

ARQUITETURA COGNITIVA PARA NAVEGAÇÃO EM LABIRINTOS

LUCIENE DE O. MARIN* MAURO ROISENBERG† EDSON R. DE PIERI*

**Departamento de Automação e Sistemas (DAS) – UFSC*

†*Laboratório de conexãoismo e ciências cognitivas (L3C)
Departamento de Informática e Estatística (INE) – UFSC*

Emails: luciene@das.ufsc.br, mauro@inf.ufsc.br, edson@das.ufsc.br

Abstract— This work presents a cognitive architecture to the navigation of an agent that simulates a mobile robot in mazes. Its construction is inspired by the theory of the cognitive maps and the rats behavior that delimit their environment with odor marks. The proposed architecture allows that reflexive and reactive behaviors act in a concomitant way with the exploration and navigation between specific places. A recurrent neural net ART classifies states of the environment together with the agent's internal state, making to emerge the simpler behaviors. The exploration behavior is guided by the recognition of external marks (bifurcations and blind alleys) and by the information of the attractiveness of the visited places. The agent doesn't has any information a priori of the environment. The cognitive map is built during the exploration phase and it allows that the agent efficiently performs paths between any two places of the maze. Computers simulations shown that the agent gets the latent learning of mazes, similar the rats behavior in ethology experiments.

Keywords— Navigation, Artificial Neural Networks, Cognitive Maps, Latent Learning.

Resumo— Este trabalho apresenta uma arquitetura cognitiva para a navegação de um agente que simula um robô móvel em labirintos. Sua construção inspira-se na teoria dos mapas cognitivos e no comportamento de ratos que delimitam seus ambientes com marcas de odor. A arquitetura proposta permite que comportamentos reflexivos e reativos atuem de maneira concomitante com os comportamentos de exploração e navegação entre lugares específicos. Uma rede neural ART recorrente classifica estados do ambiente juntamente com o estado interno do agente, fazendo emergir os comportamentos mais simples. O comportamento de exploração é guiado pelo reconhecimento de marcadores externos (bifurcações e becos sem saída) e pela informação da atratividade dos locais visitados. O agente não conta com nenhuma informação a priori do ambiente. O mapa cognitivo é construído durante a fase de exploração e permite que agente execute eficientemente caminhos entre quaisquer dois locais do labirinto. As simulações mostram que o agente adquire aprendizado latente dos labirintos, semelhante ao comportamento de ratos em experimentos etológicos.

Palavras-chave— Navegação, Redes Neurais Artificiais, Mapas Cognitivos, Aprendizado Latente.

1 Introdução

A tarefa de navegação para um robô móvel autônomo é complexa porque ela envolve sub-tarefas não triviais tais como fusão sensorial, auto-localização, construção de mapas e planejamento de caminho. Uma área de pesquisa recente e promissora chamada *robótica biologicamente inspirada* (Sharkey 2003) estuda os sistemas de navegação biológicos a fim de proporem modelos de navegação computacionais. Os trabalhos de (Trullier et al. 1997) e (Franz & Mallot 2000) revisam e classificam diversos destes modelos em diferentes níveis de complexidade.

Ratos são um dos animais mais estudados devido às suas habilidades de navegação cognitiva. Tolman (1932) introduziu a teoria dos mapas cognitivos ao afirmar que ratos respondem a estímulos com ações aprendidas e suas respectivas relações com o espaço. Mais tarde a descoberta de células hipocâmpais chamadas *place cells* (células que se ativam conforme a posição espacial) (O'Keefe & Nadel 1978) inspirou a construção de inúmeros modelos de navegação tais como os trabalhos de (Mataric 1990, Schmajuk & Thieme 1992, Schölkopf & Mallot 1995, Voicu & Schmajuk 2002a, Voicu & Schmajuk 2002b, Hafner 2005), que se

baseiam na construção de mapas cognitivos artificiais. Tais modelos são propostos em diferentes graus de simulações e, geralmente, nenhum deles é completo de forma a alcançar a flexibilidade e o desempenho da navegação de animais. Portanto a área de pesquisa em robótica biologicamente inspirada ainda está amplamente em aberto.

Este trabalho visa contribuir na construção de uma arquitetura cognitiva que também inspira-se na capacidade de navegação de ratos com o suporte da teoria dos mapas cognitivos e células hipocâmpais. Sua maior eficácia reside na integração de comportamentos reflexivos, reativos, de exploração e navegação, implementados sobre um sistema de redes neurais e mapeamento cognitivo. Ela controla a tarefa de navegação de um agente que simula um robô móvel em labirintos do tipo T, sem nenhum conhecimento a priori do ambiente. Os comportamentos reflexivos e reativos emergem de uma estrutura de rede neural ART recorrente em conjunto com redes diretas. O comportamento de exploração realiza a construção do mapa cognitivo e é guiado pelos valores de atratividade das direções alternativas de cada lugar visitado. Ao término de uma completa exploração do ambiente, o agente pode executar de maneira eficiente caminhos entre quaisquer lugares

de “Início” e “Objetivo” do labirinto. A definição de “lugar” compreende o local onde o agente tomará como informação êxtero-cêntrica (*allothetic*) os marcos que compreendem bifurcações e becos sem saída relacionando-os com sua informação egocêntrica (*idiothetic*) obtida pela técnica de integração de caminho (*path integration*). Sendo esta última aparentemente presente em animais (Golob & Taube 1999). Já a definição de caminho eficiente, implica que o agente não visitará qualquer lugar fora do percurso entre os locais de Início e Objetivo.

O restante deste artigo está organizado como segue: a seção 2 introduz o problema da navegação em labirintos, bem como as diferentes soluções presentes na literatura. A seção 3 mostra a construção da arquitetura cognitiva proposta e seus detalhes de implementação. A seção 4 expõe os resultados das simulações realizadas no software WSU Khepera, comparando o desempenho do agente em três diferentes labirintos. A seção 5 apresenta as conclusões e direções futuras desta pesquisa.

2 Navegação em labirintos

Labirintos com várias junções em “T” são utilizados em experimentos que visam responder questões sobre posição versus aprendizado de resposta e mapas cognitivos. O conceito de aprendizado latente (Tolman 1932) diz que ratos geram um mapa cognitivo do labirinto durante suas explorações mesmo que nenhuma recompensa lhes seja dada. Já o conceito de aprendizado de lugar afirma que ratos, quando colocados em labirintos com paredes externas transparentes aprendem que o objetivo está em um determinado lugar no espaço com relação a marcos externos. Esta é a principal forma de aprendizado na teoria dos mapas cognitivos. E o conceito do aprendizado de resposta assume que ratos podem aprender uma resposta particular para um labirinto, como ‘esquerda, direita, esquerda, esquerda, direita’, segundo a teoria do estímulo-resposta. Nesta teoria, ratos escolhem ir para esquerda ou direita dependendo de quais escolhas os levaram à comida em experiências anteriores. A comida como recompensa reforça as escolhas corretas. Experimentos mostram que se aos ratos são dadas muitas pistas externas (janelas, lâmpadas, relógio na parede) e eles executaram o labirinto poucas vezes, o aprendizado de lugar será mais utilizado. Entretanto, se as pistas externas foram poucas, e os ratos executaram o labirinto muitas vezes, eles usarão aprendizado de resposta, escolhendo de maneira consistente o mesmo caminho sem levar em consideração, por exemplo, a rotação do labirinto (Bures et al. 1998).

Ambientes do tipo labirinto são ótimas estruturas de teste para o desenvolvimento de estratégias de soluções em robótica móvel. O problema

da navegação de um robô em labirinto pode ser facilmente estendido para outros cenários, tais como planejar um movimento diante de obstáculos, procurar por vítimas em escombros, vistoriar tubulações de esgoto, entre outras.

De uma maneira clássica, a busca em labirinto é tratada pela teoria dos grafos e trabalhos sobre complexidade computacional (Lumelsky 1991), por algoritmos de roteamento (Jan et al. 2003), algoritmos clássicos de planejamento de caminho baseado em sensores (Noborio et al. 2000) e autômato de estados finitos (Martinengo et al. 1994).

As soluções baseadas em resultados biológicos observados não se preocupam tanto com aspectos de complexidade computacional e sim na construção de modelos de navegação biologicamente plausíveis, na tentativa de obterem o desempenho e a flexibilidade das estratégias de navegação biológicas. Por exemplo, Schmajuk & Thieme (1992) apresentaram uma abordagem de rede neural biologicamente plausível e de tempo real para comportamentos de mapeamento cognitivo. Seu mapa cognitivo é um mapa topológico que representa as adjacências e não direções entre lugares, bem como associações entre lugares e objetivos. Schölkopf & Mallot (1995) desenvolveram um mecanismo que aprende um mapa cognitivo de um labirinto hexagonal através de uma rede neural com aprendizagem não supervisionada. O mapa cognitivo é construído em forma de um grafo de “visões” durante a fase de exploração. Já o modelo de rede neural de navegação espacial de Voicu & Schmajuk (2002a) assume uma representação prévia do ambiente como um conjunto de localizações potencialmente conectadas. Eles definiram uma nova descrição para aprendizado latente em termos da competição entre exploração (*exploration*) e aproveitamento (*exploitation*). Em (Voicu & Schmajuk 2002b) o modelo anterior foi estendido para ambiente abertos.

A arquitetura cognitiva proposta neste trabalho utiliza-se do aprendizado auto-organizável de uma rede neural ART, baseada na teoria da ressonância adaptativa (Carpenter & Grossberg 1988), e da aprendizagem por reforço (Sutton & Barto 1998) para as redes neurais diretas de três camadas. Este aprendizado em tempo de operação faz emergir a execução dos comportamentos reflexivos¹ (evitar obstáculos) e reativos² (seguir corredores). Já a implementação do mapeamento cognitivo se faz através da detecção de lugares e suas respectivas informações direcionais, resultando o comportamento de explorar o ambiente por completo. Ao finalizar esta fase exploratória, o agente possuirá o comportamento de executar caminhos

¹Comportamentos cuja a ação emergente é função unicamente das entradas sensoriais.

²Comportamentos cuja a ação emergente depende não apenas das entradas sensoriais, mas também do estado interno do agente.

eficientes entre quaisquer localizações do labirinto.

3 A Arquitetura Cognitiva

A arquitetura cognitiva proposta é esquematizada na Figura 1. O módulo que se refere à rede ART reage aos estímulos externos e internos que são respectivamente o estado do ambiente e o estado interno do agente (recorrência). Este módulo aciona uma rede MLP para aprender ou fornecer a ação local correta a cada passo de controle. Esta

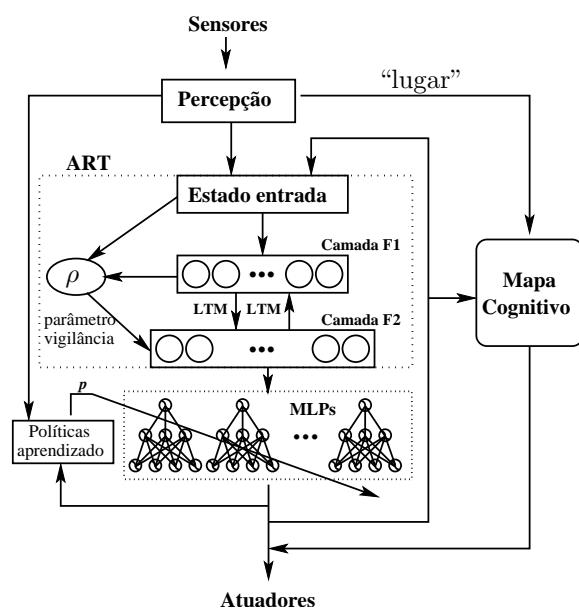


Figura 1: A arquitetura cognitiva.

parte da arquitetura atua quando o agente segue os corredores, evitando obstáculos. Já no processo de mapeamento cognitivo também se utiliza da percepção e do estado interno do agente, atuando no momento em que o agente alcança um lugar propriamente dito. A seguir, cada módulo da arquitetura cognitiva será explicado com maiores detalhes.

O módulo **Percepção** recebe dados dos sensores de proximidade e provê a informação da presença ou não de obstáculos nas quatro direções (oeste, norte, leste e sul). Esta informação é fornecida às porções reativa (Rede ART) e reflexiva (políticas de aprendizado das redes MLPs). Este módulo também detecta os lugares (bifurcações e becos sem saída), desviando o controle para os processos de exploração/execução de caminho. Assim que o agente deixa um determinado “lugar”, o controle novamente é passado para a parte reativa/reflexiva da arquitetura.

Os módulos que compreendem a rede **ART** e as redes **MLPs** implementam os comportamentos reativo e reflexivo respectivamente. O aprendizado auto-supervisionado da rede neural ART é capaz de resolver o *dilema da elasticidade e plasticidade* - continuar aprendendo sem esquecer o

conhecimento adquirido anteriormente. Ela discrimina diferentes categorias de ações conforme a situação do ambiente e o estado interno do agente. O estado interno consiste da informação da ação tomada pelo agente no passo anterior. A saída da rede que fornece o índice do neurônio vencedor na camada F2 dispara a criação de redes multicamada de perceptrons (MLP) que irão, através da aprendizagem por reforço, fornecer a ação correta aos atuadores. As políticas de aprendizado desempenham o papel de punir as redes diretas, pela alteração aleatória de um de seus pesos, sempre que as mesmas fornecerem ações incorretas, por exemplo, ir contra a parede, andar para trás. Portanto, o comportamento reativo emergente é seguir corredores. Experimentos que mostram o aprendizado de trajetórias de um agente implementado somente com estes módulos da arquitetura podem ser vistos em (Marin et al. 2006).

O módulo **Mapa Cognitivo** realiza o mapeamento do ambiente durante a fase de exploração. Ao final da exploração, o mapa cognitivo compreenderá a representação espacial do labirinto definida por um grafo dirigido. Os nós do grafo representam os lugares e as arestas representam as ligações entre eles, bem como a informação direcional origem-destino. O mapa cognitivo é construído com o auxílio da informação de atratividade das direções que guia o comportamento de exploração. Ao detectar bifurcações e becos sem saída, o agente marca estes “lugares”, simulando o comportamento de um rato que deixa marcas de odor (Bures et al. 1998) em localidades onde encontra pistas salientes no labirinto e em seguida os relaciona e os armazena em seu mapa cognitivo biológico (Tolman 1932, O’Keefe & Nadel 1978).

Lugares são definidos como bifurcações e becos sem saída pois estas configurações do ambiente são consideradas nesta implementação como marcos externos (informação êxtero-cêntrica). Ao detectar uma bifurcação ou beco sem saída, o agente define um “lugar” armazenando sua posição espacial obtida através da técnica de integração de caminho. O lugar identificado é então definido como um nó no mapa cognitivo, a fim de ser reconhecido a posteriori.

Durante a fase de exploração, o agente não possui nenhum conhecimento prévio do ambiente. Ao identificar um novo lugar, ele estabelece como valor 1 a atratividade de cada direção alternativa. Ao deixar este lugar (pela direção de atratividade mais forte), ele decrementa de 0,1 o valor de sua atração. Quando os valores de atratividade das direções alternativas são iguais, o agente segue as seguintes prioridades: Oeste, Norte, Leste e Sul. Estas prioridades definem o padrão de movimentos que permitem uma exploração completa do ambiente e seu respectivo mapeamento cognitivo.

A execução de caminhos eficientes se inicia ao término da fase de exploração. A propriedade de

aprendizado latente do agente é descrita pelo comportamento de executar caminhos eficientes entre quaisquer dois pares de lugar Início e Objetivo no labirinto. A execução do caminho se dá através da transposição do mapa cognitivo em uma árvore binária tendo por raiz o lugar Objetivo. Um algoritmo em pré-ordem percorre a árvore, obtendo do mapa cognitivo a informação das direções referentes a cada par de lugares origem-destino (nós pai - filho). Elas são transferidas para os valores de atratividade das direções, a fim de guiar o agente nas escolhas de ações que levam ao lugar Objetivo. Portanto o caminho eficiente consiste da composição dos sub-caminhos tomados seguindo a hierarquia da árvore no sentido “*bottom-up*”.

4 Simulações

As simulações foram realizadas no software *WSU Khepera Robot*³ que reproduz o controle de um robô Khepera (Mondada et al. 1993) que conta somente com seus sensores de proximidade. Os resultados comparam o desempenho da arquitetura cognitiva em três labirintos do tipo T, mostrados na Figura 2. O robô foi colocado nos labirintos a), b) e c) e foram computados o número de passos durante a fase de exploração e a quantia de mapeamentos estado-ação da rede ART com relação às complexidades dos labirintos. A partir dos dados mostrados na Tab. 1, conclui-se que o agente leva mais tempo para realizar a exploração no labirinto de maior complexidade, c). Esta com-

Lab.	Exploração	Map. estado-ação	Nº de lugares	Nº de curvas
a)	987	27	14	0
b)	1256	33	12	2
c)	1425	30	14	4

Tabela 1: Análise de desempenhos da fase de exploração dos labirintos a), b) e c) da Figura 2.

plexidade está relacionada ao número de curvas, bifurcações, becos sem saída e ao tamanho de cada labirinto. A quantia de mapeamentos estado-ação de uma maneira geral implica nas diferentes percepções do ambiente que estão sujeitas aos ruídos dos sensores e às variações quanto ao comprimento e largura dos corredores. Para os três labirintos analisados estes valores são próximos devido às suas semelhanças quanto ao número de lugares e tamanho.

Um exemplo de mapeamento de estado-ação é mostrado na Figura 3, durante a execução de

³O simulador *WSU Khepera Robot*, desenvolvido pela *Wright State University* e *Ohio Board of Regents*. Seu uso é dirigido pela Licença Pública da KSM versão 1.0. O código fonte, documentação, e o texto da licença encontram-se juntos com esta versão do programa. Na falta desta, uma distribuição completa pode ser obtida em: <http://gozer.cs.wright.edu/ksim/ksim/html>. A versão 7.2 foi liberada em 6 de julho de 2004

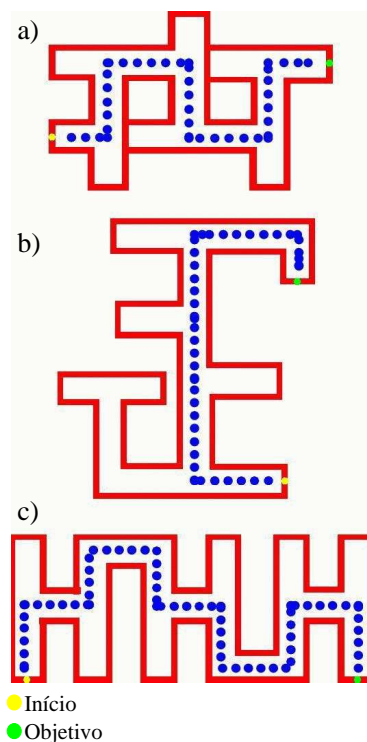


Figura 2: Os labirintos analisados e os respectivos caminhos executados pelo agente entre os lugares Início e Objetivo.

um caminho eficiente no labirinto c) da Figura 2. Os círculos em cores ilustram as diferentes categorias de ações para cada estado de entrada da rede ART, enquanto o agente realiza a navegação do local de Início ao local Objetivo. Quando o agente




Figura 3: Mapeamento de Estado-Ação para o labirinto c) da Figura 2 durante a fase de execução do caminho eficiente entre Início e Objetivo.

percorre um corredor, por exemplo, a ação a ser realizada será a mesma durante todo o percurso naquela direção (círculos com cores iguais). Assim que os sensores detectam mudanças quanto aos obstáculos no ambiente, um novo neurônio vencedor da camada F2 da rede ART é ativado, disparando outra rede MLP para determinar a ação correta.

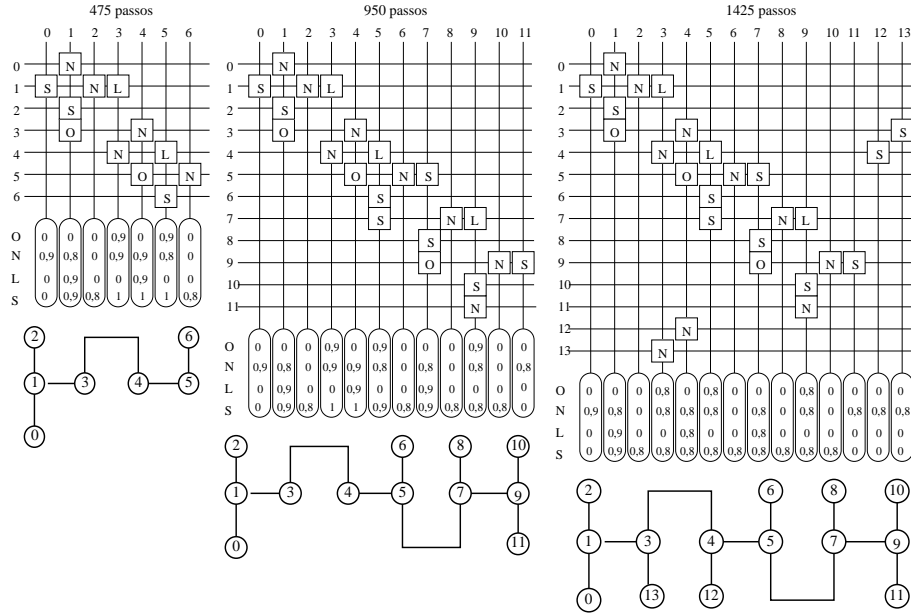


Figura 4: Mapa Cognitivo do Labirinto c) da Figura 2 durante a Fase de Exploração.

A evolução da construção do mapa cognitivo do labirinto c) da Figura 2 é exemplificada na Figura 4. Ao completar-se 475 passos, os lugares já visitados pelo agente são ao total de 7 (numerados de 0 a 6). Os quatro pesos relacionados ao lugar representam o valor da atratividade nas direções oeste, norte, leste e sul respectivamente. De início, todos os pesos nas direções onde não há presença de obstáculos valem 1. Quando ocorrem pesos iguais a prioridade segue oeste, norte, leste e sul. O valor de atratividade de uma direção é decrementado de 0,1 assim que o agente a seleciona, com relação ao lugar em que se localiza. Por exemplo, completados 475 passos, o lugar 3 (bifurcação) possui os pesos (0,9 0,9 0,0 1,0) indicando que o agente chegou nele pela direção oeste (0,9) e partiu pela direção norte (0,9). A seguir, executados 950 passos da exploração, o agente agora tem 12 lugares visitados até momento. O lugar 5 então com os pesos (0,9 0,8 0,0 0,9) descreve que o agente visitou um beco sem saída ao norte (0,8), e tomou a direção ao sul (0,9) na última vez que visitou este lugar e da próxima vez tomará a direção à oeste. Em 1425 passos, no caso de visitar novamente o lugar 3, o agente será atraído a seguir pela direção sul, ainda não selecionada, e então descobrirá o lugar 13.

A Figura 5 exemplifica a execução de caminho e a leitura do mapa cognitivo do Labirinto c) da Figura 2. O agente executa o caminho eficiente entre os lugares Início e Objetivo através da transposição do mapa cognitivo para uma árvore binária, onde a raiz é o lugar Objetivo (nó 11). O algoritmo em pré-ordem, à medida que percorre a árvore, lê no mapa cognitivo a informação de cada aresta que liga o par de lugares pai - filho (origem - destino). Este valor é transferido para




Figura 5: Execução do caminho eficiente entre os lugares 0 e 11 do labirinto c) da Figura 2.

a atratividade das direções que guiará o agente na escolha das ações que devem ser tomadas em cada bifurcação para se alcançar o lugar Objetivo pelo caminho mais eficiente. As trajetórias executadas durante a fase de execução de caminho, para os três labirintos analisados, são mostradas na Figura 2.

5 Conclusão e Direções Futuras

Este trabalho apresentou uma arquitetura cognitiva, com propriedades de aprendizado latente, para navegação de um agente em labirintos. Sua porção reflexiva e reativa, juntamente com a estratégia de exploração permitem a criação de um mapeamento cognitivo do ambiente. Nenhuma informação a priori é fornecida e locais como bifurcações e becos sem saída servem de marcos para o agente identificar o local e armazenar relações espaciais em seu mapa cognitivo à medida que ex-

plora o labirinto. Foram computados os desempenhos com relação à fase de exploração e os resultados das simulações mostram que o agente é capaz de executar caminhos eficientes entre quaisquer locais de origem e objetivo.

Trabalhos futuros serão dirigidos ao problema de desvios e atalhos, e às mudanças no ambiente durante o tempo de operação do agente. Conceitos de computação neuro-etológica serão implementados para tornar a arquitetura cognitiva proposta o quão biologicamente plausível possível. Comparações com outras técnicas possíveis de serem aplicadas ao problema serão testadas na seqüência do trabalho. Comparações de desempenho, tempo de execução e falhas permitirão estabelecer as vantagens e desvantagens da técnica proposta.

Referências

- Bures, J., Fenton, A. A., Kaminsky, Y., Wesierska, M. & Zahalka, A. (1998). Rodent navigation after dissociation of the allocentric and idiothetic representations of space, *Neuropharmacology, Elsevier Science Ltd.* **37**: 689–699.
- Carpenter, G. A. & Grossberg, S. (1988). The ART of adaptive pattern recognition self-organizing by a neural network, *IEEE Computer* **21**(3): 77–88.
- Franz, M. O. & Mallot, H. A. (2000). Biomimetic robot navigation, *Robotics and Autonomous Systems* **30**: 133–153.
- Golob, E. J. & Taube, J. S. (1999). Head direction cells in rats with hippocampal or overlying neocortical lesions: evidence for impaired angular path integration, *Journal of Neuroscience* **19**(7): 198–211.
- Hafner, V. V. (2005). Cognitive maps in rats and robots, *Adaptive Behavior* **13**(2): 87–96.
- Jan, G. E., Chang, K.-Y. & Parberry, I. (2003). A new maze routing approach for path planning of a mobile robot, *Proceedings of the 2003 IEEE/ASME International Conference on Advanced Intelligency Mechatronics (AIM 2003)* pp. 552–557.
- Lumelsky, V. J. (1991). A comparative study on the path length performance of maze-searching and robot motion planning algorithms, *IEEE Transactions on Robotics And Automation* **7**(1): 57–66.
- Marin, L. O., Roisenberg, M. & Pieri, E. R. D. (2006). A neural architecture for online path learning in maze navigation, *8th International IFAC Symposium on Robot Control SY-ROCO 2006*, Bologna, Italy.
- Martinengo, A., Campmi, M. & Torre, V. (1994). Artificial systems and complex behaviours, *Intelligent Robots and Systems. Advanced Robotic Systems and the Real World, IROS'94. Proceedings of the IEEE/RSJ/GI International Conference on* **1**: 194–201.
- Mataric, M. J. (1990). Navigating with a rat brain: Neurobiologically-inspired model for robot spatial representation, *From Animals to Animals 1: Proceedings of the first International Conference on Simulation of Adaptive Behaviour* pp. 169–175. Bradford Books, Cambridge, MA.
- Mondada, F., E. Franz & Lenne, P. (1993). Mobile robot miniaturization: a tool for investigation in control algorithms, *Int. Symposium on Experimental Robotics. Kyoto, Japan*.
- Noborio, H., Fujimura, K. & Horiuchi, Y. (2000). A comparative study of sensor-based path-planning algorithms in an unknown maze, *Proceedings of the 2000 IEEE,RSJ. International Conference on Intelligent Robots and Systems* pp. 9009–9016.
- O'Keefe, J. & Nadel, L. (1978). *The hippocampus as a cognitive map*, Oxford University Press.
- Schölkopf, B. & Mallot, H. A. (1995). View-based cognitive mapping and path planning, *Adaptive Behavior* **3**(3): 311–348.
- Schmajuk, N. A. & Thieme, A. D. (1992). Purposive behavior and cognitive mapping: An adaptive neural network, *Biol. Cybern.* **67**: 165–174.
- Sharkey, N. E. (2003). *The Handbook of Brain Theory and Neural Networks*, Michael A. Arbib, MIT Press, chapter “Biologically Inspired Robotics”, pp. 160–164.
- Sutton, R. S. & Barto, A. G. (1998). *Reinforcement Learning: An Introduction*, MIT Press, Cambridge, MA.
- Tolman, E. C. (1932). Cognitive maps in rats and men, *Psychol. Rev.* **55**: 189–208.
- Trullier, O., Wiener, S. I., Berthoz, A. & Meyer, J.-A. (1997). Biologically based artificial navigation systems: review and prospects, *Progress in Neurobiology. Elsevier Science Ltd* **51**: 483–544.
- Voicu, H. & Schmajuk, N. A. (2002a). Exploration, navigation and cognitive mapping, *Adapt. Behav.* **8**: 207–223.
- Voicu, H. & Schmajuk, N. A. (2002b). Latent learning, shortcuts and detours: a computational model, *Behavioural Processes* **1**(59): 67–86.