

UMA ABORDAGEM PARA CONSTRUÇÃO DE GRADE DE OCUPAÇÃO VISUAL 2D USANDO VISÃO MONOCULAR

André M. Santana¹, Kelson R. T. Aires¹, Adelardo A. D. Medeiros²

¹Departamento de Informática e Estatística – DIE (UFPI - Teresina, PI, Brasil)

²Departamento de Engenharia de Computação e Automação – DCA (UFRN - Natal, RN, Brasil)
{andremacedo, kelson}@ufpi.edu.br, {adelardo}@dca.ufrn.br

Resumo – Este trabalho apresenta uma proposta de utilizar informação planar através do cálculo de uma matriz de homografia para construir grade de ocupação visual 2D a partir de visão monocular. Um algoritmo de segmentação é usado para classificar partes do mundo em “chão” e “não-chão” e a partir desta classificação é possível usar a matriz de homografia para mapear como células livres a parte “chão” da imagem e também é possível usá-la para mapear as fronteiras das partes “não-chão” como obstáculos do mundo. Resultados experimentais com um robô real são apresentados para validar a proposta.

Palavras-Chave – Grade de Ocupação Visual, Visão Monocular, Segmentação de Imagem..

1 Introdução

Mapeamento automático de ambientes é uma área de investigação muito ativa em Robótica e na Inteligência Artificial. Há pelo menos duas décadas e, apesar dos progressos significativos nesta área, ainda existem grandes desafios. Um deles está relacionado ao custo das soluções existentes e o outro à qualidade dos mapas encontrados.

A investigação na construção automática de mapa usando robôs tem uma longa história. Um representante precoce da abordagem de mapeamento é Alberto Elfes que apresentou um importante algoritmo para modelagem do ambiente utilizando grades de ocupação [1, 2]. Com essa forma de representação, os espaços contínuos do ambiente são discretizados, de maneira que o ambiente passa a ser representado sob a configuração de uma grade ou matriz multidimensional (2D ou 3D). Cada elemento da matriz, também chamado de célula, representa um local do ambiente que pode estar, de acordo com uma formulação probabilística, ocupado, vazio ou pode ainda não ter sido explorado.

A Figura 1 mostra como seria a representação em uma grade de ocupação de uma parte de um ambiente com dados obtidos por um feixe de sonar. Nessa figura as células em preto representam objetos detectados pelo sonar, as células em branco representam regiões livres ou não ocupadas por objetos e, por fim, as células em cinza representam regiões ainda não mapeadas pelo sonar. Ressalta-se que o modelo espacial probabilístico baseado em grade de ocupação apresenta-se como um mapa que pode ser usado diretamente para tarefas de navegação, tais como planejamento de caminho com desvio de obstáculo e estimativa de posição.




Figura 1 - Representação de um feixe de sonar em uma grade de ocupação 2D.

Um problema enfrentado por Elfes foi a existência de incertezas nas medidas retornadas pelos sonares. Embora tenham adotado métodos para filtrar informações não-desejadas, a informação do feixe sonoro fornecia apenas um dado indireto sobre uma região ocupada do ambiente (por exemplo, o sonar apenas fornece a informação de distância entre o robô e o obstáculo, mas não informa sobre a posição deste obstáculo). Como um feixe do sonar só informava se um volume do ambiente de trabalho estava vazio ou ocupado, Elfes modelou o feixe usando funções de distribuição de probabilidade. Tais funções descreviam a confiança de que vários pontos dentro do cone (modelo matemático do feixe) representavam regiões livres de obstáculos, e a incerteza sobre a localização de um ponto (obstáculo real) sobre a sua superfície. As informações retornadas pelas funções de distribuição de probabilidade sobre os volumes do espaço real eram projetadas em uma matriz, com células descrevendo uma área pré-definida do ambiente. Essas probabilidades eram combinadas com as probabilidades de outros feixes sonoros para a mesma região do espaço real de modo a se construir o mapa[2].

A razão dessa popularidade das técnicas probabilísticas vem do fato de que o processo de mapear ambientes sofre uma forte influência das incertezas presentes nas informações sensoriais e, com as técnicas probabilísticas, é possível tratar esse problema modelando explicitamente as diversas fontes de ruídos e seus efeitos nas medições [3]. Assim, os algoritmos probabilísticos têm se apresentado como uma boa alternativa para tratar o problema das incertezas e ruídos, produzindo resultados mais satisfatórios para o problema de mapeamento.

Embora se tenha comentado nesta seção o uso de sonares para a construção de grades de ocupação, o uso de câmeras vêm se mostrando como um excelente sensor para este tipo de tarefa. Câmeras são facilmente conectadas ao hardware do robô, fornecem rica informação sobre o ambiente, consomem pouca energia e são relativamente baratas quando comparadas a outros sensores utilizados em robôs, laser por exemplo. Assim, o objetivo desse trabalho é apresentar uma abordagem para a construção de grade de ocupação probabilística 2D usando como sensor principal do robô apenas uma única câmera.

2 Formulação Probabilística

A fórmula estatística padrão para representar o mapeamento com grade de ocupação é dada pela expressão matemática mostrada na Equação (2.1) [2, 3]. É oportuno lembrar que o algoritmo supõe o conhecimento da pose do robô. Nesta equação, \mathbf{M} representa o mapa adquirido e $\mathbf{Z}_{1:t}$ é o conjunto das medições sensoriais até o instante de tempo t .

$$P(m_{x,y} | z_{1:t}) \quad (2.1)$$

O espaço contínuo do ambiente no qual o robô se encontra é discretizado em células, as quais, juntas, representam de forma aproximada o ambiente mapeado. Essa discretização pode corresponder a um corte longitudinal do ambiente 3D no plano dos sensores, no caso de ser uma grade 2D, ou pode ser uma discretização 3D do ambiente, no caso de uma grade 3D. Isso depende das características e/ou modelo dos sensores utilizados.

Considerando a discretização do ambiente em células, pode-se definir o mapa como um conjunto finito de células $m_{x,y}$, onde cada uma possui um valor agregado que corresponde à probabilidade de ela estar ocupada. As células podem possuir valores entre o intervalo de 0 a 1. O valor 0 significa que a célula está vazia e 1 que a célula está ocupada.

Sendo o mapa um conjunto finito de células, o problema de mapeamento pode ser decomposto em um conjunto de problemas de estimativa do valor de cada célula do mapa. A Equação (2.2) representa uma instância da estimativa do valor de uma célula $m_{x,y}$ e é traduzida como a probabilidade da célula $m_{x,y}$ estar ocupada, quando são dadas as medições sensoriais $z_{1:t}$ até o instante t .

$$P(m_{x,y} | z_{1:t}) \quad (2.2)$$

Por razões de instabilidade numérica com probabilidades próximas de 0 ou 1, é comum calcular o *log-odds* (probabilidade logarítmica) de $P(m_{x,y} | z_{1:t})$ ao invés de $P(m_{x,y} | z_{1:t})$. O *log-odds* é definido por:

$$l_{x,y}^t = \log \frac{P(m_{x,y} | z_{1:t})}{1 - P(m_{x,y} | z_{1:t})} \quad (2.3)$$

e o valor da probabilidade de ocupação da célula pode ser recuperado através da Equação (2.4).

$$P(m_{x,y} | z_{1:t}) = 1 - \frac{1}{e^{l_{x,y}^t}} \quad (2.4)$$

O valor da probabilidade pode ser estimado recursivamente em qualquer instante t pela regra de Bayes aplicada a $P(m_{x,y} | z_{1:t})$ (Equação 2.5):

$$P(m_{x,y} | z_{1:t}) = \frac{P(z_t | z_{1:t-1}, m_{x,y}) P(m_{x,y} | z_{1:t-1})}{P(z_t | z_{1:t-1})} \quad (2.5)$$

onde $P(z_t | z_{1:t-1}, m_{x,y})$ representa o modelo probabilístico do sensor de alcance, $P(m_{x,y} | z_{1:t-1})$ é o valor de ocupação da célula $m_{x,y}$ no instante $t-1$ e $P(z_t | z_{1:t-1})$ é o valor real medido pelo sensor.

Supondo que o mapeamento é realizado em ambientes estáticos, logo, vale a assertiva de que a medição atual do sensor é independente das medições passadas. Com base nas suposições feitas, a equação (2.5) pode ser simplificada resultando na Equação (2.6).

$$P(m_{x,y} | z_{1:t}) = \frac{P(z_t | m_{x,y}) P(m_{x,y} | z_{1:t-1})}{P(z_t)} \quad (2.6)$$

A aplicação da regra da Probabilidade Total à Equação (2.6) implica na equação (2.7). Nela é computada a probabilidade de a célula $m_{x,y}$ estar ocupada, tendo como base o modelo probabilístico do sensor $P(z_t | m_{x,y})$ e o valor de ocupação da célula disponível *a priori* $P(m_{x,y} | z_{1:t-1})$.

$$P(m_{x,y} | z_{1:t}) = \frac{P(z_t | m_{x,y}) P(m_{x,y} | z_{1:t-1})}{\sum_{m_{x,y}} P(z_t | m_{x,y}) P(m_{x,y} | z_{1:t-1})} \quad (2.10)$$

3 Trabalhos Relacionados

A literatura mostra muitos trabalhos, novos e antigos, sobre mapeamento de ambientes usando grade de ocupação. Um trabalho mais antigo de Konolige (1997) [4] propõe um método que trata de um refinamento matemático do método de mapeamento apresentado por Elfes [1], nomeado de MURIEL (*Multiple Representation Independent Evidence Log*), o método proposto visa tratar os problemas intrínsecos aos sonares, como múltiplas reflexões e redundância de leituras. Borenstein & Koren (1997) criaram um método baseado em histogramas, cujo principal objetivo é diminuir o custo computacional intrínseco à representação baseada em grade de ocupação.

Utilizando uma formulação de força que diminui ao longo do tempo, Andrade-Cetto & Sanfeliu (2002)[6] mostram uma solução para mapeamento de ambientes dinâmicos utilizando grade de ocupação. A cada reobservação de um marco a força associada a ele é reforçada e um filtro de Kalman é utilizado para filtrar marcos com baixa força. Canas & Matellan (2006)[7] fazem uma comparação entre várias técnicas de mapeamento de ambientes dinâmicos utilizando grade e Yguel, Aycard & Laugier (2006)[8] propõe a utilização de GPUs para fundir informações e construir um mapa de grade desocupando o processador para que ele possa ser utilizado em outras tarefas endereçadas ao robô.

Na vertente de processamento de imagens, Sabo (2002)[9] utiliza uma única câmera para a construção de uma grade de ocupação. Pontos notáveis são identificados na imagem através de técnicas de diferença de gradientes de cor e são marcados na grade junto com uma região de incerteza associada à odometria. Merhy et al. (2008)[10] apresenta estratégias de refino de grades de ocupação baseados em segmentação probabilística. Os autores consideram que as probabilidades associadas a cada célula do mapa de grade podem ser codificadas como níveis de textura de uma imagem.

Braillon et al. (2006)[11] detectam obstáculos fundindo informações de visão estéreo e fluxo ótico para representar uma grade de ocupação e em um trabalho posterior Braillon et al. (2008)[12] propõe uma estratégia de não calculá-lo a cada passo devido ao custo computacional elevado. Blanco & Gonzalez (2007)[13] apresentam uma técnica de matching para mapas construídos com grade de ocupação baseado em imagens armazenadas durante o processo. O diferencial deste trabalho é que os mapas podem ser comparados mesmo que tenham sido discretizados de forma diferente.

Propondo a utilização de uma câmera como um sonar visual, Choi & Oh (2006)[14] montam um mapa de um ambiente doméstico utilizando como uma única fonte sensorial uma câmera. O objetivo era construir um mapa de grade, e não de características, baseado apenas em informações visuais e comparar o método com mapas produzidos por sonares. O sonar visual foi modelado como um conjunto de raios virtuais na imagem e a detecção dos pontos limites (pontos finais) eram encontrados utilizando a diagonal de cor de Mahalanobis. Os autores comentam que o problema desta abordagem é a detecção de pontos espúrios e sugerem técnicas de filtragem para eliminá-los.

Outros trabalhos propõem a construção de mapas volumétricos a partir de grades de ocupação [15,16]. No primeiro, uma grade 3D é construída, utilizando múltiplas câmeras, para fazer o rastreamento de pessoas em um ambiente outdoor. O segundo constrói um mapa de grande, utilizando visão estéreo, com a informação da variância da altura do terreno. Essa informação é útil devido a necessidade de calcular a probabilidade de travessia de um célula do mapa considerando que o ambiente mapeado é defeituoso.

Em um trabalho mais recente, Hata & Wolf (2010)[17] propõem a utilização de uma grade 2D construída a partir de nuvens de pontos 3D visando identificar regiões navegáveis de um determinado terreno. A partir de informações dessa grade o robô pode inferir níveis de navegação: navegável, parcialmente navegável e não navegável.

Conforme os trabalhos já apresentados verifica-se na literatura que muitos deles envolvendo mapeamento estão utilizando câmeras como o principal sensor. A seguir apresentaremos de forma mais específicas trabalhos relacionado à mapeamento visual.

Horswill (1993)[18] comenta que ambientes *indoor* possuem duas propriedades que devem ser exploradas: a) Terreno plano: ambientes internos raramente têm pisos irregulares e são normalmente constituídos por um ou mais planos bem definidos ligados por elevadores ou escadas. Esse pressuposto permite que o ambiente possa ser modelado por um conjunto de mapas em duas dimensões; b) Texturas: ambientes internos possuem normalmente texturas uniformes e são normalmente revestidos por azulejos, ladrilhos ou carpete. A informação de textura pode ser usada para classificar áreas como ocupadas ou desocupadas.

Alguns trabalhos de mapeamento visual utilizam segmentação de imagens para detectar áreas livres. Martin (2002)[21] constatou que o chão em um ambiente *indoor* normalmente apresenta cor uniforme e que arestas são os melhores indicadores para as paredes do ambiente. Taylor et al. (2007)[22] utilizam segmentação de imagem para incorporação de espaços livres em mapa global. Isto é realizado em duas etapas: primeiro, um extrator de bordas é utilizado para identificar as fronteiras e em seguida, utilizando a informação da imagem segmentada, preenche-se no mapa os espaços livres. Além dessa informação visual um sonar é utilizado para dar mais confiança aos dados extraídos da imagem.

Sim & Dudek (2008)[23] analisaram o problema de automaticamente construir um mapa visual do ambiente com especial atenção à seleção de uma política de exploração que equilibre precisão e eficiência. Eles apresentam vantagens e desvantagens de exploração baseada em trajetórias retas, circulares concêntricas, em formato de oito, randômica, triângulo e estrela.

Apresentado vários trabalhos relacionados à esta pesquisa, percebe-se que a área de mapeamento automático usando robôs está sendo amplamente investigada e que soluções com sensor ótico estão sendo consideradas. A seção seguinte apresenta o sistema proposto.

4 Sistema Proposto

A modelagem da grade de ocupação probabilística 2D obtida a partir de um sistema de visão monocular pressupõe o conhecimento da pose do robô, das incertezas da pose e de uma matriz de homografia. Neste caso, a obtenção destes três requisitos é possível a partir do SLAM visual do trabalho de Santana & Medeiros (2010)[24].

O sistema de SLAM de Santana & Medeiros (2010) [24] usa uma matriz de homografia, calculada no início da exploração, para fazer diretamente o mapeamento imagem-mundo das linhas existente no chão. Neste trabalho, um algoritmo de segmentação é usado para classificar o mundo em “chão” e “não-chão”. A partir desta classificação é possível usar a matriz de homografia para mapear como células livres a parte “chão” da imagem e também é possível usá-la para mapear as fronteiras das partes “não-chão” como obstáculos do mundo. A Figura 2 mostra o esquema desta proposta de construção de uma grade de ocupação visual.

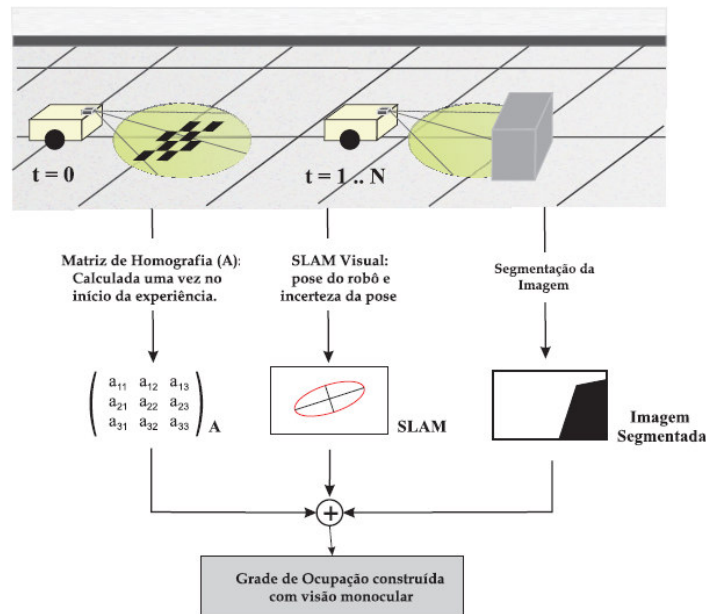


Figura 2 - Esquema de construção da grade de ocupação visual.

As etapas necessárias para a construção da grade de ocupação apresentada neste trabalho são: discretizar a imagem em células, classificar as células da imagem em “chão” e “não chão”, qualificar a parte “chão” como células livres e a parte “não chão” como células não-livres, reclassificar as células não-livres como obstáculo ou ocluso, mapear as células obstáculo para o mundo usando uma matriz de homografia e, por fim, expandir as células obstáculo usando as incertezas da pose do robô.

4.1 Discretização e Classificação

Nesta abordagem, o processamento de imagem é uma etapa fundamental. Para a discretização da imagem utilizou-se células (porções quadradas de tamanho fixo da imagem) e para a classificação foi feita uma análise das componentes de cor dessas células. Utilizou-se a idéia de considerar a área imediatamente abaixo do robô como uma área livre e assim, esta área pode usada como padrão para a classificação. O padrão é mapeado na imagem em uma área pré-definida e o algoritmo *Mean Shift* é usado para que se possa calcular as médias e variâncias das componentes de cor desta região. Uma vez calculada as variáveis de cor (média e variância de R, G e B) da região padrão usando o *Mean Shift*, estas variáveis são usadas como pontos de comparação entre esta região e as outras partes da imagem. A Figura 3 ilustra o comentado.




Figura 3 - Área de atuação do algoritmo *Mean Shift*.

A imagem capturada pela câmera é discretizada em células e a comparação entre as componentes de cor da região padrão com as componentes de cor de cada célula é usada para classificá-las como livres ou não-livres. A fim de encontrar um tamanho ideal da discretização de cada célula na imagem, ou seja, encontrar o tamanho da janela, em pixels, que será usada para fazer a comparação, foi realizado um estudo com diversas medidas.

Usando janelas de 5 x 5 pixels o tempo médio de processamento foi de 600ms; janelas de 10 x 10 pixels resultaram em um tempo médio de 300ms; com janelas de 15 x 15 o tempo médio foi de 220ms e com janela de 20 x 20 pixels o tempo foi de 170ms. Com base neste último valor, este foi o tamanho padrão das janelas utilizadas. A Figura 4 mostra o gráfico do tempo de processamento usando cada uma das medidas descritas. Nela, além de constatar os valores apresentados, também é possível notar que o sistema possui tempo de processamento estável.




Figura 4 - Gráfico do tempo de processamento do sistema de segmentação.

Para exemplificar o resultado do algoritmo de classificação usado neste trabalho, as Figuras 5.a e 5.b mostram uma imagem contendo objetos de formas mais clássicas e as Figuras 5.c e 5.d mostram uma imagem contendo um objeto com uma forma mais complexa. A região em preto foi classificada como chão e a região em branco foi classificada como não chão.




Figura 5 - Classificação da imagem: (a) Imagem original de objetos mais clássicos discretizada em células, (b) Imagem classificada usando o algoritmo proposto, (c) Imagem original de objetos mais complexos discretizada em células, (d) Imagem classificada usando o algoritmo proposto.

4.2 Mapeamento Imagem-Mundo e Reclassificação

Um problema inerente a esta abordagem é o efeito da inclinação da câmera que faz com que os pontos na imagem representem uma forma diferente no mundo. A figura 6(a) mostra pontos distribuídos uniformemente na imagem de 640 x 480 pixels e a figura 6(b) apresenta o mapeamento destes pontos no mundo usando uma matriz de homografia. A matriz homográfica foi calculada para que o campo de visão da câmera fosse de 1m. Observando essa figura é possível perceber que uma célula na imagem (conjunto de quatro pontos) pode ser mapeada em mais de uma célula da grade no mundo.

Ainda nesta ilustração, a figura 6(a) mostra uma grade em uma imagem onde os quadrados possuem 20 pixels de lado e a figura 6(b) mostra que o mapeamento de uma célula em uma grade de 10cm de discretização pode ser feito em mais de uma célula e que muitas células podem ser mapeadas em uma única célula da grade.




Figura 6 - Efeito da inclinação da câmera no mapeamento imagem-mundo.

Outro problema desta abordagem é que um obstáculo na imagem é mapeado para o mundo de forma projetiva (ver Figura 7). Assim, todas as células na imagem que são consideradas não livres não podem ser mapeadas na grade 2D, pois dispõe-se apenas de informação da região fronteira entre os obstáculos e o chão.

Para sanar este problema foi implementado um algoritmo para reclassificar as células não livres como obstáculo ou oclusa. A idéia do algoritmo consiste em calcular um vetor cujo módulo é metade do tamanho da discretização da grade e no sentido do ponto (0,0) e, em seguida, é testado se a extremidade do vetor está contida em uma célula livre ou em uma célula não livre; se a extremidade estiver dentro de uma célula não livre esta célula é considerada *oclusa* e não será mapeada efetivamente na grade; caso contrário, a célula é considerada *obstáculo* e é mapeada na grade.




Figura 7 - Região de mapeamento imagem-mundo.

4.3 Expansão e Probabilidade de Ocupação

A fim de embutir no processo de construção da grade as incertezas da pose do robô, foram utilizadas as variâncias das componentes x (σ_x^2) e y (σ_y^2) em uma etapa de expansão dos obstáculos. Embora essas medidas não representem fielmente a incerteza do posicionamento do robô no mundo, pois a representação correta seria a elipse de incerteza, estas medidas servem para representá-la de forma aproximada. A expansão é feita de forma simples: se σ_x for maior que metade da discretização da grade este valor é incorporado às componentes x de cada célula ocupada no instante t ; se σ_y for maior que metade da discretização da grade este valor é incorporado às componentes y de cada célula ocupada no instante t .

O passo seguinte consiste em calcular a probabilidade de ocupação de cada célula. Nesta ótica, a câmera utilizada é modelada como um sensor de distância e isto nos permite usar a formulação probabilística clássica proposta por Elfes. Ele comenta que a modelagem dos sensores deve ser feita respeitando o princípio de funcionamento dos mesmos e verificando as restrições que levam ao surgimento de imprecisões. Assim, a modelagem de um sensor de alcance pode ser dada por uma função Gaussiana (Equação 4.1)

$$P(r, |d_{x,y}) = \frac{1}{\sqrt{2\pi}\sigma_r} \exp \left[-\frac{1}{2} \left(\frac{r - d_{x,y}}{\sigma_r} \right)^2 \right] \quad (4,1)$$

onde r é a distância medida pelo sensor, $d_{x,y}$ é a distância euclidiana entre a célula em que o sensor se encontra e a célula $m_{x,y}$ que está sendo analisada e σ_r é variância que representa a imprecisão na distância medida pelo sensor. O comportamento da variância do sensor é dado pela equação $f(r) = a.e^{(b,r)}$ e os valores das constantes foram calculados por experimentação sendo $a = 0:0002$ e $b = 3$.

5 Resultados Experimentais

A Figura 8 mostra um conjunto de experiências realizadas com sistema completo em funcionamento, ou seja, a partir das imagens uma grade de ocupação é construída. Ressalta-se que os resultados apresentados nesta figura consideram o robô parado e com incerteza mínima. Foram testadas situações em que os obstáculos se encontravam próximos uns dos outros e um pouco mais afastados (Figuras 8.a e 8.b). Também foram testadas situações onde um obstáculo maior não interferia na visada de um obstáculo menor e a situação inversa (Figuras 8.c e 8.d). Este último resultado mostra uma vantagem do método proposto em relação às construções tradicionais de grade de ocupação com laser ou sonar, pois com estes sensores os dois obstáculos não seriam mapeados simultaneamente dado que as leituras destes tipos de sensores são apenas em uma direção.




Figura 8 - Construção de grade de ocupação visual a partir de visão monocular.

Outra experiência, desta vez com o robô em movimento, também foi realizada para validar esta proposta. O robô navegou em um típico ambiente interno onde os obstáculos não estão no mesmo plano de navegação do robô. A Figura 9 ilustra o ambiente e a trajetória comandada ao robô. Durante este experimento 1238 imagens foram processadas em um tempo médio de 360ms incluindo o processamento necessário para o sistema de localização do robô. A grade de ocupação construída nesta experiência é exibida na Figura 10. O resultado foi satisfatório uma vez que é possível identificar nesta imagem algumas características reais do ambiente mapeado como o hall entre os cômodos, as paredes deste hall, as extremidades da cama além da estrutura completa do ambiente navegado.




Figura 9 – (a) Descrição do ambiente, (b) imagem real do ambiente, (c) mapa de grade de ocupação visual.




Figura 10 – Mapa de grade de ocupação visual probabilística 2D.

6 Conclusões e Perspectivas

Este trabalho apresentou uma abordagem para construção de grade de ocupação probabilística usando apenas visão monocular. O algoritmo de segmentação implementado é usado para classificar o mundo em “chão” e “não-chão” e a partir desta classificação é possível usar a matriz de homografia para mapear como células livres, a parte “chão” da imagem, e também é possível mapear as fronteiras das partes “não-chão” da imagem como obstáculos do mundo.

Foram realizados dois experimentos com robô real para validar a proposta: a primeira, considerando o robô parado e diversas configurações de obstáculos dispostos no ambiente e a segunda, em um típico ambiente indoor. Os resultados foram satisfatórios e o sistema se mostrou estável e funcionando em um tempo computacional aceitável para aplicações robóticas. Os experimentos mostram que essa abordagem tem bom potencial para a utilização em robôs de serviço, por exemplo.

Como trabalhos futuros pretende-se: estudar de forma mais profunda a modelagem probabilística do sensor; evoluir esta abordagem para uma solução de SLAM e; aperfeiçoar o algoritmo de segmentação do terreno de forma a torná-lo adaptativo - usando Redes Neurais, por exemplo.

7 Referências

- [1] Elfés, A. (1987), ‘Sonar-based real-world mapping and navigation’, *Journal of Robotics and Automation*, pp. 249–265 .
- [2] Elfés, A. (1989), *Occupancy Grids: A Probabilistic Framework for Robot Perception and Navigation*, Tese de doutorado, Electrical and Computer Engineering, Carnegie Mellon University.
- [3] Thrun, S., W. Burgard & Fox. D. (2005), *Probabilistic Robotics*, MIT Press.
- [4] Konolige, K. (1997), ‘Improved occupancy grids for map building’, *Autonomous Robots Vol.4*, pp. 351–367 .
- [5] Borenstein, J. & Y. Koren (1997), ‘The vector field histogram fast obstacle avoidance for mobile robots’, *IEEE Journal of Robotics and Automation* .
- [7] Canas, J. & V. Matellan (2006), ‘Dynamic gridmaps: comparing building techniques’, *Mathware and Soft Computing* .
- [8] Yguel, M., O. Aycard & C. Laugier (2006), ‘Efficient gpu-based construction of occupancy grids using several laser range-finders’, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* .
- [9] Sabo, R. (2002), ‘Incremental map building using an occupancy grid for an autonomous monocular robot’, *International Conference on Control, Automation, Robotics And Vision*, pp. 613–618 .
- [10] Merhy, B., P. Payeur&E. Petriu (2008), ‘Application of segmented 2-d probabilistic occupancy maps for robot sensing and navigation’, *IEEE Transaction on Instrumentation and Measurement*, Vol. 57, No. 12, pp. 2827–2837 .
- [11] Brailion, C., K. Usher, C. Pradalier, J. Crowley & C. Laugier (2006), ‘Fusion of stereo and optical flow data using occupancy grids’, *IEEE Intelligent Transportation Systems Conference*, pp. 1240–1245 .
- [12] Brailion, C., C. Pradalier, K. Usher, J. Crowley & C. Laugier (2008), ‘Occupancy grids from stereo and optical flow data’, *Experimental Robotics*, Springer, 367–376 .
- [13] Blanco, J. & J. Gonzalez (2007), ‘A new method for robust and efficient occupancy gridmap matching’, *Iberian Conference on Pattern Recognition and Image Analysis* .
- [14] Choi, Y. & S. Oh (2006), ‘Grid-based visual SLAM in complex environment’, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* .
- [15] Fleuret, F., J. Berclaz, R. Lengagne & P. Fua (2008), ‘Multicamera people tracking with a probabilistic occupancy map’, *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 30, No. 2, pp. 267–282 .
- [16] Marks, T., A. Howard, M. Bajracharya, G. Cottrell & L. Matthies (2008), ‘Gamma- SLAM: Using stereo vision and variance grid maps for SLAM in unstructured environments’, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 3717–3724 .
- [17] Hata, A. & D. Wolf (2010), ‘Mapeamento e classificação de terrenos utilizando aprendizado supervisionado’, *Congresso Brasileiro de Automática(CBA)*.
- [20] Horswill, I. (1993), ‘Polly: a vision-based artificial agent’, *AAAI Conference on Artificial Intelligence*.
- [21] Martin, M. C. (2002), ‘Genetic programming for robot vision’, *International Conference on the Simulation of Adaptive Behavior*, pp. 256–265 .
- [22] Taylor, T., W. Boles & S. Geva (2007), ‘Map building using cheap digital cameras’, *BiennialConference of the Australian Pattern Recognition*.
- [23] Sim, R. & G. Dudek (2008), ‘Effective exploration strategies for the construction of visual maps’, *IEEE/RSJ Conference on Intelligent Robots and Systems (IROS)*, pp.69–76 .
- [24] Santana, A. & A. Medeiros (2010), ‘Monocular-SLAM using floor lines’, *IEEE Latin American Robotic Symposium*.