

ALGORITMO HÍBRIDO DE OTIMIZAÇÃO GLOWWORM-BOIDS

Gian FRITSCHÉ^{1,2,*}, Paulo B. Moura OLIVEIRA¹, Eduardo J. Solteiro PIRES¹, Pedro L. Paula FILHO²

¹INESC TEC – INESC Tecnologia e Ciência (INESC Porto, polo UTAD), Departamento de Engenharias,
Escola de Ciências e Tecnologia, 5001–811 Vila Real, Portugal

²Universidade Tecnológica Federal do Paraná, Campus Medianeira
Avenida Brasil, 4232, Medianeira Brasil

gian.fritsche@gmail.com, {oliveira,epires}@utad.pt, pedrol@utfpr.edu.br

Resumo

Este trabalho descreve a utilização de técnicas de inspiração natural na simulação de enxames, utilizando regras comportamentais propostas nos algoritmos Boids e Glowworm. O objetivo principal do trabalho consiste em desenvolver uma técnica híbrida entre os algoritmos Boids e Glowworm, que permita a exploração e otimização de espaços multimodais de uma forma eficiente.

Palavras-chave: Algoritmo glowworm; Boids; Inteligência artificial; Enxames robóticos.

Abstract

This work reports the use of natural inspired algorithms to simulate swarms, using the Boids behavioral rules and Glowworm algorithm. The overall goal is to develop a hybrid technique between Boids and Glowworm to efficiently explore and optimize multimodal search spaces.

Keywords: Glowworm algorithm; Boids; Artificial intelligence; Robotic swarms.

INTRODUÇÃO

A utilização de algoritmos de inteligência coletiva de enxames tem aplicações relevantes na robótica móvel, por exemplo na tomada de decisão de percurso, entre outras. O algoritmo Boids [1] é uma técnica que foi inicialmente desenvolvida para a simulação gráfica de pássaros, e que tem sido aplicada em aplicações robóticas [2]. Outro algoritmo, mais recente, é o Glowworm [3, 4], utilizado para pesquisa e otimização de funções multimodais, ou seja, funções que possuem múltiplos pontos ótimos. Este algoritmo é inspirado no comportamento dos vaga-lumes. Neste trabalho são apresentados os resultados de testes de simulação dos algoritmos Boids e Glowworm, e testes de um algoritmo híbrido, em desenvolvimento, que visa aproveitar as vantagens exploratórias do Boids e o bom desempenho na pesquisa multimodal demonstrada pelo Glowworm.

ALGORITMO BOIDS

O algoritmo Boids foi proposto por Craig Reynolds [1], consistindo num modelo de simulação do movimento coordenado de animais, como bando de aves e cardumes, onde cada pássaro simulado é implementado como um agente capaz de tomar decisões independentes, baseadas em um conjunto de três regras. O comportamento global do bando emerge da contínua interação entre os comportamentos simples de cada indivíduo. Cada uma das três regras calcula um vetor que representa a direção e

a velocidade para cada pássaro. Em seguida, os três vetores são adicionados à velocidade atual do pássaro, e a velocidade somada à posição atual. A primeira regra, chamada de coesão, simula o comportamento dos pássaros ficarem próximos uns dos outros. Cada pássaro calcula a média das posições dos demais, e retorna a diferença entre a sua posição atual e o centro de posição dos restantes. Esta velocidade, v_c , pode ser calculada para cada agente através da Equação (1). Na qual $x_i(t)$ representa a posição do pássaro i na iteração t , x_{ctr} a média das posições dos restantes e α_1 determina a taxa de aproximação ao centro. A segunda regra, denominada de separação, foi proposta para evitar colisões com os pássaros vizinhos. São considerados vizinhos os pássaros em que a diferença das posições seja menor do que uma determinada distância δ que pode ser ajustada de acordo com a aplicação. Cada pássaro calcula a média das distâncias que se deve afastar de cada vizinho de modo a evitar colisões. A velocidade de separação, v_s pode ser calculada com a Equação (2). Na qual $dist(i, j)$ representa a distância entre os elementos i e j , e α_2 estabelece a taxa de separação entre os elementos (boids). A terceira regra, chamada de alinhamento, simula o comportamento dos pássaros de manterem a mesma direção e velocidade. Calculando para cada pássaro a média das velocidades dos demais e devolvendo a diferença entre essa velocidade e a velocidade do pássaro. Esta velocidade pode

* Bolsista do CNPq – Brasil

ser calculada com a Equação (3). Na qual α_3 define a taxa de alinhamento relativamente a média das velocidades dos demais boids, v_{ctr} . A implementação do algoritmo é simples e escalável, bem como a adição de novos comportamentos. Alterando as taxas de ponderação, a_1 , a_2 , a_3 , das regras, é possível controlar o comportamento do enxame, dando mais ou menos importância a determinada regra.

$$vc_i(t) = \alpha_1[x_i(t) - x_{ctr}(t)] \quad (1)$$

$$vs_i(t) = \begin{cases} vs_i(t) - \alpha_2(x_i(t) - x_j(t)) \Leftarrow dist(i, j) < \delta \\ vs_i(t) \Leftarrow dist(i, j) \geq \delta \end{cases} \quad (2)$$

$$va_i(t) = \alpha_3[v_{ctr}(t) - v_i(t)] \quad (3)$$

ALGORITMO GLOWWORM

Este algoritmo foi proposto por Krishnanand e Ghose [3, 4] e é inspirado no comportamento dos vaga-lumes. O algoritmo é aplicado à otimização e visa encontrar diversas soluções ótimas. Cada vaga-lume é caracterizado pela sua posição, vetor x , e por uma substância luminescente chamada luciferina, representada pelo vetor l . Cada vaga-lume tem uma vizinhança circular com raio r , que determina o alcance de interação com possíveis vizinhos. A luciferina é atualizada de acordo com a Equação (4). Onde: ρ é um parâmetro de decaimento da luciferina definido no intervalo $[0,1]$, J é o valor da função objetivo, γ representa a constante de melhoria da luciferina e t a iteração atual. Um vaga-lume j pertence à vizinhança do vaga-lume i , N_i , segundo a Equação (5), onde: $dist(i,j)$ representa a distância euclidiana entre i e j , e r representa o raio para o vaga-lume i . O vaga-lume i seleciona o melhor vizinho j , segundo

a Equação (6). O movimento de um vaga-lume i na direção de um vizinho j selecionado é determinado com a Equação (7), onde s representa o tamanho do incremento da posição. O raio da vizinhança é atualizado dinamicamente com a Equação (8), onde: β é um parâmetro constante e n_t define o número de vizinhos. O algoritmo apresenta bons resultados na resolução de problemas multimodais, capturando diversos ótimos globais e locais.

$$l_i(t+1) = (1 - \rho)l_i(t) + \gamma J(x(t)) \quad (4)$$

$$j \in N_i(t), N_i(t) = \{j: dist(i, j) < r_i; l_i(t) < l_j(t)\} \quad (5)$$

$$p_{ij}(t) = \frac{l_j(t) - l_i(t)}{\sum_{k \in N_i(t)} (l_k(t) - l_i(t))} \quad (6)$$

$$x_i(t+1) = x_i(t) + s \cdot \frac{x_j(t) - x_i(t)}{\|x_j(t) - x_i(t)\|} \quad (7)$$

$$r_i(t+1) = \min\{r_s, \max\{0, r_i(t) + \beta(n_t - |N_i(t)|)\}\} \quad (8)$$

ALGORITMO HÍBRIDO GLOWWORM-BOIDS

Neste trabalho é proposto uma hibridização entre os dois algoritmos apresentados, com o objetivo de melhorar o desempenho do Glowworm, capturando mais pontos ótimos e evitando a estagnação da busca, que ocorre quando um elemento não tem qualquer vizinho com quem possa partilhar a sua experiência. No algoritmo proposto para cada elemento do Glowworm é inicializado um mini enxame Boids na sua vizinhança que garante a existência de vizinhos e uma melhor exploração do espaço de pesquisa. A cada iteração as partículas boids movimentam-se seguindo as três regras do algoritmo Boids e uma quarta regra, que faz com que o glowworm guie a movimentação do respectivo mini enxame, conforme

a Equação (9), onde v_{glw} é a posição da partícula glowworm na iteração t . Em seguida é escolhido o melhor indivíduo de cada mini enxame. Em caso de problemas de minimização, ou seja, onde o objetivo é encontrar os pontos de menor valor na função objetivo, é considerado melhor o indivíduo que possuir o menor valor, em caso de maximização, onde o objetivo é encontrar os pontos de maior valor, é considerado melhor o indivíduo que possuir o maior valor. Então são trocadas as posições de cada glowworm i com o melhor do seu mini enxame.

$$v_{g_i}(t) = \alpha_4[v_{glw}(t) - v_i(t)] \quad (9)$$

Estes passos são repetidos até que seja satisfeita a condição de parada.

Na Figura 2 é apresentado o desvio padrão da movimentação das partículas pelo espaço de pesquisa utilizando os algoritmos Glowworm (Figura 2 a)) e Glowworm-boids (Figura 2 b)). É possível observar


que a hibridização dos algoritmos Glowworm e Boids torna a pesquisa mais exploratória e diversificada do que a efetuada pelo Glowworm. O que auxilia na obtenção de mais pontos ótimos. Para os testes foi utilizada a função de Branin, que possui 3 pontos ótimos de coordenadas conhecidas e valor ótimo 0,

$$f(x, y) = (y - \frac{5.1}{4\pi^2}x^2 + \frac{5}{\pi}x - 6)^2 + 10(1 - \frac{1}{8\pi})\cos(x) + 10 \quad (10)$$


$$-5 \leq x \leq 10, 0 \leq y \leq 15$$

apresentada na Equação (10)

Na Figura 3 é apresentado o gráfico de barras de outro teste realizado na função de Branin, utilizando 101 execuções de cada algoritmo (Glowworm e Glowworm-Boids). É apresentado a média, máximo e mediana de pontos ótimos encontrados nas 101 execuções para os algoritmos Glowworm e Glowworm-Boids respectivamente. Onde o algoritmo híbrido obteve melhores resultados tanto em média, máximo e mediana.



a) Algoritmo Glowworm



Algoritmo Glowworm-boids.

Figura 2: Gráficos dos testes realizados com os algoritmos Glowworm e Glowworm-boids.




Figura 3: Pontos ótimos encontrados

CONCLUSÕES

Apresentaram-se resultados preliminares de simulação, utilizando uma função multimodal clássica de pontos ótimos conhecidos, sem realizar o estudo de caso de um problema real de otimização. Propôs-se um algoritmo híbrido entre o Glowworm e o Boids. A utilização de um mini enxame Boids ao redor de cada partícula do Glowworm visa melhorar exploração da vizinhança, evitando a estagnação da busca. É necessário realizar mais testes, em mais funções, para averiguar melhor o mérito do algoritmo proposto.

REFERÊNCIAS

- REYNOLDS, C. W. Flocks, herds, and schools: A distributed behavioral model. *Computer Graphics*, p. 25–34, 1987.
- BERMAN S.; HALÁSZ A.; KUMAR V.; PRATT S. Algorithms for the Analysis and Synthesis of a Bio-Inspired Swarm Robotic System, E. Sahin et al. Eds., *Swarm Robotics Ws*, LNCS 4433, p. 56-70, Springer-Verlag, 2007.
- KRISHNANAND K.N.; GHOSE D. Glowworm swarm optimization for simultaneous capture of multiple local optima of multimodal functions. *Swarm Intelligence v.3*, p 87–124, 2009.
- KRISHNANAND K.N.; GHOSE D. Glowworm Swarm Optimization for Simultaneous Capture of Multiple Local Optima of Multimodal Functions. Report TR-PME-2006-09, Indian Institute of Science Bangalore, 2006. 2006.