

# 1. Computação Evolutiva

**Prof. Renato Tinós**

Programa de Pós-Graduação Em  
Computação Aplicada

Depto. de Computação e Matemática  
(FFCLRP/USP)

## 1.5. Aspectos de Projeto

- 1.5.1. Uso de Algoritmos Evolutivos (AEs)
- 1.5.2. Testes de AEs
- 1.5.3. Projeto de AEs
- 1.5.4. Desempenho de Aes
- 1.5.5. Controle de Parâmetros

## 1.5.1. Uso de Algoritmos Evolutivos (AEs)

- Experimentos com AEs
  - Qual o objetivo?
    - Desenvolvimento e/ou estudo de AEs?
      - Para problema específico?
    - Aplicação
  - Como avaliar?

## 1.5.1. Uso de Algoritmos Evolutivos (AEs)

Exemplo 1.5.1. Otimizar, por parte da empresa, entregas de compras feitas pela Internet

- Diferente destinos a cada dia
- Tempo limitado para executar o algoritmo

***Deve achar uma solução (razoavelmente) boa no tempo disponível***

## 1.5.1. Uso de Algoritmos Evolutivos (AEs)

### Exemplo 1.5.2. Otimizar o sistema nacional de tráfego em rodovias

- Custo total muito alto
  - Custo da computação é negligenciável
- Disponibilidade grande de
  - Tempo (meses) para executar os algoritmos
  - Recursos (Ex.: máquinas)

***Deve produzir um ótimo resultado (uma única vez): deve ser o melhor possível!***

## 1.5.1. Uso de Algoritmos Evolutivos (AEs)

- **Perspectivas**

- **Design**

- Ache uma solução muito boa uma única vez

- **Produção**

- Ache uma solução razoável várias vezes
  - As instâncias do problema mudam

- **Academia**

- Desenvolvimento de investigações científicas e novos AEs

## 1.5.2. Testes de Algoritmos Evolutivos

- No caso de comparações entre algoritmos, pode-se:
  - Usar instâncias de problemas a partir de repositório público ou já utilizados no meio acadêmico
    - Pode-se escolher problemas com diferentes características
    - Será que são problemas semelhantes aos problemas reais?
  - Usar instâncias de problemas aleatórios
  - Usar instâncias de problemas práticos
    - Dificuldade de comparar com os resultados obtidos por outros pesquisadores

## 1.5.2. Testes de Algoritmos Evolutivos

- Exemplo Ruim:
  - Desenvolver um novo AG
    - Comparar o AG padrão (?) com o novo AG
    - Testar em 10 problemas da literatura
      - Resultado: novo AG é melhor em 7, igual em 1, pior em 2 problemas
    - Conclui-se que....
- Será que essa é uma boa metodologia?
  - Deve-se responder às seguintes questões
    - Quão relevante são os resultados?
      - Deve-se levar em conta os resultados e as características de cada problema
      - Deve-se comparar com algoritmos que têm características semelhantes ou que têm bom desempenho nos problemas em que se espera que o novo algoritmo seja bom
    - Podem ser generalizados os resultados?
    - É possível explicar o porquê dos resultados?

## 1.5.3. Projeto de Algoritmos Evolutivos

- Escolha de uma representação
- Escolha uma forma de mapear o genótipo no fenótipo
- Escolha uma forma de avaliar os indivíduos
- Escolha operadores de reprodução
  - Exemplo: recombinação e mutação
- Escolha operadores de seleção
  - Quem serão os pais?
  - Quem será escolhido para compor a próxima população
- Decida como inicializar a população e os parâmetros e se estes último serão controlados (e como)
- Decida o critério de parada

## 1.5.3. Projeto de Algoritmos Evolutivos

- **AEs são estocásticos**
  - Não se pode tirar conclusões a partir de uma única execução
  - Deve-se executar independentemente o AE várias vezes
    - com diferentes sementes aleatórias
  - Deve-se usar medidas estatísticas para análise dos resultados
    - Médias, medianas, desvios
  - Deve-se usar testes estatísticos para gerar as conclusões
- **Experimentos com AEs envolvem comparação**
  - **Competição deve ser justa**
    - Uso da mesma quantidade de recursos
      - Exemplo: mesmo número de avaliações de solução
    - Uso de diferentes parâmetros
    - Uso das mesmas medidas de desempenho

## 1.5.4. Desempenho de Algoritmos Evolutivos

- Várias medidas de desempenho são utilizadas
  - Exemplos
    - Resultado médio em um dado tempo
    - Tempo médio para um dado resultado
    - Proporção de execuções que resultaram em sucesso (Ex.: achar o ótimo global)
    - Melhor resultado em  $n$  execuções
    - ...

## 1.5.4. Desempenho de Algoritmos Evolutivos

- Unidades de tempo
  - Tempo decorrido?
    - Depende da máquina
  - Tempo de CPU?
    - Depende de características de implementação
  - Gerações?
    - E se o tamanho da população muda durante a execução?
  - Avaliações da função de fitness?
    - Geralmente usada
    - Deve-se tomar cuidado quando representações diferentes são usadas

## 1.5.4. Desempenho de Algoritmos Evolutivos

- **Medidas de Desempenho**
  - *off-line*
    - **Eficiência** (velocidade do alg.)
      - Tempo de CPU
      - Números de pontos gerados no espaço de busca
    - **Evetividade** (qualidade do alg.)
      - Taxa de sucesso
      - Qualidade da solução no final
  - *on-line*
    - Distribuição da população (genótipo)
    - Distribuição do fitness (fenótipo)
    - Melhorias no fitness do melhor indivíduo por unidade de tempo ou por operação de reprodução
    - ...

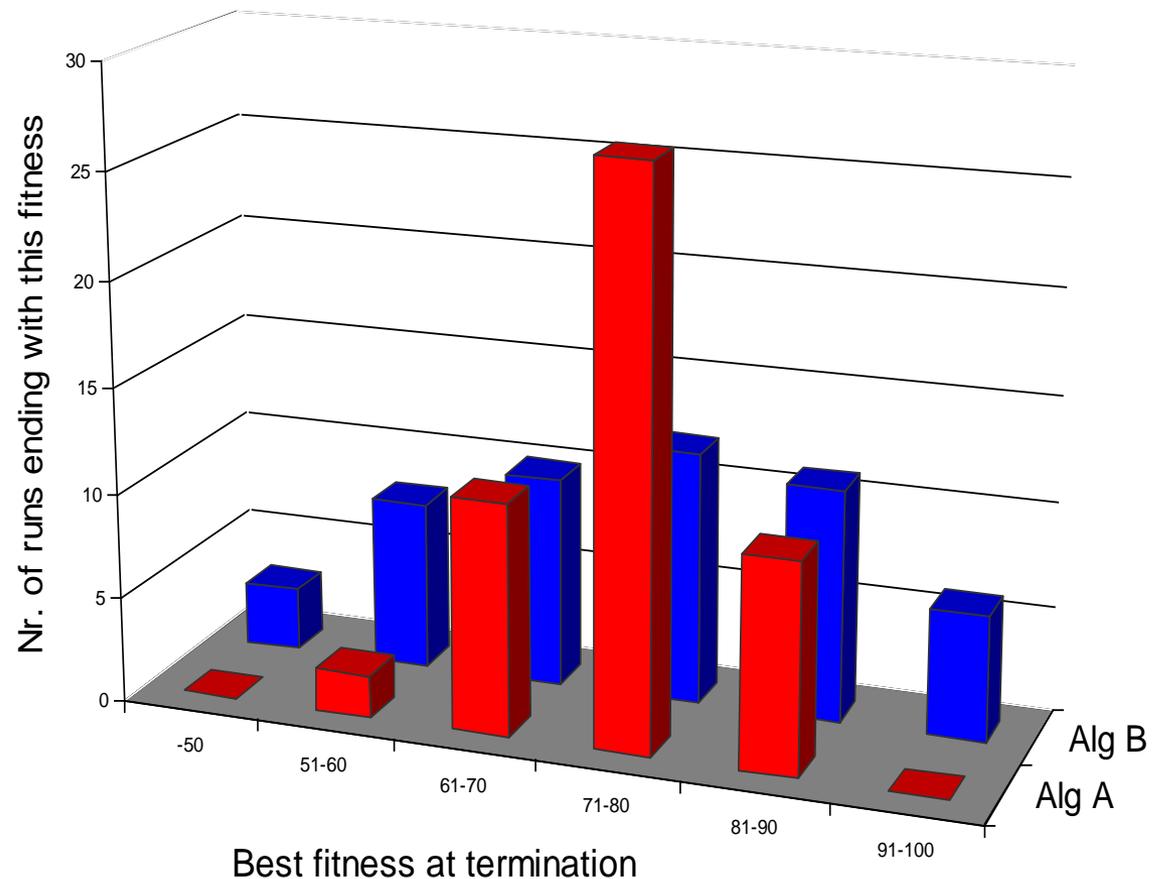
## 1.5.4. Desempenho de Algoritmos Evolutivos

- Medidas de Desempenho
  - **AES**: *average no. of evaluations to solution*
  - **SR**: *success rate*
    - % das execuções que acharam a solução (ótimo global ou igual a uma qualidade pré-definida)
  - **MBF**: *mean best fitness*
    - Média dos melhor fitness encontrado em cada execução
      - As vezes, é melhor usar outras medidas
        - Mediana
        - Melhor e pior
        - Quartis

## 1.5.4. Desempenho de Algoritmos Evolutivos

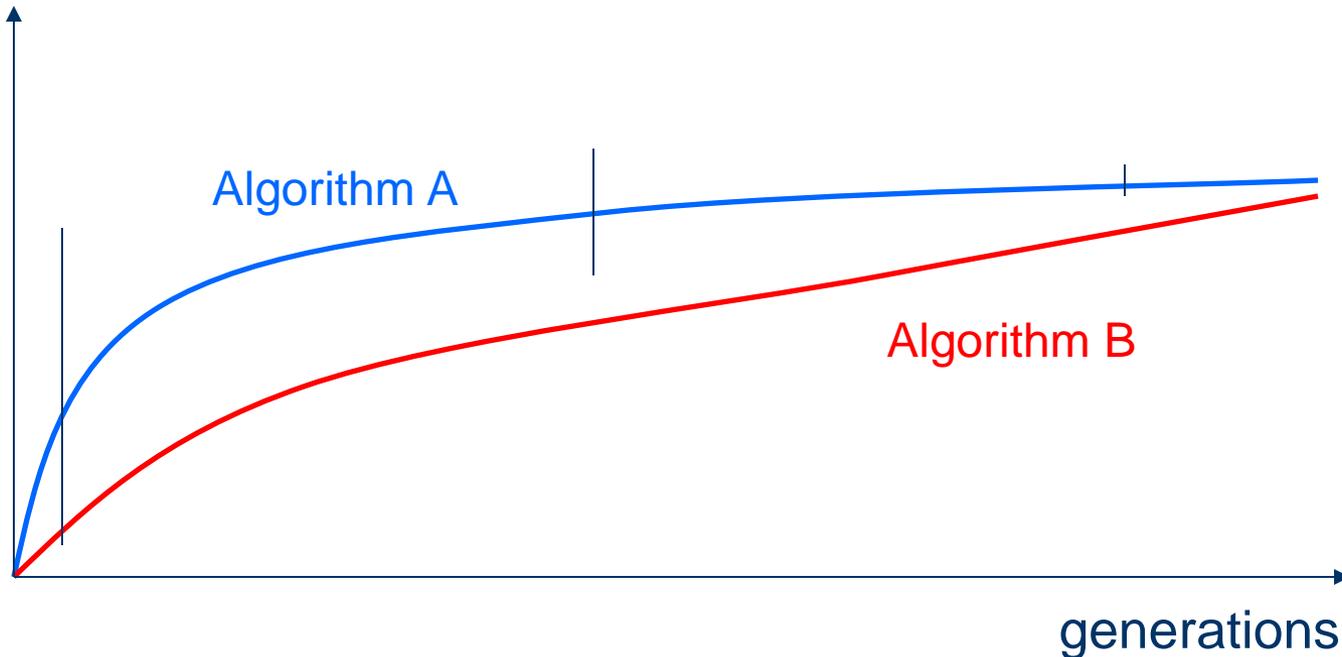
Exemplo:

Qual algoritmo é melhor?  
Por que?  
Quando?



## 1.5.4. Desempenho de Algoritmos Evolutivos

Populations mean (best) fitness



Qual algoritmo é melhor? Por que? Quando?

## 1.5.4. Desempenho de Algoritmos Evolutivos

- Comparação estatística e significância
  - Necessária quando diferentes algoritmos (ou com diferentes parâmetros) são comparados

## 1.5.4. Desempenho de Algoritmos Evolutivos

- Comparação estatística e significância
  - Exemplo:

Trial	Old Method	New Method
1	500	657
2	600	543
3	556	654
4	573	565
5	420	654
6	590	712
7	700	456
8	472	564
9	534	675
10	512	643
Average	545.7	612.3

## 1.5.4. Desempenho de Algoritmos Evolutivos

- Comparação estatística e significância
  - Exemplo:

Trial	Old Method	New Method
1	500	657
2	600	543
3	556	654
4	573	565
5	420	654
6	590	712
7	700	456
8	472	564
9	534	675
10	512	643
Average	545.7	612.3
SD	73.5962635	73.5473317
T-test	<b>0.07080798</b>	

- Desvio-padrão fornece informação adicional
- Teste  $t$  (ou similares) indica a chance de os valores serem provenientes da mesma distribuição (ex.: 7% de chance neste exemplo).

## 1.5.4. Desempenho de Algoritmos Evolutivos

- Teste  $t$  assume:
  - Distribuição normal
    - Deve-se checar através de métodos apropriados
  - Variância similar quando existem muito pouco dados
  - Grupos de dados com a mesmo tamanho
- Outros testes:
  - *Wilcoxon tests*
    - Não paramétrico
- Considerar especificidades
  - Resultados pareados?
  - Comparações de mais de 2 algoritmos?

## 1.5.5. Controle de Parâmetros

- Motivação
  - Algoritmos Evolutivos (AEs) têm diversos parâmetros que definem a estratégia de busca
    - Exemplos
      - Operador de mutação e taxa de mutação
      - Operador de recombinação (ou crossover) e respectiva taxa
      - Mecanismo de seleção e pressão seletiva
      - Tamanho da população
  - Ajuste dos parâmetros influencia diretamente o desempenho do processo evolutivo
  - Parâmetros de um AE são geralmente fixos durante uma execução
  - Questão 1: Como encontrar bons valores dos parâmetros de um AE?

## 1.5.5. Controle de Parâmetros

- **Ajuste de Parâmetros**
  - Método tradicional
    - Teste e comparação através de execuções do AE com diferentes valores dos parâmetros
      - Deve-se alterar um parâmetro de cada vez
  - Problemas
    - Requer tempo
    - Parâmetros são relacionados
      - Busca exaustiva não é viável
        - Alternativa: **Grid Search**
    - Bons valores podem se tornar ruins durante a execução

## 1.5.5. Controle de Parâmetros

- Motivação
  - AE são sistemas dinâmicos
    - Assim, valores dos parâmetros ótimos podem variar durante uma execução
  - Questão 2: Como variar os valores dos parâmetros?

## 1.5.5. Controle de Parâmetros

- **Controle de Parâmetros**
  - Valores dos parâmetros são ajustados on-line (durante a execução)
  - Métodos
    - **Determinista**: regras pré-definidas
    - **Adaptativo**: usando feedback do processo de busca
    - **Auto-adaptativo**: codificando os parâmetros no cromossomo e permitindo que eles sejam modificados pelo processo evolutivo

## 1.5.5.1. Exemplos

- Tarefa:

$$\min f(x_1, \dots, x_n)$$

$$L_i \leq x_i \leq U_i \quad , \quad i = 1, \dots, n \quad // \text{ limites}$$

$$g_i(\mathbf{x}) \leq 0 \quad , \quad i = 1, \dots, q \quad // \text{ rest. de desigualdade}$$

$$h_i(\mathbf{x}) = 0 \quad , \quad i = q+1, \dots, m \quad // \text{ rest. de igualdade}$$

- Estratégia

- AE com representação real  $(x_1, \dots, x_n)$

- Recombinação intermediária (média)

- Mutação Gaussiana:

$$x'_i = x_i + N(0, \sigma)$$

desvio-padrão  $\sigma$  é chamado de tamanho do passo de mutação

## 1.5.5.1. Exemplos

- Controle determinista do tamanho do passo de mutação
  - Substitua  $\sigma$  constante por função  $\sigma(t)$  determinista
  - Exemplo

$$\sigma(t) = 1 - 0,9 \frac{t}{T}$$

sendo  $0 \leq t \leq T$  o índice da geração

- Características
  - Mudança no parâmetro é independente do processo evolutivo
  - Controle do parâmetro
    - É ditado pelo usuário
    - É previsível
    - Age sob todos os indivíduos da população

## 1.5.5.1. Exemplos

- Controle adaptativo do tamanho do passo de mutação
  - Substitua  $\sigma$  constante por função  $\sigma(t)$  adaptativa
    - Depende da evolução do processo explicitamente
  - Exemplo: **Regra do 1/5 de sucesso** (ES)
    - Mude  $\sigma(t)$  a cada  $k$  gerações de acordo com:

$$\sigma(t) = \begin{cases} \sigma(t-1)/c & \text{se } p_s > 1/5 \\ \sigma(t-1)c & \text{se } p_s < 1/5 \\ \sigma(t-1) & \text{caso contrário} \end{cases}$$

Sendo:  $t$  o índice da geração;  $0,817 \leq c < 1$

$p_s$  a taxa de mutações benéficas durante as últimas  $k$  gerações

- Características
  - Mudança no parâmetro é dependente do progresso do processo evolutivo
  - Controle do parâmetro
    - Não é previsível
    - Age sob todos os indivíduos da população

## 1.5.5.1. Exemplos

- Controle auto-adaptativo do tamanho do passo de mutação
  - Cada indivíduo é associado a um  $\sigma$ 
    - Pode associar um  $\sigma_i$  a cada dimensão do problema
  - Cromossomo:  $(x_1, \dots, x_n, \sigma)$
  - Cada  $\sigma$  individual é sujeito a seleção e mutação (e recombinação)
  - Exemplo

$$\sigma' = \sigma \times e^{N(0, \tau)}$$

$$x'_i = x_i + N(0, \sigma')$$

- Características
  - Mudança no parâmetro é dependente de processo evolutivo
  - Controle do parâmetro
    - Não é previsível
    - Age separadamente em cada indivíduo da população

## 1.5.5.1. Exemplos

- Restrições

$$g_i(\mathbf{x}) \leq 0 \quad , i = 1, \dots, q \quad // \text{rest. de desigualdade}$$

$$h_i(\mathbf{x}) = 0 \quad , i = q+1, \dots, m \quad // \text{rest. de igualdade}$$

- Possível solução

- Incorporar penalidades na função de avaliação

$$\text{fitness}(\mathbf{x}) = f(\mathbf{x}) + W \mathbf{p}(\mathbf{x})$$

sendo  $W$  uma cte. positiva (peso) e

$$p(\mathbf{x}) = \sum_{i=1}^m \begin{cases} 1 & \text{se restrição } i \text{ é violada} \\ 0 & \text{se restrição } i \text{ não é violada} \end{cases}$$

## 1.5.5.1. Exemplos

- Controle determinista das penalidades
  - Substitua a constante  $W$  pela função  $W(t)$

$$W(t) = (C t)^\alpha$$

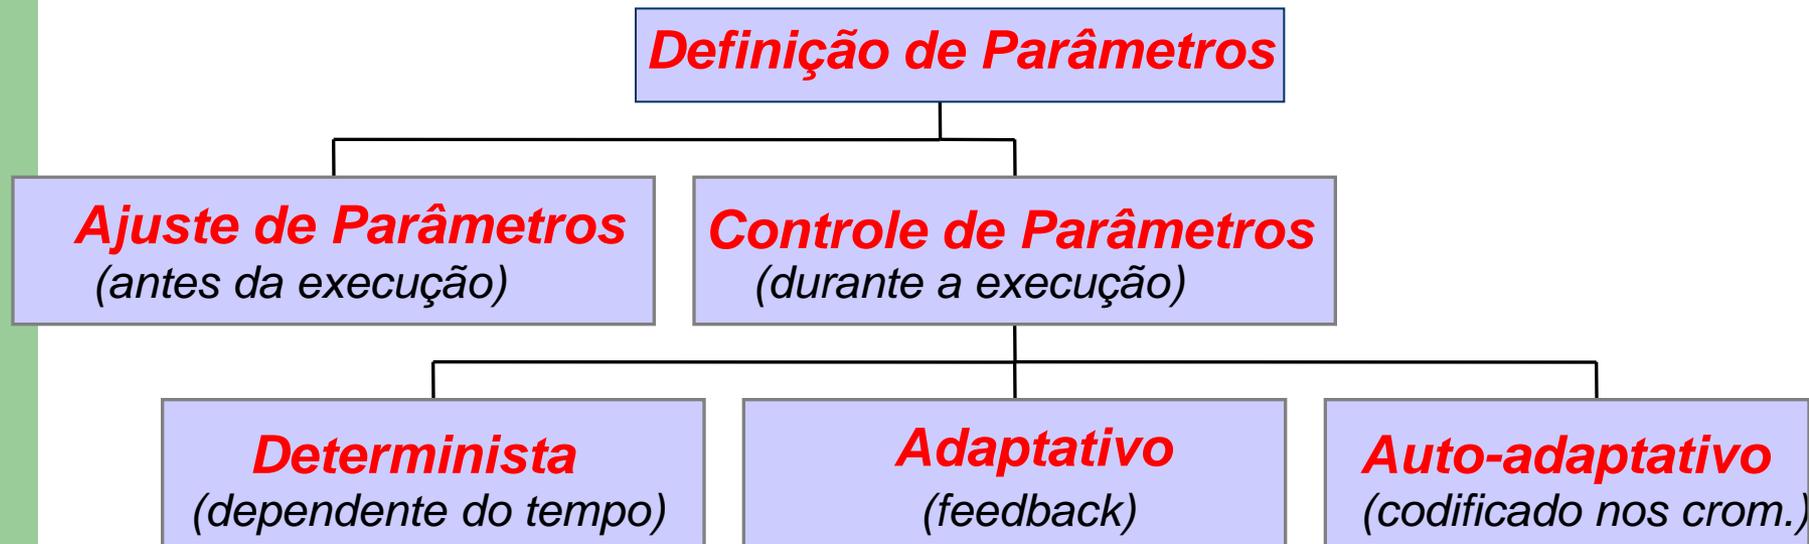
Sendo  $0 \leq t \leq T$  o índice da geração,  $C$  e  $\alpha$  valores positivos maiores ou iguais a 1

- Controle adaptativo e auto-adaptativo também podem ser empregados para o controle das penalidades

## 1.5.5.2. Aspectos do Controle de Parâmetros

- Praticamente qualquer componente de um AE pode ser parametrizado e controlado
  - Exemplos:
    - Representação
    - População
      - Exemplo: tamanho da população
    - Operadores de reprodução
    - Funções de avaliação
    - Operadores de seleção
      - Exemplo.: pressão seletiva

## 1.5.5.2. Aspectos do Controle de Parâmetros



## 1.5.5.2. Aspectos do Controle de Parâmetros

- As mudanças nos parâmetros podem ser baseadas em:
  - **Tempo ou número de avaliações** (Controle determinista)
  - **Estatísticas sobre população** (Controle adaptativo)
    - Progresso durante execução
    - Diversidade da População
    - Distribuição dos genes
    - Etc.
  - **Relativa ao fitness** dos indivíduos criados com determinados parâmetros (Controle adaptativo e controle auto-adaptativo)

# Comentários

- Referências
  - Eiben, A. E. & Smith, J. E. *Introduction to Evolutionary Computation*. Springer, 2003
    - Capítulo 8
    - Capítulo 14
- Agradecimentos
  - Parte do material desta apresentação foi obtida através de
    - Material de apoio do livro Eiben, A. E. & Smith, J. E. *Introduction to Evolutionary Computation*. Springer, 2003.