

# Sistemas Autônomos Inteligentes em Navegação de Robôs: Aquisição de Conceitos Espaciais e Discriminação de Objetos

Eric Aislan Antonelo<sup>1</sup>, Mauricio Figueiredo<sup>2</sup>

<sup>1</sup> Departamento de Automação e Sistemas – Universidade Federal de Santa Catarina  
88040-900 – Florianópolis – SC

<sup>2</sup> Departamento de Informática – Universidade Estadual de Maringá  
87020-900 – Maringá – PR

eric@das.ufsc.br, mauricio@din.uem.br

***Abstract.** In this work, it is proposed an autonomous system capable of constructing its navigation strategy for mobile robots coherently with the acquired environmental knowledge: spatial proximity concept and color patterns associated to each type of object. The autonomous system, based on neural networks, doesn't have innate behaviors of target seeking or obstacle avoidance, but it learns these specific behaviors for each type of object as the robot interacts with the environment. Simulation results are showed and confirm the system's potenciality, as well as its generalization capacity.*

***Resumo.** Neste trabalho, propõe-se um sistema autônomo capaz de construir sua estratégia de navegação para robôs móveis coerentemente com o conhecimento adquirido sobre o ambiente: conceitos espaciais (de proximidade) e padrões de cores associados a cada tipo de objeto. O sistema autônomo, baseado em redes neurais, não apresenta comportamentos instintivos de desvio de obstáculos ou de busca de alvos, mas aprende tais comportamentos específicos para cada tipo de objeto à medida que interage com o ambiente. Resultados de simulação são apresentados confirmando suas potencialidades, bem como evidenciando sua capacidade de generalização.*

## 1. Introdução

De uma forma geral, é possível entender a navegação de robôs móveis como o problema de determinação de trajetórias, proporcionando condições para que tarefas (objetivos) sejam executadas com desempenho aceitável. Sistemas de navegação vêm sendo pesquisados segundo diversas vertentes, dependendo das características do ambiente e do robô, bem como do tipo de tarefa e do desempenho exigido [Figueiredo 1999].

Uma das vertentes tem cativado a comunidade científica não só pelo desafio, mas também pela importância estratégica, a saber, a navegação autônoma, ou seja, aquela em que o sistema de navegação determina sem auxílio externo a trajetória do robô em um ambiente desconhecido. Neste contexto, os sistemas de navegação devem exibir características autônomas, sendo capazes de aprender sua própria estratégia de navegação a partir de interações (experiências) com o ambiente [Figueiredo 1999].

A navegação autônoma de robôs impõe dificuldades severas às técnicas tradicionais de engenharia de controle pela falta de um modelo de ambiente adequado. Estratégias baseadas em técnicas de Inteligência Artificial vêm se difundindo como uma alternativa viável, e.g. redes neurais e sistemas evolutivos. Resultados importantes têm sido alcançados, passando a estimular, inclusive, a pesquisa sob o ponto de vista dos sistemas autônomos inteligentes.

É intrínseco às redes neurais seu potencial para a aprendizagem, tornando-as muito atraentes em projetos de sistemas de navegação autônoma. Em [Vershure 1998], [Crestani 2002] e [Calvo 2003], a abordagem baseada em comportamento é associada à teoria da aprendizagem por reforço (clássica). Dois repertórios reproduzem comportamentos instintivos, a saber, busca-de-alvo e desvio-de-obstáculo. A partir dos respectivos reflexos instintivos, as redes se ajustam de forma a construir suas estratégias de navegação, combinando e coordenando os comportamentos instintivos. A arquitetura proposta em [Millan 1996] desconsidera a abordagem baseada em comportamento, mas mantém a aprendizagem por reforço. Experimentos demonstram que o sistema aprende a aperfeiçoar a trajetória do robô.

De forma distinta, o sistema proposto em [Cazangi 2002] não espelha uma arquitetura baseada em comportamento, ou seja, não há comportamentos instintivos a priori. A aprendizagem por reforço clássica é integrada a arquitetura de um sistema classificador. O sistema evolutivo aprende simultaneamente os comportamentos desvio-de-obstáculo e busca-de-alvo, além de aprender a coordená-los.

O sistema de navegação autônoma proposto se destaca por dois aspectos principais (tomando como base a maioria das propostas na literatura): a partir de estímulos captados por um único campo sensorial, o sistema aprende a discriminar objetos pertencentes a diferentes classes (o robô não possui campos sensoriais específicos e distintos para alvos e obstáculos); e características dinâmicas dos modelos de neurônios adotados proporcionam ao sistema aprender conceitos espaciais, gerando uma estratégia de navegação capaz de priorizar alvos mais próximos no traçado de trajetórias (diante da possibilidade do campo sensorial ter captado simultaneamente dois alvos). O sistema de navegação corresponde a uma rede neural que aprende por reforço (teoria clássica). Além de modelos de neurônios inovadores, a arquitetura também se diferencia pelo seu padrão de conexões. Experimentos de simulação consideram ambientes gerais com objetos de múltiplas classes (atrativos e repulsivos).

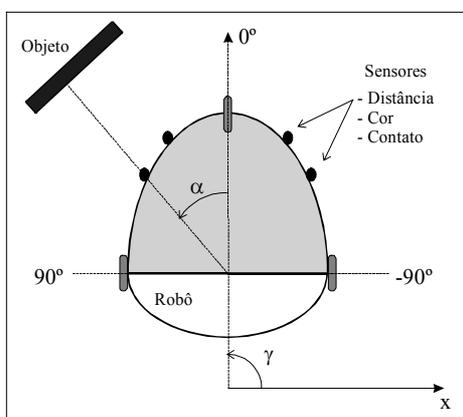
Este artigo é organizado da maneira como segue. A Seção 2 descreve o modelo de robô utilizado bem como o ambiente com o qual o robô interage. O sistema autônomo de navegação proposto é descrito na Seção 3. Resultados de simulação são analisados na Seção 4. A Seção 5 corresponde a uma breve discussão sobre as características e potencialidades do sistema proposto.

## **2. Modelos do Ambiente e do Robô**

O robô explora um ambiente em que estão presentes tanto objetos repulsivos quanto objetos atrativos. Cada objeto se diferencia dos demais pela sua cor, captada por um campo sensorial específico (por exemplo, objetos repulsivos podem exibir a cor azul e objetos atrativos, a cor verde). Objetos repulsivos também são obstáculos. Sempre que

um robô atinge um objeto atrativo (um possível alvo), este objeto deixa de fazer parte do ambiente.

O modelo de robô é apresentado na Figura 1. O robô interage com o ambiente por meio de sensores de distância, cor e contato; e por seu único atuador que controla a direção de movimento. Os sensores estão dispostos em 67 posições predefinidas à frente do robô, distribuindo-se no intervalo de  $-90^\circ$  a  $90^\circ$ . Assim, existem três sensores distintos para cada uma das 67 posições pré-determinadas do robô. Cada sensor provê uma informação específica com relação ao objeto situado mais próximo do robô na direção do sensor (ângulo  $\alpha$ ). Cada sensor de distância capta a distância entre o robô e o objeto mais próximo, assumindo valores no intervalo  $[0,1]$  (valores próximos a zero indicam distâncias menores que valores próximos a um). Um sensor de cor assume valores no intervalo  $[0,1]$ , resultante da normalização da componente “Hue” do sistema HSV-(Hue, Saturation, Value). Os sensores de contato detectam momentos quando o robô atinge qualquer objeto (atrativos ou repulsivos).



**Figura 1. Modelo do robô**

A velocidade do robô é constante durante a navegação (0,35 unidades de distância por iteração). O veículo é capaz de executar manobras de no máximo  $15^\circ$  a cada iteração.

### **3. Sistema Autônomo de Navegação**

#### **3.1. Introdução**

Sistemas nervosos biológicos comportam mecanismos inatos ou instintivos (e.g., reflexos de recuo e captura; e sensações de fome e medo) para suporte à emergência de comportamentos específicos adquiridos a partir de interações com o ambiente [Kandell 1991] e [Donahoe 1994]. Comportamentos inatos são essenciais para a integridade e desenvolvimento do animal, sendo quase exclusivos logo após o nascimento. Não estão associados a experiências particulares estabelecidas com o ambiente, porém são necessários na formação de comportamentos particulares importantes para a adaptação junto ao ambiente.

Tomando-se como referência os sistemas biológicos, os comportamentos inatos (pré-incorporados) detêm uma função igualmente preponderante em sistemas

autônomos inteligentes [Edelman 1987]. Sob esta justificativa, o projeto do sistema proposto é norteado tanto no que se refere à aprendizagem quanto à arquitetura.

### 3.2. Arquitetura

O sistema autônomo inteligente corresponde a uma rede neural organizada em três camadas (Figura 2). Na primeira camada, há dois repertórios neurais, repertório Identificador de Proximidade (IP) e repertório Identificador de Cor (IC), os quais recebem os estímulos provenientes dos campos sensoriais de distância e cor, respectivamente, além do campo sensorial de contato. Da mesma forma, a segunda camada compreende dois repertórios neurais: atração (RA) e repulsão (RR). Cada qual estabelece conexões com ambas as redes da primeira camada, além do campo sensorial de contato.

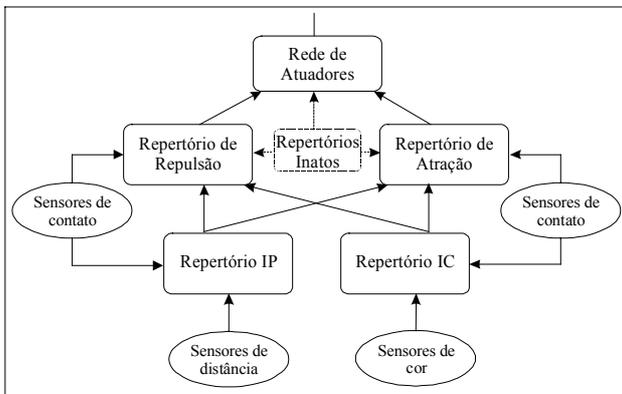


Figura 2. Arquitetura do sistema autônomo

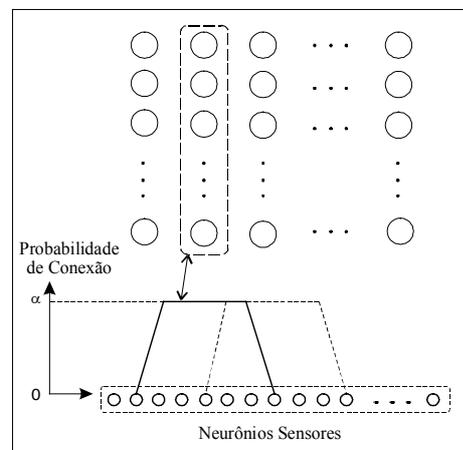


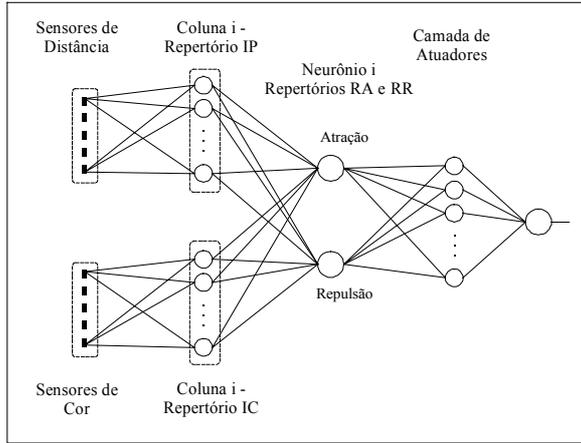
Figura 3. Arquitetura de IP e IC

A rede de atuadores (RT), conectada aos repertórios RA e RR, determina o ajuste na direção de movimento do robô. A aprendizagem do sistema se desenvolve segundo a teoria de aprendizagem por reforço clássica, com base nas atividades dos repertórios inatos.

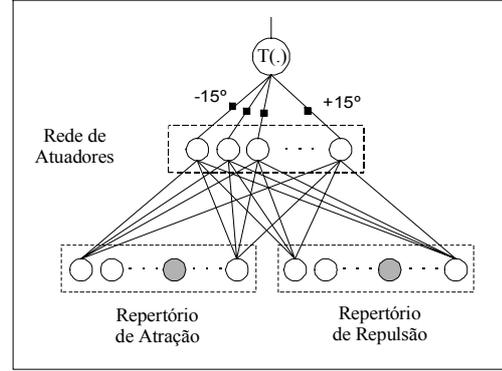
*Repertórios IP e IC:* A arquitetura da rede neural que compõe cada repertório é tal qual apresentada na (Figura 3). Cada coluna de neurônios está assentada topologicamente em uma estrutura unidimensional, ou seja, não existe comprometimento espacial entre neurônios de diferentes colunas. Os neurônios de cada coluna estabelecem conexões com neurônios sensores segundo uma distribuição de probabilidades específica. (Figura 3).

Para efeitos didáticos, considere que as redes apresentem iguais números de colunas ( $q$ ) e de neurônios em cada coluna ( $l$ ).

*Repertórios RA e RR:* Cada rede neural, RA ou RR, é formada por uma única camada de neurônios. O número de neurônios em cada rede corresponde ao número de colunas presentes nas redes IP ou IC. Cada neurônio desta camada se conecta com a respectiva coluna da rede IP e da rede IC (Figura 4).



**Figura 4. Visão parcial da arquitetura**



**Figura 5. Rede de atuadores**

*Rede de Atuadores:* Há duas camadas na rede de atuadores. A cada neurônio da primeira camada está associado um possível valor de ajuste na direção de movimento. Cada neurônio recebe estímulos dos neurônios das redes RA e RR, estando conectado também ao único neurônio da camada de saída (Figura 5). Os repertórios inatos estão conectados ao campo sensorial de contato (não mostrado na Figura 1 para favorecimento da clareza).

### 3.3. Raciocínio

Há diversos tipos de modelos de neurônios adotados na concepção do sistema autônomo inteligente, distribuídos conforme os repertórios a que pertencem.

*Repertórios IP e IC:* A saída do  $j$ -ésimo neurônio da  $k$ -ésima coluna do repertório IP, na iteração  $n$ , é definida pela Equação 1:

$$y_j^k(n) = \begin{cases} u_j^k(n) & \text{se } j = i^k(\mathbf{x}^k(n)) \\ 0 & \text{se } j \neq i^k(\mathbf{x}^k(n)), \end{cases} \quad (1)$$

em que:  $i^k(\mathbf{x}^k(n))$  é o neurônio vencedor;  $\mathbf{x}^k(n) = [x_1, x_2, \dots, x_m]^T$  é o vetor de entradas (distâncias a objetos);  $u_j^k(n)$  é um parâmetro (memória interna definido em seção posterior); e  $k = 1, 2, \dots, q$  ( $q$ : número de colunas). O neurônio vencedor  $i^k(\mathbf{x}^k(n))$  é definido por:

$$i^k(\mathbf{x}^k(n)) = \arg \min_j \|\mathbf{x}^k(n) - \mathbf{w}_j^k(n)\|, \quad j = 1, 2, \dots, l, \quad (2)$$

em que:  $\mathbf{w}_j^k(n)$  é o vetor de pesos sinápticos e  $l$  é o número de neurônios em cada coluna.

Além de  $u_j^k(n)$ , cada neurônio exibe outro parâmetro interno. Trata-se do grau de atividade  $e_j^k(n)$ , definido por:

$$e_j^k(n+1) = \begin{cases} e_j^k(n) + \phi e_j^k(n) & \text{se } j = i^k(\mathbf{x}^k(n)) \\ e_j^k(n) - \sigma e_j^k(n) & \text{se } j \neq i^k(\mathbf{x}^k(n)), \end{cases} \quad (3)$$

em que:  $\phi$  é o fator de ganho e  $\sigma$  é o fator de perda.

A Equação 4 define a saída do  $j$ -ésimo neurônio da  $k$ -ésima coluna do repertório IC:

$$y_j^k(n) = \begin{cases} 1 & \text{se } j = i^k(\mathbf{x}^k(n)) \\ 0 & \text{se } j \neq i^k(\mathbf{x}^k(n)), \end{cases} \quad (4)$$

em que  $i^k(\mathbf{x}^k(n))$  é definido de forma análoga à Equação 2.

*Repertórios RA e RR:* A saída do  $j$ -ésimo neurônio tanto do repertório RA quanto do repertório RR é dada por:

$$y_j(n) = \begin{cases} 0 & \text{se } s_j \leq \phi \\ \alpha(s_j - \phi) & \text{se } \phi < s_j < (\phi + 1/\alpha) \\ 1 & \text{se } s_j \geq (\phi + 1/\alpha), \end{cases} \quad (5)$$

em que:  $s_j = \mathbf{x}_j(n) \cdot \mathbf{w}_j(n)$  é o produto escalar entre o vetor de entradas e o vetor de pesos sinápticos;  $\alpha$  e  $\phi$  são constantes; e  $j = 1, 2, \dots, q$  ( $q$ : número de neurônios da rede neural).

*Rede de Atuadores:* A saída do  $j$ -ésimo neurônio da primeira camada da rede de atuadores é dada por:

$$y_j(n) = g\left(\sum_{i=1}^{2q} x_{ji}(n)w_{ji}\right), \quad (6)$$

em que:  $g(\cdot)$  é a função hiperbólica (na simulação, o parâmetro “inclinação” é 2.5). Observe que existem  $2q$  entradas correspondentes ao total de  $2q$  neurônios das redes RA e RR.

A saída da rede de atuadores tem a seguinte expressão:

$$y = \sum_{j=1}^r w_j \bar{x}_j, \quad \text{para } \bar{x}_j = x_j / \sum_{p=1}^r x_p \quad \text{e} \quad w_j = 15(2j - r) / r, \quad (7)$$

em que:  $r$  é o número de neurônios da primeira camada ( $w_j$  constante é igual a algum valor no intervalo de ajuste da direção de movimento  $[-15, 15]$ ).

### 3.4. Aprendizagem

A estratégia de aprendizagem por reforço (clássica) é bem caracterizada pelo fato de ser dirigida pelo disparo de comportamentos inatos (tal como ocorre em sistemas biológicos [Donahoe 1994]). Sempre quando ocorre algum contato com objetos, o repertório inato dispara um dos comportamento inatos (atração ou repulsão), além de iniciar o processo de aprendizagem. Os mecanismos de aprendizagem, que tratam dos ajustes nos pesos sinápticos, são específicos para cada repertório neural, sendo descritos em seguida.

*Repertórios IP e IC:* O contato entre o robô e objetos é detectado por um dos sensores de seu campo sensorial de contato. O estímulo correspondente define uma única coluna nas redes IC e IP (considere a  $k$ -ésima coluna,) em que o ajuste dos pesos sinápticos ocorre (existe uma correspondência espacial entre colunas destas redes e a posição de sensores de contato).

Para efeitos de modelar o mecanismo de ajuste sináptico no repertório IP, considere os procedimentos:

1- Competição por Similaridade: calcule o neurônio vencedor  $i(n)$  dado por:

$$i(n) = \arg \min_j \|\mathbf{x}(n) - \mathbf{w}_j(n)\|, \quad j = 1, 2, \dots, l. \quad (8)$$

2- Atualização:

i) Ajuste os vetores de pesos sinápticos de todos neurônios usando a seguinte fórmula:

$$\mathbf{w}_j(n+1) = \mathbf{w}_j(n) + \eta h(i(n), j)(\mathbf{x}(n) - \mathbf{w}_j(n)), \quad (9)$$

em que:  $\eta$  é a taxa de aprendizagem, e  $h(i(n), j) = \exp(-(i(n) - j)^2 / l)$  é a função de vizinhança;

ii) Ajuste os seguintes parâmetros para  $j = 1, 2, \dots, l$ :

$$\begin{aligned} u_j(n+1) &= u_j(n) + \eta h(i(n), j)(1 - u_j(n))e_j(n)/3 \\ e_j(n+1) &= 1. \end{aligned} \quad (10)$$

O parâmetro  $u_j(n)$  é utilizado no modelo de raciocínio do neurônio. O parâmetro  $e_j(n)$  também é ajustado no raciocínio (a cada iteração  $n$ ).

O algoritmo de aprendizagem para o repertório IC é apresentado a seguir:

1- Competição por Similaridade: calcule o neurônio vencedor  $i(n)$  dado por:

$$\begin{aligned} i(n) &= \arg \min_j \|\mathbf{x}(n) - \mathbf{w}_j(n)\|, \\ j &\in \{k / k \in \{1, 2, \dots, l\} \text{ e } \|\mathbf{x}(n) - \mathbf{w}_k(n)\| < m_k(n)\}. \end{aligned} \quad (11)$$

2- Atualização: Ajuste o vetor de pesos sinápticos e a memória de desempenho:

$$\begin{aligned} \mathbf{w}_{i(n)}(n+1) &= \mathbf{w}_{i(n)}(n) + \eta(\mathbf{x}(n) - \mathbf{w}_{i(n)}(n)) \\ m_{i(n)}(n) &= \|\mathbf{x}(n) - \mathbf{w}_{i(n)}(n)\|, \end{aligned} \quad (12)$$

em que  $\eta$  é a taxa de aprendizagem.

*Repertórios RA e RR:* Os pesos sinápticos do  $j$ -ésimo neurônio (RA ou RR) correspondentes às entradas conectadas ao repertório IP são todos unitários (constantes). Diferentemente, os pesos sinápticos correspondentes às entradas conectadas ao repertório IC são ajustáveis.

Considere que neurônios da  $k$ -ésima coluna do repertório IC tenham ajustado seus pesos sinápticos. O mecanismo de aprendizagem atua sobre o  $k$ -ésimo neurônio da

rede RA, se o comportamento inato disparado for de atração. Caso contrário, no  $k$ -ésimo neurônio do repertório RR.

O ajuste dos pesos sinápticos é tal como na expressão da Equação 13:

$$\mathbf{w}_k(n+1) = \mathbf{w}_k(n) + \eta \mathbf{x}(n)(1 - \mathbf{w}_k(n)), \quad (13)$$

em que  $\eta$  é a taxa de aprendizagem.

*Rede de Atuadores:* Apenas os pesos sinápticos da primeira camada da rede de atuadores são ajustados. O repertório inato reproduz algum dos comportamentos inatos (atração ou repulsão) quando ocorre um contato entre o robô e algum objeto. Para tanto, produz coerentemente disparos em neurônios na primeira camada da rede de atuadores.

O ajuste dos pesos sinápticos do  $j$ -ésimo neurônio da primeira camada da rede de atuadores é tal como na expressão da Equação 14:

$$w_{ji}(n+1) = w_{ji}(n) + \eta y_j x_i(n)(1 - w_{ji}(n)), \quad (14)$$

em que  $y_j(n)$  é a saída do  $j$ -ésimo neurônio,  $x_i(n)$  é sua  $i$ -ésima entrada e  $\eta$  é a taxa de aprendizagem.

#### 4. Resultados de Simulação

Esta seção apresenta os resultados obtidos em simulação que possibilitam analisar as características e potencialidades do controlador proposto. Os experimentos são realizados em um ambiente computacional provido de ferramentas de simulação desenvolvidas em [Antonelo2003a]. Para efeitos de simulação, as configurações das redes IP e IC são: estruturas formadas por 25 colunas de 12 neurônios cada;  $e_j(n) \in [0, 2]$ ;  $\varphi = 0,028$  e  $\sigma = 0,013$  e;  $e_j(0) = 0,06$ ,  $u_j(0) = 1$  e  $m_j(0) = 50$ . Para as redes RR e RA, tem-se:  $\alpha = 1,3$  e  $\phi = 1,1$ . Para todos os ajustes de pesos sinápticos,  $\eta = 0,4$  (taxa de aprendizagem). Os pesos sinápticos dos neurônios das redes IP e IC são inicializados com valores aleatórios, e das redes RA, RR e RT (primeira camada) com valores de baixa magnitude.

As figuras que se seguem são representações instantâneas do simulador. O robô é representado por um semicírculo. Objetos repulsivos são representados por polígonos escuros, enquanto objetos atrativos são representados por polígonos mais claros. Pontos de contatos repulsivos (ou colisões) são marcados com círculos claros. Pontos de contatos atrativos são assinalados com círculos pretos. Observe que as simulações foram realizadas com objetos de diversas cores (eg., cor azul para obstáculos, cor laranja para alvos).

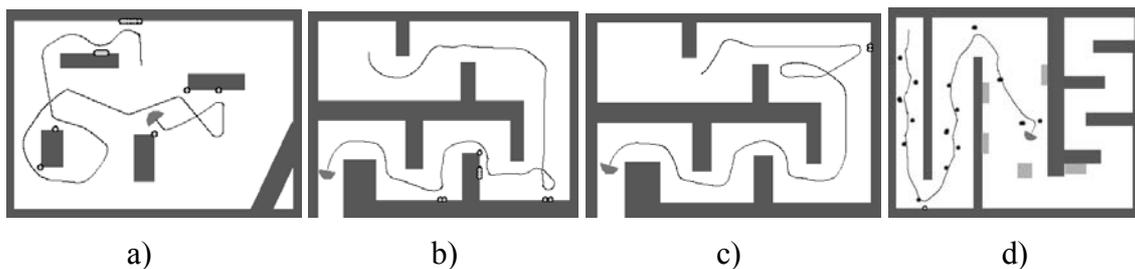
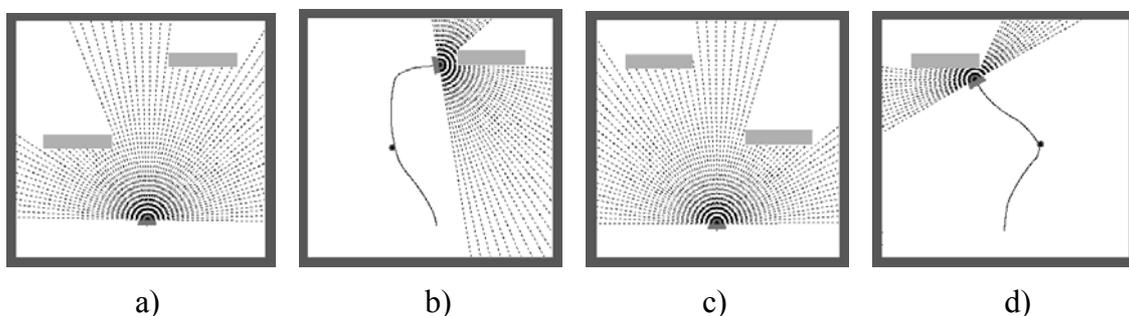


Figura 6. Aprendizagem de desvio de obstáculos e busca de alvos

Antes de qualquer interação com o ambiente, o robô não apresenta qualquer comportamento específico e o ambiente é desconhecido. As trajetórias apresentadas na Figura 6 (a), (b) e (c) mostram estágios evolutivos da estratégia de navegação com relação a objetos repulsivos. Após várias colisões no ambiente (a), o robô desenvolve uma trajetória mais eficiente em (b), conseguindo dirigir adequadamente o veículo por corredores largos (generalização do conhecimento adquirido). Em corredores mais estreitos, ainda ocorre algumas colisões, pois é necessária a aprendizagem de manobras mais complexas. A situação (c) apresenta uma trajetória com somente duas colisões. Após interagir com os ambientes apresentados na Figura 6 (a), (b) e (c), o robô é inserido no ambiente exibido na Figura 6 (d), em que estão presentes objetos atrativos (alvos). O robô precisa tocar duas ou três vezes em cada alvo até conseguir capturá-lo (disparando o processo de aprendizagem).

As próximas simulações ajudam a analisar a importância da existência dos repertórios IP (identificação de proximidade) e IC (identificação de cor) atuando conjuntamente no sistema autônomo.

O ambiente da Figura 7 (a) contém um alvo próximo ao robô e situado à sua esquerda e outro alvo distante do robô e situado à sua direita. A trajetória exibida na Figura 7 (b) indica que o comportamento do robô prioriza o objeto mais próximo situado à sua esquerda. Para verificar tal habilidade, os alvos são remanejados de maneira que o robô busque o alvo mais próximo situado à sua direita (Figura 7(c)). Como pode ser observado em Figura 7 (d), a trajetória do robô indica claramente a preferência pelo objeto mais próximo.



**Figura 7. Discriminação espacial**

## 5. Conclusão

Sistemas de navegação com elevado grau de autonomia representam uma vertente de grande interesse para a comunidade científica. Este trabalho propõe um sistema autônomo de navegação que constrói sua estratégia de navegação enquanto interage com o ambiente. O sistema é composto por uma rede neural que aprende por reforço (teoria clássica). Sua concepção busca a plausibilidade biológica conforme as argumentações defendidas em [Edelman 1987], tanto no que se refere aos aspectos neurofisiológicos quanto psicológicos [Donahoe 1994]. O sistema proposto se destaca por dois aspectos principais: aprende a discriminar objetos pertencentes a classes distintas (obstáculos e alvos) através de estímulos provenientes de um único campo sensorial (que fornece valores correspondentes à cor do objeto); modelos de neurônios com dinâmica interna proporcionam a aprendizagem do conceito espacial de proximidade, viabilizando a

construção de uma estratégia de navegação capaz de priorizar objetos mais próximos (e.g., desviar do obstáculo mais perto, buscar o alvo mais próximo). Inicialmente, o sistema é incapaz tanto de distinguir obstáculos de alvos quanto de priorizar objetos próximos ao robô. A medida que interações ocorrem (contato com objetos), o sistema associa os comportamentos de atração e repulsão a alvos e obstáculos, respectivamente. Experimentos de simulação consideram ambientes gerais com objetos de múltiplas classes (obstáculos e alvos) e apresentam resultados que confirmam as potencialidades supracitadas do sistema, bem como evidenciam a capacidade de generalização da estratégia de navegação para ambientes distintos.

## 6. Referências Bibliográficas

- Antonelo, E. A. (2003) “Sistemas Autônomos Inteligentes Voltados à Aquisição de Conceitos Espaciais e à Discriminação de Padrões Luminosos em Navegação de Robôs Móveis”, trabalho de graduação referente ao curso de Ciência da Computação, Departamento de Informática, Universidade Estadual de Maringá, Maringá, PR.
- Calvo, R. e Figueiredo M. (2003) “Reinforcement Learning for Hierarchical and Modular Neural Network in Autonomous Robot Navigation”, Proceedings of 2003 International Joint Conference on Neural Networks – IJCNN, Oregon, USA.
- Cazangi, R. e Figueiredo, M. (2002) “Simultaneous Emergence of Conflicting Basic Behaviors and Their Coordination in an Evolutionary Autonomous Navigation System”, Proceedings of 2002 IEEE Congress on Evolutionary Computation, (cd-rom), Honolulu, EUA.
- Crestani, P. R., Figueiredo, M., e Von Zuben, F. (2002) “A Hierarchical Neuro-Fuzzy Approach to Autonomous Navigation”, Proceedings of 2002 International Joint Conference on Neural Networks, (cd-rom), Honolulu, USA.
- Donahoe, J. W. & Palmer, D. C. (1994) “Learning and Complex Behavior”, Allyn and Bacon, Needham Heights, Massachusetts, EUA.
- Edelman, G., (1987) “Neural Darwinism: The theory of neuronal group selection”, Basic books, New York, USA.
- Figueiredo, M. (1999) “Navegação Autônoma de Robôs”, Livro da VII Escola Regional de Informática - VII ERI, SBC.
- Fung, W. e Liu, Y. (2003) “Adaptive Categorization of ART Networks in Robot Behavior Learning Using Game-Theoretic Formulation”, Neural Networks, Vol. 16, no 10, pp. 1403 a 1420, dezembro.
- Kandell, E.; Schwartz, J. e Jessel, T. (1991) “Principles of Neural Science”, Elsevier, New York.
- Millan, J. (1996) “Rapid, Safe, and Incremental Learning of Navigation Strategies”; IEEE Transactions on Systems, Man, and Cybernetics, Vol. 26, no 3, pp.408-420.
- Sutton, R. S., & Barto, A.G. (1998) Reinforcement learning: an introduction, MIT Press.
- Vershure, P. e Voegtlin, T. (1998) “A Bottom Up Approach Towards the Acquisition and Expression of Sequential Representations Applied to Behaving Real-World Device: Distributed Adaptive Control III”, Neural Networks, Vol.11, pp.1531–1549.