

ARQUITETURA DE CONTROLE PARA AGENTES AUTÔNOMOS COOPERATIVOS ATRAVÉS DE REDES COGNITIVAS DINÂMICAS.

MÁRCIO MENDONÇA¹, IVAN R. CHUN¹, LÚCIA VALÉRIA R. ARRUDA², FLÁVIO NEVES JÚNIOR²

1. *Departamento de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná
Av. Alberto Carrazai, Cornélio Procópio, PR - 86300-000
E-mails: mendonca@utfpr.edu.br; ivancrun@gmail.com*

2. *Laboratório de Automação e Sistemas de Controle Avançado (LASCA).
Universidade Tecnológica Federal do Paraná.
Campus Curitiba – Av. Sete de Setembro, 3165
CEP 80230-901, Curitiba, Paraná, Brasil
E-mails: lvrarruda@utfpr.edu.br; neves@utfpr.edu.br*

Abstract—This paper presents an architecture developed for robotic navigation through dynamic cognitive networks (DCN), an evolution of fuzzy cognitive maps applied in autonomous navigation, in particular cooperative autonomous navigation. The proposed architecture is inspired by the Brooks subsumption architecture because of its hierarchical management functions and parallel processing. A dynamic cognitive network is designed with several levels of functionality, from low-level actions to the highest level of management and action planning. In the last level is inserted into the model sharing between straight trajectory agents through a memory traffic based on multi-agent systems and bio-inspired algorithms.

Keywords—Dynamic Cognitive Networks, Cooperative Autonomous Navigation, Subsumption Architecture, Multi-Agent System and Fuzzy logic.

Resumo— Este trabalho apresenta uma arquitetura de navegação robótica desenvolvida através de redes cognitivas dinâmicas (DCN), uma evolução dos mapas cognitivos *fuzzy*, aplicadas em navegação autônoma, em especial navegação autônoma cooperativa. A arquitetura proposta é inspirada na arquitetura de subsumção de Brooks devido ao gerenciamento hierárquico de funções e processamento paralelo. Uma rede cognitiva dinâmica é desenvolvida com vários níveis de funcionalidades, desde ações de baixo nível até o nível mais alto de gerenciamento e planejamento de ações. No último nível é inserido no modelo um compartilhamento de trajetória entre uma sequência agentes, através de uma memória de tráfego baseado em sistemas multiagentes e algoritmos bio-inspirados.

Palavras-chave— Redes Cognitivas Dinâmicas, Navegação Autônoma Cooperativa, Arquitetura Subsumção, Sistemas Multi-Agentes e Lógica *Fuzzy*.

1 Introdução

Robôs móveis, em especial robôs autônomos, tem sido um assunto atraente entre pesquisadores. Neste sentido, pode ser um terreno comum para comparar diferentes soluções para os mesmos problemas. Pesquisas utilizando sistemas computacionais inteligentes têm sido utilizadas na construção de sistemas de navegação autônomos, aplicações com pouco ou nenhum conhecimento do ambiente (COSTA E GOUVEA, 2010). Neste contexto, a aplicação da teoria Sistemas Autônomos tem a capacidade de executar tarefas complexas com alto grau de sucesso (RUSSEL E NORVIG, 1995). A complexidade envolvida nas tarefas de geração de trajetórias eficientes é reconhecidamente alta e, em muitos casos, exige que o sistema autônomo seja capaz de aprender uma estratégia de navegação através da interação com o ambiente.

Pesquisas em robótica autônoma, em particular robótica coletiva, utilizando sistemas bio-inspirados em insetos com vida social (inteligência coletiva) são conhecidas na literatura (MOSES, BANERJEE,

2011), (BAYINDIR E SAHIN, 2007), (PARKER, 2008) utilizam grupos de robôs com comportamento inspirado em colônia de insetos e são utilizados para gerenciar mais de um agente ou robô (móvel), na execução de suas funcionalidades. A aplicação das técnicas e /ou conceitos de robótica coletiva estão relacionados com sistemas autônomos e sistemas multi-agentes (WOOLDRIDGE; JENNINGS, 1995). Da teoria de agentes autônomos, em especial agentes autônomos cooperativos, deve-se ressaltar a capacidade de autonomia sozinho e/ou em grupo, ou seja, sucesso em cenários diferentes sem intervenção de humanos (RUSSEL, NORVIG, 1995).

E finalmente, um conceito explorado nesse trabalho é de se desenvolver uma arquitetura utiliza a capacidade de evolução de um agente. Conceitualmente evolução é diferente de aprendizado, porque um agente só pode evoluir caso o mesmo herde conhecimento de outro agente anterior, enquanto que aprendizado o agente só precisa de si mesmo (DE CASTRO, 2007).

Os conceitos citados serão contextualizados no ambiente de simulação proposto, no qual, obstáculos dinâmicos surgem durante a trajetória, alvos necessitam ser alcançados pelo agente móvel e dados de

exploração serão compartilhados entre os mesmos. Desse modo, existem diferentes objetivos, com alguns até conflitantes como a coleta de alvos e desvio de obstáculos, em um cenário praticamente desconhecido pelos agentes exploradores.

De um modo geral, essa pesquisa trata problemas com decisões sequenciais em ambientes parcialmente ou totalmente desconhecidos com múltiplos objetivos. Nesse nível de complexidade a arquitetura proposta apresenta capacidade de aprendizado, de sintonia, adaptação e evolução. Essas características serão necessárias para gerenciamento de ações. No nível mais alto da arquitetura DCN apresenta um algoritmo bio-inspirado, inspirado na tarefa de coleta de alimentos por colônias de formigas (LABELLA, DORIGO E DENEUBOURG, 2006).

E, de modo específico, a proposta dessa pesquisa é de se explorar a capacidade de aquisição de conhecimento e refinar com dados históricos e/ou comportamento dinâmico (sintonia *on-line*), na construção de uma arquitetura de controle baseada na arquitetura de subsunção de Brooks (BROOKS, 1986). Além da sintonia dinâmica, os dados de navegação dos robôs exploradores anteriores auxiliam para navegar de forma autônoma (explorar, desviar obstáculos e coletar alvos) e reconhecimento do ambiente.

A construção da arquitetura de controle pode ser dividida em dois passos: no primeiro passo o controlador utilizará inicialmente conhecimento de baixo nível (virar e esquerda caso surja um obstáculo à direita) e a ocorrência de eventos (surgimento de alvos ou obstáculos) para gerenciamento das ações de controle. Um algoritmo de aprendizagem por reforço (SUTTON E BARTO, 1998) é utilizado para uma sintonia (ajuste fino) do modelo cognitivo em tempo de navegação. Devido à execução de funcionalidades diferentes e possivelmente conflitantes, uma arquitetura de subsunção com funcionalidades inspirada nos trabalhos de Braitenberg (1984) e baseada em DCN, é desenvolvida para gerenciamento das ações de controle (MENDONÇA, et al., 2011). O segundo passo utiliza todas as recursividades do primeiro, entretanto, dados da trajetória dos robôs anteriores são também utilizados pelos robôs posteriores de forma ponderada para reconhecimento do ambiente. Essa segunda etapa é inspirada no comportamento de formigas, devido a um rastro ou memória de posição deixada.

2 Fundamentos

Mapas cognitivos *fuzzy* (FCM) são sistemas não lineares dinâmicos para a modelagem de conhecimento causal. Eles combinam aspectos da lógica *fuzzy*, redes neurais, redes semânticas, sistemas especialistas e sistemas dinâmicos não lineares. FCMs são capazes de modelar sistemas complexos e se aplicam a uma ampla gama de problemas em engenharia e áreas afins (PAPAGEORGIOU, 2012).

A Rede Cognitiva Dinâmica, do inglês *Dynamic Cognitive Networks* (DCN), é uma evolução do FCM, que por sua vez é uma evolução do modelo cognitivo de Axelrod (AXELROD, 1976), em forma de grafo que abstrai conhecimento de forma estruturada com relações causais (causas e efeitos) e conceitos que podem representar variáveis, ações, estados entre outras funções (KOSKO, 1986). Diversos trabalhos e aplicações são encontrados na literatura como, por exemplo, os trabalhos de (STYLIOU et al., 2008), (PAPAGEORGIOU, STYLIOU E GROUMPOS, 2007) na área médica, (PIPE, 2000) navegação robótica, (MENDONÇA, ARRUDA E NEVES, 2009) em controle de processos, entre outros. Trabalhos específicos como métodos de treinamento da FCM (GLYKAS, 2010) e o mais recente e completo é o trabalho de (PAPAGEOGIU, 2012).

Devido à dificuldade de tratamento dinâmico das informações, variações e ou evoluções do FCM surgiram na Literatura. Desse modo, podem-se citar os trabalhos de Carvalho (CARVALHO, 2001) com Rule Base FCM e o trabalho de Park e Kin (PARK e KIN, 1995) entre outros. E, as DCN como evoluções. Neste contexto, pode-se citar os trabalhos de Miao e colaboradores (Miao et al., 2001, 2010), Koulouriotis e colaboradores (KOULOURIOTIS, et al., 2005) e Mendonça e colaboradores (MENDONÇA, et al., 2011). A DCN herda o formalismo matemático do FCM dos trabalhos citados no início da sessão, maiores detalhes da DCN empregada no desenvolvimento da arquitetura pode ser encontrado no trabalho de Mendonça e colaboradores (2011).

3 Desenvolvimento

Um importante objetivo na área de robótica é a criação de robôs autônomos. Tais robôs devem aceitar descrições de alto nível das tarefas que devem executar, sem necessidade de intervenção humana (GUDWIN, 2011).

Nos sistemas de controle dos robôs móveis, atualmente, utilizam-se técnicas de inteligência computacional, tais como: redes neurais, lógica *fuzzy* ou a combinação destas com técnicas convencionais. Os usos dessas técnicas devem-se a capacidade dos seres humanos em lidar com processos complexos, baseados em informações imprecisas e/ou aproximadas. A estratégia adotada por eles é também de natureza imprecisa e geralmente passível de ser expressa em termos linguísticos (ZADEH, 1968). Deste modo, através de conceitos da lógica *fuzzy*, é possível modelar esse tipo de informação. Entretanto, informações também podem ser adquiridas a partir dos dados de operação e/ou, funcionamento de um sistema através de técnicas de identificação e modelagem (PASSINO E YOURKOVICH, 1997). Entre estas técnicas as redes neurais se destacam pela capacidade de processar dados massivos de uma maneira paralela (HAYKIN, 2000).

3.1 Arquitetura DCN

A arquitetura DCN, como mostra a figura 1, apresenta dois blocos extremos que representam as interfaces de entrada e saída, um bloco inferior que representa o motor de inferência e/ou tomada de decisão. Os dois blocos superiores representam a base de regras e relações para tratamento do conhecimento na forma dinâmica e de eventos. Essa representação em blocos auxilia no entendimento do funcionamento da arquitetura como um todo. Deste modo, as aplicações que empreguem DCN terão representações gráficas semelhantes, com diferenças nas variáveis de entrada e saída.

Na prática, esses blocos darão origem a conceitos e relações, como por exemplo, os blocos de interfaceamento com o ambiente em que o modelo será inserido, são feitos através de conceitos de entrada e saída da DCN. O bloco relações causais e relações *fuzzy* representa as tomadas de decisões contínuas e as suas respectivas relações e os conceitos conectados, o bloco base de regras linguísticas representa às outras relações, em especial, as relações e conceitos de seleção e fator, com suas respectivas regras, que modelam as ações orientadas pela ocorrência de eventos.

Esta arquitetura explora a capacidade de aquisição de conhecimento estruturado, com diferentes fontes de conhecimento. Essas fontes podem ou não ter a mesma origem, o que permite a construção de tomadas de decisões de baixo nível (relações causais) e estratégicas por um especialista(s) trabalhando de modo simultâneo ou não “*White board*” (COPPIN, 2010).



Figura 1 – Arquitetura blocos DCN

A arquitetura DCN-Subsunção combina diversas técnicas computacionais inteligentes (Lógica *Fuzzy*, Redes Neurais Artificiais, Teoria de Agentes) e é orientada a eventos.

Em resumo o método proposto neste trabalho para a construção de modelos cognitivos baseados em DCN, lança mão de vários conceitos e técnicas que estão na interseção de 3 áreas bases dos sistemas inteligentes. Da teoria de agentes inteligentes vem às características da arquitetura de subsunção, como: adaptação com ambiente, hierarquia de ações. Da

lógica *fuzzy*, o método herda as técnicas de aquisição de conhecimento e tratamento de incertezas e, por fim das redes neurais, utilizou-se a capacidade de treinamento e a representação estrutural em forma de grafos.

3.2 Arquitetura SUBSUNÇÃO-DCN

As tomadas de decisões e inferências neste tipo de arquitetura funcionam em processamento paralelo e são capazes de tomar decisões relacionadas a comportamentos humanos como “raciocinar sobre o comportamento de objetos” e “explorar” o ambiente (BROOKS, 1986).

A arquitetura de Subsunção é a mais conhecida para agentes inteligentes e foi proposta por Brooks (1986). Ressalta-se que existem outras propostas conhecidas na literatura (GUDWIN, 2002), entretanto, optou-se por se utilizar a arquitetura de subsunção. Essa arquitetura foi originalmente idealizada para a utilização em robôs móveis autônomos capazes de realizar o processamento de informações complexas em tempo real (CHONG, TAN, NG, 2007). Algumas características são citadas: utiliza uma hierarquia que prioriza funções de acordo com a heurística de operação do processo. É uma arquitetura baseada na ação-situação. As decisões dos agentes são realizadas através de um conjunto de comportamentos direcionados a tarefas a cumprir. Deste modo, cada camada é capaz de inibir o comportamento das camadas acima dela.

A figura 2 mostra um exemplo de funcionalidades com três camadas. Os veículos auto-guiados que utilizam esta arquitetura possuem grandes expectativas quanto às possibilidades de aplicação prática, inclusive industriais. Muito embora seres vivos com capacidade motora não encontrem grandes dificuldades em gerar trajetórias eficazes e tomar decisões nos mais variados ambientes, dotar sistemas artificiais com tais habilidades não é uma tarefa elementar (COLOMBETTI; DORIGO; BORGHI, 1996).

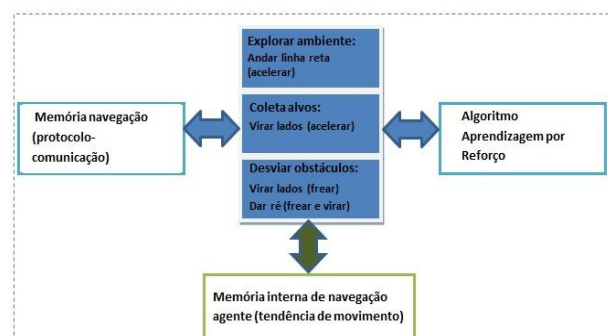


Figura 2 - Arquitetura DCN-Subsunção.

A figura 2 mostra a arquitetura DCN-Subsunção, com as camadas de tomadas de decisões hierárquicas, a prioridade é desvio de obstáculos, encontrar alvos e se o caminho esteja livre é ativada uma ação de exploração, no caso é andar em linha reta.

A figura 3 mostra a estratégia do controlador por meio de uma máquina de estados.

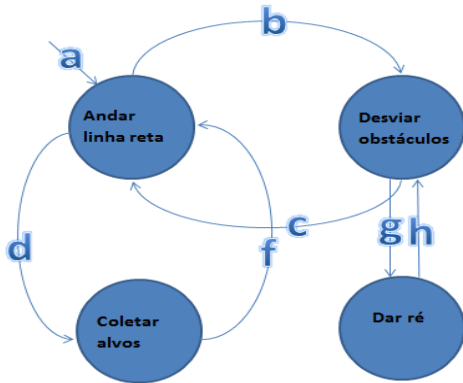


Figura 3 – DCN-Subsunção cooperativa

O formalismo em forma de grafo permite visualizar os diferentes estados e principalmente a transição entre eles, por exemplo, no estado de “dar ré” o agente móvel não ira coletar alvos, o agente terá que retornar ao estado de desvio de obstáculos para fazer tal transição.

Dos FCMs clássicos são herdadas as relações de causa e efeito (W1-W7) que nesse caso são responsáveis pelas ações de baixo nível (figura 4). Os sensores S.R., S.F. e S.L. lateral direito, frontal e lateral esquerdo são conceitos clássicos. As saídas OUTLeft, OUTFront e OUTRight são também conceitos clássicos e as repostas das inferências da DCN-SUBSUNÇÃO.

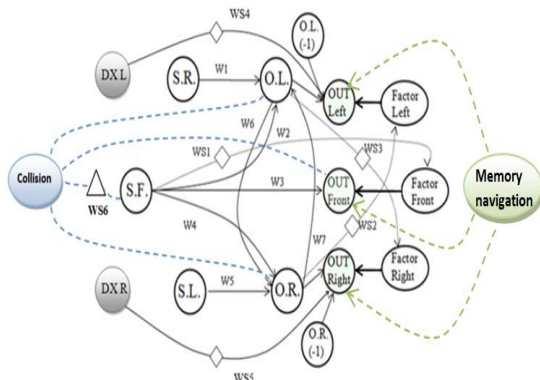


Figura 4 – DCN-Subsunção cooperativa

Os conceitos DXL e DXR são conceitos que processam a distancia com os alvos, e, junto com as relações de seleção (WS4 e WS5) disparam o evento de busca de alvos. Já as relações WS1, WS2 e WS3 são relações que disparam a redução do efeito de “zig-zag” juntamente com os conceitos de fator de saída.

4 Resultados

Um ambiente de simulação com animação 2-D foi também desenvolvido para testar e validar o sis-

tema de navegação desenvolvido. No ambiente de simulação, o rastro com três cores ou tons mais intensos simboliza o robô móvel. Já os sinais de “+” mais claros simbolizam os obstáculos estáticos, o sinal “*” em um tom mais forte representa um obstáculo dinâmico, o símbolo “+” também representa obstáculos que surgem durante a navegação (obstáculos “inesperados”) do robô móvel, e finalmente o “▲” representa os alvos a serem coletados pelo robô. Nas simulações com obstáculos dinâmicos uma trilha ou rastro também é usado para mostrar a sequencia de ações de direção e aceleração na trajetória. Os cenários simulados podem ser reproduzidos em uma escala de 1:100 na construção de cenários reais.

Quando os ambientes são virtuais, apontam-se algumas vantagens, como, por exemplo, torna-se mais fácil manter o foco e os objetivos nas tarefas em que se deseja estudar. Em robôs, diversos problemas tais como ruídos, problemas com sensores e atuadores acabam desviando a atenção do que seria o foco principal (GUDWIN, 2011).

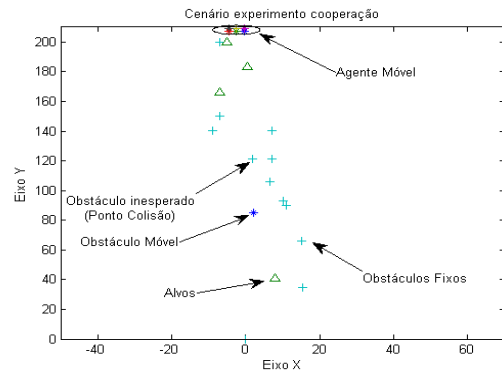


Figura 5 – Visão do Cenário (geral).

A dificuldade imposta no cenário de teste sugere nível complexidade no problema; na primeira passagem uma colisão é iminente e ocorre no ponto (x=2, y=121).

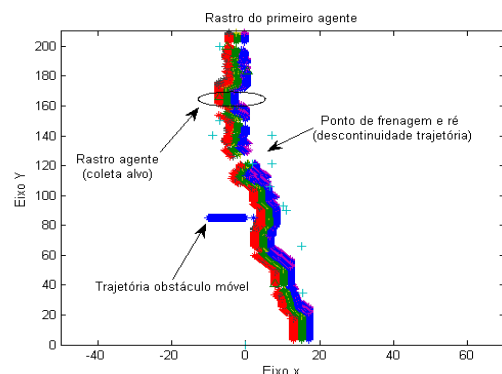


Figura 6 - Memória de navegação “rastro” primeiro agente.

A figura 5 mostra todo o cenário, o mesmo em todos os experimentos ou rodadas. A figura 6 mostra a memória de navegação “rastro” das ações do primeiro agente. A figura 7 destaca o ponto crítico que necessita de ação de frenagem ré. A figura 8 mostra

as ações do segundo agente também ampliada, e pode-se observar que o agente ou robô móvel passa mais distante, entretanto ainda dispara a ré. A figura 9 mostra que o terceiro agente consegue executar uma trajetória sem dar ré, ou seja, tem uma melhor otimização durante trajetória devido aos dados históricos previamente compartilhados pelos agentes anteriores.

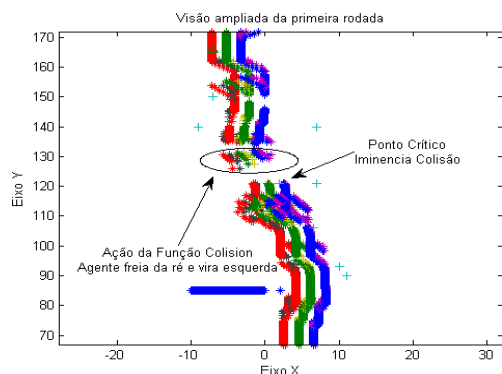


Figura 7 - Memória de navegação "rastros" primeiro agente ampliado no ponto crítico

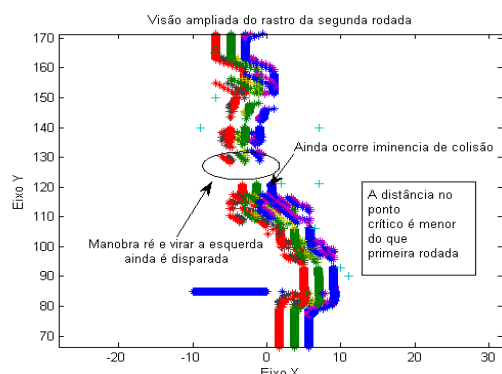


Figura 8 - Memória de navegação "rastros" segundo agente ampliado no ponto crítico

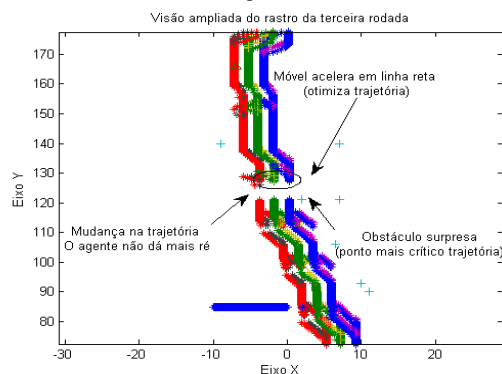


Figura 9 - Memória de navegação "rastros" terceiro agente ampliado no ponto crítico

Os algoritmos de aprendizado são utilizados *off-line* e até mesmo *on-line*, porém o conceito de evolução não se pode aplicar no mesmo indivíduo ou agente.

5 Conclusões

Devido aos resultados, ainda que iniciais, em especial quanto à cooperação entre os agentes, pode-se observar autonomia, capacidade de adquirir conhe-

cimento para compensar conhecimento prévio incerto ou parcial. Por exemplo, a ação de virar à esquerda sabe-se inicialmente a intensidade que o agente ou robô móvel deve virar à esquerda. Entretanto, com a utilização de algoritmo A.R. a interação com ambiente as tomadas de decisões finais foram sintonizadas.

A arquitetura DCN-Subsunção mostrou capacidade de aprendizado, adaptação e cooperação, que habilitaram o agente ser racional, durante navegação as inferências determinaram seqüências de ações que permitiram alcançar seus objetivos (explorar, desviar obstáculos e coletar alvos). Devido aos agentes terem demonstrado aprendizado sozinho e/ou de evolução em grupo, através de comunicação e compartilhamento de informações utilizadas na estratégia de controle para exploração e planejamento de trajetória. Ressalta-se a atuação da cooperação entre os agentes, em especial, na terceira rodada da simulação, não necessitou dar ré no ponto mais crítico do cenário. Espera-se ter contribuído no desenvolvimento de arquiteturas de controle para construção de agentes e sistemas multi-agentes autônomos móveis com ou sem cooperação, através de uma arquitetura híbrida.

Futuros trabalhos endereçam o aprimoramento da comunicação entre os agentes através de um protocolo. Desenvolvimento de outras estratégias de cooperação, como por exemplo, o uso do conceito de feromônios artificiais. A construção de mais cenários e com maior complexidade. E, finalmente, embarcar em plataformas robóticas reais.

Referências Bibliográficas

- Axelrod, R. (1976) Structure of decision: the cognitive maps of political elites. New Jersey: Princeton University Press.
- Bayindir L. and Sahin E., (2007). A Review of Studies in Swarm Robotics. The Turkish Journal of Electrical Engineering & Computer Sciences, vol. 15, no. 2, 2007, pp. 115-147.
- Braitenberg, V. (1984). Vehicles: Experiments in synthetic psychology. MA: MIT Press
- Brooks, R. A. (1986). A robust layered control system for a mobile robot. IEEE Journal of Robotics and Automation, v. 2, n. 1, p. 14-23, Mar.
- Carvalho, J.P.B. (2001). Mapas cognitivos baseados em regras difusas: modelação e simulação da dinâmica de sistemas qualitativos. Dissertação de doutorado. Universidade Técnica de Lisboa, Lisboa, Portugal.
- Chong H.-Q., Tan A.-H., and NG. G.-W. (2007) Integrated cognitive architectures: a survey. Artif. Intell. Rev. 28, 2, 103-130, (August). DOI=10.1007/s10462-009-9094-9
- Colombetti, M.; Dorigo, M.; Borghi, G. (1996). Behavior analysis and training: a methodology for behavior engineering. IEEE Transactions on Systems, Man, and Cybernetics, Part B, Cybernetics, v. 26, n. 3, p. 365-380, Jun.

- Coppin, B. (2010). *Inteligência artificial*. Rio de Janeiro: Livros Técnicos e Científicos.
- Costa, E.D.S.; Gouvea, M.M. (2010), "Autonomous Navigation in Dynamic Environments with Reinforcement Learning and Heuristic," *Machine Learning and Applications (ICMLA)*, Ninth International Conference on, vol., no., pp.37-42, 12-14 Dec.
- De Castro, L. N. . *Fundamentals of natural computing: an overview*. *Physics of Life Reviews*, v. 4, p. 1-36, 2007.
- Glykas (2010), Michael. *Fuzzy Cognitive Maps Advances in Theory, Methodologies, Tools and Applications*. Greece Springer.
- Gudwin, R. R. (2002), *Semiônica: Uma Proposta de Contribuição à Semiótica Computacional*, Tese (obtenção do Título de Professor Livre-Docente) Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas.
- Gudwin, R. R. (2011). *Arquiteturas de Criaturas Artificiais*. Simpósio Brasileiro de Automação Inteligente. São João Del Rei. Pp 943-958.
- Haykin, S.(2000). *Redes neurais, princípios e prática*, 2. ed. São Paulo: Bookman.
- Koulouriotis, D. E; Diakoulakis I.E.; Emiris D.M.; Zopounidis C.D.. (2005) Development of dynamic cognitive networks as complex systems approximators: validation in financial time series. *Applied Soft Computing*, v. 5, n. 2, p. 157-179. Jan.
- Labella T. H., Dorigo M. and Deneubourg J.-L., (2006). Division of Labor in a Group of Robots Inspired by Ants' Foraging Behavior, *ACM Transactions on Autonomous and Adaptive Systems*, vol. 1, no. 1, September 2006, pp. 4-25.
- Kosko, B. (1986) Fuzzy cognitive maps. *International Journal Man-Machine Studies*, v. 24, n. 1, p.65-75.
- Mendonça, M.; Arruda, L. V. R.; Neves Junior, F. (2009). Mapas cognitivos aplicados ao controle qualitativo de processos. In: *Simpósio Brasileiro De Automação Inteligente*, 9., Brasília.
- Mendonça, M., Angélico, B.A., Arruda, L.V.R. Neves, F.J. (2011). *Arquitetura de Subsunção Baseada em Redes Cognitivas Dinâmicas com Aplicação Em Navegação Autônoma*. SBAI – Simpósio Brasileiro de Automação Inteligente. Pg 233-238. São João del-Rei. M.G.
- Miao, Y., Z.Q. Liu, C.K. Siew and C.Y. Miao (2001) Dynamical cognitive network — an extension of fuzzy cognitive. *IEEE Trans. on Fuzzy Systems*, Vol. 9, no. 5, pp. 760-770.
- Miao, Y. Z.Q. Liu, C.K. Siew and C.Y. Miao (2010) Transformation of cognitive maps. *IEEE Transactions on Fuzzy Systems*, v. 18, n. 1, p. 114-124, Feb.
- Moses, M.; Banerjee, S., (2011) Biologically inspired design principles for Scalable, Robust, Adaptive, Decentralized search and automated response (RADAR). *Artificial Life (ALIFE)*, 2011 IEEE Symposium on , vol., no., pp.30,37, 11-15 April
- Papageorgiou, E., Stylios, C.; Groumpos, P. (2007) Novel for supporting medical decision making of different data types based on Fuzzy Cognitive Map Framework. *Proceedings of The 29th Annual International Conference of The Ieee Embs Cité Internationale, Lyon, France August 23-26*.
- Papageorgiou, E. (2012). *Learning Algorithms for Fuzzy Cognitive Maps*. *IEEE Transactions ON Systems and Cybernetics. Part C: Applications and Reviews*. Vol 42 pag 150-163. March.
- Park, K. S.; Kim, S. H. (1995). Fuzzy cognitive maps considering time relationships. *International Journal of Human-Computer Studies*, v. 42, n. 2, p. 157-168, Feb.
- Parker L. E., (2008). *Distributed Intelligence: Overview of the Field and its Application in Multi-Robot Systems*”, *Journal of Physical Agents*, vol.2, no. 1, March, pp. 5-14.
- Passino, M. K.; Yourkovich, S. (1997) *Fuzzy control*. Menlo Park: Addison-Wesley.
- Pipe, A. G. (2000). An architecture for building “potential field” cognitive maps in mobile robot navigation. *Adaptive Behavior*, v. 8, n. 2, p. 173-203.
- Russell, S. J.; Norvig, P. (1995) *Artificial intelligence: a modern approach*. Englewood Cliffs: Prentice Hall.
- Stylios, C. D., Georgeopoulos, V.C. Malandraki, G.A., Chouliara S. Fuzzy cognitive map architectures for medical decision support systems. *Applied Soft Computing*, v. 8, n. 3, p. 1243-1251, Jun. 2008.
- Sutton, R.; Barto, A. (1998) *Reinforcement Learning: an Introduction*. Cambridge: MIT Press.
- Wooldridge, M.J.; Jennings, N.R. (1995) *Intelligent Agents: Theory and Practice Knowledge Engineering Review* Vol. 10 No. 2 Cambridge University Press pp. 115-152.
- Zadeh, L.A. (1968) Fuzzy algorithms, *Info. & Ctl*. Vol. 12, pp. 94-102.