SCE5880

Algoritmos de Estimação para Robótica Móvel

Localização II

Filtro de Kalman

Monte Carlo

Monte Carlo

Filtro de partículas:

- Representa pdfs através de amostras
- Representa funções não-lineares, não gaussianas e multi-modais
- Eficiente computacionalmente
- Implmenetação simples.

Filtro de Partículas

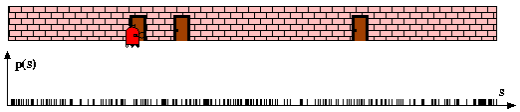

Filtro de Partículas: observação

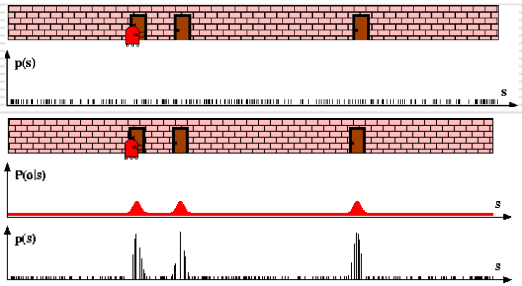

Filtro de Partículas: movimentação

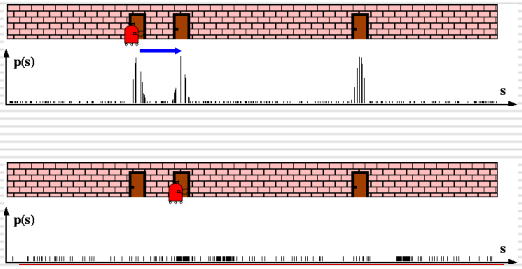

Filtro de Partículas: observação

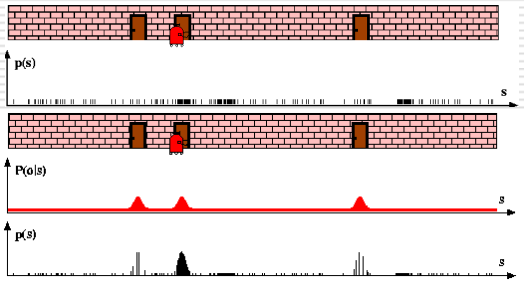

Filtro de Partículas: movimentação

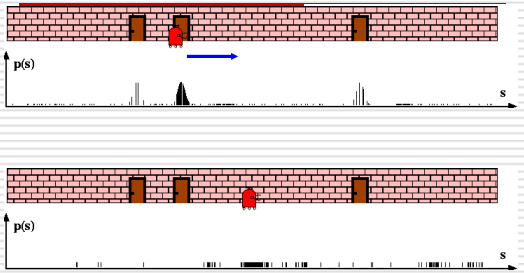

7

Algoritmo – filtro de partículas

Algorithm MCL$(\mathcal{X}_{t-1}, u_t, z_t, m)$:

$\bar{\mathcal{X}}_t = \mathcal{X}_t = \emptyset$
for $m = 1$ to M do
  $x_t^{[m]} = \text{sample\_motion\_model}(u_t, x_{t-1}^{[m]})$
  $w_t^{[m]} = \text{measurement\_model}(z_t, x_t^{[m]}, m)$
  $\bar{\mathcal{X}}_t = \bar{\mathcal{X}}_t + \langle x_t^{[m]}, w_t^{[m]} \rangle$
endfor
for $m = 1$ to M do
  draw i with probability $\propto w_t^{[i]}$
  add $x_t^{[i]}$ to $\mathcal{X}_t$
endfor
return $\mathcal{X}_t$

8

Resorteio

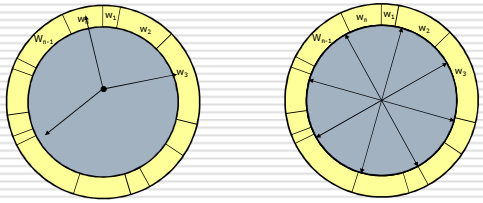

- Busca binária

9

Sample Odometry Motion Model

1. Algorithm **sample_motion_model**(u, x):

$u = \langle \delta_{rot1}, \delta_{rot2}, \delta_{trans} \rangle, x = \langle x, y, \theta \rangle$

1. $\hat{\delta}_{rot1} = \delta_{rot1} + \text{sample}(\alpha_1 |\delta_{rot1}| + \alpha_2 \delta_{trans})$
2. $\hat{\delta}_{trans} = \delta_{trans} + \text{sample}(\alpha_3 \delta_{trans} + \alpha_4 (|\delta_{rot1}| + |\delta_{rot2}|))$
3. $\hat{\delta}_{rot2} = \delta_{rot2} + \text{sample}(\alpha_1 |\delta_{rot2}| + \alpha_2 \delta_{trans})$
4. $x' = x + \hat{\delta}_{trans} \cos(\theta + \hat{\delta}_{rot1})$
5. $y' = y + \hat{\delta}_{trans} \sin(\theta + \hat{\delta}_{rot1})$
6. $\theta' = \theta + \hat{\delta}_{rot1} + \hat{\delta}_{rot2}$
7. Return $\langle x', y', \theta' \rangle$

sample_normal_distribution

10

Propagação das partículas

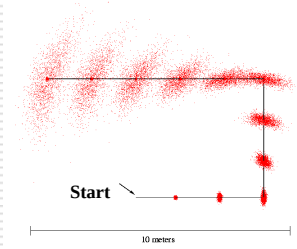

11

Exemplos

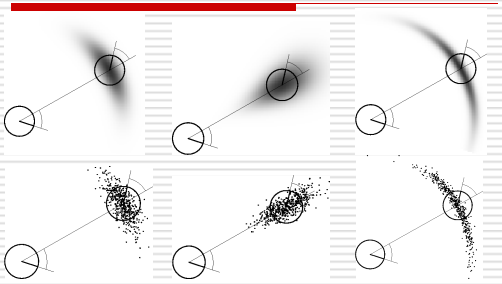

12

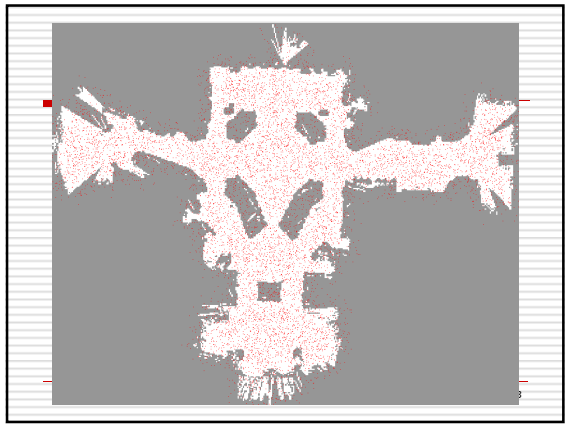
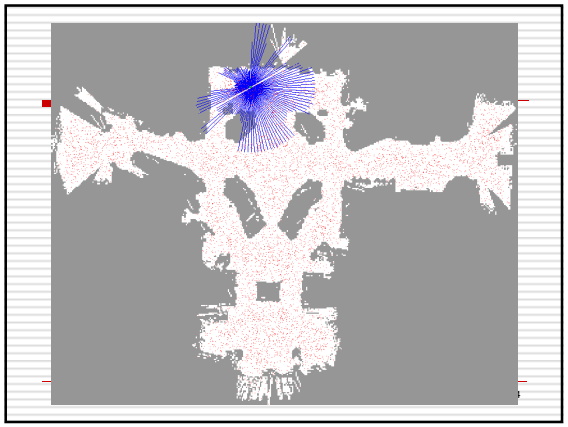
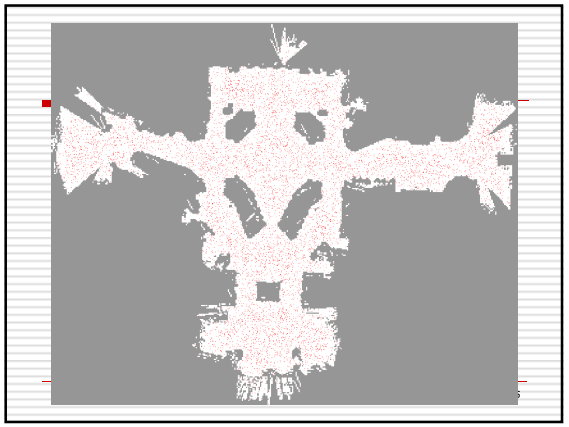
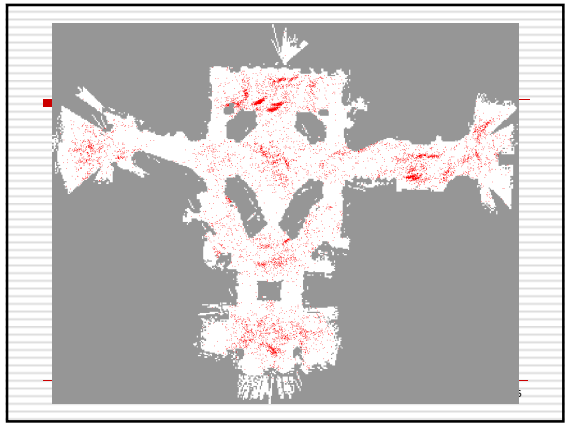
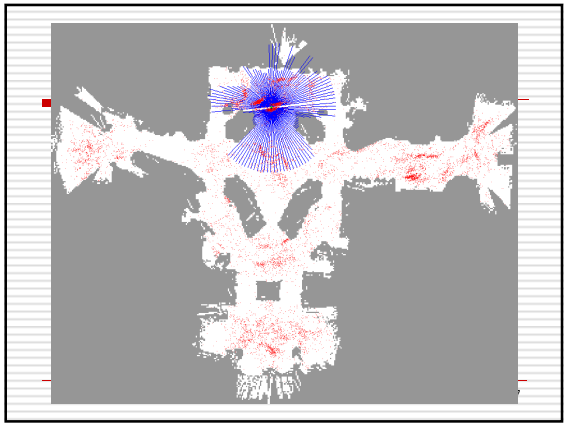
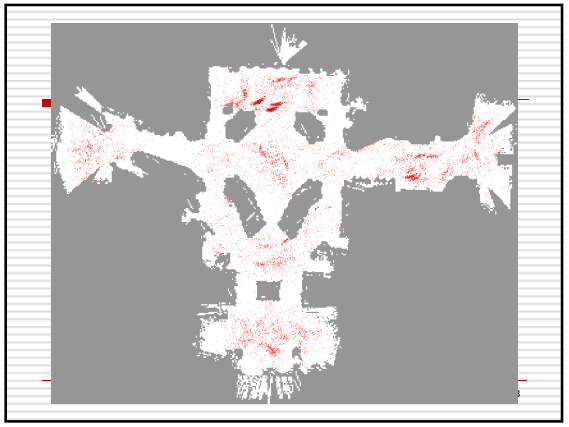



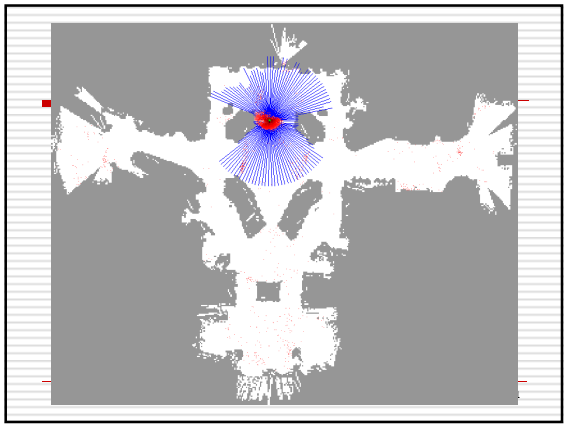
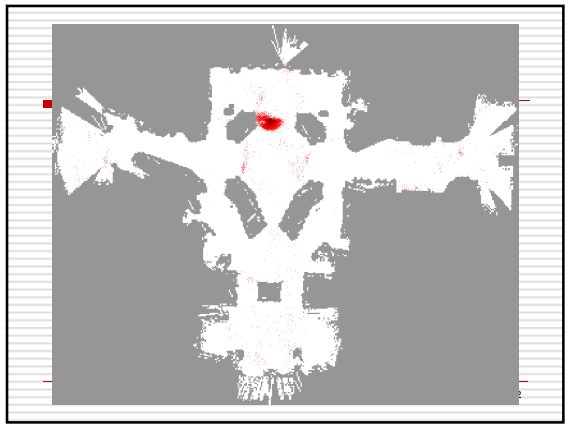
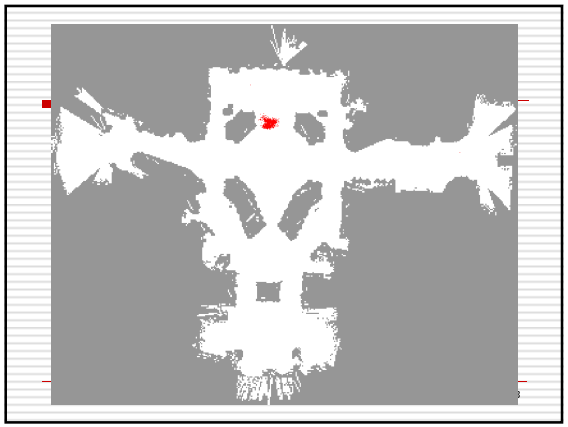
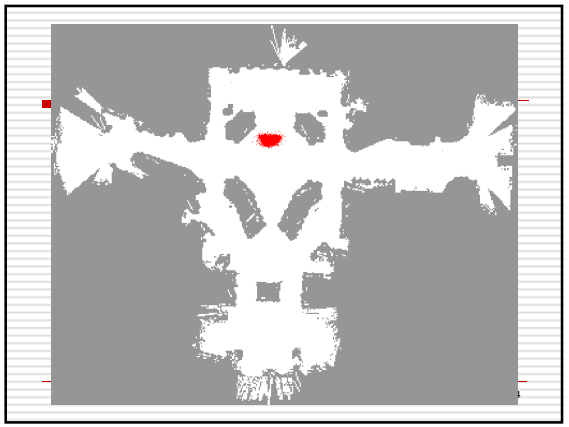

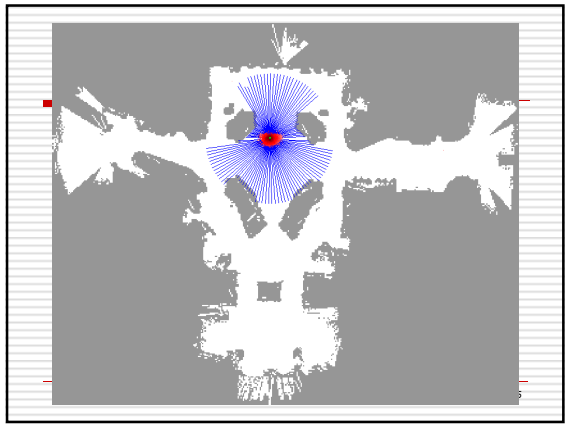

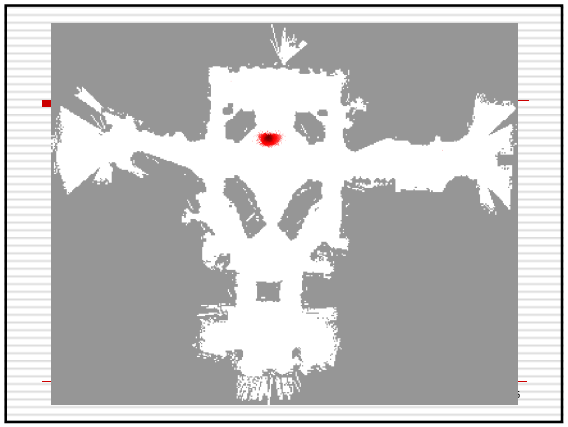

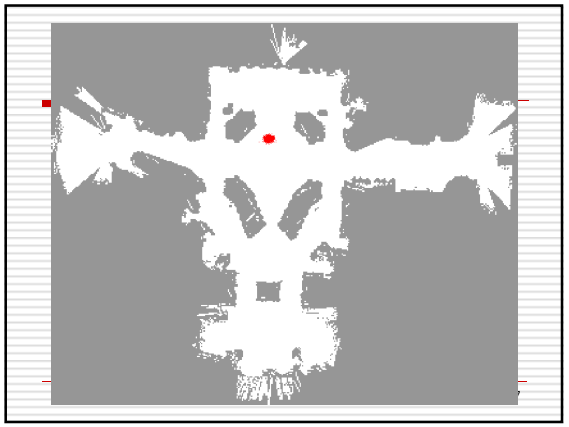

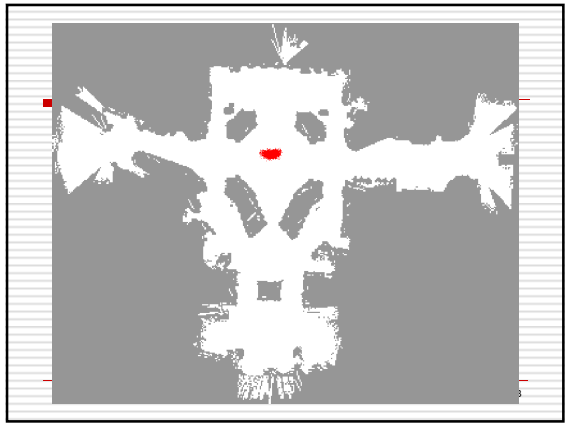

Limitações

- O método de Monte Carlo é capaz de:
  - tracking
  - Busca global
- E quanto ao problema do robô teletransportado (kidnapped robot)?

29

Soluções

- Inserir amostras randômicas (supondo que o robô pode estar em qualquer lugar).
- Inserir amostras proporcionais a verosemelhança de cada partícula (supondo que o robô tem maiores chances de estar nos locais onde as partículas tem maior verosemelhança).

30

Algoritmo MCL (c/ recover)

Algorithm Augmented_MCL($\mathcal{X}_{t-1}, u_t, z_t, m$):
  static w_{slow}, w_{fast}
  $\bar{\mathcal{X}}_t = \mathcal{X}_t = \emptyset$
  for $m = 1$ to M do
    $x_t^{[m]} =$ sample_motion_model$(u_t, x_{t-1}^{[m]})$
    $w_t^{[m]} =$ measurement_model$(z_t, x_t^{[m]}, m)$
    $\bar{\mathcal{X}}_t = \bar{\mathcal{X}}_t + \langle x_t^{[m]}, w_t^{[m]} \rangle$
    $w_{avg} = w_{avg} + \frac{1}{M} w_t^{[m]}$
  endfor
  $w_{slow} = w_{slow} + \alpha_{slow}(w_{avg} - w_{slow})$
  $w_{fast} = w_{fast} + \alpha_{fast}(w_{avg} - w_{fast})$
  for $m = 1$ to M do
    with probability $\max(0.0,\ 1.0 - w_{fast}/w_{slow})$ do
      add random pose to $\mathcal{X}_t$
    else
      draw $i \in \{1, \ldots, N\}$ with probability $\propto w_t^{[i]}$
      add $x_t^{[i]}$ to $\mathcal{X}_t$
    endwith
  endfor
  return $\mathcal{X}_t$

Gráficos – KLD Sampling

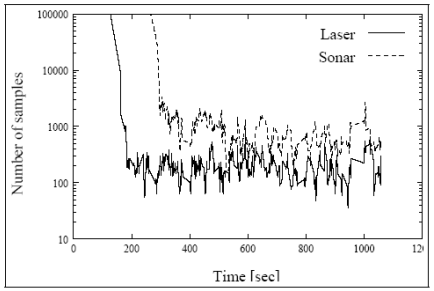

Localização baseada em mapa

- Cada partícula representa a possibilidade do robô estar naquela posição especifica.
- É atribuído um peso a cada partícula proporcional a sua chance de representar a posição do robô.
- Partículas com peso baixo são excluídas.
- Dado número suficiente de partículas, é provado que o método converge.
- Depois que o robô é localizado, a trajetória completa é estimada propagando-se as partículas no sentido contrário

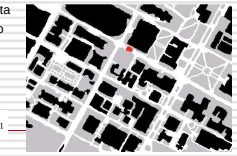

Nova estimativa | peso | propagação | Estimativa anterior

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

Resultados da localização

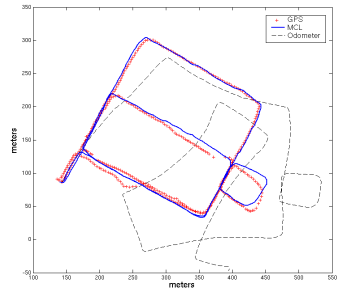

Localização baseada em GPS

- Cada partícula representa uma possível trajetória completa do robô
- É atribuído um peso a cada partícula de acordo com sua proximidade do GPS.
- Partículas que divergem do GPS recebem peso baixo e são eliminadas.

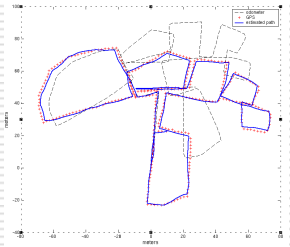

Resumo

- Filtros de partículas são implementações de filtros de Bayes
- As pdfs são representadas por amostras.
- No contexto da localização, as partículas são propagadas de acordo com o odômetro
- No contexto da localização, as partículas recebem seus pesos baseados no modelo de observação .