

DECISÃO COLETIVA BIOINSPIRADA EM ENXAMES ROBÓTICOS: ANÁLISE EXPERIMENTAL DO VÍDEO “CAN ANTS INSPIRE ROBOTS?”

BIO-INSPIRED COLLECTIVE DECISION-MAKING IN ROBOTIC SWARMS: AN EXPERIMENTAL ANALYSIS OF THE VIDEO "CAN ANTS INSPIRE ROBOTS?"

Cintya Wedderhoff Machado¹

Márcio Mendonça²

Vitor Blanc Milani³

Mário Sérgio Martinelli Medina⁴

109

RESUMO: A robótica de enxame investiga como grupos de robôs relativamente simples podem cooperar por meio de interações locais, sem depender de um controlador central ou de informações globais sobre o ambiente. Este artigo analisa o vídeo “Can Ants Inspire Robots?”, apresentado no IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2012), e a publicação científica associada ao experimento. O objetivo é examinar o mecanismo descentralizado empregado por robôs móveis para selecionar o caminho mais rápido entre uma fonte e um ninho. A estratégia utiliza dinâmica de opiniões, realimentação positiva e a regra k-Unanimity, pela qual um robô somente altera sua escolha quando as últimas k opiniões observadas indicam unanimemente outra alternativa. A pesquisa caracteriza-se como análise documental, audiovisual, descritiva e quantitativa. No experimento exibido no vídeo, dez das quinze execuções com robôs reais convergiram para o caminho mais rápido, representando 66,7% de acerto, enquanto as simulações indicaram aproximadamente 68% de sucesso. O tempo médio de convergência foi de cerca de 15 minutos. Experimentos complementares elevaram a taxa de acerto para 86,7% nos robôs reais e 96% nas simulações quando a diferença entre os tempos dos caminhos foi ampliada. O aumento da memória de $k = 2$ para $k = 4$ resultou em 80% de acerto, porém aumentou expressivamente o tempo de consenso. Conclui-se que decisões

¹ Cintya Wedderhoff Machado é Mestranda no Programa de Pós-Graduação em Ensino de Ciências Humanas, Sociais e da Natureza (PPGEN) da Universidade Tecnológica Federal do Paraná (UTFPR).

Lattes: <http://lattes.cnpq.br/4604594140489347>. ORCID: <https://orcid.org/0009-0008-9635-1230>

E-mail: cintyamachado@alunos.utfpr.edu.br.

² Márcio Mendonça é Professor Titular e Professor EBT da Universidade Tecnológica Federal do Paraná (UTFPR), vinculado ao Programa de Pós-Graduação em Engenharia Mecânica (PPGEM-CP). Doutor.

Lattes: <http://lattes.cnpq.br/5415046018018708>. ORCID: <https://orcid.org/0000-0002-7203-9241>.

E-mail: mendonca@utfpr.edu.br.

³ Vitor Blanc Milani é Mestrando no Programa de Pós-Graduação em Engenharia Mecânica (PPGEM-CP) da Universidade Tecnológica Federal do Paraná (UTFPR).

Lattes: <http://lattes.cnpq.br/4504374098250296>. ORCID: <https://orcid.org/0000-0001-6793-6987>.

E-mail: vblancmilani@gmail.com.

⁴ Mário Sérgio Martinelli Medina é Mestrando em Informática e Técnico de Laboratório de Informática da Universidade Tecnológica Federal do Paraná (UTFPR).

Lattes: <http://lattes.cnpq.br/6624259960900455>. ORCID: <https://orcid.org/0009-0009-8985-5411>.

E-mail: mariomedina@utfpr.edu.br.

coletivas eficientes podem emergir de regras individuais simples, embora exista uma relação de objetivos contraditórios entre rapidez e precisão.

PALAVRAS-CHAVE: Robótica de enxame. Inteligência de enxame. Decisão coletiva. Sistemas multiagentes. Robótica bioinspirada.

ABSTRACT: Swarm robotics investigates how groups of relatively simple robots can cooperate through local interactions without relying on a central controller or global information about the environment. This article analyzes the video *Can Ants Inspire Robots?* presented at the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2012), together with the scientific publication associated with the experiment. The objective is to examine the decentralized mechanism employed by mobile robots to select the shortest path between a source and a nest. The proposed strategy combines opinion dynamics, positive feedback, and the k-Unanimity rule, according to which a robot changes its decision only when the last k observed opinions unanimously support an alternative. The study is characterized as documentary, audiovisual, descriptive, and quantitative research. In the experiment presented in the video, 10 of 15 trials with real robots converged on the shortest path, corresponding to a success rate of 66.7%, while simulations achieved approximately 68% success. The average convergence time was about 15 minutes. Additional experiments increased the success rate to 86.7% for real robots and 96% in simulations when the difference between path traversal times was enlarged. Increasing the memory parameter from $k = 2$ to $k = 4$ improved the success rate to 80% but significantly increased the consensus time. The results indicate that efficient collective decisions can emerge from simple individual rules, despite the inherent trade-off contradictions between decision speed and accuracy.

KEYWORDS: Swarm robotics. Swarm intelligence. Collective decision-making. Multi-agent systems. Bio-inspired robotics.

1 Introdução

Os sistemas naturais formados por insetos sociais, como formigas, abelhas e cupins, demonstram que comportamentos coletivos complexos podem surgir a partir de indivíduos com capacidades cognitivas e sensoriais relativamente limitadas. Em vez de depender de uma liderança central, esses organismos coordenam suas atividades mediante interações locais, realimentação positiva e troca distribuída de informações. Esses princípios constituem uma das principais fontes de inspiração da robótica de enxame (Dorigo; Theraulaz; Trianni, 2021; Reina; Ferrante; Valentini, 2021).

Na robótica de enxame, numerosos robôs simples atuam cooperativamente para realizar tarefas que poderiam ser inviáveis ou pouco eficientes para uma única unidade. Os agentes não precisam possuir conhecimento completo do ambiente e não dependem necessariamente de comunicação global. O comportamento coletivo

emerge da repetição de regras individuais e das interações entre os agentes e o ambiente, favorecendo escalabilidade, flexibilidade, robustez diante de falhas e capacidade de auto-organização (Brambilla *et al.*, 2013; Dorigo; Theraulaz; Trianni, 2021).

Um dos problemas centrais desse campo é a tomada coletiva de decisões. Em aplicações práticas, um enxame pode precisar escolher uma rota, selecionar uma região de exploração, distribuir tarefas ou decidir qual recurso deve ser transportado. Como não existe uma unidade supervisora responsável pela escolha, o consenso deve emergir de observações locais e da influência exercida pelos próprios agentes (Reina; Ferrante; Valentini, 2021; Shan; Mostaghim, 2021).

O vídeo *Can Ants Inspire Robots? (Can ants inspire robots?, 2012)* apresenta uma aplicação desse princípio em uma tarefa de coleta e transporte. Os robôs devem deslocar-se entre um ninho e uma fonte, escolhendo um entre dois caminhos possíveis. O mecanismo proposto permite que o enxame selecione coletivamente a alternativa com menor tempo médio de execução sem que cada robô precise medir, comparar ou armazenar explicitamente o tempo de todos os trajetos. O trabalho foi apresentado no IROS 2012 por Brutschy *et al.* (2012).

Diante desse contexto, formula-se o seguinte problema de pesquisa: de que modo regras locais simples e interações descentralizadas permitem que um enxame robótico identifique e adote coletivamente o caminho mais eficiente? O objetivo geral deste artigo é analisar o funcionamento do sistema apresentado no vídeo, descrever sua configuração experimental e discutir os resultados obtidos nos testes com robôs reais e nas simulações computacionais. A relevância do estudo decorre do potencial dessas estratégias para sistemas autônomos distribuídos, nos quais a ausência de um controlador central pode ampliar a robustez e a capacidade de adaptação (Dorigo; Theraulaz; Trianni, 2021; Schranz *et al.*, 2020).

2 Fundamentação Teórica

2.1 Robótica de enxame

A robótica de enxame é uma abordagem da robótica coletiva inspirada na organização de sistemas biológicos descentralizados. Nessa abordagem, cada agente possui recursos computacionais, sensoriais e de comunicação limitados.

Entretanto, a cooperação de diversos agentes pode produzir capacidades coletivas superiores às capacidades individuais (Dorigo; Theraulaz; Trianni, 2021; Şahin, 2005).

Entre as características recorrentes desses sistemas encontram-se o controle descentralizado, a utilização prioritária de informações locais, a redundância proporcionada pelo número de agentes, a robustez diante da falha de unidades individuais e a emergência de comportamentos coletivos a partir de regras simples (Brambilla *et al.*, 2013; Dorigo; Theraulaz; Trianni, 2021).

A comunicação indireta por meio de marcas deixadas no ambiente também constitui uma importante estratégia de coordenação coletiva. Em sistemas robóticos, esse mecanismo pode ser implementado artificialmente por sinais visuais, sensores ou mapas compartilhados, permitindo reproduzir o efeito funcional dos feromônios utilizados por colônias de formigas (Mayet *et al.*, 2010).

No experimento analisado, não existe um controlador central determinando qual caminho deve ser adotado. Cada robô mantém uma opinião individual e pode modificá-la após observar as opiniões de outros robôs próximos. O comportamento coletivo resulta, portanto, da propagação distribuída dessas escolhas.

2.2 Dinâmica de opiniões e realimentação positiva

A dinâmica de opiniões descreve como as preferências individuais se modificam em consequência das interações sociais. Em um enxame robótico, uma opinião pode representar uma rota, uma ação, um local ou uma tarefa. No sistema analisado, as alternativas são denominadas ação A e ação B. A ação A corresponde ao caminho com menor tempo médio de percurso.

Modelos matemáticos de formação de opinião demonstram que diferenças no tempo de exposição às alternativas podem favorecer espontaneamente a emergência de um consenso coletivo, mesmo quando nenhum agente possui conhecimento global do sistema. Esse fenômeno fundamenta diversos algoritmos bioinspirados empregados em robótica distribuída (Montes de Oca *et al.*, 2011; Reina; Ferrante; Valentini, 2021; Shan; Mostaghim, 2021).

A utilização de mecanismos artificiais inspirados na comunicação por feromônios representa uma das principais estratégias de coordenação em robótica de enxame. Em vez de substâncias químicas, os robôs podem empregar sinais

luminosos, marcas virtuais ou informações compartilhadas no ambiente para reproduzir o efeito funcional da estigmergia observada em colônias de insetos (Mayet *et al.*, 2010).

Cada robô executa inicialmente a alternativa correspondente à sua opinião atual. Ao encontrar outros agentes na zona de observação, registra as escolhas identificadas e utiliza essas informações para decidir se deve permanecer com a opinião atual ou alterá-la.

A realimentação positiva ocorre porque uma opinião que se torna mais frequente passa a ser observada por um número maior de agentes. Consequentemente, aumenta a probabilidade de novos robôs adotarem essa mesma escolha. Existe ainda um viés relacionado ao tempo de execução: os robôs que utilizam o caminho mais rápido concluem a tarefa em menor tempo e retornam com maior frequência à zona de observação. Assim, a alternativa mais eficiente tende a ser visualizada mais vezes, aumentando sua disseminação pelo enxame (Brutschy *et al.*, 2012).

2.3 Regra k-Unanimity

A regra k-Unanimity determina as condições necessárias para que um robô altere sua opinião. Cada agente mantém uma memória contendo as últimas k opiniões observadas. Uma mudança ocorre somente quando todas essas observações indicam unanimemente a mesma alternativa.

Considerando a memória de um robô representada por $M_i(t) = \{o_1, o_2, \dots, o_k\}$, o agente passa a adotar a opinião X apenas quando $o_1 = o_2 = \dots = o_k = X$. Quando as observações não são unânimes, o robô conserva sua escolha anterior.

O parâmetro k controla a sensibilidade do sistema. Valores pequenos permitem mudanças mais rápidas, porém aumentam a possibilidade de decisões influenciadas por amostras reduzidas.

Valores maiores exigem evidências mais consistentes, podendo elevar a precisão e a estabilidade, mas tornam a convergência mais lenta. A formulação ampliada da regra demonstra que o mecanismo permite ajustar a relação entre rapidez e precisão da decisão coletiva (Scheidler *et al.*, 2016; Shan; Mostaghim, 2023).

2.4 Pensamento computacional e robótica de enxame

O pensamento computacional compreende formas de formular problemas e conceber soluções de maneira que possam ser representadas e executadas por agentes de processamento de informação. Nessa perspectiva, não se restringe à programação: envolve abstração, decomposição, reconhecimento de padrões, representação de dados e elaboração de procedimentos algorítmicos (Wing, 2006).

O experimento analisado materializa esses elementos ao decompor a decisão coletiva em regras locais, abstrair cada rota por uma opinião identificada por cor e estabelecer uma sequência precisa de observação, armazenamento e atualização por meio da regra k-Unanimity.

Brennan e Resnick (2012) organizam o pensamento computacional em conceitos, práticas e perspectivas. Aplicada à robótica de enxame, essa abordagem permite que estudantes e pesquisadores modelem o comportamento dos agentes, simulem diferentes valores de k, testem hipóteses, comparem resultados e depurem regras que não produzem o consenso esperado.

A passagem entre modelo, simulação e experimento físico favorece o raciocínio iterativo e sistemático, além de tornar compreensível como decisões globais podem emergir de interações simples entre robôs (Montuori *et al.*, 2024).

3 Metodologia

3.1 Natureza da pesquisa

Este estudo caracteriza-se como pesquisa documental e audiovisual, com abordagem descritiva e quantitativa. Foram examinados o vídeo “Can Ants Inspire Robots?” o artigo associado apresentado no IROS 2012, os gráficos e as descrições dos experimentos com robôs reais e simulados e a publicação posterior sobre a regra k-Unanimity.

O vídeo constitui a principal fonte audiovisual desta investigação documental, complementando as informações metodológicas e quantitativas descritas no artigo científico correspondente (Can ants inspire robots?, 2012).

A dimensão descritiva identifica os componentes, os comportamentos e a sequência de funcionamento do sistema. A dimensão quantitativa compara as taxas de convergência e os tempos observados nos três experimentos relatados. Ressalta-

se que os experimentos e os dados analisados foram produzidos pelos pesquisadores responsáveis pelo trabalho original; o presente artigo realiza sua sistematização e discussão, procedimento compatível com a análise documental de fontes preexistentes (Morgan, 2022).

3.2 Plataforma robótica e ambiente experimental

Os experimentos utilizaram robôs móveis denominados foot-bots. Cada robô possuía câmera omnidirecional, sensores de luminosidade e proximidade, sensores de solo e sinalizador luminoso RGB. O sinalizador permitia representar visualmente a opinião do robô, enquanto a câmera possibilitava reconhecer as opiniões de agentes próximos.

A arena experimental apresentava dimensões aproximadas de 4,5 m por 3,5 m. O ambiente continha um ninho, uma fonte, uma zona de observação, referências visuais e dois caminhos alternativos. Os robôs não dispunham de mapa completo da arena. A navegação entre o ninho e a fonte era realizada com base nas luzes e nos marcos disponíveis no ambiente.

3.3 Tarefa experimental

A tarefa consistia em buscar um objeto na fonte e transportá-lo até o ninho. Para realizar o percurso, cada robô precisava escolher entre o caminho A, com menor tempo médio de execução, e o caminho B, com maior tempo médio.

No segundo experimento foi utilizada uma versão prolongada do caminho B, denominada Blong.

Na zona de observação, os robôs identificavam as opiniões dos demais agentes. As informações eram armazenadas em uma memória limitada às últimas k observações. Quando todas as posições dessa memória continham a mesma opinião, o robô adotava a alternativa correspondente.

3.4 Configuração dos experimentos

Foram realizados três experimentos com robôs reais, cada um composto por quinze execuções, além de 50.000 repetições simuladas para cada configuração no ambiente ARGoS, com espaço bidimensional e modelo cinemático. A comparação entre as configurações permitiu examinar dois fatores centrais para a decisão coletiva:

a diferença entre os tempos de execução das rotas e o tamanho da memória utilizada pela regra k-Unanimity.

No Experimento I, adotou-se uma razão aproximada de 1,3 entre os tempos de execução dos caminhos A e B, com memória $k = 2$, estabelecendo a condição de referência para a análise. No Experimento II, manteve-se $k = 2$, mas o caminho B foi prolongado (Blong), elevando a razão entre os tempos para aproximadamente 1,9. Essa alteração tornou mais evidente a diferença de desempenho entre as alternativas e permitiu verificar em que medida um contraste temporal maior favoreceria a seleção coletiva do caminho mais eficiente.

O Experimento III retomou os mesmos caminhos do Experimento I, porém ampliou a memória de $k = 2$ para $k = 4$. Com isso, foi possível avaliar o efeito de uma exigência maior de unanimidade sobre a precisão e o tempo de convergência. Em conjunto, os três experimentos possibilitaram analisar a relação entre sensibilidade da regra, qualidade da decisão e velocidade de formação do consenso.

O vídeo disponibilizado apresenta uma execução correspondente ao Experimento I, que serve como base visual para a descrição do comportamento coletivo discutido a seguir.

4 Resultados Observados

4.1 Comportamento coletivo apresentado no vídeo

No início da execução, os robôs encontram-se distribuídos entre as duas opiniões. Parte do grupo seleciona o caminho A, enquanto os demais utilizam o caminho B. Não existe uma ordem externa determinando a escolha correta.

Figura 1 – Observação local e mudança de opinião indicada pelas cores dos LEDs




Fonte: quadros do vídeo experimental reproduzidos em Scheidler *et al.* (2016, p. 1182).

Na sequência da Figura 1, a luz verde representa a opinião A e a luz roxa representa a opinião B. O robô destacado ingressa na zona de observação com a opinião A, identifica e armazena a opinião B e, após satisfazer a condição de unanimidade definida pelo parâmetro k , altera sua própria opinião ao deixar a zona.

A mudança de cor torna visível a atualização do estado interno do agente e evidencia que a comunicação ocorre localmente, sem transmissão de uma ordem global. Durante a movimentação, os agentes percorrem repetidamente o trajeto entre o ninho e a fonte. Ao retornarem à zona de observação, identificam as opiniões dos robôs próximos.

Como o caminho A é mais rápido, os agentes que o utilizam completam maior número de ciclos em determinado intervalo de tempo. Consequentemente, sua opinião aparece com maior frequência nas interações locais.

Figura 2 – Estágio inicial da propagação das opiniões aos 1 min e 30 s



Fonte: quadro do vídeo experimental reproduzido em Scheidler *et al.* (2016, p. 1184).

A Figura 2 registra uma fase ainda inicial do processo, na qual as duas opiniões coexistem na arena. Os robôs verdes e roxos encontram-se distribuídos nos diferentes trechos e as observações acumuladas ainda não produziram consenso.

Mesmo assim, o deslocamento repetido já cria o mecanismo de seleção: os agentes vinculados ao caminho mais rápido retornam com maior frequência à zona de observação e aumentam a exposição da opinião A.

A repetição dessas interações provoca uma mudança gradual na distribuição das opiniões. A quantidade de robôs favoráveis ao caminho A aumenta até que o grupo alcance ou se aproxime do consenso (Shan; Mostaghim, 2021, 2023).

O vídeo evidencia três etapas: diversidade inicial de opiniões, propagação gradual da alternativa mais eficiente e formação descentralizada do consenso. Esse comportamento visual coincide com a sequência apresentada na gravação original disponibilizada pelos autores do experimento (Can ants inspire robots?, 2012).

Na Figura 3, o efeito acumulado do algoritmo torna-se mais perceptível. A opinião associada ao caminho A passa a ocupar parcela maior do enxame, enquanto permanecem alguns robôs roxos em processo de circulação e atualização.

Esse estágio ilustra a realimentação positiva: quanto mais frequente se torna a opinião A, maior é a probabilidade de ela compor as últimas k observações e provocar novas mudanças de opinião.

Figura 3 – Efeito intermediário da realimentação positiva aos 8 min e 20 s




Fonte: quadro do vídeo experimental reproduzido em Scheidler *et al.* (2016, p. 1184).

A Figura 4 apresenta o resultado final da execução: os robôs exibem a cor verde, indicando consenso em torno da opinião A e, conseqüentemente, do caminho de menor tempo médio.

O consenso foi alcançado sem controlador central, mapa global compartilhado ou comparação explícita dos tempos por cada robô. A decisão coletiva emerge da frequência das interações, da memória limitada e da regra de atualização aplicada individualmente. O resultado mais relevante é que o caminho mais rápido se torna

predominante sem que os robôs recebam uma instrução central e sem que disponham de conhecimento global da arena. A escolha emerge da combinação entre diferença nos tempos de execução, encontros locais e realimentação positiva.

Figura 4 – Resultado final: convergência do enxame para o caminho A aos 16 min e 10 s



Fonte: quadro do vídeo experimental reproduzido em Scheidler *et al.* (2016, p. 1184).

4.2 Resultados quantitativos

O Quadro 1 sintetiza os principais resultados apresentados pelos pesquisadores nos experimentos com robôs reais e nas simulações.

Quadro 1 – Resultados dos experimentos com robôs reais e simulações

Experimento	Configuração principal	Resultados	Tempo de convergência
I	Razão de tempos $\approx 1,3$; $k = 2$	Robôs reais: 10/15 (66,7%) Simulação: 68%	Aproximadamente 15 minutos, em média
II	Razão de tempos $\approx 1,9$; $k = 2$	Robôs reais: 13/15 (86,7%) Simulação: 96%	Aproximadamente o dobro do Experimento I
III	Razão de tempos $\approx 1,3$; $k = 4$	Robôs reais: 12/15 (80%) Simulação: 83%	Aumento expressivo em relação ao Experimento I

Fonte: elaborado pelos autores com base em Brutschy *et al.* (2012) e Scheidler *et al.* (2016).

No Experimento I, mostrado no vídeo, dez das quinze execuções convergiram corretamente para o caminho A, o que corresponde a uma taxa de sucesso de 66,7%. Nas 50.000 execuções simuladas, a probabilidade de selecionar o caminho mais rápido foi de aproximadamente 68%. A proximidade entre os resultados reais e simulados indica que o modelo computacional reproduziu adequadamente a tendência geral do comportamento coletivo nessa configuração.

O tempo médio de convergência do Experimento I foi de aproximadamente 15 minutos. Esse resultado mostra que o consenso não foi instantâneo, pois dependeu da repetição dos ciclos de deslocamento e da acumulação de observações locais.

No Experimento II, o aumento da diferença entre os tempos dos dois caminhos tornou o caminho A mais facilmente distinguível. A taxa de sucesso dos robôs reais aumentou para 86,7%, enquanto a simulação atingiu aproximadamente 96%. Entretanto, esse ganho de precisão veio acompanhado de aumento no tempo de convergência, aproximadamente duas vezes superior ao registrado no Experimento I.

No Experimento III, a memória passou de $k = 2$ para $k = 4$. Doze das quinze execuções convergiram para o caminho correto, produzindo taxa de sucesso de 80%. As simulações indicaram probabilidade de aproximadamente 83%. Apesar da melhora em relação ao Experimento I, o tempo necessário para o consenso aumentou consideravelmente.

A diferença absoluta entre os percentuais obtidos com robôs reais e simulações foi de aproximadamente 1,3 ponto percentual no Experimento I, 9,3 pontos percentuais no Experimento II e 3 pontos percentuais no Experimento III. A diferença absoluta média foi de cerca de 4,5 pontos percentuais, sugerindo boa correspondência global entre o modelo simulado e a plataforma física, embora a simulação tenha sido mais otimista no Experimento II.

5 Discussão

Os resultados confirmam que uma regra individual simples pode gerar um comportamento coletivo funcional. Nenhum robô precisa conhecer as dimensões da arena, calcular globalmente o menor caminho ou receber uma decisão de um agente coordenador. A alternativa mais eficiente é favorecida indiretamente porque os robôs que a executam retornam com maior frequência à zona de observação.

Esse mecanismo pode ser comparado à comunicação indireta encontrada em colônias de insetos. Embora o experimento não utilize feromônios físicos, a diferença na frequência com que cada opinião fica disponível exerce função semelhante: escolhas mais eficientes recebem reforço mais frequente e passam a influenciar parcela crescente do grupo.

O principal resultado técnico é a demonstração de que o tempo de execução das ações pode atuar como mecanismo implícito de avaliação. Os robôs não precisam medir diretamente a qualidade de cada opção, pois essa qualidade é refletida na frequência de retorno e de interação dos agentes.

Observa-se uma relação de compromisso entre precisão e velocidade. Uma diferença mais perceptível entre os tempos dos caminhos aumenta a probabilidade de identificar corretamente a melhor alternativa. Uma memória maior reduz mudanças de opinião baseadas em observações isoladas, mas o aumento da exigência para a alteração da escolha prolonga o processo de formação do consenso (Scheidler *et al.*, 2016; Shan; Mostaghim, 2021, 2023).

O Experimento I apresentou convergência mais rápida, mas também a menor taxa de acerto. O Experimento II obteve a maior precisão, principalmente nas simulações, porém necessitou de mais tempo. O Experimento III demonstrou que o aumento de k pode tornar a decisão mais confiável, mas reduz a velocidade de adaptação.

Outro resultado relevante é a robustez conceitual da abordagem. Como não existe controlador central, a falha de um robô não necessariamente interrompe o processo. Os demais agentes continuam observando, movimentando-se e atualizando suas opiniões. Essa propriedade é importante para aplicações em inspeção, exploração, agricultura, busca e resgate ou monitoramento ambiental (Kegeleirs; Birattari, 2025; Schranz *et al.*, 2020).

A importância dessa ferramenta para a robótica reside na capacidade de converter percepções locais e de baixo custo em uma decisão coletiva útil. Como cada agente necessita apenas identificar a opinião de um vizinho, manter uma memória curta e aplicar uma regra simples, reduzem-se as exigências de comunicação global e de processamento centralizado. Essa característica favorece escalabilidade, tolerância a falhas e continuidade da missão quando parte do enxame perde comunicação ou deixa de operar, aspectos particularmente relevantes em exploração, inspeção, logística, agricultura, monitoramento ambiental e busca e salvamento (Brambilla *et al.*, 2013; Dorigo; Theraulaz; Trianni, 2021; Jamshidpey; Dorigo; Heinrich, 2023; Scheidler *et al.*, 2016; Schranz *et al.*, 2020).

Entretanto, a descentralização não garante automaticamente a escolha correta. No Experimento I, cinco das quinze execuções não convergiram para a alternativa mais rápida. A realimentação positiva pode fortalecer tanto a melhor opinião quanto uma alternativa inicialmente majoritária. Se muitos agentes adotarem prematuramente a opção menos eficiente, essa escolha pode ser reforçada antes que o viés temporal do caminho mais rápido se torne dominante (Shan; Mostaghim, 2023).

5.1 Limitações e aprendizados do estudo

As limitações observadas também constituem aprendizados importantes para a interpretação e o aprimoramento da abordagem. Foram avaliadas apenas duas alternativas principais de percurso, em uma arena estruturada e com referências visuais previamente posicionadas; além disso, os testes reais envolveram quinze execuções por configuração, quantidade relativamente pequena em comparação com as 50.000 simulações. O caminho mais rápido permaneceu definido durante cada experimento, sem mudanças dinâmicas nas condições do ambiente durante a formação do consenso. O vídeo, por sua vez, apresenta apenas uma execução do Experimento I e, isoladamente, não representa toda a variabilidade estatística das repetições (Brutschy et al., 2012; Scheidler et al., 2016). Esses aspectos indicam que a eficiência da regra deve ser compreendida em função do contexto experimental e reforçam a necessidade de avaliar o mecanismo em cenários mais variados. Também se observa que o aumento de precisão pode exigir maior tempo de convergência, o que representa uma aprendizagem relevante para aplicações em tarefas que demandem respostas rápidas (Kegeleirs; Birattari, 2025).

Outro aprendizado decorre da diferença entre o ambiente simulado e a plataforma física. Sistemas reais estão sujeitos a falhas de percepção, oclusões, diferenças entre motores, perda de comunicação visual e interferências ambientais. Esses fatores ajudam a explicar por que as probabilidades obtidas nas simulações não coincidem integralmente com os resultados dos robôs físicos e evidenciam a importância de incorporar ruído, falhas e incertezas nos testes futuros (Kegeleirs; Birattari, 2025).

6 Considerações Finais

A análise do vídeo “Can Ants Inspire Robots?” demonstra que enxames robóticos podem tomar decisões coletivas por meio de regras locais e sem a utilização de um controlador central. No experimento apresentado, robôs móveis escolheram entre dois caminhos e utilizaram as opiniões observadas de outros agentes para atualizar suas próprias escolhas.

A estratégia demonstrada pode contribuir para seleção coletiva de rotas em ambientes desconhecidos, escolha de regiões prioritárias para exploração, distribuição otimizada de robôs entre fontes de recursos, definição de áreas de inspeção, busca e resgate, seleção de estações de recarga e coordenação de veículos terrestres, aéreos ou aquáticos autônomos.

Desse modo, o objetivo do artigo foi atendido ao descrever o mecanismo de decisão, sistematizar a configuração experimental e discutir seus resultados. O resultado central observado no vídeo foi a propagação gradual da opinião associada ao caminho mais rápido. No Experimento I, dez de quinze execuções reais, equivalentes a 66,7%, convergiram para a alternativa correta. O resultado simulado foi de aproximadamente 68%, e o tempo médio de convergência foi de cerca de 15 minutos.

Os experimentos complementares mostraram que uma diferença maior entre os tempos das alternativas elevou a taxa de acerto para 86,7% nos robôs reais e 96% nas simulações. O aumento da memória para $k = 4$ produziu 80% de sucesso nos testes reais e 83% nas simulações. Entretanto, as duas modificações aumentaram o tempo necessário para alcançar o consenso.

Conclui-se que a regra k-Unanimity apresenta potencial para decisões descentralizadas, robustas e ajustáveis. Os resultados também demonstram que a escolha dos parâmetros deve considerar a relação entre precisão e velocidade: decisões mais criteriosas podem ser mais confiáveis, mas exigem maior tempo de convergência. O experimento constitui uma demonstração relevante de como princípios inspirados na inteligência coletiva de insetos podem orientar o desenvolvimento de sistemas robóticos autônomos e cooperativos.

Como perspectiva futura do trabalho desenvolvido, a regra k-Unanimity pode ser combinada com outros sistemas computacionais inteligentes, como aprendizagem

por reforço, lógica fuzzy, mapas cognitivos fuzzy dinâmicos e mecanismos adaptativos. Abordagens híbridas que integram mapas cognitivos fuzzy dinâmicos e otimização por colônia de formigas já foram investigadas em exploração multi-robótica, indicando uma direção promissora para ampliar a adaptação e a tomada de decisão distribuída (Mendonça et al., 2020). Uma solução híbrida poderia modificar automaticamente o valor de k conforme a urgência da tarefa, a incerteza das observações ou o nível de concordância do enxame.

Como continuidade, recomenda-se investigar ambientes dinâmicos nos quais o caminho inicialmente mais rápido possa tornar-se bloqueado ou menos eficiente durante a operação. Também seria relevante avaliar mais de duas alternativas, diferentes tamanhos de enxame, presença de robôs defeituosos, ruído na identificação das opiniões e agentes que transmitam informações incorretas (Jamshidpey; Dorigo; Heinrich, 2023; Kegeleirs; Birattari, 2025).

Outra possibilidade consiste em desenvolver uma versão adaptativa da regra k -Unanimity. Valores menores de k poderiam ser empregados no início da tarefa para acelerar a exploração, enquanto valores maiores seriam utilizados nas etapas posteriores para estabilizar a decisão. Estudos adicionais podem comparar a regra com votação majoritária, modelo do eleitor, inibição cruzada e mecanismos baseados em feromônios artificiais, incluindo métricas de consumo de energia, distância percorrida, número de mudanças de opinião, colisões e robustez diante de falhas (Shan; Mostaghim, 2021, 2023).

REFERÊNCIAS

BRAMBILLA, Manuele; FERRANTE, Eliseo; BIRATTARI, Mauro; DORIGO, Marco. Swarm robotics: a review from the swarm engineering perspective. *Swarm Intelligence*, v. 7, n. 1, p. 1-41, 2013. DOI: <https://doi.org/10.1007/s11721-012-0075-2>.

BRENNAN, Karen; RESNICK, Mitchel. New frameworks for studying and assessing the development of computational thinking. In: ANNUAL MEETING OF THE AMERICAN EDUCATIONAL RESEARCH ASSOCIATION, 2012, Vancouver. Vancouver: American Educational Research Association, 2012. p. 1-25.

BRUTSCHY, Arne; SCHEIDLER, Alexander; FERRANTE, Eliseo; DORIGO, Marco; BIRATTARI, Mauro. Can ants inspire robots? Self-organized decision making in

robotic swarms. In: IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS (IROS), 2012, Vilamoura. Los Alamitos: IEEE Computer Society Press, 2012. p. 4272-4273. DOI: <https://doi.org/10.1109/IROS.2012.6386273>.

CAN ANTS INSPIRE ROBOTS? Self-organized decision making in robotic swarms. [S. l.]: YouTube, 2012. 1 vídeo. Disponível em: <https://www.youtube.com/watch?v=uEXK-b3EAHU>. Acesso em: 27 jul. 2026.

DORIGO, Marco; THERAULAZ, Guy; TRIANNI, Vito. Swarm robotics: past, present, and future. *Proceedings of the IEEE*, v. 109, n. 7, p. 1152-1165, 2021. DOI: <https://doi.org/10.1109/JPROC.2021.3072740>.

JAMSHIDPEY, Aryo; DORIGO, Marco; HEINRICH, Mary Katherine. Reducing uncertainty in collective perception using self-organizing hierarchy. *Intelligent Computing*, v. 2, art. 0044, 2023. DOI: <https://doi.org/10.34133/icomputing.0044>.

KEGELEIRS, Miquel; BIRATTARI, Mauro. Towards applied swarm robotics: current limitations and enablers. *Frontiers in Robotics and AI*, v. 12, art. 1607978, 2025. DOI: <https://doi.org/10.3389/frobt.2025.1607978>.

MAYET, R.; ROBERZ, J.; SCHMICKL, T.; CRAILSHEIM, K. Antbots: a feasible visual emulation of pheromone trails for swarm robots. In: INTERNATIONAL CONFERENCE ON SWARM INTELLIGENCE, 7., 2010, Brussels. Berlin: Springer, 2010. p. 84-94. DOI: https://doi.org/10.1007/978-3-642-15461-4_8.

MENDONÇA, Márcio; PALÁCIOS, Rodrigo Henrique Cunha; PAPAGEORGIOU, Elpiniki I.; SOUZA, Lucas Botoni de. Multi-robot exploration using dynamic fuzzy cognitive maps and ant colony optimization. In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS (FUZZ-IEEE), 2020, Glasgow. Piscataway: IEEE, 2020. p. 1-8. DOI: <https://doi.org/10.1109/FUZZ48607.2020.9177814>.

MONTES DE OCA, Marco A. *et al.* Majority-rule opinion dynamics with differential latency: a mechanism for self-organized collective decision-making. *Swarm Intelligence*, v. 5, n. 3-4, p. 305-327, 2011. DOI: <https://doi.org/10.1007/s11721-011-0062-z>.

MONTUORI, Chiara; GAMBAROTA, Filippo; ALTOÈ, Gianmarco; ARFÈ, Barbara. The cognitive effects of computational thinking: a systematic review and meta-analytic study. *Computers & Education*, v. 210, art. 104961, 2024. DOI: <https://doi.org/10.1016/j.compedu.2023.104961>.

MORGAN, Hani. Conducting a qualitative document analysis. *The Qualitative Report*, v. 27, n. 1, p. 64-77, 2022. DOI: <https://doi.org/10.46743/2160-3715/2022.5044>.

REINA, Andreagiovanni; FERRANTE, Eliseo; VALENTINI, Gabriele. Collective decision-making in living and artificial systems: editorial. *Swarm Intelligence*, v. 15, p. 1-6, 2021. DOI: <https://doi.org/10.1007/s11721-021-00195-5>.

SCHEIDLER, Alexander; BRUTSCHY, Arne; FERRANTE, Eliseo; DORIGO, Marco. The k-Unanimity rule for self-organized decision-making in swarms of robots. *IEEE Transactions on Cybernetics*, v. 46, n. 5, p. 1175-1188, 2016. DOI: <https://doi.org/10.1109/TCYB.2015.2429118>.

SCHRANZ, Melanie; UMLAUFT, Martina; SENDE, Micha; ELMENREICH, Wilfried. Swarm robotic behaviors and current applications. *Frontiers in Robotics and AI*, v. 7, art. 36, 2020. DOI: <https://doi.org/10.3389/frobt.2020.00036>.

ŞAHİN, Erol. Swarm robotics: from sources of inspiration to domains of application. In: ŞAHİN, Erol; SPEARS, William M. (org.). *Swarm Robotics*. Berlin: Springer, 2005. p. 10-20. DOI: https://doi.org/10.1007/978-3-540-30552-1_2.

SHAN, Qihao; MOSTAGHIM, Sanaz. Discrete collective estimation in swarm robotics with distributed Bayesian belief sharing. *Swarm Intelligence*, v. 15, p. 377-402, 2021. DOI: <https://doi.org/10.1007/s11721-021-00201-w>.

SHAN, Qihao; MOSTAGHIM, Sanaz. Noise-resistant and scalable collective preference learning via ranked voting in swarm robotics. *Swarm Intelligence*, v. 17, p. 5-26, 2023. DOI: <https://doi.org/10.1007/s11721-022-00214-z>.

WING, Jeannette M. Computational thinking. *Communications of the ACM*, New York, v. 49, n. 3, p. 33-35, mar. 2006. DOI: <https://doi.org/10.1145/1118178.1118215>.