

# Otimização por Enxame de Partículas aplicado à formação e atuação de grupos robóticos

Gustavo Pessin, Fernando Osório

Universidade de São Paulo  
Instituto de Ciências Matemáticas e Computacionais (ICMC)  
Av. do Trabalhador São-Carlense, 400, C.P. 668, 13560-970, São Carlos, SP, Brasil  
{`peessin, fosorio`}@icmc.usp.br

## Resumo

Neste artigo, descreve-se o modelo, a implementação e a avaliação da eficiência de Algoritmos de Otimização por Enxame de Partículas aplicados à formação e atuação de grupos robóticos. A atuação do grupo robótico é realizada sobre um desastre ambiental do tipo incêndio florestal. São avaliados diversos parâmetros que influenciam o comportamento da otimização, como inércia, confiança, tipos de modelos sociais e tamanho de enxame. Descrevem-se as experiências realizadas, detalhando-se os conjuntos de parâmetros que permitem obter resultados positivos e também negativos. Os resultados das simulações demonstram que, com um conjunto adequado de parâmetros, é possível obter posições satisfatórias para atuação do grupo robótico.

**PALAVRAS-CHAVE:** Otimização por Enxame de Partículas, coordenação, sistemas multirrobóticos.

## Abstract

Particle Swarm Optimization applied to robotic squad coordination. In this paper it is described the modeling, implementation and evaluation of the Particle Swarm Optimization (PSO) efficiency when applied to robotic group formation and coordination. The robotic task is performed over a natural disaster, simulated as a forest fire. The robot squad mission is to surround the fire and avoid fire's propagation. Experiments have been made with several parameter's variation seeking to get the more efficient swarm performance. This paper describes all performed experiments detailing all sets of parameters, including positive and negative results. The simulation's results showed that with an adequate set of parameters is possible to get satisfactory strategic positions for a multi-robotic system's operation.

**KEY WORDS:** Particle Swarm Optimization, coordination, multi-robotics systems.

## 1 Introdução

Diversas atividades humanas podem não ser executadas de forma eficiente ou eficaz quando realizadas por um único agente. Tarefas como combate de incêndios, limpezas de resíduos nucleares ou químicos, construção civil, agricultura e missões de segurança e defesa são exemplos de tarefas em que a operação de um grupo de agentes pode permitir maior agilidade e eficiência na execução. O uso de agentes robóticos, ao contrário de agentes humanos, pode adicionar segurança, confiabilidade e eficácia nestas operações. Sistemas multirrobóticos são extremamente

dependentes de técnicas de controle. Eles podem adicionar mobilidade, extensibilidade e robustez a uma série de aplicações (Mondada *et al.*, 2005), porém, eles também trazem a tona uma nova série de questões a serem respondidas em termos de colaboração e cooperação. Algoritmos especializados, compostos por regras e autômatos têm sido propostos buscando controlar estes conjuntos físicos em ambientes dinâmicos, o que tem apresentado ser uma tarefa árdua (Dudek e Jenkin, 2000; Go *et al.*, 2004; Bekey, 2005). Devido a este motivo, diversos pesquisadores têm migrado seus esforços para abordagens diferentes (e.g. aplicação de técnicas clássicas

de Inteligência Artificial, uso de modelos sociais, baseados em mercado, baseados em enxames).

O desenvolvimento de um sistema multirrobótico para atuar em monitoração e combate a incêndios em áreas florestais é um problema multidisciplinar. Assim, o sucesso dessa tarefa envolve o uso de uma variedade de tecnologias de diferentes campos, como robótica móvel (por exemplo, o controle de movimentação, a fusão sensorial, a modelagem robótica). De igual modo, tal atividade envolve a coleta de informações de especialistas sobre incêndios (por exemplo, o comportamento do fogo em ambientes naturais, as técnicas e os métodos de monitoração, as estratégias reais de combate). Na tarefa de controle de incêndio, um dos problemas mais relevantes tem relação com a estratégia de posicionamento dos robôs de combate. De acordo com a capacidade de atuação de cada robô, em vista das condições climáticas (vento, chuva), da topografia e da vegetação, diferentes formações podem ser sugeridas. Essas formações, quando sugeridas por especialistas, podem não considerar o grande número de variáveis envolvidas; dessa forma, é possível, na definição do posicionamento, utilizar técnicas de otimização e Aprendizado de Máquina. Uma técnica que tem apresentado resultados satisfatórios em resolver problemas de otimização é a Otimização por Enxame de Partículas, que tem caráter estocástico e é inspirada em comportamentos sociais (Kennedy e Eberhart, 1995; Eberhart e Kennedy, 1995). A tarefa de monitoração e combate a incêndios em áreas florestais é um caso em que a aplicação de um sistema multirrobótico possibilita diminuir consideravelmente os prejuízos humanos, materiais e ambientais.

No trabalho de Pessin e Osório (2009a), apresentam-se a modelagem, a implementação e a avaliação da eficiência de Algoritmos Genéticos, na busca de posições de atuação para um grupo robótico. Para isso, foram avaliadas características como estrutura de cromossomo, taxa de mutação, tipos de mutação, número de indivíduos e taxa de *crossover*. Assim, no presente estudo, descrevem-se a modelagem, a implementação e a avaliação de Algoritmos de Otimização por Enxame de Partículas. Além disso, objetiva-se delimitar posições de atuação para um grupo robótico, com base na avaliação de parâmetros como inércia, confiança, tipos de modelos de colaboração e tamanho do enxame, totalizando 54 diferentes conjuntos de parâmetros. A avaliação e o estudo da formação e atuação do grupo ocorrem sobre um desastre ambiental simulado como um incêndio florestal. São realizadas experiências com grupos de 2 e 4 robôs bombeiros. Neste artigo, na Seção 2 destacam-se conceitos e aplicações de robótica móvel. Na Seção 3, indicam-se conceitos e aplicações de Otimização por Enxame de Par-

tículas. Na Seção 4, explicita-se o trabalho desenvolvido, descrevendo o simulador, a estrutura da partícula e o *fitness* propostos, concluindo-se com a descrição, em detalhes, dos experimentos e resultados.

## 2 Robótica móvel

Um robô móvel é um dispositivo mecânico montado sobre uma base não fixa que age sob o controle de um sistema computacional, equipado com sensores e atuadores que o permitem interagir com o ambiente (Marchi, 2001; Bekey, 2005). A interação com o ambiente se realiza por intermédio de ciclos de percepção-ação, que consistem de três passos fundamentais: (i) obtenção de informação mediante sensores; (ii) processamento das informações para seleção de ação; e, (iii) execução da ação por meio do acionamento dos atuadores. Esse conjunto de operações, em uma análise superficial, pode parecer simples, porém o controle robusto de sistemas robóticos revela complicações físicas, mecânicas, eletrônicas e computacionais que tornam a criação de um conjunto de regras uma tarefa árdua e sujeita a erros. Sensores são os mecanismos de percepção de um robô os quais realizam medições físicas (por exemplo, contato, distância, orientação, temperatura) e proveem sinais ou dados crus que precisam ser interpretados pelo “cérebro” do robô. A interpretação desses sinais deve ser a única maneira de um robô autônomo entender o ambiente que o cerca, para poder realizar as mudanças de ação necessárias (JPL/NASA, 2007). Atuadores são os mecanismos de ação de um robô (por exemplo, motores, pistões, braços manipuladores), controlados por circuitos eletrônicos que recebem valores de ação. Tais valores devem ser calculados pelo robô e precisam estar de acordo com especificações de fabricantes (JPL/NASA, 2007).

A eficácia na resolução de tarefas com uso de um grupo de robôs depende de que, individualmente, os robôs tenham capacidades bem desenvolvidas. Diversos trabalhos atuais demonstram o uso de robótica móvel (sistemas com um único robô) em operações hostis, como o robô de atuação em auxílio em resgate *Raposa* (IdMind, 2007) e o robô *SACI* (Macedo *et al.*, 2007), projetado para atuar em combate contra incêndios. Outros exemplos são os protótipos militares *Boeing X-45* (Boeing, 2007) e o *nEUROn* (Dassault, 2007) que, sob supervisão humana em terra (sem nenhum piloto embarcado), estão sendo testados para missões de combate. Além disso, existem robôs para atuação em ambientes aquáticos, na exploração espacial, de cavernas e de vulcões e até para uso doméstico. Existem, também, competições (Trinity, 2007; PennState, 2007) que põem à prova

pequenos robôs móveis autônomos que têm missões como encontrar e apagar uma vela, como em um incêndio simulado.

Os grupos devem ser formados por robôs capazes de atuar efetivamente em tarefas; assim, é de vital importância o conhecimento em controle robótico. Trabalhos que descrevem o controle inteligente de navegação robótica podem ser vistos em Costa *et al.* (2003) e em Zhao e Collins (2005). Nos anos de 2004 e 2005, o *DARPA Grand Challenge* (Darpa, 2007), financiado pela *Defense Advanced Research Projects Agency*, organizou uma competição com o objetivo de construir um veículo completamente autônomo, capaz de completar um longo trecho em estradas de terra em um tempo limitado. Em 2007, foi alterado o foco da competição, renomeada para *DARPA Urban Challenge*, assumindo como novo objetivo a criação de um veículo autônomo, capaz de navegar no tráfego urbano e de realizar tarefas como ultrapassagem, estacionamento e negociação em interseções. Percebem-se tendências a estudos de cooperação e de interação múltipla. A principal motivação para o uso de sistemas com grupos robóticos decorre da capacidade extra de solucionar problemas impossíveis individualmente. Trabalhos em grupo adicionam grandes possibilidades à solução de tarefas, mas, paradoxalmente, originam uma série de questões a serem resolvidas, principalmente em termos de colaboração e cooperação.

A cooperação pode ser entendida como a capacidade que os robôs têm de trabalhar em conjunto de forma a concluírem tarefas de interesse comum (Reis, 2003). Para que exista cooperação, deve existir alguma forma de interação entre os robôs ou com humanos, mediante alguma forma de comunicação (Wooldridge e Jennings, 1995). A cooperação não depende obrigatoriamente de comunicação entre todos os robôs, visto que, como no mundo real, um coordenador (unidade de controle) pode delegar tarefas (enviar mensagens) para um grupo de pessoas (robôs) que não tenham comunicação direta entre si. Neste caso, as pessoas podem trabalhar em prol do mesmo objetivo, sem ter conhecimento do que as outras estão fazendo. A morfologia de um robô deve, ao incluir a capacidade de comunicação, possuir um módulo de controle de comunicações; este é diretamente ligado ao módulo de controle do robô (Reis, 2003).

Trabalhos que abordam a formação de grupos, como os de Yamaguchi (2003), Balch e Arkin (1998), utilizam regras pré-programadas nos agentes para realizar a formação. Os estudos de Mondada *et al.* (2005) e de Dorigo *et al.* (2004) exploram técnicas para realizar trabalhos com coletivos robóticos, as quais são usadas, principalmente, com a finalidade de aplicação do conceito de auto-organização e otimização co-

letiva, mas sem explorar a divisão de tarefas. Os trabalhos descritos demonstram que a aplicação de robótica móvel em controle de incidentes é um tópico ativo e importante de pesquisa e desenvolvimento. As diversas competições nesta área também demonstram que ainda não existe uma solução definitiva ou mais adequada ao problema, e que este é um tema de pesquisa em aberto. A literatura consultada ainda não apresenta uma forma consensual para a formação e atuação de grupos robóticos; ainda existem pouca autonomia e escassa robustez em situações não previstas.

### 3 Otimização por Enxame de Partículas

A Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*) (Kennedy e Eberhart, 1995; Eberhart e Kennedy, 1995) é uma técnica estocástica de otimização, inspirada em comportamentos sociais como os de bandos de pássaros e cardumes de peixes (Eberhart *et al.*, 2001; Engelbrecht, 2005). A otimização no PSO ocorre por meio da cooperação (aprendizado do grupo) e da competição (aprendizado individual) entre indivíduos de um bando. A cooperação e a competição são as principais características que guiam o algoritmo do PSO na exploração do espaço de busca (Engelbrecht, 2005).

O PSO compartilha diversos conceitos com a Programação Evolucionária em geral, como os Algoritmos Genéticos (AG) (Holland, 1975; Mitchell, 1996). Ambos, AG e PSO, possuem uma população inicial de indivíduos (como possíveis soluções) e uma função objetivo (que mede o quanto cada indivíduo é apto a solucionar o problema). No entanto, ao contrário do AG, no PSO não temos os conceitos explícitos de cruzamento, mutação nem seleção. Uma diferença conceitual importante entre PSO e AE é que a força motriz nestes é a sobrevivência dos melhores indivíduos, os quais competem para sobreviver e gerar uma prole. No PSO, a força motriz é a interação social e a troca de conhecimento sobre o espaço de busca (Engelbrecht, 2005).

O funcionamento do PSO é dado pela evolução de um enxame de partículas (análogo a uma população de indivíduos), inicialmente aleatórias. A cada iteração, cada partícula é atualizada, seguindo dois melhores valores: o melhor *fitness* da população e o melhor *fitness* encontrado pela partícula (considerando suas gerações passadas). Cada partícula possui uma *posição*  $x$  (ou um vetor de posições) e uma *velocidade*  $v$  (ou um vetor de velocidades). A *posição* é a representação da solução do problema, e a *velocidade* é o peso do direcionamento para o deslocamento das partículas. A Figura 1 apresenta o fluxograma de um PSO padrão.

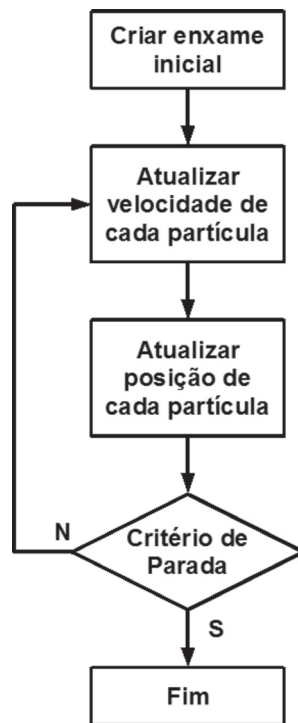


Figura 1. Fluxograma de um PSO padrão.  
Figure 1. Flowchart of a standard PSO.

O cálculo da nova posição é dado pela Equação 1. Nesta,  $x_k^i$  é a posição da partícula  $i$  no instante  $k$ , e  $v_k^i$  é a velocidade da partícula  $i$  no instante  $k$ . A velocidade da partícula é atualizada de acordo com a Equação 2.

$$x_{k+1}^i = x_k^i + v_k^i \quad (1)$$

$$v_{k+1}^i = w \cdot v_k^i + c_1 \cdot r_1 (pbest - x_k^i) + c_2 \cdot r_2 (gbest - x_k^i) \quad (2)$$

Na Equação 2,  $v_k^i$  é a velocidade atual da partícula,  $w$  é um parâmetro que representa a inércia da partícula;  $pbest$  é a melhor posição dentre todas já encontradas pelo indivíduo (*particle best*);  $gbest$  é a melhor posição dentre todas já encontradas pelo grupo (*group best*);  $c_1$  e  $c_2$  são parâmetros de confiança;  $r_1$  e  $r_2$  são números aleatórios compreendidos entre 0 e 1. Os parâmetros ( $w$ ,  $c_1$ ,  $c_2$ ,  $r_1$  e  $r_2$ ) são detalhados a seguir.

A velocidade é o parâmetro que guia o processo de otimização (Engelbrecht, 2005) e reflete tanto o conhecimento individual da partícula como o conhecimento do grupo. O conhecimento individual é identificado como Componente Cognitivo, enquanto o conhecimento do grupo é conhecido como Componente Social. A velocidade consiste de uma soma de três termos: (i) Velocidade Prévia, que serve como uma memória da direção de deslocamento e pode ser vista como um parâmetro que evita a mudança drástica de direção; (ii) Componente Cognitivo,

que direciona o indivíduo para a melhor posição encontrada, até então, pela partícula; assemelha-se à memória individual da posição que era melhor para a partícula; (iii) Componente Social, que direciona o indivíduo para a melhor posição encontrada, até então, pelo grupo.

Considerando que a partícula é atraída pelo  $gbest$  (que pode ser o melhor global ou o melhor vizinho, de acordo com a topologia de vizinhança utilizada) e pelo  $pbest$ , essa atração é o que faz o PSO tender o movimento das partículas para as melhores soluções encontradas até o momento. Os parâmetros  $c_1$  e  $c_2$ , também chamados de confiança, são utilizados para definir a importância da tendência individual ou social. O PSO padrão trabalha com valores de confiança iguais ( $c_1 = c_2$ ), atribuindo igual importância à experiência do grupo e à experiência individual (conhecido como *Modelo Completo*). Quando o parâmetro  $c_1$  possui valor zero, e o valor  $c_2$  tem valor maior que zero, o PSO usa apenas informação do grupo, não considerando a experiência individual. Este modelo é conhecido como *Modelo Social*. Quando o parâmetro  $c_2$  possui valor zero, e o valor  $c_1$  tem valor maior que zero, o PSO usa apenas informação da própria partícula, não considerando a experiência do grupo. Este modelo é conhecido como *Modelo Cognitivo*.

A ideia inicial de simular o comportamento de bandos, fazendo com que, em cada iteração, cada indivíduo calculasse sua velocidade diretamente em relação ao melhor vizinho, ou o melhor indivíduo, apresentava convergência rápida e unânime explorando de forma muito restrita o espaço de busca. A solução deste problema se deu com a introdução dos valores randômicos ( $r_1$  e  $r_2$ ) no ajuste da velocidade; e assim o PSO pode explorar de forma mais eficiente o espaço de busca (Engelbrecht, 2005).

O parâmetro de inércia tem como finalidade permitir o ajuste no que se refere à busca local ou global (Silveira *et al.*, 2009). Quanto mais perto de 1.0 for este valor, mais global é a busca, enquanto tamanhos pequenos possibilitam uma busca local. Este valor, em geral, varia entre 0,4 e 0,9. Alguns trabalhos (Eberhart e Shi, 2001; Kennedy e Eberhart, 1995) sugerem o decaimento linear do valor, porém ressaltam que nem sempre o uso de decaimento linear é a melhor solução para diversos trabalhos. A maioria dos parâmetros é dependente dos problemas (Engelbrecht, 2005).

As estruturas sociais (ou topologias) definem a forma de se obter o  $gbest$ , que pode ser o melhor global ou o melhor vizinho (Engelbrecht, 2005). O trabalho feito por Kennedy (1999) mostra que a vizinhança do tipo estrela (em que a partícula tem conhecimento da melhor posição encontrada entre todas as partículas) é uma das melhores formas para a busca de melhores soluções com o PSO. Nosso trabalho, usa a estrutura social tipo estrela, na qual todas as partículas têm ligação com as outras.



Em termos práticos, isso significa que existe um único *gbest* para todas as partículas. Outras estruturas permitem que o *gbest* seja gerado em subgrupos de partículas. Em Engelbrech (2005) e Kennedy (1999), é descrito que o modelo em estrela apresenta convergência mais rápida que outras estruturas.

As aplicações de PSO são, em geral, parecidas com as da Computação Evolucionária. Alguns trabalhos que descrevem comparações podem ser vistos em Eberhart e Shi (1998), Eberhart *et al.* (2001), Engelbrecht (2005). Em Pugh e Martinoli (2006), é descrito o desenvolvimento de um PSO para realizar o controle de navegação de robôs, em que valores de sensores de distância são usados como informação de entrada em um sistema que comanda os motores dos robôs para realizar a navegação, desviando de obstáculos. O trabalho de Rong *et al.* (2008) descreve o desenvolvimento e a avaliação de um PSO para realizar o caminhar robótico com robôs de quatro pernas, no qual se busca otimizar o tempo de aplicação de forças e valor das forças a serem aplicadas em diversas articulações. Uma abordagem semelhante é apresentada em Niehaus *et al.* (2007), porém, neste caso, o estudo de caso ocorre com um robô bípede. Esses estudos apresentam resultados satisfatórios para ambientes estáticos. Possíveis aplicações que exploram a dinamicidade das operações, como os trabalhos de Burchardt e Salomon (2006) e Pessin e Osório (2009b), usam um monitor de falhas. Os sistemas possuem duas fases: planejamento e ação. No modo de ação, ao identificar uma possível falha, o sistema para e reativa o modo de planejamento. Isso faz com que os sistemas possam ser aplicados em ambientes dinâmicos.

## 4 Formação de grupos

### 4.1 Simulador

Para que seja possível uma implementação física real, as avaliações que se propõem devem ser projetadas, desenvolvidas e testadas anteriormente em ambientes de simulação realísticos. A simulação de sistemas robóticos é especialmente interessante para robôs caros, grandes, ou frágeis (Go *et al.*, 2004), e se constitui como uma ferramenta extremamente poderosa para agilizar o ciclo de desenvolvimento de sistemas robóticos, pois elimina o desperdício de recursos. Em Pessin *et al.* (2007a), foram avaliados diversos simuladores, nos quais se pôde verificar a descrição dos

motivos da escolha pelo desenvolvimento de um novo simulador em linguagem C/C++. Uma versão 2D foi criada com a biblioteca SDL (SDL, 2007) e uma versão 3D foi desenvolvida para suportar robôs fisicamente simulados em terrenos irregulares usando OSG (OSG, 2007) (saída gráfica 3D), ODE (Smith, 2007) (realismo físico da morfologia robótica e da colisão entre os objetos presentes no ambiente) e Demeter (2007) (terreno irregular). O simulador deve ser capaz de reproduzir algum tipo de desastre para atuação do grupo de robôs. O desastre proposto foi o de incêndio florestal. Assim, o esquadrão de robôs tem a finalidade de extinguir o incêndio florestal, atuando por meio da criação de um aceiro em torno do incêndio. As Figuras 2, 5 e 6 apresentam essa operação. A implementação dos protótipos iniciou com a criação de um mapa que reúne informações sobre vegetação, topografia e comportamento de fogo. A descrição detalhada desse simulador pode ser vista em Pessin *et al.* (2007a, 2007b). O estudo dos modelos de florestas e resíduos florestais é de grande importância para o aprimoramento dos modelos de simulação a serem implementados em ambientes virtuais (Pessin *et al.*, 2007b).

### 4.2 Descrição do algoritmo de PSO

O algoritmo desenvolvido<sup>1</sup> objetiva otimizar as posições de atuação do grupo de robôs de combate a incêndios, especificamente, a posição inicial no combate, para cada robô do esquadrão (ponto de início da criação de aceiro) e a posição final no combate de cada robô do time (ponto final da criação de aceiro). Essas coordenadas são enviadas (mensagens de comando) para ativar as unidades de combate. Para realizar a simulação, é necessário: (i) conhecer a quantidade de robôs disponíveis; (ii) conhecer a velocidade de operação dos robôs; (iii) saber a posição inicial dos robôs; e (iv) possuir capacidade de simular a propagação de incêndio. Para simular a propagação de incêndio, é preciso obter: (i) a coordenada inicial do incêndio; (ii) o sentido do vento; (iii) a direção do vento; e (iv) uma cópia simplificada do mapa (terreno e vegetação). Este conjunto de informações proposto pode ser totalmente obtido com uso de sensores.

A estrutura proposta para a partícula (Tabela 1) possui informação referente a todo o grupo de robôs. São necessários 10 valores para um grupo de quatro robôs. Estes valores são armazenados na partícula como subpartículas da partícula (vetor de posições – como genes em um AG).

<sup>1</sup>Disponível em <http://pessin.googlepages.com/EvoluidorPSO4RBT2.0FullModel.rar>.

Na estrutura proposta de partícula, a posição final de um robô é a posição inicial do próximo, como demonstrado na Tabela 1. O tipo de atuação proposto (criação de aceiro) necessita que cada robô inicie sua operação exatamente na posição onde o robô anterior terminou a sua atuação. Assim, o uso de uma partícula que considera a posição final de um robô como a inicial do próximo é, de certa forma, uma otimização para a simulação com o PSO.

As posições de atuação dos robôs são calculadas mediante a aplicação, na partícula, das Equações 3 e 4. Nestas,  $(x_f, y_f)$  é a coordenada da posição final dos robôs;  $(x_a, y_a)$  é a coordenada da posição inicial do incêndio;  $r_i$  é o raio (subpartículas 5 a 9); e  $a_i$  é o ângulo (em relação ao ponto inicial do incêndio – subpartículas 0 a 4). O raio, bem como o ângulo, são específicos para cada operação de cada robô (coordenada inicial e final de criação de aceiro, como mostra a Tabela 1).

$$x_f = x_a + r_i \cdot \cos(a_i) \quad (3)$$

$$y_f = y_a + r_i \cdot \sin(a_i) \quad (4)$$

Com relação à implementação do algoritmo, usamos um conceito similar ao de alelos dos AGs, que tem como finalidade reduzir o espaço de busca. Assim, o raio pode ficar entre 0,0 e 100,0 unidades de medida e o ângulo pode ficar entre 0,0° e 360,0°. Os valores armazenados na partícula são do tipo ponto-flutuante. Análises comparativas envolvendo representação binária e representação com ponto flutuante indicaram que a representação em ponto flutuante possui vantagens significativas, principalmente com relação à precisão e à velocidade de convergência (Michalewicz, 1996). Avaliações com mudanças nos parâmetros são descritas na Seção 5.

### 4.3 Escolha do *fitness*

O algoritmo de PSO tem sua otimização guiada por uma função *fitness*. No nosso modelo, esta função tem relação com a área de vegetação salva do fogo e com a taxa de utilização das unidades de combate (robôs bombeiros). Assim, o *fitness* desenvolvido acumula os seguintes valores finais de cada simulação: (i) total de área queimada: busca minimizar a área queimada; (ii) total de área com aceiro: busca minimizar a área de trabalho dos robôs, evitando que sejam criados aceiros em áreas onde o fogo não alcança; (iii) erro médio absoluto: busca minimizar a diferença entre a média geral de aceiros úteis, em relação ao aceiro útil de cada indivíduo; assim, o tamanho das áreas de trabalho tende a se equalizar. Otimizar o *fitness*, neste caso, é minimizar o seu valor: quanto menor o *fitness* final, menos vegetação foi queimada, menos aceiro foi criado, e menor é a diferença entre o tamanho dos aceiros.

## 5 Experimentos e resultados

Assumindo que um dos aspectos mais importantes para o sistema considerado é a velocidade de convergência, realizou-se uma bateria de testes para verificar qual o melhor conjunto de parâmetros para o PSO proposto. A lista completa das variações de parâmetros é apresentada na Tabela 2. Para verificar qual o melhor conjunto de parâmetros, forma fixadas as características climáticas da simulação do incêndio e as posições iniciais dos robôs. Houve seis simulações com cada conjunto de parâmetros, totalizando 108 simulações. Em seguida, foram realizadas observações visuais em cerca de 20% dos resultados, a fim de verificar quais os *fitness* ideais para o combate ao incêndio.

Tabela 1. Estrutura da partícula proposta (grupo de quatro robôs – ângulo e raio relativo ao ponto inicial do incêndio).  
Table 1. Structure of a proposed particle (group of four robots – angle and radius related to the fire's starting point).

Subpartícula	Função	Valor Mínimo	Valor Máximo
0	Ângulo inicial do robô 0	0,0°	360,0°
1	Ângulo final do robô 0 e inicial do robô 1	0,0°	360,0°
2	Ângulo final do robô 1 e inicial do robô 2	0,0°	360,0°
3	Ângulo final do robô 2 e inicial do robô 3	0,0°	360,0°
4	Ângulo final do robô 3	0,0°	360,0°
5	Raio inicial do robô 0	10,0m	100,0m
6	Raio final do robô 0 e inicial do robô 1	10,0m	100,0m
7	Raio final do robô 1 e inicial do robô 2	10,0m	100,0m
8	Raio final do robô 2 e inicial do robô 3	10,0m	100,0m
9	Raio final do robô 3	10,0m	100,0m

As experiências  $[A..F]$  possuem apenas confiança no grupo ( $c_1=0,0$ ;  $c_2=2,0$ ), conhecido como *modelo social*; as experiências  $[G..L]$  possuem apenas confiança na própria partícula ( $c_1=2,0$ ;  $c_2=0,0$ ), caso conhecido como *modelo cognitivo*, e as experiências  $[M..R]$  possuem confiança tanto no grupo quanto na própria partícula, fato conhecido como *modelo completo* ( $c_1=2,0$ ;  $c_2=2,0$ ).

A Figura 2 apresenta o resultado visual de algumas simulações. As Figuras 2a e 2b apresentam seqüências de uma simulação com *fitness* de 3.800,00 unidades. O fogo é contido, porém o aço é pouco otimizado. A Figura 2c apresenta *fitness* de 3.480,00

unidades, e a Figura 2d apresenta *fitness* de 2.643,00 unidades. Estas duas últimas figuras apresentam operações visualmente eficientes, porém, em termos matemáticos, a análise da partícula resultante indica que, na Figura 2c, tem-se desvio-padrão sobre a média das áreas de atuação de 6,05 graus e 2,37 unidades de raio e, na Figura 2d, tem-se desvio-padrão sobre a média das áreas de atuação de 3,38 graus e 0,23 unidades de raio. As duas formações apagaram o incêndio, porém, na Figura 2d, há uma área de trabalho mais igualitária entre os robôs. Assim, a partir das observações visuais, definem-se como aceitáveis para este experimento os

Tabela 2. Lista das variações de parâmetros avaliados no PSO.  
Table 2. List of parameters' variations evaluated in the PSO.

Experiência	ConfP ( $c_1$ )	ConfG ( $c_2$ )	Inércia ( $w$ )	Tamanho do Enxame
A	0,0	2,0	0,4	80
B	0,0	2,0	0,8	80
C	0,0	2,0	1,2	80
D	0,0	2,0	0,4	160
E	0,0	2,0	0,8	160
F	0,0	2,0	1,2	160
G	2,0	0,0	0,4	80
H	2,0	0,0	0,8	80
I	2,0	0,0	1,2	80
J	2,0	0,0	0,4	160
K	2,0	0,0	0,8	160
L	2,0	0,0	1,2	160
M	2,0	2,0	0,4	80
N	2,0	2,0	0,8	80
O	2,0	2,0	1,2	80
P	2,0	2,0	0,4	160
Q	2,0	2,0	0,8	160
R	2,0	2,0	1,2	160

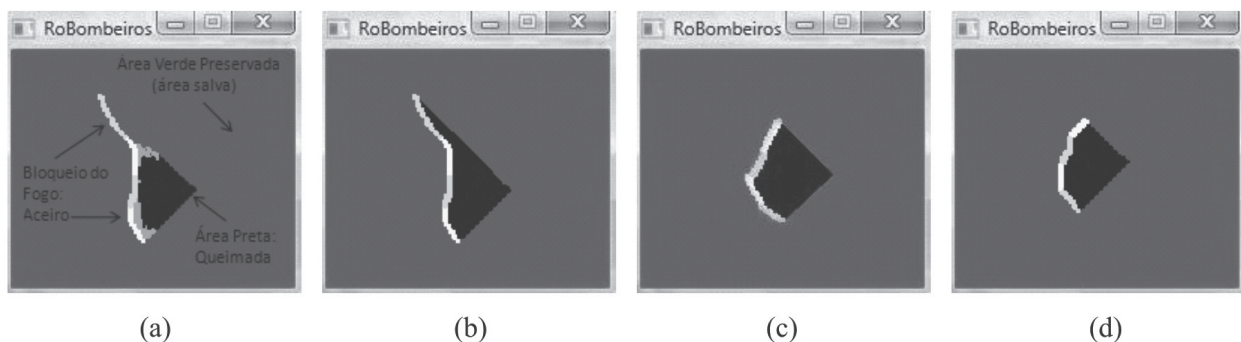


Figura 2. (a) e (b) Sequências de uma simulação com *fitness* final de 3.800,00 unidades. O fogo é contido, porém o aço é pouco otimizado. (c) Simulação com *fitness* final de 3.480,00 unidades. (d) Simulação com *fitness* final de 2.643,00 unidades.  
Figure 2. (a) and (b) sequences of a simulation with final fitness of 3800.00 units. The fire is contained, but the firebreak is not very optimized. (c) Simulation with final fitness of 3480.00 units. (d) Simulation with final fitness of 2643.00 units.

*fitness* inferiores a 3.500,00 unidades, sendo ideais os *fitness* abaixo de 3.000,00 unidades.

Dos testes iniciais realizados (Tabela 2), os únicos que apresentaram, pelo menos, 50% das soluções com *fitness* abaixo de 3.500,00 unidades foram [B,E] (modelo social com  $w=0,8$ ) e [M,P] (modelo completo com  $w=0,4$ ). Nenhuma configuração apresentou mais de 70% de soluções com *fitness* abaixo de 3.500,00 unidades. Assim, uma nova bateria de simulações foi executada, considerando as quatro variações que apresentaram os melhores resultados, com aumento no número de gerações (de 500 para 800), variações de quantidade de partículas (20, 50, 100 e 200) e variações de  $\pm 0,1$  na inércia. As simulações que usam o modelo cognitivo apresentaram resultados significativamente inferiores em relação aos modelos social e completo. Assim, nenhuma avaliação com o modelo cognitivo foi feita na segunda bateria de avaliações. A segunda bateria de avaliações pode ser vista na Tabela 3.

A Tabela 3 também apresenta o resultado das 10 simulações de cada conjunto de parâmetros. É possível constatar que a única configuração que obteve 100% das simulações com resultado abaixo de 3.500,00 foi a experiência  $F_{11}$ . O conjunto de parâmetros usado na experiência

$F_{11}$  é  $c_1=2,0$ ,  $c_2=2,0$  (modelo completo), inércia de 0,5, 800 gerações e 200 partículas. Pode-se verificar, na Tabela 3, que as experiências com 20 e 50 partículas apresentaram resultados inferiores, em comparação às experiências com 100 e 200 partículas, tanto no modelo completo (Tabela 3a) como no modelo social (Tabela 3b). Além disso, no modelo social (Tabela 3b), verifica-se que as experiências que usaram valor de inércia igual a 0,9 apresentaram resultados completamente insatisfatórios, independentemente da quantidade de partículas presentes no sistema. Outra informação que se pode observar, a partir da Tabela 3, é que as experiências com o modelo completo (Tabela 3a) apresentaram resultados melhores em comparação com as experiências com o modelo social (Tabela 3b).

A Figura 3 apresenta o gráfico das médias dos menores *fitness*, obtidos com base na bateria de avaliações descritas na Tabela 3a. É apresentada a média de 10 simulações  $\pm$  desvio-padrão. É possível observar que o conjunto de parâmetros que apresentou a melhor média com menor desvio-padrão é a experiência  $F_{11}$ , de acordo com o demonstrado na Tabela 3a.

O gráfico de evolução do *fitness*, para 4 robôs de combate, pode ser visto na Figura 4, que mostra a média de 10 simulações (modelo completo e inércia de 0,5).

Tabela 3. Segunda bateria de variações de parâmetros avaliados no PSO. (a) Variações de inércia e de números de partículas no *modelo completo*. (b) Variações de inércia e de números de partículas no *modelo social*.  
Table 3. Second set of parameters' variations evaluated in the PSO. (a) Variations of inertia and numbers of particles in the *complete model*. (b) Variations of inertia and numbers of particles in the *social model*.

Exp	Tamanho do enxame	Inércia ( $w$ )	Resultados com <i>fitness</i> final < 3.500	Exp	Tamanho do enxame	Inércia ( $w$ )	Resultados com <i>fitness</i> final < 3.500
$F_0$	20	0,3	40%	$S_0$	20	0,7	0%
$F_1$	20	0,4	40%	$S_1$	20	0,8	40%
$F_2$	20	0,5	40%	$S_2$	20	0,9	0%
$F_3$	50	0,3	40%	$S_3$	50	0,7	40%
$F_4$	50	0,4	30%	$S_4$	50	0,8	70%
$F_5$	50	0,5	50%	$S_5$	50	0,9	0%
$F_6$	100	0,3	80%	$S_6$	100	0,7	60%
$F_7$	100	0,4	80%	$S_7$	100	0,8	70%
$F_8$	100	0,5	80%	$S_8$	100	0,9	0%
$F_9$	200	0,3	70%	$S_9$	200	0,7	80%
$F_{10}$	200	0,4	80%	$S_{10}$	200	0,8	80%
$F_{11}$	200	0,5	100%	$S_{11}$	200	0,9	0%

(a)

(b)



A simulação da propagação do fogo considerou vento no sentido Leste-Oeste ( $270^\circ$ ) e velocidades relativas, como vento de 7km/h; indicou velocidade de navegação dos robôs de 35km/h; e os robôs foram posicionados em uma base, com distância de cerca de 2km do ponto inicial do incêndio. O gráfico apresentado na Figura 4 mostra que o melhor *fitness* é obtido com uma quantidade de partículas igual a 200. A partir de 150 gerações, a otimização do *fitness* praticamente estabiliza. As melhores partículas resultantes de 3 simulações usando os parâmetros descritos podem ser vistas na Tabela 4. As Figuras 5 e 6 apresentam o resultado de algumas cenas de simulações com resultados satisfatórios e não satisfatórios.

A Figura 6 apresenta a aplicação do resultado satisfatório da evolução no protótipo 3D. Verifica-se que os robôs bombeiros cercam perfeitamente o fogo, bem como criam os aceiros de forma satisfatória. É importante salientar que algumas simulações usando diferentes velocidades de navegação e de propagação do fogo foram realizadas, porém em número menor de experimentos; estas não estão detalhadas neste texto, mas também apresentaram resultados satisfatórios. Outras experiências com formação de grupo, usando Algoritmos Genéticos, podem ser vistas em Pessin e Osório (2009a, 2009b). Para a navegação, os robôs usam Redes Neurais Artificiais detalhadas em Pessin (2008).




Figura 3. Resultados da bateria de avaliações descritas na Tabela 3a. O eixo x mostra a descrição do experimento como inércia e quantidade de partículas.

Figure 3. Results of the battery of evaluations described in Table 3a. The x-axis shows the description of the experiment as inertia and an amount of particles.

Tabela 4. Melhores partículas resultantes de 3 simulações para 4 robôs.

Table 4. Best particles from 3 simulations of 4 robots.

Sim.	Subpartículas 0 a 4 (Ângulo)					Subpartículas 5 a 9 (Raio)				
	a	226,60	202,46	176,87	161,13	138,14	26,51	29,20	30,03	30,12
b	225,71	204,55	178,78	163,21	137,58	26,84	28,79	29,88	26,27	28,69
c	227,21	202,91	175,79	161,12	138,17	29,83	30,34	28,98	28,21	32,11




Figura 4. Evolução do *fitness*, de acordo com o número de gerações, para 4 robôs de combate e diferentes quantidades de partículas (800 gerações,  $w=0,5$ ).

Figure 4. Evolution of *fitness*, according to the number of generations to 4 combat robots and different amounts of particles (800 generations,  $w=0.5$ ).

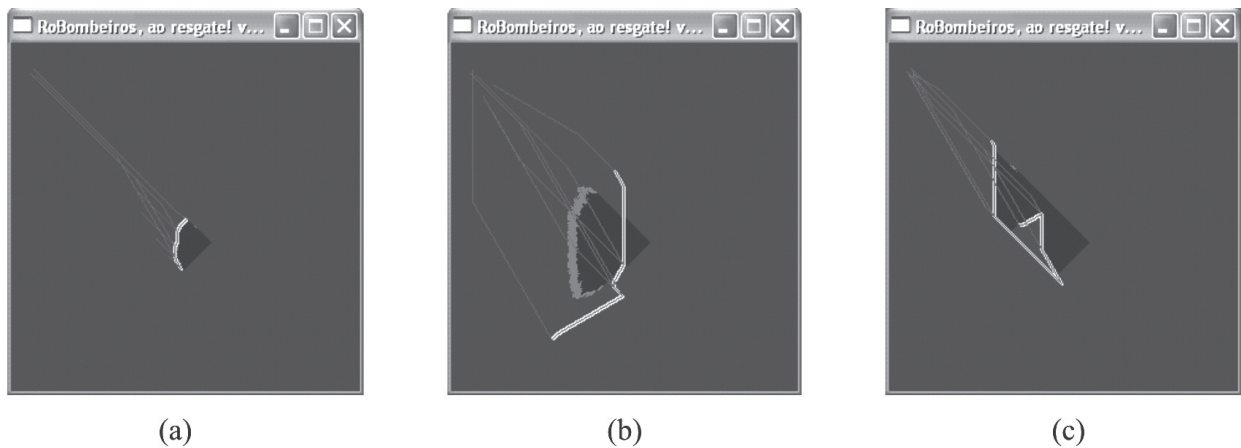


Figura 5. (a) Resultado satisfatório de uma evolução, usando 200 partículas,  $w = 0,5$  e modelo completo. (b) e (c) Resultados não satisfatórios. (b) 20 partículas,  $w = 0,7$  e modelo social: o fogo não é contido pelo aceiro. (c) 50 partículas,  $w = 0,3$  e modelo completo: as áreas de aceiro são excessivamente grandes em relação ao que seria necessário e não são bem distribuídas entre os robôs.

Figure 5. (a) Successful outcome of an evolution, using 200 particles,  $w = 0.5$  and complete model. (b) and (c) Unsatisfactory results. (b) 20 particles,  $w = 0.7$  and social model: the fire is not contained by the firebreak. (c) 50 particles,  $w = 0.3$  and complete model: the firebreak areas are too large relative to what would be necessary and are not well distributed among the robots.

## 6 Trabalhos futuros


A partir dos resultados obtidos, é possível sugerir alguns temas para investigações futuras: (i) estudos de outras técnicas de formação de grupos como os modelos baseados em enxames robóticos (Mondada *et al.*, 2005; Dorigo *et al.*, 2004) e *Market-based Approaches* (Dias *et al.*, 2006); (ii) comparação da eficiência do PSO com Algoritmos Genéticos e *Simulated Annealing* (Kirkpatrick *et al.*, 1983); e (iii) a sofisticação do modelo de simulação de incêndio e de atuação robótica. Após a avaliação das novas abordagens, o sistema deve ser construído com a utilização de robôs reais.

## 7 Conclusões


Como descrito, no trabalho de Pessin e Osório (2009a), apresenta-se a modelagem e a avaliação da efi-

ciência de Algoritmos Genéticos na formação de grupos robóticos. Naquele estudo, foram avaliadas características como estrutura de cromossomo e valores de alelos e parâmetros como taxa de mutação, tipos de mutação, número de indivíduos e taxa de *crossover*. No presente trabalho, descrevem-se a modelagem e a avaliação da eficiência de Algoritmos de Otimização por Enxame de Partículas na formação de grupos robóticos, em que se avaliam parâmetros como inércia, confiança, tipos de modelos de colaboração e tamanho de enxame, totalizando 54 diferentes conjuntos de parâmetros. Os conjuntos de parâmetros avaliados não permitem uma comparação estatística direta entre os métodos, porém é válido ressaltar que tanto o AG, demonstrado naquele trabalho (Pessin e Osório, 2009a), como o PSO, apresentado neste estudo, realizam com sucesso a tarefa de encontrar posições de atuação.


O objetivo principal deste artigo foi descrever o modelo, a implementação e a avaliação da eficiência de



(a)



(b)



(c)



(d)

Figura 6. Resultados satisfatórios das simulações. (a) e (b) Quatro robôs móveis criando o aceiro. (c) Dois robôs móveis criando o aceiro. (d) Visão detalhada da navegação com desvio de obstáculos.

Figure 6. Satisfactory results of the simulations. (a) and (b) Four mobile robots creating the firebreak. (c) Two mobile robots creating the firebreak. (d) Detailed view of the navigation with obstacles avoidance.

Algoritmos de Otimização por Enxame de Partículas aplicados à formação e atuação de grupos robóticos. Confirma-se que a atuação do grupo robótico é realizada sobre um desastre ambiental do tipo incêndio florestal. Realizaram-se experiências com diversos parâmetros e se detalharam tanto os conjuntos de parâmetros, que foi possível obter os resultados positivos e os negativos. Os resultados das simulações demonstram que, com um conjunto adequado de parâmetros, há condições de obter posições satisfatórias para atuação de um grupo robótico.

## Agradecimentos

Agradecemos à CAPES, pelo apoio financeiro por intermédio de bolsa de estudo, e ao CNPq e FAPESP, pelo financiamento ao INCT-SEC, processos 573963/2008-8 e 08/57870-9.

## Referências

- BALCH, T.; ARKIN, R.C. 1998. Behavior-based formation control for multirobot teams. *IEEE Transactions on Robotics and Automation*, **14**(6):926-939.
- BEKEY, G.A. 2005. *Autonomous Robots: From biological inspiration to implementation and control*. Cambridge, The MIT Press, 577 p.
- BOEING. 2007. Boeing company website. Disponível em: [www.boeing.com](http://www.boeing.com). Acesso em: 03/02/2007.
- BURCHARDT, H.; SALOMON, R. 2006. Implementation of path planning using GA on mobile robots. In: IEEE CONGRESS ON EVOLUTIONARY COMPUTATION (CEC'06), 8, San Francisco, 2006. *Anais...* New York, IEEE Press, p. 1831-1836.
- COSTA, E.R.; GOMES, M.L.; BIANCHI, R.A.C. 2003. Um mini robô móvel seguidor de pistas guiado por visão local. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI), VI, Bauru, 2003. *Anais...* Bauru, Sociedade Brasileira de Automática, p. 710-715.
- DARPA. 2007. Grand challenge website. Disponível em: [www.darpa.mil/grandchallenge](http://www.darpa.mil/grandchallenge). Acesso em: 08/05/2007.
- DASSAULT. 2007. Dassault company website. Disponível em: [www.dassault-aviation.com](http://www.dassault-aviation.com). Acesso em: 08/05/2007.
- DIAS, M.B.; ZLOT, R.; KALRA, N.; STENTZ, A. 2006. Market-based multirobot coordination: a survey and analysis. *Proceedings of the IEEE*, **94**:1257-1270.
- DORIGO, M.; TRIANNI, V.; SAHIN, E.; GRO, R.; LABELLA, T.; BALDASSARRE, G.; NOLFI, S.; DENEUBOURG, J.; MONDADA, F.; FLOREANO, D.; GAMBARDELLA, L. 2004. Evolving self organizing behaviors for a swarm-bot. *Autonomous Robots*, **17**:223-245.
- DUDEK, G.; JENKIN, M. 2000. *Computational principles of mobile robotics*. Cambridge/London, The MIT Press, 280 p.
- EBERHART, R.; KENNEDY, J. 1995. A new optimizer using particle swarm theory. In: INTERNATIONAL SYMPOSIUM ON MICRO MACHINE AND HUMAN SCIENCE (MHS'95), 6, Nagoya, 1995. *Anais...* Nagoya, IEEE Press, p. 39-43.
- EBERHART, R.C.; SHI, Y. 1998. Comparison between Genetic Algorithms and Particle Swarm Optimization. In: INTERNATIONAL CONFERENCE ON EVOLUTIONARY PROGRAMMING, 7, San Diego, 1998. *Anais...* Berlin, Springer-Verlag, p. 611-616.
- EBERHART, R.C.; SHI, Y. 2001. Particle swarm optimization: Developments, applications and resources. In: IEEE CONGRESS ON EVOLUTIONARY COMPUTATION (CEC'01), 3, Seoul, 2001. *Anais...* New York, IEEE Press, p. 81-86.
- EBERHART, R.C.; KENNEDY, J.; SHI, Y. 2001. *Swarm Intelligence*. San Francisco, Morgan Kaufmann, 510 p.
- ENGELBRECHT, A.P. 2005. *Fundamentals of computational swarm intelligence*. Hoboken, John Wiley & Sons, 672 p.
- GO, J.; BROWNING, B.; VELOSO, M. 2004. Accurate and flexible simulation for dynamic, vision-centric robots. In: INTERNATIONAL JOINT CONFERENCE ON AUTONOMOUS AGENTS AND MULTIAGENT SYSTEMS (AAMAS), 3, New York City, 2004. *Anais...* New York City, p. 1388-1389.
- HOLLAND, J. 1975. *Adaptation in Natural and Artificial Systems*. Ann Arbor, The University of Michigan Press, 206 p.
- IDMIND. 2007. Projecto RAPOSA. Disponível em: <http://raposa.idmind.pt>. Acesso em: 02/09/2007.
- JPL/NASA. 2007. Jet Propulsion Laboratory. Disponível em: [www.robotics.jpl.nasa.gov](http://www.robotics.jpl.nasa.gov). Acesso em: 09/05/2007.
- KENNEDY, J.; EBERHART, R. 1995. Particle Swarm Optimization. In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 9, Piscataway, 1995. *Anais...* New York, IEEE Press, p. 1942-1948.
- KENNEDY, J. 1999. Small worlds e mega-minds: Effects of neighborhood topology on particle swarm performance. In: IEEE CONGRESS OF EVOLUTIONARY COMPUTATION (CEC'99), 1, Washington D.C., 1999. *Anais...* New York, IEEE Press, p. 1931-1938.
- KIRKPATRICK, S.; GELATT, C.D.; VECCHI, M.P. 1983. Optimization by Simulated Annealing. *Science*, **220**(4598):671-680.
- MACEDO, A.R.M.; MACEDO, A.R.L.; DUARTE, J.B.F. 2007. Robótica aplicada ao combate a incidentes. *Revista TN Petróleo*, **53**:108-113.
- MARCHI, J. 2001. *Navegação de robôs móveis autônomos: estudo e implementação de abordagens*. Florianópolis, SC. Dissertação de mestrado. Universidade Federal de Santa Catarina, 118 p.
- MICHALEWICZ, Z. 1996. *Genetic Algorithms + Data Structures = Evolution Programs*. New York, Springer-Verlag, 387 p.
- MITCHELL, M. 1996. *An introduction to Genetic Algorithms*. Cambridge, The MIT Press, 205 p.
- MONDADA, F.; GAMBARDELLA, L.M.; FLOREANO, D.; DORIGO, M. 2005. The cooperation of swarm-bots: Physical interactions in collective robotics. *IEEE Robotics and Automation Magazine*, **12**:21-28.
- NIEHAUS, C.; RÖFER, T.; LAUE, T. 2007. Gait Optimization on a Humanoid Robot using Particle Swarm Optimization. In: WORKSHOP ON HUMANOID SOCCER ROBOTS, IEEE-RAS 7<sup>th</sup> INTERNATIONAL CONFERENCE ON HUMANOID ROBOTS, 2, Pittsburgh, 2007. *Anais...* New York, IEEE Press, p. 1-7.
- OSG. 2007. Open Scene Graph Community. Disponível em: [www.openscenegraph.com](http://www.openscenegraph.com). Acesso em: 02/03/2007.
- PENNSSTATE. 2007. Mobile Robotics Program. Disponível em: [www.ecsel.psu.edu](http://www.ecsel.psu.edu). Acesso em: 12/06/2007.
- PESSIN, G.; OSÓRIO, F.S.; MUSSE, S.R.; NONNENMACHER, V.; FERREIRA, S.S. 2007a. Desenvolvimento de um ambiente para simulação de robótica móvel em áreas florestais. In: SIMPÓSIO DE INFORMÁTICA DA REGIÃO CENTRO DO RS (SIRC-RS), VI, Santa Maria, 2007. *Anais...* Santa Maria, p. 1-8.
- PESSIN, G.; OSÓRIO, F.S.; MUSSE, S.R.; NONNENMACHER, V.; FERREIRA, S.S. 2007b. Simulação virtual de agentes autônomos para a identificação e controle de incêndios em reservas naturais. In: SYMPOSIUM ON VIRTUAL AND AUGMENTED REALITY (SVR), IX, Rio de Janeiro, 2007. *Anais...* Rio de Janeiro, LNCC, p. 236-245.

- PESSIN, G. 2008. *Evolução de Estratégias e Controle Inteligente em Sistemas Multi-Robóticos Robustos*. São Leopoldo, RS. Dissertação de mestrado. Universidade do Vale do Rio dos Sinos (Unisinos), 133 p. Disponível em <http://pessin.googlepages.com/disspessin2008.pdf>. Acesso em: 20/03/2008.
- PESSIN, G.; OSÓRIO, F.S. 2009a. Algoritmos genéticos aplicados à formação e atuação de grupos robóticos. *In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL (ENIA'09)*, VII, Bento Gonçalves, 2009. *Anais...* Bento Gonçalves, SBC, p. 1019-1028.
- PESSIN, G.; OSÓRIO, F. 2009b. Avaliação de um modelo tolerante a falhas para atuação tática de grupos robóticos utilizando algoritmos genéticos. *In: CONFERENCIA LATINOAMERICANA DE INFORMÁTICA (XXXV CLEI)*, XXXV, Pelotas, 2009. *Anais...* Pelotas, p. 1-10.
- PUGH, J.; MARTINOLI, A. 2006. Multi-robot learning with particle swarm optimization. *In: INTERNATIONAL JOINT CONFERENCE ON AUTONOMOUS AGENTS AND MULTIAGENT SYSTEMS (AAMAS'06)*, 5, Hakodate, 2006. *Anais...* New York, Association for Computing Machinery (ACM), p. 441-448.
- REIS, L.P. 2003. *Coordenação em sistemas multi-agente: aplicações na gestão universitária e futebol robótico*. Porto, Portugal. Tese de PhD. Universidade do Porto, 451 p.
- RONG, C.; WANG, Q.; HUANG, Y.; XIE, G.; WANG, L. 2008. Autonomous evolution of high-speed quadruped gaits using particle swarm optimization. *In: ROBOT SOCCER WORLD CUP XII (RoboCup)*, XII, Suzhou, China, 2008. *Anais...* Berlin, Springer-Verlag, p. 259-270.
- SDL. 2007. Simple DirectMedia Layer. Disponível em: <http://www.libsdl.org>. Acesso em: 05/01/2007.
- SILVEIRA, T.; OLIVEIRA, H.C.; SILVA, L.E. 2009. Controle de inércia para fuga de mínimos locais de funções não-lineares na otimização por enxame de partículas. *In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL (ENIA'09)*, VII, Bento Gonçalves, 2009. *Anais...* Porto Alegre, SBC, p. 739-748.
- SMITH, R. 2007. Open Dynamics Engine. Disponível em: <http://www.ode.org>. Acesso em: 18/02/2007.
- TRINITY. 2007. Firefighting robot contest. Disponível em: [www.trincoll.edu/events/robot](http://www.trincoll.edu/events/robot). Acesso em: 18/09/2007.
- WOOLDRIDGE, M.; JENNINGS, N. 1995. Intelligent agents: Theory and practice, *Knowledge Engineering Review*, **10**(2):115-152.
- YAMAGUCHI, H. 2003. Adaptive formation control for distributed autonomous mobile robotgroups. *In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION*, 20, Albuquerque, 2003. *Anais...* New York, IEEE Press, p. 2300-2305.
- ZHAO, Y.; COLLINS, E.G. 2005. Robust automatic parallel parking in tight spaces via fuzzy logic. *Robotics and Autonomous Systems*, **51**:111-127.

*Submitted on September 11, 2009.  
Accepted on November 23, 2009.*