

UMA ABORDAGEM BIOINSPIRADA PARA LOCALIZAÇÃO E MAPEAMENTO

LUAN SILVEIRA*, FELIPE ALBRING GUTH*, SILVIA S. C. BOTELHO*, PAULO J. L. DREWS JR*

*NAUTEC - Centro de Ciências Computacionais
Universidade Federal do Rio Grande - FURG
Rio Grande, RS, Brasil

Emails: luansilveira@furg.br, felipeguth@furg.br, silviacb@furg.br, paulodreww@furg.br

Abstract— Considering the many challenges in robotics, one of the most important concerns to a mobile robot builds a map and estimates its location in an environment, called Simultaneous Localization and Mapping (SLAM). Nowadays, the probabilistic approach has dominated the solution to the SLAM problem, anyway the last decade have witnessed important bio-inspired studies based on biological structures related to spatial navigation in animals. Past and recent studies found Place, Head Direction and Grid Cells. They are related to the tasks of mapping and location in mammals. Continuous Attractor Neural Networks (CANN) are being proposed to simulate these cells. In the present work, we show a biological approach to solve the SLAM problem based on CANN, called Hippo 3D. It is a highly parallelizable approach and capable of running in real time applications. With the method we intend to contribute to the SLAM area in three-dimensional environments such as the complex localization and mapping in underwater environments.

Keywords— Simultaneous Localization and Mapping, Bioinspired Systems, Continuous Attractor Neural Networks.

Resumo— Um dos desafios mais importantes está na capacidade de um robô móvel criar um mapa de um ambiente desconhecido e, ao mesmo tempo, localizar-se nesse mapa, processo conhecido como SLAM. Atualmente, abordagens probabilísticas dominam a solução do problema de SLAM, no entanto na última década surgiram importantes estudos bioinspirados baseados na descoberta de neurônios encontrados no cérebro dos mamíferos. Dentre as células relacionadas a tarefas de localização e mapeamento, pode-se citar as *Place Cells*, *Head Direction Cells* e as *Grid Cells*. Para simular o comportamento dessas células foram propostos modelos baseados em Redes Neurais de Atração Contínua. Neste trabalho é apresentado uma abordagem bioinspirada nesses neurônios, chamada Hippo 3D, para resolver o problema de SLAM em ambientes tridimensionais, sendo altamente paralelizável e com capacidade de execução em tempo real. Com esse trabalho pretende-se contribuir para a resolução do problema de SLAM em ambientes tridimensionais, como o ambiente subaquático.

Palavras-chave— Localização e Mapeamento Simultâneos, Sistemas bio-inspirados, Redes Neurais de Atração Contínua

1 Introdução

O mapeamento robótico tem sido largamente explorado dentro da robótica e inteligência artificial nas últimas duas décadas (Thrun, 2002). A qualidade do modelo representativo do ambiente depende das características do ambiente e dos sensores utilizados (Botelho et al., 2009). O problema de localização tem sido tratado juntamente com o mapeamento, processo conhecido como SLAM (*Simultaneous Localization and Mapping*). Esse termo pode ser descrito como criar uma representação espacial de um ambiente desconhecido usando dados sensoriais e, simultaneamente, localizar um robô no ambiente usando essa representação.

Desde o descobrimento das *Place Cells* no Hipocampo dos roedores (O'Keefe and Dostrovsky, 1971), surgiu uma onda de interesse em mecanismos de aprendizado espacial, que perdura até hoje. *Place Cell*, inicialmente encontradas em ratos, são neurônios que aumentam sua taxa de disparo sempre que o animal passa por uma determinada região do ambiente. Posteriormente, descobriu-se a existência de neurônios que tem sua taxa de disparo aumentada quando a cabeça do rato esta olhando para determinada direção, chama-

das *Head Direction Cells*. Quase três décadas após as primeiras descobertas, (Hafting et al., 2005) reportou a existência de um novo tipo de célula, as *Grid Cells*. Esses neurônios aumentam a taxa de disparo quando o animal cruza um dos vértices de um grid triangular disposto sobre o ambiente. Com esse comportamento, essas células apresentam vários campos de disparo. (Moser et al., 2008).

Em 2008, (Milford and Wyeth, 2008) criaram um sistema de localização e mapeamento robótico baseado nos neurônios encontrados no Hipocampo dos Ratos, chamado RatSLAM. Para simular o comportamento dos neurônios foi utilizado uma Rede Neural de Atração Contínua (CANN). Esse sistema foi capaz de resolver o problema de SLAM em ambientes 2D, utilizando um sistema de visão monocular e informações de odometria. Além disso, foi capaz de criar o mapa em tempo real, realizando fechamento de loops e localização através de uma sequência de pistas visuais.

Neste trabalho é apresentado uma extensão do algoritmo RatSLAM, tornando-o capaz de resolver o problema de SLAM em ambientes 3D. Devido sua inspiração nas células do Hipocampo dos roedores, o novo sistema será chamado Hippo 3D. Para validar o método foram realizados testes em ambientes tridimensionais simulados. Este trabalho

busca desenvolver um método bioinspirado para tratar o problema de localização e mapeamento em um dos cenários mais complexos da robótica atual, o fundo do mar. A seção 2 apresenta um breve resumo das descobertas de mecanismos neuronais nos mamíferos. A adaptação dessas estruturas em algoritmos para a resolução do problema de SLAM é apresentada na seção 3, seguida da demonstração do potencial do método em realizar o mapeamento de ambientes complexos.

2 Células Nervosas e Localização

Nas últimas décadas, pesquisas em neurociência experimental realizadas principalmente com roedores levaram ao descobrimento de neurônios envolvidos na navegação espacial. Resultados de experimentos com humanos e primatas são raros, mas suportam as descobertas feitas com roedores, sugerindo que todos esses mamíferos baseiam-se nos mesmos mecanismos para localização e mapeamento. (Sünderhauf and Protzel, 2010)

O primeiro tipo de célula descoberto foi a *Place Cells* no Hipocampo dos roedores (O'Keefe and Dostrovsky, 1971). Enquanto ficam inativos a maior parte do tempo, rapidamente aumentam sua taxa de disparo sempre que o rato entra em determinada área do ambiente, chamada de campo de disparo da célula. As *Place Cells* diferem em tamanho e forma. Além disso, tem sua atividade guiada por pistas visuais (*landmarks*). Muitos experimentos provaram que os campos de disparo podem ser movidos, ou de alguma forma influenciados, pela movimentação dos *landmarks* visuais (O'Keefe and Conway, 1978; O'Keefe and Speakman, 1987). No entanto, essas células são capazes de localizar o animal em um ambiente conhecido mesmo quando os *landmarks* são removidos (Muller et al., 1987). Esse comportamento sugere que pistas motoras internas ao animal, como por exemplo o sistema *vestibular*, guiam o processo de integração de caminho, que corresponde ao mecanismo de *dead reckoning* no contexto de SLAM.

Em 2005, (Hafting et al., 2005) reportou a descoberta de um tipo de neurônio mais complexo no Córtex Entorrinal dos roedores. Essas células possuem múltiplos campos de disparo em um determinado ambiente. Por esse comportamento, foram chamadas *Grid Cell*. Da mesma forma que as *Place Cells*, são influenciadas pelas pistas visuais do ambiente.

Enquanto as células supracitadas estão relacionadas a posição do animal, (Muller et al., 1996) reportou a existência de neurônios ligados a orientação da cabeça do animal, sendo também fortemente ligadas às pistas visuais encontradas no ambiente e aos sinais de movimentação próprios.

(Stringer et al., 2002) descreve o uso de redes neurais auto-organizáveis para simulação do comportamento das *Head Direction Cells*, bem

como mecanismos de integração de caminho, sendo posteriormente aplicado em sistemas robóticos de localização (Silveira et al., 2012).

2.1 Redes Neurais de Atração Contínua - CANN

Muitas abordagens bioinspiradas (Stringer et al., 2002), (Milford and Wyeth, 2008) utilizam algum tipo de Rede Neural de Atração Contínua. Normalmente essas redes neurais artificiais são utilizadas para simular o comportamento de células cerebrais que possuem memória, como as *Place*, *Head Direction* e *Grid Cells*. Essa rede caracteriza-se por apresentar conexões recorrentes entre os neurônios, responsáveis pelo efeito memória. Essa rede é capaz de manter uma estimativa contínua de localização, sendo atualizada pelas entradas visuais externas e pelos estímulos de localização internos.

O modelo CANN genérico é formado por um conjunto de neurônios interconectados, como mostrado na Fig. 1-a, além de um sistema de inibição global. A Fig. 1-b apresenta o modelo CANN para neurônios de orientação (*Head Direction Cells*). Cada neurônio possui conexão com seus vizinhos, sendo esta modulada pela distância entre eles: Quanto menor a distância, mais forte será a ligação sináptica.

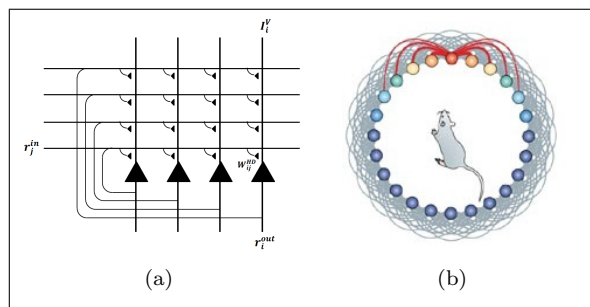


Figura 1: a) Rede Neural de Atração Contínua com conexões recorrentes. Cada saída de um neurônio é reinjetada em todos os outros neurônios da rede, modulada pelo peso sináptico w_{ij}^{HD} . Além disso, entradas externas I_i^V são aplicadas aos neurônios da rede. b) Modelo CANN para simular o comportamento das *Head Direction Cell*.

3 O sistema Hippo 3D

O sistema implementado neste trabalho é fortemente baseado no RatSLAM, descrito em (Milford and Wyeth, 2008). O RatSLAM é um sistema inspirado no cérebro dos roedores usando três componentes: A *Pose Cell*, formada por uma rede neural CANN que modela o comportamento das *Grid Cells* em conjunto com as *Head Direction Cells*; As *Local View Cells* que provêem uma interface entre as informações sensoriais capturadas no ambiente com a *Pose Cell*, simulando o sistema de percepção dos mamíferos; e uma *Mapa de Experiências* responsável por compilar as informações de

localização com as informações sensoriais do ambiente, sendo conceitualmente similar as *Place Cells* (Veja Fig. 2). Foi inicialmente apresentado por Milford e seus colegas em 2003, sofrendo algumas extensões durante os anos: (Milford et al., 2006), (Milford, 2008), (Glover et al., 2010).

Este trabalho apresenta uma implementação que contém mudanças e extensões nos módulos do RatSLAM original, objetivando principalmente a utilização do sistema em ambientes 3D. A seguir serão listadas as modificações frente ao sistema original:

- Módulo Pose Cell: Uma camada extra foi adicionada à rede neural para adaptar a estimativa de posição para ambientes tridimensionais. Essa camada representa a dimensão z . Com isso, a CANN torna-se capaz de estimar a posição xyz do agente e a orientação em torno do eixo z (yaw).

- Módulo Mapa de Experiências: O mapa de experiências permite a criação de mapas tridimensionais. Para isso, o processo de criação e atualização de experiências foi modificado, bem como o de fechamento de loops.

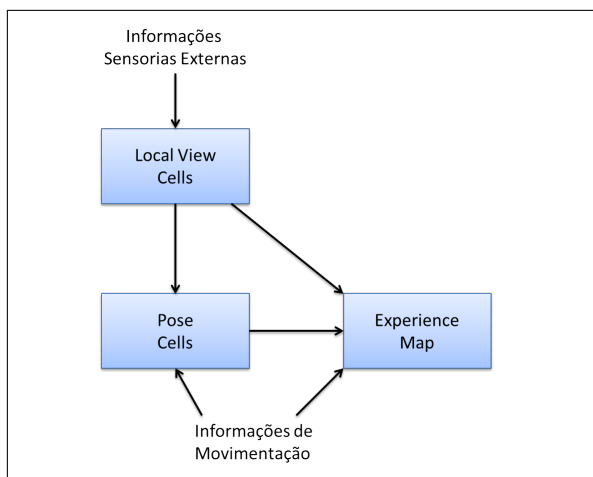


Figura 2: Arquitetura do Sistema RatSLAM.

Os componentes do sistema Hippo3D e suas iterações são ilustrados na Fig. 2. As subseções seguintes detalham o funcionamento de cada módulo.

3.1 Pose Cells

O núcleo do sistema RatSLAM é formado por uma rede neural artificial de atração contínua com 4 dimensões, constituídas por neurônios chamados Pose Cells. Cada célula da rede representa um determinado volume de espaço (por exemplo: $10m \times 10m \times 10m \times 10^\circ$) e o padrão de atividade de todas as células expressa uma crença discretizada da atual posição do robô no ambiente explorado.

Cada neurônio ativo na rede apresenta um efeito excitatório sobre ele mesmo e sobre seus vizinhos próximos, além de um efeito inibitório nos neurônios mais afastados, preservando um pacote

local de atividade na rede. Devido a inibição, esses pacotes de atividade locais competem até um estado estável ser atingido. Cada célula pode receber estímulos adicionais advindos das Local View Cells, que injetam energia na rede. Se a energia for injetada próximo a um pacote existente, aquele pacote move-se ao encontro da energia injetada. Se for injetado em uma posição distante aos pacotes de atividade existentes, eventualmente pode-se criar um novo pacote nesse local, competir com os já existentes e, possivelmente, impor-se sobre os pacotes mais antigos (Milford and Wyeth, 2008). A rede neural é finita, no entanto existe um mecanismo que possibilita um pacote de atividade deslocar-se sobre as bordas da rede. Com isso, a rede é capaz de mapear um espaço infinito (x, y, z) , embora o mapeamento torne-se ambíguo. As informações de movimentação são responsáveis pelo mecanismo de integração de caminho, permitindo que a estimativa de posição desloque-se no sentido da movimentação. Ao mesmo tempo, as informações visuais são associadas a estimativa de posição por meio de um aprendizado associativo.

3.1.1 Excitação da Rede

A primeira etapa de atualização da rede consiste na excitação dos neurônios. Cada neurônio excita seus vizinhos de acordo com o peso sináptico de ligação entre eles. Primeiramente, é necessário especificar os pesos sinápticos de excitação entre eles, nomeada matriz W^e , significando a matriz de excitação da rede. Essa matriz é calculada usando uma função gaussiana das distâncias entre os neurônios:

$$w_{ijkl}^e = e^{-\frac{d_x^2}{2 \cdot \sigma_x^2} - \frac{d_y^2}{2 \cdot \sigma_y^2} - \frac{d_z^2}{2 \cdot \sigma_z^2} - \frac{d_\theta^2}{2 \cdot \sigma_\theta^2}} \quad (1)$$

onde d_i e σ_i representam respectivamente a distância entre os neurônios e o desvio padrão de excitação na dimensão i .

A taxa de ativação dos neurônios (P) é obtida pela convolução entre a taxa de ativação atual pela matriz de excitação dos pesos:

$$P = P * W^e \quad (2)$$

3.1.2 Inibição da Rede

Após a etapa de excitação é feita uma inibição global em todos os neurônios da rede, para permitir que vários pacotes possam competir na rede. Essa etapa basicamente diminui a excitação de todos os neurônios por uma taxa constante, como mostrada na equação 3.

$$p_{ijkl} = p_{ijkl} - k^{Inib}, \quad (3)$$

onde p_{ijkl} representa a atividade do neurônio $ijkl$. Na ausência de sinais de movimentação próprios, a combinação das excitação local com a

inibição global permeia a formação de um único pacote de atividade.

3.1.3 Integração de Caminho

A próxima etapa de atualização da rede compreende a integração de caminho, que consiste do deslocamento do pacote de atividade da rede na direção da movimentação do robô. Essa etapa é realizada fazendo-se uma cópia do pacote de ativação atual e deslocando-o para a nova posição de acordo com a velocidade e direção do deslocamento.

3.2 Local View Cells Module

O erro acumulado pelo processo de integração de caminho é resetado pelas entradas visuais capturadas pelo robô. Essas entradas são conectadas às localviews por meio de conexões sinápticas. As Local View Cells são representadas por um vetor V , onde cada elemento do vetor representa a atividade de uma localview. Sempre que uma nova visualização é apresentada ao sistema, cria-se uma nova posição no vetor V e faz-se um aprendizado associativo Hebbiano entre a Local View e os neurônios da Pose Cell, dado pela equação:

$$\Delta\beta_{ijkl}^m = k\beta_{ijkl}^m p_{ijkl}, \quad (4)$$

onde β_{ijkl}^m é o peso sináptico associado entre a Local View m e o neurônio $ijkl$ da Rede Neural. Quando uma visualização conhecida é apresentada ao sistema, injeta-se energia na Pose Cell de acordo com os pesos sinápticos associados a Local View Ativa.

O aprendizado utilizado neste trabalho difere da implementação utilizada no sistema RatSLAM.

3.2.1 Normalização dos pesos sinápticos de entrada

O aprendizado Hebbiano caracteriza-se por um aumento contínuo dos pesos sinápticos, o que deve ser limitado para evitar um domínio total de uma entrada externa. Para manter a competição da rede, foi implementado uma limitação máxima para a energia a ser injetada na Pose Cell. Se a energia externa total associada a uma local View exceder a energia máxima, os pesos sinápticos serão modificados de acordo com a equação 5.

$$\begin{aligned} sum &= \sum_{i=0}^{N_i} \sum_{j=0}^{N_j} \sum_{k=0}^{N_k} \sum_{l=0}^{N_l} \beta_{ijkl}, \\ \beta_{ijkl} &= MAX_{ENERGY} * \frac{\beta_{ijkl}}{sum}, \end{aligned} \quad (5)$$

3.2.2 Aplicação da energia externa na Pose Cell

Sempre que uma informação sensorial externa for capturada pelo robô, o módulo Local View deve

injetar energia na Pose Cell para resetar os erros de integração de caminho. Com os pesos sinápticos devidamente treinados, a energia injetada na rede será dada pela equação abaixo:

$$p_{ijkl} = p_{ijkl} + \beta_{ijkl}^m, \quad (6)$$

onde p_{ijkl} representa a taxa de ativação de um neurônio da rede e β_{ijkl}^m é a ligação sináptica entre a Local View ativa m e o neurônio $ijkl$. Essa atualização é realizada sobre todos os neurônios da rede.

3.3 Mapa de Experiências

O último módulo do sistema é o Mapa de Experiências. Ele consiste em um mapa topológico formado por todas as experiências vivenciadas pelo robô. Cada experiência é uma tupla e_i , como mostrado na equação 7. Em outras palavras, cada experiência é a união da local View ativa V_m com o pacote de atividade ativo p_{ijkl} , em uma posição estimada pos .

$$e_i = \{V_i, P_i, pos_i\} \quad (7)$$

A posição pos é pose 3D, como mostrada na equação 8. Essa posição é composta por uma origem e uma orientação, como mostrada nas equações subsequentes. A Orientação é representada por um quaternion.

$$pos_i = [Origem; Orientacao], \quad (8)$$

onde:

$$Origem = [x, y, z] \quad (9)$$

$$Orientacao = [x, y, z, w] \quad (10)$$

Da mesma forma, a ligação entre duas experiências será modificado frente ao sistema RatSLAM, sendo agora representado por uma pose T_{ij} , que significa a transformação entre as duas experiências.

$$l_{ij} = \{T_{ij}\}, \quad (11)$$

Além de armazenar o mapa e a atual localização do robô, esse módulo deve ser capaz de reconhecer uma experiência no momento que a informação de Local View e da Pose Cell estão disponíveis. Para reconhecer uma experiência previamente vivenciada, o módulo compara a informações da Local View e da Pose Cell com todas as experiências anteriores. Caso encontre uma correspondência, ocorre o evento de fechamento de loop.

Caso não haja nenhuma correspondência, uma nova experiência deve ser criada. A posição pos da nova experiência é calculada a partir da experiência atual e pela transformação acumulada pela integração de caminho T_{ij} , a partir da equação:

$$p_j = p_i * T_{ij} \quad (12)$$

3.3.1 Fechamento de loop

O fechamento de loop é o processo de reconhecimento de uma experiência previamente conhecida. Esse processo será responsável por corrigir os erros de odometria acumulados durante a navegação. A equação de correção é apresentada na Eq. 13.

Na nova implementação, a correção dos erros de odometria será feita de uma outra forma, baseando-se na média das estimativas de posição da experiência, sendo mais estável que a forma anterior, baseada na correção do erro por meio de uma taxa de atualização.

$$p_{i.or} = \frac{p_{i.or} + \sum_{j=1}^{n_c} (p_j * T_{ji}).or + \sum_{k=1}^{n_s} (p_k * T_{ik}^{-1}).or}{1 + n_c + n_s}, \quad (13)$$

onde $p_{i.or}$ é um acrônimo para $p_i.origem$, representando o vetor origem da pose.

A orientação atualizada é calculada de forma similar. O primeiro passo é encontrar o ângulo yaw a partir dos quaternions de todas as estimativas. Após isso, faz-se uma média entre esses ângulos, transformando-os para coordenadas cartesianas, somando seus vetores, e encontrando o ângulo do vetor resultante.

4 Resultados

A complexidade dos ambientes marinhos e a necessidade crescente no uso de sistemas para inspeção e realização de tarefas estabelece desafios científicos e tecnológicos interdisciplinares. Uma das maiores motivações deste trabalho é aumentar a navegabilidade e a capacidade de mapeamento de robôs subaquáticos nesses ambientes.

O sistema Hippo 3D foi testado em um ambiente subaquático simulado, recuperando informações do ambiente navegado por meio de templates visuais, da mesma forma do sistema RatSLAM. (Milford, 2008).

O robô navegou em um ambiente tridimensional, com a trajetória real (Ground Truth) mostrado na Fig. 3-a. A 3-b mostra a trajetória calculada utilizando-se apenas os dados de odometria. Os resultados preliminares são mostrados na Fig. 3-c. O erro de posição do mapa final é plotado na Fig. 4.

5 Conclusões

Nos últimos anos, neurocientistas fizeram algumas descobertas de mecanismos cerebrais de mamíferos ligadas a tarefas de localização. Na robótica, um sistema bioinspirado para resolver o problema de SLAM foi desenvolvido por (Milford, 2008), apelidado RatSLAM, devido sua inspiração nas

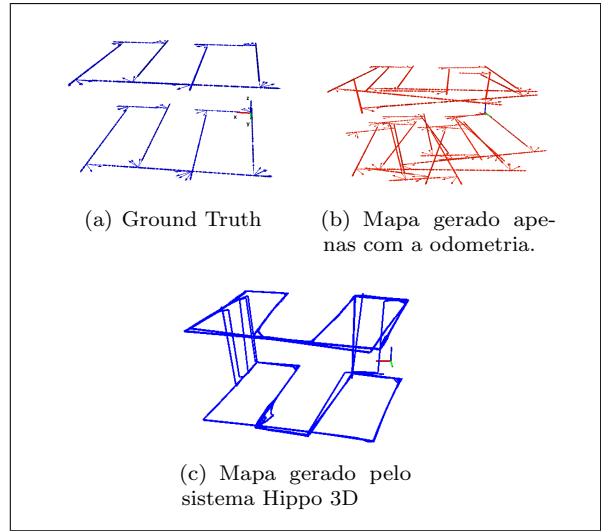


Figura 3: Resultados do Sistema Hippo 3D

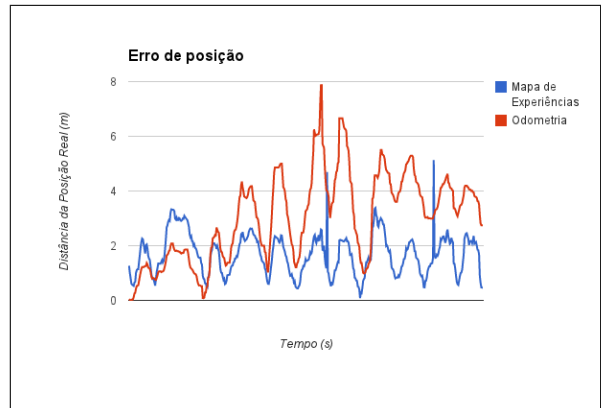


Figura 4: Erro de posição.

descobertas realizadas nos ratos. Este trabalho apresentou uma extensão desse sistema para ambientes 3D, chamado Hippo 3D.

O algoritmo foi testado em um ambiente simulado e teve sua habilidade em construir mapas tridimensionais de ambientes desconhecidos demonstrada. O sistema foi alimentado com informações visuais e de movimentação próprias. Atualmente estão sendo conduzidos experimentos com robôs reais para validar o sistema em ambientes complexos como o fundo do mar.

Como trabalhos futuros estão a completa paralelização do sistema e a utilização de algoritmos mais robustos para a correspondência de informações visuais, como o Bag of Words. Além disso pretendemos verificar a plausibilidade biológica do método Hippo 3D ao constatar a presença de *Place*, *Head Direction* e *Grid Cells* em mamíferos subaquáticos como golfinhos e baleias.

Referências

- Botelho, S., Drews-Jr, P., Figueiredo, M., Haffele, C. and Oliveira, G. (2009). Appearance-based odometry and mapping with feature descrip-

- tors for underwater robots, *Journal of the Brazilian Computer Society* **15**: 47–54.
- Glover, A., Maddern, W., Milford, M. and Wyeth, G. (2010). Fab-map + ratslam : appearance-based slam for multiple times of day, *2010 IEEE International Conference on Robotics and Automation (ICRA2010)*, IEEE, Egan Center, Anchorage, Alaska.
- Hafting, T., Fyhn, M., Molden, S., Moser, M.-B. and Moser, E. I. (2005). Microstructure of a spatial map in the entorhinal cortex, *Nature* **436**(7052): 801–6.
- Milford, M. (2008). *Robot Navigation from Nature - Simultaneous Localisation, Mapping, and Path Planning based on Hippocampal Models*, Vol. 41 of *Springer Tracts in Advanced Robotics*, Springer.
- Milford, M. and Wyeth, G. (2008). Mapping a suburb with a single camera using a biologically inspired slam system, *Robotics, IEEE Transactions on* **24**(5): 1038–1053.
- Milford, M., Wyeth, G. and Prasser, D. (2006). Ratslam on the edge : revealing a coherent representation from an overloaded rat brain, *IEEE/RSJ International Conference on Robotics and Systems 2006*, IEEE, Beijing, p. 4060.
- Moser, E. I., Kropff, E. and Moser, M.-B. (2008). Place cells, grid cells, and the brain’s spatial representation system, *Annual Review of Neuroscience* **31**(1): 69–89.
- Muller, R., Kubie, J. and Ranck, J. (1987). Spatial firing patterns of hippocampal complex-spike cells in a fixed environment, *The Journal of Neuroscience* **7**(7): 1935–1950.
- Muller, R. U., Ranck, J. B. and Taube, J. S. (1996). Head direction cells: properties and functional significance, *Current opinion in neurobiology* **6**(2): 196–206.
- O’Keefe, J. and Conway, D. H. (1978). Hippocampal place units in the freely moving rat: why they fire where they fire., *Experimental brain research. Experimentelle Hirnforschung. Expérimentation cérébrale* **31**(4): 573–590.
- O’Keefe, J. and Dostrovsky, J. (1971). The hippocampus as a spatial map. preliminary evidence from unit activity in the freely-moving rat, *Brain Research* **34**(1): 171–175.
- O’Keefe, J. and Speakman, A. (1987). Single unit activity in the rat hippocampus during a spatial memory task, *Experimental Brain Research* **68**: 1–27.
- Silveira, L., Guth, F., Figueiredo, M., Botelho, S. and Drews-Jr, P. (2012). Modelando head direction cells para estimativa de orientação idiótética de robôs móveis (in portuguese), *XIX Congresso Brasileiro de Automática (CBA)*, pp. 1–6.
- Stringer, S. M., Trappenberg, T. P., Rolls, E. T. and de Araujo, I. E. T. (2002). Self-organizing continuous attractor networks and path integration: two-dimensional models of place cells, *Network: Computation in Neural Systems* **13**(4): 429–446.
- Sünderhauf, N. and Protzel, P. (2010). Learning from nature: Biologically inspired robot navigation and slam - a review, *KI - Künstliche Intelligenz* **24**(3): 215–221.
- Thrun, S. (2002). Robotic mapping: A survey, in G. Lakemeyer and B. Nebel (eds), *Exploring Artificial Intelligence in the New Millenium*, Morgan Kaufmann, pp. 163–175.