

Optimização Numérica

Rui Mendes

11 de Maio de 2016

- Conjunto de variáveis numéricas ($X \in \mathbb{R}^n$)
- Função objectivo $f : \mathbb{R}^n \rightarrow \mathbb{R}$
- Pretende-se descobrir um valor de X para o qual a função objectivo tenha o seu máximo ou mínimo
- $\{X \in \mathbb{R}^n \mid \forall Y \in \mathbb{R}^n f(X) \leq f(Y)\}$ se estivermos a falar de minimização
- Estamos sobretudo interessados em optimização não linear
- E em casos em que não tenhamos informação sobre o gradiente



- 1 Começa-se com um valor inicial $X \in \mathbb{R}^n$
- 2 Este valor poderá ser gerado aleatoriamente
- 3 Escolhe-se um valor Y na vizinhança de X
- 4 Se a função objectivo tiver um valor melhor para Y então passa-se para Y
- 5 Repete-se este processo enquanto houverem melhoras

- Fácil de implementar
- Rápido

- Qual é a desvantagem deste método?
- A estagnação.
- Também conhecida por convergência prematura.
- O que é a convergência prematura?
- É quando o algoritmo encrava num óptimo local.
- Isso acontece porque todos os pontos na vizinhança têm soluções de qualidade pior do que a actual.

- Qual é a desvantagem deste método?
- A estagnação.
- Também conhecida por convergência prematura.
- O que é a convergência prematura?
- É quando o algoritmo encrava num óptimo local.
- Isso acontece porque todos os pontos na vizinhança têm soluções de qualidade pior do que a actual.

- Qual é a desvantagem deste método?
- A estagnação.
- Também conhecida por convergência prematura.
- O que é a convergência prematura?
- É quando o algoritmo encrava num óptimo local.
- Isso acontece porque todos os pontos na vizinhança têm soluções de qualidade pior do que a actual.

- Qual é a desvantagem deste método?
- A estagnação.
- Também conhecida por convergência prematura.
- O que é a convergência prematura?
- É quando o algoritmo encrava num óptimo local.
- Isso acontece porque todos os pontos na vizinhança têm soluções de qualidade pior do que a actual.

- Qual é a desvantagem deste método?
- A estagnação.
- Também conhecida por convergência prematura.
- O que é a convergência prematura?
- É quando o algoritmo encrava num óptimo local.
- Isso acontece porque todos os pontos na vizinhança têm soluções de qualidade pior do que a actual.

- Qual é a desvantagem deste método?
- A estagnação.
- Também conhecida por convergência prematura.
- O que é a convergência prematura?
- É quando o algoritmo encrava num óptimo local.
- Isso acontece porque todos os pontos na vizinhança têm soluções de qualidade pior do que a actual.



- Uma solução;
- Começa-se com uma temperatura elevada;
- Aceitam-se sempre soluções melhores;
- Aceitam-se soluções piores com uma probabilidade que desce com a temperatura;
- A temperatura desce com o tempo;
- Para cada temperatura fazem-se várias iterações;
- Convenciona-se chamar energia à qualidade da solução;
- Uma solução melhor tem menos energia.

- E_t Energia no tempo actual;
- E_{t-1} Energia no tempo anterior;
- T Temperatura.
- ΔE $E_t - E_{t-1}$

Probabilidade de transição

$$\begin{aligned}\Delta E \leq 0 &\implies 1 \\ \Delta E > 0 &\implies e^{\frac{-\Delta E}{T}}\end{aligned}$$



- ➊ Gerar aleatoriamente a solução inicial;
- ➋ Calcular a sua energia;
- ➌ Se ainda não se atingiu a temperatura mínima;
- ➍ Para cada uma de N experiências;
 - ➊ Perturbar localmente a solução (pode depender da temperatura);
 - ➋ Calcular a energia da nova solução;
 - ➌ Se a energia da nova solução é menor aceita-se;
 - ➍ Se for mais alta aceita-se com probabilidade $e^{\frac{-\Delta E}{T}}$;
- ➎ Desce-se a temperatura e volta-se ao ponto 3.

- 1 $T_k = a \cdot T_{k-1}$ (ou escrito de outra maneira $T_k = a^k \cdot T_0$) em que $0 < a < 1$;
- 2 $T_k = \frac{c}{\log k + d}$ em que d é normalmente 1.
- 3 O esquema 1 é o mais usado, mas não garante a solução ótima.
- 4 O esquema 2 com um c suficientemente elevado (a maior energia possível encontrada no problema) garante a convergência; mas é muito lento.



- Temperatura inicial T_0
- Temperatura final ou n° de descidas de temperatura
- N° de iterações para cada temperatura
- Esquema de arrefecimento (valor do a para o esquema 1)
- Tipo de perturbação local à solução actual (e.g., mutação gaussiana)
- Se usar mutação gaussiana: σ (desvio padrão da mutação)



- Procura local;
- Ao aceitar soluções de pior qualidade pode-se sair de mínimos locais de energia;
- À medida que a temperatura vai descendo, a probabilidade de aceitar soluções piores baixa;
- Se o arrefecimento for demasiado rápido o algoritmo estagna;
- Se o arrefecimento for demasiado lento o algoritmo não é eficiente;
- Teoricamente encontra sempre a solução óptima (se o arrefecimento for suficientemente lento);
- Pode funcionar em problemas de optimização combinatória.



- Usa uma população de soluções;
- Só se aceitam soluções melhores;
- Há dois operadores:
 - Um esquema de mutação diferencial;
 - Cruzamento uniforme
- O cruzamento é entre o individuo actual e um gerado pelo esquema de mutação;
- O cruzamento só gera uma solução e não duas como nos algoritmos genéticos.

$$\text{DE/rand/1} \quad x_1 + F \cdot (x_2 - x_3)$$

$$\text{DE/best/1} \quad x_b + F \cdot (x_1 - x_2)$$

$$\text{DE/rand-to-best/1} \quad x_1 + F \cdot (x_b - x_1) + F \cdot (x_2 - x_3)$$

$$\text{DE/rand/2} \quad x_1 + F \cdot (x_2 - x_3) + F \cdot (x_4 - x_5)$$

$$\text{DE/rand/2} \quad x_b + F \cdot (x_1 - x_2) + F \cdot (x_3 - x_4)$$

- x_i é a solução actual;
- x_1, x_2, x_3, x_4, x_5 são soluções todas diferentes entre si e diferentes de x_i ;
- x_b é a melhor solução da população
- F é um número real (normalmente entre 0 e 1)

- 1 Para cada x_i
- 2 Cria-se um x_m usando o esquema de mutação (e.g.,
$$x_m = x_1 + F \cdot (x_2 - x_3)$$
)
- 3 Cria-se x_t através do cruzamento uniforme entre x_i e x_m com probabilidade CR (usa-se pelo menos um elemento de x_m)
- 4 Avalia-se a qualidade de x_t
- 5 x_t substitui x_i se tiver melhor qualidade
- 6 Caso contrário x_i mantém-se na nova população



- ➊ Inicializa-se a população;
- ➋ Avalia-se a população;
- ➌ Para cada individuo da população x_i :
 - ➊ Segue-se o procedimento do slide anterior para gerar x_t ;
 - ➋ Avalia-se a qualidade de x_t ;
 - ➌ x_t substitui x_i se tiver melhor qualidade
 - ➍ Senão x_i passa para a nova população
- ➍ Passa-se a usar a nova população;
- ➎ Salta-se para 3 até atingir o n° máximo de iterações.



- Tamanho da população (normalmente é pequeno ~ 20);
- Esquema utilizado (normalmente DE/rand/1);
- F (com o esquema anterior 0.5 costuma funcionar bem);
- CR (com o esquema acima 0.6 costuma funcionar bem)



- Muito rápido;
- Fácil de implementar;
- Poucos parâmetros;
- Muito robusto.

- Inspirado em psicologia social e simulação de bandos de pássaros;
- Usa uma população de indivíduos;
- Cada indivíduo tem uma posição e uma velocidade;
- Em cada iteração, cada indivíduo actualiza a velocidade mediante uma aceleração usando dois componentes:
 - A atração em relação à melhor posição encontrada no passado;
 - A atração em relação à melhor posição encontrada pelo grupo no passado;



Parâmetros

Posição Posição actual $\vec{x}_i$;

Velocidade Velocidade $\vec{v}_i$;

Individualismo A melhor posição alcançada $\vec{p}_i$;

Conformismo A melhor posição encontrada pelos seus vizinhos $\vec{p}_g$;

Parâmetros $\varphi_1 = \varphi_2 = 2.05, \chi = 0.729$.

Algoritmo

$$\begin{cases} \vec{v}_i = \chi(\vec{v}_i + \vec{U}[0, \varphi_1](\vec{p}_i - \vec{x}_i) + \vec{U}[0, \varphi_2](\vec{p}_g - \vec{x}_i)) \\ \vec{x}_i = \vec{x}_i + \vec{v}_i \end{cases}$$



- 1 Inicializar a população;
- 2 Avaliar a qualidade dos indivíduos;
- 3 Para cada indivíduo:
 - 1 Escolher indivíduos na sua vizinhança;
 - 2 Imitar esses indivíduos;
 - 3 Actualizar a melhor experiência caso o valor actual seja melhor;
- 4 Iterar para 2 se ainda não atingimos o critério de paragem.



- Rápido;
- Contém elitismo;
- Fácil de implementar.



- Inspirado na improvisação da música Jazz;
- Usa um armazém de soluções (harmonias);
- Em cada iteração gera-se uma nova harmonia;
- A nova harmonia é gerada combinando partes das harmonias existentes no armazém;
- Existe uma componente de inspiração que modifica partes da nova harmonia;
- A harmonia gerada substitui a pior harmonia do armazém se for melhor do que esta.

- ➊ Para cada coordenada:
- ➋ Com probabilidade **hmcr** (*Harmony Memory Considering Rate*):
 - ➊ Usa-se o valor de uma coordenada duma harmonia escolhida aleatoriamente de dentro do armazém;
 - ➋ Com probabilidade **par** (*Pitch Adjusting Rate*) perturba-se esse valor;
- ➌ Se não se fez o ponto anterior escolhe-se um valor aleatório para essa coordenada;
- ➍ Avalia-se a nova harmonia.



Se se pretender perturbar o valor de uma coordenada x :

$$x = x + fw \cdot U[-1, 1] \cdot amplitude$$

em que:

fw é o parâmetro *Fret Width*

amplitude é a amplitude dessa coordenada, i.e., se x pode ter valores no intervalo $[a; b]$ então amplitude é $b - a$

$U[-1, 1]$ dá valores aleatórios segundo a distribuição uniforme entre -1 e 1



hms	Harmony Memory Size	~ 30
hmcr	Harmony Memory Considering Rate	~ 0.9
par	Pitch Adjusting Rate	~ 0.7
fw	Fret Width	$\sim [0.0001; 0.001]$



- Simples de implementar;
- A selecção é interessante porque é a substituição da pior harmonia do armazém;
- A selecção é mais suave do que o DE;
- Pode ser adaptado a problemas de optimização combinatoria



Problemas

- 1 Esfera
- 2 Problema XOR
- 3 Problema Multiplexador

Algoritmos

- 1 Simulated Annealing
- 2 Particle Swarm Optimization
- 3 Differential Evolution



Minimizar

$$f(x) = \sum_{i=1}^N (x_i - a_i)^2$$

$$N = 30$$

$$-100 \leq x_i \leq 100$$

$$-80 \leq a_i \leq 80$$

em que a_i é escolhido previamente



Treinar uma **feed forward neural network** para o problema do XOR.

x_1	x_2	r
0	0	0
0	1	1
1	0	1
1	1	0

Usar uma rede com 2 neurónios na camada de entrada, 2 neurónios na camada intermédia e 1 neurónio de saída.



Treinar uma **feed forward neural network** para o problema do multiplexador.

x_1	x_2	c	r
0	0	0	0
0	1	0	0
1	0	0	1
1	1	0	1
0	0	1	0
0	1	1	1
1	0	1	0
1	1	1	1

Usar uma rede com 3 neurónios na camada de entrada, 6 neurónios na camada intermédia e 1 neurónio de saída.