


# Computação Evolucionária

**Prof. Heitor Silvério Lopes**

[hslopes@utfpr.edu.br](mailto:hslopes@utfpr.edu.br)  
<http://silverio.net.br/heitor>



# IA x IC




## # Inteligência Artificial (IA)

- Utiliza modelos computacionais inspirados no raciocínio humano

## # Inteligência Computacional (IC):


- Utiliza modelos computacionais inspirados na natureza (métodos bioinspirados)
- Também conhecida como Computação Natural ou *Soft Computing*

# Inteligência Computacional






# Sistemas fuzzy





- # **Inspiração biológica:** imprecisão do raciocínio humano
- # A lógica *fuzzy* foi criada por **Lotfali Askar-Zadeh** na década de 60
- # É uma forma de tratar incertezas e imprecisões inerentes ao conhecimento.
- # Utiliza variáveis linguísticas em vez de variáveis numéricas.
- # Tem um sólido embasamento teórico

# Redes Neurais




- ✦ **Inspiração biológica:** funcionamento dos neurônios
- ✦ Precursores: W. McCulloch e W. Pitts, D.O. Hebb, J.L. McClelland
- ✦ **F. Rosenblatt** → Primeiro modelo matemático de um neurônio
- ✦ Desenvolvimento nas décadas de 50 a 80

<https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1> em 27/06/2020



# Computação evolucionária



- # **Inspiração biológica:** Evolução das espécies
- # Charles Darwin, 1859:



- "Sobre a origem das espécies por meio de seleção natural"
- A evolução dos seres vivos é baseada no Princípio da Seleção Natural:
  - # Indivíduos mais fortes e mais bem-adaptados ao ambiente têm maior chance de sobrevivência e de dar continuidade à sua espécie



# Seleção natural e evolução

**Importante!**

- # A seleção natural é probabilística
- # A seleção natural atua sobre os indivíduos de uma espécie
- # A consequência a longo prazo é a evolução da espécie
- # Evolução (adaptação) como um processo "inteligente" de otimização
- # Inspiração para a construção de paradigmas computacionais que imitem a evolução das espécies, como forma de otimização




# Hipóteses de Darwin relevantes para a Computação Evolucionária

- # H1: Dentro de uma mesma espécie os indivíduos apresentam pequenas diferenças entre si
  - Há diferenças genotípicas/fenotípicas
- # H2: Algum processo de variação continuada deve ser responsável pela introdução de novas informações na carga genética dos indivíduos
  - Ocorrem mutações não-determinísticas
- # H3: Não há limite para a introdução sucessiva de variações genéticas
  - Processo continuado de evolução



# História da Computação Evolucionária


- # As primeiras ideias surgiram em 1957-1962, porém havia pouco ou nenhum embasamento teórico, suporte computacional incipiente, e ceticismo da comunidade científica.
- # Décadas de 60/70 houve a emergência, de forma independente, das principais linhas de pesquisa:
  - Algoritmos Genéticos (AG)
  - Programação Evolucionária (PE)
  - Estratégias Evolucionárias (EE)



# História da Computação Evolucionária

## # Algoritmo Genético (AG)

- Criado por John Holland na Universidade de Michigan (EUA) na **década de 60**
- Publicou o seu livro em **1975**: "Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence"
- "Sistema adaptativo artificial"; "planos reprodutivos generalizados"
- Foi o orientador de doutorado de vários pesquisadores importantes da área, incluindo Rick Riolo, John Grefenstette, **David Goldberg**, Erick Goodman, **Kenneth DeJong** e **John Koza**









# História da Computação Evolucionária



## Programação Evolucionária (PE)

- Desenvolvido por Lawrence Fogel, Owens e Walsh em 1966 na Universidade da Califórnia em San Diego
- Objetivo: aplicar à evolução simulada de máquinas de estados finitos para a previsão de séries não-estacionárias.
- Teve seu auge na década de 80, mas caiu em desuso



## Estratégias Evolucionárias (EE)

- Desenvolvido por Bienert, Ingo Rechenberg e Hans-Paul Schwefel em 1965 na Universidade Técnica de Berlin
- Foi desenvolvido para otimização numérica em problemas de *design* industrial
- Também caiu em desuso na década de 90

# Escopo da Computação Evolucionária

- O escopo de aplicação de CE é em problemas de **Busca e Otimização**
- Grandes áreas de aplicação:
  - **Engenharias**
  - **Computação**
  - **Matemática aplicada**
- Problemas de outras naturezas:
  - Modelagem como um problema de otimização.
  - P.ex. Aprendizado: max(qtd. info. absorvidas); min(qtd. erros conceituais); max(capacidade de extrapolação), min(tempo aprendizado)....



# Otimização

## # Definição de otimização:

- "Processo de melhoramento iterativo de uma solução para um problema, com respeito a uma função objetiva específica."

## # Problemas típicos da área de otimização:

- Maximização (ou minimização) de funções algébricas
- Problemas combinatoriais
  - ex. Problema do caixeiro viajante, problema da mochila
- Projetos de engenharia:
  - maximização de desempenho
  - minimização de custo



# Métodos para otimização

## # Métodos fortes:

- Para problemas específicos onde há linearidade, diferenciabilidade, estacionariedade
- Em geral garantem a obtenção da solução ótima

## # Métodos específicos:

- Para problemas muito particulares

## # Métodos fracos:

- Para problemas genéricos onde pode existir não-linearidade, não-estacionariedade (etc).
- Não garantem a obtenção da solução ótima, só eventualmente podem fornecer uma solução satisfatória

# Métodos de otimização

## # Numéricos:

- Analíticos: derivadas parciais = 0
- Diretos: técnicas de gradiente (*steepest descent* ou *hill-climbing*)



## # Enumerativos:

- Busca exaustiva
- Programação dinâmica



## # Probabilísticos: → Heurísticas

- Busca aleatória
- *Simulated annealing*
- Computação Evolucionária & Inteligência de Enxames



# Métodos enumerativos

- # Excelentes para um grande número de problemas, entretanto:
  - Aplicável somente a problemas de "dimensões pequenas"
  - Aceitável quando envolve tempos computacionais "razoáveis"
- # Tendem a ser cada vez mais utilizados, à medida que a capacidade computacional disponível aumenta
- # Não servem para problemas com complexidade Não-Polinomial (NP)



# "Ingredientes" de problemas de otimização

- # Função objetivo:
  - a qual se quer maximizar ou minimizar.
  - exemplos:  $\max(\text{lucro})$ ,  $\min(\text{custo})$
  - pode não existir ou ser múltipla
- # Conjunto de variáveis:
  - que afetam o valor da função objetivo
  - em problemas interessantes, este conjunto pode ser muito grande
- # Conjunto de restrições:
  - não permite que o conjunto de variáveis assumam determinados valores

# "Ingredientes" de problemas difíceis

- # Multimodalidade (máximos locais)
- # Grande conjunto de restrições
- # "Ruído"
- # "Deceptividade" (*deception*)
- # Isolamento do ótimo desejado (*Royal Road*)
- # Não-estacionariedade (variação dinâmica)
- # Espaço de busca **arbitrariamente** grande



# Quando pode ser interessante utilizar uma técnica de CE ?



- # Quando a complexidade do problema torna inviável a sua formulação matemática e o tratamento por métodos algébricos
- # Quando o número de possíveis soluções a serem examinadas leva à uma explosão combinatória intratável por métodos exaustivos
- # Quando o problema é fortemente não-estacionário
- # Quando o custo computacional e a qualidade da solução sub-ótima forem aceitáveis
- # Quando não existir outra alternativa viável !





# Princípio dos Algoritmos Evolutivos

# Abordagem "intuitiva": tentativas e refinamentos sucessivos:

- 1 gere soluções para o problema
- 2 avalie as soluções
- 3 se a melhor solução satisfaz, pare
- 4 selecione as melhores soluções
- 5 construa novas soluções utilizando partes das melhores soluções
- 6 eventualmente modifique as soluções
- 7 volte ao passo 2

# Algoritmo genético #1:


## Codificação das variáveis do problema

- Mapeamento fenótipo x genótipo


*mundo real*



variáveis  
do problema




cromossomo



# Algoritmo genético #2:

## População" de possíveis soluções

### ■ Busca paralela





# Algoritmo genético #3:

## Função de *fitness*


- Avalia a qualidade da solução para o problema



# Algoritmo genético #4:

## Seleção


- Implementa e guia o processo evolutivo
- Seleciona os indivíduos mais aptos a se reproduzir e passar o seu material genético
- Métodos probabilísticos ou determinísticos



# Algoritmo genético #5:

## Reprodução e operadores genéticos

- *Crossover*: recombinação de material genético de dois pais - realiza busca local
- *Mutação*: variação aleatória - realiza busca global






# Algoritmo genético #6:

## Critério de parada do algoritmo

- Número predeterminado de gerações
- Quando não há mais melhora
- Quando não há mais diversidade
- Quando atingiu o ótimo



# Diferenças entre **AG** e outros métodos de otimização

- # Codificação: (fenótipo  $\leftrightarrow$  genótipo)
  - AG's trabalham com conjuntos de parâmetros codificados e não os parâmetros propriamente ditos.
- # Busca paralela: (paralelismo implícito)
  - AG's realizam a busca utilizando uma população de pontos simultaneamente, não um único ponto
- # Busca probabilística
  - AG's utilizam regras de transição probabilísticas, não determinísticas.

# CE como método de engenharia

- # A otimização é um dos princípios da Engenharia
- # Projeto de engenharia:
  - Muitos parâmetros a serem otimizados
  - Muitos graus de liberdade
  - Muitas restrições a serem satisfeitas
- # CE:
  - Facilita a tarefa de projeto gerando soluções subótimas ou mesmo ótimas em um tempo razoável
- # CE emprega um método intuitivo:
  - Processo criativo
  - Refinamento iterativo



# Vantagens das técnicas de CE

- Não requerem um conhecimento matemático profundo do problema ao qual é aplicado.
- Têm robustez
- Requerem pouco esforço de implementação
- São facilmente hibridizáveis com outras técnicas
- São facilmente adaptáveis a muitas classes de problemas, inclusive problemas multiobjetivos
- São implícita e explicitamente paralelizáveis
- São capazes de manipular de restrições

# Desvantagens das técnicas de CE

- Não garantem encontrar a solução ótima em tempo finito
- Há pouco embasamento teórico - a prática se desenvolveu mais do que a teoria
- O ajustes dos parâmetros de controle requer conhecimento prévio, calibração com experimento fatorial ou tentativa-e-erro
- Não são intrinsecamente melhores do que qualquer outro algoritmo de otimização ("*No free-lunch theorems*")

***"Não existem métodos fáceis para resolver problemas difíceis."***



**René Descartes**