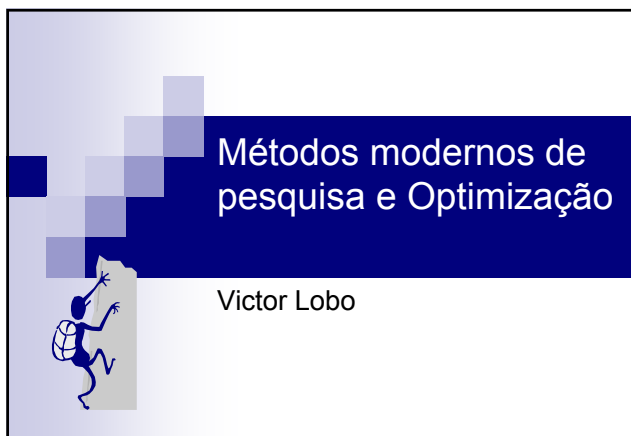


Cap.7 - Optimizaç o

V 3.0, V.Lobo, EN/ISEGI, 2005




M todos modernos de pesquisa e Optimizaç o

Victor Lobo

T picos


- Introduç o
- M todos matem ticos
- M todo de Monte Carlo
- Hill- Climbing
- Simulated Annealing
- Algoritmos Gen ticos
- Tabu Search



Tantos algoritmos novos!!!

Introduç o

- Problema de optimizaç o
 - Dada uma funç o $f(X)$
 - encontrar o seu  ptimo (m ximo ou m nimo)



Cada um faz a sua pesquisa!!!

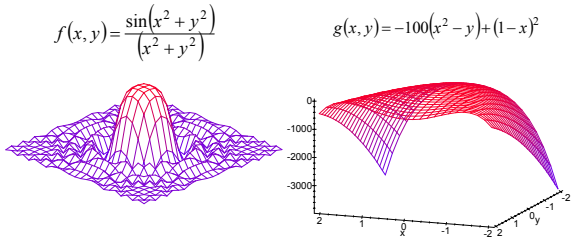
- Problema de pesquisa
 - Seja um *ponto inicial*
 - Encontrar o  ptimo da funç o $f(X)$
- Problema de pesquisa
 - Seja um conjunto de *pontos iniciais*
 - Encontrar o  ptimo da funç o $f(X)$

Propriedades de $f(X)$

- Dom nio
 - \mathbb{R}^n
 - \mathbb{I}^n
 - Sub conjunto de \mathbb{R}^n ou de \mathbb{I}^n
 - S mbolos
- Propriedades de $f(X)$
 - Deriv vel
 - N o deriv vel
- Optimizaç o Matem tica
 - Gradiente
- Optimizaç o com restriç es
 - Multiplicadores de Lagrange
- Optimizaç o Inteira
 - Investigaç o operacional
- M todos heur sticos
 - Hill- Climbing
 - Simulated Annealing
 - Algoritmos Gen ticos
 - Tabu Search


Exemplos

$$f(x, y) = \frac{\sin(x^2 + y^2)}{(x^2 + y^2)}$$

$$g(x, y) = -100(x^2 - y) + (1 - x)^2$$


Outros Exemplos

- Problema das N-Rainhas
 - Qual a funç o de optimizaç o
 - Problema de satisfaç o de restriç es
- "Assignment Problem"
 - Um conjunto de n pessoas   capaz de realizar n tarefas. O custo da pessoa i fazer a tarefa j   c_{ij} . Encontrar a atribuic o de tarefas (t_1, \dots, t_n) que minimize o custo



$$\begin{cases} X_i = \{1, \dots, N\} \\ X_j \neq X_i \quad \forall j \neq i \\ X_j \neq X_i \pm (j - i) \quad \forall j > i \\ i, j \in \{1, \dots, N\} \end{cases}$$

$$\text{m nimo} \sum_{i=1}^n c_{it_i}$$

Cap.7 - Optimizaçã

V 3.0, V.Lobo, EN/ISEGI, 2005

Mais outro exemplo

- Coloraçã de um grafo
 - Um grafo é definido por um conjunto de nós, alguns dos quais estã ligados entre si através de arcos. Dois nós ligados por um arco sã designados por adjacentes. O problema da coloraçã de um grafo é atribuir cores a cada um dos nós de tal modo que dois nós adjacentes nã tenham a mesma cor.
 - "O objectivo é encontrar o número mìnimo de cores capazes de colorir um grafo."

Mais exemplos

"0-1 Knapsack problem"

Um conjunto de "n" itens deve ser empacotado numa mochila com capacidade de C unidades. Existem v_i unidades de cada item "i" e usa c_i unidades de capacidade. Determine o subconjunto I de itens que podem ser empacotados de modo a maximizar

tal que

$$\begin{aligned} \text{máximo } & \sum_{i \in I} v_i \\ & \sum_{i \in I} c_i \leq C \end{aligned}$$

Tantos problemas giros!!!



Uma nova terminologia

- Estado → Soluçã
- Conjunto dos descendentes → Vizinhança
- Espaço de estados → Espaço de soluções

Porque!!!



Codificaçã dos estados e operadores

- Domínios em \mathfrak{R}^n
 - Codificaçã: vector com um ponto em \mathfrak{R}^n
 - Cálculo dos descendentes
 - Orientada: Método do gradiente
 - Não orientada: Adicionar vector aleatõrio por exemplo gaussiano
- Domínios simbólicos
 - Problema das N-rainhas
 - Exemplos de codificaçã
 - Vector de inteiros de 1 a N sem repetições
 - Exemplo do operador
 - Mudar duas das posições seleccionados aleatoriamente

Método do gradiente

- Seja uma funçã $f(x_1, \dots, x_n)$ derivável.

$$X = X_0 \pm \eta \nabla f(X) \Big|_{X=X_0}$$

- O mìnimo de $f(x_1, \dots, x_n)$ dado por
- O máximo de $f(x_1, \dots, x_n)$ dado por

$$\begin{cases} x_i^{t+1} = x_i^t - \eta \frac{\partial f(X)}{\partial x_i} \Big|_{X=X^t} \\ i = 1, \dots, n \wedge t = 0, \dots, T \end{cases} \quad \begin{cases} x_i^{t+1} = x_i^t + \eta \frac{\partial f(X)}{\partial x_i} \Big|_{X=X^t} \\ i = 1, \dots, n \wedge t = 0, \dots, T \end{cases}$$

Matemática!!!



Método do Gradiente

Problema: maximizar $f(X)$ em que $f(X)$ é derivável

Seleccionar uma soluçã inicial $X_0 \in \mathfrak{R}^n$


repita

$$X = X_0 + \eta \nabla f(X) \Big|_{X=X_0}$$

se $f(X) > f(X_0)$ entã $X_0 = X$

atã critério de paragem

X_0 é a soluçã.



Cap.7 - Optimizaç o

V 3.0, V.Lobo, EN/ISEGI, 2005

Hill-Climbing

Problema: maximizar $f(s)$

Seleccionar uma soluç o inicial $s_0 \in S$
repita

Seleccionar aleatoriamente $s \in N(s_0)$ $N(s_0)$   a vizinhança de s_0

se $f(s) > f(s_0)$

ent o $s_0 = s$; Contador = 0;

sen o Contador = Contador + 1

at  crit rio de paragem

s_0   a soluç o.




Exemplo do caixeiro viajante

■ Consideremos o espaço de soluç es representados pela sequ ncia de 6 letras, em que s  a primeira e a  ltima s o repetidas.

■ O conjunto de vizinhança definida pela troca de duas letras

■ Considere o ponto inicial *ABCDEA*



Soluç o

ADBCEA ou AECBDA

Problemas com o Hill-Climbing

■ P ra nas seguintes situaç es

M ximos locais

Planaltos

Arestas.

Kirkpatrick (1983)

“When optimising a very large system (i.e. a system with many degrees of freedom), instead of “always” going downhill, try to go downhill “most of the time”.

Annealing

■ Na f sica da m teria condensada refere-se como “annealing” o processo que se segue:

Um s lido num banho quente   aquecido, aumentando a temperatura at  um valor m ximo. A essa temperatura, todo o material encontra-se na fase l quida e as part culas arruma-se aleatoriamente

A temperatura do banho quente   arrefecida suavemente, permitindo que todas as part culas se arrumem num estado “ground” que corresponde ao estado de menor energia dessa estrutura.


Cap.7 - Optimizaç o

V 3.0, V.Lobo, EN/ISEGI, 2005

Algoritmo de Metropolis (1953)

- Desenvolvido para simular a evoluç o de um sistema f sico quente que tende para o estado de equil brio t rmico.
- Em cada passo do algoritmo, um  tomo do sistema   sujeito a um pequeno deslocamento aleat rio.
- Calcula-se a variaç o ΔE da energia do sistema.
 - Se $\Delta E < 0$ o deslocamento   aceite. Se n o o deslocamento s  ser  aceite com uma probabilidade
 - onde T   a temperatura $p(\Delta E) = e^{-\frac{\Delta E}{T}}$

Funç o $\exp(-\delta/T)$




Simulated annealing

Problema: minimizar $f(s)$
 Seleccionar uma soluç o inicial $s_0 \in S$; uma temperatura inicial $T > 0$; e uma funç o de reduç o de temperatura α

repita

```


    repita
        Seleccionar aleatoriamente  $s \in N(s_0)$  //  $N(s_0)$    a vizinhança de  $s_0$ 
         $\delta = f(s) - f(s_0)$ 
        se  $\delta < 0$  ent o  $s_0 = s$ ; Contador = 0;
        sen o
            seja  $x$  um n mero aleat rio entre 0 e 1
            se  $x < \exp(-\delta/T)$  ent o  $s_0 = s$ ; Contador = Contador + 1
    at  Contador = Nmax
     $T = \alpha(T)$ 
    at  crit rio de paragem
     $s_0$    a soluç o.
    
```



Algoritmos Gen ticos

- Baseado na simulaç o da din mica de populaç es
- A pesquisa   baseada em populaç es
- Terminologia
 - *Populaç o* - conjunto de descriç es de indiv duos
 - *Cromossoma* - descriç o de um indiv duo
 - *Gene* - Posiç o dentro do cromossoma
 - *Alelo* - Valor existente no gene
 - *fitness* - medida de adaptaç o do indiv duo ao meio ambiente

Esquema b sico



Um exemplo muito simples

- Encontrar o m ximo da funç o $f(x) = x^2$ no dom nio $[0, 31]$
- Exemplo de cromossomas
 - [00000] $\rightarrow x = 0$
 - [01100] $\rightarrow x = 12$
 - [11101] $\rightarrow x = 29$
- Qual a funç o de fitness?
 - $f(x)$
- Como codificar?
 - Utilizaremos uma codificaç o bin ria de 5 bits

Cap.7 - Optimizaçã

V 3.0, V.Lobo, EN/ISEGI, 2005

Operadores

- Selecciona para reprodução
 - Uniforme
 - Roleta
 - Integral
 - Torneio
- Reprodução
 - Depende do problema*
 - Cruzamento 1 ponto
 - Cruzamento de n pontos
- Mutação
 - Depende do problema*
 - Inverso
 - Troca de dois genes
- Substituição
 - Completa
 - Parcial com selecciona
 - Uniforme
 - Roleta
 - Torneio

Selecçã para a reproduçã

- A hipótese de um indivíduo ser seleccionado para a reproduçã é funçã do seu fitness
- Roleta
 - Escolha aleatória e directamente proporcional ao seu fitness
- Integral
 - Respeita a muito rigidamente o fitness relativo
- Torneio
 - Dois indivíduos seleccionados aleatoriamente disputam um torneio. O melhor passa.

Processo de selecciona para o exemplo

Desc.	Crom.	X	f(x)	$\frac{f(x)}{\sum f}$	$\frac{f}{7}$	Selec.
1	01101	13	169	0.14	0.58	1
2	11000	24	576	0.49	1.97	2
3	01000	8	64	0.06	0.22	0
4	10011	19	361	0.31	1.23	1
Soma				1.00	4.0	
Média				0.25	1.0	
Máximo				0.49	1.97	

Cruzamento

- 1 Ponto de cruzamento
 - Sejam dois cromossomas de dimensã "N". Selecciona-se aleatoriamente um ponto de corte do cromossoma (1...(N-1)). Cada um dos dois descendentes recebe informaçã genética de cada um dos pais

Exemplo
 Cr 1 - 11101001
 Cr 2 - 10101101
 Seja o ponto de cruzamento 4
 Cr 1 - 11101001
 Cr 2 - 10101101
 Descendentes
 Desc 1 - 11101101
 Desc 2 - 10101001

Cruzamento - Outro exemplo

- 2 pontos de cruzamento
 - Semelhante ao caso anterior mas agora com a escolha de dois pontos de corte
- Exemplo
 - Dois cromossomas pais
 - Dois descendentes

Processo de cruzamento para o exemplo

Cromos.	Cônjuge	Ponto de Cruzamento	Nova Populaçã	Valor x	f(x)
0 1 1 0 1	2	4	0 1 1 0 0	12	144
1 1 0 0 0	1	4	1 1 0 0 1	25	625
1 1 0 0 0	4	2	1 1 0 1 1	27	729
1 0 0 1 1	3	2	1 0 0 0 0	16	256
Soma					1754
Média					439
Máximo					729

Cap.7 - Optimizaç o

V 3.0, V.Lobo, EN/ISEGI, 2005

Tabu Search

- Algoritmo de pesquisa com um  nico ponto
- Proposto por Fred Glover
- Tem mem ria
 - Memoriza os  ltimos movimento
 - Tabela de Tabu

Exemplo do "Tabu Search"

- Pretende-se construir um m dulo de material isolante composto por 7 camadas de diferentes materiais
- Codificaç o

2	5	7	3	4	6	1
---	---	---	---	---	---	---
- Operador de vizinhança
 - Trocar dois m dulos entre si




Tabela de Tabu

	2	3	4	5	6	7
1						
	2					
		3				
			4			
				5		
					6	

Itera o 0

2	5	7	3	4	6	1
---	---	---	---	---	---	---

$f(X) = 10$

↓

2	4	7	3	5	6	1
---	---	---	---	---	---	---

$f(X) = 16$

Tabela de Tabu

	2	3	4	5	6	7
1						
	2					
		3				
			4			
				5		
					6	

N(X) Δf

5,4	6
7,4	4
3,6	2
2,3	0
4,1	-1

Itera o 1

2	4	7	3	5	6	1
---	---	---	---	---	---	---

$f(X) = 16$

↓

2	4	7	1	5	6	3
---	---	---	---	---	---	---

$f(X) = 18$

Tabela de Tabu

	2	3	4	5	6	7
1						
	2					
		3				
			4	3		
				5		
					6	

N(X) Δf

3,1	2
2,3	1
3,6	-1
7,1	-2
6,1	-4

Itera o 2

2	4	7	1	5	6	3
---	---	---	---	---	---	---

$f(X) = 18$

↓

4	2	7	1	5	6	3
---	---	---	---	---	---	---

$f(X) = 14$

Tabela de Tabu

	2	3	4	5	6	7
1		3				
	2					
		3				
			4	2		
				5		
					6	

N(X) Δf

1,3	-2
2,4	-4
7,6	-6
4,5	-7
5,3	-9

Cap.7 - Optimizaç o

V 3.0, V.Lobo, EN/ISEGI, 2005

Itera o 3 - Aspira o

$f(X) = 14$
 $f(X) = 20$

Tabela de Tabu

	2	3	4	5	6	7	N(X)	Δf	
1	2						4,5	6	T ←
2		3					5,3	2	
3			4				7,1	0	
4				1			1,3	-3	T
5					1		2,6	-6	
6						1			

Itera o 4

$f(X) = 20$

Tabela de Tabu

	2	3	4	5	6	7	N(X)	Δf	
1	1						7,1	0	T ←
2		2					4,3	-3	
3			3				6,3	-5	
4				3			5,4	-6	T
5					3		2,6	-8	
6						1			

Bibliografia

- Colin R, Reeves, Modern Heuristic Techniques for Combinatorial Problems, McGraw-Hill
- David E. Goldberg, Genetic Algorithms in search Optimization & Machine Learning, Addison Wesley