



Estratégias Evolutivas

Sumário

- Introdução
 - Histórico
 - Características
- Pseudocódigo
- Componentes
 - Operandos
 - Operadores
- Aperfeiçoamentos
- Considerações finais e Conclusões
- Conferências, workshops e livros

Histórico

- É uma subclasse dos algoritmos evolutivos inspirado na biologia evolutiva
 - Mutação;
 - Seleção natural;
 - Recombinação.
- Baseada na teoria da seleção natural de Darwin.
 - Os indivíduos mais aptos são mais capazes de sobreviver e reproduzir.
 - Mutações aleatórias sobre os indivíduos geralmente acontece.
- Inicialmente proposta por Rechenberg, Schwefel e Peter Bienert na Universidade Técnica de Berlim por volta de 1964.
 - otimização em mecânica de fluidos
 - problemas de otimização de funções de forma mais genérica
 - Os primeiros algoritmos de estratégia evolutiva operavam com um único indivíduo na população, sujeito à mutação e seleção.

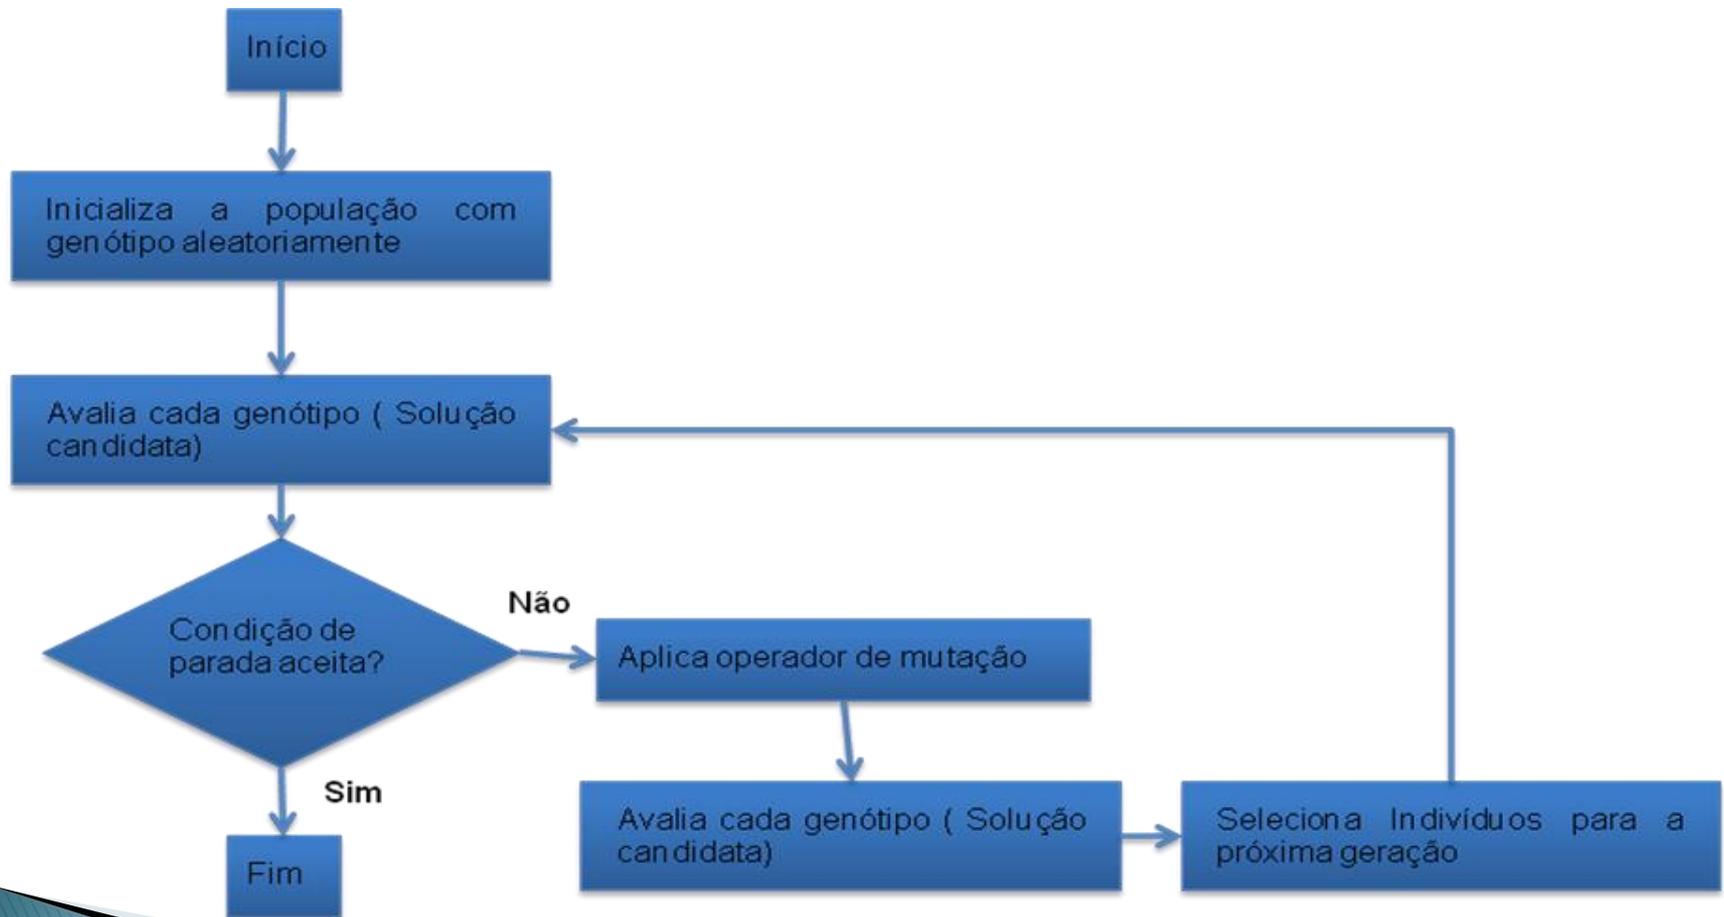
Características

- ▶ Auto adaptação de parâmetros da estratégia
EX: (taxas de mutação, desvios padrões das mutações, probabilidades de recombinação)
- ▶ Em relação à evoluções dos operandos.
- ▶ Um aspecto negativo observado é a convergência lenta.

Sumário

- Introdução
 - Motivação
 - Características
- **Pseudocódigo**
- Componentes
 - Operandos
 - Operadores
- Aperfeiçoamentos
- Considerações finais e Conclusões
- Conferências, workshops e livros

Pseudocódigo



Pseudocódigo

```
Set the generation counter,  $t = 0$ ;  
Initialize the strategy parameters;  
Create and initialize the population,  $C(0)$ , of  $\mu$  individuals;  
For each individual,  $X_i(t) \in C(t)$  do  
    Evaluate the fitness,  $f(X_i(t))$ ;  
End  
While stopping condition(s) not true do  
    For  $i = 1, \dots, \lambda$  do  
        Choose  $p \geq 2$  parents at random;  
        Create offspring through application of crossover operator on parent  
            genotypes and strategy parameters;  
        Mutate offspring strategy parameters and genotype;  
        Evaluate the fitness of the offspring;  
    End  
    Select the new population,  $C(t+1)$ ;  
     $t = t + 1$ ;  
End
```

Pseudocódigo

```
Set the generation counter,  $t = 0$ ;  
Initialize the strategy parameters;  
Create and initialize the population,  $C(0)$ , of  $\mu$  individuals;  
For each individual,  $X_i(t) \in C(t)$  do  
    Evaluate the fitness,  $f(X_i(t))$ ;  
End  
While stopping condition(s) not true do  
    For  $i = 1, \dots, \lambda$  do  
        Choose  $p \geq 2$  parents at random;  
        Create offspring through application of crossover operator on parent  
        genotypes and strategy parameters;  
        Mutate offspring strategy parameters and genotype;  
        Evaluate the fitness of the offspring;  
    End  
    Select the new population,  $C(t+1)$ ;  
     $t = t + 1$ ;  
End
```

Pseudocódigo

Estratégia Evolutiva

```
Set the generation counter,  $t = 0$ ;  
Initialize the strategy parameters;  
Create and initialize the population,  $C(0)$ , of  $\mu$  individuals;  
For each individual,  $X_i(t) \in C(t)$  do  
    Evaluate the fitness,  $f(X_i(t))$ ;  
End  
While stopping condition(s) not true do  
    For  $i = 1, \dots, \lambda$  do  
        -Choose  $p \geq 2$  parents at random;  
        -Create offspring through application of  
            crossover operator on parent  
            genotypes and strategy parameters;  
        -Mutate offspring strategy parameters and  
            genotype;  
        -Evaluate the fitness of the offspring;  
    End  
    Select the new population,  $C(t+1)$ ;  
     $t = t + 1$ ;  
End
```

Algoritmo Genético

```
inicializar a população  
aleatoriamente;  
while critério não for atendido do  
    for each Individuo do  
        -avaliar a função de fitness;  
        -selecionar os “pais” para a  
            reprodução;  
        -produzir novos indivíduos  
            (crossover e mutação)  
        -avaliar a aptidão de novos  
            indivíduos;  
        -reconstruir a população;  
    endForeach  
endWhile
```

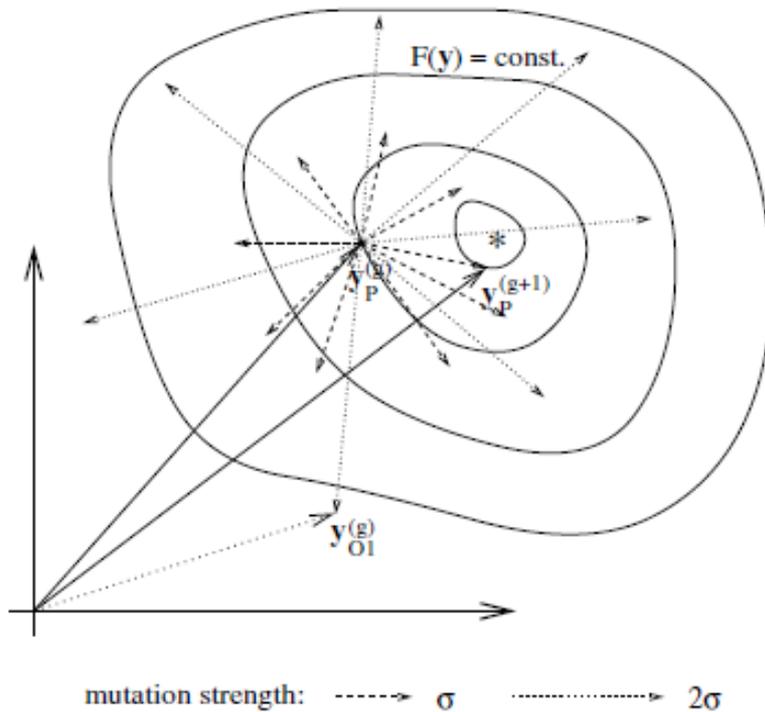
Sumário

- Introdução
 - Motivação
 - Características
- Pseudocódigo
- **Componentes**
 - Operandos
 - Operadores
- Aperfeiçoamentos
- Considerações finais e Conclusões
- Conferências, workshops e livros

Operandos

- ▶ As estruturas de dados correspondem aos vetores de pontos (candidatos a solução) no espaço de busca.
- ▶ Indivíduo: $v = (x, \sigma, \theta) \rightarrow (x[], \sigma[], \theta[])$
 - x vetor de atributo.
 - σ vetor de desvios padrões (“coeficiente de mutação”)
 - θ vetor de Ângulos de Rotação
- ▶ Normalmente são atribuído valores reais.

Auto-Adaptação: Motivação



$x[1, 5]$
 $\sigma[2, 3]$
 $\theta[3, 2]$

Inicialização

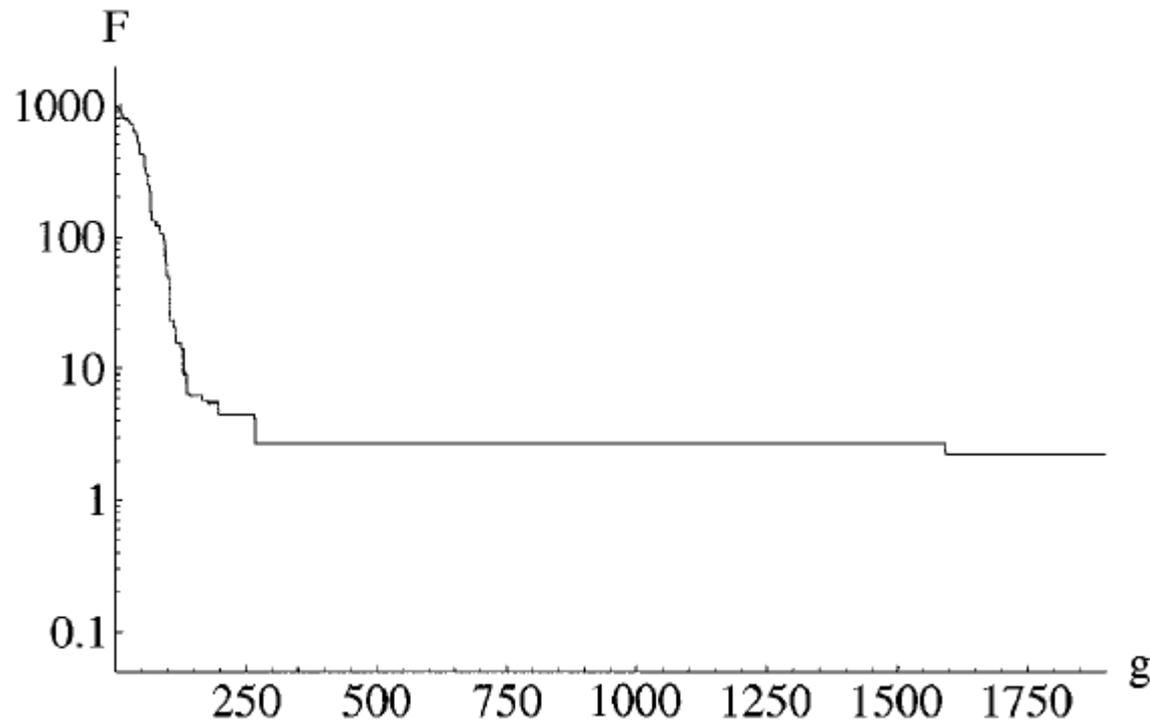
- ▶ A consiste em atribuir valores aleatórios Individuo.
- ▶ Inicialização dos **parâmetros de estratégia**.

Auto-Adaptação

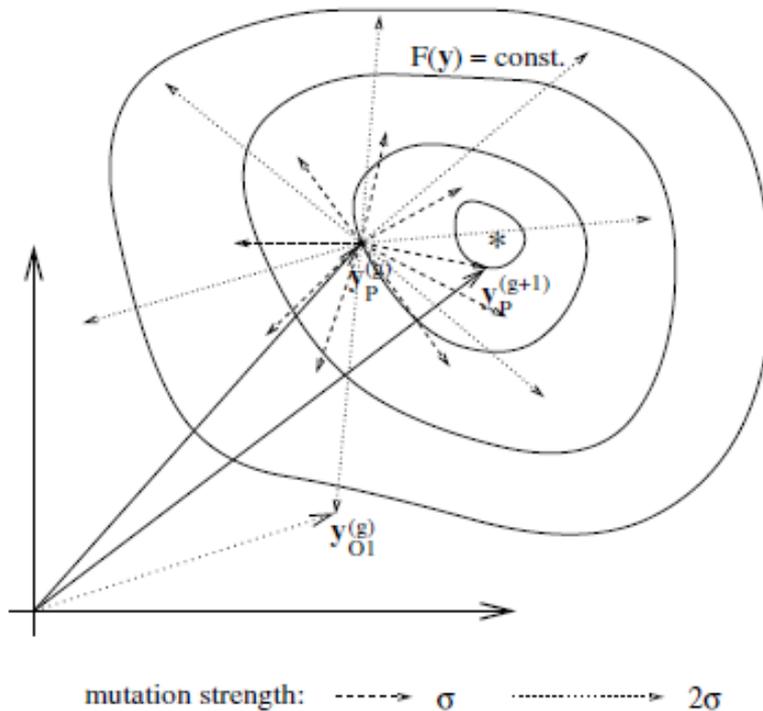
- ▶ Adaptação consiste na evolução dos parâmetros da estratégia.
- ▶ EX:
 - $v = (x, \sigma, \alpha)$ [vetor de característica x , conjuntos σ e α de parâmetros da estratégia (recombinação e mutação)].
 - Aplica (recombinação e mutação) em σ e α , resultando em σ' e α' .
 - Depois utiliza σ' e α' nos atributos de x , resultando em x' .

Auto-Adaptação: Motivação

- ▶ (1 + 1) ES (distribuição normal e σ constante)



Auto-Adaptação: Motivação

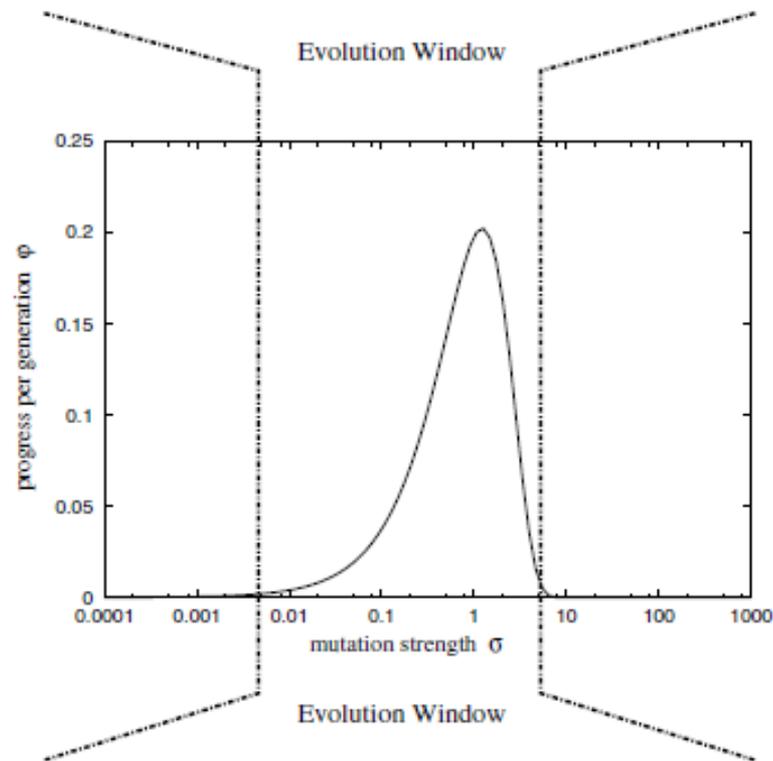


σ → taxa de mutação
 P_s → probabilidade de sucesso
 φ → taxa de progresso

$\sigma \rightarrow 0 : P_s \rightarrow 1/2$, but $\varphi \rightarrow 0$
 $\sigma \rightarrow \infty : P_s \rightarrow 0$ and $\varphi \rightarrow 0$

Auto-Adaptação: Motivação

- ▶ Evolution-Window
 - Proposta por Rechenberg



Auto-Adaptação: 1 / 5th rule

- ▶ Proposto por *Rechenberg (1975)*
- ▶ *“In order to obtain nearly optimal (local) performance of the (1+1)-ES in real-valued search spaces, tune the mutation strength in such a way that the (measured) success rate is about 1/5.”*

$$\sigma = \begin{cases} \sigma / c, & P_s > 1/5 \\ \sigma * c, & P_s < 1/5 \\ \sigma, & P_s = 1/5 \end{cases}$$

- ▶ P_s – porcentagem de sucesso das mutações
- ▶ $0.8 \leq c \leq 1$

MUITO ESPECÍFICO!

Auto-Adaptação

- ▶ Introduzido em ES
- ▶ Evolução dos **parâmetros estratégicos** juntamente com parâmetros de estrutura de dados
- ▶ Parâmetros estratégicos também são sujeitos à seleção e à herança
- ▶ Resultados experimentais:
 - Valores σ devem decrescer ao longo das gerações
 - Reajuste automático de σ para funções objetivo dinâmicas

Auto-Adaptação

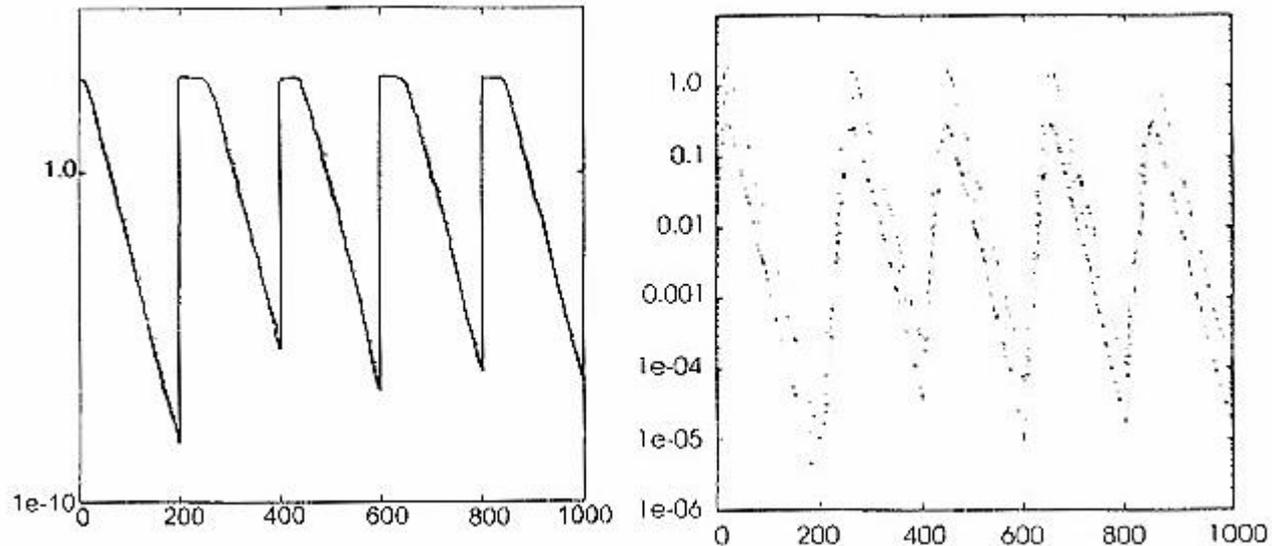


Fig. Experimento com Função esférica de ótimo dinâmico. Valor ótimo é alterado a cada 200 gerações(eixo-x). O melhor *fitness* da população é refletido no (eixo-y, esquerda). *Step sizes* no (eixo-y, direita).

Operadores

- ▶ SELEÇÃO
- ▶ RECOMBINAÇÃO
- ▶ MUTAÇÃO

Seleção

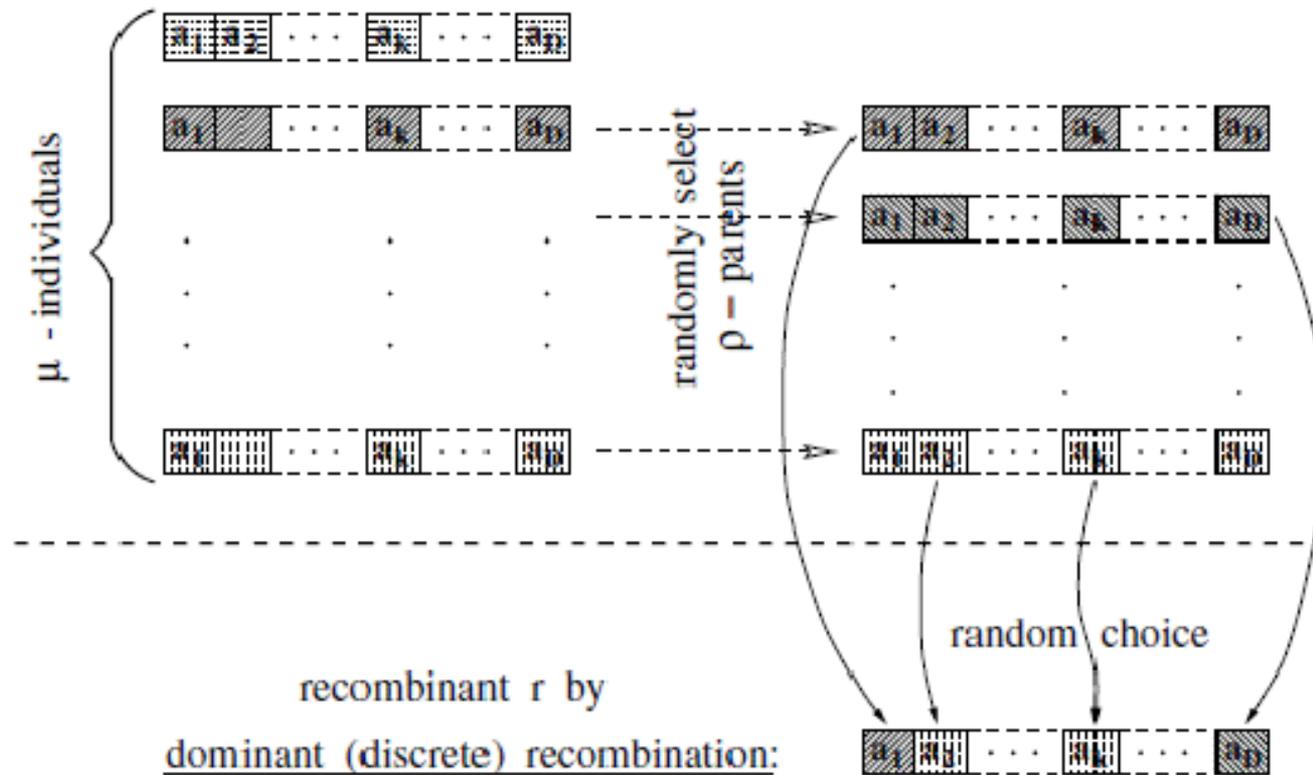
- ▶ Utilizada em dois momentos
- ▶ Aleatoriedade na escolha dos pais
- ▶ Duas estratégias principais foram desenvolvidas para selecionar indivíduos da próxima geração:
 - $> (\mu + \lambda)$ – ES: plus strategies;
 - $> (\mu, \lambda)$ – ES: comma strategies;
- ▶ Extensão da plus strategies: (μ, κ, λ) , onde κ = lifespan

Recombinação

- ▶ Quantidade de pais:
 - Crossover local
 - Crossover global

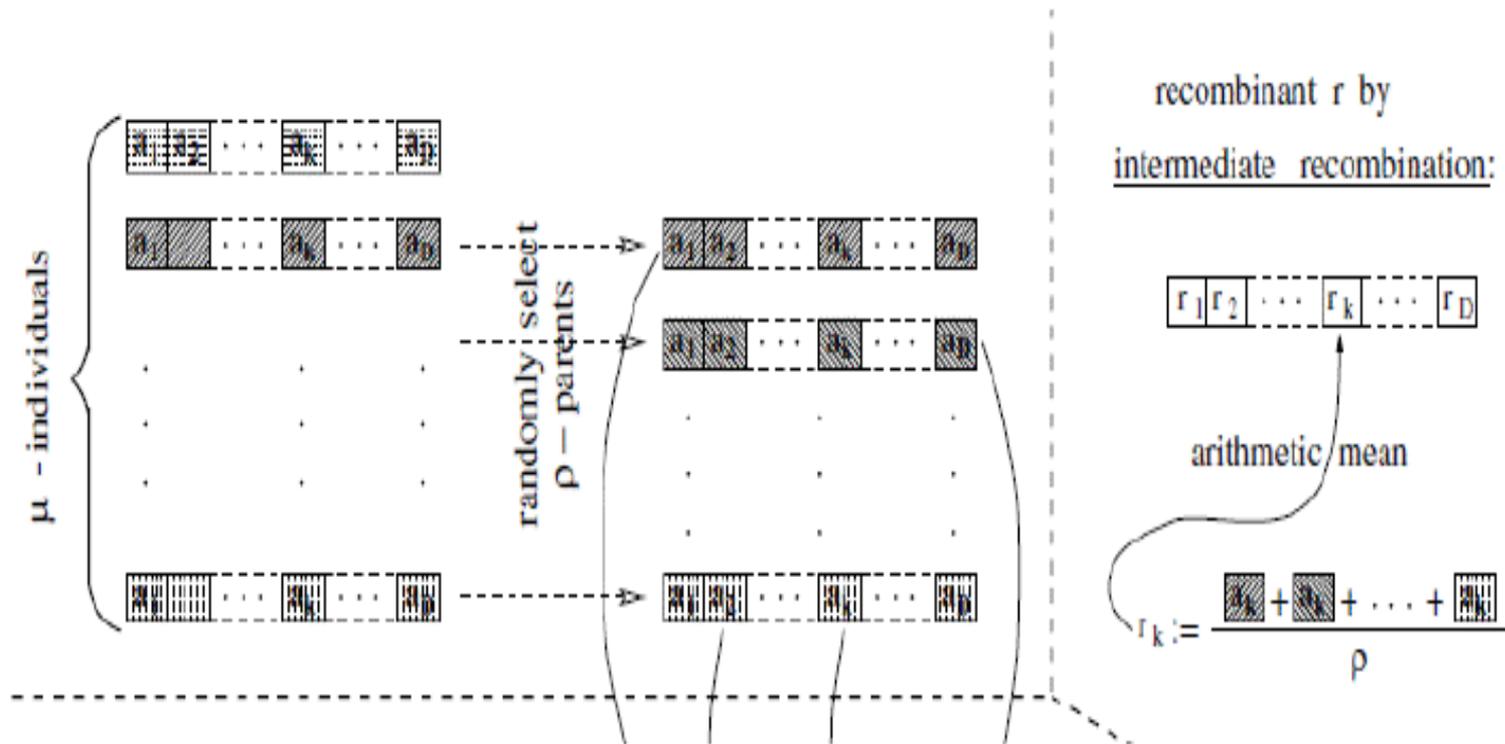
Recombinação

▶ Recombinação discreta



Recombinação

▶ Recombinação intermediária



Mutação

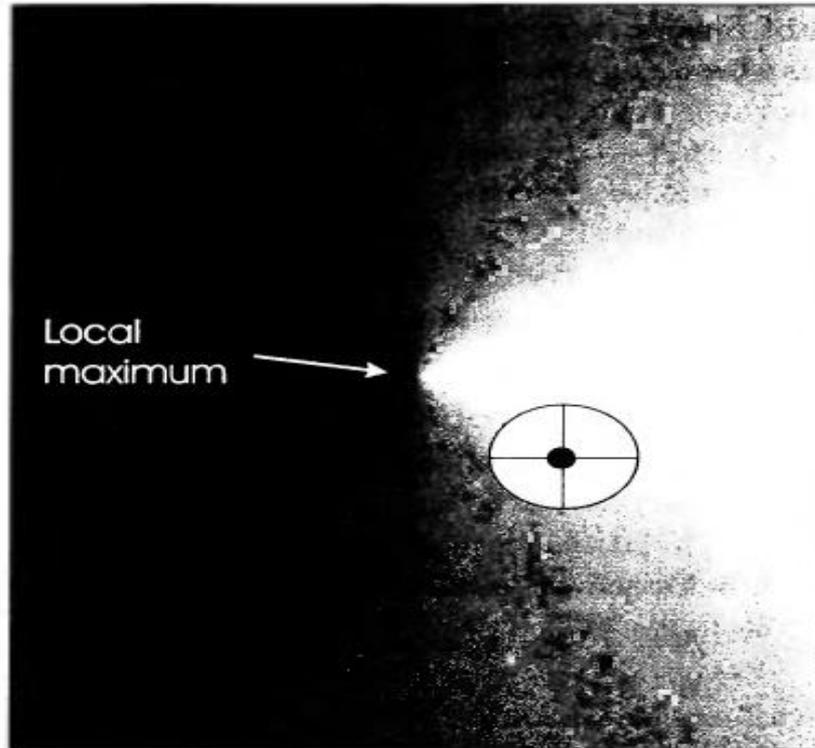
- ▶ Considerações teóricas:
 - Reachability
 - Unbiasedness
 - Scalability
- ▶ Mutação gaussiana
- ▶ Novo valor do gene:
 - $x' = x + N(0, \sigma)$

Mutação

- ▶ σ também sofre mutação e evolui junto com a solução x (auto-adaptação)
- ▶ Ordem dos eventos:
 - 1) evolução dos parâmetros do indivíduo: $\sigma \rightarrow \sigma'$
 - 2) evolução das variáveis objeto: $x \rightarrow x' = x + N(0, \sigma')$

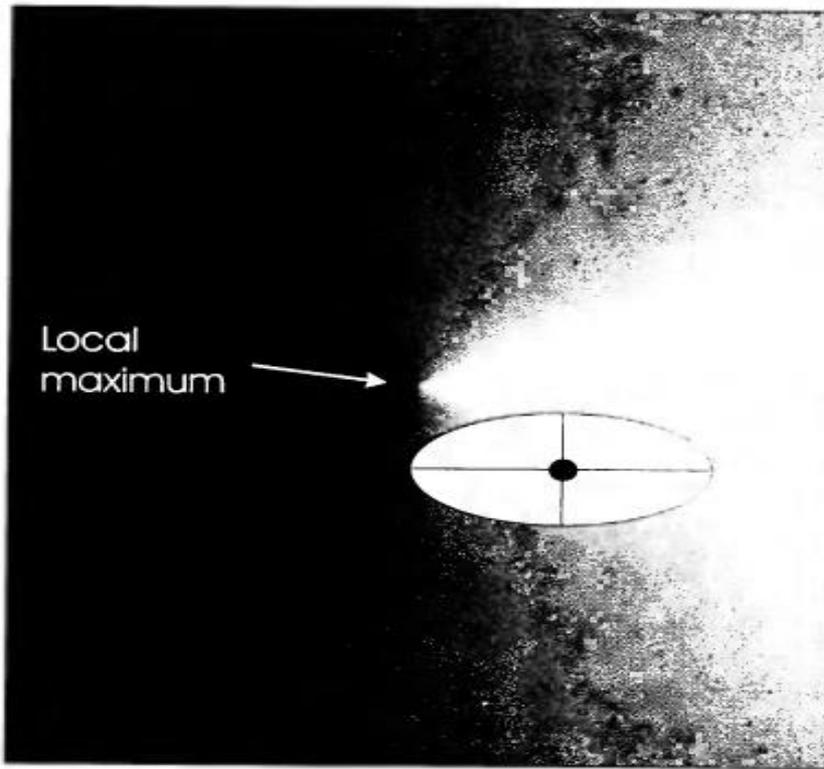
Mutação

- ▶ Variações do operador de mutação:
- ▶ mutação com um único step-size:
 - $I = \langle x_1, \dots, x_n, \sigma \rangle$



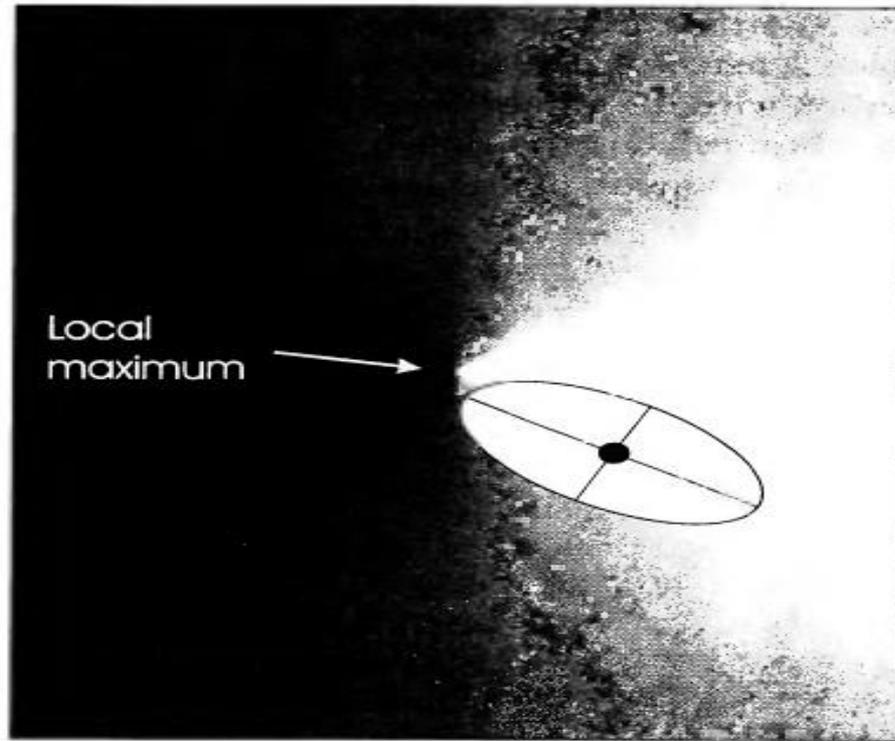
Mutação

- ▶ Mutação com n step sizes:
 - $I = \langle x_1, \dots, x_n, \sigma_1, \dots, \sigma_n \rangle$



Mutação

- ▶ Mutação correlacionada:
 - $I = \langle x_1, \dots, x_n, \sigma_1, \dots, \sigma_n, \alpha_1, \dots, \alpha_k \rangle$



Sumário

- Introdução
 - Motivação
 - Características
- Pseudocódigo
- Componentes
 - Operandos
 - Operadores
- **Aperfeiçoamentos**
- Considerações finais e Conclusões
- Conferências, workshops e livros

Aperfeiçoamentos: CMA-ES

Input: $m \in \mathbb{R}^n$, $\sigma \in \mathbb{R}_+$, λ

Initialize: $C = I$, and $p_c = \mathbf{0}$, $p_\sigma = \mathbf{0}$,

Set: $c_c \approx 4/n$, $c_\sigma \approx 4/n$, $c_1 \approx 2/n^2$, $c_\mu \approx \mu_w/n^2$, $c_1 + c_\mu \leq 1$, $d_\sigma \approx 1 + \sqrt{\frac{\mu_w}{n}}$,
and $w_{i=1\dots\lambda}$ such that $\mu_w = \frac{1}{\sum_{i=1}^\mu w_i^2} \approx 0.3 \lambda$

While not terminate

$$x_i = m + \sigma y_i, \quad y_i \sim \mathcal{N}_i(\mathbf{0}, C), \quad \text{for } i = 1, \dots, \lambda$$

sampling

$$m \leftarrow \sum_{i=1}^\mu w_i x_{i:\lambda} = m + \sigma y_w \quad \text{where } y_w = \sum_{i=1}^\mu w_i y_{i:\lambda}$$

update mean

$$p_c \leftarrow (1 - c_c) p_c + \mathbb{1}_{\{\|p_\sigma\| < 1.5\sqrt{n}\}} \sqrt{1 - (1 - c_c)^2} \sqrt{\mu_w} y_w$$

cumulation for C

$$p_\sigma \leftarrow (1 - c_\sigma) p_\sigma + \sqrt{1 - (1 - c_\sigma)^2} \sqrt{\mu_w} C^{-\frac{1}{2}} y_w$$

cumulation for σ

$$C \leftarrow (1 - c_1 - c_\mu) C + c_1 p_c p_c^T + c_\mu \sum_{i=1}^\mu w_i y_{i:\lambda} y_{i:\lambda}^T$$

update C

$$\sigma \leftarrow \sigma \times \exp\left(\frac{c_\sigma}{d_\sigma} \left(\frac{\|p_\sigma\|}{\mathbb{E}\|\mathcal{N}(\mathbf{0}, I)\|} - 1\right)\right)$$

update of σ

Sumário

- Introdução
 - Motivação
 - Características
- Pseudocódigo
- Componentes
 - Operandos
 - Operadores
- Aperfeiçoamentos
- **Considerações finais e Conclusões**
- Conferências, workshops e livros

Paralelo entre GA e ES

	Genetic Algorithm	Evolution Strategies
Foco	Crossover	Mutação
Ordem de operadores	Seleção, recombinação e mutação	Recombinação, mutação e seleção
Parâmetros de variação genética	Constante ao longo das gerações	Alteração de σ e α . Sofrem mutação e recombinação (auto-adaptação)
Indivíduos	Vetores com representação simbólica	Vetores de números reais

Aplicações

- ▶ Sistemas automobilísticos
- ▶ Problemas hidrodinâmicos
- ▶ Processamento de Imagens e Visão computacional
- ▶ Otimização de parâmetros
- ▶ Segurança de computadores
- ▶ Treinamento de Redes Neurais

Conclusão

- ▶ Auto-adaptação caracteriza a técnica
- ▶ Utiliza vetores com valores reais
- ▶ Viabiliza a combinação de estratégias de seleção, mutação e crossover para adaptar ao problema
- ▶ Dependendo da estratégia utilizada, a convergência pode ser lenta ou prematura.

Referências

- ▶ Adaptado de A.E. Eiben and J.E. Smith, *Introduction to Evolutionary Computing* Capítulo: *Evolution Strategies*. (2003)
- ▶ Engelbrecht. *Computational Intelligence: an introduction*. Capítulo: *Evolution Strategies*. (2007)
- ▶ Beyer and Schwefel. *Evolution strategies: A comprehensive introduction..*(2002)
- ▶ Nikolaus Hansen. *The CMA Evolution Strategy: A Tutorial*. (2011)
- ▶ Anne Auger & Nikolaus Hansen. *Tutorial: CMA-ES — Evolution Strategies and Covariance Matrix Adaptation*. (2011)
- ▶ Dianati, Song e Treiber. *An Introduction to Genetic Algorithms and Evolution Strategies*.
- ▶ IA707 – Profs. Leandro de Castro/Fernando Von Zuben DCA/FEEC/Unicamp