

Introdução

Este projeto de iniciação científica teve como objetivo o estudo de mapeamento de ambientes utilizando sonares de um robô humanoíde. O robô utilizado na pesquisa foi o NAO H25, que possui quatro sensores ultrassônicos (sonares) – dois receptores e dois transmissores. Estes sensores captam distâncias de possíveis obstáculos na frente do robô e a partir desses dados é possível construir um mapa do ambiente em torno do robô. Foram implementados três métodos de mapeamento diferentes – HIMM, Bayesiano e Dempster-Shafer – todos eles utilizando um modelo sensorial de sonar.

Robô NAO



Figura 1: Robô NAO




Figura 2: Sonares

Modelo do Sonar

Os três métodos se baseiam na atualização de uma grade de ocupação. Grade de ocupação é um tipo de representação aproximada de ambiente em forma de matriz, neste caso, em duas dimensões. O modelo sensorial do sonar é representado por um cone de abertura β e alcance máximo R , dividido em regiões [4]. Considerando uma leitura de distância r , onde $r < R$, temos que:




Figura 3: Modelo do sonar 2D

Região I: células em torno de r , que são provavelmente ocupadas.
 Região II: células mais próximas que r , que são provavelmente vazias.
 Região III: células mais distantes que r , que são desconhecidas.
 Região IV: células fora do cone, que são inexploradas.

HIMM

O método HIMM (Histogrammic in Motion Mapping) [1] mantém um contador para cada célula e consiste em, a partir dos dados do sonar, atualizar a grade de ocupação com incrementos positivos na região I do cone e incrementos negativos na região II. Quanto mais positiva uma célula for, maior a possibilidade dela ser um obstáculo.




Figura 4: Representação em matriz

Bayesiano

O método Bayesiano para mapeamento [3] consiste em utilizar os valores obtidos dos sonares, estes convertidos em probabilidades através do Teorema de Bayes, e atualizar a grade de ocupação.

Dada uma leitura do sensor s a probabilidade de uma célula c ser ocupada é $P(ocupada|s)$ calculada pela regra de Bayes:

$$P(ocupada|s) = \frac{P(s|ocupada)P(ocupada)}{P(s|ocupada)P(ocupada)+P(s|vazia)P(vazia)}$$

A priori é considerado $P(ocupada) = P(vazia) = 0.5$. $P(s|ocupada)$ é a probabilidade da leitura s ter sido obtida dado que a célula c está ocupada. Esta probabilidade é calculada a partir do modelo do sensor utilizado, neste caso o modelo sensorial do sonar.

Método para calcular $P(s|ocupada)$ usando o modelo sensorial do sonar:

Região I:

$$P(s|ocupada) = \frac{(R-r + \frac{\beta-r}{\beta}) \cdot Max}{2}$$

$$P(s|vazia) = 1 - P(s|ocupada)$$

Max é o valor máximo de ocupação da grade, por exemplo 0.98.

Região II:

$$P(s|ocupada) = \frac{(R-r + \frac{\beta-r}{\beta})}{2}$$

$$P(s|vazia) = 1 - P(s|ocupada)$$

Dempster-Shafer

O método Dempster-Shafer para mapeamento [2] é semelhante ao método probabilístico bayesiano com a diferença de que não são atualizadas as probabilidades nas células e sim as massas de crenças (Bel-"belief function"), que indicam quão significativa as crenças são. Considerando a hipótese $\theta = \{ocupada, vazia\}$, para a grade de ocupação, o conjunto de Bel é $2^\theta = \{\emptyset, \{ocupada\}, \{vazia\}, \{ocupada, vazia\}\}$, por isso as possibilidades de subconjunto de Bel são: $\{ocupada\} = Ocupada = O$, $\{vazia\} = Vazia = V$, $\{ocupada, vazia\} = Indefinida = I$ e \emptyset . Portanto, $Bel = \{m(O), m(V), m(I)\}$.

A função Bel é calculada da mesma forma que método Bayesiano, porém na região I $m(V) = 0$ e na região II $m(O) = 0$. A priori é considerado que $m(I) = 1$, ou seja, possui toda a massa de crença.

Regra de combinação de Dempster:

Normalização da Bel:

		Bel_2		
		$m_2(O)$	$m_2(V)$	$m_2(I)$
Bel_1	$m_1(O)$	$m_{1,2}(O)$	$m_{1,2}(\emptyset)$	$m_{1,2}(O)$
	$m_1(V)$	$m_{1,2}(\emptyset)$	$m_{1,2}(V)$	$m_{1,2}(V)$
	$m_1(I)$	$m_{1,2}(O)$	$m_{1,2}(V)$	$m_{1,2}(I)$

Sendo, $Bel_1 = A$ e $Bel_2 = B$ temos:

$$conflito = \sum_{A_i \cap B_j = \emptyset} m(A_i) \cdot m(B_j)$$

$$m(C_k) = \frac{\sum_{A_i \cap B_j = C_k; C_k \neq \emptyset} (m(A_i) \cdot m(B_j))}{1 - conflito}$$

Resultados

Estes resultados foram obtidos a partir de um ambiente gerado no simulador *Webots* for NAO.

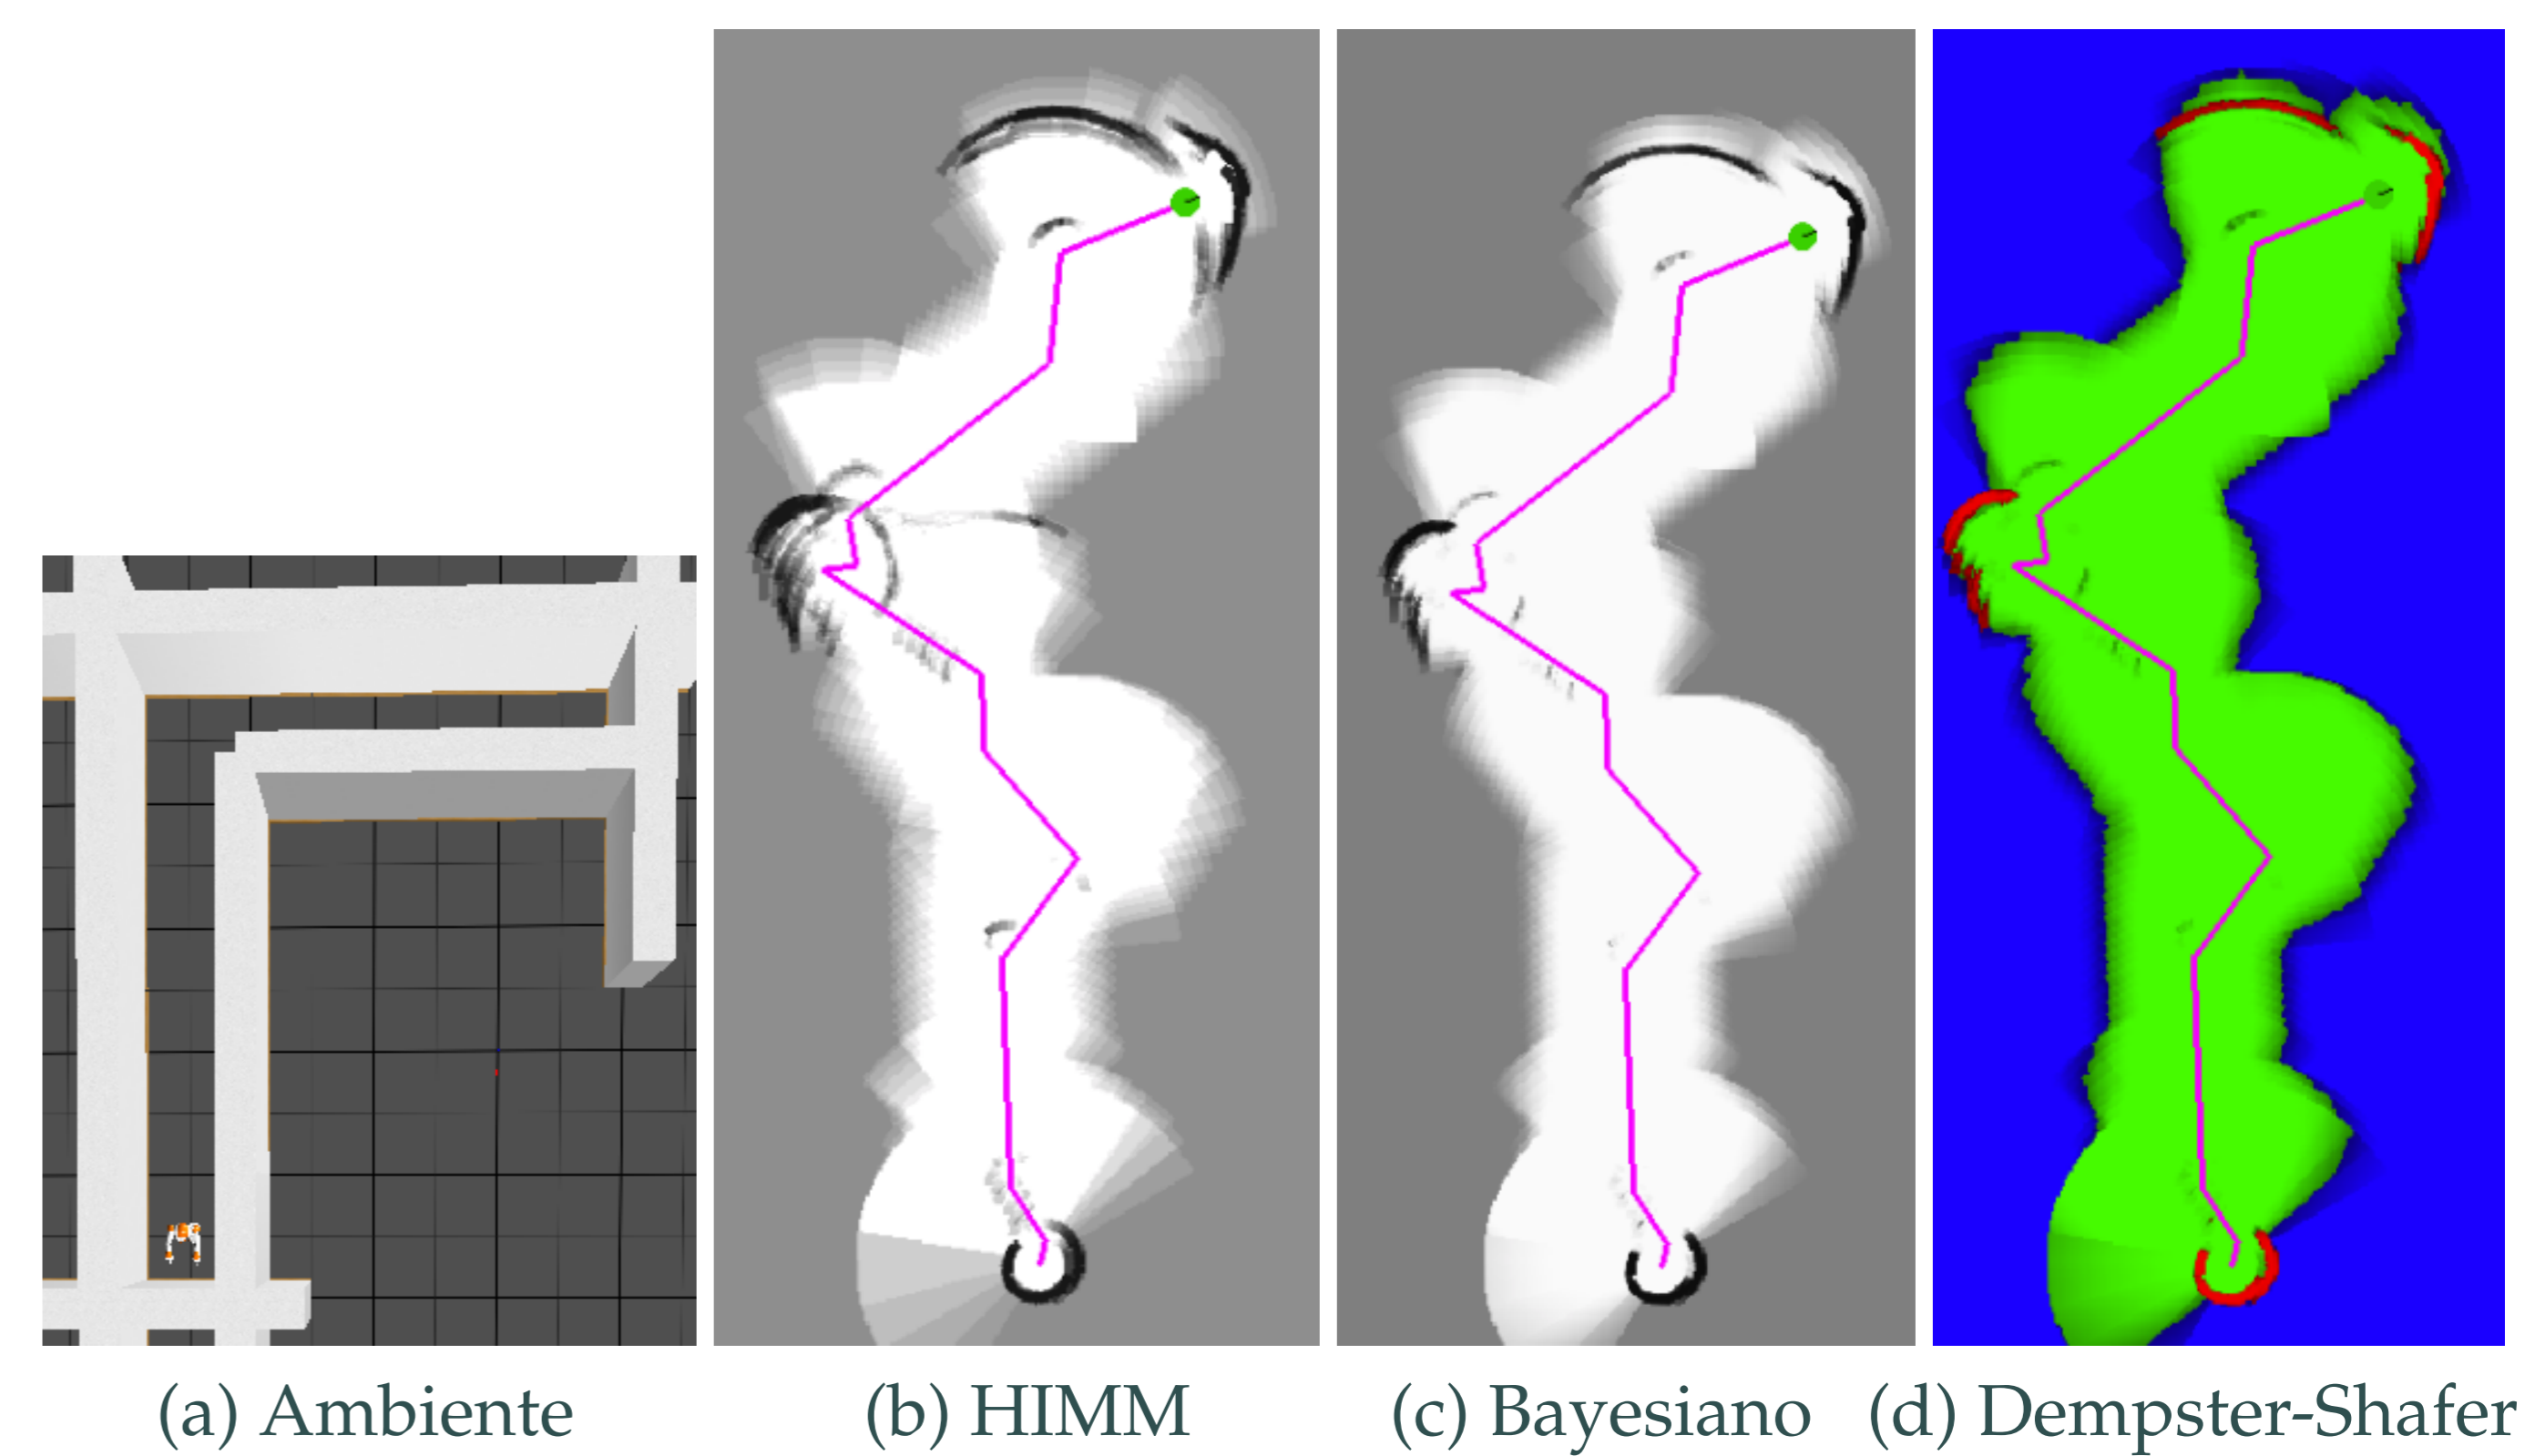


Figura 5: Resultados

Conclusão

Dos métodos testados, Dempster-Shafer e Bayesiano apresentaram resultados semelhantes e melhores do que o apresentado pelo HIMM. Isto decorre da natureza discreta do HIMM associada à pouca quantidade de informação oriunda dos sensores. De fato, este trabalho possibilitou comprovar a dificuldade de construir um mapa com tão pouca informação. Outro problema percebido foi de que a odometria do robô é precária, de forma que um mapa preciso do ambiente só será possível de ser obtido combinando outros sensores e métodos de localização.

Referências

- [1] Johann Borenstein and Yoram Koren. Histogrammic in-motion mapping for mobile robot obstacle avoidance. *Robotics and Automation, IEEE Transactions on*, 7(4):535-539, 1991.
- [2] Kenneth F Hughes and Robin R Murphy. Ultrasonic robot localization using dempster-shafer theory. In *San Diego'92*, pages 2-11. International Society for Optics and Photonics, 1992.
- [3] Hans P Moravec. Sensor fusion in certainty grids for mobile robots. *AI magazine*, 9(2):61, 1988.
- [4] Robin Murphy. *Introduction to AI robotics*. MIT press, 2000.