

APLICAÇÃO DE CONTROLADOR FUZZY PARA NAVEGAÇÃO MÓVEL AUTÔNOMA NA AGRICULTURA

MÁRCIO MENDONÇA, WAGNER F. GODOY, RODRIGO H. C. PALÁCIOS, CARLOS RENATO ALVES OLIVEIRA, JOSÉ AUGUSTO FABRI, EMERSON RAVAZZI*

* *Universidade Tecnológica Federal do Paraná*
Av. Alberto Carazzai, 1640, Centro, 86.300-000
Cornélio Procopio, PR, Brasil

Email: mendonca@utfpr.edu.br, wagnergodoy@utfpr.edu.br, rodrigopalacios@utfpr.edu.br, carlosoliver555@gmail.com, fabri@utfpr.edu.br, emersonr@utfpr.edu.br

Abstract— The employment and incorporation of new technologies in the agriculture field allows a new meaning to productivity and efficiency. Among its various pillars, autonomous robotics promotes improvements in production, through increased safety in the coexistence between robots and humans, in the execution of various activities. This work presents the use of a low cost prototype controlled by two Fuzzy techniques. The proposed model allows representing the dynamic behaviour of a mobile robot in presence of changes in the environment. A Hierarchical Weighted Fuzzy Logic Controller composes the second navigation system. Simulation results are presented allowing a comparison among both systems and showing the ability of the mobile robot to navigate among obstacles in different scenarios (navigation environment).

Keywords— Fuzzy Cognitive Maps, Autonomous Navigation Embedded, Intelligent dynamic decision systems

Resumo— O emprego e a incorporação de novas tecnologias na agricultura permitem um novo significado a produtividade e eficiência no campo. Dentre seus diversos pilares, a robótica autônoma promove melhorias na produção, por meio do aumento de segurança na coexistência entre robôs e seres humanos, na execução de diversas atividades. Este trabalho apresenta o emprego de um protótipo de baixo custo controlado por duas técnicas Fuzzy. O modelo proposto permite representar o comportamento dinâmico do robô móvel na presença de mudanças no ambiente. Um Controlador Fuzzy Ponderado Hierárquico compõe o sistema de navegação. Resultados da simulação permitem uma comparação entre os dois sistemas, demonstrando a capacidade do robô móvel navegar entre obstáculos em diferentes cenários (ambiente de navegação).

Palavras-chave— Mapas Cognitivos Fuzzy; Navegação Autônoma Embarcada; Sistemas inteligentes de decisão dinâmica

1 Introdução

A robótica é uma área multidisciplinar que emprega técnicas de controle, inteligência artificial, mecânica e eletrônica, entre outras, preferencialmente com ações de controle (Mendonça et al., 2019).

Nos últimos anos, os problemas envolvendo tomada de decisão têm sido uma área de pesquisa ativa devido ao seu impacto na resolução de problemas no mundo real (Siciliano and Khatib, 2016). A tomada de decisão pode ser definida informalmente como a tarefa de determinar e selecionar as ações adequadas que permitem a solução de um problema específico. Decidir implica que existam escolhas alternativas a serem consideradas e que o conhecimento dos especialistas e as observações dinâmicas dos sistemas podem ser usadas para melhorar essas escolhas (Nápoles et al., 2020).

O termo autonomia se refere não apenas à capacidade de ação e decisão de um sistema de controle artificial, mas também à capacidade de adaptação do mecanismo de tomada de decisão (Mataric, 2007) e (Siciliano and Khatib, 2016). De outra forma, os Sistemas Autônomos têm a capacidade de realizar tarefas complexas com alto grau de sucesso, sem intervenção humana

(Sharma, 2021). Há um interesse crescente no desenvolvimento de robôs e veículos autônomos (agentes), principalmente devido à grande diversidade de tarefas que podem ser realizadas por eles, principalmente aquelas que colocam em risco a saúde humana e/ou o meio ambiente (Shaikh et al., 2013). Como exemplos, destacam-se trabalhos sobre robô móvel autônomo para uso em soldagem (Schroth et al., 2009), exploração de ambientes (Salan et al., 2015), subaquático (Spears et al., 2014), entre outros.

Uma dificuldade na área de robótica móvel autônoma, ou agentes móveis autônomos, é a necessidade de aprender uma estratégia de navegação por meio de sua interação com o ambiente. Em geral, a área de navegação é grande e diversificada, há uma variedade de situações que necessitam de tomada de decisão ou ações de controle e o ambiente pode sofrer mudanças repentinas (Cliff, 2003). Nesse contexto, a dificuldade de desenvolver controladores para agentes móveis (robôs) é a iteração entre dois sistemas dinâmicos: robô e ambiente. Mesmo no caso de ambientes estáticos, como é o caso deste trabalho, do ponto de vista do robô o ambiente é dinâmico.

A motivação deste trabalho é propor o desenvolvimento de dois sistemas autônomos de navegação que utilizem conhecimento heurístico sobre

o comportamento do robô/veículo ou agente em diferentes situações. O primeiro sistema é modelado por Mapas Cognitivos Fuzzy (FCM) e os demais são baseados em um Controlador Lógico Fuzzy (FLC).

O principal objetivo deste trabalho é desenvolver e comparar os dois sistemas autônomos de navegação, por meio de simulações. Foi analisada a capacidade de ambos os sistemas de tomada de decisões sequenciais dinâmicas para se mover pelo ambiente e, às vezes, para alterar a trajetória devido a um evento (alcançar o alvo e evitar obstáculos). Além disso, ambos os sistemas devem agregar conhecimento discreto e contínuo sobre navegação.

Especificamente para o primeiro sistema, uma Arquitetura Híbrida baseada em Mapas Cognitivos Fuzzy Dinâmicos Híbridos é utilizada para modelar um sistema de navegação autônoma com diferentes objetivos em distintos cenários, tais como: evitar obstáculos, explorar e alcançar alvos. Este novo tipo de FCM possui aprendizado dinâmico e é suportado por uma máquina de estados que garante mudanças estruturais do FCM sob diferentes objetivos. Um FCM semelhante, denominado FCM Dinâmico (D-FCM) foi apresentado em (Kostiadis et al., 2000), no qual os conceitos e relacionamentos do D-FCM são modificados a partir de decisões orientadas por eventos modelados por regras.

Outra contribuição deste trabalho é construir um protótipo do robô, apresentado na Figura 1, e comparar os dois sistemas de navegação autônomos em um robô móvel real. Este robô móvel é equipado com dois motores de passo, um microcontrolador Arduino e sensores de ultrassom.

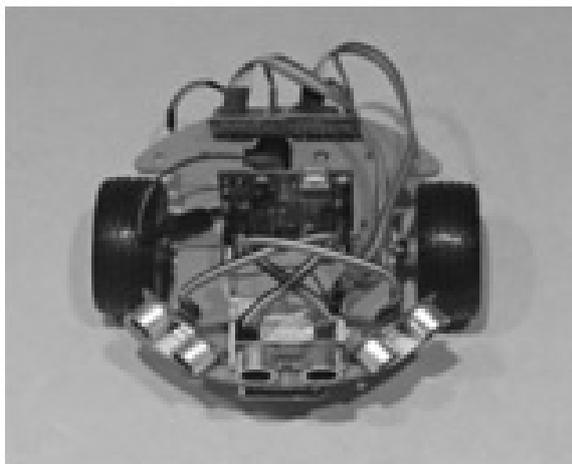


Figura 1: Robô sketch

Este artigo está organizado da seguinte forma: na Seção 2 é apresentada um breve descritivo das aplicações de robótica autônoma, na Seção 3 são discutidos os conceitos gerais sobre mapas cognitivos Fuzzy. Na Seção 4 são discutidos os aspectos

gerais para desenvolvimento de um sistema de navegação autônoma. Discussões sobre a metodologia proposta para geração dos dados utilizados neste trabalho e parâmetros de configuração empregados para as simulações são apresentadas na Seção 5. Finalmente, na Seção 6, as conclusões finais são abordadas.

2 Aplicações de Robótica Autônoma na Agricultura

Com a tendência do aumento de produção e maior necessidade de agilidade no trabalho, criou-se uma dependência de mão-de-obra em um cenário cada mais escasso de recursos humanos na agricultura. Devido a este fator de escassez, empresas estão apostando cada vez mais na robótica aplicada na agricultura para realizar os trabalhos de campo (Sharma, 2021).

A robótica na agricultura tem como principal objetivo o aumento da precisão de resultados, rapidez no processo de tomada de decisões e principalmente o aumento do rendimento operacional, fatores estes que impactam diretamente na competitividade de uma operação agrícola em um contexto que exige cada vez mais aumento de produtividade e aproveitamento sustentável do campo (Sharma, 2021).

Neste cenário, destacam-se no emprego da robótica aplicações em campos abertos e ambientes fechados como estufas e armazéns em operações de controle e gerenciamento de pragas e doenças, colheita de frutos e vegetais, irrigação, pulverização e coleta de dados relacionados a estimativa de safras, entre outros. Como um exemplo de investimento, a empresa *Saga Robotics* investiu cerca de R\$ 61,5 milhões para o impulsionamento dos seus robôs autônomos na agricultura, por meio de métodos avançados de navegação e inteligência artificial, conforme mostrado na Figura 2.



Figura 2: Exemplo de aplicação de robótica autônoma na agricultura

Outro projeto vem da empresa *Webull Intelligent Technology*, que criou um protótipo de fazenda *online* também conhecido como *Ghost Farm*. O projeto emprega tecnologias autônomas

em um pomar que cultiva pêssegos, utilizando diversas tecnologias de manejo de forma totalmente *online*, por meio de sensores e *softwares* de inteligência artificial e visão computacional, conforme Figura 3. A utilização do robô autônomo permite o aumento da renda do agricultor e converte a produção agrícola de forma eficiente e inteligente.



Figura 3: Sistemas autônomos integrados - Webull

Soluções através de computação em nuvem controlam veículos não tripulados e podem realizar diversas tarefas no campo, sendo que um robô autônomo pode substituir cerca de 70% do trabalho manual (Sharma, 2021).

3 Mapas Cognitivos Fuzzy - Uma Breve Descrição

Os FCMs foram originalmente introduzidos por Kosko (Kosko, 1986), como uma metodologia baseada em conhecimento adequada para modelagem de sistemas dinâmicos. Em outras palavras, FCM é uma metodologia para representar problemas do mundo real em termos de conceitos e relações causais entre eles. Os conceitos usados por um tomador de decisão são representados como nós, as relações causais entre esses conceitos são representadas como arestas direcionadas e os conceitos são considerados como variáveis do sistema (Papageorgiou and Froelich, 2012). Portanto, um FCM é um grafo direcionado com sinal fuzzy e *feedback* que modela sistemas complexos como uma coleção de conceitos e relações causais entre conceitos (Ahmadi et al., 2014). Podem ser encontrados na literatura dois tipos de FCM, cíclicos e acíclicos (Papageorgiou, 2014). Neste trabalho, é utilizado um FCM acíclico e manual (os pesos das relações causais são determinados por especialistas).

O modelo matemático FCM foi adaptado para

inclusão de incerteza lógica Fuzzy por Kosko (Kosko, 1986), gerando FCM difundidos. O FCM usa uma representação de conhecimento estruturada por meio de relações causais calculadas a partir de operações matriciais, ao contrário de muitos sistemas inteligentes cuja representação de conhecimento é baseada em regras se-então. O processo de inferência calculado pelas Equações 1 e 2

$$A_i = f\left(\sum_j \left[A_j^{n_{j \neq i}} \right] \right) \cdot W_{ji} \quad (1)$$

onde k é o contador de iterações, n é o número de nós no grafo, W_{ij} é o peso do arco que conecta o conceito C_j e C_i , A_i é o valor do conceito (C_i) na interação atual e a função $f(\cdot)$ é uma função do tipo sigmoide:

$$f(x) = \frac{1}{1 + e^{-\lambda x}} \quad (2)$$

A estrutura do FCM é construída a partir do conhecimento de especialistas e, posteriormente, pode ser ajustada por métodos heurísticos, algoritmo genético, algoritmos de enxame, entre outras técnicas. Apesar da etapa de ajuste, os modelos de inferência baseados em FCM carecem de robustez na presença de modificações dinâmicas não modeladas, devido à sua representação rígida do conhecimento por meio de operação gráfica e matricial (Acampora and Loia, 2011).

Para contornar este problema, este artigo desenvolve um novo tipo de FCM em que sua estrutura muda de acordo com os objetivos atuais do modelo, como atingir o alvo e evitar obstáculos a um sistema de navegação baseado em FCM. Desta forma, o modelo de Mapa Cognitivo Fuzzy Híbrido-Dinâmico é capaz de adquirir e utilizar dinamicamente o conhecimento heurístico. O HD-FCM e sua aplicação na navegação autônoma são apresentados nas próximas seções.

Alguns trabalhos relacionados, que utilizam mapas cognitivos na área de pesquisa em robótica móvel, podem ser encontrados na literatura. Dentre eles, pode-se citar o trabalho em (Min et al., 2006) que utiliza o FCM probabilístico na tomada de decisão de um time de futebol de robôs. Essas ações estão relacionadas ao comportamento da equipe, como chutar a bola na presença de adversários. O FCM probabilístico agrega uma função de verossimilhança para atualizar os conceitos do mapa.

Outras variações dos Mapas Cognitivos Fuzzy que se preocupam com a representação rígida do conhecimento são conhecidas na literatura: E-FCM (*Extended-Fuzzy Cognitive Maps*) (Hagiwara, 1992), RB-FCM (*Rule Based Fuzzy Cognitive Maps*) (Carvalho and Tome, 2000), DCN (*Dynamic Cognitive Network*) (Kostiadis et al., 2000) e (Miao et al., 2010), Mapas Cognitivos Fuzzy com Granularidade Temporal

(Acampora and Loia, 2011), Mapas Cognitivos Dinâmicos-Fuzzy (Mendonça et al., 2019) e (Ahmed and Hesham, 2010), Redes Cognitivas Rough (Nápoles et al., 2020), e outros. Um levantamento recente com grandes variações do FCM clássico nos últimos anos que sugere baixa complexidade computacional é apresentado por (Papageorgiou and Salmeron, 2013).

4 Desenvolvimento dos Sistemas de Navegação Autônoma

A arquitetura de controladores de agentes adotada neste trabalho é inspirada na Arquitetura de Subsunção (Mataric, 2007), que permite o desenvolvimento gradual de ambos os sistemas de navegação, partindo de um modelo simples com uma ou poucas funcionalidades e adicionando gradualmente novos objetivos para melhorar a exploração capacidade do agente.

No entanto, o agente (robô móvel) deve navegar em um ambiente semi-desconhecido, tendo apenas informações, a priori, sobre a posição do alvo no ambiente. Em resumo, apenas a posição do alvo e do agente inicial são conhecidas. O robô pode implementar apenas ações de navegação usuais como avançar, virar à direita e/ou virar à esquerda. O robô deve ter a capacidade de se adaptar às mudanças ambientais de acordo com a intensidade das medições do sensor, utilizando algum algoritmo de aprendizado. A Figura 4 mostra o robô e o alvo inseridos em um ambiente (cenário). Também mostra a pose (ângulo e posições x, y) do robô no cenário com as distâncias latitudinais e longitudinais entre o robô e o alvo.

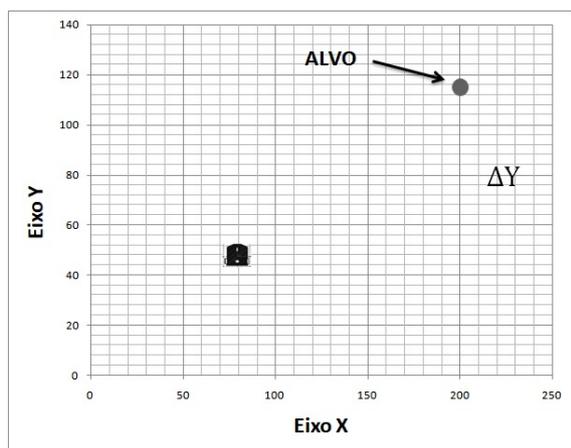


Figura 4: Cenário - distância

4.1 Sistema de Navegação HD-FCM

Dois FCMs apresentados nas Figuras 5 e 6 são desenvolvidos para realizar duas tarefas do robô: atingir os alvos e desviar dos obstáculos. Observe que ambos os FCMs possuem os mesmos conceitos

de saída (LW e RW) que correspondem respectivamente ao número de pulsos a serem aplicados nas rodas esquerda (PE) e direita (PD). No entanto, os conceitos de entrada desses FCMs são diferentes.

Na Figura 5, DSX é a distância lateral entre o robô e o alvo, e DSY é a distância frontal ao alvo (correspondente a ΔY , medido no eixo vertical). Se o alvo estiver localizado à esquerda do robô, DSX é negativo e, se estiver localizado na parte traseira do robô, DSY é negativo. Todos os pesos ($W1 - 3$ a $W2 - 4$) são números fuzzy que são normalizados no intervalo $[-1, 1]$.

A Figura 6 mostra o robô (agente) para o modelo HD-FCM para desvio de obstáculos. Os conceitos de entrada são SE (sensor esquerdo), SD (sensor direito) e SF (sensor frontal). Os valores desses conceitos são as leituras dos sensores correspondentes e medem a distância que o móvel está do obstáculo. Como um número fuzzy, esses valores são normalizados no intervalo $[0, 1]$. Também mostra os conceitos e relações para evitar obstáculos. Em resumo, os pesos $W1 - 4$ e $W3 - 5$ são positivos; caso contrário, os pesos $W3 - 4$ e $W1 - 5$ são negativos. O sinal e o valor das relações causais dependem da intensidade e influências entre os respectivos conceitos. Esses valores são necessários para manobras de evasão. Os pesos $W2 - 4$ e $W2 - 5$ conectados aos sensores frontais e rodas possuem valores negativos, quando o obstáculo está próximo ao robô desacelera. Esses pesos são ajustados usando o aprendizado Hebb, semelhante ao FCM1.

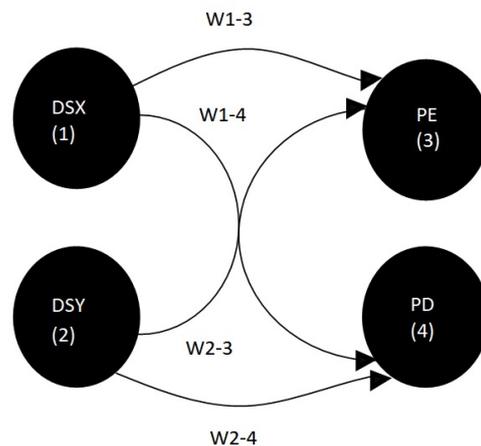


Figura 5: Tarefa - atingir alvos

Todos os pesos em ambos HD-FCM são ajustados heurísticamente de forma *off-line* da seguinte forma: após a determinação do sinal causal, os valores dos pesos foram inicializados em $+0,5$ ou $-0,5$ (dependendo da causalidade entre os conceitos). Esses pesos iniciais para os HD-FCMs são mostrados nas matrizes 3 e 4.

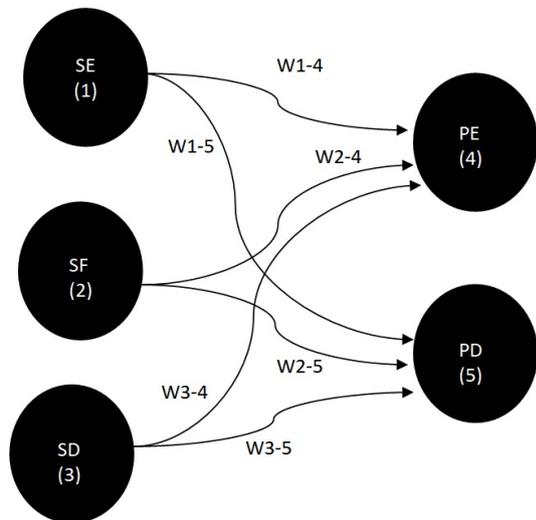


Figura 6: Tarefa - desviar dos obstáculos

$$w_{HD-FCM1} = \begin{vmatrix} 0 & 0 & 0.8 & -0.8 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{vmatrix} \quad (3)$$

$$w_{HD-FCM2} = \begin{vmatrix} 0 & 0 & 0 & 1 & -1 \\ 0 & 0 & 0 & 0.15 & 0.15 \\ 0 & 0 & 0 & -0.85 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{vmatrix} \quad (4)$$

Após esta etapa, observando-se o comportamento dinâmico do robô móvel, os valores dos pesos finais são calculados aplicando-se um algoritmo de aprendizado de Hebb. Esses valores finais dos pesos variam em torno dos valores iniciais. O processo é repetitivo e exaustivo, pois diferentes valores são somados e subtraídos do valor inicial para determinar os pesos finais.

Uma decisão deve ser tomada quando o robô muda seu objetivo. Para alterar a tarefa (objetivos móveis) é necessário mudar de FCM1 para FCM2. Uma máquina de estados finitos é utilizada pela parte deliberativa da arquitetura. A comutação é feita dinamicamente de acordo com a ocorrência de eventos específicos, a princípio o robô irá em direção ao alvo, porém, altera o modelo FCM se houver um obstáculo a uma distância de 15 cm é detectado. A faixa de detecção de distância é de 0 a 15 cm.

O vocabulário do estado da máquina é apresentado na Figura 7 é: (a) Iniciar máquina para atingir alvos; (b) Mude o FCM para evitar obstáculos e; (c) retorne a Máquina para atingir os alvos novamente.

Em suma, a arquitetura híbrida busca ser adequada para resolver problemas complexos, como atingir metas entre outros, de forma ótima e

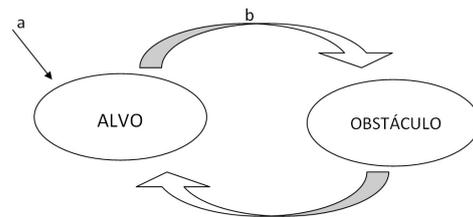


Figura 7: Vocabulário de estado da máquina

eficiente, considerando a dinamicidade do ambiente, exigindo uma resposta rápida (usando reatividade) (Mendonça et al., 2019; Hendriks and Lyons, 1994; Policastro et al., 2007). Nesse contexto, a Figura 8 mostra brevemente os conceitos das demais áreas utilizadas para aprimorar a evolução do FCM clássico para o HD-FCM.

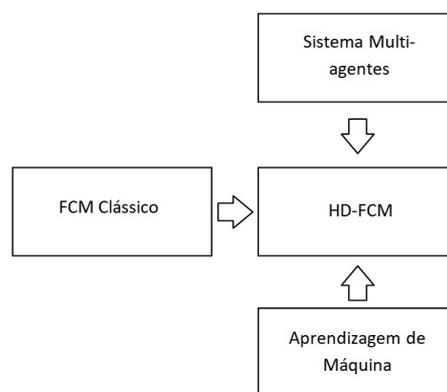


Figura 8: Áreas de pesquisa combinadas para geração do modelo do HD-FCM

4.2 Sistema de Navegação HW-FLC

Um Controlador Lógico Fuzzy Ponderado Hierárquico (HW-FLC) é usado como base para o projeto do segundo sistema autônomo de navegação (Li-Xin, 1999). O HW-FLC é composto por duas bases de regras, cada uma relacionada aos objetivos do robô móvel: atingir o alvo e evitar obstáculos.

A primeira base de regras, denominada Fuzzy I, visa determinar a rota mais curta entre o ponto de partida e o destino. Esta base de regras Fuzzy é composta por 48 regras cujos antecedentes estão relacionados às distâncias lateral e frontal entre o robô e o alvo (ΔX e ΔY na Figura 4), e as regras consequentes são os pulsos a serem aplicados nas rodas esquerda e direita do móvel. Fuzzy I desempenha o mesmo papel do modelo HD-FCM 1 apresentado na Figura 5.

Quando os sensores detectam um obstáculo, o controlador Fuzzy hierárquico prioriza a evitação de obstáculos através da segunda base de regras

(Fuzzy II). O Fuzzy II pretende apenas evitar obstáculos. As regras antecedentes são os sinais medidos pelos sensores (esquerdo, direito e frontal) e os consequentes são os pulsos a serem aplicados nas rodas esquerda e direita. Esta base de regras difusa tem 24 regras. O sistema de navegação HW-FLC usa a mesma máquina de estados finitos dada na Figura 7 para alternar (tomar uma decisão) entre as bases de regras Fuzzy I e Fuzzy II.

Não é escopo deste trabalho mostrar o desenvolvimento do HW-Fuzzy, apenas algumas de suas características relevantes são apresentadas. Uma explicação detalhada sobre HW-FLC pode ser encontrada em (Mendonça et al., 2014).

5 Resultados

Um simulador bidimensional foi implementado em Matlab para estudar o comportamento dinâmico do agente móvel acionado por ambos os sistemas de navegação autônomos. A escala utilizada para o cenário simulado é 1:100. Russel e Norvig (Sharma, 2021) sugerem que para se considerar um agente autônomo, é necessário ter sucesso em pelo menos três simulações diferentes.

As simulações comparam HD-FCM e HW-FLC com as mesmas condições (cenários) e com a mesma base de conhecimento. As duas arquiteturas são hierárquicas, porém apenas o HD-FCM não é arquitetura puramente reativa devido à capacidade de aprendizado do algoritmo de Hebb.

As simulações apresentadas na Figura 9 apresentam certo grau de dificuldade para atingir o alvo, uma vez que os obstáculos estão distribuídos no trajeto em espiral. Outra dificuldade desse problema é a tomada de decisão sequencial, ou seja, um erro na segunda manobra pode influenciar na terceira e assim sucessivamente (Mendonça et al., 2013).



Figura 9: Simulação - *target* e obstáculos em formato espiral - HD-FCM e HW-FLC

Nestas simulações, o HD-FCM precisou de 1962 passos, com precisão de 9,67 cm, enquanto o HW-FLC utilizou 1960 passos com precisão de 9,67 cm (atingindo o alvo com a mesma precisão).

Foi utilizado o mesmo hardware para os testes de tempo. Mais detalhes são mostrados na tabela 1.

Tabela 1: Resultados Simulação HD-FCM x HW-FLC

HD-FCM		HW-FLC	
Passos	1962	Passos	1960
Erro	9,67 cm	Erro	9,67 cm
Tempo	47 s	Tempo	49,4 s

O tempo de simulação do cenário mais complexo sugeriu uma pequena vantagem de 2,4 segundos para o HD-FCM, 5% mais rápido em comparação ao HW-FLC, sugerindo uma menor complexidade computacional, proporcionando uma vantagem significativa na robótica móvel considerando as mesmas dificuldades, modelo matemático, cenário e base computacional.

De acordo com os resultados simulados, o número de pulsos e a precisão são semelhantes para ambos os sistemas autônomos. No entanto, o HD-FCM pode ser facilmente incorporado em plataformas de robôs reais, devido à sua baixa complexidade computacional. O modelo FCM possui menos operações matemáticas (Spears et al., 2014) do que o controlador Fuzzy, conforme sugerem os resultados práticos.

Em um experimento real, foi utilizado um robô real com FCM1 embarcado em um microcontrolador de baixo custo baseado no Arduino Uno. O robô possui três sensores de ultrassom espaçados em 30 graus na parte frontal. As rodas do robô são acionadas por motores de dois passos.

O sistema de navegação autônomo guiou o robô para atingir o alvo, conforme mostrado na Figura 10 (reproduzindo a primeira simulação, ou seja, alcance o alvo). Devido à precisão dos atuadores das rodas, foi possível estimar a posição do robô e recalculá-la uma nova posição de acordo com a geometria dos pulsos enviados aos motores do robô e o tamanho da circunferência da roda, com precisão de 0,75 cm (considerando a posição alvo), usando 104 pulsos em uma distância percorrida de aproximadamente 1,56 m (com erro relativo de 0,5%).

Por fim, o experimento com a trajetória discretizada (sequência começando de *a* a *f* na Figura 10 sugere que o modelo simulado (agente) e o robô real (protótipo) foram fortemente correlacionados, visto que a trajetória do robô foi muito próxima da trajetória simulada. Isso corrobora com a validade do modelo cinemático utilizado em todas as simulações no trabalho anterior (Mendonça et al., 2019) e neste artigo, e a versão inicial do protótipo real.

6 Conclusões

Os resultados iniciais obtidos das simulações e de um experimento real foram promissores, pois o agente móvel cumpriu seu objetivo de atingir os

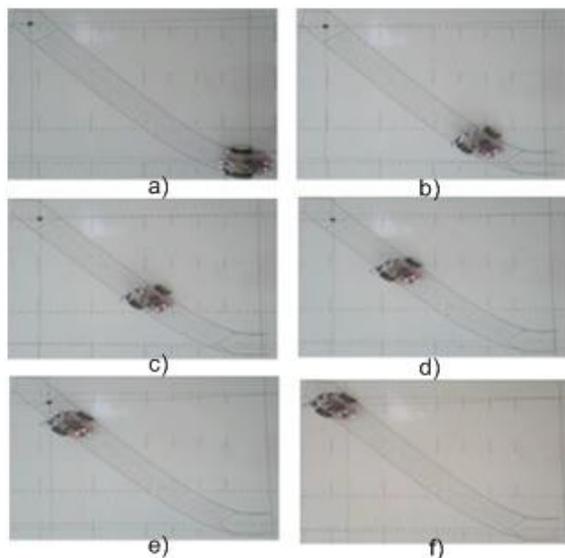


Figura 10: Simulação 3 - FCM1 embarcado em um robô móvel real

alvos em diferentes configurações e cenários simulados. Em todas as simulações o agente (robô) atingiu os alvos e evitou os obstáculos.

Observa-se que em um robô real, devido as dificuldades como precisão dos sensores, falso sinal (em especial, sensores de ultrassom), ruído nas medições, dificilmente será possível obter resultados semelhantes à simulação com cenários mais complexos, ou seja, ambiente espiral. No entanto, o objetivo do experimento inicial (atingir o alvo a menos que haja obstáculos, apenas FCM) sugere que as duas arquiteturas hierárquicas propostas podem ser usadas em controladores de robôs autônomos.

Uma vantagem significativa do HD-FCM sobre o HW-FLC foi observada em várias simulações: HD-FCM apresentou a velocidade mais rápida (5% mais rápida em experimentos de simulação) nas mesmas condições (cenário, modelo cinemático, hardware).

A acurácia encontrada no experimento real foi da ordem de 99,5% sugerindo que o uso de FCM embutido em hardware *open source* de prateleira pode ser utilizado no desenvolvimento de robôs de baixo custo. O erro relativo encontrado sugere que os controladores podem ser aplicados em cenários de pequenas dimensões.

Trabalhos futuros sugerem: melhorar a complexidade dos cenários, testar os sistemas de navegação autônomos propostos em cenários dinâmicos como, por exemplo, com obstáculos móveis para avaliar o desempenho de ambos os controladores, investigar a complexidade computacional das ferramentas propostas e, finalmente, verificar a técnica de comportamento em distâncias maiores para possíveis aplicações agrícolas.

Agradecimentos

Os autores agradecem a contribuição da Universidade Tecnológica Federal do Paraná - Campus Cornélio Procópio, pelo apoio financeiro para o desenvolvimento desta pesquisa.

Referências

- Acampora, G. and Loia, V. (2011). On the temporal granularity in fuzzy cognitive maps, *IEEE Transactions on Fuzzy Systems* **19**(6): 1040–1057.
- Ahmadi, S., Forouzideh, N., Yeh, C.-H., Martin, R. and Papageorgiou, E. I. (2014). A first study of fuzzy cognitive maps learning using cultural algorithm, *2014 9th IEEE Conference on Industrial Electronics and Applications*, pp. 2023–2028.
- Ahmed, M. G. and Hesham, A. H. (2010). A novel multiagent system based on dynamic fuzzy cognitive map approach, *2010 10th International Conference on Intelligent Systems Design and Applications*, pp. 254–259.
- Carvalho, J. and Tome, J. (2000). Rule based fuzzy cognitive maps-qualitative systems dynamics, *PeachFuzz 2000. 19th International Conference of the North American Fuzzy Information Processing Society - NAFIPS (Cat. No.00TH8500)*, pp. 407–411.
- Cliff, D. (2003). *Biological inspired computing approaches to cognitive systems: a partial tour of the literature*, pp. i–xi.
- Hagiwara, M. (1992). Extended fuzzy cognitive maps, *[1992 Proceedings] IEEE International Conference on Fuzzy Systems*, pp. 795–801.
- Hendriks, A. and Lyons, D. (1994). Using perception to plan incremental adaptations, *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'94)*, Vol. 3, pp. 1780–1787 vol.3.
- Kosko, B. (1986). *Fuzzy Cognitive Maps*, Vol. 24, pp. 65–75.
- Kostiadis, K., Hunter, M. and Hu, H. (2000). The use of design patterns for the development of multi-agent systems, *Smc 2000 conference proceedings. 2000 IEEE international conference on systems, man and cybernetics. 'cybernetics evolving to systems, humans, organizations, and their complex interactions' (cat. no.0, Vol. 1, pp. 280–285 vol.1.*
- Li-Xin, W. (1999). Analysis and design of hierarchical fuzzy systems, *IEEE Transactions on Fuzzy Systems* **7**(5): 617–624.

- Mataric, M. J. (2007). *Front Matter*, pp. i–xvii.
- Mendonça, M., Angílico, B. A., Arruda, L. V. R. and Neves, F. J. (2013). A subsumption architecture to develop dynamic cognitive network-based models with autonomous navigation application, *Journal of Control, Automation and Electrical Systems* **1**(1): 314.
- Mendonça, M., da Silva, E. S., Assolari, K., Assolari, M. and Arruda, L. (2014). *Hierarchical fuzzy approach applied in the development of an autonomous architecture for mobile agents*, Vol. 10, pp. 193–202.
- Mendonça, M., Kondo, H. S., Botoni, L. S., Palácios, R. H. C. and Silva, J. P. A. (2019). Semi-unknown environments exploration inspired by swarm robotics using fuzzy cognitive maps, *2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pp. 1–8.
- Miao, Y., Miao, C., Tao, X., Shen, Z. and Liu, Z. (2010). Transformation of cognitive maps, *IEEE Transactions on Fuzzy Systems* **18**(1): 114–124.
- Min, H.-q., Hui, J.-x., Lu, Y.-s. and Jiang, J.-z. (2006). Probability fuzzy cognitive map for decision-making in soccer robotics, *2006 IEEE/WIC/ACM International Conference on Intelligent Agent Technology*, pp. 321–325.
- Nápoles, G., Goossens, W., Moesen, Q. and Mosquera, C. (2020). Fast k-fuzzy-rough cognitive networks, *2020 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8.
- Papageorgiou, E. I. (2014). Fuzzy cognitive maps for applied sciences and engineering from fundamentals to extensions and learning algorithms, *Springer* **1**(1): 45–51.
- Papageorgiou, E. I. and Froelich, W. (2012). Multi-step prediction of pulmonary infection with the use of evolutionary fuzzy cognitive maps, *Neurocomputing. Elsevier* **1**(1): 3–14.
- Papageorgiou, E. I. and Salmeron, J. L. (2013). A review of fuzzy cognitive maps research during the last decade, *IEEE Transactions on Fuzzy Systems* **21**(1): 66–79.
- Policastro, C. A., Romero, R. A. and Zuliani, G. (2007). Robotic architecture inspired on behavior analysis, *2007 International Joint Conference on Neural Networks*, pp. 1482–1487.
- Salan, S., Drumwright, E. and Lin, K.-I. (2015). Minimum-energy robotic exploration: A formulation and an approach, *IEEE Transactions on Systems, Man, and Cybernetics: Systems* **45**(1): 175–182.
- Schroth, G., Stork, I., Wersborg, G. and Diepold, K. (2009). A cognitive system for autonomous robotic welding, *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3148–3153.
- Shaikh, M. H., Kosuri, K., Ansari, N. A. and Khan, M. J. (2013). The state-of-the-art intelligent navigational system for monitoring in mobile autonomous robot, *2013 International Conference of Information and Communication Technology (ICoICT)*, pp. 405–409.
- Sharma, R. (2021). Artificial intelligence in agriculture: A review, *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*, pp. 937–942.
- Siciliano, B. and Khatib, O. (2016). *Robotics and the Handbook*, Springer International Publishing, Cham, pp. 1–6.
- Spears, A., Howard, A. M., Schmidt, B., Meister, M., West, M. and Collins, T. (2014). Design and development of an under-ice autonomous underwater vehicle for use in polar regions, *2014 Oceans - St. John's*, pp. 1–6.