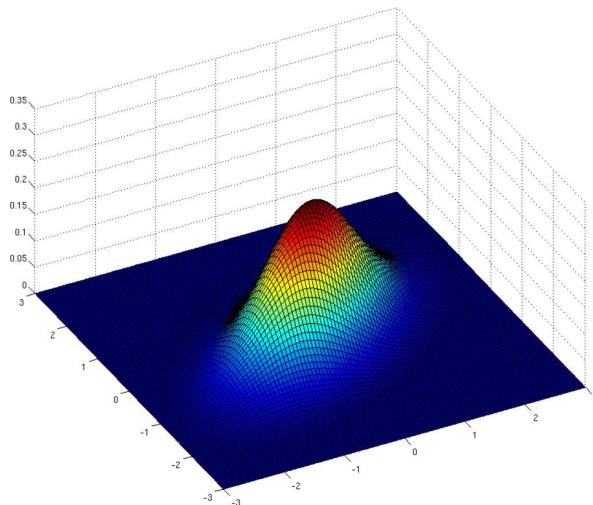
- **Diskrétní:** X je spočetná, tj.
$$X = x_1, x_2, \dots, x_n$$
- **Spojité:** X nabývá nespočetně mnoha hodnot (z intervalu)
- p se nazývá **hustota pravděpodobnosti**
- Různá rozložení
- Nejznámější: **Normální (Gausián)**
- $$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$



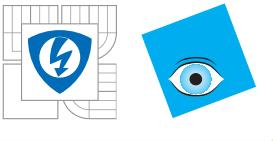


Vícerozměrné normální rozložení

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



- 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

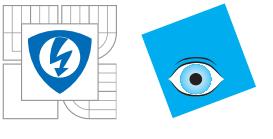
$$p(x|y) = p(x, y)/p(y)$$

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

- Pokud X a Y jsou nezávislé, potom

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





Teorém úplné pravděpodobnosti

Diskrétní případ

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

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

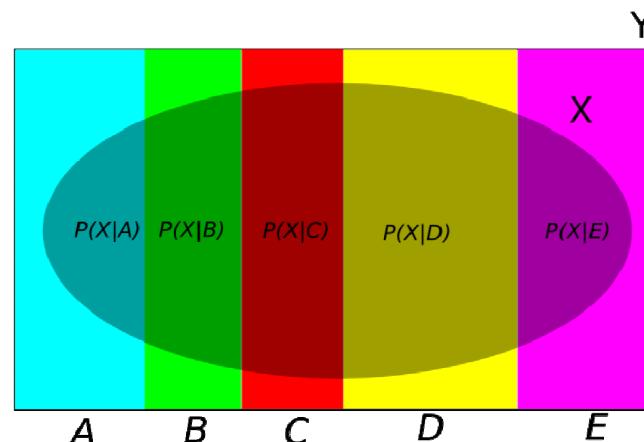
$$p(x) = \sum_y p(x|y)p(y)$$

Spojitý 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

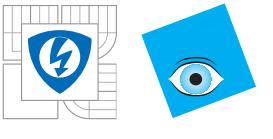
$$p(x, y) = p(x|y)p(y) = p(y|x)p(x)$$

\Rightarrow

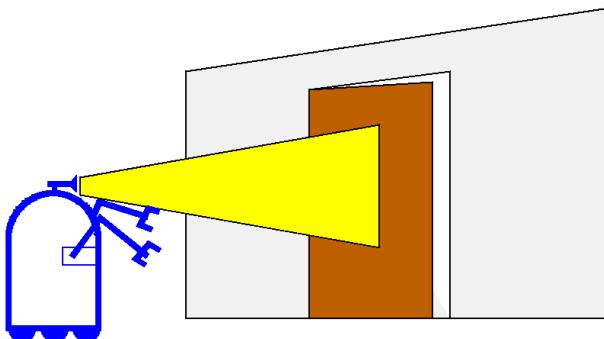
$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} = \frac{\text{likelihood} \cdot \text{prior}}{\text{evidence}}$$

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

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

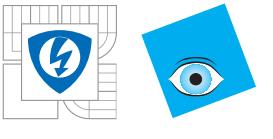


Příklad - odhad stavu



- 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:

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



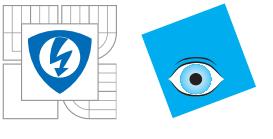
Příklad - otevřené dveře

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

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

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

- Po naměření z se jistota otevření dveří zvýší.



Příklad - druhé měření

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

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

- z_2 snižuje pravděpodobnost, že jsou dveře otevřené.

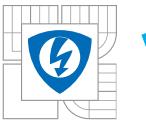


Akce

- 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

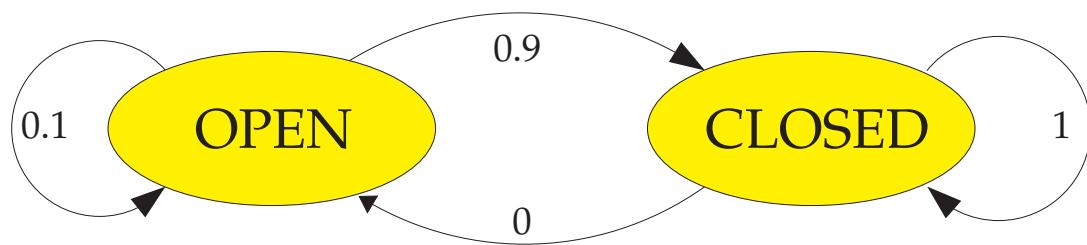
$$p(x|u, x')$$

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

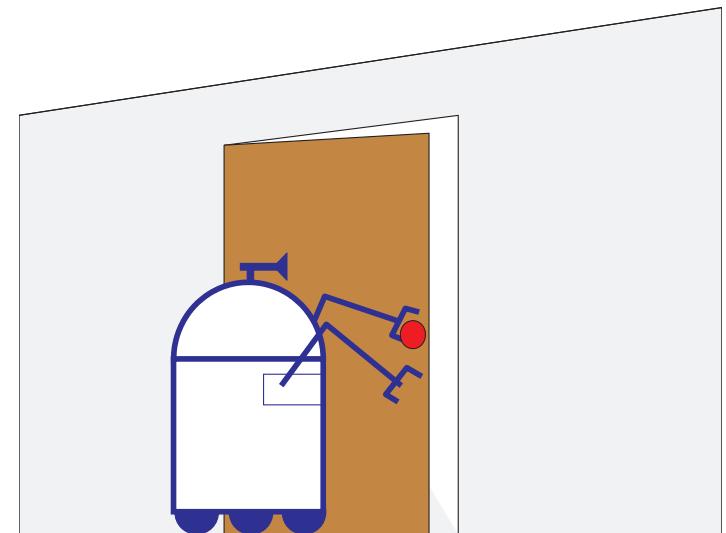


Pokračování příkladu - zavíráme dveře

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



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



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



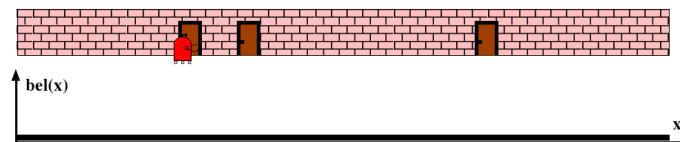
Pokračování příkladu - zavíráme dveře

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

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

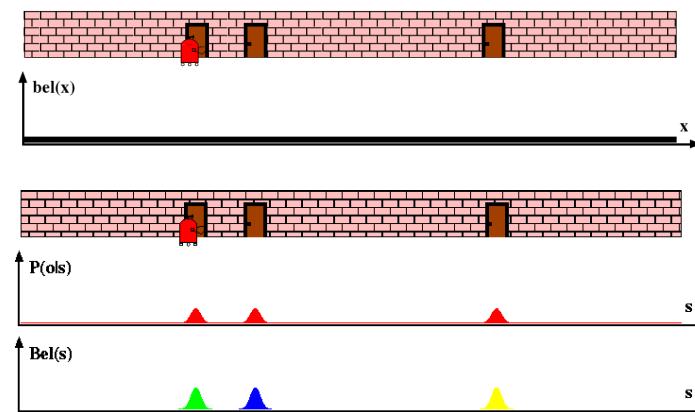


Motivace



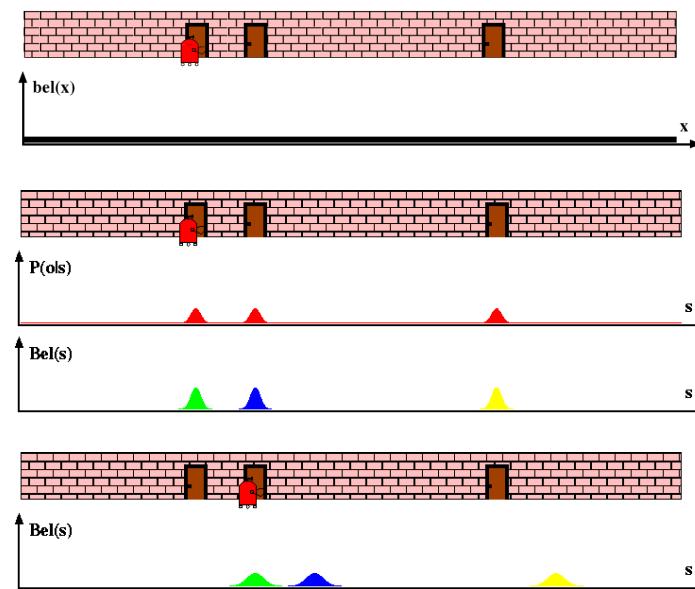


Motivace



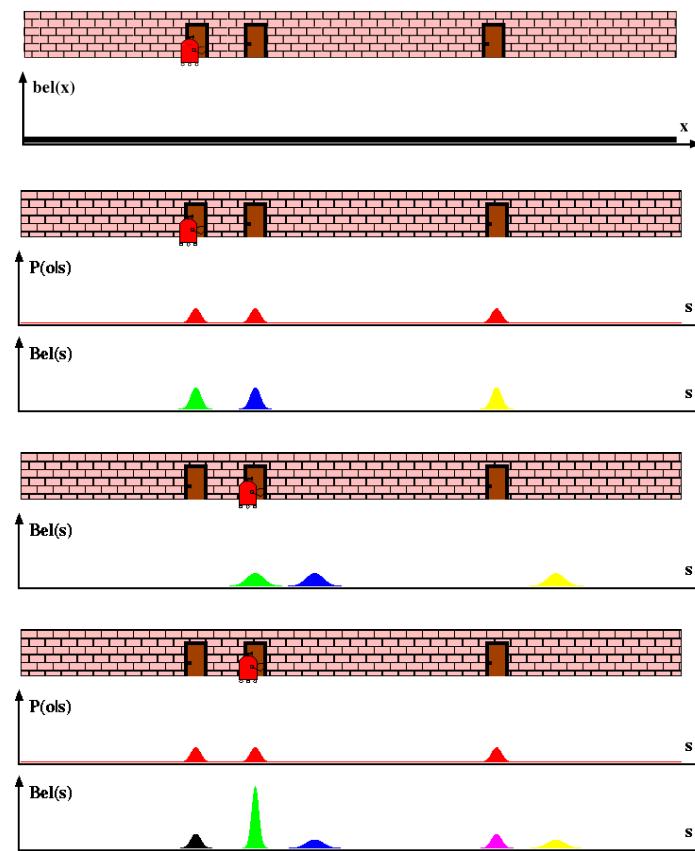


Motivace



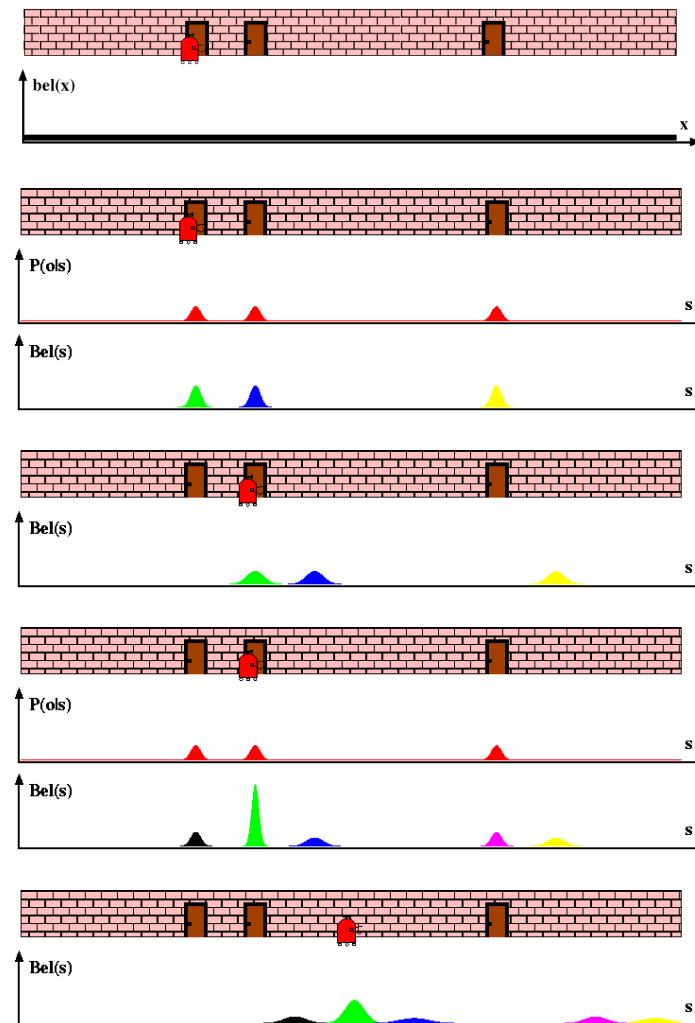


Motivace





Motivace



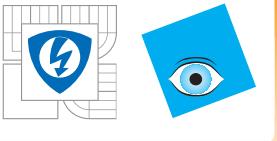


Bayesův filtr: framework

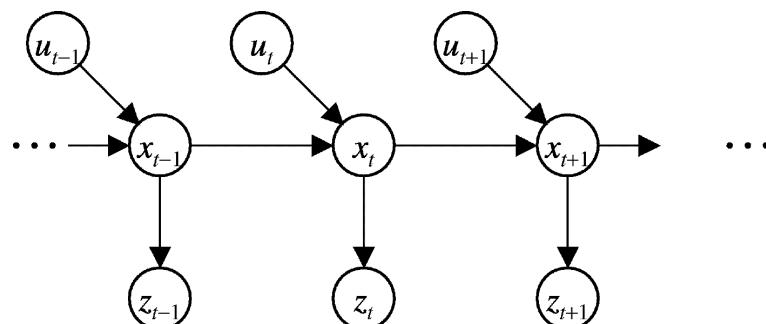
- Je dáno:
 - Posloupnost pozorování z a akcí u :

$$d_t = \{u_1, z_1, \dots, u_t, z_t\}$$

- Sensorický model $p(z|x)$
- Model akcí (pohybu) $p(x|u, x')$
- Počáteční (prior) pravděpodobnost stavu $p(x)$
- Chceme:
 - Odhad stavu (posterior)
 - Posteriorní pravděpodobnost označujeme jako belief (víra):
 $Bel(x_t) = p(x_t|u_1, z_1, \dots, u_t, z_t)$



Markovův předpoklad

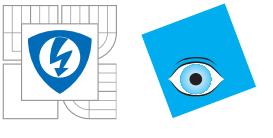


Následující stav závisí pouze na aktuálním stavu a nezávisí na stavech předchozích.

$$\begin{aligned} p(z_t | x_{0:t}, z_{1:t}, u_{1:t}) &= p(z_t | x_t) \\ p(x_t | x_{1:t-1}, z_{1:t}, u_{1:t}) &= p(x_t | x_{t-1}, u_t) \end{aligned}$$

S tím souvisí:

- Statický svět (nebo dynamika modelovaná v x)
- Dokonalý model světa (model senzoru) a model pohybu
- Nezávislý šum
- Přesná reprezentace $p(x)$



Bayesův filtr - odvození

$$\begin{aligned} Bel(x_t) &= p(x_t | u_1, z_1, \dots, u_t, z_t) \\ \text{Bayes} &= \eta p(z_t | x_t, u_1, z_1, \dots, u_t) p(x_t | u_1, z_1, \dots, u_t) \\ \text{Markov} &= \eta p(z_t | x_t) p(x_t | u_1, z_1, \dots, u_t) \\ \text{Total prob.} &= \eta p(z_t | x_t) \int p(x_t | u_1, z_1, \dots, u_t, x_{t-1}) \\ &\quad p(x_{t-1} | u_1, z_1, \dots, u_t) dx_{t-1} \\ \text{Markov} &= \eta p(z_t | x_t) \int p(x_t | u_t, x_{t-1}) p(x_{t-1} | u_1, z_1, \dots, u_t) dx_{t-1} \\ \text{Markov} &= \eta p(z_t | x_t) \int p(x_t | u_t, x_{t-1}) p(x_{t-1} | u_1, z_1, \dots, z_{t-1}) dx_{t-1} \\ &= \eta p(z_t | x_t) \int p(x_t | u_t, x_{t-1}) Bel(x_{t-1}) dx_{t-1} \end{aligned}$$



Bayesův filtr

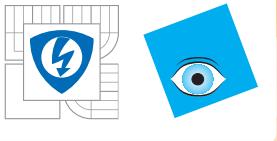
$$Bel(x_t) = \eta p(z_t|x_t) \int p(x_t|u_t, x_{t-1}) Bel(x_{t-1}) dx_{t-1}$$

Algoritmus Bayes_filter($Bel(x), d$)

```
if  $d$  is a measurement  $z$  then
     $\eta = 0$ 
    for all  $x$  do
         $Bel'(x) = p(z|x)Bel(x)$ 
         $\eta = \eta + Bel'(x)$ 
    end for
    for all  $x$  do
         $Bel'(x) = \eta^{-1}Bel'(x)$ 
    end for
end if
```

```
if  $d$  is a action  $u$  then
    for all  $x$  do
         $Bel'(x) = \int p(x|u, x')Bel(x')dx'$ 
    end for
end if
```

return $Bel'(x)$



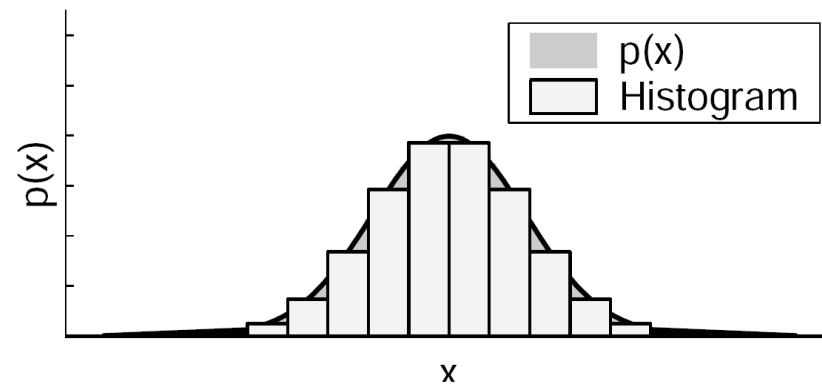
Bayesovy filtry - celá rodina metod

- Kalmanův filtr
- Histogramový filtr
- Particle filtr
- Skryté Markovovy modely
- Dynamické Bayesovy sítě
- Částečně pozorovatelné Markovovy rozhodovací procesy (POMDPs)



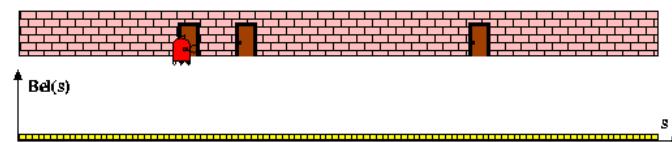
Neparametrické filtry

- Aproximace hustoty pravděpodobnosti konečnou množinou hodnot
- Umí reprezentovat libovolné rozložení
- Velikost množiny reprezentantů ovlivňuje rychlosť výpočtu a kvalitu filtrace
- Histogramový x částicový filtr



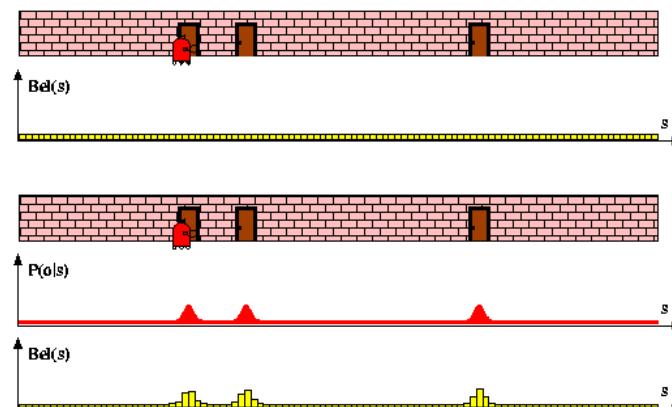


Histogramový filtr



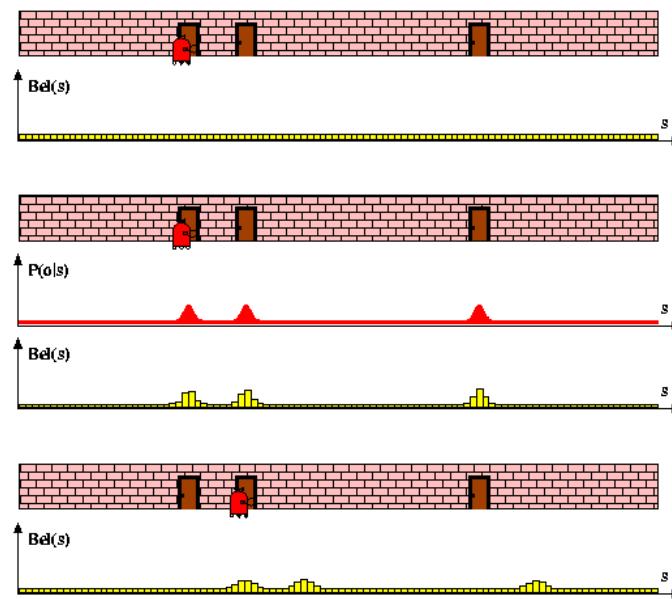


Histogramový filtr



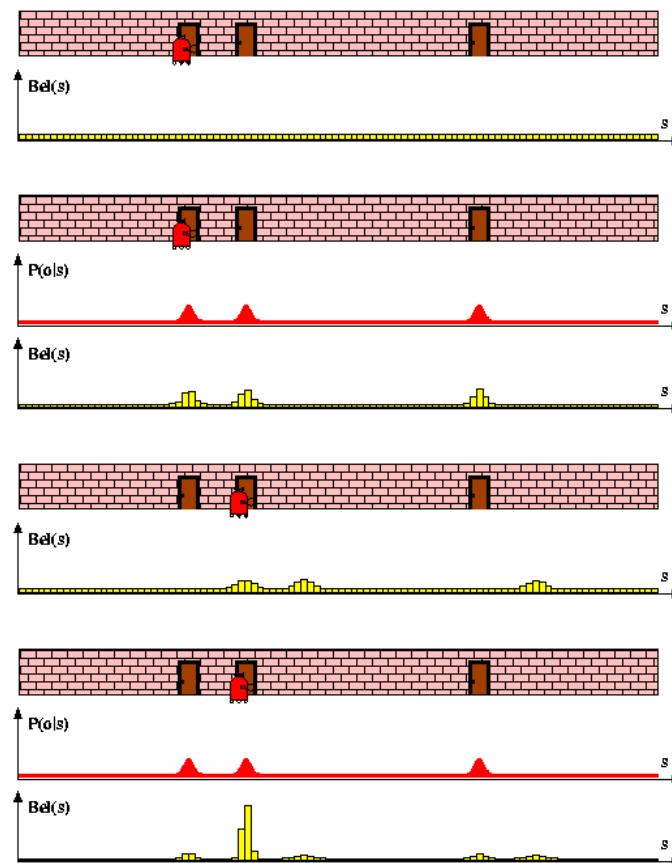


Histogramový filtr



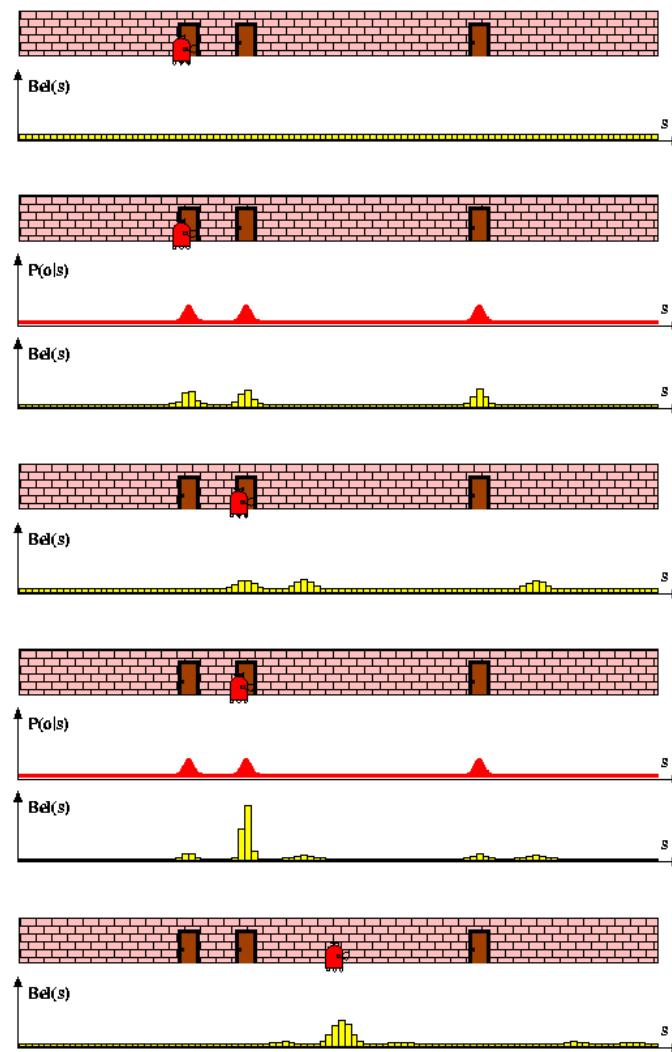


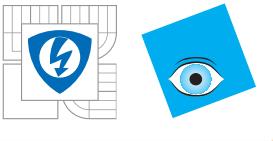
Histogramový filtr





Histogramový filtr





Histogramový filtr

if d is a **measurement** z **then**

$$\eta = 0$$

for all x **do**

$$Bel'(x) = p(z|x)Bel(x)$$

$$\eta = \eta + Bel'(x)$$

end for

for all x **do**

$$Bel'(x) = \eta^{-1}Bel'(x)$$

end for

else if d is a **action** u **then**

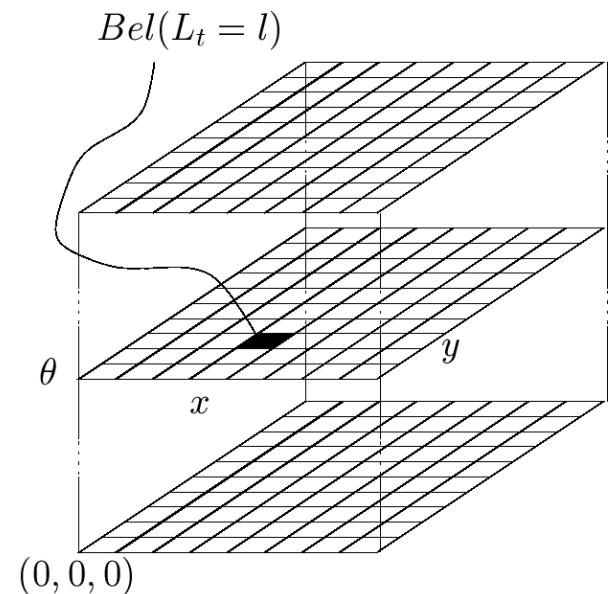
for all x **do**

$$Bel'(x) = \int p(x|u, x')Bel(x')dx'$$

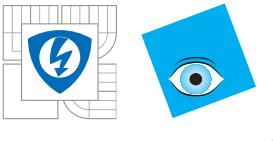
end for

end if

return $Bel'(x)$

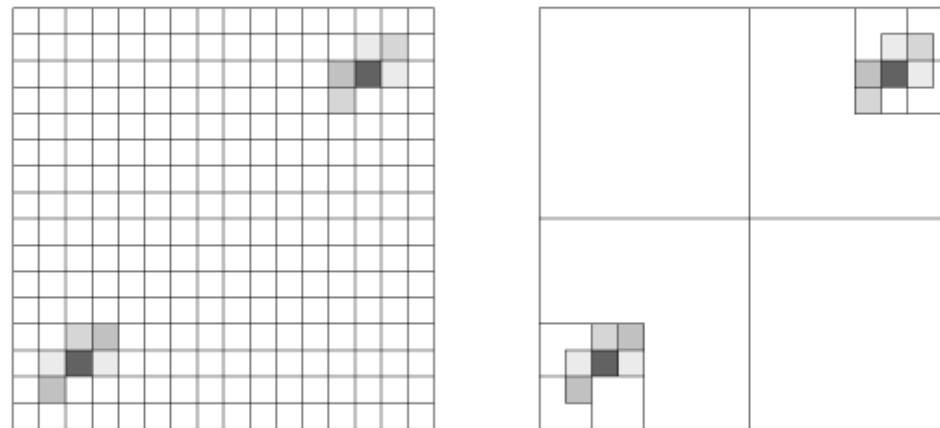


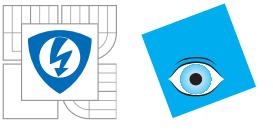
$$Bel(x_t = \langle x, y, \phi \rangle)$$



Histogramový filtr

- Složitost $O(n^2)$ – při aktualizaci z modelu pohybu se prochází každá buňka!
- Selektivní update
 - uvažuje se jen část stavového prostoru
 - ale pak je potřeba sledovat, jak úspěšně je robot lokalizován
- Dynamická dekompozice stavového prostoru – kd-stromy (density trees): „jemnost“ dělení závisí na hustotě pravděpodobnosti (vyšší hustota => jemnější dělení)



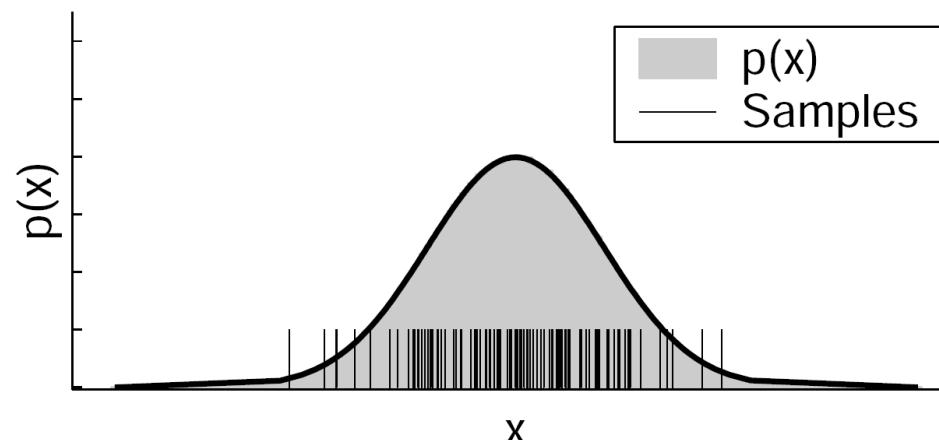


Částicový filtr (particle filter)

- Hustota pravděpodobnosti je reprezentována „vhodně“ (náhodně umístěnými vzorky):

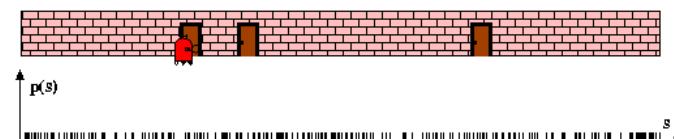
$$Bel(x_t) \approx \{x_{(i)}, w_{(i)}\}_{i=1,\dots,m}$$

- Vzorky jsou vážené.
- Podle váhy v čase $t - 1$ se vybírají vzorky pro čas t
- Velice jednoduchý na implementaci
- Nejuniverzálnější z BF: reprezentace **ne Gausovské** distribuce a **nelineárních** procesů



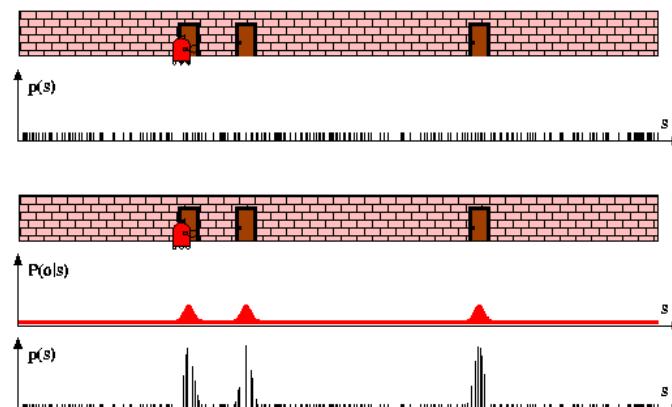


Částicový filtr



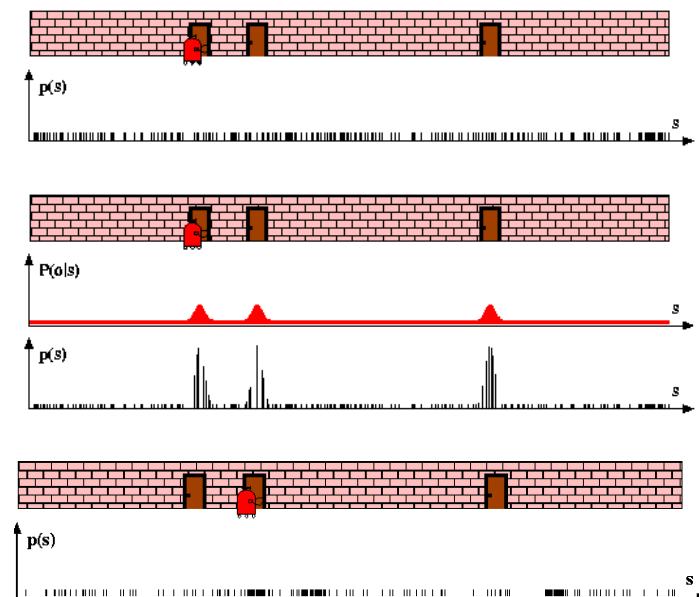


Částicový filtr



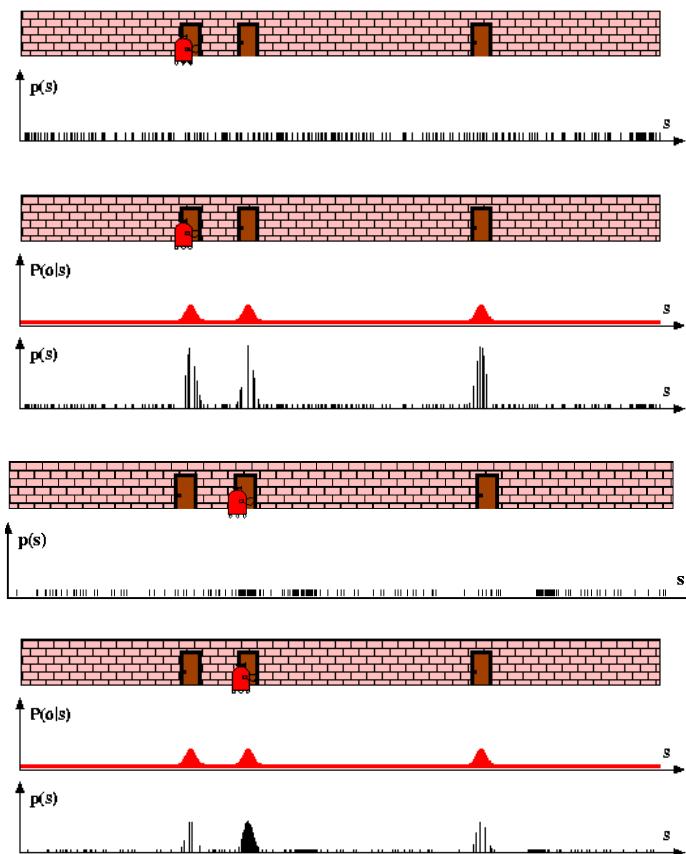


Částicový filtr



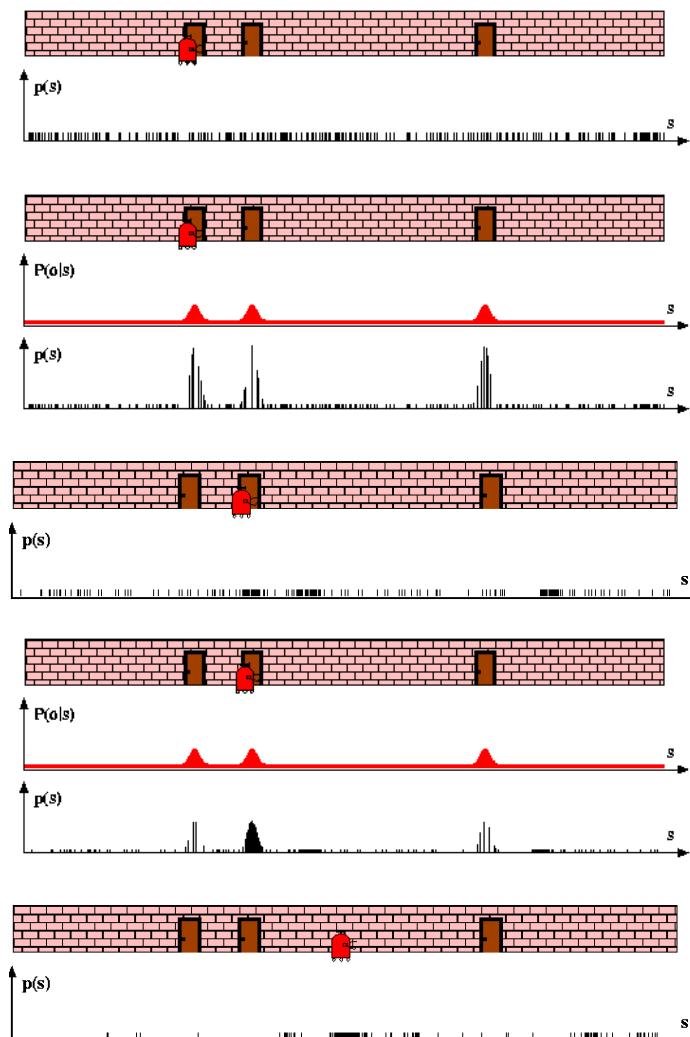


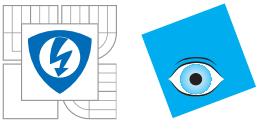
Částicový filtr





Částicový filtr





Algoritmus částicového filtrov

Particle_filter(S_{t-1}, u_{t-1}, z_t)

$S_t = \emptyset, \eta = 0$

for $i = 1, \dots, n$ **do**

 Vyber index j_i podle diskrétní distribuce dané w_{t-1}

 Vyber x_t^i z $p(x_t|x_{t-1}, u_{t-1})$ na základě $x_{t-1}^{j_i}$ a u_{t-1}

$w_t^i = p(z_t|x_t^i)$

$\eta = \eta + w_t^i$

$S_t = S_t \cup \{ \langle x_t^i, w_t^i \rangle \}$

end for

for $i = 1, \dots, n$ **do**

$w_t^i = \frac{w_t^i}{\eta}$

end for

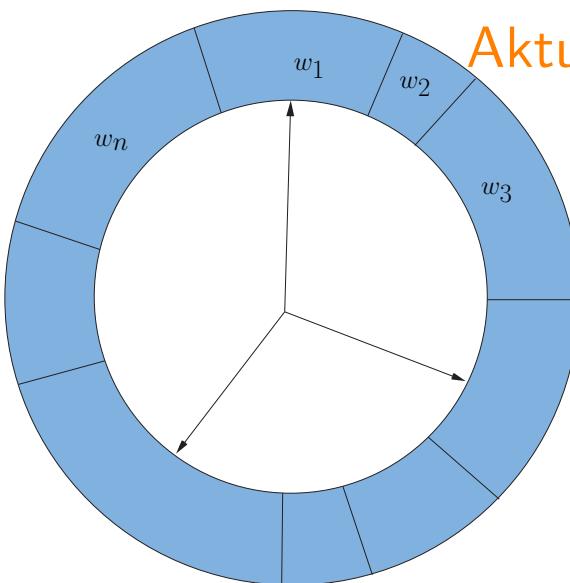
Generuj nové vzorky

Spočítej váhu

Aktualizuj normalizační faktor

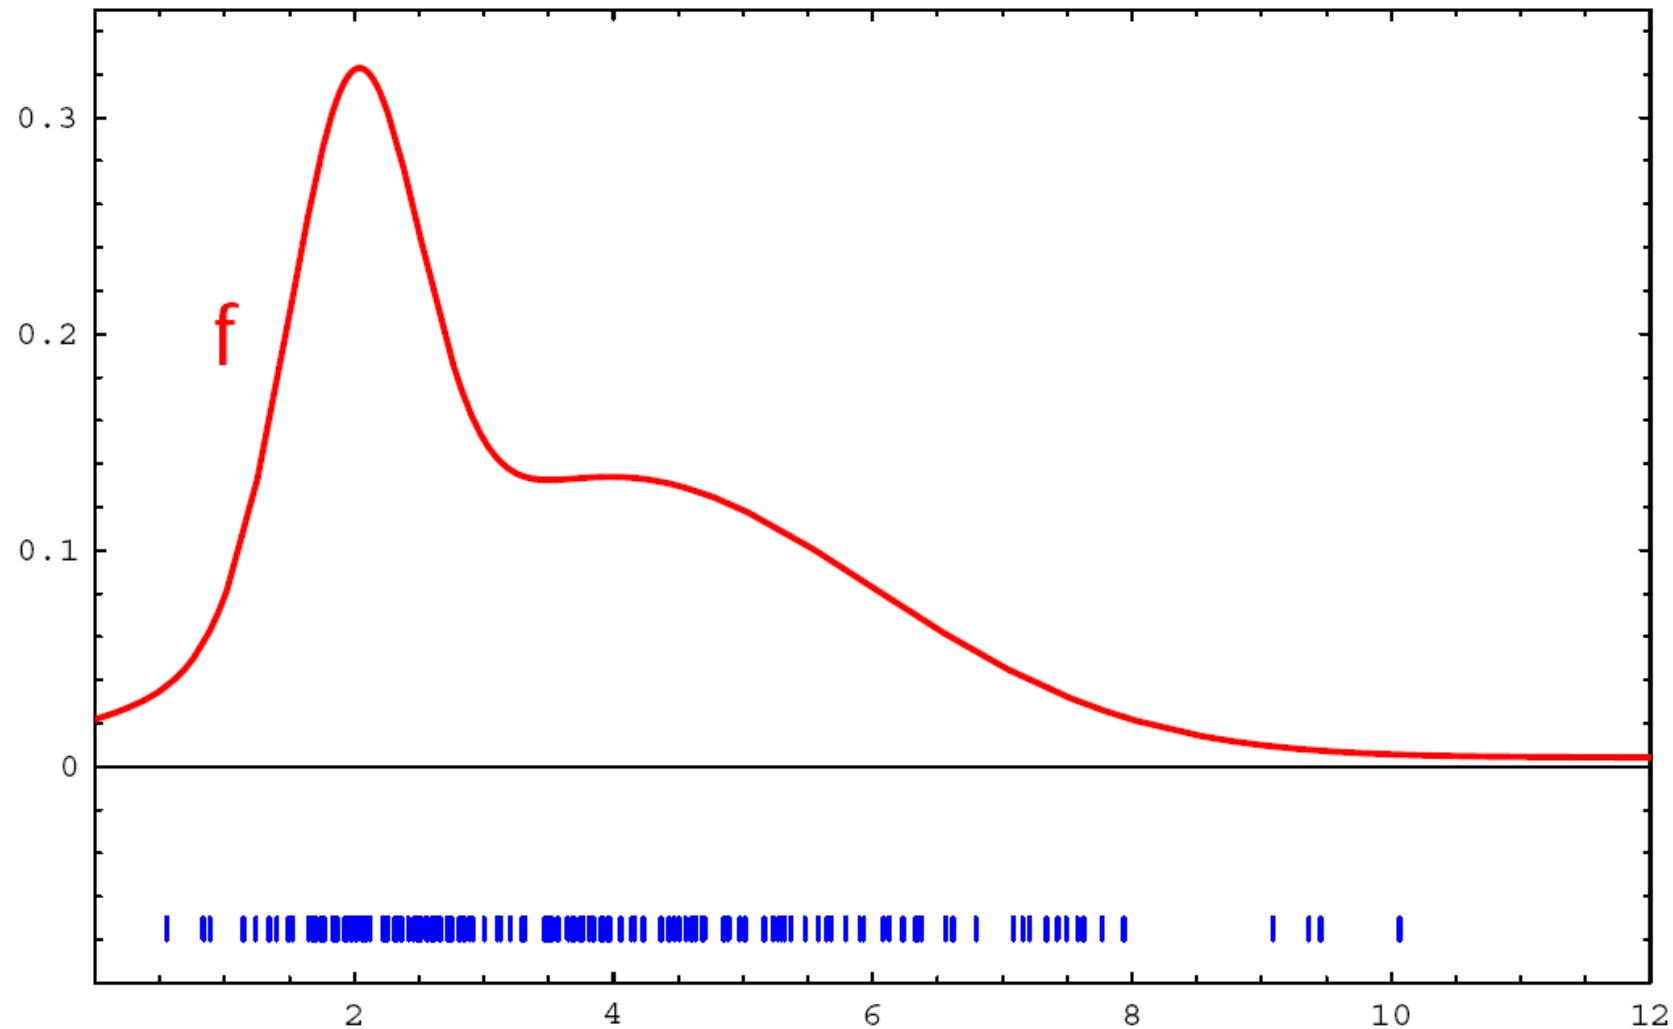
Přidej vzorek

Normalizuj váhy



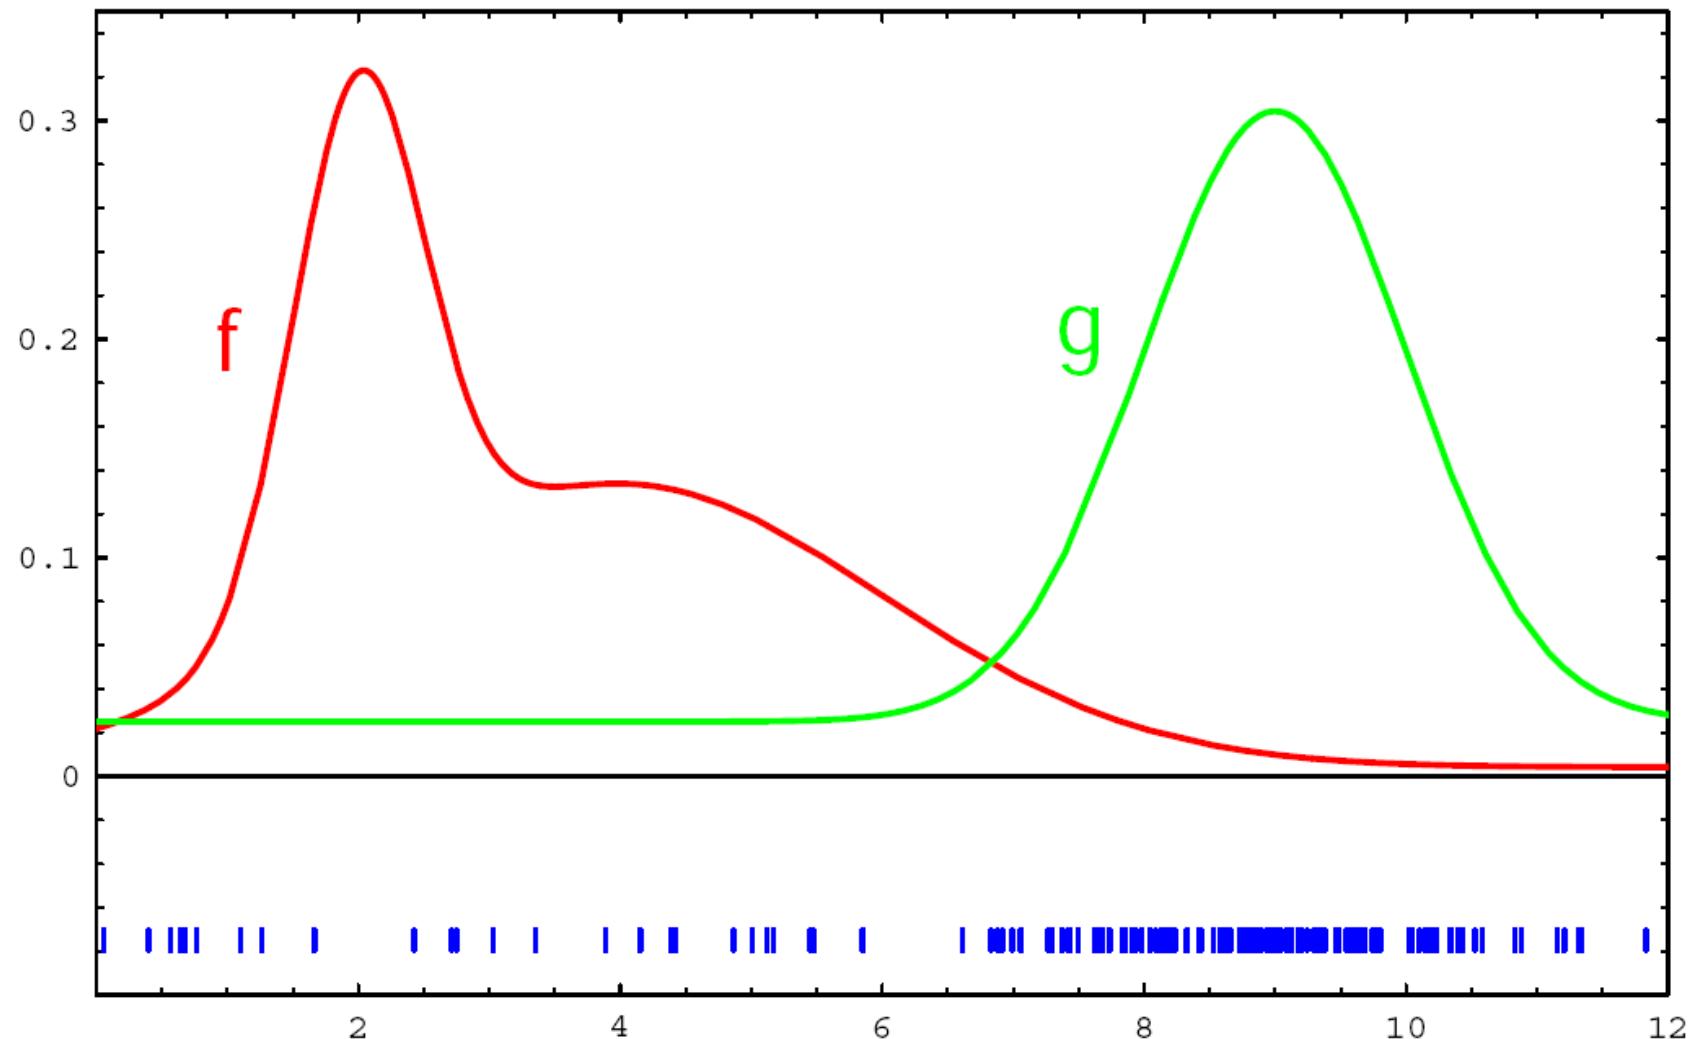


Proč se váží?



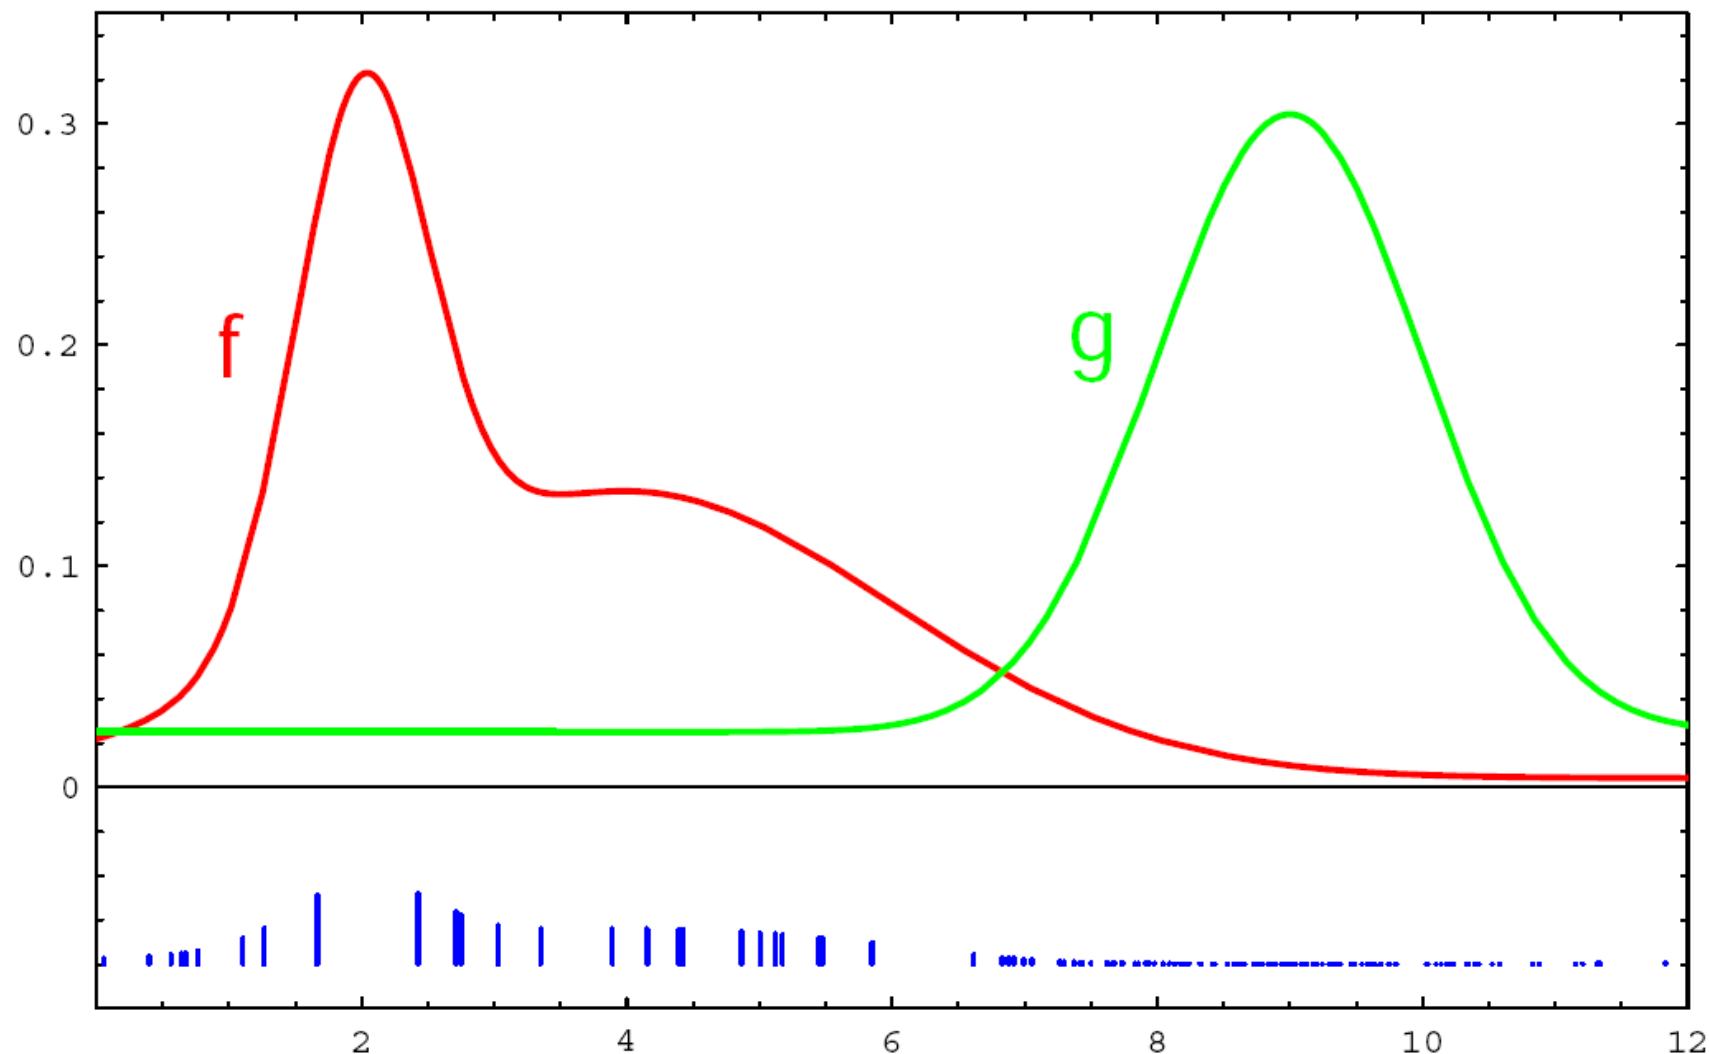


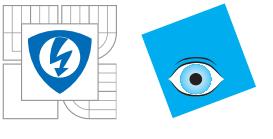
Proč se váží?





Proč se váží?





Kalmanův filtr

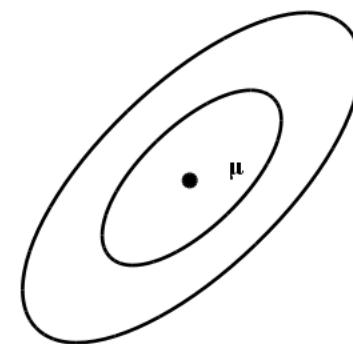
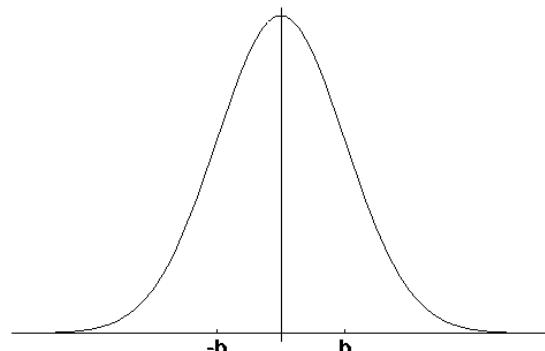
- Unimodální reprezentace hustoty pravděpodobnosti Gaussiaًm

$$p(x) \sim N(\mu, \sigma^2)$$

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

$$p(x) \sim N(\mu, \Sigma)$$

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





Lineární transformace

- Lineární transformace zachovávají normální rozdělení

$$\left. \begin{array}{l} X \sim N(\mu, \sigma^2) \\ Y = aX + b \end{array} \right\} \Rightarrow Y \sim N(a\mu + b, a^2\sigma^2)$$

$$\left. \begin{array}{l} X_1 \sim N(\mu_1, \sigma_1^2) \\ X_2 \sim N(\mu_2, \sigma_2^2) \end{array} \right\} \Rightarrow p(X_1)p(X_2) \sim N\left(\frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}\mu_1 + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\mu_2, \frac{1}{\sigma_1^{-2} + \sigma_2^{-2}}\right)$$

$$\left. \begin{array}{l} X \sim N(\mu, \Sigma) \\ Y = AX + B \end{array} \right\} \Rightarrow Y \sim N(A\mu + B, A\Sigma A^T)$$

$$\left. \begin{array}{l} X_1 \sim N(\mu_1, \Sigma_1) \\ X_2 \sim N(\mu_2, \Sigma_2) \end{array} \right\} \Rightarrow p(X_1)p(X_2) \sim N\left(\frac{\Sigma_2}{\Sigma_1 + \Sigma_2}\mu_1 + \frac{\Sigma_1}{\Sigma_1 + \Sigma_2}\mu_2, \frac{1}{\Sigma_1^{-1} + \Sigma_2^{-1}}\right)$$



Základní předpoklady

- Musí platit Markovova podmínka + tři následující:
 - Pravděpodobnost přechodu stavu (model pohybu) $p(x|u, x')$ je lineární s přidaným Gausovým šumem:

$$x_t = Ax_{t-1} + B_t u_t + \varepsilon_t$$

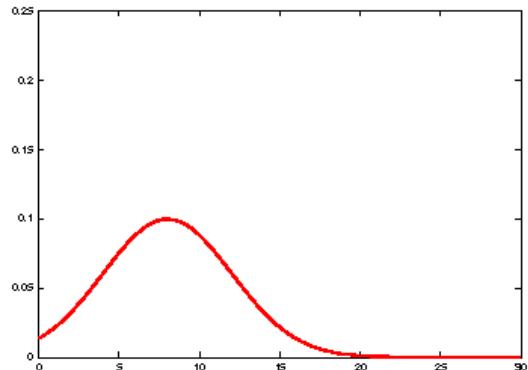
- Model senzoru musí být lineární s Gausovým šumem

$$z_t = Cx_t + \delta_t$$

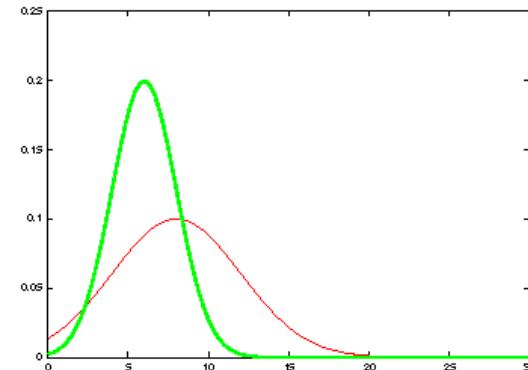
- Počáteční informace (víra) musí mít normální rozložení



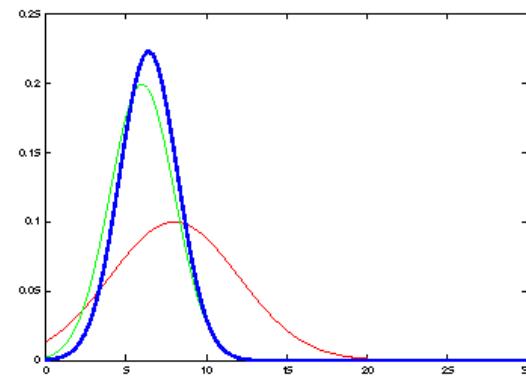
Kalmanův filtr



Apriorní znalost



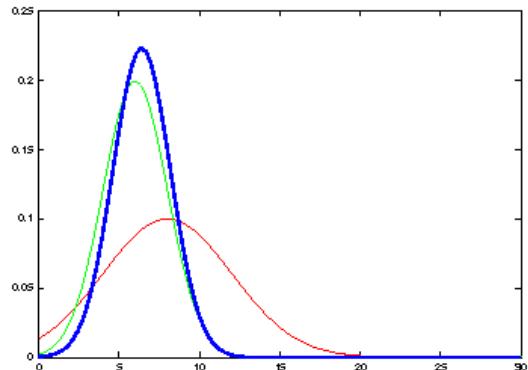
Nové měření



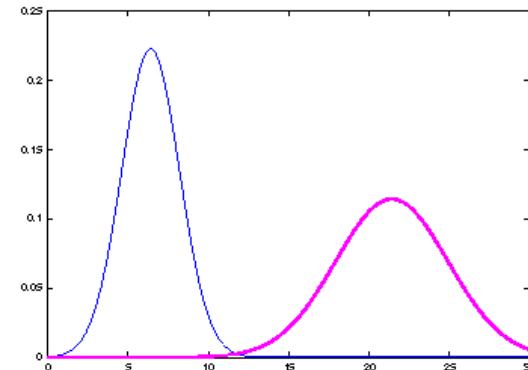
Integrace nového měření



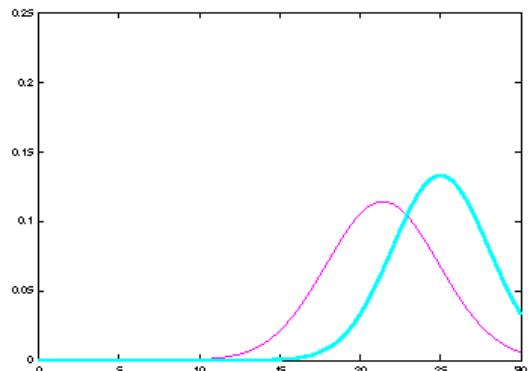
Kalmanův filtr



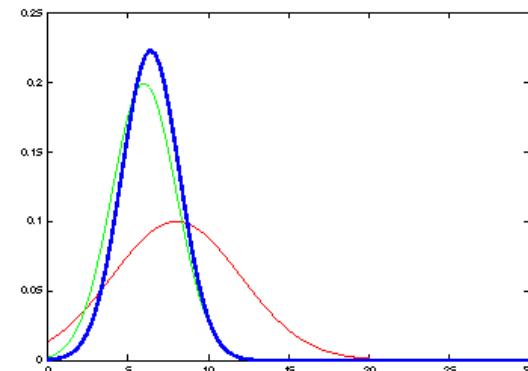
Aktuální stav



Provedení akce



Nové měření



Integrace nového měření



Algoritmus

Algoritmus Kalman_filter($\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$)

Predikce (integrace akce)

$$\bar{\mu}_t = A_t \mu_{t-1} + B_t u_t$$

$$\bar{\Sigma}_t = A_t \Sigma_{t-1} A_t^T + R_t$$

Korekce (integrace měření)

$$K_t = \bar{\Sigma}_t C_t^T (C_t \bar{\Sigma}_t C_t^T + Q_t)^{-1}$$

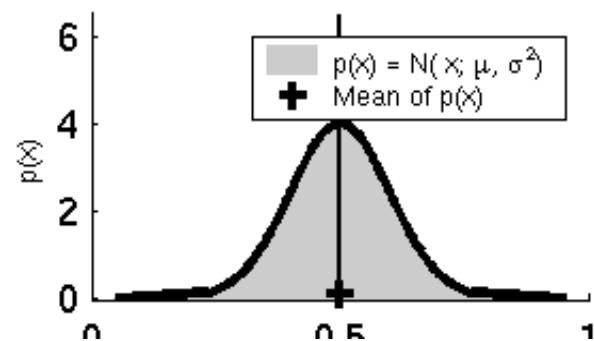
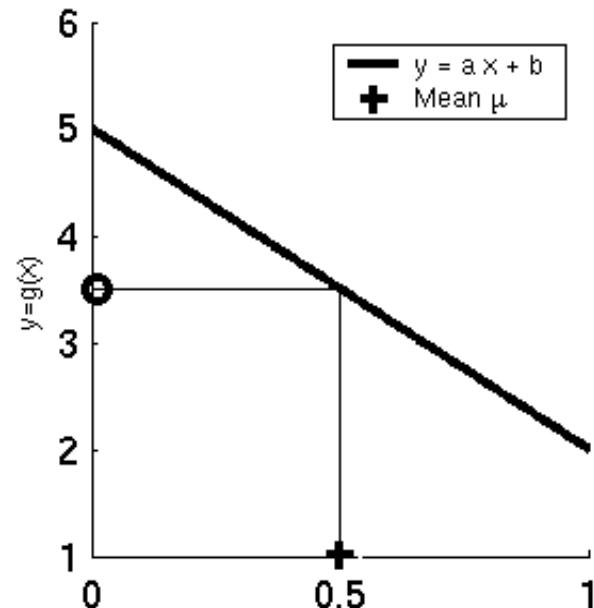
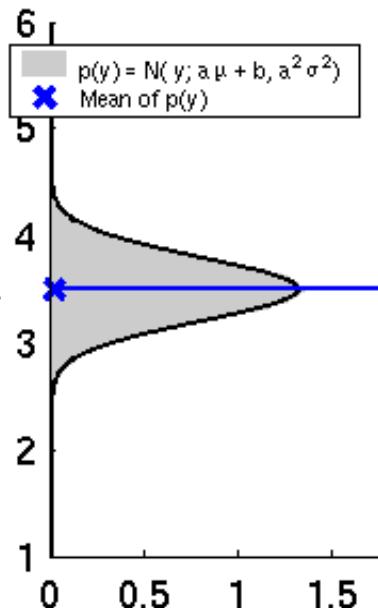
$$\mu_t = \bar{\mu}_t + K_t (z_t - C_t \bar{\mu}_t)$$

$$\Sigma_t = (E - K_t C_t) \bar{\Sigma}_t$$

return μ_t, Σ_t

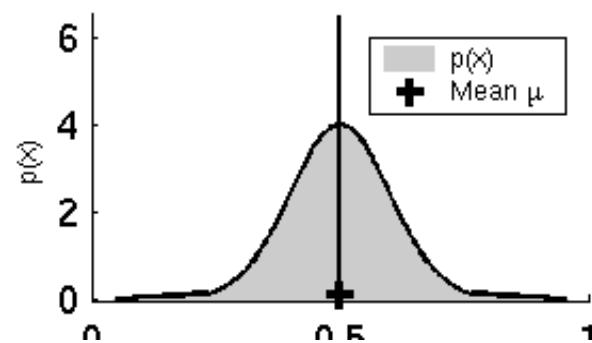
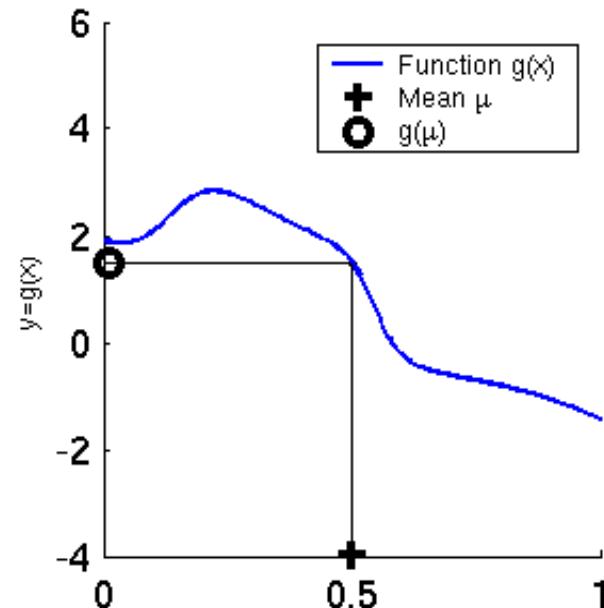
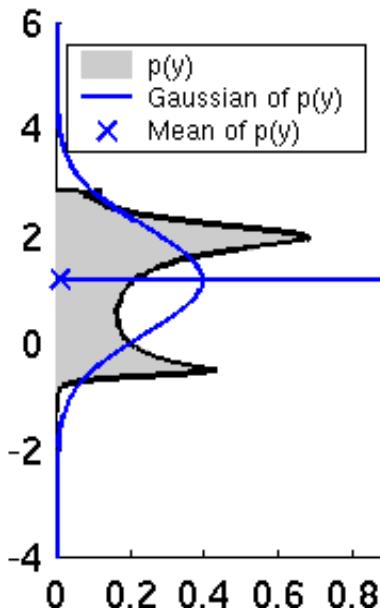


Lineární transformace Kalmanova filtru



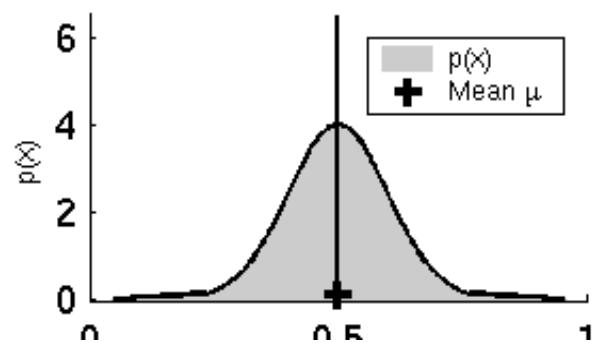
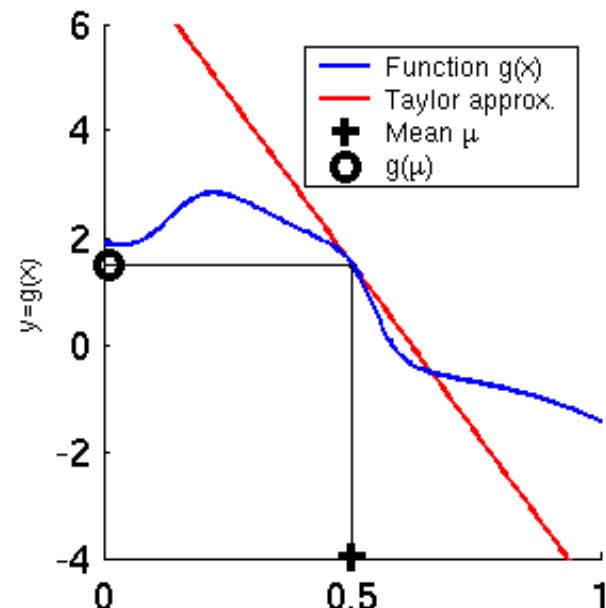
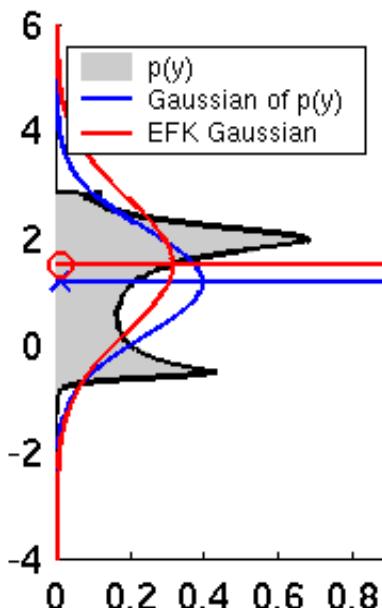


Nelineární transformace





Rozšířený Kalmanův filtr



$$x_t = g(u_t, x_{t-1})$$
$$z_t = h(x_t)$$



Rozšířený Kalmanův filtr

- Pro linearizaci používáme Taylorův rozvoj v μ , tj. matice derivací funkcí – Jakobiány
- Predikce:

$$g(u_t, x_{t-1}) \approx g(u_t, \mu_{t-1}) + \frac{\partial g(u_t, \mu_{t-1})}{\partial x_{t-1}}(x_{t-1} - \mu_{t-1})$$
$$g(u_t, x_{t-1}) \approx g(u_t, \mu_{t-1}) + G_t(x_{t-1} - \mu_{t-1})$$

- Korekce:

$$h(x_t) \approx h(\bar{\mu}_t) + \frac{\partial h(\bar{\mu}_t)}{\partial x_t}(x_t - \bar{\mu}_t)$$
$$h(x_t) \approx h(\bar{\mu}_t) + H_t(x_t - \bar{\mu}_t)$$



Algoritmus

Algoritmus Extended_Kalman_filter($\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$)

Predikce (integrace akce)

$$\bar{\mu}_t = g(u_t, \mu_{t-1})$$

$$\bar{\Sigma}_t = G_t \Sigma_{t-1} G_t^T + R_t$$

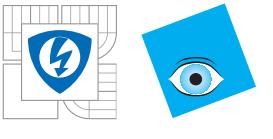
Korekce (integrace měření)

$$K_t = \bar{\Sigma}_t H_t^T (H_t \bar{\Sigma}_t H_t^T + Q_t)^{-1}$$

$$\mu_t = \bar{\mu}_t + K_t(z_t - h(\bar{\mu}_t))$$

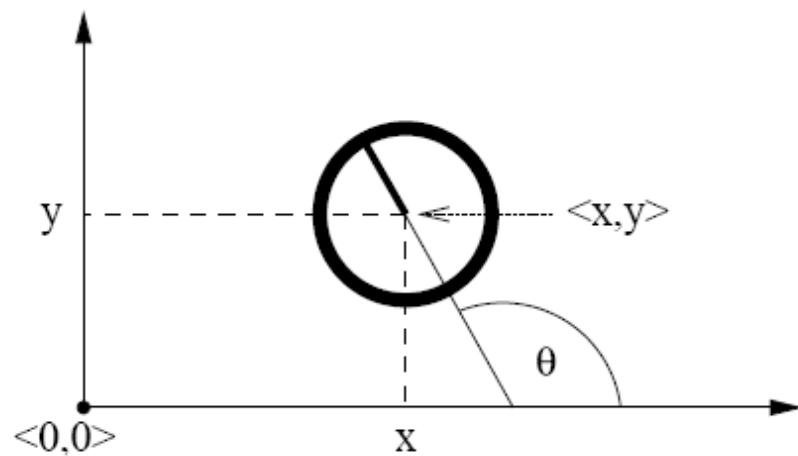
$$H_t = \frac{\partial h(\bar{\mu}_t)}{\partial x_t}$$

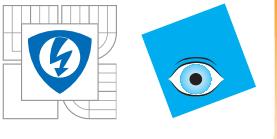
$$G_t = \frac{\partial g(u_t, \mu_{t-1})}{\partial x_{t-1}}$$



Model pohybu

- Pro implementaci Bayesova filtru potřebujeme definovat model pohybu $p(x|x', u)$.
- Model pohybu definuje pravděpodobnost, že po provedení akce u ve stavu x' bude robot ve stavu x . Předpokládáme robot pohybující se v rovině, tj $x = \langle x, y, \phi \rangle$
- Existují různé modely (v závislosti na typu řízení, zahrnutí kinematiky, atd.)



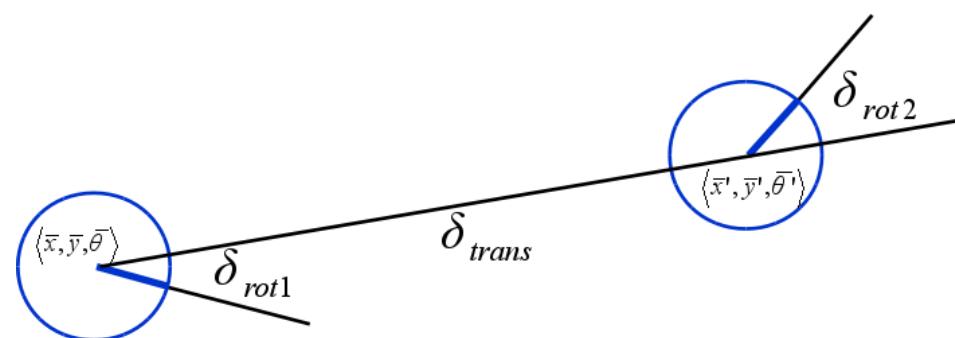


Odometrický model pohybu

Ideální případ

- Robot se pohybuje z $\langle \bar{x}, \bar{y}, \bar{\phi} \rangle$ do $\langle \bar{x}', \bar{y}', \bar{\phi}' \rangle$
- Z odometrie získáme $u = \langle \delta_{rot_1}, \delta_{rot_2}, \delta_{trans} \rangle$

$$\begin{aligned}\delta_{trans} &= \sqrt{(\bar{x}' - \bar{x})^2 + (\bar{y}' - \bar{y})^2} \\ \delta_{rot_1} &= atan2(\bar{y}' - \bar{y}, \bar{x}' - \bar{x}) - \bar{\phi} \\ \delta_{rot_2} &= \bar{\phi}' - \bar{\phi} - \delta_{rot_1}\end{aligned}$$





Přidáme šum

$$\hat{\delta}_{rot_1} = \delta_{rot_1} + \varepsilon_{\alpha_1} |\delta_{rot_1}| + \alpha_2 |\delta_{trans}|$$

$$\hat{\delta}_{trans} = \delta_{trans} + \varepsilon_{\alpha_3} |\delta_{trans}| + \alpha_4 (|\delta_{rot_1}| + |\delta_{rot_2}|)$$

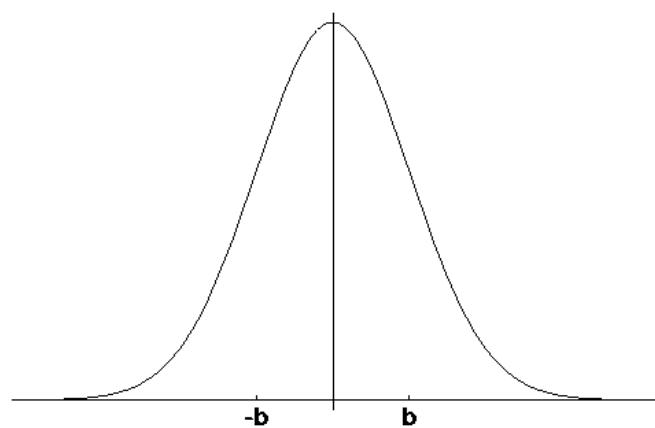
$$\hat{\delta}_{rot_2} = \delta_{rot_2} + \varepsilon_{\alpha_1} |\delta_{rot_2}| + \alpha_2 |\delta_{trans}|$$

- Šum je dán čtyřmi parametry
- Na celém modelu je nejtěžší získat právě parametry šumu – experimentálně



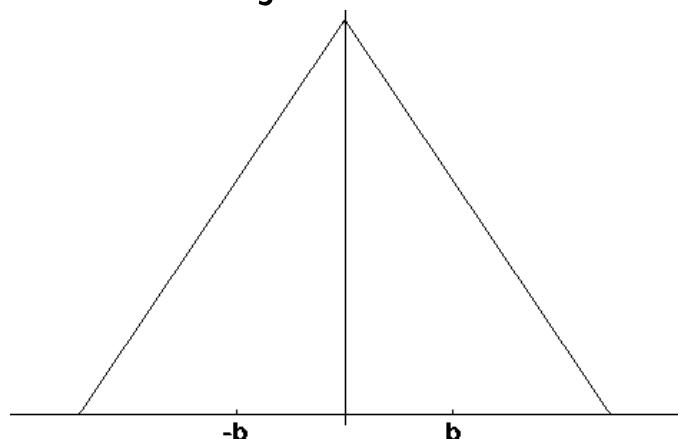
Typické distribuce šumu

Normální

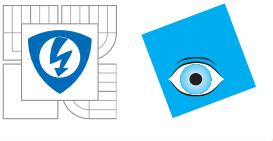


$$\varepsilon_{\sigma^2}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}}$$

Trojúhelníková



$$\varepsilon_{\sigma^2}(x) = \begin{cases} 0 & \text{pokud } |x| > \sqrt{6\sigma^2} \\ \frac{\sqrt{6\sigma^2} - |x|}{6\sigma^2} & \text{jinak} \end{cases}$$



Odometrický model pro vzorkování

$$u = \langle \delta_{rot_1}, \delta_{rot_2}, \delta_{trans} \rangle, x = \langle x, y, \phi \rangle \Rightarrow x' = \langle x', y', \phi' \rangle$$

Náhodné řízení

$$\begin{aligned}\hat{\delta}_{rot_1} &= \delta_{rot_1} + sample(\alpha_1 |\delta_{rot_1}| + \alpha_2 |\delta_{trans}|) \\ \hat{\delta}_{trans} &= \delta_{trans} + sample(\alpha_3 |\delta_{trans}| + \alpha_4 (|\delta_{rot_1}| + |\delta_{rot_2}|)) \\ \hat{\delta}_{rot_2} &= \delta_{rot_2} + sample(\alpha_1 |\delta_{rot_2}| + \alpha_2 |\delta_{trans}|)\end{aligned}$$

Výpočet pozice

$$\begin{aligned}x' &= x + \hat{\delta}_{trans} + \cos(\phi + \hat{\delta}_{rot_1}) \\ y' &= x + \hat{\delta}_{trans} + \sin(\phi + \hat{\delta}_{rot_1}) \\ \phi' &= \phi + \hat{\delta}_{rot_1} + \hat{\delta}_{rot_2} \\ \text{return } &\langle x', y', \phi' \rangle\end{aligned}$$

sample (normální rozložení): $\frac{1}{2} \sum_{i=1}^{12} rand(-b, b)$



Výpočet $p(x|u, x')$

Hodnoty z odometrie (u)

$$\begin{aligned}\delta_{trans} &= \sqrt{(\bar{x}' - \bar{x})^2 + (\bar{y}' - \bar{y})^2} \\ \delta_{rot_1} &= atan2(\bar{y}' - \bar{y}, \bar{x}' - \bar{x}) - \bar{\phi} \\ \delta_{rot_2} &= \bar{\phi}' - \bar{\phi} - \delta_{rot_1}\end{aligned}$$

Ideální případ

$$\begin{aligned}\hat{\delta}_{trans} &= \sqrt{(x' - x)^2 + (y' - y)^2} \\ \hat{\delta}_{rot_1} &= atan2(y' - y, x' - x) - \phi \\ \hat{\delta}_{rot_2} &= \phi' - \phi - \delta_{rot_1}\end{aligned}$$

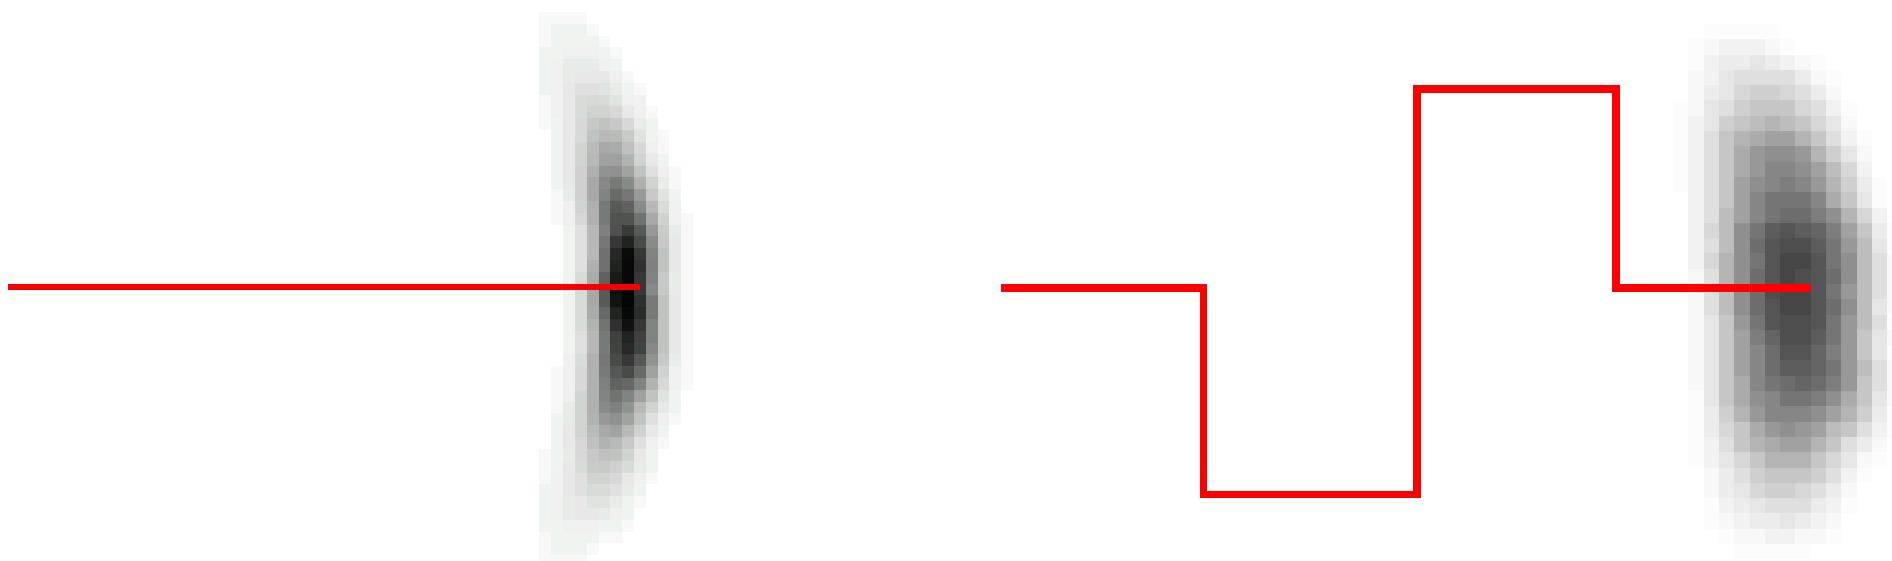
Výpočet pravděpodobnosti

$$\begin{aligned}p_1 &= prob(\delta_{rot_1} - \hat{\delta}_{rot_1}, \alpha_1 |\delta_{rot_1}| + \alpha_2 \delta_{trans}) \\ p_2 &= prob(\delta_{trans} - \hat{\delta}_{trans}, \alpha_3 \delta_{trans} + \alpha_4 (|\delta_{rot_1}| + |\delta_{rot_2}|)) \\ p_3 &= prob(\delta_{rot_2} - \hat{\delta}_{rot_2}, \alpha_1 |\delta_{rot_2}| + \alpha_2 \delta_{trans}) \\ \text{return } p_1 p_2 p_3 &\leftarrow \text{předpokládáme nezávislost}\end{aligned}$$



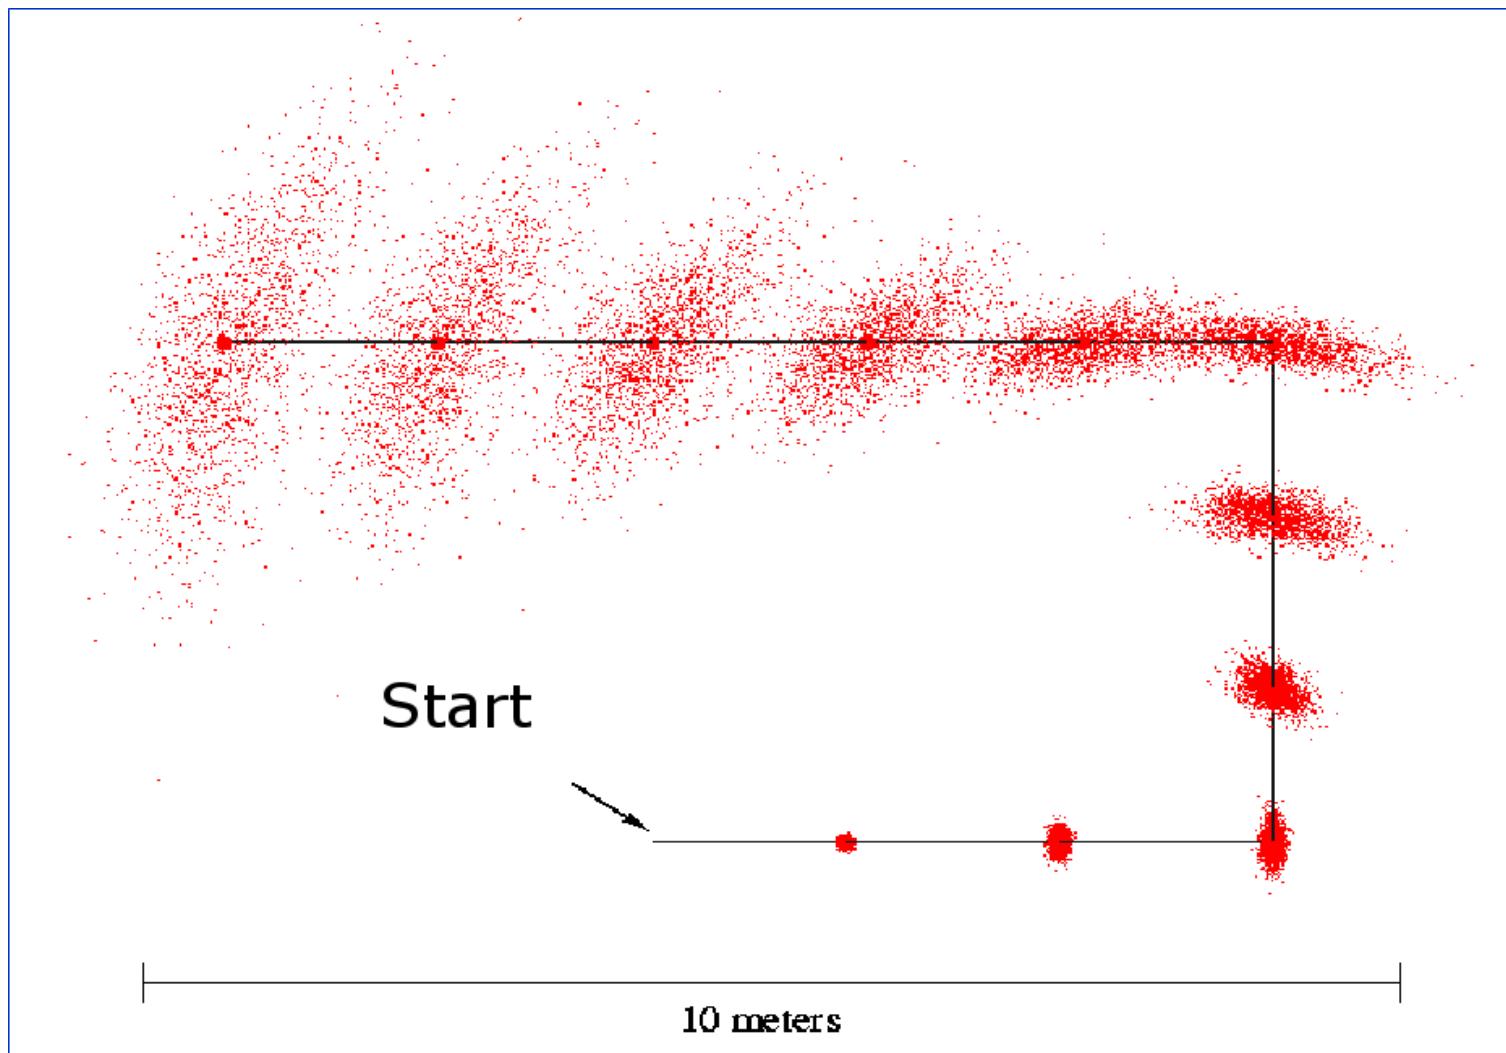
Aplikace

- Výsledná hustota pravděpodobnosti závisí na ujeté trajektorii, ne pouze na výsledné pozici!
- Pro složitější pohyby se opakovaně provádí předchozí algoritmus.
- Typický případ, jak vypadá distribuce (2D projekce)





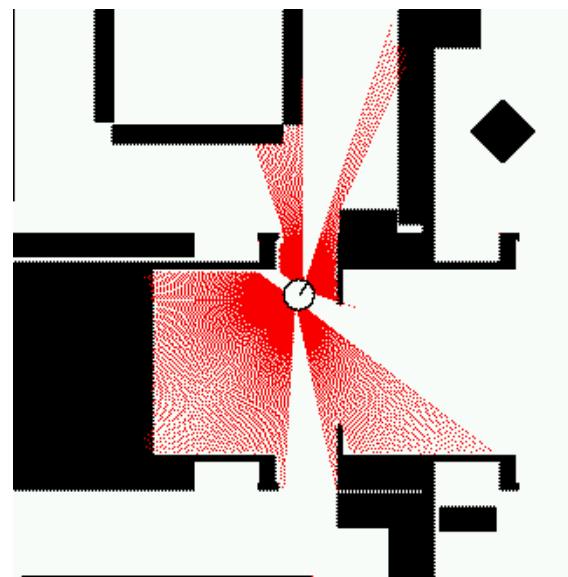
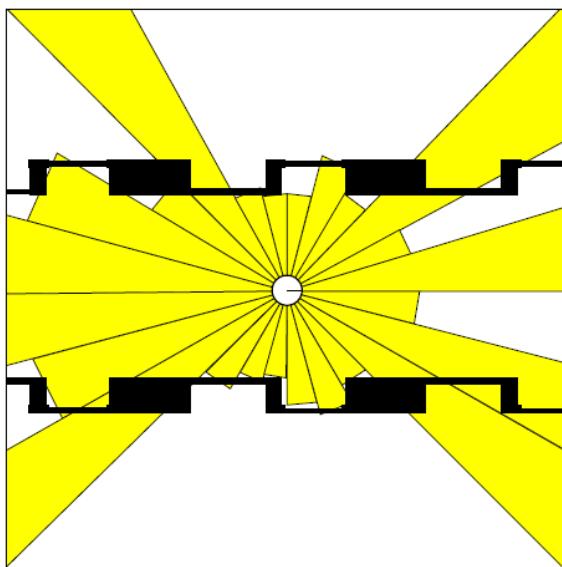
Skládání trajektorií





Model senzoru

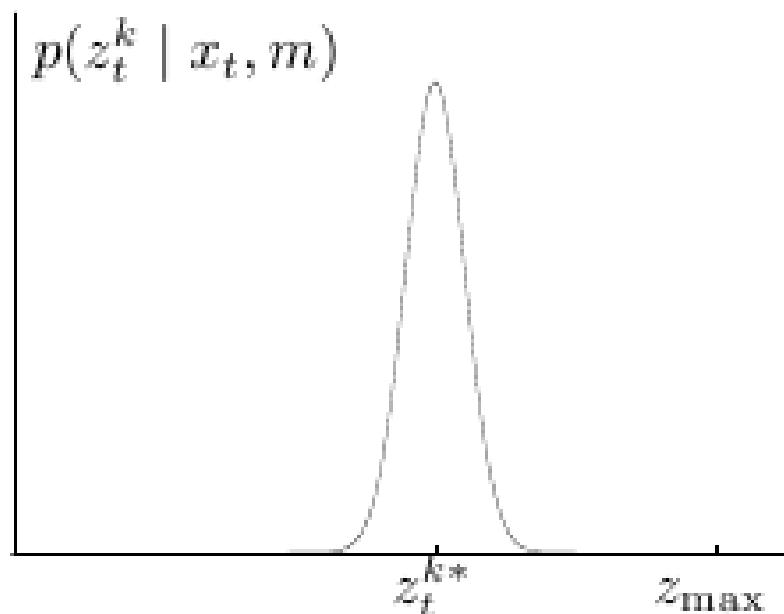
- Cílem je určit $p(z|m, x)$.
- Budeme používat proximitní senzory (laser).
- Scan se skládá z k měření (paprsků): $z = \{z_1, z_2, \dots, z_k\}$
- Předpokládáme, že paprsky jsou nezávislé: $P(z|x, m) = \prod_{k=1}^K p(z_k|x, m)$



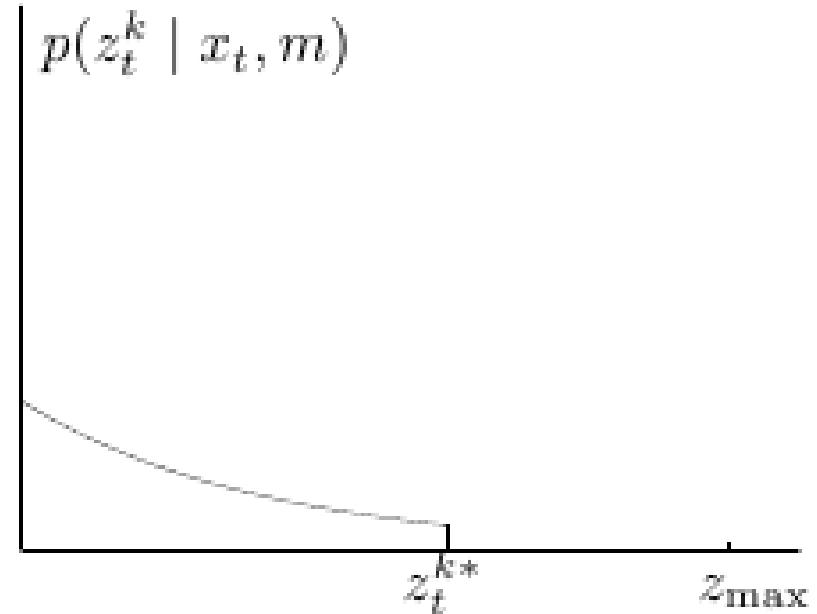


Paprskový model - komponenty

Normální rozložení



Poisonovo rozložení



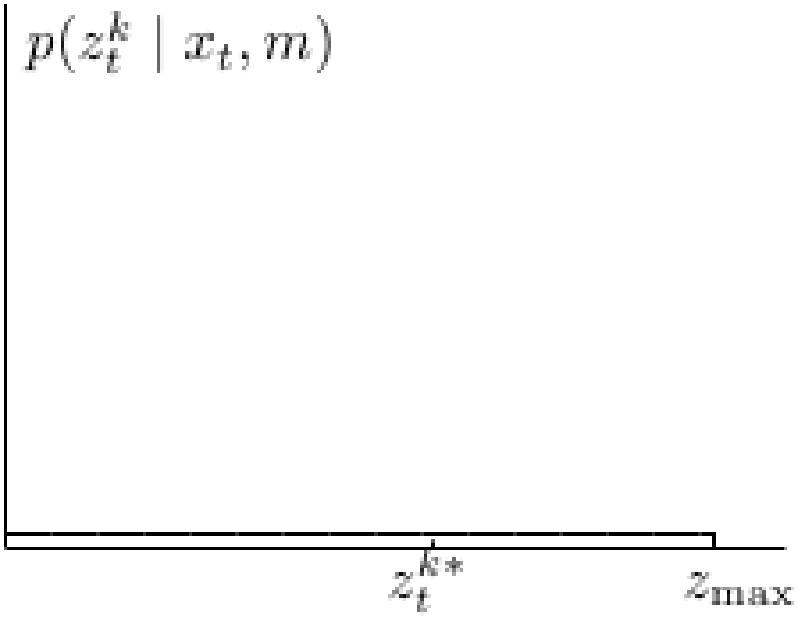
$$p_{hit}(z|x, m) = \begin{cases} \eta N(z, z^*, \sigma_{hit}^2) & \text{pokud } 0 \leq z \leq z_{\max} \\ 0 & \text{jinak} \end{cases}$$

$$p_{short}(z|x, m) = \begin{cases} \eta \lambda_{short} e^{-\lambda_{short} z} & \text{pokud } 0 \leq z \leq z^* \\ 0 & \text{jinak} \end{cases}$$



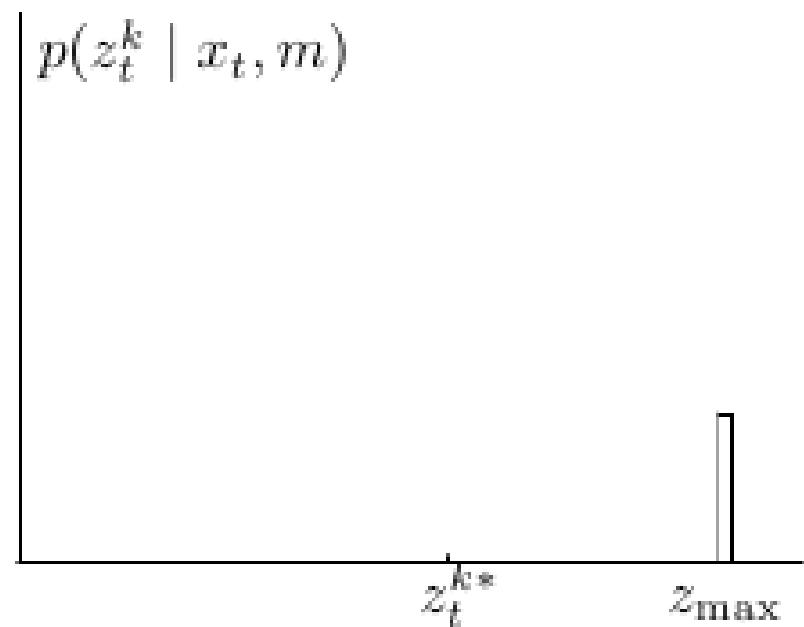
Paprskový model - komponenty

Rovnoměrné rozložení



$$p_{rand}(z|x, m) = \begin{cases} \frac{1}{z_{\max}} & \text{pokud } 0 \leq z \leq z_{\max} \\ 0 & \text{jinak} \end{cases}$$

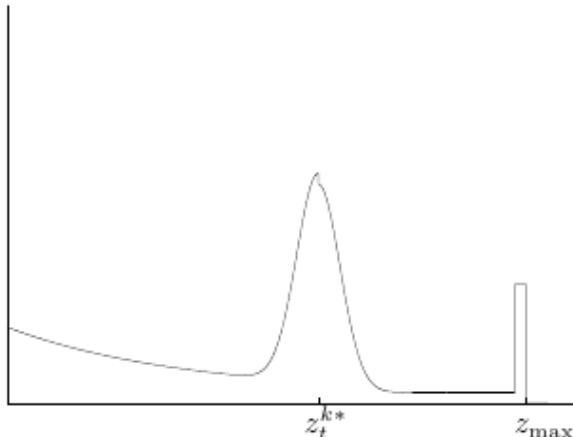
Diskrétní rozložení :-)



$$p_{max}(z|x, m) = \begin{cases} 1 & \text{pokud } z = z_{\max} \\ 0 & \text{jinak} \end{cases}$$

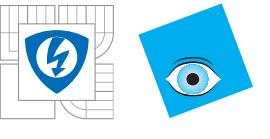


Sloučení



$$p(z|x, m) = \begin{pmatrix} \alpha_{hit} \\ \alpha_{short} \\ \alpha_{rand} \\ \alpha_{max} \end{pmatrix}^T \begin{pmatrix} p_{hit}(z|x, m) \\ p_{short}(z|x, m) \\ p_{rand}(z|x, m) \\ p_{max}(z|x, m) \end{pmatrix}$$

- Parametry modelu se určí nějakým učícím algoritmem na základě naměřených dat (E-M, genetické algoritmy)
- z_{exp} se počítá raytracingem, což je časově náročné.
- Lze počítat jen některé paprsky (např. 8); navíc větší nezávislost.
- Lze použít předpočítané mapy (pro každé $\langle x, y, z\phi \rangle$)
- Vynásobením modelu senzoru $\lambda < 1$ omezíme vliv senzoru.
- Model je nespojitý \Rightarrow aproximační vyjádření hustoty pp. může minout daný stav.



Sloučení

V prezentaci byly použity obrázky z prezentací Sebastiana Thruna (<http://probabilisticrobotics.org/>).

