

OTIMIZAÇÃO

Método do Gradiente (Máxima Descida)

Equação de Busca

Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$, uma função a minimizar; i. e., deseja-se encontrar $x^* \in \mathbb{R}^n$, tal que $f(x^*)$ seja mínima.

Supondo que x^p é um vetor próximo de x^* , obtém-se, através do desenvolvimento de $f(x)$ em série de Taylor:

$$f(x^p + \delta x) = f(x^p) + [f'(x^p)]^T \delta x + \frac{1}{2} H^T \delta x^2 H + \dots$$

Assim:

$$f(x^p + \delta x) - f(x^p) = \nabla f(x^p) \cdot \delta x$$

ou:

$$[-\nabla f(x^p)] \cdot [dx] = f(x^p) - f(x^p + \delta x)$$

Para que a redução em f seja a máxima possível, é necessário que o produto escalar do 1º membro seja máximo, ou seja:

$$\delta x = -c \nabla f(x^p) \text{ (colineares)}$$

Considerando $\delta x = x^{(p+1)} - x^{(p)}$, fica:

$$x^{(t+1)} = x^{(t)} - c \nabla f(x^{(t)})$$

onde:

$c \rightarrow$ Passo do método

Ex.: O presente exemplo tem por objetivo mostrar a influência do valor do passo c na convergência do método. Para tanto, será analisado o caso simples de uma função de duas variáveis, sem restrições, definida por:

$$f(x, y) = x^2 - 2x + y^2$$

Calculando as derivadas parciais para formação do vetor gradiente, tem-se:

$$\frac{\partial f}{\partial x} = 2x - 2 \qquad \frac{\partial f}{\partial y} = 2y$$


Aplicando a equação determinada anteriormente:

$$\begin{bmatrix} x \\ y \end{bmatrix}^{(t+1)} = \begin{bmatrix} x \\ y \end{bmatrix}^{(t)} - c \cdot \begin{bmatrix} 2x - 2 \\ 2y \end{bmatrix}^{(t)}$$

A fim de comprovar a dependência da convergência com o passo, adotou-se como iniciação o ponto $(x_0; y_0) = (-1; 1)$ e testam-se 3 valores distintos para c : $c = 1,50$; $c = 0,75$ e $c = 0,50$.


Para $c = 1,50$:

<i>iter</i>	0	1	2	3
<i>x</i>	-1	5	-7	17
<i>y</i>	1	-2	4	-8



Para $c = 0,75$:


<i>iter</i>	0	1	2	3	4	...
<i>x</i>	-1	2	0.50	1.25	0.875	...
<i>y</i>	1	-0.5	0.25	-0.125	0.0625	...



Para $c = 0,50$:

<i>iter</i>	0	1	...
<i>x</i>	-1	1	...
<i>y</i>	1	0	...

Notar que, para $(x; y) = (1; 0)$ o vetor gradiente se anula. Portanto, esse é o ponto de ótimo da função, que, para $c = 0,50$, é alcançado em uma única iteração.



Método do Gradiente Ótimo

O fator c determina o tamanho do passo na direção de máxima descida.

Aqui se estabelece um sub-problema de otimização: determinar o melhor valor para c .

Isso pode ser resolvido através de uma busca unidirecional, tomando como variável o parâmetro c e aproximando a função $f(x - c \nabla f(x))$ por uma parábola, definida pelos seguintes parâmetros:

- Valor da função objetivo na iteração mais recente:

$$f_0 = f(c = 0)$$


- Inclinação da função para $c = 0$:

$$\frac{df(x - c \nabla f)}{dc} = \frac{df(x)}{dc} \cdot (-\nabla f) = \nabla^T f \cdot (-\nabla f)$$
$$f'_0 = \frac{df}{dc} = -\nabla^T f \cdot \nabla f$$

- Valor da função para um passo-teste c_T :

$$f_T = f(c = c_T)$$

A parábola assim definida é mostrada na figura a seguir:



A equação da parábola fica:

$$p = f_0 + f'_c + \frac{[f_T - (f_0 + f'_c c_T)]}{c_T^2} \cdot c^2$$

e o valor ótimo de c fica:

$$\tilde{c}_{ot} = \frac{1}{2} \left[\frac{(c_T^2 f'_0)}{(f_0 + c_T f'_0 - f_T)} \right]$$

Supondo ainda uma função objetivo quadrática:

$$f(x) = \frac{1}{2} x^T H x + b^T x + a$$

então, $\nabla f(x)$ é dado por:

$$\nabla f(x) = H x + b$$

A busca linear exata para $x^{(a)} = x + c d$ é:

$$\begin{aligned} f(x + c d) &= \frac{1}{2} (x + c d)^T H (x + c d) + b^T (x + c d) + a \\ &= \frac{1}{2} x^T H x + (c d^T H + b^T) \cdot x + \frac{1}{2} c^2 d^T H d + c b^T d + a \end{aligned}$$

Então:

$$\begin{aligned} \frac{df(x + c d)}{dc} &= d^T H x + c d^T H d + b^T d = 0 \\ &= d^T H x + c d^T H d + d^T b = 0 \\ c d^T H d &= -d^T (H x + b) \\ c &= -\frac{d^T \nabla f}{d^T H d} \end{aligned}$$

Como $d = -\nabla f$

$$c = \frac{\nabla^T f \cdot \nabla f}{\nabla^T f \cdot H \cdot \nabla f}$$

Ex.: Realizar uma busca linear exata para a função:

$$f(x, y) = x^2 - 2x - y + y^2 \quad \nabla f = \begin{bmatrix} 2x - 2 \\ 2y - 1 \end{bmatrix}$$

$$\begin{aligned} f(x_0 - c(2x_0 - 2), y_0 - c(2y_0 - 1)) &= [x_0 - c(2x_0 - 2)]^2 - \\ &- 2[x_0 - c(2x_0 - 2)] - [y_0 - c(2y_0 - 1)] + [y_0 - c(2y_0 - 1)]^2 \\ &= x_0^2 - 2cx_0(2x_0 - 2) + c^2(2x_0 - 2)^2 - 2[x_0 - c(2x_0 - 2)] + \\ &+ y_0^2 - 2cy_0(2y_0 - 1) + c^2(2y_0 - 1)^2 - [y_0 - c(2y_0 - 1)] \\ &= c^2[(2x_0 - 2)^2 + (2y_0 - 1)^2] - c[(2x_0 - 2)(2x_0) - 2(2x_0 - 2) + \\ &+ (2y_0)(2y_0 - 1) - (2y_0 - 1)] + x_0^2 + y_0^2 - 2x_0 - y_0 \\ &= c^2 \left[\underbrace{(2x_0 - 2)^2 + (2y_0 - 1)^2}_z \right] - c \left[\underbrace{(2x_0 - 2)^2 + (2y_0 - 1)^2}_z \right] + \\ &+ x_0^2 + y_0^2 - 2x_0 - y_0 \end{aligned}$$

$$\frac{\partial f}{\partial c} = 0 \Rightarrow 2cz - z = 0 \Rightarrow \text{para } z \neq 0 \text{ tem-se: } c_{ot} = 1/2 = 0.5$$

$$\text{para } x_0 = 5, y_0 = -5 \quad \nabla f = [8, -11]^T \Rightarrow \begin{cases} x_{ot} = 5 - 0.5 \times 8 = 1 \\ y_{ot} = -5 - 0.5 \times (-11) = 0.5 \end{cases}$$

$$\text{para } x_0 = -3, y_0 = 2 \quad \nabla f = [-8, 3]^T \Rightarrow \begin{cases} x_{ot} = -3 - 0.5 \times (-8) = 1 \\ y_{ot} = 2 - 0.5 \times (3) = 0.5 \end{cases}$$

Observa-se que, como a função objetivo é quadrática, adoção do passo ótimo para qualquer ponto de partida leva à obtenção do ótimo em uma única iteração.