

8º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

UM MÉTODO DE DESCRIÇÃO E RECONHECIMENTO DE AMBIENTES SUBAQUÁTICOS PARCIALMENTE ESTRUTURADOS UTILIZANDO SONAR FLS.

AUTORES:

Matheus Machado dos Santos, Maria Isabel Machado, Paulo Drews e Silvia da Costa Botelho

INSTITUIÇÃO:

Universidade Federal do Rio Grande - FURG

Este Trabalho foi preparado para apresentação no 8º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás - 8º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás - ABPG, no período de 20 a 22 de outubro de 2015, em Curitiba/PR. Esse Trabalho foi selecionado pelo Comitê Científico do evento para apresentação, seguindo as informações contidas no documento submetido pelo(s) autor(es). O conteúdo do Trabalho, como apresentado, não foi revisado pela ABPG. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões da Associação Brasileira de P&D em Petróleo e Gás. O(s) autor(es) tem conhecimento e aprovação de que este Trabalho seja publicado nos Anais do 8º PDPETRO.

UM MÉTODO DE DESCRIÇÃO E RECONHECIMENTO DE AMBIENTES SUBAQUÁTICOS PARCIALMENTE ESTRUTURADOS UTILIZANDO SONAR FLS.

Abstract

The use of robots in underwater exploration is gradually usual. The automation process of monitoring, inspection and underwater maintenance requires a good mapping system and simultaneous localization SLAM. One of the key issues of these systems is how to describe the sensory information of a navigation that they can be used to recognize a region that has already been visited. This paper proposes a description method of acoustic images of forward looking sonar FLS using a Gaussian probability model and a graph to represent the topological relations, is also presented a method to compare the descriptors. It is used in a real dataset of a marina.

Introdução

O mar é uma fonte de riquezas minerais e biológicas. Entretanto a sua exploração passa por um conjunto de desafios associados a características inóspita do meio.

O uso de sistemas robóticos para a realização de missões subaquáticas é crescente. Tanto robôs operados remotamente (Remoted Operated Robot - ROV) como autônomos (Autonomous Underwater Robot - AUV) começam a ser massivamente empregados em tarefas de monitoramento, exploração e inspeção de sítios subaquáticos.

A rápida absorção das ondas de alta frequência pela coluna d'água impede a propagação de ondas de rádio impossibilitando a comunicação sem fio e a utilização de GPS para localização. Os sensores ópticos também são afetados, limitando o alcance dos sensores laser e de imageamento devido à turbidez da água. Entretanto, os sensores acústicos não sofrem com a turbidez da água, porém os seus dados são de baixa resolução e muitas vezes difíceis de serem interpretados.

A capacidade de um sistema de identificar e se auto localizar, através de leituras sensoriais, em um ambiente desconhecido no qual está navegando é chamada de SLAM (do inglês, *Simultaneous Localization and Mapping*) (DURRANT-WHYTE; BAILEY, 2006) e é uma característica indispensável para a execução de qualquer tarefa autônoma e desejável em operações manuais ou semiautônomas.

Uma das questões chaves para resolver o problema de SLAM é como descrever as informações sensoriais de forma que elas possam ser posteriormente identificadas como uma região conhecida.

Essas detecções geralmente são realizadas utilizando sensores como câmeras, lasers, ou sonar, esse último mais específico para ambientes subaquáticos. E consistem basicamente na identificação de um mesmo lugar, em um ambiente desconhecido, utilizando informações sensoriais capturadas de diferentes pontos de vista.

Grande parte dos trabalhos de SLAM terrestre encontrados na literatura (MADDERN; MILFORD; WYETH, 2012), (SIBLEY *et al.*, 2010), (MILFORD; WYETH, 2008), (KONOLIGE; AGRAWAL, 2008), fazem o uso de imagens ópticas. A descrição das imagens inicia-se com a extração das regiões que contém os cantos dos objetos presentes na imagem. Em seguida essas regiões são descritas utilizando descritores locais, como o SIFT (LOWE, 2004) e o SURF (HERBERT; TINNE; LUC VAN, 2006), que são invariantes a escala, a rotação e a translação. Para posteriormente identificar as regiões semelhantes através da similaridade das descrições.

Porém no caso de imagens acústicas, onde as informações de textura dos objetos são praticamente inexistentes, esses tipos de descritores locais não apresentam bons resultados (HURTOS *et al.*, 2013). Portanto alguns trabalhos buscaram outras formas de descrição de imagens acústicas baseada na forma dos objetos (RIBAS *et al.*, 2006), (JOHANSSON *et al.*, 2010) (AYKIN; NEGAHDARIPOUR, 2013) ou no domínio da frequência (HURTOS *et al.*, 2012).

Este trabalho propõe um método probabilístico de descrição de imagens acústicas de um sonar de imageamento frontal FLS, que considera as formas dos objetos detectados e as relações topológicas entre eles.

Na próxima seção é dada uma breve descrição de como a imagem acústica é formada, na seção seguinte é descrito como o método proposto funciona, logo após o método é demonstrado utilizando imagens reais e finalmente na última seção o trabalho é concluído.

Formação da imagem acústica

Os sonares do tipo FLS (do inglês *Forward Looking Sonar*) são sensores ativos que enviam ondas acústicas que se propagam pelo meio até ser refletida por algum obstáculo ou ser completamente absorvidas pelo meio. As ondas refletidas são registradas pelo sensor. Os retornos capturados são representados por uma imagem onde os pixels representam a intensidade da onda refletida naquela região. A intensidade da onda refletida está relacionada com as propriedades de refletância dos objetos e a taxa de absorção da onda pelo meio.

O sonar do tipo *Forward Looking Sonar*- FLS envia ondas acústicas para frente e os retornos acústicos são capturados por uma matriz de hidrofone fixa, reduzindo o efeito de distorção provocado pelo movimento do robô, sendo ideal para o uso em movimento e em lugares com água turva. A figura 3c é um exemplo de uma imagem acústica de um sonar FLS.

Metodologia

O método de descrição de imagens acústicas proposto está dividido em três etapas para a descrição das imagens e uma para calcular a semelhança entre os descritores. A descrição de uma imagem acústica passa por uma etapa de extração das regiões de interesse utilizando uma busca recursiva, uma etapa de descrição das regiões extraídas utilizando o modelo probabilístico gaussiano e uma etapa de construção do grafo que estabelece as relações topológicas entre as regiões de interesse descritas. Logo após é mostrado como é realizada a comparação entre os descritores e a identificação das imagens semelhantes.

Extraindo Regiões de Interesse

As regiões de interesse são aquelas que possuem os retornos acústicos de mais alta intensidade. O processo de extração dessas regiões se divide em duas etapas. Inicialmente é realizada uma busca linear pelos pixels com intensidades superiores a um determinado valor ρ_{linear} . Para cada pixel encontrado é realizado uma busca recursiva em largura dos pixels vizinhos que possuem intensidades superiores a um segundo valor chamado de $\rho_{recursivo}$, sendo que $\rho_{recursivo} \leq \rho_{linear}$. Nessa busca é considerada a vizinhança 8.

O conjunto de pixels encontrados em cada busca é uma amostra que será descrita pelo modelo gaussiano. Cada elemento da amostra possui a linha Y , a coluna X e a intensidade I de cada pixel, e são representados como um vetor coluna como mostrado em (1).

$$X = \begin{bmatrix} x1 \\ x2 \\ \dots \\ xN \end{bmatrix}; Y = \begin{bmatrix} y1 \\ y2 \\ \dots \\ yN \end{bmatrix}; I = \begin{bmatrix} i1 \\ i2 \\ \dots \\ iN \end{bmatrix} \quad (1)$$

Durante a busca dos pixels vizinhos é utilizado uma máscara que determina quais pixels foram visitados, garantindo que um pixel pertença a apenas uma amostra.

Descrevendo as Regiões de Interesse

A gaussiana ajustada para cada amostra é definida como $GA = (\mu X, \mu Y, \mu I, \sigma X, \sigma Y, \sigma I, \theta, N)$, onde $\mu X, \mu Y, \mu I$ são as respectivas médias aritméticas das variáveis X, Y e I . O valor de σI é o desvio padrão da variável I , o valor de σX é o desvio padrão no eixo de maior dispersão, o valor σY é o desvio padrão no segundo eixo de maior dispersão, e θ é o ângulo de rotação da gaussiana com relação à imagem e finalmente N é número de elementos da amostra. Veja a figura 1.

O valor σI é calculado aplicando a equação do desvio padrão (2).

$$\sigma I = \frac{1}{N-1} \sum_{i=1}^N (i_i - \sigma i)^2 \quad (2)$$

Os valores de $\sigma X, \sigma Y$ são os autovalores da matriz de covariância Σ da amostra. A matriz de covariância Σ de uma amostra é calculada pela equação (3).

$$\begin{aligned} \sigma(x, y) &= E[(x - E(x))(y - E(y))] \\ \Sigma &= \begin{bmatrix} \sigma(x, x) & \sigma(x, y) \\ \sigma(y, x) & \sigma(y, y) \end{bmatrix} \end{aligned} \quad (3)$$

Os autovalores λ e os autovetores $\vec{v}$ são encontrados resolvendo o sistema de equações (4) utilizando a decomposição em valores singulares SVD.

$$\Sigma \vec{v} = \lambda \vec{v}$$

$$\begin{bmatrix} \sigma(x, x) & \sigma(x, y) \\ \sigma(y, x) & \sigma(y, y) \end{bmatrix} \begin{bmatrix} vx \\ vy \end{bmatrix} = \lambda \begin{bmatrix} vx \\ vy \end{bmatrix} \quad (4)$$

Resolvendo o sistema de equações (4), são encontrados dois autovalores λ_1, λ_2 e dois autovetores $\vec{v}_1, \vec{v}_2$, onde $\vec{v}_1$ aponta para a direção de maior dispersão, λ_1 é o comprimento de $\vec{v}_1$ e $\sigma X = \lambda_1$. $\vec{v}_2$ aponta em direção da segunda maior dispersão, λ_2 é o comprimento de $\vec{v}_2$ e $\lambda_2 = \sigma Y$. O ângulo de rotação θ é a tangente do autovetor $\vec{v}_1$, $\theta = \text{atan2}(v1x, v1y)$ veja na figura 1.

Estabelecendo as Relações Topológicas

Após a descrição das regiões de interesse da imagem utilizando o modelo gaussiano, um grafo G é criado para representar as suas relações topológicas. Onde G é um grafo dirigido e simétrico definido como $G = (V, E)$ onde $V = \{GA_1, GA_2, \dots, GA_N\}$ e $E = \{E_1, E_2, \dots, E_M\}$. As arestas $E_i = \{GA_{orig}, GA_{dest}, \theta_e, \rho\}$ conectam duas GAs qualquer $\{GA_{orig}, GA_{dest} \in V / GA_{orig} \neq GA_{dest}\}$, onde θ_e é a inclinação da aresta com relação ao eixo de maior dispersão θ da gaussina de origem GA_{orig} calculado pela equação (5) e ρ é o tamanho da aresta que liga GA_{orig} a GA_{dest} calculado pela distância euclidiana entre as médias das gaussianas, equação (6). Veja a figura 1.

$$\theta_e = \text{atan2}(\mu Y_{dest} - \mu Y_{orig}, \mu X_{dest} - \mu X_{orig}) - \theta_{orig} \quad (5)$$

$$\rho = \sqrt{(\mu X_{orig} - \mu X_{dest})^2 + (\mu Y_{orig} - \mu Y_{dest})^2} \quad (6)$$

Como a inclinação das arestas é calculada com referência ao eixo de maior dispersão da gaussiana de origem, a inclinação da aresta será a mesma independente do ponto de vista do sonar, desde que o eixo de maior dispersão da região descrita não varie.




Figura 1 - Modelo de Representação das Regiões de Interesse, em verde e azul os autovalores e autovalores da matriz de covariância Σ da região de interesse representada por GA_1 . Em amarelo a aresta que liga GA_1 com GA_2 .

A Comparação dos Descritores

A última etapa é a detecção das imagens semelhantes com base na comparação dos grafos topológicos de cada imagem. Uma função $cmp(GA_m, GA_n)$ compara a semelhança entre um par de vértices GA_m, GA_n de dois grafos G_k, G_l distintos, sendo que $GA_m \in G_k$ e $GA_n \in G_l$. O algoritmo da figura 2 mostra como a função $cmp(GA_m, GA_n)$ compara as arestas.

A função $proxima(E_i, GA_j)$ é usada para acessar a próxima aresta adjacente após E_i em ordem de inclinação θ_e crescente de um vértice GA_j qualquer. A diferença de inclinação média $\epsilon\theta$ e a diferença de comprimento médio $\epsilon\rho$ entre as arestas são calculadas apenas entre os pares de arestas semelhantes.

Um par de arestas é considerado semelhante quando $\Delta\rho < max\rho$ e $\Delta\theta < max\theta_e$ é satisfeito. Onde $\Delta\rho$ e $\Delta\theta$ são respectivamente as diferenças de comprimento e inclinação entre as arestas e $max\rho$ e $max\theta$ são valores pré-determinados.

A função retorna o número de pares de arestas semelhantes $\Sigma Acerto$ e a soma ponderada σ_{mn} , das diferenças médias de inclinação $\epsilon\theta$ e de tamanho $\epsilon\rho$, indicando a semelhança entre os dois vértices. Neste caso quanto menor for σ_{mn} , maior é a semelhança do par de vértices. Os pesos $w\theta$ e $w\rho$ são pré-determinados.

Para encontrar os pares de vértices semelhantes entre dois grafos G_k, G_l quaisquer são calculados σ_{mn} e $\Sigma Acerto$ usando $cmp(GA_m, GA_n)$ para todos $GA_m \in G_k$ com relação a todos $GA_n \in G_l$. Os pares de vértices com menos que $\rho_{semelhante}$ arestas semelhantes, $\Sigma Acerto < \rho_{semelhante}$, são descartados. Os pares de vértices com os menores valores de σ_{mn} são considerados semelhantes.

Este método de comparação tem a premissa de que o ambiente é parcialmente estruturado e parcialmente estático, e que, portanto os eixos de maior dispersão das regiões de interesse e as suas relações topológicas não se alteram com o passar do tempo e nem com a mudança do ponto de vista do sonar.

Algoritmo 1 Compara Vertices

```

função CMP( $GA_x, GA_y$ )
   $\Sigma Acerto \leftarrow 0$ 
  enquanto  $u \neq fim \neq fim$  faça
     $\Delta\rho \leftarrow ||u.\rho - v.\rho||$ 
     $\Delta\theta \leftarrow ||u.\theta_e - v.\theta_e||$ 
    se  $\Delta\rho < max\rho$  e  $\Delta\theta < max\theta_e$  então
       $\epsilon\theta \leftarrow \epsilon\theta + \Delta\theta$ 
       $\epsilon\rho \leftarrow \epsilon\rho + \Delta\rho$ 
       $\Sigma Acerto \leftarrow \Sigma Acerto + 1$ 
       $u \leftarrow proxima(u, GA_x)$ 
       $v \leftarrow proxima(v, GA_y)$ 
    senão
      se  $u.\theta_e < v.\theta_e$  então
         $u \leftarrow proxima(u, GA_x)$ 
      senão
         $v \leftarrow proxima(v, GA_y)$ 
      fim se
    fim se
  fim enquanto
  se  $\Sigma Acerto > 0$  então
     $\epsilon\theta \leftarrow \epsilon\theta / \Sigma Acerto$ 
     $\epsilon\rho \leftarrow \epsilon\rho / \Sigma Acerto$ 
  fim se
   $\sigma_{xy} \leftarrow w\theta\epsilon\theta + w\rho\epsilon\rho$ 
  retorna  $\sigma_{xy}, \Sigma Acerto$ 
fim função

```

Figura 2 - Algoritmo de comparação de vértices**Resultados e Discussão**

O método foi testado no dataset ARACATI2014 disponibilizado por (SILVEIRA *et al.*, 2015). Neste Dataset um mini ROV Seabotix LBV300-5 equipado com um sonar FLS Teledyne BlueView P900-130 e um sensor de localização DGPS percorre por cerca de 300m em uma marina no Yacht Clube de Rio Grande em Rio Grande, Rio Grande do Sul, Brasil. É um lugar parcialmente estruturado onde, nas imagens acústicas, podem ser identificados, os cascos dos navios, o cais e os postes de madeira utilizados para amarrar os navios, veja na figura 3.



Figura 3 - Imagens do Dataset ARACATI2014 (Silveira et al.,2015). a) O trajeto percorrido pelo ROV em vermelho, os pontos azul e versão são os pontos de início e término da trajetória. b) Imagens do local. c) Uma imagem acústica capturada pelo ROV no local.

A figura 4 mostra as etapas de descrição de duas imagens acústicas (figuras 4a e 4b). As figuras 4c e 4d exibem os resultados da etapa de extração das regiões de interesse. As figuras 4e e 4f mostram o resultado da descrição das regiões de interesse usando o modelo Gaussiano, a linha verde indica a direção do eixo de maior dispersão e o número próximo a esta linha indica a sua inclinação em graus. As figuras 4g e 4h mostram o grafo topológico encontrado para cada imagem. A figura 4i mostra os vértices semelhantes dos dois grafos.




Figura 4 - Etapas de descrição e comparação de imagens acústicas

Para validação do método proposto foram extraídas manualmente as regiões de interesse e definidas as regiões semelhantes entre 35 pares de imagens. Em média foram extraídas manualmente 20 regiões de interesse de cada imagem. Ao total 22% dos pares criados a mão foram encontrados pelo método proposto. Dos 35 pares de imagem, 16 tiveram 5 ou mais acertos e 24 tiveram 3 ou mais acertos.

O método proposto demonstrou-se ser sensível a objetos com formas aproximadamente redonda. Nestes casos a inclinação do eixo de maior dispersão do mesmo objeto descrito em diferentes imagens varia prejudicando a detecção das semelhanças.

Conclusões

Este trabalho apresentou um método de descrição de imagens acústicas que considera a forma dos objetos e as suas relações topológicas para ambientes parcialmente estruturados e demonstrou como as imagens acústicas reais do dataset ARACATI2014 (SILVEIRA *et al.*, 2015) são descritas e comparadas.

Como trabalhos futuros pretende-se fazer um estudo detalhado deste método aplicado em outros dataset e também utilizar o método para estimar informações de odometria e detecção de loop em percursos fechados para alimentar um sistema de SLAM como o DolphinSLAM proposto por (SILVEIRA *et al.*, 2015).

Agradecimentos

Os autores agradecem ao Grupo de Pesquisa em Automação e Robótica Inteligente NAUTEC-FURG, ao Programa de Recursos Humanos PRH-27-FURG, a Agência Nacional do Petróleo ANP, pelo apoio e o suporte para este trabalho.

Referências Bibliográficas

- AYKIN, M. D.; NEGAHDARIPOUR, S. On Feature Matching and Image Registration for Two-dimensional Forward-scan Sonar Imaging. **J. Field Robotics**, May 2013. 602–623.
- DURRANT-WHITE, H.; BAILEY, T. Simultaneous localization and mapping: part I. **Robotics Automation Magazine**, 13, 2006.
- HERBERT, B.; TINNE, T.; LUC VAN, G. Surf: Speeded up robust features. **In ECCV**, 2006. 404–417.
- HURTOS, N. et al. Fourier-based registrations for two-dimensional forward-looking sonar image mosaicing. **Intelligent Robots and Systems (IROS), 2012 IEEE/RSJ International Conference on**, Oct 2012. 5298–5305.
- HURTOS, N. et al. Evaluation of registration methods on two-dimensional forward-looking sonar imagery. **OCEANS - Bergen, 2013 MTS/IEEE**, June 2013. 1–8.
- JOHANSSON, H. et al. Imaging sonar-aided navigation for autonomous underwater harbor surveillance. **Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on**, Oct 2010. 4396–4403.
- KONOLIGE, K.; AGRAWAL, M. FrameSLAM: From bundle adjustment to real-time visual mapping. **IEEE Transactions on Robotics**, 2008. 1066–1077.
- LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints. **International Journal of Computer Vision**, November 2004. 91–110.
- MADDERN, W.; MILFORD, M.; WYETH, G. CAT-SLAM: probabilistic localisation and mapping using a continuous appearance-based trajectory. **IJRR**, 31, 2012.
- MILFORD, M. J.; WYETH, G. F. Mapping a Suburb With a Single Camera Using a Biologically Inspired SLAM System. **IEEE Transactions on Robotics**, 24, 2008.
- RIBAS, D. et al. SLAM using an Imaging Sonar for Partially Structured Underwater Environments. **Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on**, Oct 2006. 5040–5045.
- SIBLEY, G. et al. Vast-scale outdoor navigation using adaptive relative bundle adjustment. **The International Journal of Robotics Research**, 2010.
- SILVEIRA, L. et al. An Open-Source Bio-Inspired Solution to Underwater SLAM. **IFAC Workshop on Navigation, Guidance and Control of Underwater Vehicles NGCUV**, 2015.
- WILLIAMS, S.; MAHON, I. Simultaneous localisation and mapping on the Great Barrier Reef. **Robotics and Automation, 2004. Proceedings. ICRA '04. 2004 IEEE International Conference on**, 2, 2004.