

Comparativo de Estratégias Baseadas em C-SLAM e Inteligência Coletiva através de HD-FCM

Mapas Cognitivos Fuzzy Dinâmicos Hierárquicos

Márcio Mendonça^{1,2}, Ivan R. Chrun¹,

¹Laboratório de Automação e Sistemas de Controle Avançado (LASCA)

Universidade Tecnológica Federal do Paraná
Curitiba, Brasil

mendonca@utfpr.edu.br; ivanchrun@gmail.com;

Jancer F. Z. Destro², Edson L. Bassetto²

²Laboratório de Segurança, Iluminação e Eficiência Energética (LABISEE)

Depto Engenharia Elétrica (DAELE)
Universidade Tecnológica Federal do Paraná

Cornélio Procópio, Brasil

frank@utfpr.edu.br; bassetto@utfpr.edu.br;

Abstract— Este trabalho apresenta uma arquitetura de navegação robótica construída através de Mapas Cognitivos Fuzzy Dinâmicos e Hierárquicos, do inglês Hierarchical Dynamic-Fuzzy Cognitive maps (HD-FCM), uma evolução dos Mapas Cognitivos Fuzzy, aplicadas em navegação autônoma, em especial navegação autônoma cooperativa homogênea com controle descentralizado. A arquitetura proposta é inspirada na arquitetura de subfunção de Brooks devido ao gerenciamento hierárquico de funções e processamento paralelo, e em conceitos de técnicas de SLAM como Landmarks artificiais (faixa de compartilhamento de memória) e recuperação de informações. Para avaliar a evolução proposta um breve comparativo com uma estratégia será apresentado em cenários diferentes. Devido ao nível de complexidade das estratégias dos controladores. Uma arquitetura baseada em HD-FCM será desenvolvida com vários níveis de funcionalidades, desde ações de baixo nível até o nível mais alto de gerenciamento, como por exemplo: compartilhamento de informações, planejamento de ações (coleta de alvos fixos ou desvio de obstáculos), sintonia dinâmica do modelo por meio de Algoritmo de Aprendizado por Reforço adaptado para uma base de regras heurísticas.

Keywords—Redes Cognitivas Dinâmicas; Navegação Autônoma Cooperativa; Arquitetura de Subfunção; Sistemas Multi-Agentes; Lógica Fuzzy.

I. INTRODUÇÃO

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. Técnicas de robótica e agentes autônomos podem ser aplicadas em diferentes áreas, por exemplo, em segurança (para evitar situações de risco para os seres humanos), na exploração de ambientes com difícil acesso ou inóspitos, e no serviço de forma crítica. Este é um campo emergente de pesquisa e aplicação, tal como apresentado por Maki et al. [1] e Vernon; Metta e Sandini [2]. O problema de explorar um ambiente pertence à problemas fundamentais em robótica móvel. Existem diversas áreas para aplicações como por exemplo: a exploração planetária, reconhecimento, resgate, roçada ou limpeza em que a área de cobertura é também uma

das aplicações da área robótica [3]. Pesquisas em robótica autônoma, em particular robótica coletiva utilizando sistemas biológicos inspirados em insetos com vida social (inteligência coletiva), são conhecidas na literatura.

O uso de múltiplos robôs é muitas vezes sugerido por possuir vantagens sobre sistema de robô único. De fato, vários robôs cooperativos são capazes de completar tarefas complexas e com maior eficiência que um único robô [4].

Neste contexto, podem-se citar alguns trabalhos com robótica coletiva, do inglês “Swarm Robotics”, [5][6][7] entre outros.

Nesses trabalhos se 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. Teoria de sistemas multi-agentes é geralmente exigido para resolver problemas em ambientes dinâmicos e imprevisíveis, nestas circunstâncias a capacidade de aprender é particularmente importante para ambientes com mudanças rápidas [8].

A motivação e o conceito explorado nesse trabalho é o de inteligência coletiva, utilizando e comparando duas distintas estratégias. Nas quais a arquitetura utiliza a capacidade de evolução de um agente; com regiões e taxas de cooperação de memórias diferentes. 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 [9]. Ressalta-se que, todas as tomadas de decisões, auto-organizações, entre outras funcionalidades de todos os agentes ou robôs, tem processamento interno sem nenhum controle externo (ênfase de técnicas inspiradas em *Swarm Intelligence*).

Os conceitos citados serão contextualizados no ambiente de simulação proposto, no qual obstáculos dinâmicos surgem durante a trajetória, alvos fixos necessitam ser alcançados pelo agente móvel, e dados de exploração são 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, a priori, 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 e tomadas de decisões de forma hierárquica. Essas características serão necessárias para gerenciamento de ações. No nível mais alto a arquitetura HD-FCM apresenta um algoritmo bio-inspirado, inspirado na tarefa de coleta de alimentos por colônias de formigas [10], nas duas estratégias propostas. E, em especial, alguns conceitos de C-SLAM também são extraídos.

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 [11].

A construção da arquitetura de controle pode ser dividida em dois passos: no primeiro passo o controlador utilizará inicialmente conhecimento de baixo nível (virar a esquerda caso surja um obstáculo à direita), observa-se que o FCM clássico é atemporal e reativo (os conceitos de saída respondem diretamente aos conceitos de entrada); assim uma saída para essas limitações, está na detecção da ocorrência de eventos (surgimento de alvos ou obstáculos, os quais exigem dos controladores decisões hierárquicas). Um algoritmo de aprendizagem por reforço similar ao clássico proposto por [12], ou um algoritmo de aprendizagem adaptado de Hebb, podem ser utilizados para uma sintonia (ajuste fino) do modelo cognitivo em tempo de navegação; neste trabalho são usados Algoritmos de Aprendizagem Por Reforço (Q-Learning) adaptado por regras heurísticas [13]. Assim, devido à execução de funcionalidades diferentes e possivelmente conflitantes, uma arquitetura híbrida será desenvolvida inspirada na Arquitetura de subsunção. Porém, com o incremento de funcionalidades de forma gradativa, de forma similar ao trabalho de Braitenberg [14], neste trabalho, foram observadas e avaliadas as funções de baixo nível inicialmente. Primeiro somente desvio de obstáculos, depois adicionada a coleta de alvos por meio de camadas em níveis hierárquicos. Após essa etapa foi adicionado o Algoritmo de Aprendizado por Reforço com uma política baseada em regras. E, finalmente, duas estratégias de compartilhamento de dados de navegação.

Desse modo, as estratégias podem ser classificadas como técnicas de dois passos ou etapas. A primeira etapa o agente (robô) faz reconhecimento do cenário utilizando somente seus sensores e o conhecimento prévio da posição dos alvos fixos. A segunda etapa utiliza todas as recursividades do primeiro, entretanto, também utiliza dados da trajetória dos robôs anteriores (como memória de navegação), 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.

Este trabalho está dividido da seguinte forma: Seção 2 aborda fundamentos e cita alguns trabalhos com aplicações do

FCM na literatura. A Seção 3 apresenta alguns fundamentos de controle de robôs, e o desenvolvimento da arquitetura Subsunção HD-FCM. A seção 4 com resultados simulados, e a Seção 5 conclui e sugere futuros trabalhos.

II. FUNDAMENTOS

Mapas Cognitivos *Fuzzy* (FCM) e suas evoluções são sistemas não lineares dinâmicos para a modelagem de conhecimento causal. Eles combinam aspectos da Lógica *Fuzzy*, Redes Neurais Artificiais, Redes Semânticas, Sistemas Especialistas, não Lineares e Sistemas Dinâmicos. FCMs são capazes de modelar sistemas complexos e se aplicam a uma ampla gama de problemas em engenharia e áreas afins [15].

Diversos trabalhos e aplicações são encontrados na literatura como, por exemplo, os trabalhos de [16] na área médica, [17] navegação robótica, [13] em controle de processos, entre outros. Trabalhos específicos como métodos de treinamento da FCM [18], os mais recentes e completos são os trabalhos de [15] e [19]. Devido à dificuldade de tratamento dinâmico das informações, variações e ou evoluções do FCM surgiram na Literatura. Podem-se citar os trabalhos de [20] (*Rule Base FCM*) e o trabalho de [21] (*Fuzzy Time Cognitive Map – FTCM*), entre outros. E, os D-FCM como evoluções. Neste contexto pode-se citar os trabalhos de [13][22][23][24]. O trabalho de [19] e [25] complementa as citações, com diferentes evoluções dos FCM.

III. DESENVOLVIMENTO

Nos sistemas de controle dos robôs móveis, atualmente, utilizam-se técnicas de inteligência computacional tais como: Redes Neurais Artificiais, Lógica Nebulosa ou a combinação destas com outras técnicas inteligentes, em especial para ajuste ou otimização, como algoritmos genéticos, por exemplo. O uso dessas técnicas é devido a seres humanos serem capazes de 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 [26]. 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 [27]. Outra forma de aquisição de informação em sistemas computacionais inteligentes é por meio de dados históricos ou de operação através da aplicação de Redes Neurais Artificiais [28].

A. Arquitetura Subsunção HD-FCM

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 [11].

A arquitetura de Subsunção é a mais conhecida para agentes inteligentes e foi proposta por Brooks [11]. 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. Tem inspiração na neurobiologia, em especial, na sinergia que existe entre a sensação e a atuação de insetos, entre outras.

Deste modo, cada camada é capaz de inibir o comportamento das camadas abaixo dela. Nessa aplicação prioridade é desvio de obstáculos, encontrar alvos e se o caminho esteja livre é ativada uma ação de exploração, nesse caso é andar em linha reta. As funcionalidades e, consequentemente, as ações funcionam de modo hierárquico, entretanto o algoritmo de Aprendizagem por Reforço e o protocolo de comunicação entre agentes funcionam de modo paralelo. A hierarquia implementada foi desviar de obstáculos a de maior prioridade, seguida de coletar alvos e explorar o ambiente (em linha reta).

A figura 1 mostra a estratégia do controlador por meio de uma máquina de estados.

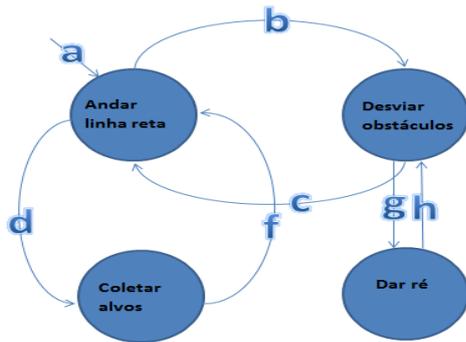


Fig. 1. HD-FCM cooperativa.

No modo geral, uma arquitetura híbrida visa ser adequado para a resolução de problemas complexos, atingindo metas ou objetivos de uma forma otimizada e eficiente [29].

A Figura 2 apresenta a arquitetura HD-FCM. A arquitetura proposta é apresentada de uma forma genérica, para ajudar o entendimento do HD-FCM. Cada bloco representa uma parte específica do sistema. O Sistema de Percepção simboliza os sensores; Sistema Estado Interno, a máquina de estados finitos; o Sistema de comportamento, o FCM; o sistema de aprendizagem, o algoritmo dinâmico de aprendizagem; do Meio Ambiente, a interação com o ambiente (percepção, planejamento e ações).

Por fim, o sistema motor, responsável pelos movimentos do agente e inferências sobre o ambiente de acordo com seu estado atual ou objetivo (evitar obstáculos, atingir os alvos ou compartilhar memória de navegação), sintonizado dinamicamente por um algoritmo de aprendizagem por reforço heurístico inspirado no trabalho clássico de Sutton e Barto [12] e, em especial, devido à inclusão de heurísticas [30].

A arquitetura HD-FCM, como mostra a figura 2, em resumo, combina diversas técnicas computacionais inteligentes (Lógica Fuzzy, Redes Neurais Artificiais, Teoria de Agentes, em especial Arquiteturas Computacionais Híbridas) e é orientada a eventos. Não é o escopo desse trabalho apresentar detalhes de desenvolvimento dessa arquitetura. Porém poderá ser conferida no trabalho de [31].

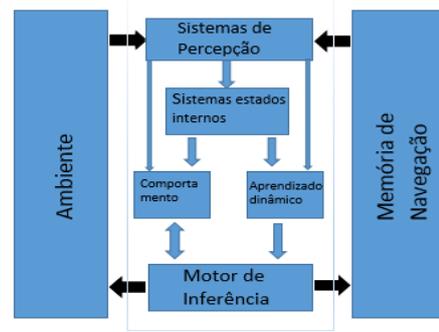


Fig. 2. Arquitetura HD-FCM.

Em resumo, o método proposto neste trabalho para construção de modelos cognitivos baseados em HD-FCM, utiliza vários conceitos e técnicas que estão na interseção de 3 áreas bases dos sistemas inteligentes. Da teoria de agentes inteligentes, 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.

Dos FCMs clássicos são herdadas as relações de causa e efeito (W1-W7) que nesse caso são responsáveis pelas ações de baixo nível (figura 3). Detalhes construtivos desse HD-FCM podem ser conferidos no trabalho de [32].

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 e os conceitos de atraso (O.R.-1) e (O.L.-1), e as relações WS1, WS2 e WS3 são relações que disparam a redução do efeito de “zig-zag” inserindo uma tendência de movimento (o agente pondera suas ações, levando em consideração tomadas de decisões anteriores para a atual) juntamente com os conceitos de fator de saída. WS6 representa a relação de seleção para a ativação do conceito de colisão. As relações WS7, WS8 e WS9 são conceitos e relações de seleção para utilizar informações de outros agentes, armazenados na memória do agente. E, desse modo, os conceitos *Collision* e *Memory navigation* são referentes a reversão do movimento na iminência de colisão e memória de navegação dos agentes anteriores. De um modo geral o HD-FCM é desenvolvido norteado pela arquitetura proposta.

Dois estratégias serão avaliadas nessa pesquisa, as estratégias têm inspiração no comportamento de formigas na busca de alimentos que através de feromônios deixados pelo caminho proporcionam o compartilhamento de uma memória de navegação que ao passar do tempo passa a ser otimizada [10]. Olhando pelo ponto de vista de técnicas de SLAM, esse trabalho utiliza conceitos de *Landmark* artificial (memória de rastro ou de tomadas de decisões) e resgate de memória de navegação [33]. Em resumo as técnicas operam de forma que o robô antecedente compartilha sua memória de navegação e é, a posteriori, utilizada pelo sequente, não como forma de sensores e sim de forma matemática.

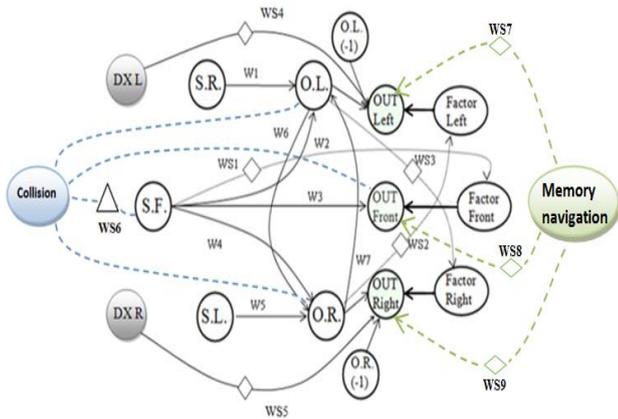


Fig. 3. HD-FCM-cooperativa (estratégia 2 – modificada).

As duas estratégias se diferem do seguinte modo: a primeira estratégia utiliza 95% das ações tomadas pelos HD-FCM e 5% da memória de navegação; já a segunda compartilha somente 1% somente a uma distância de 40 cm (em escala) antes do ponto considerado crítico da trajetória. Com isso o robô sucessor fica mais autônomo ganha uma maior autônomia e, nos cenários investigados, obtiveram melhores resultados, inclusive com uma pequena entrada de ruído nos sensores de entrada (para aproximar as simulações de situações reais). A diferença dos HD-FCM são as funções de seleção inseridas entre conceito de memória e as saídas (na versão inicial, não era necessária). Um ruído branco foi inserido na entrada dos sensores; na próxima seção serão apresentados os resultados das duas estratégias.

IV. RESULTADOS

Um ambiente é classificado como dinâmico quando existem objetos móveis na cena [33].

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 “o” representa obstáculos que surgem durante a navegação (obstáculos “inesperados”) do robô móvel, e finalmente o “▲” representa os alvos a serem coletados pelo robô

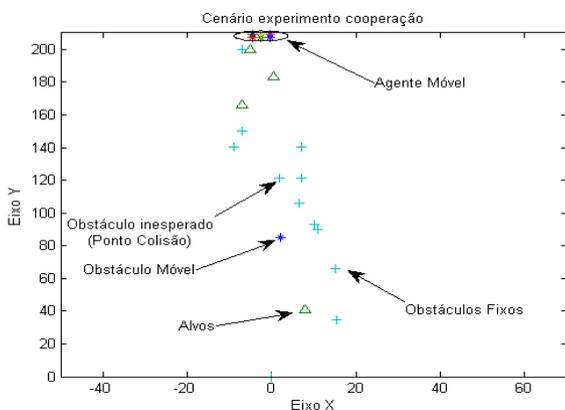


Fig. 4. Visão do Cenário (geral).

Um simulador com animação 2-D foi também desenvolvido para testar e validar o sistema de navegação desenvolvido.

Quando os ambientes são virtuais, apontam-se algumas vantagens. Como, torna-se mais fácil manter o foco e os objetivos nas tarefas em que se deseja estudar [34].

Nas simulações com obstáculos dinâmicos uma trilha ou rastro também é usado para mostrar a sequência de ações de direção e aceleração na trajetória.

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

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, o qual compartilha memória de navegação para agente seguinte das duas rodadas. A figura 7 destaca o ponto crítico que necessita de ação de frenagem e ré, para a primeira estratégia, não necessário na segunda rodada. De modo específico, essa figura também mostra as ações do segundo agente com as duas estratégias.

Como se pode observar, na primeira estratégia, que na segunda passagem, o agente móvel ainda quase colide com o mesmo obstáculo, mas consegue manobrar evitando a colisão. Já na terceira passagem com a “evolução” da trajetória anterior, o agente consegue desviar do obstáculo sem acionar o estado de ré

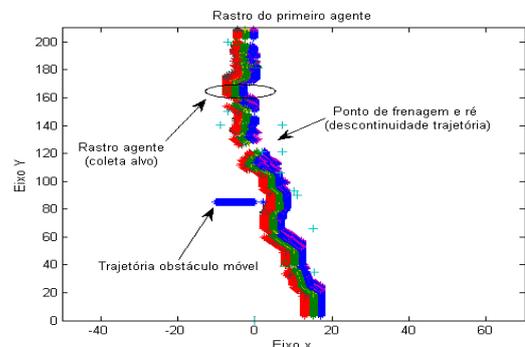


Fig. 5. Memória de navegação “rastro” primeiro agente nas duas estratégias.

O rastro do primeiro agente é considerado passo inicial ou passo 1 de ambas as estratégias

A figura 8 mostra que o terceiro agente (utilizando a estratégia 1) consegue executar uma trajetória sem dar ré, ou seja, tem uma melhor otimização durante a trajetória, devido aos dados históricos previamente compartilhados pelos agentes anteriores. Já na terceira passagem (figura 8b) com a “evolução” da trajetória anterior, o agente consegue desviar do obstáculo sem acionar o estado de ré.

A figura 9 mostra a sintonia dinâmica dos pesos das relações causais depois de superar o ponto crítico (rodada 3 para estratégia 1 e rodada 2 para estratégia 2). Observa-se que: existe um ajuste suave nas duas situações e pouca variação dos sensores, entretanto não foi objetivo desse trabalho mostrar a

evolução dos ajustes em cada rodada, somente uma rápida noção da sintonia dinâmica.

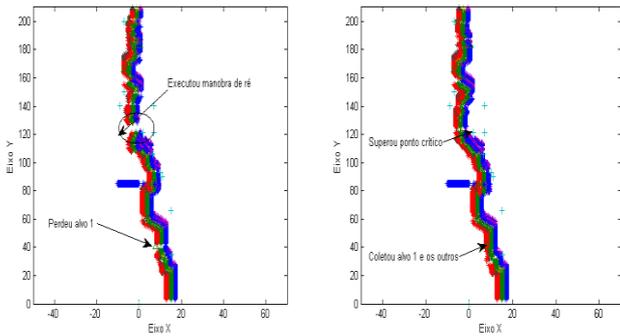


Fig. 6. Memória de navegação “rastros” segundo agente ampliada no ponto crítico (estratégia 1 e 2).

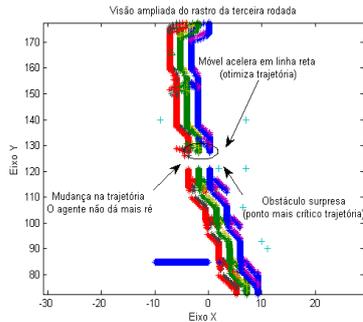


Fig. 7. Visão ampliada da memória de navegação “rastros” terceiro agente ampliada no ponto crítico da estratégia 1.

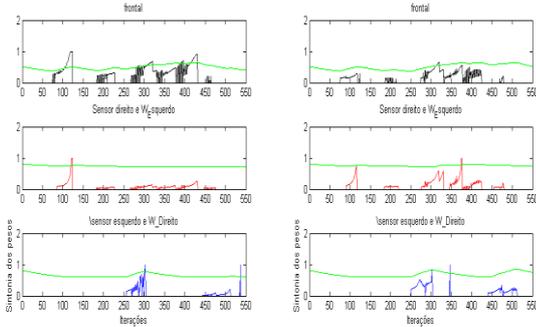


Fig. 8. Ajuste dinâmico dos sensores.

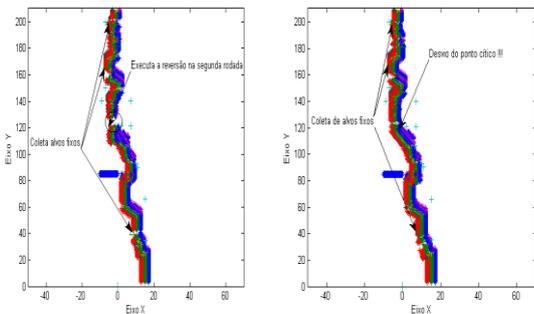


Fig. 9. Memória de navegação “rastros” segundo agente ampliada no ponto crítico (estratégia 1 e 2) com ruído branco nos sensores

As figuras 10 e 11 mostram a evolução da estratégia num cenário com ruído, nesse caso como o primeiro passo é praticamente o mesmo, somente os resultados serão apresentados. Entretanto, o mesmo comportamento é inicialmente observado no cenário sem ruído. No segundo passo a estratégia 2 executa a reversão (ré) enquanto que a primeira não.

Entretanto, no segundo passo, a estratégia 1 não executa a reversão no ponto crítico. Porém, perde um alvo e bate em um obstáculo. E, as simulações mostraram que essa estratégia é mais suscetível ao ruído. Como mostra a figura 11.

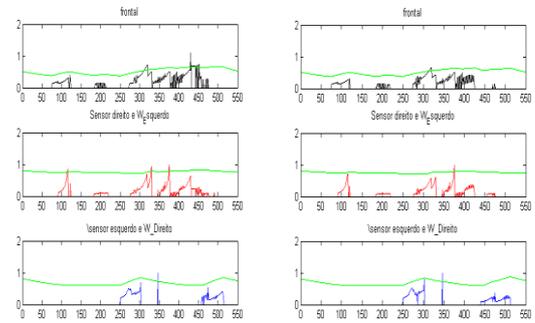


Fig. 10. Ajuste dinâmico dos sensores.

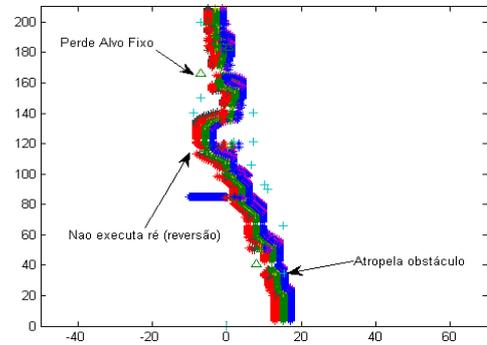


Fig. 11. Memória de navegação “rastros” do terceiro agente na estratégia 1 com ruído branco e erros na trajetória.

V. CONCLUSÕES

Devido aos resultados simulados, ainda que iniciais, em especial, com condições praticamente ideais (somente, com a presença de ruídos bem pequenos da ordem de 5%, nos últimos experimentos ou sinais fantasmas, como por exemplo, nos sensores de ultrassom), a proposta do controlador atingiu os resultados esperados para robôs autônomos e/ou sistemas multi-agentes.

Neste contexto, as duas estratégias das arquiteturas HD-FCM inspiradas na arquitetura clássica de Subsunção mostrou capacidade de aprendizado, adaptação e cooperação que habilitaram o agente ser racional, durante navegação as inferências determinaram sequências de ações que permitiram alcançar seus objetivos (explorar: desviar obstáculos e coletar alvos). Ressalta-se a otimização, por meio da cooperação entre os agentes, em especial, na terceira rodada, para estratégia 1 e

na segunda rodada para estratégia 2, não necessitou ré ou reversão no ponto mais crítico, desse modo apresentando significativa vantagem sobre a estratégia 1 (inicial). Ressalta-se que: com a utilização de algoritmo A.R. a interação com ambiente pode-se obter tomadas de decisões sintonizadas, por conseguinte, atenuadas às incertezas das ações de baixo nível.

Pode-se observar nos experimentos com a inserção de um ruído mínimo nos sensores de entrada. Que: a estratégia 2 se mostrou em vantagem devido a nenhuma colisão e antecipação de um passo ou rodada em relação à estratégia 1. Além dos erros observados na figura 11. Outro fato negativo para a estratégia 1 foi a perda do primeiro alvo já na segunda rodada.

Futuros trabalhos endereçam a construção de mais cenários com maior complexidade. Investigar o comportamento dos controladores na presença de ruídos com maior intensidade, e alterações no cenário, na rodada seguinte, que neste trabalho, apesar da presença de elementos dinâmicos eles (cenários) se repetem. Melhoria na cinemática dos agentes ou robôs móveis, para deixar a movimentação mais realística, análises quantitativas (estatísticas) quanto ao desempenho das estratégias. E, finalmente, embarcar em plataformas robóticas reais.

REFERÊNCIAS

- [1] Maki, T.; Kume, A.; Ura, T.; Sakamaki, T. and Suzuki, H., "Autonomous detection and volume determination of tubeworm colonies from underwater robotic surveys", OCEANS 2010 IEEE - Sydney, pp.1,8, 24-27 May. 2010.
- [2] Vernon D.; Metta, G. and Sandini, G., "A Survey of Artificial Cognitive Systems: Implications for the Autonomous Development of Mental Capabilities", in Computational Agents, IEEE Transactions on Evolutionary Computation, special issue on Autonomous Mental Development, vol. 11, no. 2, pp. 151-180, 2007
- [3] Birk, A.; Stoyanov, T.; Nevatia, Y.; Ambrus, R. and Pathak, K., "Terrain Classification for Autonomous Robot Mobility: from Safety, Security Rescue Robotics to Planetary Exploration" in Planetary Rovers Workshop, International Conference on Robotics and Automation (ICRA). IEEE, 2008.
- [4] De Rango, F. and Palmieri, N., "ATRC: A swarm-based robot team coordination protocol for mine detection and unknown space discovery," Performance Evaluation of Computer and Telecommunication Systems (SPECTS), 2012 International Symposium on. pp.1,7, 8-11 July 2012
- [5] Bayindir L. and Sahin E., "A Review of Studies in Swarm Robotics", The Turkish Journal of Electrical Engineering & Computer Sciences, vol. 15, no. 2, 2007, pp. 115-147. 2007.
- [6] Parker L. E., "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, 2008.
- [7] Payton, D.; Estkowski, R. and Howard, M., "Compound Behaviors in Pheromone Robotics", Robotics and Autonomous Systems, vol. 44, pp. 229-240. 2003.
- [8] Wooldridge, M.J. and Jennings, N.R. "Intelligent Agents: Theory and Practice", Knowledge Engineering Review Vol. 10 No. 2 Cambridge University Press pp. 115-152. 1995.
- [9] De Castro, L. N. "Fundamentals of Natural Computing: An overview". Physics of Life Reviews, vol. 4, pp. 1-36, 2007.
- [10] Labella T. H., Dorigo M. and Deneubourg J.-L., "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. 2006.
- [11] Brooks, R. A., "A robust layered control system for a mobile robot", IEEE Journal of Robotics and Automation, vol. 2, no. 1, pp. 14-23, Mar. 1986.
- [12] Sutton, R.; Barto, A. "Reinforcement Learning: an Introduction. Cambridge: MIT Press. 1998
- [13] Mendonça, M.; Angélico, B.A.; Arruda, L.V.R. and Neves, F.J. "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. 2011.
- [14] Braitenberg V., "Vehicles: Experiments in Synthetic Psychology", The MIT Press. 1986.
- [15] Papageorgiou, E.I. "Learning Algorithms for Fuzzy Cognitive Maps". IEEE Transactions ON Systems and Cybernetics. Part C: Applications and Reviews. Vol 42 pag 150-163. March. 2012.
- [16] Stylios, C. D.; Georgeopulos, V.C.; Malandraki, G.A. and Chouliara S. "Fuzzy cognitive map architectures for medical decision support systems. Applied Soft Computing, v. 8, n. 3, p. 1243-1251, Jun. 2008.
- [17] Pipe, A. G. "An architecture for building "potential field" cognitive maps in mobile robot navigation". Adaptive Behavior, vol. 8, no. 2, pp. 173-203, 2000.
- [18] Glykas, M., "Fuzzy Cognitive Maps Advances in Theory, Methodologies, Tools and Applications". Greece Springer. 2010.
- [19] Papageorgiou E.I. and Salmeron J.L., "A Review of Fuzzy Cognitive Maps Research During the Last Decade". Fuzzy Systems, IEEE Transactions on, vol.21, no.1, pp.66-79, Feb. 2013.
- [20] Carvalho, J.P.B., "Mapas cognitivos baseados em regras difusas: modelação e simulação da dinâmica de sistemas qualitativos". Dissertação de doutorado. Universidade Técnica de Lisboa, Lisboa, Portugal. 2001.
- [21] Park, K. S. and Kim, S. H., "Fuzzy cognitive maps considering time relationships". International Journal of Human-Computer Studies, v. 42, n. 2, p. 157-168, Feb. 1995.
- [22] Miao, Y.; Liu, Z.Q.; Siew, C.K. and Miao, C.Y. "Dynamical cognitive network — an extension of fuzzy cognitive". IEEE Trans. on Fuzzy Systems, vol. 9, no. 5, pp. 760-770. 2001.
- [23] Miao, Y.; Liu, Z.Q.; Siew, C.K. and Miao, C.Y. "Transformation of cognitive maps". IEEE Trans-actions on Fuzzy Systems, vol. 18, no. 1, pp. 114-124, Feb. 2010.
- [24] Koulouriotis, D. E.; Diakoulakis I.E.; Emiris D.M. and Zopounidis C.D., "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. 2005.
- [25] Acampora, G and Loia, V. On the temporal granularity in fuzzy cognitive maps. IEEE Transactions on fuzzy systems, vol. 19, no. 6, pp. 1040-1057. 2011.
- [26] Zadeh, L.A. "Fuzzy algorithms", Info. & Ctl. vol. 12, pp. 94-102. 1968.
- [27] Passino, M. K.; Yourkovich, S. "Fuzzy control". Menlo Park: Addison-Wesley. 1997.
- [28] Haykin, S., "Redes neurais, princípios e prática", 2. ed. São Paulo: Bookman. 2000.
- [29] Costa, E.D.S. and Gouvea, M.M., "Autonomous Navigation in Dynamic Environments with Reinforcement Learning and Heuristic", Machine Learning and Applications (ICMLA), Ninth International Conference on, pp.37-42, 12-14 Dec. 2010.
- [30] Romero, R. A. F. "Robótica Móvel". LTC., VitalBook. 2014.
- [31] Mendonça, M., Arruda, L.V.R., Chrun, I. R. e Da Silva, E. S. "Hybrid Dynamic Fuzzy Cognitive Maps Evolution for Autonomous Navigation System". In Press: FUZZ-IEEE 2015 (a ser realizado em Agosto de 2015).
- [32] Papageorgiou, E. I. "Fuzzy Cognitive Maps for Applied Sciences and Engineering: From Fundamentals to Extensions and Learning Algorithms". Springer-Verlag Berlin Heidelberg. 2014. ISSN 1868-4394
- [33] Bighetli J. A. "Navegação de Robôs em Ambientes Internos Usando Slam". Dissertação de Mestrado. Unesp-Bauru. 2011.
- [34] Gudwin, R. R. "Arquiteturas de Criaturas Artificiais. Simpósio Brasileiro de Automação Inteligente". São João Del Rei. pp 943-958. (2011).