

Memória de Curta Duração em Sistema Autônomo Aplicado à Navegação de Robôs

Wilson de Souza Melo Júnior, Maurício Figueiredo
Departamento de Informática, Universidade Estadual de Maringá – UEM
Av. Colombo, 5790, CEP 87020-900, Maringá – PR
wsmjunio@din.uem.br, mauricio@din.uem.br

Abstract

This article presents a neural based autonomous system applied to mobile robot navigation. A coordination repertory balances instinctive behaviors (target seeking and collision avoidance), generated by two neural structures. In the same hierarchical level of the coordination repertory, there is other neural repertory, a neural-fuzzy network, that performs two main functions: a self-evaluation of the autonomous system and storage of the most recent landscapes captured by sensors. The autonomous system learns to navigate the robot, based on the conditioning theory, while interacts with the environment. Computer simulations show that the autonomous system is able to learn a general navigation strategy that provides good trajectories (without collisions and taking targets) for environment configurations even different from that considered during learning period. Furthermore, we consider a simpler version of the autonomous system (without the neural fuzzy network repertory) in comparison experiments. The experiment results show that the autonomous system escapes from “u” configurations, but the simpler version does not.

1. Introdução

De uma forma geral, o problema de navegação autônoma de robôs móveis (veículos) consiste na determinação de trajetórias que conduzam o robô até o alvo, sem que ocorram colisões contra obstáculos. As dificuldades envolvidas na busca de soluções para este problema têm direcionado a atenção da comunidade científica para técnicas alternativas, tais como: redes neurais, computação evolucionária, sistemas nebulosos, agentes inteligentes.

Os resultados alcançados com o uso de tais abordagens têm contribuído para a sua crescente credibilidade [1][2][3][4]. A proposta presente em [5] consiste em um sistema de navegação autônoma baseado em redes neurais nebulosas. A estrutura neural é do tipo auto-organizada e inspirada na teoria de seleção dos grupos neurais. O sistema é capaz de desenvolver as próprias estratégias de navegação à

medida que interage com o ambiente externo. Aperfeiçoamentos deste sistema são sugeridos em [6] a partir de propostas de novos modelos de neurônios artificiais e remodelagem de sua arquitetura neural.

Uma vez que os sistemas neurais têm por inspiração os sistemas biológicos, os princípios que regem a natureza de seus comportamentos devem ser aplicáveis a ambos os sistemas [7]. Sendo assim, sistemas de controle artificiais podem ser aprimorados com a aplicação de conceitos oriundos da psicologia. A teoria do reflexo condicionado tem contribuído intensamente na formulação de modelos para sistemas artificiais [8]. Sistemas que utilizam esta teoria aprendem por reforço do ambiente. O reforço consiste em estimular o sistema autônomo com um sinal de recompensa positivo ou negativo, conforme a atitude do robô estiver favorável ou desfavorável aos seus objetivos pré-definidos.

Em [9] propõe-se o uso de sensores de luz (além dos sensores de distância a objetos), os quais concedem ao sistema de navegação informações mais completas sobre o ambiente de navegação. Através do espectro luminoso, o robô é capaz de diferenciar três classes de objetos: obstáculos, fontes de alimentação e extratores de energia. Neste ambiente, investiga-se uma classe mais geral de sistemas neurais, em que o objetivo não é pré-definido. A interação com o ambiente possibilita ao sistema autônomo aprender a classificar os diferentes objetos.

Sistemas autônomos reativos com aprendizado demonstram dificuldades ao se depararem com configurações do tipo “u”. Na presença de tais configurações, as trajetórias geradas correspondem a ciclos infinitos. Uma das propostas apresentadas para superar tais dificuldades surge em [10]. O sistema neural, bastante complexo em sua arquitetura e lento com respeito a aprendizagem, é capaz de aprimorar trajetórias pouco eficientes (inclusive aquelas geradas em presença de configurações do tipo “u”). Uma outra proposta é lançada em [11]. Arquiteturas hierarquizadas em três níveis compõem o sistema autônomo: sistema reativo (o mais específico), sistema adaptativo e sistema reflexivo (o mais geral). O sistema reflexivo corresponde a uma memória de longa duração, armazenando de certa forma a história da trajetória do sistema.

O presente trabalho descreve um sistema autônomo baseado em redes neurais nebulosas. A arquitetura do sistema autônomo proposto apresenta simplicidade em sua concepção, mantendo um balanceamento coerente entre a complexidade do modelo estrutural e o conhecimento extraído e elaborado a partir das percepções sensoriais. Campos sensoriais para estímulos luminosos e estruturas neurais de auto avaliação têm papel fundamental no comportamento desenvolvido pelo robô em presença de configurações do tipo “u”. Tais estruturas neurais avaliam o comportamento do robô a partir da comparação das percepções sensoriais mais recentemente armazenadas. Resultados de simulação mostram que o sistema gera uma estratégia de aprendizagem geral capaz de se mostrar eficiente mesmo em ambientes diferentes daqueles onde se sucedeu o período de aprendizagem. Sistemas reativos simples (uma versão simplificada do modelo proposto) é adotado para efeitos de comparação. Experimentos mostram que o sistema autônomo original é capaz de escapar de configurações do tipo “u” para os quais o sistema reativo simples mostrou ser ineficiente.

O artigo tem continuidade com a seguinte sequência de seções. A seção 2 descreve as características do robô móvel utilizado, bem como o ambiente de simulação. A arquitetura básica do sistema é tratada na seção 3. A seção 4 detalha as idéias que fundamentam a estrutura neural que tanto representa a memória de curta duração quanto procede a auto-avaliação do sistema autônomo. Os resultados obtidos em simulação são apresentados na seção 5. A seção 6 apresenta as conclusões resultantes das simulações e os comentários finais.

2. Características do Robô

Neste trabalho o ambiente de simulação é constituído por um espaço bidimensional, no qual alvos e obstáculos são distribuídos sem qualquer restrição. Os alvos determinam pontos de localização que deverão ser alcançados pelo robô, ao passo que os obstáculos representam objetos diversos, com os quais o robô deverá evitar colisões.

O robô presente no ambiente de simulação está associado a modelos simples de veículos. Cada iteração no ambiente corresponde a um passo no deslocamento do robô. Cada passo é de valor fixo em todo o período que durar o experimento. O sistema autônomo ajusta a direção de movimento do robô antes de cada passo de deslocamento. Os ajustes (em graus) podem variar entre [-15, 15].

As informações do ambiente são capturadas por duas classes de dispositivos: sensores de direção e sensores de distância. Cada veículo possui um único sensor de direção e um número variado de sensores de distância (neste trabalho foram considerados 21). O sensor de direção é associado a um único alvo, informando ao sistema de navegação o ângulo de desvio do alvo com relação à direção de movimento.

Cada um dos sensores de distância informam ao robô a respeito de sua proximidade ao obstáculo (presente na direção na qual alinha-se o respectivo sensor).

Quando o robô captura um alvo, este é removido e outro é imediatamente posicionado no ambiente. Uma colisão contra um obstáculo é modelada conforme as leis da física aplicáveis ao choque de corpos perfeitamente elásticos.

Tanto a captura de alvos como a colisão contra obstáculos são detectadas por um segundo grupo de sensores: sensores de captura e sensores de colisão, respectivamente. Estes sensores têm a função de informar ao sistema de navegação a ocorrência dos eventos a que estão relacionados. Um terceiro campo sensorial captura os padrões luminosos (cores) emitidos pelos obstáculos.

3. Sistemas de Navegação Autônoma

O sistema de navegação autônoma é responsável pelo controle do robô móvel. Sua concepção busca estabelecer uma paridade entre os sistemas biológicos e os artificiais, no que concerne as suas estruturas, suas dinâmicas e os comportamentos delas resultantes. Também mantém como princípio a coerência entre a complexidade estrutural do sistema e suas capacidades decorrentes. Critica-se a possibilidade de um sistema autônomo apresentar comportamentos ou capacidades os quais não foram desenvolvidos a partir da interação com o ambiente, ou mesmo que estruturas simples estejam associadas a capacidades extremamente complexas. De uma forma geral, sua concepção está em acordo com as teorias relacionadas à emergência do comportamento complexo e aos grupos neurais presentes em [8] e [12].

3.1. Concepção básica: estrutura, raciocínio e aprendizagem

Dois repertórios neurais, que geram respostas instintivas, são a priori incorporados ao sistema: um de desvio de obstáculos e outro de captura de alvos (Figura 1). Tais instintos podem estabelecer comportamentos conflitantes. Por exemplo, situações de impasse surgem quando um obstáculo se interpõe entre o robô e o alvo a ser capturado.

Um terceiro repertório neural, associado a um nível hierárquico superior, é acrescentado ao sistema. Este repertório tem a finalidade de coordenar os comportamentos gerados pelas respostas instintivas, culminando assim em um novo comportamento emergente. Tal repertório não possui, a princípio, nenhum conhecimento sobre o ambiente. Este será adquirido por um processo de aprendizagem, baseado na teoria do condicionamento clássico. O condicionamento se estabelece a partir de duas classes

de eventos bem definidos: colisão contra obstáculos ou captura de alvos.

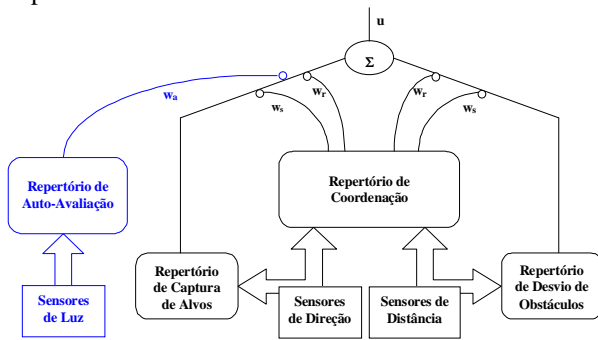


Figura 1: Sistema de navegação autônoma.

O repertório de coordenação é constituído por uma rede neural nebulosa e um neurônio nebuloso, ambos não supervisionados. As entradas da rede neural são associadas aos valores obtidos pelos sensores de distância. Seu algoritmo de aprendizagem é executado somente quando o sensor de colisão é excitado. Desta forma, a rede armazena padrões prototípicos correspondentes a situações de colisão iminente. O neurônio nebuloso apresenta, na prática, a mesma funcionalidade. Todavia, sua entrada está associada ao sinal obtido pelo sensor de direção ao alvo e seu aprendizado ocorre apenas quando o sensor de captura é estimulado. Sendo assim, este neurônio armazena padrões prototípicos que correspondem a situações de captura de alvos.

A saída do sistema de controle é determinada por um neurônio nebuloso, cuja função é agregar as saídas dos demais repertórios neurais instintivos. Os sinais advindos do repertório de coordenação funcionam como sinapses inibitórias ao sinal gerado pelos repertórios instintivos. Dessa forma, o reconhecimento de um padrão de colisão inibirá o instinto de captura de alvo e estimulará o instinto de desvio de obstáculos. Por outro lado, o reconhecimento de um padrão de captura terá ação inibitória sobre o instinto de desvio de obstáculos, ressaltando o instinto de captura.

A descrição mais detalhada da concepção básica pode ser encontrada em [13].

4. Repertório de Auto-Avaliação

Sob a perspectiva do nível de decisão, o repertório de auto-avaliação situa-se no mesmo nível do repertório de coordenação (Figura 1). Sua saída atuará de forma inibitória sobre os sinais exibidos pelo repertório de captura, sempre que as atitudes do robô estiverem associadas a uma dinâmica monótona (associados, por exemplo, a trajetórias cíclicas). A inspiração para a concepção do repertório provém do fato de que a atenção está associada inversamente com a repetitividade dos estímulos [8].

Parte da estrutura do repertório de auto-avaliação representa um modelo para a memória de curta duração. Trata-se de um sistema neural nebuloso baseado nas redes auto-organizadas propostas em [14]. A arquitetura do repertório se completa com um único neurônio nebuloso que agrega as saídas da rede neural nebulosa (Figura 2).




Figura 2 : Repertório de auto-avaliação.

A memória de curta duração armazena os padrões de estímulos capturados pelos sensores de luz. A saída dos sensores são conectadas a cada um dos neurônios nebulosos que compõem a rede neural nebulosa. Cada entrada x_i do neurônio, proveniente de cada um dos sensores de luz, está associada a um respectivo peso sináptico w_i (Figura 3).




Figura 3 : Modelo de neurônio nebuloso.

A saída y do neurônio é dada pela equação:

$$y = f\left(\prod_{i=1}^n \Delta(G(x_i), H(w_i))\right), \quad (1)$$

em que: Π é uma t-norma produto, f é a função identidade e Δ a função medida do grau de compatibilidade entre conjuntos nebulosos $G(x)$ e $H(x)$ dos quais x_i e w_i são seus respectivos valores modais (a dispersão é constante e pré-definida).

Neste trabalho, a função Δ é definida por:

$$\Delta(G(x), H(x)) = S(T(G(x), H(x))), \quad (2)$$

em que: T e S são normas do tipo t e s , respectivamente.

A aprendizagem da rede neural nebulosa segue os conceitos de auto-organização propostos em [12].

Sendo assim, os neurônios da rede competem entre si e o vencedor guia o processo de aprendizagem. Considerando as sinapses do n-ésimo neurônio, o ajuste é dado por:

$$w_i^n(T+1) = w_i^n(T) + D^{-1}(1 - w_a(T))(x_i(T) - w_i(T)), \quad (3)$$

em que: D é a distância Euclidiana entre o n-ésimo neurônio e o neurônio vencedor, w_a é a saída do repertório de auto-avaliação (conforme descrito a seguir).

Tal como descrita a rede neural nebulosa apresenta sinais de saída altos caso os estímulos correspondam a situações repetitivas e respostas baixas para situações contrárias.

A saída do repertório de auto-avaliação é determinada por um neurônio nebuloso. Suas entradas correspondem às saídas dos neurônios da memória de curta duração. Suas sinapses não alteram as entradas, uma vez que são modeladas por pesos sinápticos unitários. As funções de agregação e ativação são, respectivamente, uma s-norma e a função identidade. Conseqüentemente, a saída do repertório é dada por:

$$w_a = \sum_{i=1}^m (y_i), \quad (4)$$

em que: y_i corresponde às saídas de cada um dos neurônios que compõem a memória de curta duração e S é a s-norma máximo.

O sinal de saída w_a também influencia no próprio processo de aprendizagem da memória de curta duração. Sinais baixos indicam que o padrão luminoso capturado não tem sido armazenado recentemente, e portanto deve ser memorizada com maior intensidade. Sinais altos, por outro lado, indicam que o mesmo padrão luminoso vem sucessivamente se repetindo. Uma vez que o armazenamento de novas configurações é reforçado, estas tendem a sobrepor as antigas, caracterizando assim um tipo de memória de curta duração.

O valor de saída w_a , proveniente do repertório de auto avaliação, deve ser agregado ao neurônio nebuloso responsável por ponderar os valores gerados pelos demais repertórios de controle (Figura 1). O valor de u , que corresponde à saída do sistema de controle autônomo, é expresso pela seguinte equação:

$$u = (1 - w_r)(1 - w_a)U_{TS} + (1 - w_s)w_r U_{CA}, \quad (5)$$

em que: w_r e w_s são as saídas do repertório de coordenação; e U_{TS} e U_{CA} são as saídas dos repertórios de busca de alvos e desvio de obstáculos, respectivamente.

5. Resultados de Simulação

Para melhor exame e ilustração dos resultados considerou-se dois conjuntos de experimentos (nas figuras apresentadas em seguida, as linhas em frente ao robô correspondem às direções em que os sensores de distância atuam).

Em um primeiro conjunto, será ressaltado a capacidade de aprendizagem do robô. O sistema de navegação autônoma é incorporado ao robô, desconhecendo tanto o ambiente onde o robô é inserido quanto qualquer estratégia de navegação. A princípio o sistema de navegação gera trajetórias pouco eficientes, ou seja, algumas colisões eventualmente ocorrem. À medida que interage com o ambiente, o sistema autônomo passa a adquirir conhecimento e elaborar suas estratégias de navegação. Após um período de aprendizagem, quando ocorrem colisões, o robô passa a percorrer trajetórias eficientes, alcançando alvos sem que colisões ocorram (Figura 4).

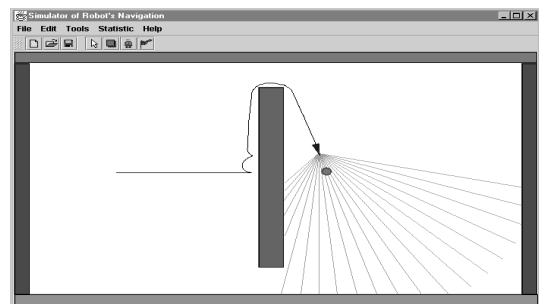


Figura 4: Aprendizagem do sistema autônomo.

O satisfatório desempenho do robô, após o período de aprendizagem, não está restrito ao ambiente de aprendizagem. Mesmo em ambientes distintos (daquele onde a aprendizagem ocorreu) o robô é conduzido por trajetórias eficientes, conforme as figuras em seguida podem ilustrar.

Um segundo conjunto de experimentos terá como objetivo principal demonstrar a capacidade do robô em escapar de configurações do tipo “u”. Nestes experimentos, considera-se que o sistema de navegação já passou por um período de aprendizagem.

Inicialmente, o robô é levado a “entrar” em uma configuração do tipo “u” (Figura 5). Para alcançar o segundo alvo, o robô deve distanciar-se do mesmo (atenuando o comportamento de captura de alvos, que é instintivo).

Observa-se, na Figura 6, que inicialmente o robô insiste em alcançar o alvo, sendo impedido pelo obstáculo. Após um breve período em que algumas oscilações na trajetória se apresentam, o robô passa a percorrer uma trajetória sinuosa, mas que proporciona uma rota alternativa até o alvo.

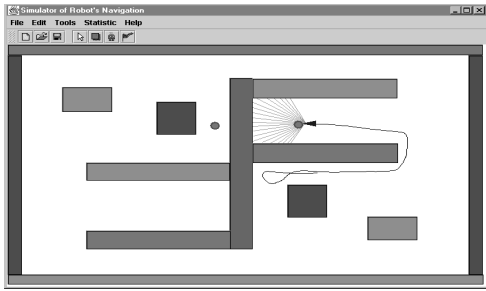


Figura 5 : Captura de alvo em configuração tipo “u”.

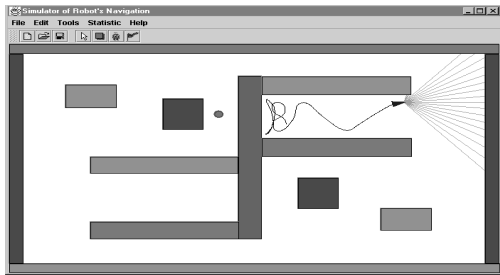


Figura 6 : Robô em rota alternativa para o alvo.

Para efeitos de comparação, considere que o sistema autônomo passe a operar sem o repertório de auto-avaliação (o conhecimento adquirido e presente no repertório de coordenação permanece inalterado). Em um procedimento idêntico ao anterior, ilustrado na Figura 5, o robô alcança um primeiro alvo no ambiente, em que uma configuração tipo “u” está presente. Ao iniciar sua trajetória em busca do segundo alvo, o robô inicia uma trajetória cíclica, na qual permanece indefinidamente (Figura 7).

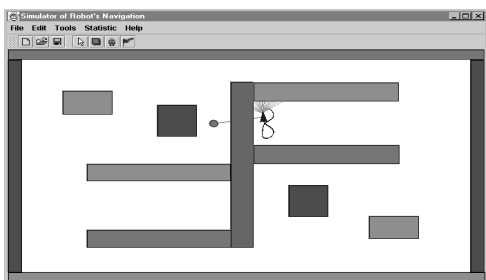


Figura 7 : Robô em uma trajetória cíclica.

As figuras seguintes apresentam os sinais w_r e w_s gerado pelo repertórios de coordenação e o sinal w_a , pelo repertório de auto-avaliação.

A Figura 8 corresponde aos sinais presentes no sistema de navegação correspondente a situação ilustrada na Figura 5. Note que o sinal w_s é alto pois o robô caminha em direção ao alvo. Os sinais w_r e w_a são baixos pois o sistema de navegação não identifica qualquer risco de colisão e nem há trajetórias que produzam padrões repetitivos.

A Figura 9 corresponde aos sinais presentes no sistema de navegação correspondente à situação

ilustrada na Figura 6. Note que o sinal w_s é baixo pois o robô dirige-se em direção oposta ao alvo. O sinal w_r oscila devido à trajetória sinuosa. O sinal w_a é alto pois frequentemente detecta padrões repetitivos capturados pelos sensores.




Figura 8 : Robô alcançando primeiro alvo.




Figura 9 : Robô deixando a configuração tipo “u”.

6. Conclusão

A navegação autônoma de robôs abre inúmeros campos de pesquisa relacionados à área de inteligência artificial.

A proposta traz à discussão a importância de estruturas de auto-avaliação e memória de curta duração (acrescente-se também as de longa duração, ambas declarativas) como componentes essenciais para geração de trajetórias eficientes em navegação autônoma (ou qualquer outro tipo de aplicação que apresente características complexas semelhantes).

O sistema autônomo busca manter coerência em dois aspectos importantes: balanceamento entre sua complexidade e as capacidades emergentes resultantes (por exemplo, não apresenta abstrações inteligentes

superiores, e.g., construção de mapas internos a partir de estruturas neurais simples); e fidelidade em sua fonte de inspiração que são os sistemas biológicos. Ambos os aspectos são críticos para que o processo de investigação leve ao desenvolvimento de sistemas autônomos inteligentes com características superiores [12]. Mesmo diante de tais restrições é possível gerar soluções alternativas para o problema de navegação autônoma de robôs.

Resultados de simulação são apresentados, demonstrando um desempenho satisfatório tanto em termos de aprendizagem de estratégias de navegação como também na geração de trajetórias alternativas para escape de configurações em “u”.

Propostas futuras visarão eliminar deficiências em ambientes onde uma grande variedade de cores cause a falsa impressão de uma trajetória não monótona mesmo quando o robô permanece em um ciclo contínuo.

Referências

- [1] Haykin, S., “Neural Networks: a comprehensive foundation”, Prentice Hall, New Jersey, 1999.
- [2] Pedrycz, W. e Gomide, F., An Introduction to Fuzzy Sets: Analysis and Design (Complex Adaptive Systems), MIT Press, New York, 1998.
- [3] Simpson, P.K., “Neural Networks Applications”, IEEE Press, New York, 1996.
- [4] Gasós, J. e Saffiotti, A., “Integrating fuzzy geometric maps and topological maps for robot navigation”, Proceedings of the 3rd Int Conf on Intelligent Industrial Automation (IIA'99), Genova, Itália, 1999.
- [5] Figueiredo, M., “Navegação Autônoma de Robôs”, Livro da VII ERI (Escola de Informática da SBC – Regional Sul), pp. 74-106, maio, 1999.
- [6] Crestani, P.R., “Aperfeiçoamento de Sistemas de Navegação Autônomos baseados em Redes Neurais Nebulosas”, Trabalho de Graduação, Departamento de Informática, Universidade Estadual de Maringá, 1999.
- [7] Schmajuk, N.A., “The Psychology of Robots”, Proceedings of IEEE, vol. 84, nº 10, pp. 1553-1560, 1996.
- [8] Donahoe, J., e Palmer, D., “Learning and Complex Behavior”, Allyn and Bacon, Boston, 1994.
- [9] Lonardoní, A. V., “Sistema de Navegação Autônomo Baseado em Redes Neurais Auto-organizadas”, Trabalho de Graduação, Departamento de Informática, Universidade Estadual de Maringá, 1999.
- [10] Millan, J., “Rapid, Safe, and Incremental Learning of Navigation Strategies”, IEEE transactions on System, Man, and Cybernetics, Part B, pp. 408-420, 1996.
- [11] Verschure, P.F.M.J., “A Bottom Up Approach Towards the Acquisition and Expression of Sequential Representations Applied to a Behaving Real-World Device: Distributed Adaptive Control III, Neural Networks, vol. 11, pp. 1531-1549, 1998.
- [12] Edelman, G., “Neural Darwinism”, Basic Books, New York, 1987.
- [13] Figueiredo, M. “Redes Neurais Nebulosas Aplicadas a Problemas de Modelagem e Controle Autônomo”, Tese de Doutorado, Departamento de Engenharia de Computação e Automação Industrial, FEEC, UNICAMP, 1997.
- [14] Kohonen, T., “Self-Organization and Associative Memory”, Springer-Verlag, Berlin, 1997.