

~ Teoria de Evolução Natural - C. Darwin

~ A vida na terra é o resultado de um processo de seleção, pelo meio ambiente, dos mais adaptados/aptos, e por isso mesmo, com mais chances de reproduzir-se.

~ A computação evolutiva é um paradigma para resolver problemas.

~ não exige, para resolver um problema, um conhecimento prévio de uma maneira de encontrar a solução.

~ Baseada em mecanismos evolutivos da natureza

↳ Auto-organização

↳ Comportamento adaptativo

~ Em Computação Evolutiva, abrimos mão da garantia de obtenção de uma solução ótima para se conquistar a tratabilidade via uma ferramenta de propósito geral.

Para que serve:

- ① Validar teorias e conceitos associados à biologia da evolução.
- ② Lidar com problemas com os quais não é possível ou é muito custoso obter uma solução detalhada. E.g.: funções não deriváveis (otimização)
- ③ Não é necessário reiniciar todo o processo de busca de uma solução frente a pequenas mudanças nas especificações do problema dado que refinamentos podem ser feitos a partir da solução atual.

Como simula este comportamento

~ CE está baseada em algumas ideias básicas:

- ① População de soluções (e.g., inicialmente aleatória) no qual os indivíduos registram os parâmetros que descrevem uma possível solução.
- ② Função de avaliação: julga a aptidão de cada indivíduo. Apenas atribui uma "nota".

③ Operadores : aplicados a uma dada geração para obtenção de uma próxima geração. (58)

④ operador seleção : permite escolher os indivíduos (reprodução asexual) ou um par deles (reprodução sexual) para gerar descendência.

- A probabilidade de escolha recai sobre os indivíduos mais bem avaliados.

⑤ Recombinação - simula a troca de material genético entre os amostrados e determina a carga genética dos descendentes.

⑥ mutação : - operador que realiza mudanças aleatórias no material genético.

Como avaliar a adaptação?

Uma população inicial de soluções evolui ao longo das gerações que são simuladas no processo em direção a soluções mais adaptadas por meio dos operadores de seleção, mutação e recombinação.

Indivíduos formam uma população


População * ① 0 1 0 0 1
② 1 0 0 1 1
③ 1 0 0 1 0
④ 0 0 1 1 0
⑤ 0 0 0 0 1
⑥ 0 1 0 1 0

função de avaliação

$f(I_i)$


Recombinação

(Pai)




Mutação

59




Entendendo melhor


visão geral do espaço de busca



Estado atual




Escolha dos indiv. p/ reprodução



e que serão descartados

próxima geração.



Diferentes Abordagens de Computação Evolutiva

- ① Estratégias Evolutivas
- ② Programação Evolutiva
- ③ Algoritmos Genéticos
- ④ Programação Genética.

Estratégias Evolutivas

60

- ① Empregam apenas operadores de mutação.
- ② Não necessita de muitas informações sobre o problema.
- ③ Muito utilizada em otimização (problemas multi-dimensionais, multi-modais e não lineares).

Algoritmo Básico

- ① População com m indivíduos. Cada um el m genes.
- ② Cada indivíduo produz k/m descendentes com pequenas mudanças (mutações).
- ③ Apenas os m melhores indivíduos das k gerações permanecem vivos.

Programação Evolutiva

- ① Cada indivíduo gera um único descendente através de mutação.
- ② A melhor metade da população ascendente e a melhor metade da população descendente formam a nova geração.

Algoritmo Básico

- ① População inicial escolhida aleatoriamente.
- ② Cada indivíduo (solução) gera um novo indivíduo utilizando-se mutação.
- ③ Calcula-se a aptidão de cada solução. Os mais aptos são retidos.

Algoritmos Genéticos

- ① Combinam variações aleatórias com seleção de indivíduos mais aptos.
- ② mantêm uma população de ~~soluções~~ soluções candidatas.
- ③ Busca multi-direcional e ~~paralelismo~~ paralelismo intrínseco. Algoritmos genéticos possuem o que chamamos de paralelismo intrínseco.

Algoritmos Genéticos

(61)

④ Utiliza os operadores de Recombinação e mutação

Algoritmo Básico ① Inicia população (soluções candidatas).

② Avalia cada cromossomo (solução).

③ Cria novos cromossomos a partir da população atual (mutação + recombinação).

④ Substitui ascendentes por descendentes.

⑤ Se atingir critério de parada, termina.


Programação Genética

① Extensão de algoritmos genéticos.

② Indivíduos são programas.

③ Representação comum: árvores.

Exemplo




$$\left(2.2 - \frac{X}{11}\right) + \left(7 * \cos(Y)\right)$$

percurso em pré-ordem.

④ Codificação dos indivíduos : binária vs ponto flutuante.

~ Uma codificação errada pode levar a problemas de convergência prematura (mín. local) e valores inválidos (fora de domínio).



(2, 4, 6, 8, 3, 1, 7, 5).

Problema das 8 rainhas

② Como criar uma população inicial ? Aleatório ou usar um método simples ?

③ Operadores genéticos

(a) Quais os seus parâmetros

(b) mutação deve ser de valor alto ou baixo ?

(c) Como deve ser a recombinação ? Qual o ponto de corte ?

④ Como selecionar os indivíduos para a próxima geração ?

(a) método roleta : probabilidade proporcional ao fitness. Com isso, podemos perder o melhor indivíduo. Solução : usar elitismo.


(b) seleção baseada em rank : ordena pelo fitness.

Exemplos de problemas

63

Problema ④ : Voltagem

Suponha que tenhamos um problema de otimização em que queremos a maior voltagem possível em uma saída



$16^9 \sim 68,7 \times 10^9$ combinações

Configuração : ⑩ posições.

⑨ botões

Objetivo : encontrar a combinação que maximiza o sinal de saída.

Nosso primeiro problema é escolher a codificação

↳ ⑩ posições possíveis : ④ bits

↳ Indivíduo ④ bits * ⑨ botões = 36 bits.



Posição	Representação	Posição	Representação
0	0000	4	0100
1	0001	5	0101
2	0010	6	0110
3	0011	7	0111

Posição atual : 0010

Cromossomo (solução candidata)



operadores genéticos : mutação simples e recombinação uniforme

O que é recombinação uniforme : Para cada posição (gene), escolhe-se com certa probabilidade se pai (x) ou (y) é que contribui.

função de adaptação : voltagem de saída.

Valores arbitrários (A) Probabilidade de bits 1 na população: 50%.


(B) Taxa de mutação: 3%.

(C) Recombinação: 60%.

(D) Tipo de seleção na recombinação: bi-clássica (50% bons, 10% ruins).

Resultado

Paralelismo
intrínseco!



* 1500 indivíduos

* Quantas combinações exam?
 $\sim 10^9$.

* Resultado em < 1 segundo.

↓

R_1	R_2	$\dots$	R_k
-------	-------	---------	-------

Como descrever uma imagem? Inúmeras formas. Qual a melhor?

④ Ex: $(1, 50, 25, 35, \dots, 20)$

forma: $(0, 1, 1, 0, 0, 1, \dots)$


③ texture: (235, 35, 200, 120, ...)

1) Dados esses números que representam imagens, como combiná-las?
multiplicação

- sama
- subtraksi
- Rara
- Log.


Como conseguir boas comunicações? Programação Genética.

$f(d_1, d_2, d_3)$
descriptores
função de combinação







$$\frac{(d_1 * d_2) + \sqrt{d_3}}{d_4}$$

Reprodução



Recombinação





Questões interessantes

- ① Como seria se usássemos algoritmos genéticos?
- ② GP x GA? Qual é melhor?
PG x AG
- ③ E no caso específico de recuperação de imagens?

Lição da aula

- ① Computação evolutiva pode ajudar a resolver problemas difíceis.
- ② Util em machine Learning? Como?
 - ⊕ otimização.
 - ⊕ Busca de parâmetros.
 - ⊕ Estab. de soluções candidatas, etc.
- ③ Baseada em leis da natureza } seleção natural
mutação
reprodução.

- ④ Algoritmos Evolucionários não devem/mão podem ser considerados caixas-pretas prontos para o uso mas sim como um conjunto de procedimentos gerais que podem ser adaptados facilmente a diversas aplicações.

④ Considere o clássico problema TSP

↳ Traveling Salesperson problem

↳ Suponha que um indivíduo precise partir de um ponto A visitar outros 99 pontos diferentes e retornar a A. Dadas as coordenadas dos 100 pontos, descubra o percurso de menor distância que passe uma única vez por todos os ~~itens~~ pontos e retorne à origem A.

Pergunta-se ① Podemos usar AG? Porquê?

② Quantas combinações teríamos se tentássemos na força bruta?

③ Imagine e proponha uma codificação para o problema.

④ Como gerar uma solução inicial?

⑤ Proponha uma função de adequação.

Leitura Recomendada : * Computação Evolutiva : uma abordagem pragmática
Fernando Von Zuben.

Comparação com técnicas baseadas em Gradiente

⑥ Técnicas de descida do gradiente exigem

① função objetivo diferenciável.

② Baixo custo de diferenciação.

③ o que fazer se a diferenciação não é possível ou muito cara?