

# Gradiente Conjugado

## Optimización no restringida

Gamaliel Moreno

Maestría en Ciencias del Procesamiento de la Información

Ene-Julio, 2020

El método de gradiente conjugado es una técnica matemática que puede ser útil para optimizar problemas lineales y no lineales. Este método fue desarrollado por Magnus Hestenes y Eduard Stiefel.



Hay un conjunto de ecuaciones lineales que queremos resolver representadas en notación vectorial como:

$$\mathbf{Ax} = \mathbf{b}$$

$A$  es una matriz definida simétrica, real y positiva conocida  $n \times n$ ,  $b$  es un vector conocido y queremos resolver el vector  $x$ . Una solución única a este problema está representada por el vector  $x^*$ .

Recuerda

$$f(x) \approx f(x^k) + (x - x^k)^T \nabla f(x^k) + \frac{1}{2}(x - x^k)^T H(x^k)(x - x^k)$$

Derivando

$$\nabla f(x) \approx \nabla f(x^k) + H(x^k)(x - x^k)$$

Igualando a cero y siendo  $H$  sdp ( $x^T Hx > 0$ )

$$H(x^k)(x - x^k) = -\nabla f(x^k)$$

Hay un conjunto de vectores conjugados  $P$  donde  $P = \{p_k : \forall i \neq k, i, k \in [1, n], \langle p_i, p_k \rangle\}$ . Usando este conjunto  $P$  la solución  $x^*$  puede ser expresado como

$$x^* = \sum_{i=1}^n \alpha_i p_i$$

y de esto se obtiene

$$b = Ax^* = \sum_{i=1}^n \alpha_i Ap_i$$

sustituyendo

$$p_k^T b = \alpha_k p_k^T A p_k$$

entonces el coeficiente  $\alpha$  puede calcularse con

$$\alpha_k = \frac{\langle p_k, b \rangle}{\|p_k\|^2}$$

Para el caso específico de minimización

$$H(x^k)(x - x^k) = -\nabla f(x^k)$$

Esto sugiere tomar el primer vector base  $p_0$  como negativo del gradiente de  $f$  en  $x = x_0$ . Comenzando con una suposición inicial  $x_0$ , esto significa que tomamos  $p_0 = b - Ax_0$ . Los otros vectores en la base se conjugarán con el gradiente, de ahí el nombre de método de *gradiente conjugado*.

El método de gradiente conjugado es un método de primer orden, pero tiene la propiedad de la convergencia cuadrática y, por lo tanto, tiene una ventaja significativa sobre los métodos de segundo orden. Se dice que dos direcciones,  $S_1$  y  $S_2$ , se conjugan si

$$S_1^T H S_2 = 0$$

donde  $H$  es una matriz simétrica.

Las direcciones ortogonales son direcciones conjugadas. Iniciando en el punto  $x_{1a}$ , La dirección de búsqueda  $S_1$  resulta en el punto mínimo  $x_a^*$ . Similarmente, iniciando en el punto  $x_{1b}$ . El resultado de la búsqueda en dirección  $S_1$  en el punto mínimo  $x_b^*$ . La línea que une  $x_a^*$  y  $x_b^*$  es la búsqueda de dirección  $S_2$ , entonces  $S_1$  y  $S_2$  son direcciones conjugadas.

El método del paso más descendente fue modificado por Fletcher y Reeves en el método del gradiente conjugado. Iniciando con la dirección de búsqueda

$$S_1 = -\nabla f(x_1)$$

y subsecuentemente la dirección de búsqueda es tomado como combinación lineal de  $S_1$  y  $-\nabla f(x_2)$ . Eso es

$$S_2 = -\nabla f(x_2) + \alpha S_1$$

Usando la propiedad de  $S_1^T H S_2 = 0$  de las direcciones conjugadas,  $\alpha$  puede ser evaluada con

$$\alpha = \frac{\|\nabla f(x_{i+1})\|^2}{\|\nabla f(x_i)\|^2}$$

Iniciando con  $S_1 = -\nabla f(x_1)$ , la dirección de búsqueda en cada iteración es calculada usando la ecuación

$$S_{i+1} = -\nabla f(x_i) + \frac{\|\nabla f(x_{i+1})\|^2}{\|\nabla f(x_i)\|^2} S_i$$

# Método gradiente conjugado Fletcher-Reeves