

SLAM II Localização e Mapeamento Simultâneos

1


GraphSLAM

- As posições do robô ao longo do tempo e os landmarks correspondem a nós em um grafo.
- As informações odométricas entre posições consecutivas e landmarks vistos em diferentes posições equivalem a arcos do grafo.
- O algoritmo é executado em 2 etapas.
 - Na primeira etapa, o mesmo apenas acumula dados e constrói o grafo.
 - Na segunda etapa, o o grafo é rearranjado para acomodar os dados obtidos.
- Diferente do SLAM utilizando filtro de Kalman, o Graph SLAM estima a posição do robô durante todo o trajeto.

SCE-5868 Denis F. Wolf

2

GraphSLAM



Sum of all constraints:

$$J_{\text{GraphSLAM}} = x_0^T \Omega_0 x_0 + \sum_t [x_t - g(u_t, x_{t-1})]^T R^{-1} [x_t - g(u_t, x_{t-1})] + \sum_i [z_i - h(m_i, x_t)]^T Q^{-1} [z_i - h(m_i, x_t)]$$

SCE-5868 Denis F. Wolf

3

Filtro de Informação

Matriz de informação $\rightarrow \Omega = \Sigma^{-1}$

Vetor de informação $\rightarrow \xi = \Sigma^{-1} \mu$

$$\Sigma = \Omega^{-1}$$

$$\mu = \Omega^{-1} \xi$$

SCE-5868 Denis F. Wolf

4

Filtro de Informação

- 1: **Algorithm Kalman_filter**($\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$):
- 2: $\hat{\mu}_t = A_t \mu_{t-1} + B_t u_t$
- 3: $\hat{\Sigma}_t = A_t \Sigma_{t-1} A_t^T + R_t$
- 4: $K_t = \hat{\Sigma}_t C_t^T (C_t \hat{\Sigma}_t C_t^T + Q_t)^{-1}$
- 5: $\mu_t = \hat{\mu}_t + K_t (z_t - C_t \hat{\mu}_t)$
- 6: $\Sigma_t = (I - K_t C_t) \hat{\Sigma}_t$
- 7: return μ_t, Σ_t

- 1: **Algorithm Information_filter**($\xi_{t-1}, \Omega_{t-1}, u_t, z_t$):
- 2: $\Omega_t = (A_t \Omega_{t-1}^{-1} A_t^T + R_t)^{-1}$
- 3: $\xi_t = \hat{\Omega}_t (A_t \Omega_{t-1}^{-1} \xi_{t-1} + B_t u_t)$
- 4: $\Omega_t = C_t^T Q_t^{-1} C_t + \hat{\Omega}_t$
- 5: $\xi_t = C_t^T Q_t^{-1} z_t + \hat{\xi}_t$
- 6: return ξ_t, Ω_t

SCE-5868 Denis F. Wolf

5

Information Filter

Controle:

$$\Omega \leftarrow \Omega + \begin{pmatrix} 1 \\ -G_t \end{pmatrix} R_t^{-1} (1 - G_t)$$

$$\xi \leftarrow \xi + \begin{pmatrix} 1 \\ -G_t \end{pmatrix} R_t^{-1} [g(u_t, \mu_{t-1}) + G_t \mu_{t-1}]$$

Percepção:

$$\Omega \leftarrow \Omega + H_t^T Q_t^{-1} H_t$$

$$\xi \leftarrow \xi + H_t^T Q_t^{-1} [z_t^i - h(\mu_t, c_t^i) - H_t \mu_t]$$

SCE-5868 Denis F. Wolf

6

GraphSLAM

(a) Observation in landmark m_1

(b) Robot motion from x_1 to x_2

(c) Several steps later

SCE-5868 Denis F. Wolf 7

GraphSLAM

(a) The removal of m_1 changes the link between x_1 and x_2

(b) The removal of m_2 introduces a new link between x_2 and x_1

(c) Final Result after removing all map features

SCE-5868 Denis F. Wolf 8

GraphSLAM

SCE-5868 Denis F. Wolf 9

GraphSLAM

(a) (b) (c) (d) (e) (f)

SCE-5868 Denis F. Wolf 10


GraphSLAM

SCE-5868 Denis F. Wolf 11

GraphSLAM


SCE-5868 Denis F. Wolf 12

GraphSLAM



SCE-5868 Denis F. Wolf 13

GraphSLAM



SCE-5868 Denis F. Wolf 14

GraphSLAM

Coordinated exploration with three robots from unknown start locations

The robots are fully autonomous. All computation is performed on-board.

Shown is the perspective of one robot

SCE-5868 Denis F. Wolf 15

GraphSLAM

Resumo:

Método **off-line** que estima a trajetória **completa** do robô e o mapa.

SCE-5868 Denis F. Wolf 16

Rao-blackwellized Particle Filter (FastSLAM)

Idéia básica: utilizar um **filtro de partículas** para estimar a **posição do robô** e o **mapa do ambiente**.

Vantagens:

- Modelos de percepção e controle **não-lineares** ☹
- Permite **diferentes associações de dados** em paralelo ☹
- Estima **toda a trajetória** do robô **on-line** ☹

Desvantagem:

- Número de partículas necessário cresce **exponencialmente** com o número de variáveis. ☹ ☹ ☹

SCE-5868 Denis F. Wolf 17

Rao-blackwellized Particle Filter

Como simplificar o problema:

Existe alguma **dependência** entre as variáveis?

O mapa depende da posição do robô!

SCE-5868 Denis F. Wolf 18

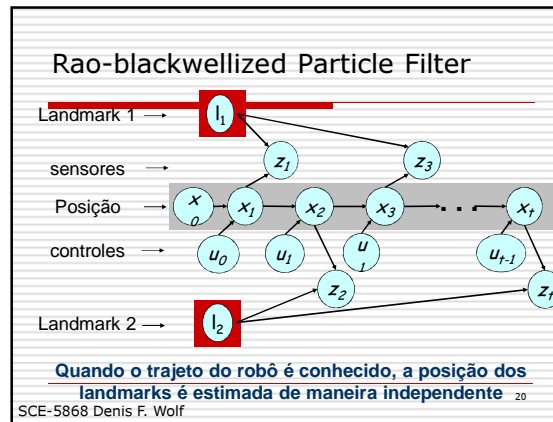
Rao-blackwellized Particle Filter

posição mapa sensores & controle

$$p(x_{1:t}, l_{1:m} | z_{1:t}, u_{0:t-1}) = p(x_{1:t} | z_{1:t}, u_{0:t-1}) \cdot p(l_{1:m} | x_{1:t}, z_{1:t})$$

Fatorização apresentada originalmente por Murphy em 1999

SCE-5868 Denis F. Wolf 19



Fatoração do mapeamento

$$p(x_{1:t}, l_{1:m} | z_{1:t}, u_{0:t-1}) = p(x_{1:t} | z_{1:t}, u_{0:t-1}) \cdot p(l_{1:m} | x_{1:t}, z_{1:t}) = p(x_{1:t} | z_{1:t}, u_{0:t-1}) \cdot \prod_{i=1}^M p(l_i | x_{1:t}, z_{1:t})$$

Localização

Posições dos landmarks condicionalmente independentes

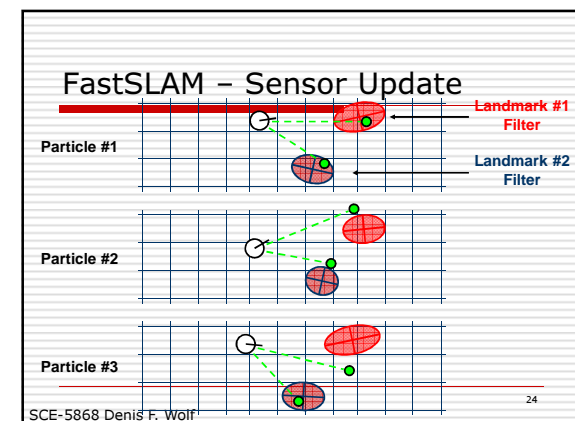
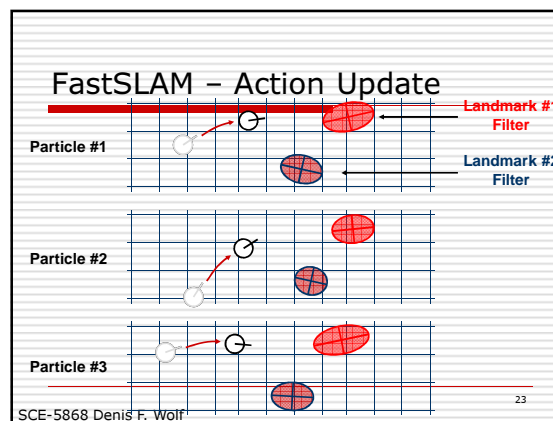
SCE-5868 Denis F. Wolf 21

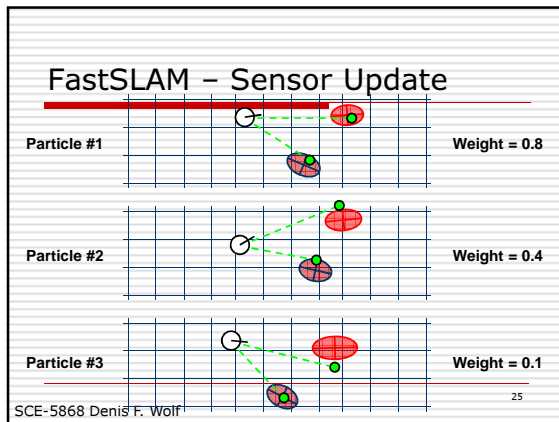
FastSLAM

- Rao-Blackwellized particle filtering baseado em landmarks [Montemerlo et al., 2002]
- Cada landmark é representado por um 2x2 Extended Kalman Filter (EKF)
- Cada partícula mantém M EKFs

Particle #1	x, y, θ	Landmark 1	Landmark 2	Landmark M
Particle #2	x, y, θ	Landmark 1	Landmark 2	Landmark M
...
Particle N	x, y, θ	Landmark 1	Landmark 2	Landmark M

SCE-5868 Denis F. Wolf 23





Rao-blackwellized Particle Filter

Video:
SLAM com câmera stereo


SCE-5868 Denis F. Wolf 26

Problema: associação de dados

- Qual observação corresponde a qual landmark?

- Possíveis associações dependem da posição do robô.
- Soluções robustas para o SLAM devem considerar varias associações possíveis.

SCE-5868 Denis F. Wolf 27




Associação de dados

A observação foi gerada pelo landmark vermelho ou pelo azul?


$P(\text{observation}|\text{red}) = 0.3$ $P(\text{observation}|\text{blue}) = 0.7$

- Duas opções para a associação:
 - Associar ao mais provável
 - Associação aleatória utilizando o peso proporcional a probabilidade
- Se a probabilidade de associação é muito pequena, gerar um novo landmark.

SCE-5868 Denis F. Wolf 29



Results - Accuracy



SCE-5868 Denis F. Wolf

31

Rao-blackwellized Particle Filter

posição mapa sensores & controle

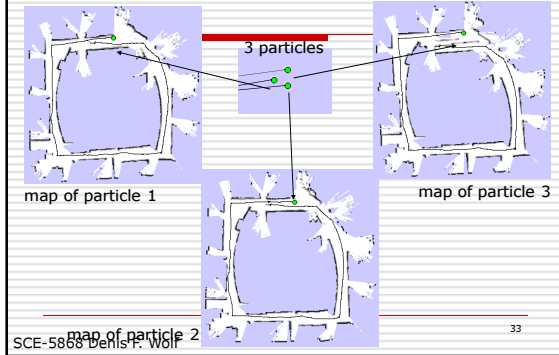
$$p(x_{1:t}, m | z_{1:t}, u_{0:t-1}) = p(x_{1:t} | z_{1:t}, u_{0:t-1}) \cdot p(m | x_{1:t}, z_{1:t})$$

occupancy grid

SCE-5868 Denis F. Wolf

32


Exemplo utilizando mapa métrico



SCE-5868 Denis F. Wolf

33


Rao-blackwellized Particle Filter



SCE-5868 Denis F. Wolf

34


Rao-blackwellized Particle Filter



SCE-5868 Denis F. Wolf

35

Rao-blackwellized Particle Filter



SCE-5868 Denis F. Wolf

36

Rao-blackwellized Particle Filter

Resumo:

- ❑ Cada partícula representa uma trajetória do robô, juntamente com o respectivo mapa gerado.
- ❑ Decompõe o mapa em várias distribuições normais de poucas dimensões ao invés de uma única distribuição com várias dimensões.
- ❑ Resolve ambos os problemas de on-line SLAM e full SLAM.