

# Estratégia de Formação Auto-adaptativa Baseada em uma Modificação do Algoritmo ACO

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

Departamento de Ciências da Computação

Universidade de São Paulo

São Carlos, Brasil

Email: {jrodrigo,rcalvo,rafrance}@icmc.usp.br

**Resumo**—Neste trabalho é proposta uma estratégia para coordenação de um sistema com múltiplos robôs aplicado a tarefas em que a formação é uma característica essencial requerida. O projeto da estratégia é inspirado em mecanismos biológicos que definem a organização social de sistemas coletivos, especificamente, sistemas de colônias de formigas. Diagramas de Voronoi e triangularização de Delaunay são outras técnicas utilizadas para modelar a estratégia. A estratégia se adapta a diversos cenários, nos quais a estrutura do ambiente muda. O desempenho do sistema de coordenação é avaliado utilizando-se um simulador. A estratégia é flexível e robusta em relação ao ambiente, adaptando a topologia do grupo quando necessário. Tarefas de mapeamento do ambiente podem ser eficientemente executadas, independentemente da configuração do ambiente ou dos obstáculos presentes no mesmo.

**Palavras chaves**—sistemas com múltiplos agentes; formação; sistemas bio-inspirados; estratégias autônomas

## I. INTRODUÇÃO

A forma na qual indivíduos se integram autonomamente em um grupo dinâmico e complexo tem atraído a atenção da comunidade científica. A descoberta de regras que guiam a dinâmica do grupo e como princípios físicos são relacionados aos indivíduos são áreas de estudo de matemáticos, físicos, biólogos e cientistas da computação [1]. Outro ponto de interesse é o motivo pelo qual agentes biológicos de uma mesma espécie tendem a se mover próximos uns dos outros. Através de observações de situações reais e simuladas de agentes biológicos, Partridge [2] afirma que os animais são capazes de realizar tarefas mais complexas, aumentando suas habilidades de defesa, assim como suas chances de sobrevivência, quando se movem em um grupo. Há várias aplicações nas quais sistemas com múltiplos agentes são adotados, tais como: mapeamento de ambientes, transporte de objetos, escolta de materiais perigosos e operações de resgate [3].

Para as aplicações citadas, um fator essencial é a posição espacial relativa entre os robôs. No presente artigo, esta característica é denominada formação dos robôs. A formação dos robôs implica na organização e na manutenção de uma forma geométrica pelo grupo de robôs. Sistemas com múltiplos agentes utilizam estratégias de formação tanto para estabelecer a forma geométrica do grupo de agentes quanto para

maximizar a cobertura da área de sensoriamento dos robôs [4]. A maximização da área de cobertura permite que os robôs adquiram uma melhor e mais completa representação do ambiente no qual estão inseridos. Esta representação pode ser modelada como o próprio mapa do ambiente.

Reynolds [5] definiu três critérios que devem ser satisfeitos para que um grupo de robôs estabeleça uma formação, independentemente da estratégia adotada. Estes critérios são: (1) separação – um agente do grupo deve ser repellido por aqueles que estão próximos para evitar colisões; (2) alinhamento – todos os agentes devem assumir uma mesma orientação; e (3) coesão – a formação dos agentes deve ser mantida enquanto estes se locomovem como um grupo pelo ambiente.

Um modelo bio-inspirado de coordenação de múltiplos robôs para tarefas de exploração e vigilância foi proposto por nós em [6]. Este modelo, denominado IAS-SS (do inglês *Inverse Ant System-Based Surveillance System*), é projetado de acordo com uma versão modificada do algoritmo apresentado em [7], baseado no conceito de Otimização por Colônia de Formigas (do inglês *Ant Colony Optimization* – ACO). A direção de movimento dos agentes na estratégia IAS-SS é definida para guiá-los preferencialmente para áreas com baixa concentração de feromônio. Neste caso, os robôs são espalhados pelo ambiente e monitoram várias áreas simultaneamente.

O fenômeno conhecido como evaporação do feromônio garante ainda que os robôs visitem novamente áreas já monitoradas anteriormente. É importante salientar que estas características são substancialmente favoráveis para algumas aplicações, como por exemplo, o mapeamento. Uma vez que os robôs que compõem o sistema são espalhados pelo ambiente de acordo com as taxas de feromônio, uma maior área de sensoriamento é atingida, e consequentemente um mapa mais representativo do ambiente é construído. Além disso, em decorrência do fenômeno de evaporação, esta estratégia garante que os robôs voltem a monitorar uma área previamente visitada depois de certo tempo, permitindo assim que qualquer alteração na estrutura do ambiente seja devidamente captada e representada através do mapeamento contínuo das áreas que constituem o ambiente considerado.

Como uma extensão da estratégia IAS-SS e considerando a formação de robôs, o presente trabalho objetiva propor uma estratégia de coordenação bio-inspirada de múltiplos robôs para o problema de formação, denominada SAFS (do inglês *Self-Adaptive Formation System*). Uma vez que a tarefa de formação requer uma maior interação entre os agentes, a estrutura dos robôs é mais complexa em relação àquela proposta no IAS-SS. A topologia da formação é determinada através de fundamentos baseados em diagramas de Voronoi e triangularização de Delaunay.

Uma característica intrínseca desta estratégia é a habilidade de aumentar a área de cobertura monitorada pelo grupo de robôs sempre que a topologia muda. Resultados experimentais demonstram que a estratégia não depende de conhecimento prévio sobre o ambiente, atuando eficientemente em ambientes com diferentes configurações. Uma vez que a estratégia é flexível e robusta em relação ao ambiente, adaptando a topologia do grupo quando necessário, tarefas de mapeamento do ambiente podem ser eficientemente executadas, independentemente da configuração do ambiente ou dos obstáculos presentes nele.

O restante do artigo é organizado como segue. Na Seção II são apresentados alguns trabalhos relacionados. A estratégia de formação SAFS é descrita na Seção III. Na Seção IV, os resultados obtidos através de simulações são discutidos. As principais contribuições e aspectos relevantes deste trabalho, assim como propostas de trabalhos futuros, são abordados na Seção V.

## II. TRABALHOS RELACIONADOS

A técnica ACO, introduzida por [7], é uma abordagem meta-heurística, inicialmente utilizada para resolver problemas de otimização discreta. O método baseia-se no comportamento de populações de formigas à procura de alimento e na organização do trabalho, possibilitando a execução de atividades coletivas descentralizadas por meio da auto-organização. Diversas abordagens para formação de robôs foram propostas na literatura considerando os critérios elucidados por Reynolds [5]. Embora não exista uma clara definição, as abordagens para formação de robôs podem ser organizadas nas seguintes categorias: comportamental, baseada em consenso, líder-seguidor, estrutura virtual e abordagens baseadas em funções potenciais com líder virtual.

Na abordagem comportamental, vários comportamentos são definidos. Um agente pode assumir um destes comportamentos ou um comportamento resultante da combinação de qualquer número deles. De acordo com o estado atual do ambiente um comportamento pode ser mais enfatizado do que outro [8]. Através de derivações da abordagem comportamental, foi proposto em [9] um conjunto de funções de controle, baseadas em campos potenciais clássicos e na velocidade dos agentes, para definir a formação dos robôs.

O controle da formação baseado em consenso depende do fluxo de dados entre os agentes. Os agentes de um time são capazes de atualizar suas próprias informações, através do fluxo distribuído de dados, até convergirem para um objetivo

comum. As conexões de comunicação entre os agentes determinam os vizinhos de um agente [10].

De acordo com a abordagem líder-seguidor, a função do líder é indicar o caminho que deverá ser percorrido pelos seguidores. Além de seguir o líder, os seguidores devem manter a coesão do grupo. Diversos mecanismos são adotados para atingir a formação. Redes neurais adaptativas e otimização por enxame de partículas [11] são utilizados para ajustar a direção de movimento do grupo, segundo uma trajetória previamente definida. Um mecanismo essencial para definir a formação em [12] é a comunicação entre os agentes. Neste contexto, há dois modelos de comunicação: no primeiro, o líder distribui informação (em relação a sua trajetória) para todos os robôs; no segundo, o líder transmite este dado apenas aos seus vizinhos. Uma limitação da abordagem líder-seguidor é o fato de que se o líder falha, a formação dos robôs é danificada devida a perda de comunicação entre o líder e os seguidores.

A abordagem de estrutura virtual lida com uma das limitações da robótica cooperativa, sendo esta a concepção da formação estática e geométrica. Nesta abordagem, uma formação geométrica é definida por um agente externo, antes que os agentes internos iniciem a navegação. Uma estrutura virtual é fundamental para certas tarefas específicas, como por exemplo, o comboio e transporte de objetos [13]. Veículos aéreos são coordenados segundo uma abordagem de estrutura virtual em [14]. De acordo com Alboul et al. [15], robôs móveis são utilizados em um ambiente dividido em triângulos virtuais. Inicialmente, os robôs são posicionados nos vértices destes triângulos, de maneira que as bordas dos triângulos representam conexões entre os robôs.

Como uma alternativa da estrutura virtual, abordagens baseadas em funções potenciais intensificam a interação entre os agentes. A formação é atingida de acordo com a função potencial adotada. Em [16], os robôs são espalhados no ambiente através de campos potenciais, visando maximizar a área de cobertura do ambiente. Cada robô é repelido dos obstáculos e dos demais robôs, sendo que este processo é realizado até que o grupo de robôs atinja um estado de equilíbrio. Contudo, a convergência do sistema não é garantida para qualquer configuração inicial do ambiente, considerando as posições dos robôs e obstáculos [17].

Motivada pelas vantagens das abordagens descritas anteriormente, a estratégia SAFS é projetada como uma proposta híbrida de abordagens do tipo comportamental, baseada em consenso e líder-seguidor. Dessa forma, a estratégia SAFS apresenta as seguintes características: (1) descentralização: os robôs são independentes e suas tomadas de decisão são baseadas apenas em informações locais; (2) livre de colisões: o ato de estabelecer uma formação implica que os robôs devem manter uma distância segura entre si; (3) adaptação: a estratégia de coordenação deve ser capaz de manter a formação dos robôs independentemente da configuração do ambiente; (4) topologia dinâmica: o conjunto de topologias que o grupo de robôs pode assumir é desconhecido. O grupo é capaz de adaptar adequadamente a topologia da formação para um cenário específico; e (5) estabilidade: independente do cenário encontrado pelo grupo, os robôs não devem se dispersar do grupo.

A união destas características em uma única estratégia de formação não é encontrada em nenhuma das abordagens existentes. Além disso, como a estratégia se adapta a qualquer tipo de ambiente, aplicações que envolvem a tarefa de exploração do ambiente podem ser eficientemente realizadas. Uma vez que não há colisões entre os robôs e a estratégia é eficaz em ambientes com diferentes configurações, uma tarefa importante para a robótica móvel, que é o mapeamento autônomo de ambientes, poderia ser realizada localmente em cada um dos agentes do grupo.

### III. SISTEMA DE FORMAÇÃO AUTO-ADAPTATIVO

Na estratégia SAFS, os robôs depositam feromônio com propriedades repulsivas e atrativas para realizar comportamentos de exploração e formação, respectivamente. Considerando a abordagem líder-seguidor, o líder é o único robô a liberar feromônio repulsivo, para indicar áreas exploradas, e feromônio atrativo, denotando o trajeto a ser percorrido pelos seguidores. O líder detecta apenas o feromônio repulsivo, guiando os robôs para áreas com baixas concentrações deste feromônio. Os seguidores, em contrapartida, depositam apenas feromônio repulsivo, demarcando áreas exploradas, e detectam apenas o feromônio atrativo, visando seguir a trajetória adotada pelo líder.

A comunicação direta entre os agentes é estabelecida por uma antena. Este dispositivo emite e detecta informação, ou mensagens, em torno dos robôs dentro de um raio de comunicação  $R_C > 0$ . Há dois tipos de mensagens que podem ser emitidas e detectadas pela antena, modeladas como pares do tipo:  $(msg\_id, msg\_nivel)$  e  $(msg\_id, msg\_feromonio)$ . O primeiro termo em ambos os tipos,  $msg\_id$ , corresponde ao identificador de um determinado robô. O segundo termo,  $msg\_nivel$  e  $msg\_feromonio$ , indicam o nível hierárquico na topologia da formação dos robôs e a concentração de feromônio repulsivo detectada pelo agente, respectivamente. O primeiro par é emitido de forma contínua, enquanto que o segundo apenas é transmitido quando é necessário definir um novo líder para a formação.

A formação dos robôs é estabelecida enquanto os mesmos se locomovem pelo ambiente. A formação é representada através de uma topologia, na qual cada robô é associado a um nível hierárquico. Uma vez que o robô líder está no nível zero, o nível hierárquico dos seguidores é gradualmente incrementado em uma unidade, segundo a amplitude do caminho no grafo que descreve a topologia da formação (Fig. 1).

O sistema cibernético dos robôs na estratégia SAFS é composto por sete componentes: Núcleo de Decisão, Módulo de Hierarquia, Módulo de Inicialização, Módulo Líder, Módulo Seguidor, Módulo de Desvio de Obstáculos e Módulo de Feromônio.

A cada instante, os robôs recebem estímulos do ambiente através de seus sensores de feromônio e de distância de obstáculos, além das informações provenientes da antena. Estes sinais são interpretados no Núcleo de Decisão, que é responsável por atualizar o estado do robô. As funções do Núcleo de Decisão de um robô são: identificar sua vizinhança,

o instante em que o grupo necessita de um líder e o momento exato em que o robô deve desviar de um obstáculo.

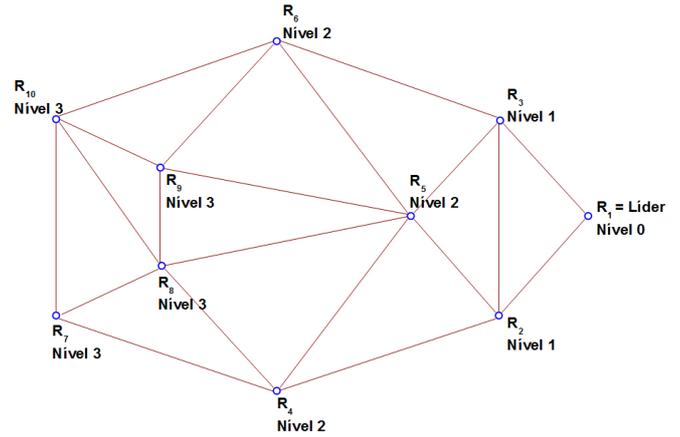


Figura 1. Nível hierárquico dos robôs em formação

Considerando a primeira função, um robô  $r_k$  é capaz de detectar seus vizinhos através de mensagens recebidas pela antena. Estas informações são organizadas em dois conjuntos de pares,  $D_{A1} = \{(msg\_id_i, msg\_nivel_i) \mid 0 \leq i \leq n\}$  e  $D_{A2} = \{(msg\_id_i, msg\_feromonio_i) \mid 0 \leq i \leq n\}$ , em que  $n$  é o número de vizinhos detectados, ou seja, os robôs que estão a uma distância de  $r_k$  menor do que  $R_C$ . Se um robô não possui vizinhos ( $n^k = 0$ ), então o Núcleo de Decisão deduz que este é um líder. Neste contexto, o Módulo Líder é ativado e o Módulo Seguidor é desativado. O vetor  $N^k$  resultante do processo de detecção contém o par ordenado  $(msg\_id_i, msg\_q_i)$ , em que  $q_i \in Q$  é a posição do  $i$ -ésimo vizinho do robô  $k$ . O Algoritmo 1 define as etapas do processo de detecção de vizinhança.

---

#### Algoritmo 1 Função de Detecção de Vizinhança

---

##### Entrada:

$$D_{A1} = \{(msg\_id_i, msg\_nivel_i) \mid i = 0, 1, \dots, n^k\}$$

##### Saída:

$$N^k = \{(msg\_id_j, msg\_q_j) \mid j = 0, 1, \dots, n^k\}$$

$$n^k$$

1. **para todo** robô  $msg\_id_i \in D_A$  **faça**
  2. Encontre a distância até o robô  $msg\_id_k$
  3. Encontre a direção de  $msg\_id_i$  em relação à  $msg\_id_k$
  4. Calcule a posição  $msg\_q_i$  do robô  $msg\_id_i$
  5.  $N^k \leftarrow (msg\_id_i, msg\_q_i)$
  6. **fim para**
  7. **retorne**  $N^k$  e  $n^k$
- 

De acordo com a segunda função do Núcleo de Decisão, um robô recebe informação sobre o nível de seus vizinhos

( $D_{A1}$ ) continuamente. Se o robô é um seguidor, a informação detectada é útil para determinar seu próprio nível na topologia do grupo. Se um robô não recebe os níveis de seus vizinhos, este não é capaz de transmitir seu próprio nível. Se o robô não recebe esta informação por um período longo, ou este está disperso do grupo ou está em um grupo que ainda não possui líder. Neste caso, o Módulo de Inicialização é ativado para eleger um novo líder.

Para detectar o instante em que um robô deve desviar de um obstáculo (terceira função), o Núcleo de Decisão analisa todas as leituras do sensor de distância de obstáculos. Se pelo menos uma destas leituras indica que a distância entre o robô e o obstáculo mais próximo é menor do que  $\eta > 0$ , então o Módulo de Desvio de Obstáculos é ativado.

O único módulo que é ativado independentemente do estado do robô é o Módulo de Hierarquia, no qual a topologia do grupo de robôs é estabelecida. Níveis hierárquicos são propagados entre as conexões do grafo que representam a topologia. Dentre os  $N_k$  vizinhos do robô  $r_k$  determinados pelo Núcleo de Decisão, apenas aqueles diretamente conectados são considerados. Para este propósito, a triangularização de Delaunay é aplicada, resultando no grafo  $G_k(V_k, E_k)$ , em que  $V_k$  é o conjunto de vértices que correspondem às posições dos vizinhos, incluindo a posição do robô  $r_k$  ( $V_k = N^k \cup \{(msg\_id_k, msg\_q_k)\}$ ) e  $E_k$  é o conjunto de conexões. Os vizinhos diretamente conectados ao robô  $r_k$  são denotados como vizinhos adjacentes e modelados pelo conjunto  $N_{ADJ}^k = \{(msg\_id_i, msg\_q_i) \mid (msg\_q_i, msg\_q_k) \in E_k\}$ .

No Módulo de Inicialização, um novo líder é definido. Uma vez que o líder é guiado para regiões com baixa concentração de feromônio repulsivo, o novo líder é aquele que detecta a menor concentração desta substância. No instante em que o Módulo de Inicialização é ativado, a transmissão de  $D_{A1}$  é interrompida e os robôs começam a emitir  $D_{A2}$ , na qual a quantidade de feromônio repulsivo é armazenada. O líder é definido utilizando o fluxo de informação entre os robôs. O procedimento para detecção da menor concentração de feromônio e, conseqüentemente, para definição do novo líder é descrito no Algoritmo 2.

---

#### Algoritmo 2 Inicialização

---

##### Entrada:

$modo\_inicialização_k$

$D_A = \{(msg\_id_i, msg\_feromonio_i) \mid i = 0, 1, \dots, n^k\}$

$N^k = \{(msg\_id_j, msg\_q_j) \mid j = 0, 1, \dots, n^k\}$

##### Saída:

$(id\_feromonio_k, qtde\_feromonio_k)$

1. **se**  $modo\_inicialização_k = 1$  **então**
  2.   **para todo**  $(msg\_id_i, msg\_feromonio_i) \in N^k$  **faça**
  3.     **se**  $qtde\_feromonio_k > msg\_feromonio_i$  **então**
  4.        $qtde\_feromonio_k \leftarrow msg\_feromonio_i$
- 

5.      $id\_feromonio_k \leftarrow msg\_id_k$
  6.   **fim se**
  7.   **fim para**
  8. **fim se**
  9. **retorne**  $(id\_feromonio_k, qtde\_feromonio_k)$
- 

As funções atribuídas ao líder são especificadas no Módulo Líder, sendo estas: (1) atrair seguidores, liberando uma trilha de feromônio atrativo a ser percorrida; (2) iniciar o processo que define os níveis hierárquicos do grupo; e (3) estimular o deslocamento do grupo para regiões com baixa concentração de feromônio repulsivo. Embora este módulo seja fundamental na abordagem líder-seguidor, a formação não é prejudicada se o líder do grupo falha. Neste caso, o Núcleo de Decisão detecta a interrupção da transmissão da informação de nível e ativa o Módulo de Inicialização para determinar um novo líder.

Na estratégia SAFS, os seguidores são responsáveis por manter a formação. Os seguidores são orientados segundo três comportamentos: (1) seguir a trilha de feromônio atrativo liberada pelo líder; (2) seguir os vizinhos; e (3) dispersar dos mesmos, comportamento este representado pela atração dos centroides das células do diagrama de Voronoi.

No Módulo de Feromônio, dois tipos diferentes de feromônio são depositados. Se um robô é o líder, então o mesmo deposita feromônio atrativo e repulsivo. Caso contrário, o robô libera apenas feromônio repulsivo. A dinâmica para liberação e evaporação de feromônio é a mesma apresentada em [6]. Por fim, no Módulo de Desvio de Obstáculos, é utilizado um mecanismo para evitar obstáculos baseado em lógica fuzzy [18]. Embora a estratégia SAFS guie os robôs em uma navegação livre de colisões, há algumas exceções nas quais um robô pode colidir contra outros robôs ou obstáculos, devido à suas próprias características físicas. Este mecanismo é ativado quando a distância do robô e um obstáculo é menor do que uma constante pré-definida  $\eta$ .

## IV. RESULTADOS EXPERIMENTAIS

Os experimentos são executados na plataforma Player/Stage, que é capaz de executar vários modelos de robôs e sensores, simulando simultaneamente suas dinâmicas exatas. O modelo de robô utilizado neste trabalho é o Pioneer 2DX equipado com um sensor laser capaz de mapear o ambiente.

Inicialmente, é analisada a eficiência da força de atração dos centroides. Diferente das demais forças, esta permite que os robôs se dispersem, evitando colisões. Embora o grupo de robôs não se desloque, apenas com esta força, é possível observar a habilidade da estratégia SAFS em dispersar os robôs do grupo. Além disso, a dispersão dos robôs implica na maximização da área de cobertura, a qual reflete uma importante característica da formação. A aplicação desta força reflete o critério de separação definido por Reynolds [5]. Em tarefas de mapeamento, esta força pode ser vista como um fator determinante para se obter um mapa que represente realisticamente um ambiente qualquer.

Para verificar a dispersão dos robôs, assim como a maximização da área de cobertura, são utilizados 10 robôs próximos uns dos outros em um ambiente amplo. Na Fig. 2(a), apresentam-se os robôs em suas configurações espaciais iniciais. A cada instante, os robôs detectam seus vizinhos adjacentes, constroem células de Voronoi, computam seus centroides e, por fim, se locomovem até estes. Se um robô está longe de seu centroide, então o mesmo estará próximo ao limite de fronteira da célula. Isto significa que existe um risco de colisão com um obstáculo ou outro robô. Neste caso, a intensidade da força de atração do centroide é maior. À medida que um robô se aproxima de seu centroide, a intensidade da força diminui. O estado de equilíbrio é atingido no instante em que todos os robôs estão exatamente, ou extremamente próximos, de seus respectivos centroides. A configuração final dos robôs após a dispersão é ilustrada na Fig. 2(b).

Para o próximo experimento, são utilizados novamente 10 robôs em um ambiente que consiste de duas áreas amplas ligadas por um corredor estreito. Inicialmente, não há líder no grupo. Então, o Núcleo de Decisão dos robôs detecta a ausência de transmissão da informação de nível hierárquico e ativa o Módulo de Inicialização, visando definir um líder. Especificamente, o líder definido é destacado por uma flecha na Fig. 3(a).

Uma vez que os robôs estão próximos uns dos outros e distante de seus centroides, o primeiro comportamento observado é a dispersão, estabelecendo uma formação. Depois disso, a formação é mantida com a mesma topologia até o líder atingir o corredor, Fig. 3(b). Neste momento a topologia é reorganizada, de forma autônoma, permitindo que o grupo atravesse o corredor, Fig. 3(c) e Fig. 3(d). Saindo do corredor, o grupo encontra novamente uma área ampla, de modo que as forças de atração dos centroides impulsionam os robôs a se dispersar mais uma vez, maximizando a área de cobertura do grupo, como observado na Fig. 3(e). As células de Voronoi

geradas durante a navegação são apresentadas na Fig. 3(f) – 3(j). As regiões em amarelo indicam locais com concentração de feromônio atrativo, sendo que nas regiões mais escuras a concentração é maior.

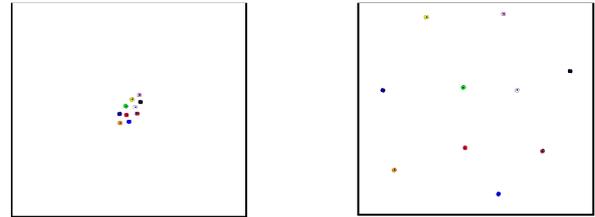


Figura 2. Processo de dispersão baseado na atração dos centroides: (a) configuração inicial; (b) configuração final.

Uma análise adicional é verificada na Fig. 4. Para cada robô, é observada a distância para seu vizinho mais próximo durante 1000 iterações. Este vizinho foi escolhido, pois este representa o maior risco de colisão. Deve-se salientar que o robô 1 é o líder e como tal, não possui um vizinho adjacente com nível inferior ao seu próprio. Sendo assim, sua curva é constante em zero. Até a iteração 60, há pequenas oscilações nas curvas devido ao comportamento de dispersão do sistema. Depois disso, a formação é estabelecida, de maneira que a curva de distância flutua em torno de um valor constante até o grupo atingir o corredor (iteração 210). Neste momento, caracterizado pelo gargalo, as curvas de distância sofrem algumas variações. Devido à formação alongada dentro do corredor (iteração 210 até 420), o Módulo de Hierarquia pode definir um vizinho adjacente com nível baixo que esteja longe do líder. A expansão do grupo ocorre novamente quando os robôs deixam o corredor (iteração 420 até 630).

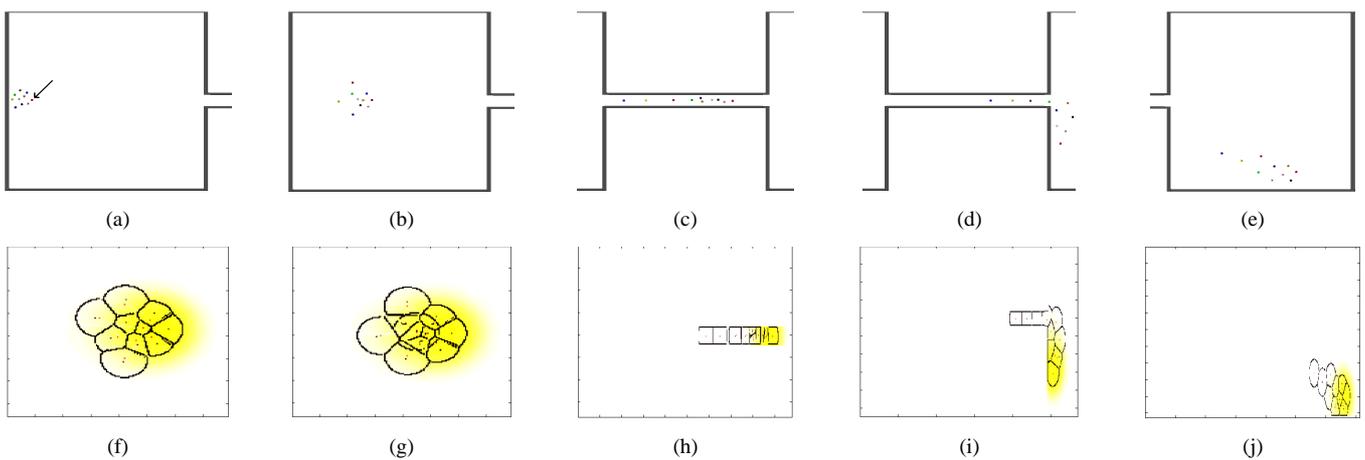


Figura 3. Agregação das forças de atração: (a)-(e) simulação; (d)-(f) células de Voronoi

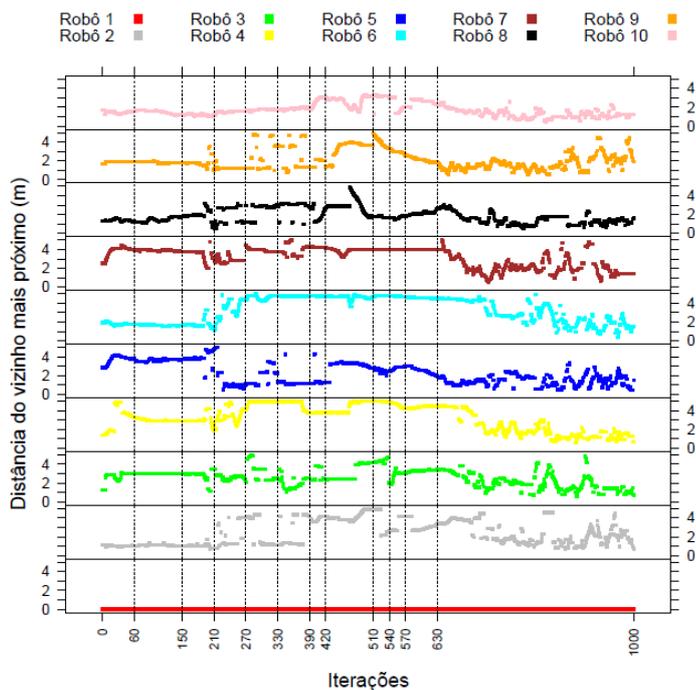


Figura 4. Distância ao vizinho mais próximo

De acordo com as diversas situações apresentadas ao grupo de robôs, a estratégia SAFS adapta a topologia da formação, de modo que nenhum robô se afasta do grupo. Isto comprova que a estratégia SAFS é capaz de atingir as cinco características descritas em II, através do equilíbrio providenciado pela combinação das forças de atração.

## V. CONCLUSÕES

Neste trabalho foi proposta uma estratégia de coordenação distribuída e bio-inspirada para sistemas aplicados à formação de robôs. A estratégia SAFS é baseada em Otimização por Colônias de Formigas (ACO), diagramas de Voronoi e triangulação de Delaunay. Inspirada nas abordagens comportamental, baseada em consenso e líder-seguidor, a estratégia possui as seguintes características: descentralizada, livre de colisões, adaptativa, topologicamente dinâmica e estável. A estratégia foi testada para avaliar sua habilidade de formação em situações diversas. Nos experimentos realizados foi evidenciada a robustez da estratégia, considerando principalmente a estrutura do ambiente.

Como trabalhos futuros, a capacidade da estratégia SAFS em mudar de líder e de se dividir em subgrupos será investigada. Resultados preliminares demonstram que estes eventos não degradam o desempenho da estratégia. Dessa forma, a metodologia descrita neste artigo suporta adaptações na topologia do grupo causadas pelas mudanças de direção de movimento e pela divisão do grupo. Além disso, pretende-se investigar o desempenho da estratégia de coordenação em uma aplicação de exploração do ambiente. Neste caso, será analisado o efeito da estratégia no mapeamento do ambiente. Cada robô deverá ser responsável por construir um mapa local que represente as regiões do ambiente que o mesmo explorou. Uma vez que os robôs consigam obter seus mapas locais, um

método de integração de dados será estudado para unificar a informação distribuída entre os diversos robôs.

## AGRADECIMENTOS

Os autores agradecem a FAPESP e CNPq pelo suporte financeiro. Processo n° 2010/07955-8, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

## REFERÊNCIAS

- [1] T. A. Frewen, I. D. Couzin, A. Kolpas, J. Moehlis, R. Coifman and I. G. Kevrekidis, "Coarse Collective Dynamics of Animal Groups, Coping with Complexity: Model Reduction and Data Analysis", *Lecture Notes in Computational Science and Engineering.*, vol. 75, 2011, pp. 299-309.
- [2] B. L. Partridge, "The structure and function of fish schools", *Scientific American*, vol. 246, n. 6, 1982, pp. 114-123.
- [3] M. Wu, A. Konno and M. Uchiyama, "Cooperative object transportation by multiple humanoid robots", *IEEE/SICE International Symposium on System Integration*, 2011, pp. 779-784.
- [4] D. W. Gage, *Command control for many-robot systems*. Naval Command Control and Ocean Surveillance Center RDT and DIV, 1992.
- [5] C. W. Reynolds, "Flocks, herds and schools: A distributed behavioral model", *Proc. of the 14<sup>th</sup> Annual Conference on Computer Graphics and Interactive Techniques*. ACM, New York, NY, USA, 1987, pp. 25-34.
- [6] R. Calvo, J. R. de Oliveira, M. Figueiredo and R. A. F. Romero, "A distributed, bio-inspired coordination strategy for multiple agent systems applied to surveillance tasks in unknown environments", in *International Joint Conference on Neural Networks*, 2011, pp. 3248-3255.
- [7] M. Dorigo. *Optimization, learning and natural algorithms*. PhD thesis, Dipartimento di Elettronica, Politecnico di Milano, 1992.
- [8] R. Calvo, M. Figueiredo and R. A. F. Romero, "Autonomous cognition and reinforcement learning for mobile robots". *Proc. of 2010 Int. Joint Conference on Neural Networks*, Barcelona, pp. 1060-1067, 2010.
- [9] H. G. Tanner, A. Jadbabaie and G. J. Pappas, "Flocking in fixed and switching networks", *IEEE Transactions on Automatic Control*, vol. 57, n. 5, 2007, pp. 863-868.
- [10] T. Vicsek, A. Czirok, E. Ben-Jacob, I. Cohen and O. Shochet, "Novel type of phase transition in a system of self-driven particles", *Physical Review Letters*, vol. 75, issue 6, 1995, pp. 1226-1229.
- [11] Y. Li and X. Chen, "Mobile robot navigation using particle swarm optimization and adaptive NN", *Lecture Notes in Computer Science*. Springer, vol. 3612, 2005, pp. 628-631.
- [12] J. Tan, O. M. Lozano, N. Xi and W. Sheng, "Multiple vehicle systems for sensor network area coverage", *Fifth World Congress on Intelligent Control and Automation*, vol. 5, 2004, pp. 4666-4670.
- [13] M. A. Lewis and K. Tan, "High precision formation control of mobile robots using virtual structures", *Auton. Robots*. Kluwer Academic Publishers, vol. 4, issue 4, 1997, pp. 387-403.
- [14] R. Wei and R. W. Beard, "A decentralized scheme for spacecraft formation flying via the virtual structure approach", *Proc. of the 2003 American Control Conference*, vol. 2, 2003, pp. 1746-1751.
- [15] L. Alboul, H. Abdul-Rahman, P. Haynes, J. Penders and J. Tharin, "An approach to multi-robot site exploration based on principles of self-organization", *Intelligent Robotics and Applications. Lecture Notes in Computer Science*, vol. 6425, 2010, pp. 717-729.
- [16] 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", *International Symposium on Distributed Autonomous Robotics Systems*, 2002, pp. 299-308.
- [17] D. V. Dimagonas and K. J. Kyriakopoulos, "Distributed cooperative control and collision avoidance for multiple kinematic agents", *45<sup>th</sup> IEEE Conference on Decision and Control*, 2006, pp. 721-726.
- [18] M. Lee, M. Tarokh and M. Cross, "Fuzzy logic decision making for multi-robot security systems", *Art. Intell. Rev.*, 2010, pp. 177-194.