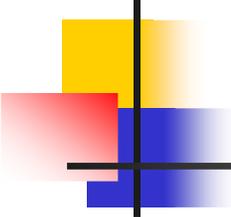


# Computação Evolutiva

---

Aula 16 – Estratégias Evolutivas  
(Parte III)

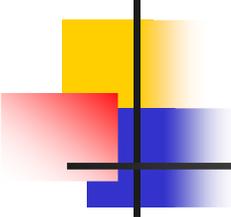
Prof. Tiago A. E. Ferreira



# Roteiro

---

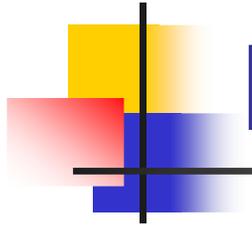
- Processo de Recombinação
- Seleção de Pais
- Seleção por sobrevivência
- Problema da Auto-Adaptação
- Exemplos de aplicações



# Recombinação

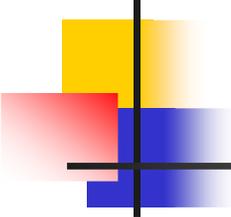
---

- Cria apenas um único filho por vez
- Atua por variável / posição, sendo
  - Calculando os valores médios entre os pais, ou
  - Selecionando um valor de um dos pais
- Pode também atuar a partir de dois ou mais pais
  - Utilizando os dois pais selecionados para gerar um filho, ou
  - Selecionando dois pais para cada posição a ser criada no filho.



# Nomes das Recombinações

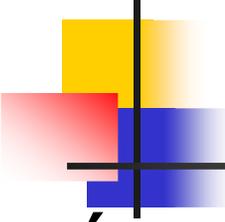
	Dois pais fixos	Dois pais para cada posição $i$
$z_i = (x_i + y_i)/2$	Ponto local intermediário	Ponto Global Intermediário
$z_i$ é $x_i$ ou $y_i$ escolha aleatória	Local Discreto	Global discreto



# Seleção de Pais

---

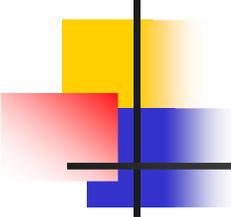
- Os pais são selecionados através de uma distribuição uniforme de probabilidade
- Desta forma:
  - A seleção de pais em uma EE é não tendenciosa
  - Todo o indivíduo tem a mesma probabilidade de ser selecionado



# Seleção por Sobrevivência

---

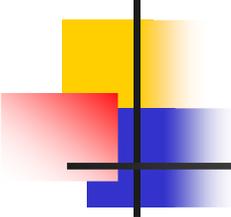
- É aplicado após a criação de  $\lambda$  filhos a partir de  $\mu$  pais através de mutação e recombinação
- De forma determinística filtra os “maus membros”
- A base da seleção é:
  - Unicamente conjunto de filhos:  $(\mu, \lambda)$  – seleção; ou
  - O conjunto de pais e filhos:  $(\mu + \lambda)$  – seleção



# Seleção por Sobrevivência

---

- A seleção  $(\mu + \lambda)$  é uma estratégia elitista
- A seleção  $(\mu, \lambda)$  pode ser “esquecida”
- Frequentemente a seleção  $(\mu, \lambda)$  é preferida para:
  - Melhor para se livrar de ótimos locais
  - Melhor para seguir ótimos móveis

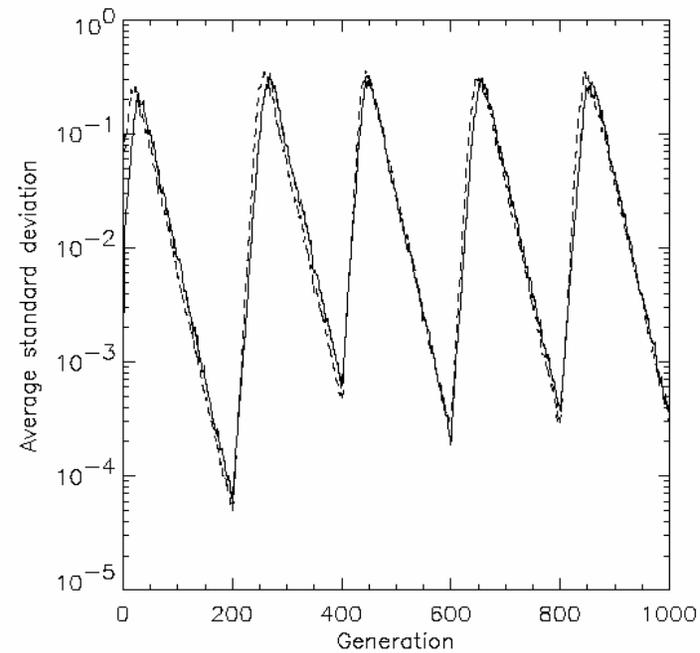
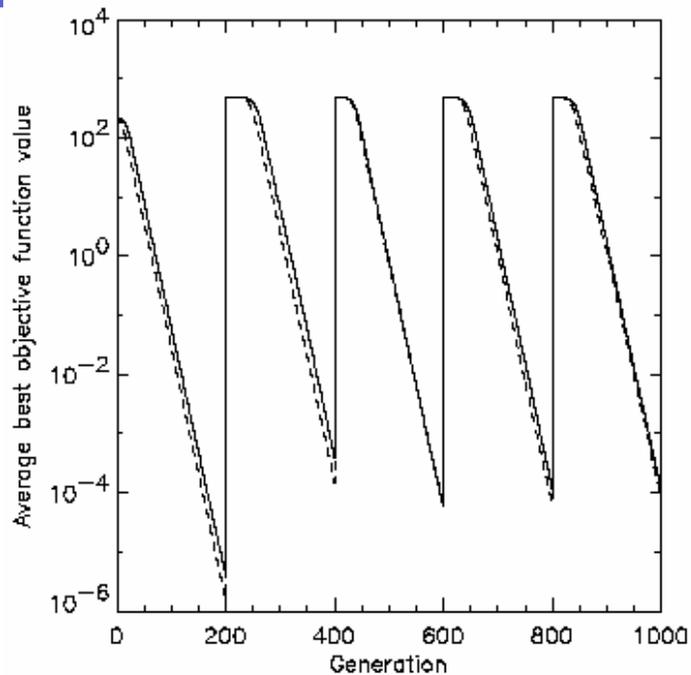


# Ilustração de Auto-Adaptação

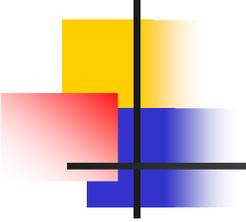
---

- Dado um ambiente onde o cenário de fitness é alterado dinamicamente (ex.: pontos ótimos são deslocados a cada 200 gerações)
- EE de Auto-Adaptação é hábil para:
  - Seguir os ótimos
  - Ajustar os passos de mutação após todo deslocamento

# Ilustração de Auto-Adaptação



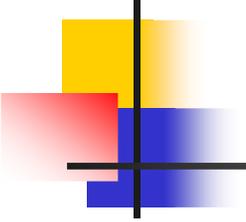
Alterações nos valores do Fitness (esquerda) e tamanho do passo da mutação (direita)



# Pré-requisitos para a Auto-Adaptação

---

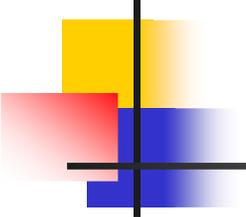
- $\mu > 1$  para diferentes estratégias
- $\lambda > \mu$  para gerar excesso de prole
- Pressão de seleção não é tão forte, e.g.,  $\lambda \approx 7 \cdot \mu$
- Uso da seleção ( $\mu, \lambda$ ) para se livrar do erro de adaptação em  $\sigma$
- Estratégia de mistura de parâmetros por recombinação



# Exemplo: O experimento do conhaque de cereja

---

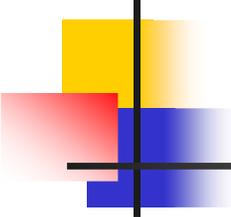
- Tarefa: produzir uma mistura colorida da mesma cor do conhaque de cereja
- Ingredientes: água + corantes vermelho, amarelo e azul
- Representação:  $\langle w, r, y, b \rangle$
- Valores escalados para um predefinido volume (30 ml)
- Mutação: Baixos/Médios/Altos valores de  $\sigma$  usados com igual chances
- Seleção: Estratégia (1,8)



# Exemplo: O experimento do conhaque de cereja

---

- Fitness: Realização de mistura e comparação com a cor real
- Critério de parada: cor alcançada ser satisfatória
- Solução é encontrada na maioria das vezes dentro de 20 gerações
- Precisão é muito boa!



# Exemplo: A Função de Ackley

---

- A função de Ackley (com  $n=30$ )

$$f(x) = -20 \cdot \exp\left(-0.2 \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$$

- Estratégia Evolutiva:

- Representação:

- $-30 < x_i < 30$
- 30 diferentes tamanhos de passo

- Seleção (30,200)

- Término: após 200000 gerações

- Resultados: Média das melhores soluções é  $7.48 \cdot 10^{-8}$