

Uma Estratégia de Coordenação Distribuída e Bio-Inspirada para Sistema Multiagentes Aplicada à Tarefa de Vigilância em Ambientes Desconhecidos

Rodrigo Calvo, Janderson R. de Oliveira, Roseli A. F. Romero

Instituto de Ciências Matemáticas e de Computação
Universidade de São Paulo
{rcalvo,jrodrigo,rafrance}@icmc.usp.br

Mauricio Figueiredo

Departamento de Computação
Universidade Federal de São Carlos
mauricio@dc.ufscar.br

Resumo – Uma estratégia distribuída de coordenação modelada de acordo com uma versão modificada do algoritmo que simula o comportamento de formigas é descrito. A estratégia é capaz de adaptar o sistema proposto para situações em que o número de robôs ou a estrutura do ambiente mudam. Duas versões da estratégia são avaliadas considerando diferentes sistemas de múltiplos robôs e ambientes. Simulações confirmam que comportamentos de exploração e vigilância emergem do comportamento individual do agente. O tempo necessário para concluir a exploração e o tempo decorrido entre dois sensoriamentos consecutivos em uma região avaliam a estratégia. Os resultados mostram a eficiência da estratégia para realizar tarefas cooperativas.

Palavras-chave – Sistema de colônia de formigas, sistemas coletivos, estratégia de coordenação, tarefa de vigilância.

Abstract – A new distributed coordination strategy, designed according to a modified version of the artificial ant system, is described. The strategy is able to adapt the current system dynamics if the number of robots or the environment structure or both change. Experiment simulations are executed to evaluate two versions of the strategy considering different multiple robot systems and environment structures. Results confirm that exploration and surveillance general behaviors emerge from the individual agent behavior. Needed time to conclude the task and the period of time between two consecutive sensory on a specific region are parameters to evaluate the strategy. The results show that the strategy is effective and efficient to execute the cooperative tasks.

Keywords – Ant colony system, swarm systems, coordination strategy, surveillance task.

1. INTRODUÇÃO

Sistemas multiagentes são caracterizados se sua dinâmica reflete alguma sinergia, ou seja, comportamentos globais emergem dos individuais, o que torna o sistema capaz de cumprir um determinado objetivo. Se somente um agente ou um grupo alcançam igualmente o mesmo objetivo e com o mesmo desempenho que o grupo obteve, então, a princípio, este não é considerado um sistema multiagente. Há muitas aplicações em que sistemas multiagentes são adotados, tais como: operações de resgate, eventos catastróficos, extinção de incêndios e exploração de ambientes hostis [1–3]. Algumas das principais razões que justificam esta escolha são: aumento da complexidade da tarefa e redução de recursos (velocidade, força, energia) vindos de um único agente; necessidade para adaptação ao espaço ou variação temporal da demanda de serviço; e robustez.

Aspectos como comunicação e fusão de informação são investigados em sistemas multiagentes [4–7]. Outro importante aspecto é a coordenação dos agentes que permite o sistema executar tarefas eficientemente como exploração, cobertura e vigilância de ambientes. Estratégias de coordenação são desenvolvidas para conceber sistemas multiagentes com características de descentralização de controle, baixa redundância entre os esforços dos agentes e comportamento cooperativo.

De acordo com a técnica descrita em [8], robôs constroem um mapa cooperativamente. O autor introduz a noção de uma fronteira como o limite entre as áreas exploradas e não exploradas. Durante o deslocamentos dos robôs, novos limites são detectados e fronteiras são agrupadas em regiões. Então, os robôs se movem em direção ao centro da região mais próxima, enquanto compartilha os mapas. A estratégia é centralizada desde que o algoritmo A* considera todas as informações geradas pelos robôs e define a nova direção de movimento individualmente. Porém, a estratégia não evita redundâncias dos recursos e esforços dos robôs. Diversas estratégias de exploração baseada em fronteira são investigadas em [9]. Tais estratégias diferem no processo de escolha da posição meta (localizada na fronteira) e na coordenação dos robôs. Técnicas de particionamento de ambientes são utilizadas para otimizar o desempenho, porém, os experimentos são limitados a ambientes conhecidos e convexos.

Uma estratégia de coordenação é apresentada em [10] e baseada em campos potenciais em que forças repulsivas afastam um robô dos demais e dos obstáculos. Os robôs iniciam a navegação em uma mesma região e se mantêm em movimento até cancelar as forças repulsivas. Neste instante, a rede de sensores móveis é estabelecida. Esta abordagem assegura a cobertura de um ambiente desde que o número de robôs seja suficientemente elevado.

A execução contínua da exploração de ambientes é aplicada em tarefas de segurança e monitoramento para tornar frequente a visita de um mesmo local [11]. Durante a missão de segurança, a estratégia em [12] permite que os robôs alternem seu comportamento em patrulhar, inspecionar, seguir um intruso e preservar um local. O método de tomada de decisão é baseado em lógica nebulosa dependente de fatores de entrada que descrevem a situação corrente de exploração. O sistema de vigilância descrito em [13] detecta mudanças no ambiente comparando histogramas de cores em imagens previamente obtidas. Porém, o ambiente é totalmente estável.

O problema de vigilância, considerado nesta proposta, requer que os robôs visitem (ou sensoriem) um ambiente repetidamente e continuamente. O desafio consiste em determinar as trajetórias ótimas para sensoriar e explorar todo o ambiente. Neste sentido, o problema de vigilância usando multiagentes é investigado como um problema de sensoriamento cooperativo em [11]. Uma formulação matemática é proposta como um problema de otimização. O objetivo é minimizar o tempo existente entre dois sensoriamentos consecutivos em que o ambiente é completamente coberto. A solução encontrada é um algoritmo de aproximação de custo computacional polinomial baseado na representação de grafo topológico e na cobertura de caminhos. Mesmo que este problema seja caracterizado como NP-completo, um estudo computacional de complexidade e um algoritmo de aproximação são apresentados para solucioná-lo.

Estratégias de coordenação desenvolvidas por meio de formulação matemática cujo o modelo de agentes e ambientes são dependentes de parâmetros, sofrem degradação no desempenho devido à falha de agentes [14, 15]. Teorias bio-inspiradas e evolucionárias fornecem fundamentos para desenvolver estratégias alternativas [16, 17]. Particularmente, versões artificiais análogas aos sistemas definem a dinâmica da organização social, observado em sistemas de enxames, são apropriados em aplicações envolvendo múltiplos agentes, por exemplo, controle, comunicação e coordenação descentralizados [18–20].

Uma nova estratégia de coordenação, denominado Sistema de Vigilância baseado na Modificação do Algoritmo de Colônias de Formigas (IAS-SS, sigla do inglês *Inverse Ant System-Based Surveillance System*), desenvolvido de acordo com uma modificação do algoritmo de formiga [21] é descrito. A estratégia é, primeiramente, direcionada à coordenação de múltiplos robôs aplicado às tarefas de exploração e vigilância de ambientes. Algumas características do sistema IAS-SS são: descentralização, independência de parâmetros do número de agentes e da estrutura do ambiente. A estratégia é capaz de adaptar a dinâmica do sistema se o número de agentes ou a estrutura do ambiente são alterados. Simulações são executadas para avaliar duas versões da estratégia de navegação do IAS-SS considerando diferentes configurações para o conjunto de agentes e do ambiente. Resultados confirmam que os comportamentos para a realização das tarefas de exploração e vigilância emergem do comportamento individual dos agentes (mover para locais com baixa concentração de feromônio). Diferentes conjuntos de dados são considerados para investigar as estratégias: tempo necessário para concluir a tarefa de exploração e o tempo demandado entre dois sensoriamentos consecutivos de uma região específica. Os resultados mostram que a estratégia é eficiente para executar as tarefas cooperativamente.

O restante do texto é organizado como segue. Seção 2 apresenta os fundamentos do sistema de colônia de formigas artificiais. A descrição do sistema de múltiplos robôs para a realização das tarefas de exploração e vigilância e as estratégias de coordenação do sistema IAS-SS são o foco da Seção 3. A dinâmica correspondente à liberação e evaporação do feromônio assim como os mecanismos para determinar a direção de movimento dos robôs também são definidos. Seção 4 mostra resultados de simulação obtidos a partir de conjuntos de experimentos. As principais contribuições, os aspectos relevantes da proposta e as expectativas para trabalhos futuros são destacados na Seção 5.

2. SISTEMA DE COLÔNIA DE FORMIGAS

Tarefas complexas realizadas por colônias de formigas, tais como transporte de objetos (alimentos) e construção de caminhos em busca de alimentos, demandam, relativamente, mais recursos do que uma única formiga possui [22, 23].

Há dois mecanismos de comunicação entre formigas biológicas: direta ou indireta. A comunicação direta envolve somente o agente transmissor e o receptor da informação. Por outro lado, a comunicação indireta é estabelecida pelas modificações do ambiente. Em outras palavras, mudanças no ambiente causadas por um agente refletem em informações percebidas por outro. Este mecanismo também é conhecido como estigmergia. Em particular para o algoritmo baseado no comportamento de formigas, estas depositam um tipo específico de substância (feromônio) no solo enquanto se locomovem. Diferentes tipos de feromônios são associadas a situações específicas. Se uma trilha de feromônio é encontrada e o seu tipo característico sugere a presença de alimento, mais formigas seguirão esta trilha, depositando mais feromônios ao longo do caminho e conseqüentemente reforçando o estímulo presente naquele trajeto. Um comportamento contrário acontece se o feromônio é do tipo repulsivo, o que poderia indicar risco e perigo. O mecanismo de estigmergia é considerado um dos fatores que contribuem decisivamente para ampliar as capacidades de uma única formiga. Colônias de formigas utilizam o mecanismo de estigmergia para coordenar suas atividades de forma distribuída [24].

Sistemas de formigas artificiais são projetados para resolver problemas complexos: problemas de otimização combinatória [21]. Analogamente, formigas artificiais (por exemplo, robôs) são capazes de utilizar a estigmergia. Trilhas de feromônio fornecem um tipo de informação distribuída que agentes artificiais podem utilizar como ferramenta para tomadas de decisão ou para modificar experiências anteriores [25]. Um comportamento de coordenação distribuída surge a partir dessa capacidade, fornecendo soluções para problemas associados à exploração de hiperespaços.

3. SISTEMA DE VIGILÂNCIA BASEADO NA VERSÃO MODIFICADA DO SISTEMA DE COLÔNIA DE FORMIGAS

O sistema proposto IAS-SS é desenvolvido para lidar com tarefas de exploração e vigilância, sendo projetado de acordo com as principais idéias da teoria de colônias de formigas artificiais. Essencialmente, o sistema é um grupo de agentes artificiais (por exemplo, robôs), cada um dos quais sendo capaz de se locomover independentemente e tomar decisões baseadas, exclusivamente, em estímulos recebidos do ambiente.

Enquanto os robôs navegam pelo ambiente, uma substância específica é depositada em suas trajetórias, o feromônio (análogo ao feromônio encontrado em sistemas de formigas biológicas). Os robôs processam individualmente os estímulos obtidos a partir do feromônio encontrado ao seu redor e ajustam suas direções de navegação. O sistema de navegação do robô considera um conjunto de estímulos detectados em diferentes ângulos a uma mesma distância. Quanto menor a quantidade da substância detectada em uma direção, maior é a probabilidade desta ser selecionada pelo robô. A lógica de decisão no IAS-SS é oposta àquela adotada na teoria tradicional de sistemas de colônia formigas. A lógica tradicional gera um realimentação positiva, ou seja, quanto maior a quantidade da substância em uma direção maior é a probabilidade de esta ser seguida.

O diagrama de blocos da Figura 1 representa a seqüência das principais ações que o sistema realiza a cada iteração.



Figura 1: Diagrama de Blocos Funcional para um único agente.

É importante mencionar que os robôs exibem a habilidade de evitar obstáculos sem um mecanismo específico incorporado ao sistema de navegação. Tal comportamento de navegação emerge da estimergia entre os agentes artificiais como uma consequência natural da forma como o feromônio é liberado no ambiente e dos efeitos dos estímulos gerados pelos feromônios.

Considerando um grupo de N robôs $k, k = 1, \dots, N$, em que cada robô k executa duas operações básicas, ajuste de direção e depósito de feromônio, uma descrição detalhada do sistema IAS-SS é dada a seguir.

3.1 AJUSTE DE DIREÇÃO

Para determinar o ângulo de direção duas estratégias são adotadas. A primeira, Amostragem Estocástica (AE), considera todos os estímulos de feromônio que podem ser detectados nos limites de alcance dos sensores (Figura 2). A segunda, Amostragem Estocástica Elitista (AEE), determina o ajuste da direção baseada apenas nos estímulos associados às menores concentrações de feromônio.




Figura 2: Modelo sensorial de um robô.

O modelo sensorial adotado detecta estímulos de feromônio a uma distância específica R , na extensão de 90° a esquerda até 90° a direita. O modelo utilizado processa a média da quantidade de feromônio depositada em cada intervalo angular. Um total de 180 ângulos divididos em intervalos angulares de mesma dimensão são analisados considerando os estímulos detectados nos diferentes ângulos $A_s, s = 1, \dots, S$.

3.2 AMOSTRAGEM ESTOCÁSTICA

Um valor de probabilidade é atribuído a cada ângulo discreto na amplitude do alcance do sensor. A probabilidade atribuída ao ângulo A_s é inversamente proporcional à quantidade de feromônio depositada no respectivo intervalo angular, ou seja, quanto menor é a quantidade de feromônio detectada, maior é a probabilidade associada ao ângulo em questão. Especificamente, a probabilidade $P(s)$ atribuída ao ângulo A_s é:

$$P(s) = \frac{1 - \tau_s}{\sum_{i=1}^S (1 - \tau_i)} \quad (1)$$

em que, τ_s é a quantidade de feromônio correspondente ao ângulo A_s .

O ajuste da direção é determinado por meio de uma variável aleatória discreta a definida através da probabilidade $P(s)$, assumindo valores no conjunto A_s , $s = 1, \dots, S$. De acordo com a estratégia, os robôs tendem a se mover para direções que apresentam baixa quantidade de feromônio. O comportamento geral observado é que os robôs se deslocam para áreas não exploradas ou para áreas pouco visitadas pelos robôs durante um período de tempo. O ajuste da direção é dado por:

$$\Theta_k(t) = \Theta_k(t-1) + \gamma A_s^* \quad (2)$$

em que, $\Theta_k(t)$ é a direção do movimento do robô k no instante t , $\gamma \in [0, 1]$ é a constante de suavização para o ajuste da direção e A_s^* é a direção selecionada pela probabilidade da equação 1.

No entanto, o mecanismo AE não é eficiente para áreas de grandes dimensões onde a quantidade de feromônio depositada é semelhante em diversas regiões. A pequena diferença da quantidade de feromônio entre as regiões torna possível a seleção de ângulos A_s definindo direções desfavoráveis a serem seguidas devido à natureza estocástica da estratégia. Para maximizar a área explorada em um período de tempo reduzido, um segundo mecanismo é investigado.

3.3 AMOSTRAGEM ESTOCÁSTICA ELITISTA

Diferentemente da Amostragem Estocástica, nesta abordagem nem todos os intervalos angulares são considerados para definir a direção do robô, mas apenas dois subconjuntos deles. O primeiro subconjunto U é formado pelos intervalos angulares cuja quantidade de feromônio é muito baixa. Especificamente, a estratégia ordena os intervalos angulares de acordo com a respectiva quantidade de feromônio e, então, apenas aqueles ângulos A_s associados às menores quantidades de feromônio são considerados para definir a direção. O segundo subconjunto V consiste de elementos escolhidos aleatoriamente, de acordo com uma distribuição uniforme, a partir dos ângulos A_s que não se encontram no primeiro subconjunto. Analogamente ao mecanismo AE, a probabilidade a cada intervalo de ângulo em ambos subconjuntos é inversamente proporcional a quantidade de feromônio depositada na respectiva região e definida de acordo com a equação 1. A porção de intervalos de ângulos considerados para os subconjuntos U e V são determinados pelos parâmetros α e β .

3.4 LIBERAÇÃO E EVAPORAÇÃO DE FEROMÔNIO

Em sistemas de formigas artificiais tradicionais, os agentes liberam feromônio apenas em suas respectivas posições, sinalizando exatamente o caminho percorrido pelos robôs [22]. Os agentes artificiais no IAS-SS, ao contrário, espalham feromônio sobre uma ampla área frontal às suas respectivas posições, correspondente à área de alcance do sensor.

Uma vez que o agente determina seu ajuste de direção (veja Seção 3.1), este se desloca e espalha feromônio na área de abrangência do sensor. A quantidade de feromônio depositada em uma determinada região decresce à medida que a distância em relação à posição do robô aumenta. O modelo de liberação de feromônio é descrito a seguir. Considere que L_t e Q são a área de abrangência do sensor na iteração t e o espaço completo do ambiente, respectivamente, tal que $L_t \subset Q \subset \mathbb{R}^2$. Assim, a quantidade de feromônio $\Delta_X^k(t)$, que o k -ésimo robô deposita na posição X na iteração t é dado por:

$$\Delta_X^k = \begin{cases} \eta \times e^{-\frac{(x-x_k)^2}{\sigma^2}}, & \text{if } X \in L_t \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

em que, X_k é a posição do k -ésimo robô e σ é a dispersão da Gaussiana, e $\eta \in [0, 1]$ é um fator que não permite a quantidade de feromônio depositada seja 1.

Múltiplos robôs depositam feromônio no ambiente simultaneamente, de forma que a quantidade total de feromônio depositada na posição X na iteração t depende da contribuição de cada robô. Além disso, o feromônio não é uma substância estável, ou seja, este evapora a uma taxa específica. A quantidade total de feromônio que evapora $\Phi_X(t)$ na posição X no instante t é modelada como segue:

$$\Phi_X(t) = \rho \tau_X(t) \quad (4)$$

em que, ρ é a taxa de evaporação e $\tau_X(t)$ é a quantidade total de feromônio na posição X na iteração t . Portanto, a quantidade total de feromônio $\tau_X(t)$ em X no instante t é (Equação 5):

$$\tau_X(t) = \tau_X(t)(1 - \rho) + \sum_{k=1}^K \left((1 - \tau_X(t)) \Delta_{x,y}^k \right) \quad (5)$$

4. RESULTADOS EXPERIMENTAIS

Simulações experimentais são realizadas para avaliar, preliminarmente, a estratégia de coordenação bioinspirada do sistema IAS-SS. A estratégia é considerada para gerar a dinâmica de sistemas de múltiplos robôs aplicados a tarefas de exploração e vigilância.

Os experimentos são divididos em três grupos. O primeiro consiste nos experimentos que exploram os métodos de ajuste de direção descritos na Seção 3.1. Os mecanismos são comparados com um modelo completamente uniforme. O segundo grupo é




Figura 3: Estrutura de ambientes.

projetado para investigar a influência das posições iniciais dos robôs no desempenho de suas tarefas. Os experimentos do terceiro grupo visam analisar o impacto do número de robôs no desempenho do sistema.

Os dados experimentais são selecionados e compilados assumindo as seguintes perspectivas. Primeiro, a tarefa de exploração é executada se o ambiente é completamente coberto, ou seja, o sistema é capaz de fornecer informações suficientes para mapear o ambiente. Contudo, quanto mais rápido o sistema completa esta tarefa, melhor é o seu desempenho. Segundo, o sistema realiza a tarefa de vigilância se não há um instante T^* tal que, depois deste instante, exista alguma região no ambiente que não é mais visitada. Apesar desta definição para a tarefa de vigilância ser precisa, esta não é adequada, uma vez que encontrar T^* pode ser impossível. Portanto, para fins práticos, é importante que o sistema conclua a tarefa continuamente, ou seja, o sistema deve iniciar uma nova etapa de sensoriamento de todo o ambiente sempre que a tarefa é concluída. Assim, quanto menor o tempo entre duas etapas de sensoriamento consecutivas, melhor é o desempenho do sistema.

Os ambientes no qual o sistema IAS-SS é aplicado são divididos em pequenas regiões conectadas, denominadas aqui como salas. Os ambientes utilizados nos experimentos estão na Figura 4. Os parâmetros do sistema são definidos como: $R = 8$ metros (raio do semicírculo onde o feromônio é depositado); $\gamma = 0.5$ (constante de suavização do ajuste da direção); velocidade do robô setada como 0.5 metros por segundo; $\sigma = 0.43R$ (dispersão da gaussiana de propagação de feromônio); $\rho = 10^{-4}$ (taxa de evaporação); $e \tau_X(0) = 0.5$ (quantidade de feromônio na iteração $t = 0$); $S = 360$ (número de intervalos angulares); α e β correspondem a 30% e 10% de todos os intervalos de ângulos, respectivamente; e o número máximo de iterações: 1000. Os valores atribuídos aos parâmetros correspondem àqueles para os quais o sistema IAS-SS atinge o melhor desempenho, considerando experimentos realizados previamente. O tempo discreto é adotado na simulação e é equivalente ao número de iterações.

4.1 ESTRATÉGIA UNIFORME VERSUS AMOSTRAGEM ESTOCÁSTICA VERSUS AMOSTRAGEM ESTOCÁSTICA ELITISTA

As estratégias de ajuste de direção, Amostragem Estocástica (AE) e Amostragem Estocástica Elitista (AEE), possuem características aleatórias, uma vez que o ajuste de direção é determinado de acordo com uma variável aleatória discreta. Para demonstrar que seus respectivos desempenhos não são uma mera consequência do comportamento aleatório, tais estratégias são comparadas com a Estratégia Uniforme (EU). De acordo com a estratégia EA, uma variável aleatória discreta, definida por uma distribuição uniforme no espaço de ângulos A_s , determina o ajuste de direção a ser realizado. Observa-se que não há conexão entre o feromônio e a estratégia uniforme; diferentemente das estratégias AE e AEE.

O ambiente projetado para a avaliação é ilustrado na Figura 3(a), onde é possível identificar seis salas. Três robôs k , $k \in \{1, 2, 3\}$, iniciam a navegação a partir das salas 1, 2 e 6, respectivamente.

Três conjuntos de gráficos da Figura 4, apresentam os resultados de simulação, cada um dos quais corresponde a uma estratégia. Para cada estratégia, registra-se o comportamento dos robôs. O eixo y representa as salas do ambiente e o eixo x representa as iterações da simulação. Cada linha vertical indica a iteração na qual os robôs completaram um ciclo de sensoriamento de todo o ambiente (os robôs visitaram, cooperativamente, todas as salas), considerando que uma nova etapa de sensoriamento é iniciada assim que o sistema conclui um ciclo. O período entre duas linhas verticais, ou seja, o período para completar uma etapa de sensoriamento é denotado como Intervalo de Vigilância (I.V.).

Dois aspectos são considerados para análise do desempenho das estratégias: o tempo necessário para completar a tarefa de exploração; e o intervalo de tempo entre dois sensoriamentos consecutivos (I.V.). Primeiramente, considerando a tarefa de exploração, os gráficos demonstram que o sistema IAS-SS com a estratégia EU é capaz de concluir a tarefa de exploração, contudo, após um longo período, precisamente na iteração 959. Observa-se que com as estratégias AE e AEE o sistema realiza mais eficientemente a tarefa, ou seja, o sistema a conclui num período de tempo menor, nas iterações 62 e 41, respectivamente.

O sistema IAS-SS com a estratégia EU conclui a tarefa de vigilância uma única vez (há apenas um único ciclo de I.V.), considerando toda a simulação. Há um contraste marcante quando este desempenho é comparado com aqueles obtidos pelas estratégias AE e AEE. As linhas verticais indicam que o sistema com estas últimas estratégias conclui continuamente a tarefa de vigilância (os robôs visitam cooperativamente todas as salas).

As tabelas `tab:alternancia1` e `tab:alternancia2` resumizam os resultados obtidos. O sistema com a estratégia AE conclui a tarefa de vigilância 9 vezes e com a estratégia AEE 12 vezes. Os intervalos entre dois ciclos consecutivos de sensoriamento são de 208 e 119 iterações, respectivamente. O sistema IAS-SS com AEE demonstra ser, claramente, superior.

As estratégias AE e AEE induzem um comportamento mais colaborativo quando comparado com a estratégia EU. Observa-se que os robôs que utilizam estratégias dependentes da intensidade de feromônio alternam mais regularmente de sala do que

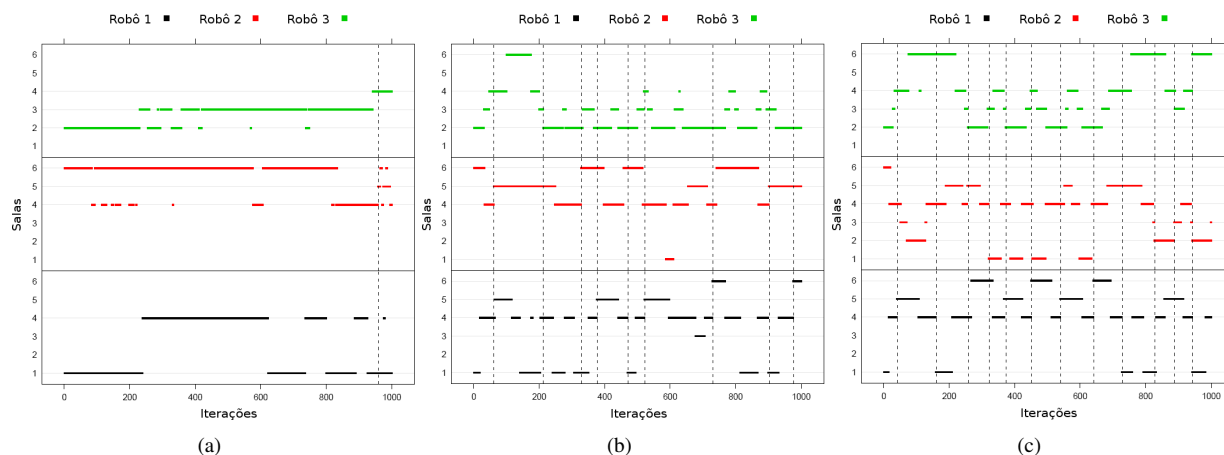


Figura 4: Desempenho do sistema IAS-SS de acordo com diferentes estratégias: (a) EU; (b) AE; (c) AEE mechanism.

aqueles que utilizam a estratégia EU. Por exemplo, o robô 2 visita as salas 6, 4 e 5 se o IAS-SS é executado com a estratégia EU; 1, 4, 5 e 6 se a estratégia AE é adotada; e o robô 2 visita todas as salas se a estratégia AEE é utilizada.

Tabela 1: Período do Intervalo de Vigilância para os Mecanismos de Ajuste de Direção

Mecanismos	Período máximo de I.V. Interval	Intervalos de Vigilância (iterações)											
		1°	2°	3°	4°	5°	6°	7°	8°	9°	10°	11°	12°
EU	959	959	—	—	—	—	—	—	—	—	—	—	—
AE	208	62	151	116	48	94	51	208	172	75	—	—	—
AEE	119	41	119	98	64	51	78	89	101	87	100	61	55

Tabela 2: Salas monitoradas em cada ciclo de Intervalos de Vigilância

Mecanismo	Robô	Salas monitoradas											
		1 st	2°	3°	4°	5°	6°	7°	8°	9°	10°	11°	12°
EU	# 1	1,4	—	—	—	—	—	—	—	—	—	—	—
	# 2	6,4,5	—	—	—	—	—	—	—	—	—	—	—
	# 3	2,3,4	—	—	—	—	—	—	—	—	—	—	—
AE	# 1	1,4	5,4,1	4,1	1,4,5	5,4,1	1,4,5	5,4,3,6	6,4,1	1,4,6	—	—	—
	# 2	6,4,5	5	5,4,6	6	6,4	6,4	4,1,5	4,6,5	5	—	—	—
	# 3	2,3,4	4,6,3,2	2,3	2,3	2,3	2,3,4	4,3,2	2,3,4	3,2	—	—	—
AEE	# 1	1,4,5	5,4,1	1,4	4,6	6,4,5	5,4,6	6,4,5	5,4,6	6,4,1	1,4	1,4,5	5,4,1
	# 2	6,4	4,3,2	4,5	5,4,1	1,4	4,1	4,1	4,5,1	4,5	5,4,3,2	2,3	3,4,2
	# 3	2,3,4	4,6	6,4,3,2	2,3	3,4,2	2,3,4	4,3,2	2,3,4	2,3,4	4,6	6,4,3	3,4,6

4.2 POSIÇÃO INICIAL DOS ROBÔS

Este grupo de experimentos avalia a eficiência do sistema IAS-SS para configurações distintas de posicionamento dos robôs. Duas configurações dos robôs são projetadas: 1) todos os robôs iniciam a navegação na mesma sala, Configuração Agrupado (CA) e 2) os robôs iniciam a navegação em salas distintas, Configuração Separado (CS). Para tarefas de exploração e vigilância, é óbvio que uma maior eficiência é garantida quando os robôs não estão próximos uns dos outros. Contudo, os experimentos tendem a demonstrar que, depois de um determinado período, os cenários envolvendo a configuração CA atingem a mesma eficiência daqueles em que a configuração CS é adotada. Experimentos para analisar o desempenho de acordo com a posição inicial dos robôs são realizados no ambiente da Figura 3(b). Para ambas as configurações, três robôs são lançados. Para as configurações CA e CS, os robôs iniciam a navegação a partir da sala 6; e salas 2, 6 e 7, respectivamente.

A seguir, seis configurações de ambientes são geradas a partir da combinação das configurações iniciais de posicionamentos (CA e CS) e das estratégias de ajuste de direção (Seção 4.1). O conceito chave da tarefa de vigilância é a minimização do tempo (iterações) no qual uma região permanece sem visita. Portanto, uma forma de medir o desempenho é analisar o período máximo (número máximo de iterações) no qual cada sala permanece sem ser visitada. Este período é apresentado na Figura 5(a) para distintas configurações ambiente.

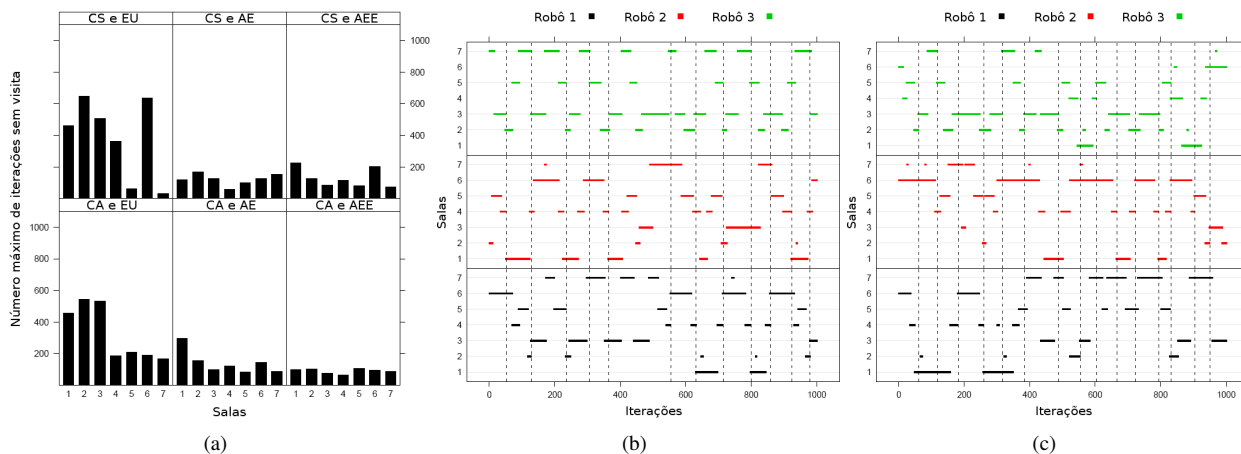


Figura 5: (a) Número máximo de iterações sem visita nas salas; (b) desempenho do sistema IAS-SS de acordo com diferentes configurações para a estratégia AEE e configuração CS; (c) CA.

Embora a configuração CS apresente uma pequena vantagem sobre a configuração CA, uma vez que na iteração $t = 0$ os robôs monitoram instantaneamente três salas distintas, o desempenho de ambas as configurações são similares. Uma das principais características do sistema IAS-SS é a habilidade dos robôs manterem distantes uns dos outros de acordo com o modelo de feromônio baseado na repulsão. Então, mesmo com a configuração CA, os robôs tendem a se espalhar pelo ambiente à medida que se locomovem. Assim, após um período de tempo, o desempenho da configuração CA torna-se semelhante àquele obtido pela configuração CS. Ou seja, a vantagem da configuração separados é diluída durante a navegação dos robôs. Para ilustrar este fato, os gráficos da Figura 5 apresentam o comportamento dos robôs e os intervalos de vigilância para as configurações de posicionamento utilizando a estratégia AEE. As demais estratégias não são apresentadas devido a limites de espaço.

4.3 NÚMERO DE ROBÔS

Os próximos experimentos abordam a relação entre o tamanho do ambiente e o número de robôs utilizados. De fato, quanto maior o número de robôs empregados, mais regiões são exploradas e monitoradas simultaneamente, de modo que, poucas ou nenhuma região permanece vazia por um longo período. Para avaliar o desempenho da coordenação de movimento e a eficiência da tarefa de vigilância, experimentos são realizados aumentando o número de robôs no ambiente da Figura 3(b). Como observado nos experimentos descritos anteriormente, a estratégia AEE apresenta desempenho mais eficiente em relação às demais, portanto, esta é adotada para analisar a eficiência das tarefas de exploração e vigilância a medida que o número de robôs é incrementado. Todos os robôs a serem adicionados são alocados na sala 1.

Embora esteja claro que o tempo para explorar todo o ambiente decai conforme o número de robôs aumenta, a tarefa de vigilância é realizada, sobretudo, com um número de robôs restrito. Esta característica enfatiza que o número de robôs não é um fator que limita o tamanho do ambiente a ser explorado. Poucos robôs são capazes de monitorar áreas amplas. O ciclo de I.V. é completado independentemente do número de robôs. Contudo, como comportamento geral do sistema, o tamanho do ciclo de I.V. é reduzido à medida que o número de robôs aumenta. Além disso, como consequência da adição de robôs, mais ciclos de I.V. se tornam presentes, conforme observado na Tabela 3. Devido ao espaço limitado, siglas foram estabelecidas para a descrição da Tabela 3, são elas: N.R., número de robôs; N.C.I.V., número de ciclos I.V.; e M.I.I.V, média de iterações em cada ciclo I.V.

Tabela 3: Desempenho do sistema de sensoriamento utilizando a configuração CA e mecanismo AEE

N.R.	N.C.I.V.	M.I.I.V.	N.R.	N.C.I.V.	M.I.I.V.
2	3	211.5	9	14	57.5714
3	5	178.75	10	19	44.5
4	6	147.2	11	21	38.9
5	7	117.3	12	21	39.15
6	9	93.625	13	22	39.1429
7	12	73.6364	14	26	31.96
8	13	58.0833	15	25	33.2083
9	14	57.5714	2	3	211.5

5. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho descreve uma nova estratégia de coordenação distribuída bioinspirada, denominada sistema IAS-SS, para sistemas multiagentes aplicados a tarefas de exploração e vigilância. A estratégia é baseada na teoria de sistemas de formigas.

De acordo com esta estratégia, os agentes são capazes de se comunicar indiretamente, tal como os agentes biológicos, contudo adotando uma reação ao feromônio distinta em relação à teoria tradicional. A estratégia do IAS-SS define a direção que orienta os agentes para regiões que apresentam baixas concentrações de feromônio.

Dois parâmetros, o número de robôs e as suas posições iniciais, acentuam a capacidade da estratégia. Duas versões da estratégia IAS-SS são consideradas e comparadas com uma estratégia totalmente aleatória. As estratégias baseadas no IAS-SS são significativamente superiores. Algumas características da estratégia proposta são: não dependência de conhecimento prévio da estrutura do ambiente; robustez em relação ao número de robôs utilizados, ou seja, em situações em que o número de robôs se altera (devido a falhas ou inserções de novos agentes), a estratégia é capaz de mudar a dinâmica do sistema para atingir um bom desempenho; e a estratégia mantém os robôs devidamente separados, orientando-os para regiões não visitadas recentemente.

Como trabalhos futuros alguns parâmetros do sistema IAS-SS serão considerados para análises, por exemplo: o mecanismo de liberação de feromônio. Além disso, um método de localização será integrado ao sistema IAS-SS para implantação da estratégia em robôs reais. Em adição, tarefas de vigilância mais complexas serão investigadas, como por exemplo quando um agente estranho invade o ambiente.

REFERÊNCIAS

- [1] J. G. Bellingham and K. Rajan. “Robotics in remote and hostile environments”. *Science*, vol. 318, no. 5853, pp. 1098–102, 2007.
- [2] H. H. Schmitt. “From the Moon to Mars”. *Nature*, 2009.
- [3] F. Mazzini, D. T. Kettler, J. Guerrero and S. Dubowsky. “Tactile Robotic Mapping of Unknown Surfaces, With Application to Oil Wells”. *IEEE T. Instrumentation and Measurement*, vol. 60, no. 2, pp. 420–429, 2011.
- [4] X.-L. Long, J.-P. Jiang and K. Xiang. “Towards Multirobot Communication”. In *Robotics and Biomimetics, 2004. ROBIO 2004. IEEE International Conference on*, pp. 307–312, 2004.
- [5] A. Speranzon. “Coordination, Consensus and Communication in Multi-Robot Control Systems”. Ph.D. thesis, Royal Institute of Technology, 2006.
- [6] C. Liu, Y. Ma and C. Liu. “Cooperative Multi-robot Map-Building Under Unknown Environment”. In *Proc. of the 2009 Int. Conf. on Art. Int. and Comp. Int. - Vol. 03, AICI '09*, pp. 392–396, Washington, DC, USA, 2009. IEEE Computer Society.
- [7] L. Andersson and J. Nygard. “On Multi-robot Map Fusion by Inter-robot Observations”. In *In proceedings of 12th International Conference on Information Fusion*, 2009.
- [8] B. Yamauchi. “A frontier-based approach for autonomous exploration”. In *Proceedings of the 1997 IEEE Int. Symposium on Computational Intelligence in Robotics and Automation*, pp. 146–, Washington, DC, USA, 1997. IEEE Computer Society.
- [9] S. Frank, K. Listmann, D. Haumann and V. Willert. “Performance analysis for multi-robot exploration strategies”. In *Proceedings of the Second international conference on Simulation, modeling, and programming for autonomous robots, SIMPAR'10*, pp. 399–410, Berlin, Heidelberg, 2010. Springer-Verlag.
- [10] A. Howard, M. J. Mataric and G. S. Sukhatme. “Mobile Sensor Network Deployment using Potential Fields: A Distributed, Scalable Solution to the Area Coverage Problem”. pp. 299–308, 2002.
- [11] F. Pasqualetti, A. Franchi and F. Bullo. “On optimal cooperative patrolling”. pp. 7153–7158, Atlanta, GA, USA, 2010.
- [12] M. Lee, M. Tarokh and M. Cross. “Fuzzy logic decision making for multi-robot security systems”. *Artificial Intelligence Review*, vol. 34, pp. 177–194, 2010. 10.1007/s10462-010-9168-8.
- [13] M. Castelnovi, P. Musso, A. Sgorbissa and R. Zaccaria. “Surveillance robotics: analyzing scenes by colors analysis and clustering”. In *Computational Intelligence in Robotics and Automation, 2003. Proceedings. 2003 IEEE International Symposium on*, volume 1, pp. 229 – 234 vol.1, july 2003.
- [14] J. Tan, N. Xi, W. Sheng and J. Xiao. “Modeling multiple robot systems for area coverage and cooperation”. In *Robotics and Automation, 2004. Proceedings. ICRA '04. 2004 IEEE International Conference on*, volume 3, pp. 2568 – 2573 Vol.3, april-1 may 2004.
- [15] Q. Jiang. “An improved algorithm for coordination control of multi-agent system based on r-limited voronoi partitions”. In *Automation Science and Engineering, 2006. CASE '06. IEEE International Conference on*, pp. 667 –671, 2006.
- [16] F. Kobayashi, N. Tomita and F. Kojima. “Re-formation of mobile robots using genetic algorithm and reinforcement learning”. In *SICE 2003 Annual Conference*, volume 3, pp. 2902 –2907 Vol.3, 2003.
- [17] L. Barnes, W. Alvis, M. Fields, K. Valavanis and W. Moreno. “Swarm Formation Control with Potential Fields Formed by Bivariate Normal Functions”. *Mediterranean Conference on Control and Automation*, vol. 0, pp. 1–7, 2006.

- [18] J. Hereford. “A Distributed Particle Swarm Optimization Algorithm for Swarm Robotic Applications”. In *Evolutionary Computation, 2006. CEC 2006. IEEE Congress on*, pp. 1678 –1685, 2006.
- [19] M. S. M. Hess and K. Schilling. “Formation driving using particle swarm optimization and reactive obstacle avoidance”. In *Proc. of 1st IFAC Workshop on Multivehicle Systems (MVS'06)*.
- [20] M. Dorigo, M. Birattari and T. Stutzle. “Ant colony optimization artificial ants as a computational intelligence technique”. *IEEE Comput. Intell. Mag.*, vol. 1, no. 4, pp. 28–39, 2006.
- [21] M. Dorigo. “Optimization, Learning and Natural Algorithms”. Ph.D. thesis, Politecnico di Milano, Italy, 1992.
- [22] E. Bonabeau, M. Dorigo and G. Theraulaz. “Inspiration for optimization from social insect behavior”. *Nature*, 2000.
- [23] G. D. C. M. Dorigo and L. Gambardella. “Ant Algorithms for Discrete Optimization”. Technical report, IRIDIA/98-10, Universite Libre de Bruxelles, 1999.
- [24] D. Yingying, H. Yan and J. Jingping. “Multi-robot cooperation method based on the ant algorithm”. In *Swarm Intelligence Symposium, 2003. SIS '03. Proceedings of the 2003 IEEE*, pp. 14 – 18, 2003.
- [25] C. Blum. “Review of ”Ant colony optimization” by M. Dorigo, T. Stutzle, MIT Press, Cambridge, MA, 2004”. *Artif. Intell.*, vol. 165, pp. 261–264, July 2005. Reviewer-Blum, Christian.