

# Avaliação de Técnicas de Otimização Aplicadas à Formação e Atuação de Grupos Robóticos

Gustavo Pessin, Fernando S. Osório, Maurício A. Dias, Jefferson R. Souza e David F. Neto  
Universidade de São Paulo (USP)  
Instituto de Ciências Matemáticas e de Computação (ICMC)  
Av. do Trabalhador São-carlense, 400 - C.P. 668 - 13.560-970 - São Carlos, SP  
Email: {*pepin, fosorio, macdias, jrsouza, david*}@icmc.usp.br

**Resumo**—Neste trabalho avaliamos técnicas estocásticas de otimização buscando comparar a qualidade dos resultados com trabalhos prévios dos autores. As técnicas avaliadas no presente trabalho são o *Simulated Annealing* (SA) e o *Hill Climbing* (HC). A comparação dos resultados é realizada com trabalhos que utilizaram Algoritmos Genéticos (AG) e Algoritmos de Otimização por Enxame de Partículas (PSO). As técnicas de otimização são aplicadas na formação de grupos robóticos para atuação sobre um desastre ambiental do tipo incêndio florestal. São avaliados diversos parâmetros que influenciam o comportamento da otimização. A comparação entre os resultados tem como objetivo analisar se é possível obter resultados satisfatórios de formação de grupos com técnicas de otimização que exijam menor demanda computacional. Considerando os parâmetros propostos, tanto o SA como o HC não permitiram obter resultados tão satisfatórios quanto os obtidos usando AG e PSO para a formação do grupo de robôs.

**Palavras-chave**—Técnicas de otimização, Sistemas multirrobóticos, Hill Climbing, Simulated Annealing.

## I. INTRODUÇÃO

Diversas atividades podem não ser executadas de forma eficiente ou eficaz quando realizadas por um único agente. Tarefas como combate de incêndios, limpeza de resíduos nucleares ou químicos, construção civil, agricultura e missões de segurança e defesa são exemplos 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 [1], porém, 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 tem sido propostos buscando controlar estes conjuntos físicos em ambientes dinâmicos, o que tem apresentado ser uma tarefa árdua [2]. 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, de mercados e de enxames).

O desenvolvimento de um sistema multirrobótico para

atuação em monitoração e combate a incêndios em áreas florestais é um problema multidisciplinar. Assim, o sucesso desta tarefa envolve o uso de uma variedade de tecnologias de diferentes campos, como robótica móvel (e.g. controle de movimentação, fusão sensorial, modelagem robótica). Envolve a coleta de informações de especialistas sobre incêndios (e.g. comportamento do fogo em ambientes naturais, técnicas e métodos de monitoração, estratégias reais de combate). Na tarefa de controle de incêndio, uma das questões mais importantes tem relação com a estratégia de posicionamento dos robôs de combate. De acordo com a capacidade de atuação de cada robô, as condições climáticas (vento, chuva), a topografia e a vegetação, diferentes formações podem ser sugeridas. Estas formações, quando sugeridas por especialistas, podem não levar em conta o grande número de variáveis envolvidas, assim, a definição do posicionamento poderia fazer uso de técnicas de otimização. A tarefa de monitoração e combate a incêndios em áreas florestais é um caso onde a aplicação de um sistema multirrobótico poderia diminuir consideravelmente os prejuízos humanos, materiais e ambientais.

No trabalho [3] apresentamos a modelagem e a avaliação de Algoritmos Genéticos (AG) na busca de posições de atuação para um grupo robótico, avaliando características como estrutura de cromossomo e uso de valores de alelos e parâmetros como taxa de mutação, tipos de mutação, número de indivíduos e taxa de *crossover*. No trabalho [4] apresentamos a modelagem e a avaliação de Algoritmos de Otimização por Enxame de Partículas (PSO) na mesma aplicação, avaliando parâmetros como inércia, níveis de confiança, tipos de modelos de colaboração e tamanho de enxame. Os conjuntos de parâmetros avaliados não permitiram uma comparação estatística direta entre os métodos, porém, pôde-se perceber que tanto o AG, apresentado em [3], como o PSO, apresentado em [4], realizam com sucesso a tarefa de encontrar posições de atuação para o grupo robótico de forma relativamente similar.

Duas técnicas de otimização bastante difundidas em áreas de engenharia, e que apresentam resultados satisfatórios em diversos problemas são o *Simulated Annealing* (SA) e o *Hill Climbing* (HC). Ambos exigem menores recursos computa-

cionais quando comparados às técnicas de AG ou PSO. Assim, neste artigo<sup>1</sup> buscamos avaliar o resultado apresentado pelos métodos em comparação com os resultados obtidos com os trabalhos que exploraram o uso de AG e PSO. A comparação entre os resultados tem como objetivo analisar se é possível obter resultados satisfatórios de formação de grupos com técnicas de otimização computacionalmente menos demandantes.

A avaliação e o estudo da formação e atuação do grupo se dão sobre um desastre ambiental, simulado como um incêndio florestal. São realizadas experiências com grupos de 4 robôs bombeiros. Neste artigo, apresentamos na Seção II conceitos e aplicações de robótica móvel. Na Seção III apresentamos, respectivamente, conceitos e aplicações de HC e SA. Na Seção IV detalhamos o trabalho desenvolvido, descrevendo o simulador, a estrutura da solução e o *fitness* propostos, concluindo com a descrição detalhada dos experimentos e resultados.

## II. ROBÓTICA MÓVEL

Grupos de robôs devem ser formados por robôs capazes de atuar efetivamente em tarefas, assim, é de vital importância o conhecimento em controle robótico. Trabalhos descrevendo controle inteligente de navegação robótica podem ser vistos em [5] e [6]. Nos anos de 2004 e 2005, o *DARPA Grand Challenge* [7], 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*, tendo 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 interação múltipla, cooperação e negociação. A principal motivação na utilização de sistemas com grupos robóticos se dá devido à capacidade extra de solucionar problemas impossíveis individualmente. Trabalhos em grupo adicionam grandes possibilidades na solução de tarefas, mas trazem consigo uma série de questões a serem resolvidas, principalmente em termos de colaboração e cooperação.

Trabalhos abordando formação de grupos como [8] e [9] utilizam regras pré-programadas nos agentes para realizar a formação. Os trabalhos [10] e [1] exploram técnicas para realizar trabalhos com coletivos robóticos, usadas principalmente com a finalidade de aplicação do conceito de auto-organização e otimização coletiva, porém não é explorada explicitamente 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

<sup>1</sup>Códigos-fonte disponíveis em <http://sites.google.com/site/pessin>

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 existe pouca autonomia e robustez a situações não previstas.

## III. TÉCNICAS DE OTIMIZAÇÃO

As técnicas de otimização utilizadas neste trabalho, empregadas na busca de posições para formação de grupos robóticos, são detalhadas a seguir.

### A. Hill Climbing

O algoritmo padrão de Subida de Encosta (*Hill Climbing* - HC) é uma heurística de busca local a qual ajusta a posição de uma solução candidata somente se a nova posição é melhor que a posição prévia [11], [12]. O nome da técnica é uma analogia a forma usada por um alpinista para subir uma encosta, onde é escolhido um ponto inicial e somente são feitos movimentos que permitam alcançar pontos mais altos. A otimização no HC ocorre através da avaliação de soluções vizinhas de uma única solução inicial aleatória. Esta avaliação é feita através de uma função de avaliação (*fitness*) [13]. O HC padrão usa apenas um valor inicial, e toda a otimização tem como base esse único valor. A partir deste valor inicial são geradas soluções candidatas (chamadas de soluções vizinhas). O algoritmo executa por um número de passos definido (análogo a quantidade de gerações num AG). Além deste parâmetro, existem dois outros parâmetros que influenciam diretamente a otimização, que são (i) *quantidade de vizinhos* e (ii) *forma de obtenção de vizinhos*. A quantidade de vizinhos é o parâmetro que define a quantidade de soluções avaliadas em cada passo da otimização<sup>2</sup>; é, de certa forma, análoga ao conceito de população nos AGs. A forma de obtenção de vizinhos é análoga ao conceito de mutação.

O uso de HC tem apresentado sucesso em diversas áreas, principalmente quando usado de forma híbrida com outras técnicas. Trabalhos apresentando o uso de HC podem ser vistos em [14] e [15].

### B. Simulated Annealing

Arrefecimento Simulado (*Simulated Annealing* - SA) [16] é uma técnica com origem em mecânica estatística, baseada em uma metáfora de um processo térmico de recozimento, utilizado em metalurgia para obtenção de estados de baixa energia num sólido. O processo de recozimento consiste de (i) a temperatura do sólido é aumentada para um valor máximo no qual ele se funde e (ii) o resfriamento deve ser realizado lentamente até que o material se solidifique. O resfriamento lento faz com que os átomos que compõem o material sejam organizados em uma estrutura uniforme,

<sup>2</sup>Neste artigo, usamos o termo *geração* como sinônimo de *passo de otimização*

como resultado, é esperado uma redução dos defeitos do material [17]. A otimização no SA segue um padrão relativamente similar ao HC, ocorrendo através da avaliação de soluções vizinhas de uma única solução inicial aleatória. O SA padrão também usa apenas um valor inicial, e toda a otimização tem como base esse único valor. A maior diferença entre os métodos ocorre pelo motivo do SA substituir a solução atual por uma solução próxima escolhida de acordo com o *fitness* e com uma variável de temperatura  $t$ . Quanto maior for  $t$ , maior a aleatoriedade incluída na próxima solução escolhida. Com a execução do algoritmo, o valor de  $t$  é decrementado, fazendo o algoritmo convergir para uma solução ótima local. Desta forma, no início da execução, o SA permite uma maior exploração do espaço de busca. Os conceitos de *quantidade de vizinhos* e de *forma de obtenção de vizinhos* descrito na subseção anterior também se aplicam ao SA. O uso de SA tem encontrado sucesso em diversas áreas, sendo que exemplos de aplicações podem ser vistos em [18] e [19].

#### IV. FORMAÇÃO DO GRUPO

Para a implementação física real, as avaliações que propomos devem ser desenvolvidas e testadas anteriormente em ambientes de simulação realísticos. A simulação de sistemas robóticos é especialmente interessante para robôs caros, grandes, ou frágeis [2], sendo uma ferramenta extremamente poderosa para agilizar o ciclo de desenvolvimento de sistemas robóticos, eliminando desperdício de recursos. No caso deste trabalho, o simulador proposto foi desenvolvido para reproduzir um acidente ambiental que suporta a atuação de um grupo de robôs. O tipo de acidente ambiental desenvolvido foi o de um incêndio florestal. Assim, um grupo de robôs móveis (como motoniveladoras) tem o propósito de combater o fogo criando um aceiro na vegetação próximo do foco do incêndio. As características detalhadas do simulador e dos modelos de vegetação e de propagação do fogo podem ser vistas em [20].

O mecanismo de planejamento usa uma técnica estocástica de otimização para definir as posições iniciais e finais de cada robô. Os algoritmos desenvolvidos buscam otimizar especificamente: (i) Posição inicial no combate, para cada robô do grupo (ponto de início da criação de aceiro); (ii) Posição final no combate de cada robô do grupo (ponto final da criação de aceiro). Estas coordenadas são enviadas (mensagens de comando) para ativar as unidades de combate. Para realizar a simulação, são necessários: (i) Conhecer a quantidade de robôs disponíveis; (ii) Conhecer a velocidade de operação dos robôs; (iii) Saber a posição inicial dos robôs; (iv) Possuir capacidade de simular a propagação de incêndio. Para simular a propagação de incêndio são necessários: (i) Obter a coordenada inicial do incêndio; (ii) Obter o sentido do vento; (iii) Obter a direção do vento; (iv) Obter uma cópia simplificada do mapa (terreno

Tabela I  
ESTRUTURA PROPOSTA PARA SOLUÇÃO (GRUPO DE QUATRO ROBÔS - ÂNGULOS E RAIOS RELATIVOS AO PONTO INICIAL DO INCÊNDIO).

Posição	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

e vegetação). Este conjunto de informações proposto pode ser totalmente obtido a partir de sensores.

A estrutura proposta para a solução (Tabela I) possui informação referente a todo o grupo de robôs. São necessários 10 valores para um grupo de quatro robôs. Estes valores são armazenados num vetor de posições (análogo a genes em um AG). Na estrutura proposta do vetor, a posição final de um robô é a posição inicial do próximo, como apresenta a Tabela I. 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. Usamos, na implementação dos algoritmos, um conceito similar ao de alelos dos AGs, que tem como finalidade reduzir o espaço de busca. Assim, o raio pode ficar entre 10,0 e 100,0 unidades de medida e o ângulo pode ficar entre 0,0° e 360,0°. Os valores armazenados no vetor são do tipo ponto-flutuante, assim como nos trabalhos [3] e [4].

As posições de atuação dos robôs são calculadas aplicando no vetor de solução as Eq.  $x_d = x_a + r_i \cdot \cos(a_i)$  e  $y_d = y_a + r_i \cdot \sin(a_i)$ . Onde  $(x_d, y_d)$  é a coordenada da posição destino dos robôs,  $(x_a, y_a)$  é a coordenada da posição inicial do incêndio,  $r_i$  é o raio (posições 5 a 9) e  $a_i$  é o ângulo (em relação ao ponto inicial do incêndio - posições 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).

Ambos, HC e SA tem sua otimização guiada por uma função de *fitness*. A função de *fitness* utilizada neste trabalho é a mesma dos trabalhos [3] e [4], tendo relação com a área de vegetação salva do fogo e com a taxa de utilização das unidades de combate (robôs bombeiros). Assim, o *fitness* é o somatório dos 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 atingiria; (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

Tabela II  
CONJUNTO DE PARÂMETROS AVALIADOS.

Algoritmo	Quantidade de vizinhos avaliados em cada geração	Mutação (Forma de obtenção de novos vizinhos)
HC	{50; 100; 200}	{10%; 50%; RND}
HC	{50; 100; 200}	{10%; 50%; RND}
HC	{50; 100; 200}	{10%; 50%; RND}
SA	{50; 100; 200}	{10%; 50%}
SA	{50; 100; 200}	{10%; 50%}
SA	{50; 100; 200}	{10%; 50%}

tamanho das áreas de trabalho tende a se equalizar. Otimizar o *fitness*, no nosso 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.

## V. EXPERIMENTOS E RESULTADOS

As simulações foram realizadas considerando diferentes quantidades de vizinhos<sup>3</sup> e diferentes formas de obtenção de vizinhos<sup>4</sup> de acordo com o apresentado na Tabela II. O número de gerações utilizado é de 800 – mesmo valor utilizado no trabalho [4]. Para verificar qual o melhor conjunto de parâmetros, fixamos as características climáticas da simulação do incêndio, bem como as posições iniciais dos robôs. Foram executadas vinte simulações com cada conjunto de parâmetros, totalizando 900 simulações.

O resultado do processo de busca (otimização) pode ser visto na Fig. 2. Diversas observações visuais foram realizadas no simulador (usando os valores obtidos pelos algoritmos de otimização), apresentando que valores de *fitness* inferiores a 3.500,00 são capazes de apagar o incêndio de forma eficiente e com áreas de atuação bem distribuídas entre os robôs. Assim, para os conjuntos de parâmetros utilizados na otimização, seriam considerados satisfatórios para este trabalho os conjuntos que apresentassem todas as vinte simulações com *fitness* inferior a 3.500,00. A Fig. 1 apresenta alguns resultados satisfatórios e não satisfatórios das simulações. As Fig. 1(a), 1(b) e 1(c), apresentam, respectivamente, *fitness* de 9.891,00, 5.617,00 e 2.991,00.

Resultados abaixo de 3.500,00 ocorreram apenas em 15% dos casos nos seguintes conjuntos de parâmetros: (HC, 50 vizinhos, 10% de mutação); (HC, 100 vizinhos, 10% de mutação); (HC, 200 vizinhos, 10% de mutação). E em 5% dos casos nos seguintes conjuntos de parâmetros: (SA, 100 vizinhos, 10% de mutação); (SA, 200 vizinhos, 10% de mutação). Nenhum outro conjunto de parâmetros apresentou alguma solução com *fitness* inferior a 3.500,00.

Os conjuntos citados como capazes de encontrar algumas soluções satisfatórias, apenas as encontraram em um

<sup>3</sup>Análogo a quantidade de indivíduos em um Algoritmo Genético.

<sup>4</sup>Valor percentual aplicado para mais ou para menos sobre o valor original a fim de obter um novo número relativamente próximo ao original. Análogo a mutação em um AG. *RND* se refere a vizinhos completamente randômicos.

número muito pequeno de vezes. Sendo o desvio padrão das simulações altíssimo. Tal desvio-padrão nos faz acreditar que tanto o HC como o SA se mostram muito suscetíveis a semente aleatória utilizada.

Podemos ver na Fig. 2 que as simulações que utilizaram 10% de mutação apresentaram as menores médias finais. E que as simulações que utilizaram vizinhos aleatórios apresentaram os menores desvio-padrões. Este fato poderia ser explorado em futuras análises, por exemplo, mantendo  $n$  gerações randômicas seguidas de  $m$  gerações com mutação de 10%. Ainda, na Fig. 2, podemos ver que as piores médias foram obtidas com mutação de 50%, independente do número de indivíduos. Também podemos ver que usando 10% de mutação, existe uma pequena vantagem para o HC frente ao SA, para todos os tamanhos de população. Novas avaliações poderiam ser feitas a fim de encontrar melhores conjuntos de parâmetros. Porém, como o número de gerações avaliado neste trabalho está similar ao utilizado no AG [3] e no PSO [4], isso nos faz acreditar que o AG e o PSO oferecem vantagens. Algumas simulações utilizando 1000 gerações foram realizadas com o HC e o SA, porém, também não mostraram resultados significativamente melhores.

No SA, foram utilizados parâmetros de temperatura e resfriamento de 20,0 e 0,98. O critério de parada foi o número de gerações (igual a 800). Considerando que o SA pode trocar soluções atuais por soluções piores, observamos que isso não ocorreu em todas as simulações; quando ocorreu ela foi sempre no máximo até a geração 35 (temperatura superior a 10,0), concentrando-se nas primeiras 10 gerações (temperatura superior a 17,0).

A Fig. 3 apresenta as curvas de queda de *fitness* dos dois melhores conjuntos obtidos neste trabalho, bem como as curvas obtidas nos trabalhos [3] e [4]. Em [3] foi possível observar que o AG permitiu obter 100% dos casos com valores inferiores a 3.500,00. Em [4] foi possível observar que o PSO permitiu obter 100% dos casos com valores também inferiores a 3.500,00. Os parâmetros avaliados não permitem uma validação estatisticamente formal, porém, tanto o AG como o PSO apresentaram resultados muito superiores ao SA e ao HC avaliados neste trabalho.

## VI. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho avaliamos as técnicas de otimização de HC e SA buscando comparar a qualidade dos resultados com trabalhos prévios dos autores que utilizaram AG e PSO. As técnicas de otimização são aplicadas na formação de grupos robóticos para atuação sobre um desastre ambiental do tipo incêndio florestal. Avaliamos diversos parâmetros que influenciam o comportamento da otimização. A comparação entre os resultados teve como objetivo analisar a possibilidade de obter resultados satisfatórios de formação de grupos com técnicas de otimização que exijam menor custo computacional. Considerando os parâmetros propostos, tanto

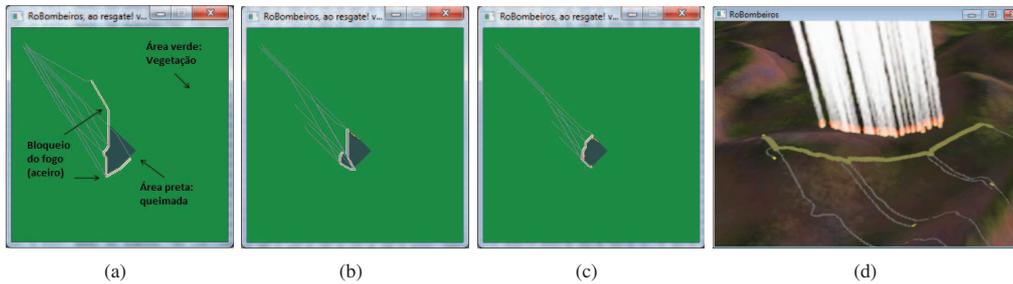


Figura 1. (a) e (b) Resultados não satisfatórios. (a) Exemplo de resultado usando HC com 200 vizinhos e mutação randômica. O aceiro é excessivamente grande em relação ao que seria necessário. (b) Exemplo de resultado usando SA com 200 vizinhos e 10% de mutação. O aceiro está mal distribuído entre os robôs. (c) Resultado satisfatório, obtido em uma das simulações usando HC com 200 vizinhos e 10% de mutação. (d) Exemplo do resultado satisfatório aplicado no simulador 3D.

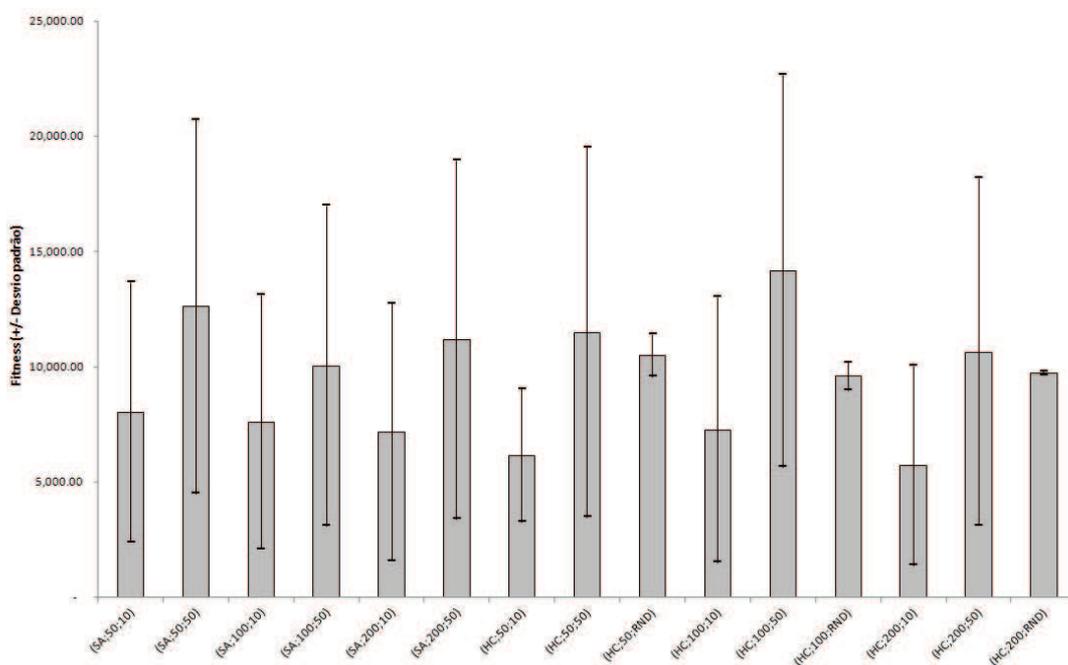


Figura 2. Resultado das avaliações apresentadas na Tabela II. O eixo x apresenta a descrição do conjunto de parâmetros como (método; número de vizinhos; mutação).

o SA como o HC não permitiram obter resultados tão satisfatórios quanto os obtidos usando AG e PSO para a formação do grupo de robôs.

O próximo passo deste trabalho é a execução do sistema proposto usando robôs reais. Para tanto, serão necessários estudos referentes a adaptação do modelo para tais ambientes, bem como a modelagem do hardware dos robôs.

#### AGRADECIMENTOS

Agradecemos a CAPES e ao CNPq pelo apoio financeiro através de bolsas de estudo e ao CNPq e FAPESP pelo financiamento ao INCT-SEC, processos 573963/2008-8 e 08/57870-9.

#### REFERÊNCIAS

- [1] F. Mondada, L. M. Gambardella, D. Floreano, and M. Dorigo, "The cooperation of swarm-bots: Physical interactions in collective robotics," *IEEE Robotics and Automation Magazine*, vol. 12, pp. 21–28, 2005.
- [2] J. Go, B. Browning, and M. Veloso, "Accurate and flexible simulation for dynamic, vision-centric robots," in *Proc. of Int. Joint Conf. on Autonomous Agents and Multiagent Systems (AAMAS)*. IEEE Computer Society, 2004, pp. 1388–1389.
- [3] G. Pessin and F. S. Osório, "Avaliação de um modelo tolerante a falhas para atuação tática de grupos robóticos utilizando algoritmos genéticos," in *XXXV Conferência Latinoamericana de Informática (CLEI)*, 2009. [Online]. Available: <http://sites.google.com/site/pessin/Home/Clei2009.pdf>

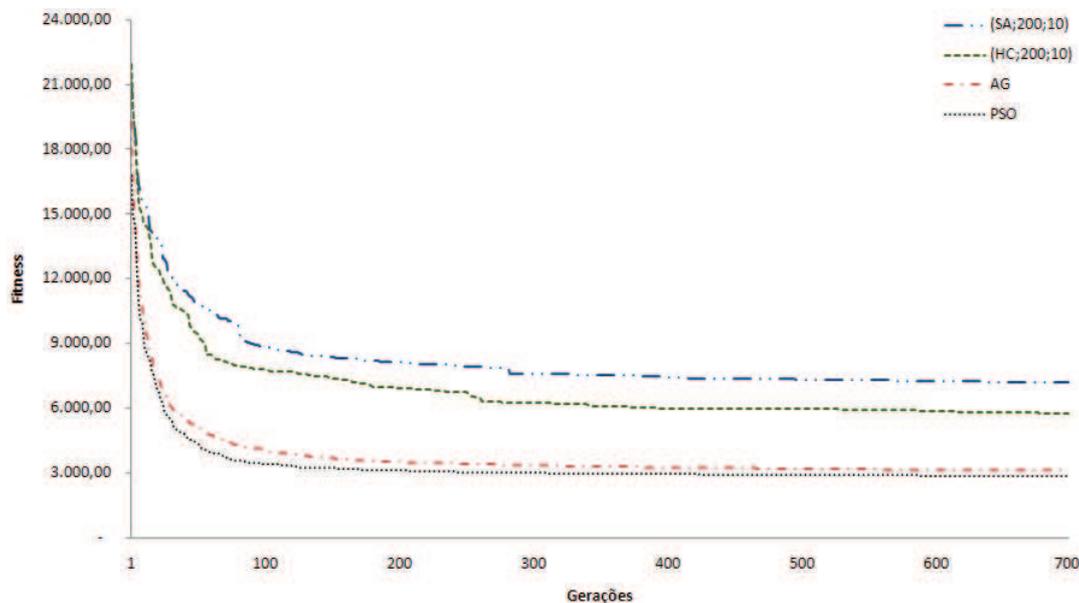


Figura 3. Curvas de queda de *fitness* dos melhores HC e SA obtidos neste trabalho – HC e SA com 200 vizinhos e 10% de mutação. Curva de queda de *fitness* do AG de [3] – AG com 150 indivíduos, 10% de mutação, *crossover* de dois pontos. Curva de queda de *fitness* do PSO de [4] – PSO com 200 partículas, inércia de 0,5 e modelo completo.

- [4] G. Pessin and F. Osório, “Otimização por enxame de partículas aplicado a formação e atuação de grupos robóticos,” *Scientia*, vol. 20, no. 2, pp. 94–106, 2009. [Online]. Available: <http://dx.doi.org/10.4013/sct.2009.20.2.03>
- [5] Y. Zhao and E. G. Collins, “Robust automatic parallel parking in tight spaces via fuzzy logic,” *Robotics and Autonomous Systems*, vol. 51, pp. 111–127, 2005.
- [6] M. Heinen, F. Osório, F. Heinen, and C. Kelber, “Seva3d: Using artificial neural networks to autonomous vehicle parking control,” in *Neural Networks, 2006. IJCNN '06. International Joint Conference on*, 2006.
- [7] Darpa, “Darpa grand challenge webpage, [www.darpa.mil/grandchallenge](http://www.darpa.mil/grandchallenge),” 2007.
- [8] H. Yamaguchi, “Adaptive formation control for distributed autonomous mobile robot groups,” in *IEEE Int. Conf. on Robotics and Automation*, 1997, pp. 2300–2305.
- [9] T. Balch and R. C. Arkin, “Behavior-based formation control for multi-robot teams,” *IEEE Transactions on Robotics and Automation*, vol. 14, no. 6, pp. 926–939, 1998.
- [10] M. Dorigo, V. Trianni, E. Sahin, R. Gro, T. Labella, G. Baldassarre, S. Nolfi, J. Deneubourg, F. Mondada, D. Floreano, and L. Gambardella, “Evolving self-organizing behaviors for a swarm-bot,” *Autonomous Robots*, vol. 17, pp. 223–245, 2004.
- [11] J. Pearl, *Heuristics: Intelligent Search Strategies for Computer Problem Solving*. Addison-Wesley, 1984.
- [12] A. P. Engelbrecht, *Fundamentals of Computational Swarm Intelligence*. John Wiley & Sons, 2005.
- [13] Z. Michalewicz and D. B. Fogel, *How to Solve It: Modern Heuristics*. Springer-Verlag, 2008.
- [14] R. Rocha, F. Ferreira, and J. Dias, “Multi-robot complete exploration using hill climbing and topological recovery,” in *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2008.
- [15] A. Lim, J. Lin, B. Rodrigues, and F. Xiao, “Ant colony optimization with hill climbing for the bandwidth minimization problem,” in *Applied Soft Computing*, vol. 6, no. 2, 2006, pp. 180–188.
- [16] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, “Optimization by simulated annealing,” *Science*, vol. 220, pp. 671–680, 1983.
- [17] J. C. Becceneri, *Computação e Matemática Aplicadas as Ciências e Tecnologias Espaciais*. SP, Brasil: INPE, 2009, ch. Meta-heurística e otimização combinatória: aplicações em problemas ambientais, pp. 65–81.
- [18] B. Suman and P. Kumar, “A survey of simulated annealing as a tool for single and multiobjective optimization,” *The Journal of the Operational Research Society*, vol. 57, no. 10, pp. 1143–1160, 2006.
- [19] C. Koulamas, S. R. Antony, and R. Jaen, “A survey of simulated annealing applications to operations research problems,” *Omega*, vol. 22, pp. 41–56, 1994.
- [20] G. Pessin, “Evolução de estratégias e controle inteligente em sistemas multi-robóticos robustos,” Master’s thesis, Universidade do Vale do Rio dos Sinos, 2008. [Online]. Available: [pessin.googlepages.com/disspessin2008.pdf](http://pessin.googlepages.com/disspessin2008.pdf)