



Sistemas Inteligentes

– Particle Swarm Optimization (PSO) – (Otimização por Enxame de Partículas)

Prof. Ivan Nunes da Silva



1. Inteligência Coletiva (Swarm)

Conceitos introdutórios

- É aquela inteligência que acaba estando distribuída **quando se considera o todo**, que é incessantemente valorizada, que é coordenada em tempo real, e que resulta em mobilização efetiva de competências bem simples.
- Os sistemas de Inteligência Coletiva são compostos tipicamente por:
 - Uma população de organismos que interagem localmente um com o outro e com seu ambiente.
 - Os agentes seguem regras bem simples, sendo que nenhuma estrutura centralizada de controle rege como os agentes (organismos) individuais devem se comportar.
 - Essas interações locais entre tais agentes conduzem à resolução de problemas com comportamento global complexo.
- Assim como os Algoritmos Genéticos, métodos baseados em Inteligência Coletiva (*Particle Swarm Optimization – PSO // **Enxame de Partículas***) são aplicados tipicamente em problemas de **otimização de sistemas**.

1. Inteligência Coletiva (Swarm)

Características de inteligência coletiva

- São notáveis a interação social e a capacidade de adaptação de vários organismos.
- Segundo a ótica da inteligência artificial e da psicologia social:
 - Inteligência e sucesso, em muitos casos, provêm muito mais da sociabilidade do que da capacidade individual.
- A inteligência artificial distribuída é uma área de pesquisa que aborda fenômenos ligados a “inteligência social”:
 - Formigas;
 - Cupins;
 - Abelhas;
 - Peixes;
 - Pássaros.

A inteligência de Enxames vem sendo designada como classe de algoritmos de otimização.




3

1. Inteligência Coletiva (Swarm)

Estratégia de mapeamento de problemas

- As estratégias modelam o “comportamento social” observado em diversos tipos de colônias.
 - Inicialmente, os indivíduos se movimentam sem nenhuma orientação prévia;
 - Se aglomeram em colônias, até que um consegue encontrar o ninho ou a comida;
 - Este atrai os que estiverem mais próximos e a chance dos outros encontrarem aumenta consideravelmente.
- Os algoritmos possuem um vetor de **velocidades** e outro de **posições** para cada uma das partículas.



4

2. Contexto de Métodos Swarm

Mecanismos de funcionamento

- Sempre baseados em duas variáveis básicas:

- Posição
- Velocidade

- Como exemplo, têm-se os pássaros:

- Pássaros estão dispostos aleatoriamente e estes estão à procura por alimento e um local para construir o seu ninho.
- Eles, à priori, não sabem onde está esse lugar, mas este é único.
- Qual o melhor comportamento que os pássaros terão que realizar para conseguir efetuar seu objetivo?

- Estratégia de busca da melhor solução:

1. Inicialmente, os pássaros voam sem nenhuma orientação prévia;
2. Se aglomeram em bandos, até que um consegue encontrar o ninho ou a comida;
3. Este atrai os que estiverem mais próximos;
4. A chance dos outros encontrarem aumenta consideravelmente.

5

2. Contexto de Métodos Swarm

Terminologia dos componentes

- Para o caso dos pássaros, estes são denominados de as “**partículas**” do processo:

- Durante a busca por alimento ou ninho, as “partículas” usam de suas experiências individuais e da experiência do próprio bando.

- Assim, o PSO é um algoritmo que possui um vetor de **velocidades** (v_i^k) e outro de **posição** (x_i^k);

- v_i^k é a velocidade corrente da partícula i na iteração k .
- x_i^k é a posição corrente da partícula i na iteração k .

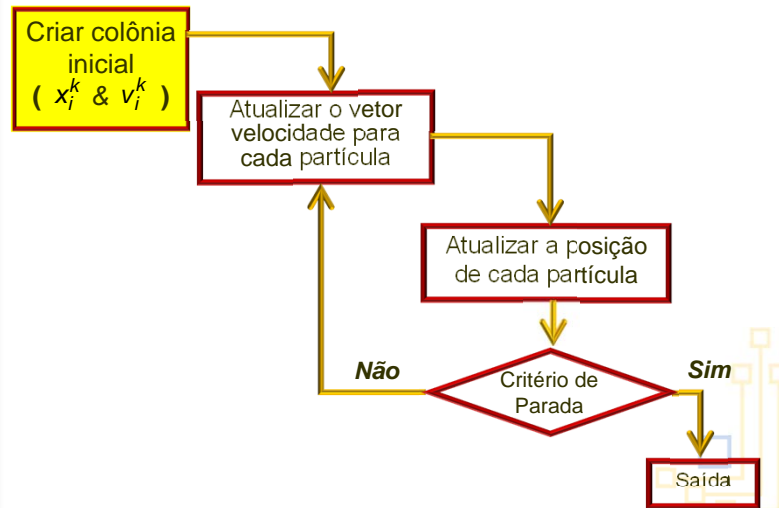
- A **posição** de cada partícula é atualizada de acordo com a velocidade atual, levando-se em conta os seguintes aspectos:

- Conhecimento adquirido pela “partícula” ($pbest$).
- Conhecimentos adquiridos pelo “bando” ($gbest$).

6

3. Algoritmo de Métodos Swarm

Diagrama de blocos principais



3. Algoritmo de Métodos Swarm

Criando colônia inicial (posição)

- A inicialização da população é normalmente obtida com as partículas dispostas aleatoriamente sobre o domínio de definição do problema;
- A equação seguinte mostra uma maneira de se obter a posição inicial:

$$x_i^{inicial} = x_{\min} + rand_1 \cdot (x_{\max} - x_{\min}) \quad (1)$$

onde:

- $x_i^{inicial}$ é a posição inicial da partícula i ;
- x_{\min} é o limite inferior do domínio de definição;
- x_{\max} é o limite superior do domínio de definição;
- $rand_1$ é um número aleatório entre 0 e 1.

8

3. Algoritmo de Métodos Swarm

Criando colônia inicial (velocidade)

- Cada partícula possui também uma velocidade que foi inicializada aleatoriamente.
- A equação seguinte mostra uma maneira de se obter o vetor de velocidades iniciais:

$$v_i^{inicial} = \frac{x_{\min} + rand_2 \cdot (x_{\max} - x_{\min})}{\Delta t} \quad (2)$$

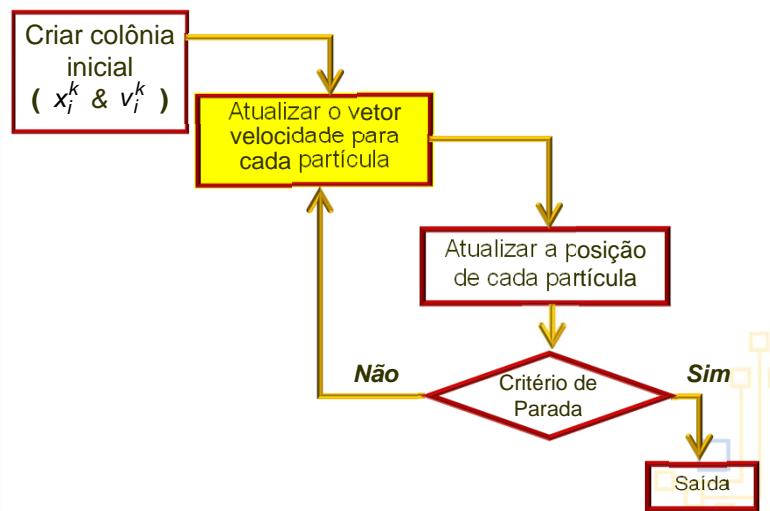
onde:

- $v_i^{inicial}$ é a velocidade inicial da partícula i ;
- x_{\min} é o limite inferior do domínio de definição;
- x_{\max} é o limite superior do domínio de definição;
- $rand_2$ é um número aleatório entre 0 e 1;
- Δt é o intervalo de tempo considerado.

9

3. Algoritmo de Métodos Swarm

Atualizando vetor de velocidades



10

3. Algoritmo de Métodos Swarm

Atualizando vetor de velocidades (regra de ajuste)

- O vetor de velocidades pode ser atualizado conforme a seguinte equação:

$$v_i^{k+1} = w_i \cdot v_i^k + c_1 \cdot \text{rand} \cdot (pbest_i - x_i^k) + c_2 \cdot \text{rand} \cdot (gbest^k - x_i^k) \quad (3)$$

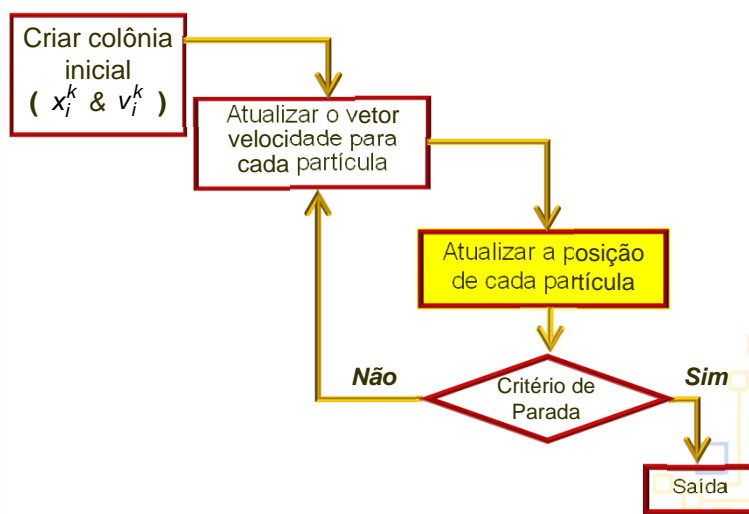
onde:

- v_i^k é a velocidade corrente da partícula i na iteração k ;
- v_i^{k+1} é a velocidade atualizada da partícula i ;
- x_i^k posição corrente da partícula i na iteração k ;
- $pbest_i$ é o melhor valor de retorno (custo) da partícula i ;
- $gbest^k$ é o melhor valor de retorno do bando na iteração k ;
- rand é um número aleatório entre 0 e 1;
- c_1 e c_2 são coeficientes de ponderação; *{parâmetros de confiança}*
- w_i é uma função de ponderação para a velocidade da partícula i . *{representa a sua inércia}*

11

3. Algoritmo de Métodos Swarm

Atualizando vetor de posições



12

3. Algoritmo de Métodos Swarm

Atualizando vetor de posições (regra de ajuste)

- A próxima posição das partículas é calculada usando-se a seguinte expressão:

$$x_i^{k+1} = x_i^k + v_i^{k+1} \cdot \Delta t \quad (4)$$

onde:

- x_i^{k+1} é a posição de cada partícula i na iteração $k+1$;
- x_i^k é posição corrente da partícula i na iteração k ;
- v_i^{k+1} é o vetor de velocidade da partícula i na iteração $k+1$;
- Δt é o intervalo de tempo considerado.



13

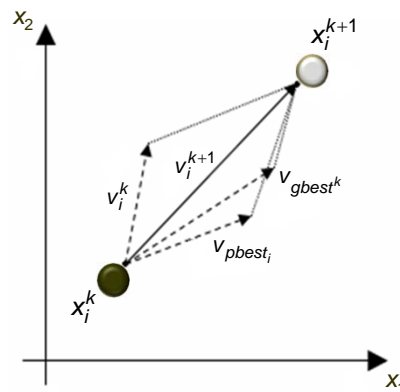
3. Algoritmo de Métodos Swarm

Atualizando vetor de posições (interpretação geométrica)

$$v_i^{k+1} = w_i \cdot v_i^k + c_1 \cdot \text{rand} \cdot (pbest_i - x_i^k) + c_2 \cdot \text{rand} \cdot (gbest^k - x_i^k)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \cdot \Delta t$$

- x_i^k é a posição corrente;
- x_i^k é a posição de busca atualizada;
- v_i^k é a velocidade corrente;
- v_i^{k+1} é a velocidade atualizada;
- v_{pbest_i} é a velocidade em função de $pbest_i$;
- v_{gbest^k} é a velocidade em função de $gbest^k$.



14

3. Algoritmo de Métodos Swarm

Atualizando vetor de posições (velocidade máxima)

- Um outro parâmetro presente é o v_{\max} , vinculado a um procedimento de limitação de velocidade para as partículas;
- Este procedimento impede que o algoritmo desenvolva valores de velocidades não pertinentes ao problema;
- Para quaisquer dimensões d do vetor v_i^k , tem-se:

$$-v_{\max} \leq v_i^k \leq v_{\max} \quad (5)$$

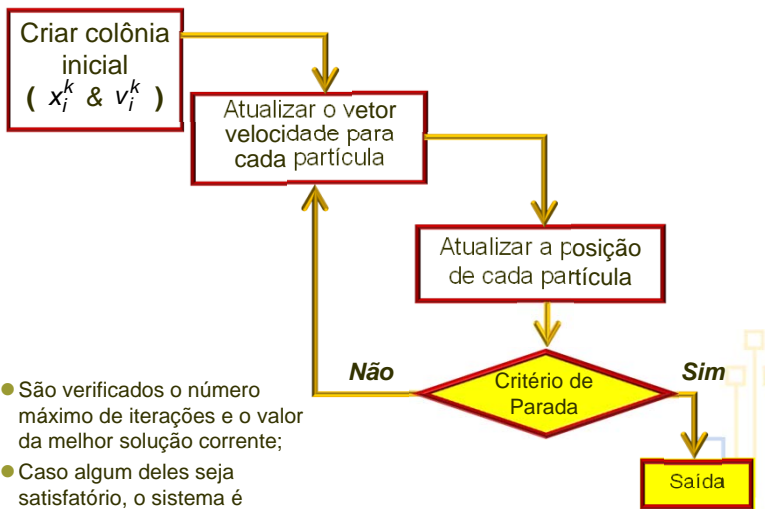
- Caso quaisquer das partículas do sistema desenvolva, em qualquer uma de suas dimensões, uma velocidade além de seus limites, este valor é automaticamente saturado, ou seja:

$$v_i^k = \begin{cases} -v_{\max}, & \text{se } v_i^k \leq -v_{\max} \\ v_{\max}, & \text{se } v_i^k \geq v_{\max} \end{cases} \quad (6)$$

15

3. Algoritmo de Métodos Swarm

Critério de parada



16

3. Algoritmo de Métodos Swarm

Pseudocódigo computacional

//Inicialização – Código em Pseudocódigo da Particle Swarm Optimization//

1. Inicialize aleatoriamente as posições x_i^k das partículas.
2. Inicialize aleatoriamente as velocidades v_i^k das partículas.
3. Inicialize $pbest_i$ e $gbest^k$

//Construção – loop principal//

4. Para cada partícula i , faça as seguintes instruções:

 //Atualiza a melhor posição da partícula atual $pbest_i$ //

 Se $x_i^k > pbest_i$ então

 Para cada dimensão d do problema faça $pbest_i = x_i^k$

 //Atualiza a melhor partícula//

 Para cada partícula vizinha, faça

 Se $pbest_i > gbest^k$ então $gbest^k = pbest_i$

 //Atualização das posições//

 Para cada dimensão d do problema faça

 Calcula v_i^{k+1} de acordo com a expressão (3).

 Verifique a condição de v_{max} dada em (5). Caso necessário, aplique a expressão (6).

5. Atualiza x_i^{k+1} de acordo com a equação (4).

//Condição de término//

6. Caso a condição de término não seja satisfeita, volte ao passo 4.


17

4. Exemplo Ilustrativo

Otimização não-linear de sistemas

$$f(x) = x \cdot \sin(10 \cdot \pi \cdot x) + 1$$

$$gbest^{100} = 1.8506$$
$$f(gbest^{100}) = 2.8502$$



18

5. Considerações Adicionais

Requisitos de aplicabilidade & tópicos promissores

● **Requisitos de aplicabilidade:**

- Conversão das possíveis soluções do problema a partir de sua representação por um vetor de **posições** e **velocidades**.
- Existência de um método para medir a qualidade (Função Objetivo) de uma solução potencial.

● **Tópicos de investigação promissores:**

- Sistemas híbridos.
- Otimização multi-objetivo.
- Aspectos de convergência, escalabilidade e análise de complexidade.
- Auto-adaptação dos seus parâmetros internos.



19

Fim da Apresentação



20