



Navegação Autônoma de Robôs Móveis


SCC 5865 ROBÓTICA

Considerações Iniciais

Entendendo o problema:

Navegação Autônoma:

Sistema independente de intervenção humana



Problema:

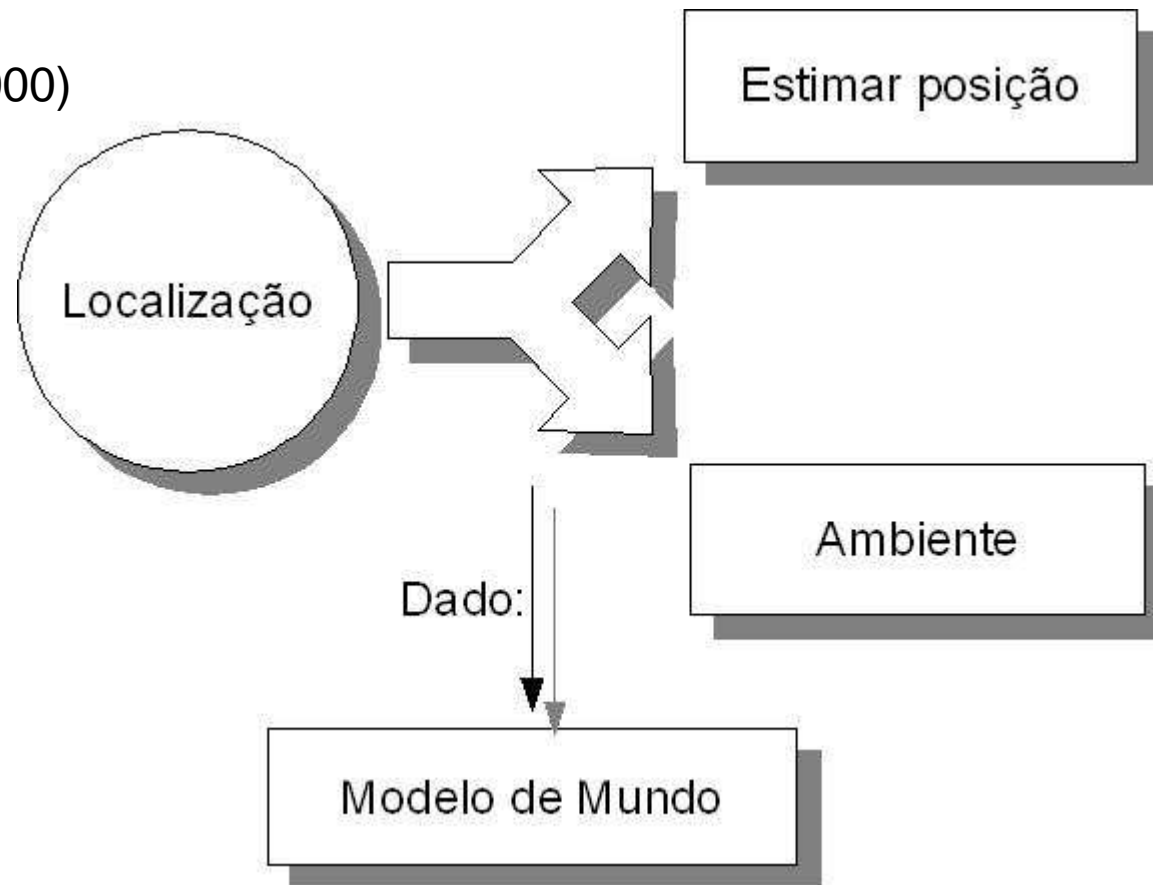
Localização

Mapeamento

Planejamento de Trajetórias

Localização

(Olson, 2000)



Localização

Paradigmas:

- ❖ Métodos Locais X Métodos Globais;
- ❖ Ambientes Estáticos X Ambiente Dinâmicos;
- ❖ Métodos Passivos X Métodos Ativos;
- ❖ Único Robô X Múltiplos Robôs.






(Thrun et al., 2000)

The Localization Problem

- Estimate robot's coordinates $s=(x,y,\theta)$ from sensor data
 - Position tracking (error bounded)
 - Global localization (unbounded error)
 - Kidnapping (recovery from failure)

Ingemar Cox (1991): “*Using sensory information to locate the robot in its environment is the most fundamental problem to provide a mobile robot with autonomous capabilities.*”

Probabilistic Localization



Sebastian Thrun

[Simmons/Koenig 95]
[Kaelbling et al 96]
[Burgard et al 96]

Bayes Filters

d = data
 o = observation
 a = action
 t = time
 s = state

$$b(s_t) = p(s_t | d_{0..t})$$

$$= p(s_t | o_t, a_{t-1}, o_{t-1}, \dots, o_0)$$

$$\stackrel{\text{Bayes}}{=} \eta p(o_t | s_t, a_{t-1}, o_{t-1}, \dots, o_0) p(s_t | a_{t-1}, o_{t-1}, \dots, o_0)$$

$$\stackrel{\text{Markov}}{=} \eta p(o_t | s_t) p(s_t | a_{t-1}, o_{t-1}, \dots, o_0)$$

$$= \eta p(o_t | s_t) \int p(s_t | s_{t-1}, a_{t-1}, \dots, o_0) p(s_{t-1} | a_{t-1}, \dots, o_0) ds_{t-1}$$

$$\stackrel{\text{Markov}}{=} \eta p(o_t | s_t) \int p(s_t | s_{t-1}, a_{t-1}) p(s_{t-1} | o_{t-1}, a_{t-2}, \dots, o_0) ds_{t-1}$$

$$= \eta p(o_t | s_t) \int p(s_t | s_{t-1}, a_{t-1}) p(s_{t-1} | d_{0..t-1}) ds_{t-1}$$

$$= \eta p(o_t | s_t) \int p(s_t | s_{t-1}, a_{t-1}) b(s_{t-1}) ds_{t-1}$$

Bayes Filters are Familiar to AI!

$$b(s_t) = \eta p(o_t | s_t) \int p(s_t | s_{t-1}, a_{t-1}) b(s_{t-1}) ds_{t-1}$$

- Kalman filters
- Hidden Markov Models
- Dynamic Bayes networks
- Partially Observable Markov Decision Processes (POMDPs)

Markov Assumption

$$\left. \begin{aligned} p(o_t | s_t, a_{t-1}, o_{t-1}, \dots, o_0) &= p(o_t | s_t) \\ p(s_t | s_{t-1}, a_{t-1}, o_{t-1}, \dots, o_0) &= p(s_t | s_{t-1}, a_{t-1}) \end{aligned} \right\} \text{ used above}$$

$$\Leftrightarrow p(o_T, \dots, o_t, a_{t-1}, \dots, o_0 | s_t) = p(o_T, \dots, o_t | s_t) p(a_{t-1}, \dots, o_0 | s_t)$$

Knowledge of current state renders past, future independent:

- “Static World Assumption”
- “Independent Noise Assumption”


Localization With Bayes Filters

$$b(s_t) = \eta p(o_t | s_t) \int p(s_t | s_{t-1}, a_{t-1}) b(s_{t-1}) ds_{t-1}$$

$$\Rightarrow b(s_t | m) = \eta p(o_t | s_t, m) \int p(s_t | s_{t-1}, a_{t-1}, m) b(s_{t-1} | m) ds_{t-1}$$



observation o





$p(o/s, m)$

Xavier: (R. Simmons, S. Koenig, CMU 1996) Markov localization in a topological map


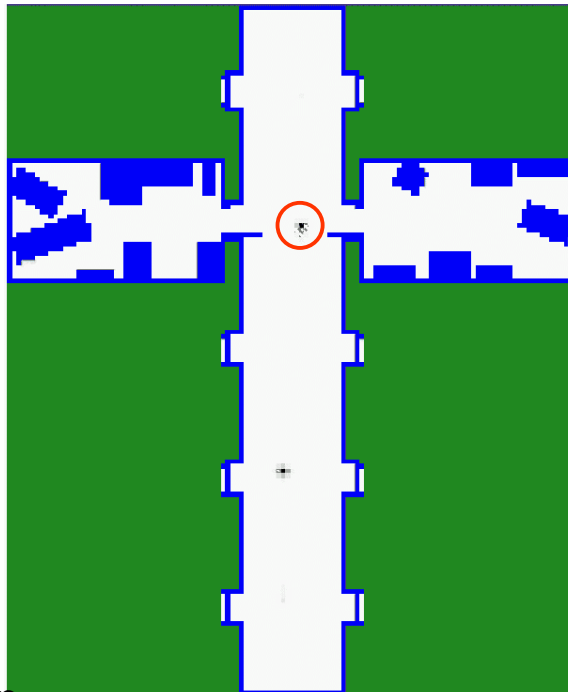


Sebastian Thrun

Markov Localization in Grid Map

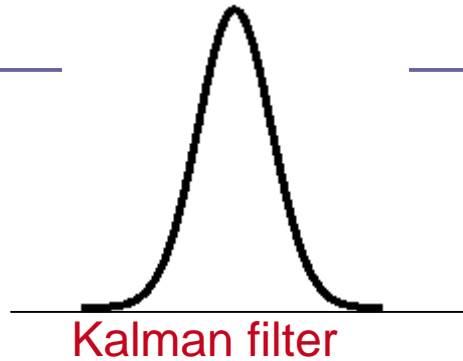


Sebastian Thrun

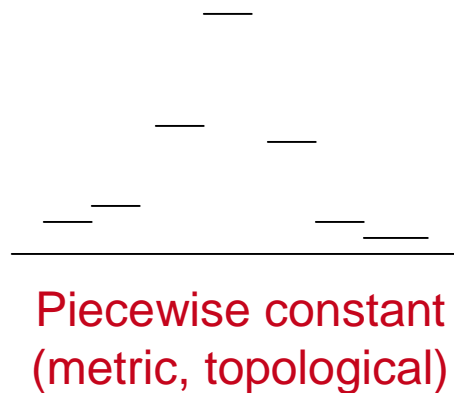


[Burgard et al 96] [Fox 99]

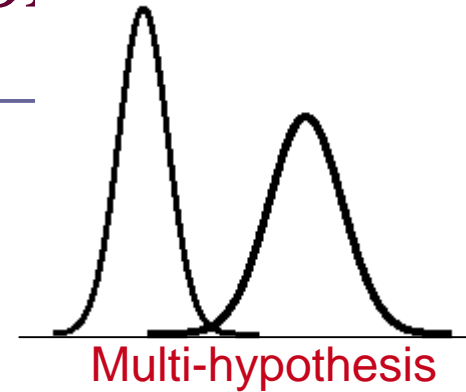
What is the Right Representation?



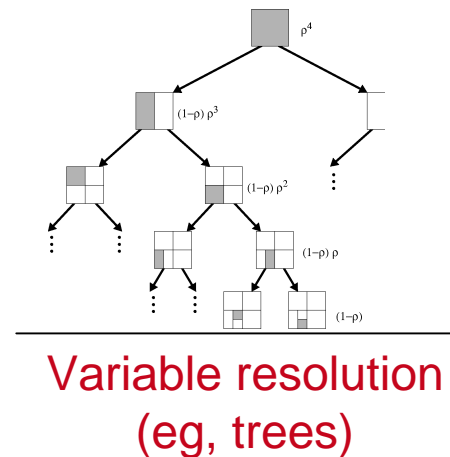
[Schiele et al. 94], [Weiß et al. 94], [Borenstein 96],
[Gutmann et al. 96, 98], [Arras 98]



[Nourbakhsh et al. 95], [Simmons et al. 95], [Kaelbling et al. 96],
[Burgard et al. 96], [Konolige et al. 99]



[Weckesser et al. 98], [Jensfelt et al. 99]




[Burgard et al. 98]

Sebastian Thrun



Idea: Represent Belief Through Samples

$$b(s_t | m) = \eta p(o_t | s_t, m) \int p(s_t | s_{t-1}, a_{t-1}, m) b(s_{t-1} | m) ds_{t-1}$$




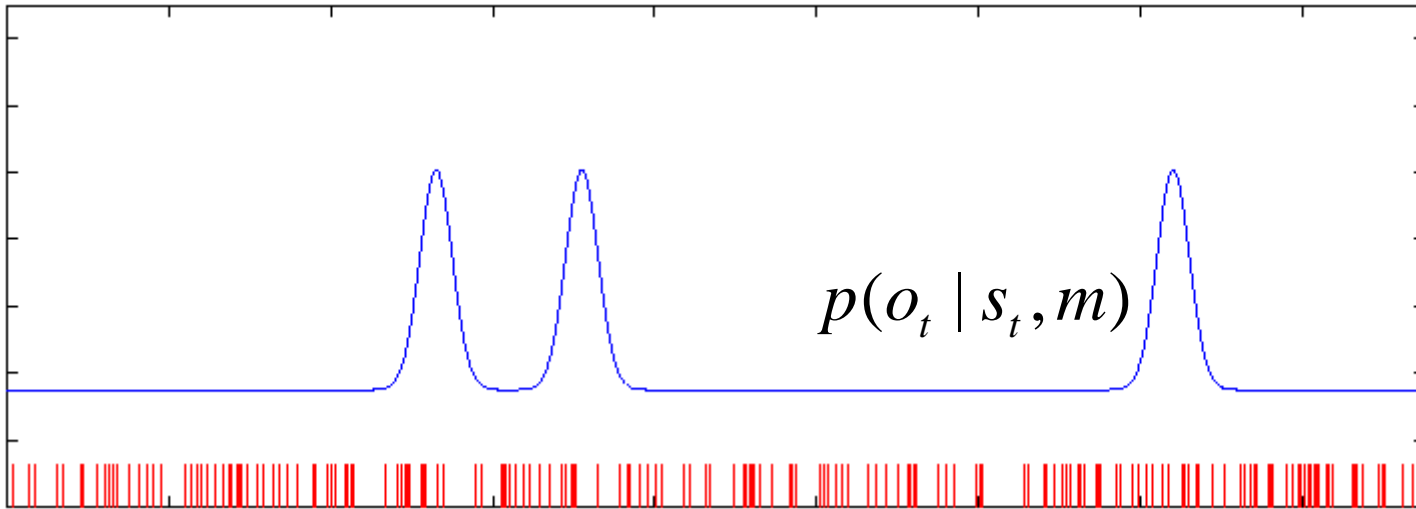

- Particle filters
[Doucet 98, deFreitas 98]
- Condensation algorithm
[Isard/Blake 98]
- Monte Carlo localization
[Fox/Dellaert/Burgard/Thrun 99]

Monte Carlo Localization (MCL)




MCL: Importance Sampling

$$b(s_t) \leftarrow \eta p(o_t | s_t, m) b(s_t)$$






MCL: Robot Motion

$$b(s_{t+1}) \leftarrow \int p(s_{t+1} | a_t, s_t, m) b(s_t) ds_t$$



MCL: Importance Sampling

$$b(s_{t+1}) \leftarrow \eta p(o_{t+1} | s_{t+1}, m) b(s_{t+1})$$



Particle Filters

Represents $b(s_t)$ by set of weighted particles $\{s_t^{(i)}, w_t^{(i)}\}$

$$b(s_t | m) = \eta p(o_t | s_t, m) \int p(s_t | s_{t-1}, a_{t-1}, m) b(s_{t-1} | m) ds_{t-1}$$

draw $s_{t-1}^{(i)}$ from $b(s_{t-1})$


draw $s_t^{(i)}$ from $p(s_t | s_{t-1}^{(i)}, a_{t-1}, m)$

Importance factor for $s_t^{(i)}$:

$$\begin{aligned} w_t^{(i)} &= \frac{\text{target distribution}}{\text{proposal distribution}} \\ &= \frac{\eta p(o_t | s_t^{(i)}, m) p(s_t^{(i)} | s_{t-1}^{(i)}, a_{t-1}, m) \text{Bel}(s_{t-1}^{(i)})}{p(s_t^{(i)} | s_{t-1}^{(i)}, a_{t-1}, m) \text{Bel}(s_{t-1}^{(i)})} \end{aligned}$$

$$\propto p(o_t | s_t^{(i)}, m)$$

Monte Carlo Localization



Sebastian Thrun

Localização

Exemplo Método de Localização:

Localização de Markov → Localização de Monte Carlo

↓
Diferentes formas de
representar a crença e
os procedimentos de
atualização.

↓
Proposta em:
(Dellaert et al., 1999)

↓
Utilizada em:

Minerva ← (Thrun et al., 2000) (Köse; Akin, 2007)

Pioneer 1 — (Bianchi, 2002) (Kootstra; Boer, 2009)
Janderson Rodrigo
(Barbosa, 2006)

Localização

Exemplo Método de Localização:

Localização de Markov \longrightarrow Técnica Probabilística

Múltiplas hipóteses sobre a posição do robô.

Modelo de Ação \longrightarrow $Bel(L) = \sum p(L | L', a) Bel(L')$

Modelo Perceptual \longrightarrow $Bel(L) = -\alpha p(s | L) Bel(L)$

Localização

Localização de Monte Carlo:

- A LMC expressa a crença $Bel(s)$ através de um conjunto de amostras s , que são associadas a um fator numérico de importância p .
- p indica a probabilidade da amostra ser relevante para a determinação da posição do robô.
- Assim a crença inicial pode ser obtida gerando-se N amostras aleatórias da distribuição prévia $P(s_o)$, e atribuindo-se para cada amostra o fator de importância uniforme N^{-1} .

Localização

Algoritmo - Localização de Monte Carlo:

Localização de Monte Carlo (S, a, o) – Extraído de (BIANCHI, 2002)

1: $S' = \emptyset$

2: $psum = 0$

3: **enquanto** $psum < pmax$ **faça**

4: crie uma amostra aleatória $\langle s, p \rangle$ de S de acordo com p_1, \dots, p_N

5: gere um s' aleatório de acordo com $P(s' | a, s, m)$

6: $p' = P(o | s', m)$

7: adicione $\langle s', p' \rangle$ a S'

8: $psum = psum + p'$


9: **fim-enquanto**

10: normalize os fatores de importância p em S'

11: **retorne** S'

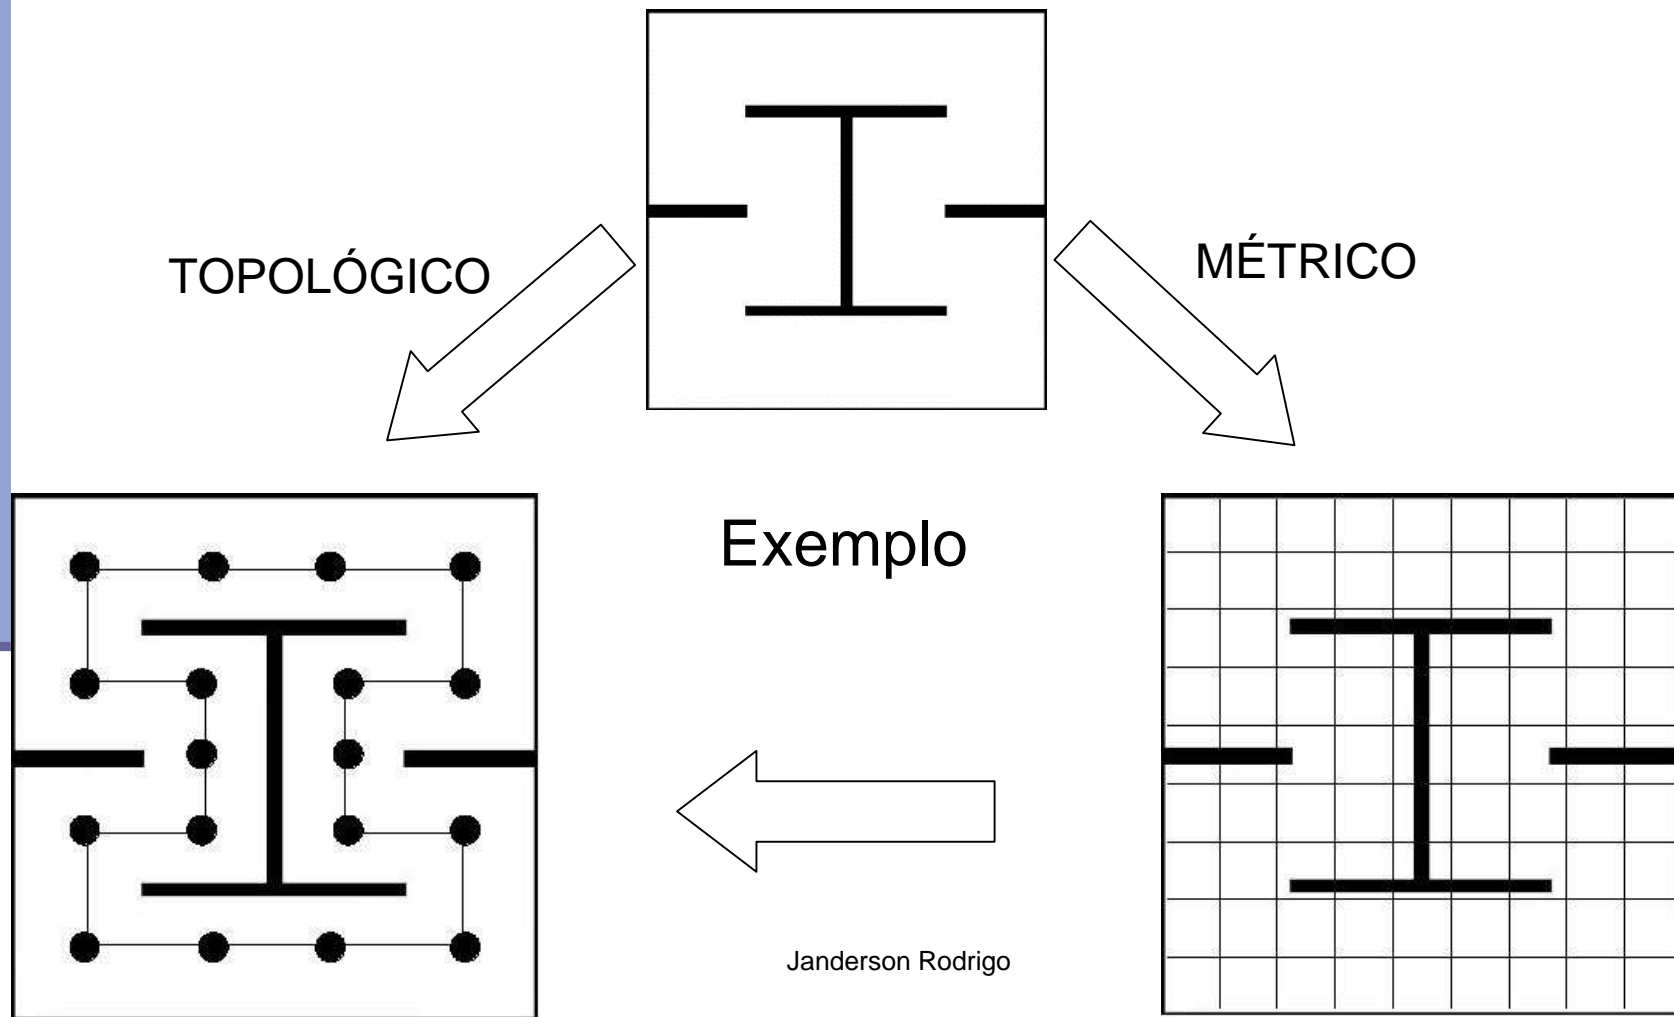
Mapeamento

(Thrun; Bücken, 1996)
(Thrun, 1998)
(Thrun, 2002)



MÉTRICO versus **TOPOLÓGICO**

Mapeamento



Janderson Rodrigo

Mapeamento

Exemplo Método de Mapeamento:

Métrico – Grade de Ocupação



Proposta em:

(Elfes, 1989)



Implementada em:

(Bianchi, 2002)

(Barbosa, 2006)

Estimativas
estocásticas dos
estados de cada célula



Três estados possíveis:

Ocupado, Livre e
Desconhecido

Mapeamento

Métrico – Grade de Ocupação:

- As estimativas do estado de cada célula são obtidas através da interpretação das leituras de distâncias utilizando modelos probabilísticos dos sensores.
- Para interpretar as medidas de distâncias (dados sensoriais), é usado um modelo estocástico do sensor. Definido por uma função de densidade de probabilidade na forma $p(r | z)$ que relaciona a leitura r ao parâmetro de espaço z referente a uma posição do mapa.

Mapeamento

Exemplo Método de Mapeamento:


Partindo-se da estimativa atual do estado da célula C_i , $P[s(C_i) = OCC | \{r\}_t]$, baseada nas observações $\{r\}_t = \{r_1, \dots, r_t\}$ e dada uma nova observação r_{t+1} , a estimativa atualizada é dada por:

$$P[s(C_i) = OCC | \{r\}_{t+1}] = \frac{p[r_{t+1} | s(C_i) = OCC]P[s(C_i) = OCC | \{r\}_t]}{\sum_{s(C_i)} p[r_{t+1} | s(C_i)]P[s(C_i) | \{r\}_t]}$$

Mapeamento

Exemplo Método de Mapeamento:

Topológico – Thinning



Proposta em:

(Kwon et al., 2006)

(Ko et al., 2004)

p_9	p_2	p_3
p_8	p_1	p_4
p_7	p_6	p_5

Assumindo que p_1 está ocupada, o algoritmo pode ser descrito através de oito condições divididas em 2 passos.

Mapeamento

Exemplo Método de Mapeamento:

Topológico – Thinning

[Passo 1]

(1) $2 \leq N(p_1) \leq 6$;

(2) $S(p_1) = 1$;

(3) $p_2 \cdot p_4 \cdot p_6 = 0$;

(4) $p_4 \cdot p_6 \cdot p_8 = 0$;

[Passo 2]

(1) Idem

(2) Idem

(3) $p_2 \cdot p_4 \cdot p_8 = 0$;

(4) $p_2 \cdot p_6 \cdot p_8 = 0$;

Mapeamento

Exemplo Método de Mapeamento:

Topológico – Thinning (Exemplos)

p ₉	p ₂	p ₃
p ₈	p ₁	p ₄
p ₇	p ₆	p ₅

Satisfaz condições passo 1



p₁ >> célula vazia

Curso RMI

p ₉	p ₂	p ₃
p ₈	p ₁	p ₄
p ₇	p ₆	p ₅

Não satisfaz primeira
condição do passo 1



p₁ >> célula ocupada

Janderson Rodrigo

Mapeamento

Algoritmo - Thinning:

Método de Esqueletização de Imagens(C)

VARIAVÉIS

i, j, continue, NC, MC: Inteiro;

INÍCIO

REPITA

continue = 0;

PARA i = (BordaSuperior+1) **ATÉ** BordaInferior **FAÇA**

PARA j = (BordaEsquerda+1) **ATÉ** BordaDireita **FAÇA**

SE (s(Cij)) **ENTÃO**

$$NC = s(C_{i-1j}) + s(C_{i-1j+1}) + s(C_{ij+1}) + s(C_{i+1j+1}) + s(C_{i+1j})$$
$$+ s(C_{i+1j-1}) + s(C_{ij-1}) + s(C_{i-1j-1});$$

Calcule a quantidade de mudanças de “0” para “1” ao redor da célula Cij (variável MC);

Mapeamento

Algoritmo - Thinning:

SE (((NC >=2) **E** (NC <= 6)) **E** (MC == 1) **E** (s(Ci-1j)*s(Cij+1)*s(Ci+1j) == 0) **E** (s(Cij+1)*s(Ci+1j)*s(Cij-1) == 0))

ENTÃO

s(Cij) = 0;
continue = 1;

FIM-SE

SE (((NC >=2) **E** (NC <= 6)) **E** (MC == 1) **E** (s(Ci-1j)*s(Cij+1)*s(Cij-1) == 0) **E** (s(Ci-1j)*s(Ci+1j)*s(Cij-1) == 0))

ENTÃO

s(Cij) = 0;
continue = 1;

FIM-SE

Mapeamento

Algoritmo - Thinning:






FIM-PARA
FIM-PARA

ENQUANTO (continue == 1);

FIM.

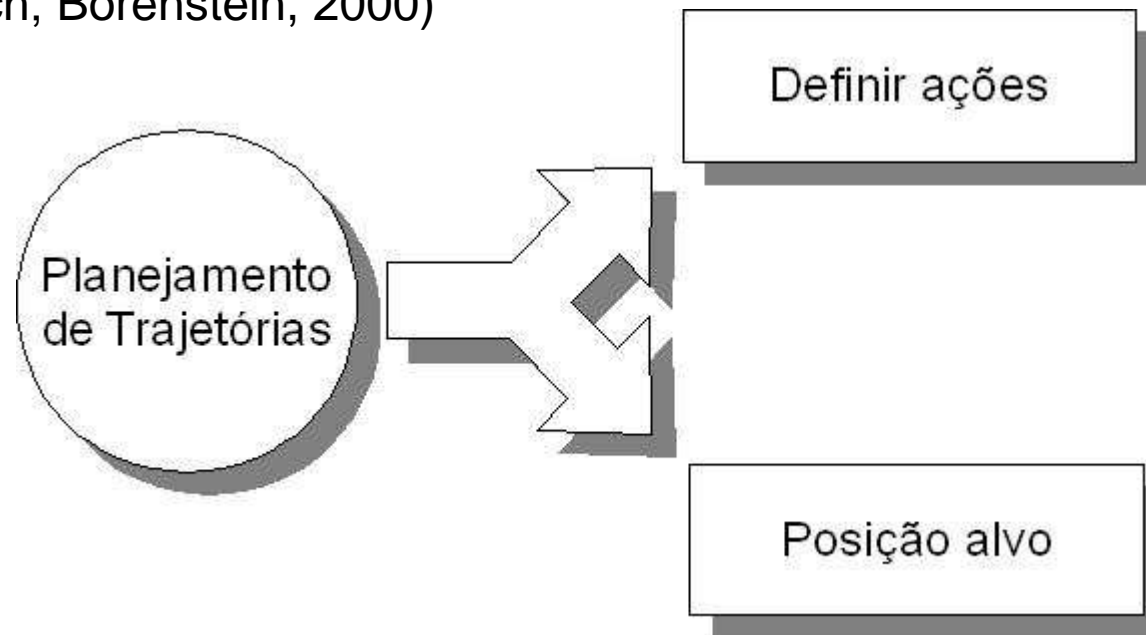
Mapeamento

Exemplo construção: Grade de Ocupação + Thinning



Planejamento de Trajetórias

(Ulrich; Borenstein, 2000)



Vector Field Histogram

Setores $\longrightarrow k = INT(\beta / \alpha)$

Densidade de Ocupação $\longrightarrow h_k = \sum_{i,j} m_{i,j}$

Curso RMI

Janderson Rodrigo

Referências

BARBOSA, A. W. **Sistema remoto para controle de robôs móveis via Web.** Dissertação de mestrado. ICMC/USP - São Carlos/SP, 2006.

BIANCHI, R. E. **Sistema de navegação de robôs móveis autônomos para o transporte de documentos.** Dissertação de mestrado. ICMC/USP - São Carlos/SP, 2002.

ELFES, A. **Occupancy Grids: A Probabilistic for Robot Perception and Navigation.** Tese Ph.D., Carnegie Mellon University, 1989.

FOX, D. **Markov Localization: A Probabilistic Framework for Mobile Robot Localization and Navigation.** Universidade de Bonn, Alemanha. Tese de Doutorado, 1998.

Referências

FOX, D.; BURGARD, W.; THRUN, S. Active Markov localization for Mobile robots. **Robotics and Autonomous Systems**, vol. 25, p. 195 – 207, 1998.

FOX, D.; BURGARD, W.; THRUN, S. Markov Localization for mobile robots in dynamic environments. **Journal of Artificial Intelligence Research**, vol. 11, p. 391 – 427, 1999.

KO, B. Y.; SONG, J. B.; LEE, S. Real-time Building of Thinning-Based Topological Map with Metric Features. In **Proceedings of International Conference on Intelligent Robots and Systems**, p. 1524 – 1529, 2004.

KÖSE, H.; AKIN, H. L. The Reverse Monte Carlo localization algorithm. **Robotics and Autonomous Systems**, vol. 55, p. 480 – 489, 2007.

KOOTSTRA, G.; BOER, B. Tackling the premature convergence problem in Monte-Carlo localization. **Robotics and Autonomous Systems**, vol. 57, p. 1107 – 1118, 2009.

Referências

KWON, T.; YANG J.; SONG, J.; CHUNG, W. Efficiency improvement in Monte Carlo localization through topological information. In **2006 IEEE/RSJ IROS - Int. Conf. on Intelligent Robots and Systems**, p. 424 – 429, 2006.

OLSON, C. F. Probabilistic self-localization for mobile robots. **IEEE Transactions On Robotics And Automation**, vol. 16(1), p. 55 – 66, 2000.

THRUN, S.; BÜCKEN, A. Integrating Grid-Based and Topological Maps for Mobile Robot Navigation. In **Proceedings of the Thirteenth National Conference on Artificial Intelligence**, 1996.

THRUN, S. Learning metric-topological maps for indoor mobile robot navigation. **Artificial Intelligence**, vol. 99, p. 21 – 71, 1998.

THRUN, S. **Robotic Mapping: A Survey**. Carnegie Mellon University, CMU-CS-02-111, 2002.

Referências

THRUN, S.; BEETZ, M.; BENNEWITZ, M.; BURGARD, W.; CREMERS, A. B.; DELLAERT, F.; FOX, D., HÄHNEL, D.; ROSENBERG, C.; ROY, N.; SCHULTE, J.; SCHULZ, D. Probabilistic Algorithms and the Interactive Museum Tour-Guide Robot Minerva. **Journal of Robotics Research**, 2000.

ULRICH, I.; BORENSTEIN, J. VFH*: Local Obstacle Avoidance with Look-Ahead Verification. In **Proceedings of the IEEE International Conference on Robotics and Automation**, p. 2505 – 2511, 2000.