

# Análise Comparativa de Técnica de Busca Padrão Combinada com Otimização por Enxame de Partículas e Estratégias Evolutivas

Viviane de J. Galvão, Heder S. Bernardino  
vivianegalvao@ice.ufjf.br, heder@ice.ufjf.br

## Introdução

O objetivo dessa pesquisa é analisar métodos de otimização em espaço de busca contínuo, no entanto, sem acesso à forma analítica das funções que se quer otimizar. Técnicas com essa característica são importantes pois esse tipo de problema aparece frequentemente em aplicações práticas, por exemplo nas engenharias. Será estudado aqui o método de busca padrão direcional combinado tanto com Otimização por enxame de partículas quanto com Estratégias Evolutivas. Experimentos computacionais são utilizados para analisar as técnicas estudadas.

## Busca Padrão Direcional

Busca Padrão Direcional[1] é um método de busca local que não requer cálculos nem valor das derivadas, o qual opera através de **movimentos exploratórios** para se movimentar à solução.

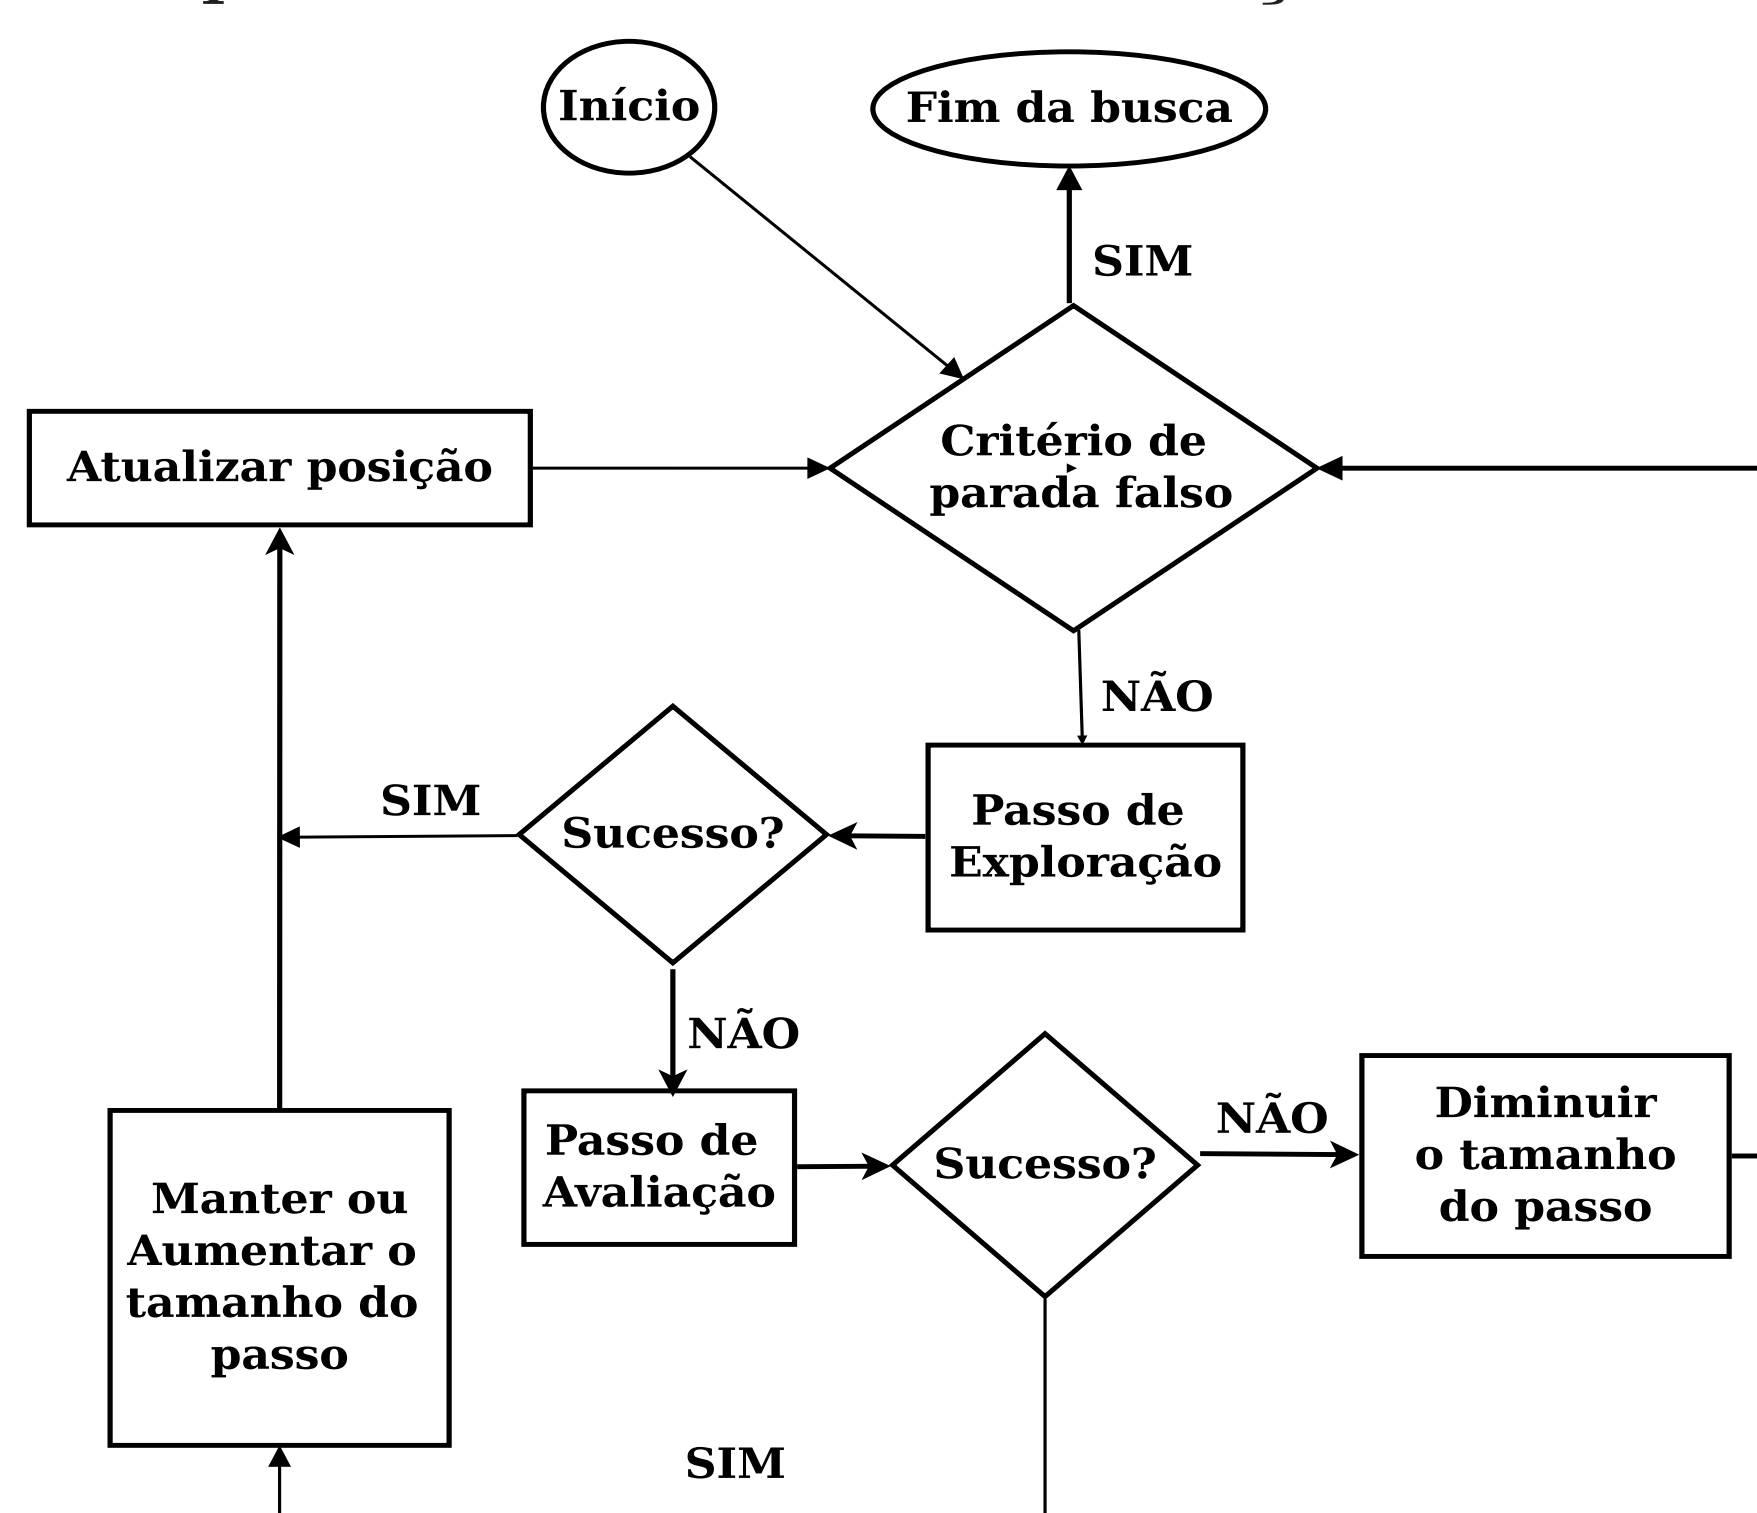


Figura 1: Fluxograma - Busca Padrão

- **Passo de Exploração:** Se  $\exists x \in \mathbb{R}^n$  tal que  $f(x) < f(x_k)$ , então  $x_{k+1} = x$  e não é necessário passar pelo passo de avaliação. Pode ser feito com auxílio de uma heurística externa;
- **Passo de Avaliação:** Seja  $G_k$  o conjunto de bases positivas geradoras do  $\mathbb{R}^n$  e um conjunto  $P_k = \{x_k + \alpha * d\} \mid d \in G_k$ . Se  $\exists x \in P_k$  tal que  $f(x) < f(x_k)$ , então  $x_{k+1} = x$  e  $\alpha_{k+1} = \gamma \alpha_k, \forall \gamma \geq 1$ ; senão,  $x_{k+1} = x_k$  e  $\alpha_{k+1} = \beta \alpha_k, \forall \beta < 1$ .

## Estratégias Evolutivas

Baseado no modelo biológico de processos de adaptação e evolução de espécies, tem-se uma população de  $n$  indivíduos sujeitos à **mutação** e **seleção**, onde os indivíduos mais aptos tem mais chance de sobreviver. Cada indivíduo representa uma possível solução com a seguinte estrutura:  $(x, \sigma)$ , onde  $x$  é uma **solução candidata** e  $\sigma$  é o seu **desvio padrão**[4]

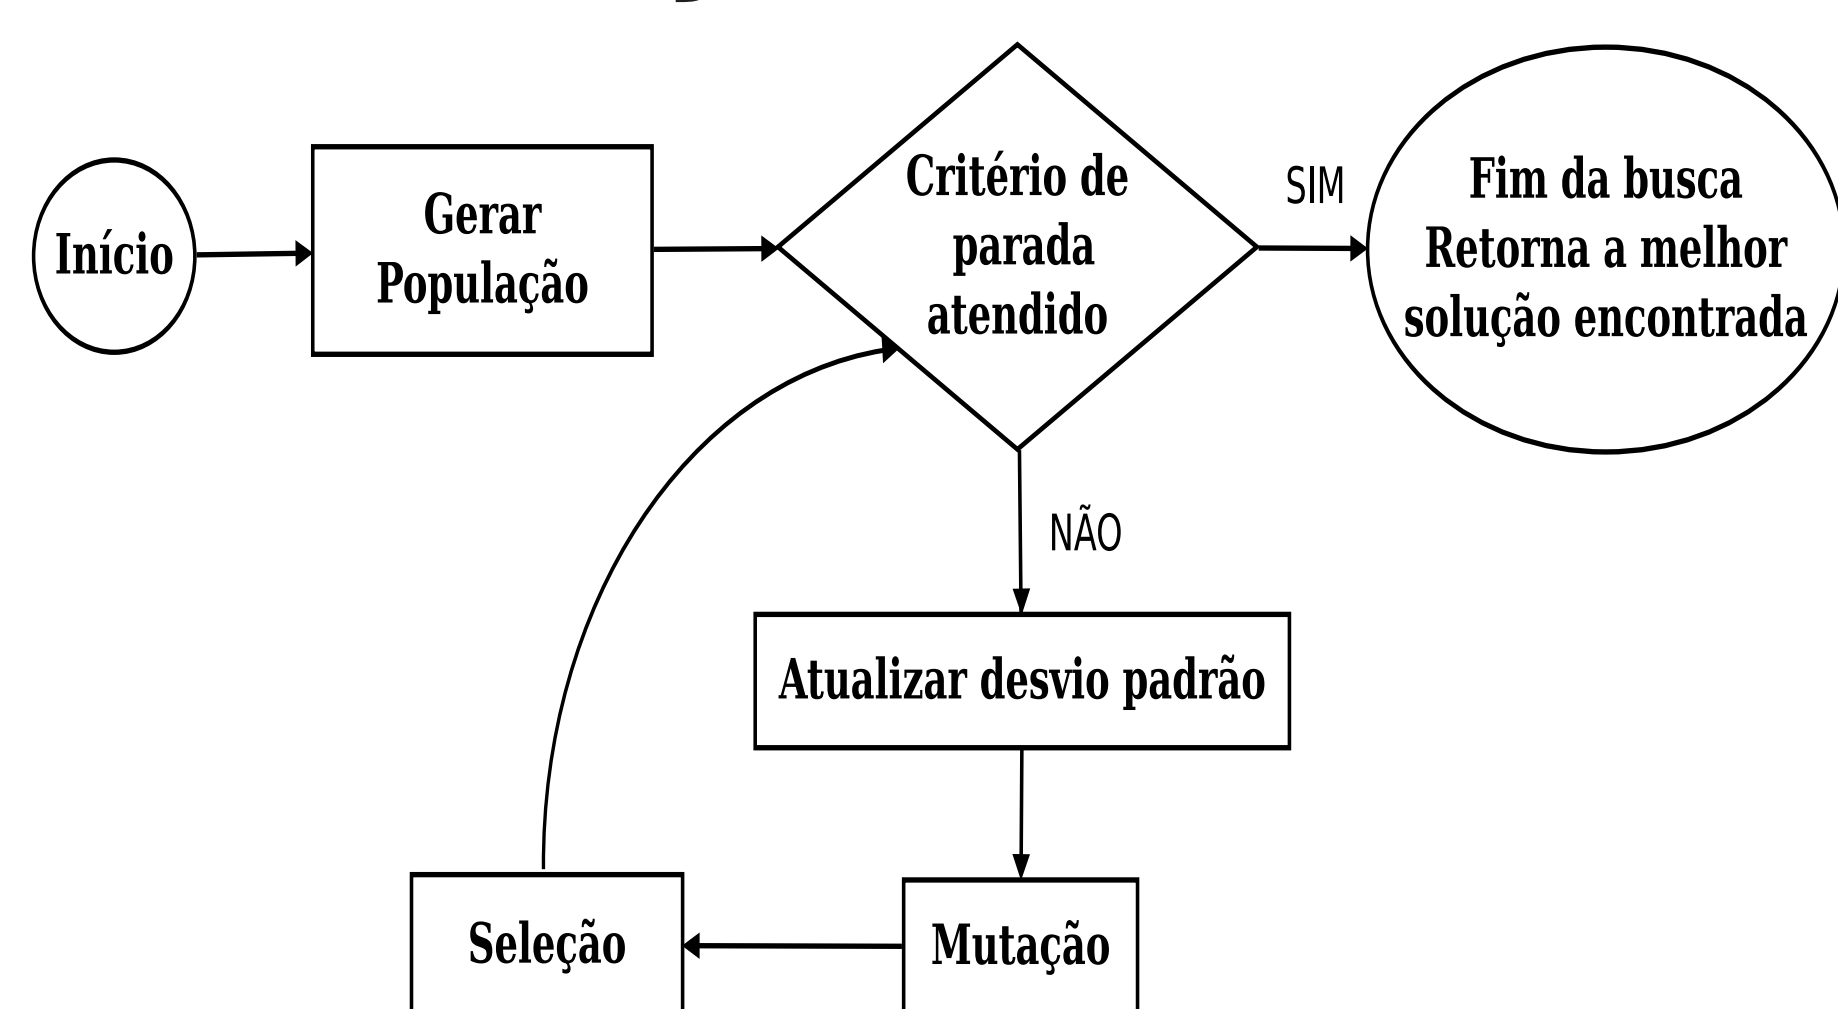


Figura 2: Fluxograma - Estratégia Evolutiva

- A atualização da solução candidata:  $x_{k+1} = x_k + \mathcal{N}(0, \sigma)$  ;
- A atualização isotrópica do desvio padrão pode ser feita através:  $\sigma_{k+1} = \sigma_k * exp(\mathcal{N}(0, 1/\sqrt{n}))$ ;

## Otimização por Enxame de Partículas

Inspirado no comportamento social de peixes e pássaros, faz a simulação dos mecanismos de inteligência coletiva, afim de encontrar uma solução para o problema. No contexto, existe uma população de  $n$  partículas, onde cada partícula tem sua **velocidade**  $v$  e sua **posição**  $x$ , sofre influência tanto de fatores locais quanto de fatores globais[3].

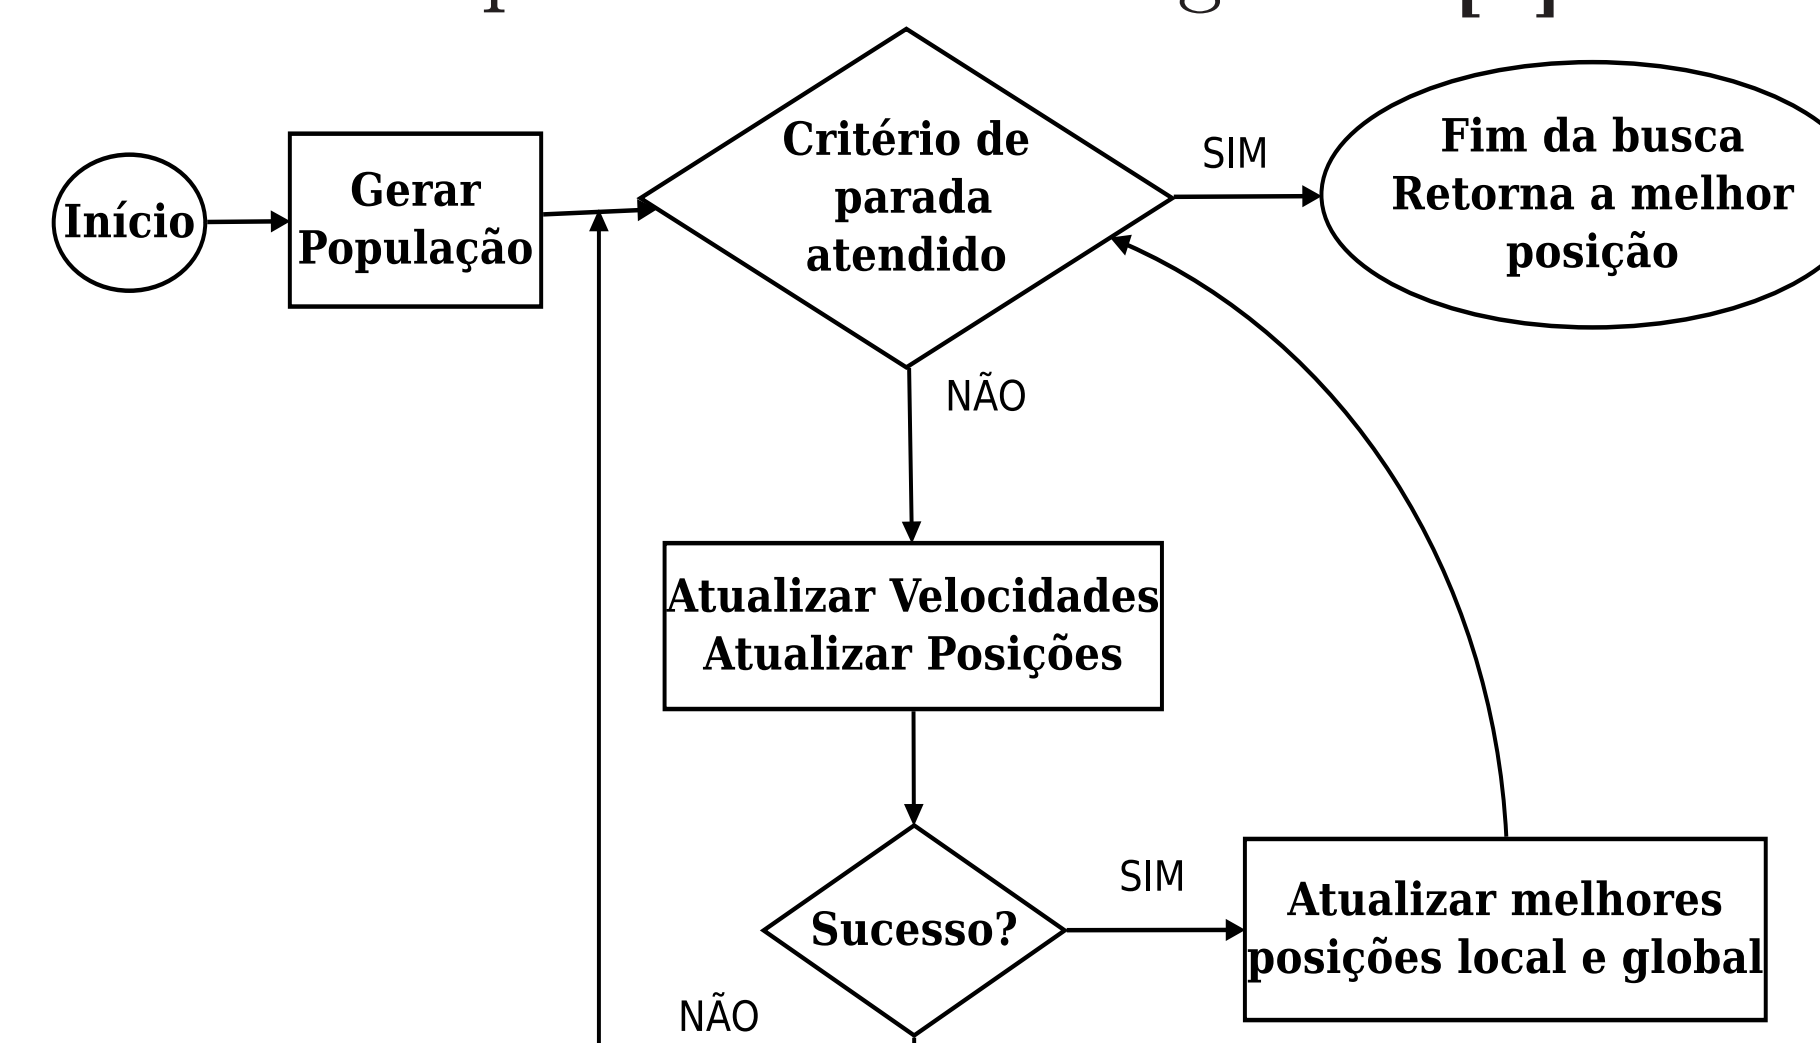


Figura 3: Fluxograma - PSO

- **Atualização da velocidade:**

$$v(t+1) = \delta v(t) + \mu \omega_1(t)(x_{local}(t) - x(t)) + \psi \omega_2(t)(x_{global}(t) - x(t))$$

–  $\delta$  é um fator de inércia da partícula,  $\mu > 0$  é um parâmetro de cognição,  $\psi > 0$  é um parâmetro social,  $\omega_1$  e  $\omega_2$  são números aleatoriamente entre  $(0, 1)$ .

- **Atualização da posição:**  $x(t+1) = x(t) + v(t)$  ;

## Experimentos Computacionais

- As técnicas foram aplicadas aos problemas  $f_{02}$ ,  $f_{03}$ ,  $f_{12}$  e  $f_{13}$  de [2];
- $f_{02}$  e  $f_{03}$  são funções unimodais, enquanto que  $f_{12}$  e  $f_{13}$  são multimodais;
- Busca Padrão Direcional:  $\alpha_{inicial}=0.7, \gamma=1.5, \beta=0.5, \alpha_{min}=10^{-5}$ ;
- Estratégias Evolutivas:  $\mu = 4$  progenitores,  $\lambda = 8$  descendentes;
- Enxame de Partículas:  $\delta = 0.9, \mu = \psi = 0.5, n = 50$ ;

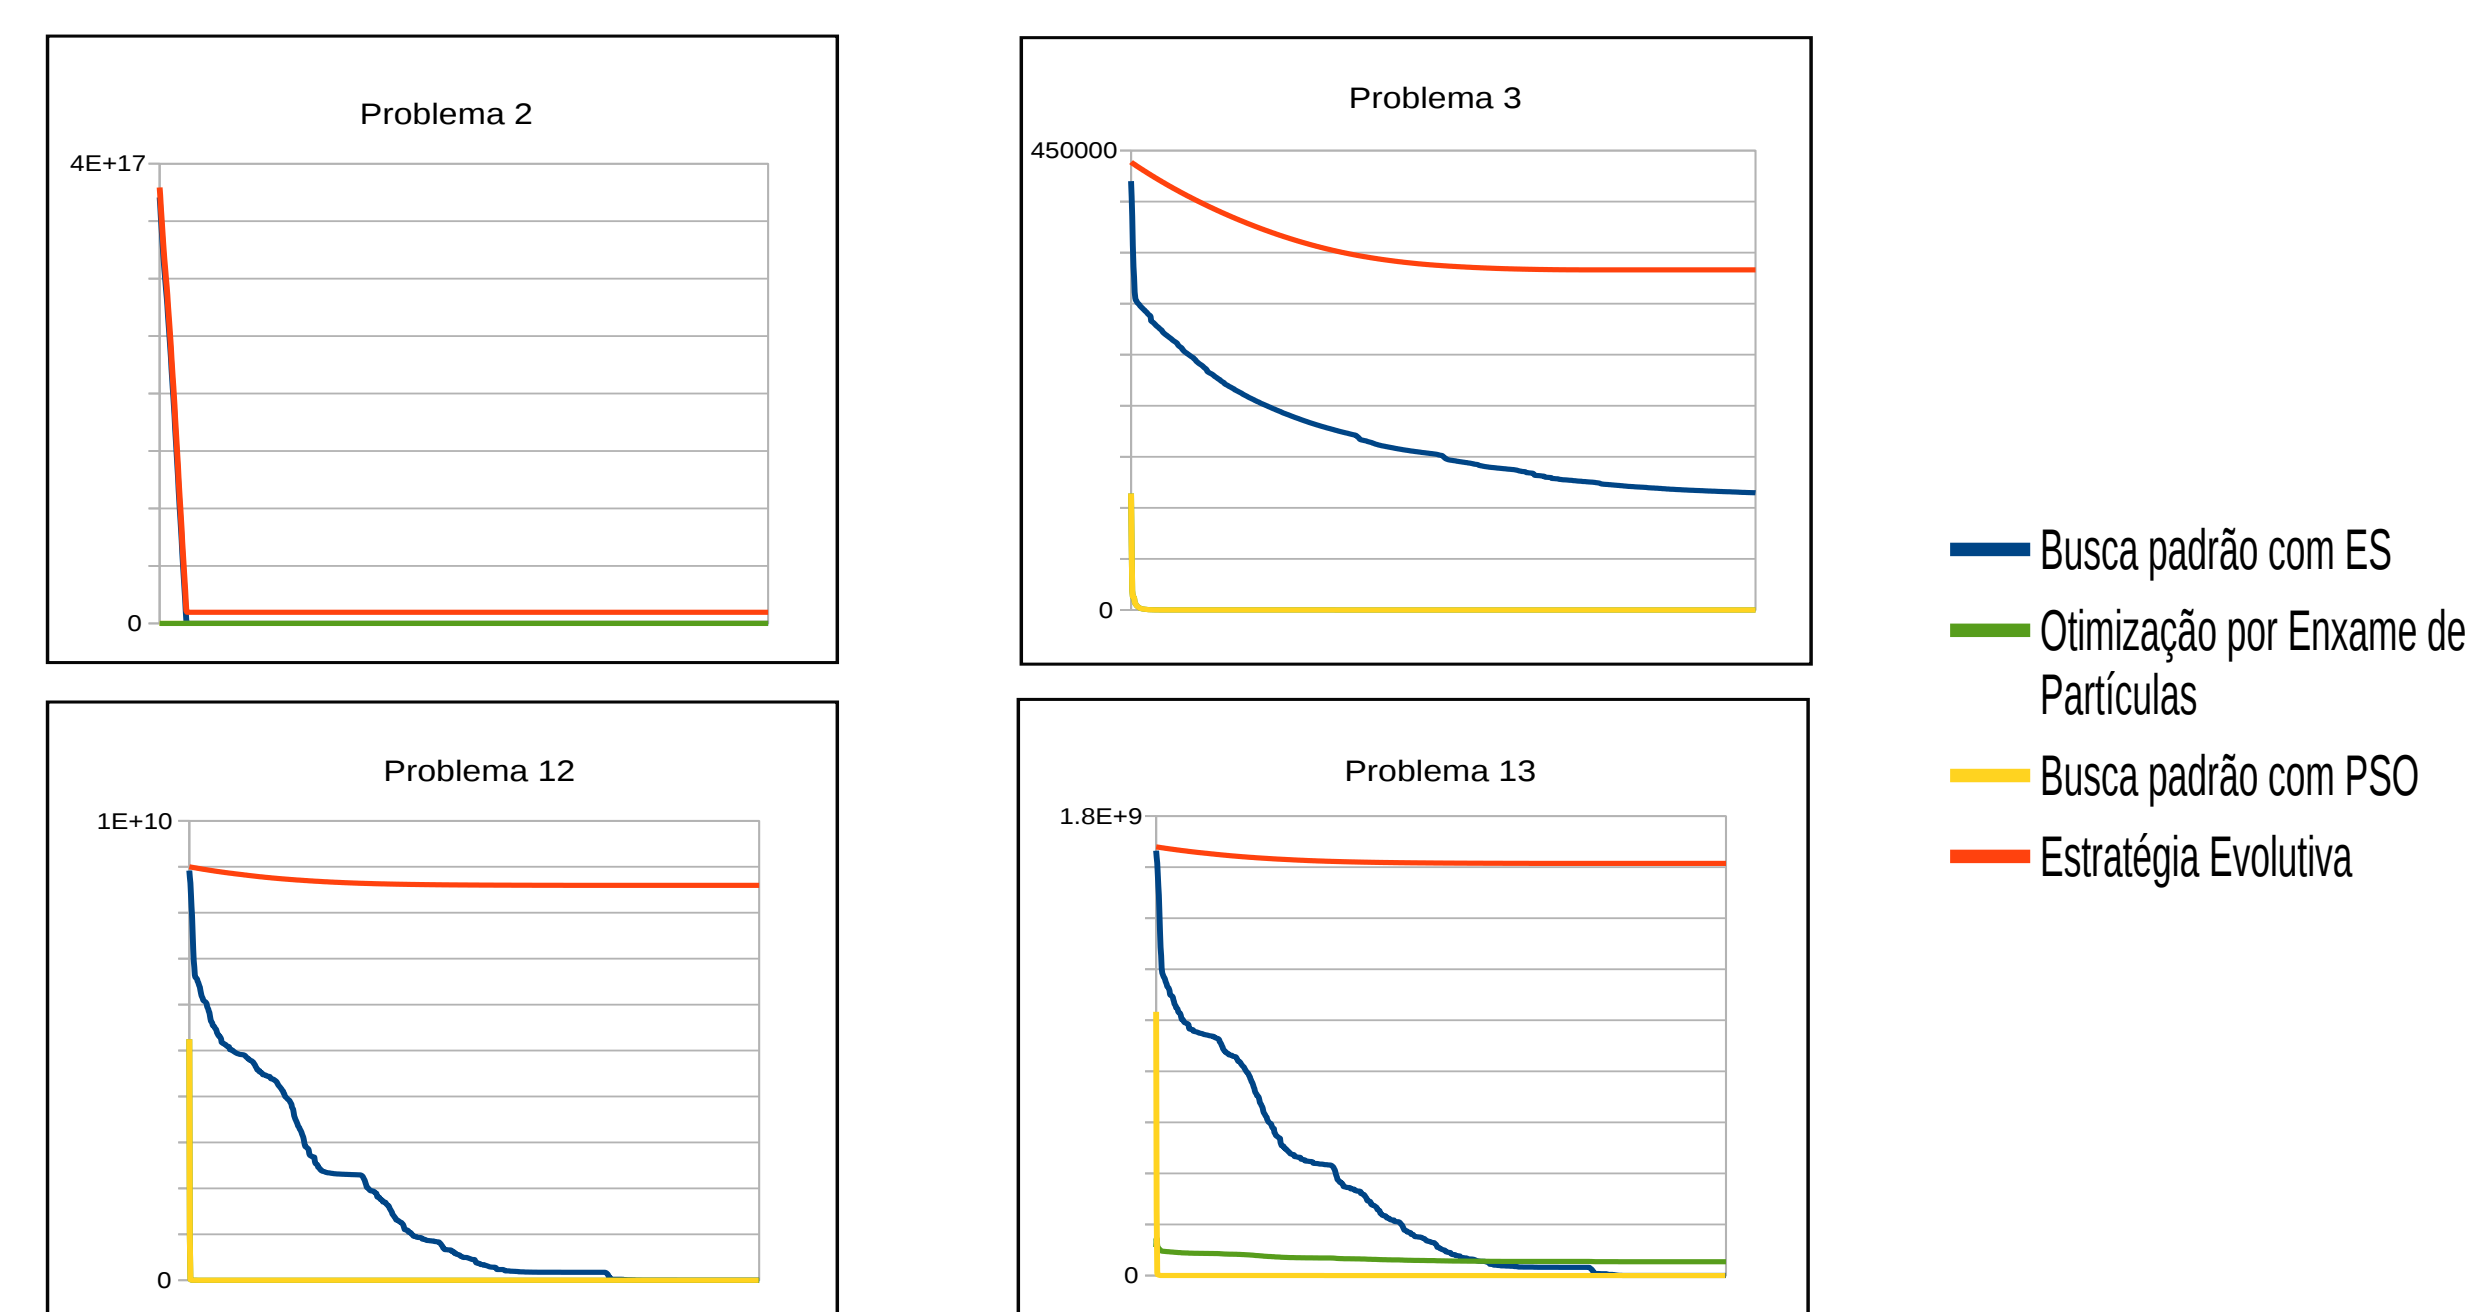


Figura 4: Média das 30 execuções independentes para cada método

## Conclusão e Trabalhos Futuros

- Há uma melhora significativa com a utilização da busca padrão em relação aos métodos estocásticos puros;
- O Enxame de Partículas apresentou melhor convergência do que a Estratégia Evolutiva adotada aqui;
- Ainda assim, boa parte das iterações fica concentrada no passo exploratório na busca padrão;
- Em trabalhos futuros, planeja-se resolver problemas de otimização com restrições utilizando penalização adaptativa e aplicar métodos desenvolvidos em problemas de engenharia estrutural.

## Referências

- [1] Conn, A. R., Scheinberg, K., Vicente, L. N., 2009. Introduction to Derivative-Free Optimization. Society for Industrial and Applied Mathematics
- [2] Heder S. Bernardino, Helio J. C. Barbosa, Leonardo G. Fonseca, 2011. Surrogate-assisted clonal selection algorithms for expensive optimization problems. Journal Evolutionary Intelligence, Springer
- [3] A.I.F. Vaz, L.N. Vicente, 2009. PSwarm: A hybrid solver for linearly constrained global derivative-free optimization. Optimization Methods and Software
- [4] Coordenadores: Antônio Gaspar-Cunha, Ricardo Takahashi, Carlos Henggeler Antunes, 2013. Manual de Computação Evolutiva e Metaheurística