

# Método de Gradientes Conjugados.

LOURDES FABIOLA URIBE RICHAUD & JUAN ESAÚ TREJO ESPINO.

Instituto Politécnico Nacional  
Escuela Superior de Física y Matemáticas

February 17, 2015

## 1 Método de Direcciones Conjugadas.

El método de direcciones conjugadas es un método iterativo para resolver un sistema lineal de ecuaciones  $Ax = b$  donde  $A \in \mathcal{M}_n(\mathbb{R}^n)$  es simétrica y definida positiva.

Como sabemos el resolver el sistema de ecuaciones es equivalente al problema de minimizar la función  $\phi(x)$  definida como:

$$\phi(x) = \frac{1}{2}x^T Ax - x^T b$$

Notemos que  $\nabla\phi(x) = Ax - b$ . Entonces definimos el residuo en cada iteración como  $r(x_k) = \nabla\phi(x_k) = Ax_k - b$ .

**Definición 1** Sea  $\mathbf{P} = \{p_0, \dots, p_k\}$  un conjunto de vectores no nulos, sea  $A \in \mathcal{M}_n(\mathbb{R}^n)$  simétrica y definida positiva. Se dice que  $\mathbf{P}$  es un conjunto conjugado con respecto a  $A$  si

$$\langle p_i, p_j \rangle_A = p_i^T A p_j = 0 \quad \text{para toda } i \neq j$$

Se puede demostrar que cualquier conjunto de vectores que es conjugado, es además un conjunto linealmente independiente. Así, dado un punto  $x_0$  y un conjunto conjugado  $\{p_0, \dots, p_{n-1}\}$ , el método de direcciones conjugadas genera la sucesión

$$x_{k+1} = x_k + \alpha_k p_k$$

donde  $\alpha_k$  es el valor que minimiza la función  $g(\alpha) = \phi(x_k + \alpha p_k)$  y está definido por

$$\alpha_k = -\frac{r_k^T p_k}{p_k^T A p_k}$$

**Teorema 1** Sea  $x_0 \in \mathbb{R}^n$  y  $\{p_1, \dots, p_{n-1}\}$  un conjunto conjugado. Entonces la sucesión generada por el algoritmo de direcciones conjugadas converge a la solución del sistema  $Ax = b$  en a lo más  $n$  iteraciones.

**Demostración 1** Denotemos por  $x^*$  a la solución del sistema  $Ax = b$ . Dado que el conjunto de direcciones  $\{p_0, p_1, \dots, p_{n-1}\}$  es linealmente independiente éste genera al espacio y podemos escribir la diferencia de  $x^*$  y  $x_0$  de la siguiente manera:

$$x^* - x_0 = \sigma_0 p_0 + \sigma_1 p_1 + \dots + \sigma_{n-1} p_{n-1} \quad (1)$$

donde  $\sigma_k \in \mathbb{R}$  para  $k = 0, \dots, n-1$ . Al multiplicar (1) por  $p_k^T A$  y usando la propiedad de conjugados tenemos

$$\begin{aligned} p_k^T A(x^* - x_0) &= \sigma_0 p_k^T A p_0 + \dots + \sigma_k p_k^T A p_k + \dots + \sigma_{n-1} p_k^T A p_{n-1} \\ p_k^T A(x^* - x_0) &= \sigma_k p_k^T A p_k \\ \sigma_k &= \frac{p_k^T A(x^* - x_0)}{p_k^T A p_k} \end{aligned} \quad (2)$$

Como  $x_k$  es generada por el método de direcciones conjugados, tenemos que

$$x_k = x_0 + \alpha_0 p_0 + \dots + \alpha_{k-1} p_{k-1}$$

Multiplicamos ésta expresión por  $p_k^T A$  y usando la propiedad de conjugado

$$\begin{aligned} p_k^T A(x_k - x_0) &= \alpha_0 p_k^T A p_0 + \dots + \alpha_{k-1} p_k^T A p_{k-1} = 0 \\ p_k^T A x_k &= p_k^T A x_0 \end{aligned}$$

por lo que

$$p_k^T A(x^* - x_0) = p_k^T A(x^* - x_k) = p_k^T (Ax^* - Ax_k) = p_k^T (b - Ax_k) = -p_k^T r_k$$

Usando esta expresión en (2) encontramos que

$$\sigma_k = -\frac{r_k^T p_k}{p_k^T A p_k} = \alpha_k$$

Finalmente de (1) tenemos que

$$x^* = x_0 + \sum_{j=0}^{n-1} \alpha_j p_j = x_n$$

Por lo que la solución  $x^*$  se obtiene a lo más al calcular en el  $n$ -ésimo paso a  $x_n$ .

**Teorema 2** Sea  $x_0 \in \mathbb{R}^n$  un punto inicial y supongamos que la sucesión  $\{x_n\}_{n \in \mathbb{N}}$  es generada por el algoritmo de Direcciones Conjugadas. Entonces:

1.  $r_k^T p_i = 0$  para  $i = 0, \dots, k-1$
2.  $x_k$  es el punto que minimiza  $\phi(x) = \frac{1}{2} x^T A x - b^T x$  sobre  $x + \text{gen}\{p_0, \dots, p_{k-1}\}$ .

**Demostración 2** Primero mostraremos que  $r_k^T p_i = 0$  para  $i = 0, \dots, k-1$ . Procedemos por inducción.

Para  $k = 0$ . Tenemos la fórmula recursiva del residuo  $r_{k+1} = r_k + \alpha_k A p_k$ , entonces:

$$r_1 = r_0 + \alpha_0 A p_0,$$

trasponiendo esta expresión y multiplicandola por  $p_0$ , tenemos:

$$r_1^T p_0 = r_0^T p_0 + \alpha_0 p_0^T A p_0,$$

sustituyendo  $\alpha_0$  por su expresión en el algoritmo vemos que:

$$r_1^T p_0 = r_0^T p_0 - \frac{r_0^T p_0}{p_0^T A p_0} p_0^T A p_0 = 0.$$

Por lo tanto se cumple para  $k = 0$ .

Ahora suponemos que se cumple para algún  $k-1$ , es decir,  $r_{k-1}^T p_i = 0$  para  $i = 0, \dots, k-2$ . Queremos probar que se cumple para  $k$ . Observe que:

$$r_k = r_{k-1} + \alpha_{k-1} A p_{k-1},$$

trasponiendo esta expresión y multiplicando la por  $p_{k-1}$ , tenemos:

$$r_k^T p_{k-1} = r_{k-1}^T p_{k-1} + \alpha_{k-1} p_{k-1}^T A p_{k-1},$$

sustituyendo  $\alpha_{k-1}$  por su expresión en el algoritmo vemos que:

$$r_k^T p_{k-1} = r_{k-1}^T p_{k-1} - \frac{r_{k-1}^T p_{k-1}}{p_{k-1}^T A p_{k-1}} p_{k-1}^T A p_{k-1} = 0.$$

Falta ver que sucede con las direcciones conjugadas  $p_i$  para  $i = 0, \dots, k-2$ . Note que:

$$r_k = r_{k-1} + \alpha_{k-1} A p_{k-1},$$

trasponiendo esta expresión y multiplicando la por  $p_i$ , tenemos:

$$r_k^T p_i = r_{k-1}^T p_i + \alpha_{k-1} p_{k-1}^T A p_i = 0 \text{ para } i = 0, \dots, k-2.$$

Esto debido a la hipótesis inductiva y a que  $p_i$  para  $i = 0, \dots, k-2$  son direcciones conjugadas. Por lo tanto  $r_k^T p_i = 0$  para  $i = 0, \dots, k-1$ .

Ahora mostraremos que un punto  $\bar{x}$  minimiza  $\phi$  sobre  $x + \text{gen}\{p_0, \dots, p_{k-1}\}$  si y sólo si  $r(\bar{x}^T) p_i = 0$  para  $i = 0, \dots, k-1$ , esto por las condiciones de optimalidad  $r(x) = \nabla \phi(x) = 0$ . Definimos una función:

$$h(\sigma) := \phi(x_0 + \sigma_0 p_0 + \dots + \sigma_{k-1} p_{k-1}),$$

como  $h$  es un función cuadrática y convexa, posee un único punto  $\sigma^*$  que minimiza la función que satisface:

$$\frac{\delta h(\sigma^*)}{\delta \sigma_i} = 0 \text{ para } i = 0, \dots, k-1,$$

por la regla de la cadena tenemos entonces que

$$\begin{aligned}\nabla\phi(x_0 + \sigma_0^*p_0 + \dots + \sigma_{k-1}^*p_{k-1})^T p_i &= 0 \text{ para } i = 0, \dots, k-1, \\ \Rightarrow r(\bar{x})^T p_i &= 0 \text{ para } i = 0, \dots, k-1.\end{aligned}$$

Por lo tanto  $\bar{x}$  minimiza  $\phi$  sobre  $x + \text{gen}\{p_0, \dots, p_{k-1}\}$ . Por lo primero sabemos que  $x_k$  satisface que  $r(x_k)^T p_i = 0$  para  $i = 0, \dots, k-1$ , pero  $\bar{x}$  es único, por lo tanto  $x_k = \bar{x}$ .

## 2 Método de Gradientes Conjugados.

Este método es un método de direcciones conjugadas con una propiedad especial. Esta propiedad es la de generar un nuevo vector  $p_k$  usando solamente la dirección anterior  $p_{k-1}$ . Por lo que este método no necesita conocer  $p_0, \dots, p_{k-2}$  del conjunto de direcciones conjugadas, automáticamente el vector  $p_k$  es conjugados a estos. Esto es una ventaja muy importante computacionalmente, debido a la poca memoria que necesita.

### 2.1 Características.

Cada dirección se escoge para que sea una combinación lineal de la dirección de máximo descenso  $-\nabla\phi(x_k)$ , que es lo mismo que el negativo del residuo  $-r_k$  y la dirección previa  $p_{k-1}$ , de este modo tenemos:

$$p_k = -r_k + \beta_k p_{k-1}, \quad (3)$$

donde el escalar  $\beta_k$  se determina por la necesidad de que  $p_k$  y  $p_{k-1}$  sean conjugados respecto a  $A$ . Entonces si multiplicamos 3 por  $p_{k-1}^T A$  e imponiendo la condición  $p_{k-1}^T A p_k = 0$ , encontramos que

$$\beta_k = \frac{r_k^T A p_{k-1}}{p_{k-1}^T A p_{k-1}}.$$

#### 2.1.1 Algoritmo.

```
function [xn, its]=cg(A,b,tol,its_max)
n=length(b);
xn=zeros(n,1);
r=-b;
p=-r;
its=0;
while (norm(r)>tol) &&(its<=its_max)
q=A*p;
alpha=(-r'*p)/(p'*q);
xn=xn+alpha*p;
r=r+alpha*q;
beta=(r'*q)/(p'*q);
p=-r+beta*p;
its=its+1;
end
end
```

Cada dirección de búsqueda  $p_k$  y cada residuo  $r_k$  esta contenido en un subespacio de Krylov.

### 2.1.2 Preliminares.

**Definición 2** Sean  $a_1, \dots, a_m \in \mathbb{R}^n$ . Denotamos por  $gen(a_1, \dots, a_m)$  al conjunto de todas las combinaciones lineales de los vectores  $a_1, \dots, a_m$ :

$$gen(a_1, \dots, a_m) := \{x \in \mathbb{R}^n : \exists \lambda_1, \dots, \lambda_m \in \mathbb{R}, \quad x = \sum_{j=1}^m \lambda_j a_j\}$$

**Corolario 1** Sean  $a_1, \dots, a_k, b_1, \dots, b_k \in \mathbb{R}^n$  tales que

$$gen(a_1, \dots, a_{k-1}) = gen(b_1, \dots, b_{k-1}), \quad a_k \in gen(b_1, \dots, b_k), \quad b_k \in gen(a_1, \dots, a_k)$$

Entonces  $gen(a_1, \dots, a_k) = gen(b_1, \dots, b_k)$

**Definición 3** Sean  $A \in \mathcal{M}_n(\mathbb{R})$  y  $v \in \mathbb{R}^n$ , un subespacio de Krylov se define como:

$$K_j(A, v) := gen\{v, Av, \dots, A^{j-1}v\}.$$

**Lema 1** Sean  $A \in \mathcal{M}_n(\mathbb{R})$ ,  $v \in \mathbb{R}^n$  y  $x \in K_j(A, v)$ . Entonces  $Ax \in K_{j+1}(A, v)$ .

**Teorema 3** Sea  $A \in \mathcal{M}_n(\mathbb{R})$  simétrica y definida positiva. Sea  $p_0 = -r_0$ . Definimos las siguientes fórmulas del método del gradiente conjugado

$$\begin{aligned} \alpha_k &= -\frac{r_k^T p_k}{p_k^T A p_k} & r_{k+1} &= r_k + \alpha_k A p_k \\ \beta_k &= \frac{r_k^T A p_{k-1}}{p_{k-1}^T A p_{k-1}} & p_k &= -r_k + \beta_k p_{k-1} \end{aligned}$$

Entonces para la  $k$ -ésima iteración del método se cumplen las siguientes propiedades:

- i)  $gen(r_0, r_1, \dots, r_k) = gen(r_0, Ar_0, \dots, A^k r_0)$
- ii)  $gen(p_0, p_1, \dots, p_k) = gen(r_0, Ar_0, \dots, A^k r_0)$
- iii)  $p_k^T A p_i = 0 \quad \forall i = 0, \dots, k-1$
- iv)  $r_k^T r_i = 0 \quad \forall i = 0, \dots, k-1$

**Demostración 3** Primero procedemos por inducción para demostrar simultáneamente I) y II). Para  $k = 0$ , tenemos que  $gen(r_0) = gen(r_0)$ . Luego por hipótesis sabemos que  $p_0 = -r_0$  por lo que es claro que  $gen(p_0) = gen(r_0)$ . Ahora suponemos que se cumple para algún  $k$  y demostraremos que se cumple para  $k + 1$ , por lo que nuestra hipótesis inductiva es:

$$gen(r_0, r_1, \dots, r_k) = gen(r_0, Ar_0, \dots, A^k r_0) \quad (4)$$

$$gen(p_0, p_1, \dots, p_k) = gen(r_0, Ar_0, \dots, A^k r_0) \quad (5)$$

Por (5) tenemos que  $p_k \in \text{gen}(r_0, Ar_0, \dots, A^k r_0)$ . Si multiplicamos por  $A$  obtenemos

$$Ap_k \in \text{gen}(Ar_0, A^2 r_0, \dots, A^{k+1} r_0)$$

tomando esta expresión y recordando que  $r_{k+1} = r_k + \alpha_k Ap_k$  se puede notar que

$$r_{k+1} \in \text{gen}(r_0, Ar_0, A^2 r_0, \dots, A^{k+1} r_0) \quad (6)$$

De nuevo por (5) sabemos que  $A^k r_0 \in \text{gen}(p_0, p_1, \dots, p_k)$ . Si multiplicamos esta expresión por la matriz  $A$  obtenemos  $A^{k+1} r_0 \in \text{gen}(Ap_0, Ap_1, \dots, Ap_k)$ . Además sabemos que  $Ap_i = \frac{r_{i+1} - r_i}{\alpha_i}$  para  $i = 0, 1, \dots, k$  por lo que

$$A^{k+1} r_0 \in \text{gen}(r_0, r_1, \dots, r_{k+1}) \quad (7)$$

Usando el Corolario 1 con las expresiones (4), (6), (7) concluimos que

$$\text{gen}(r_0, r_1, \dots, r_{k+1}) = \text{gen}(r_0, Ar_0, \dots, A^{k+1} r_0)$$

con lo que queda demostrada la propiedad I)

Por demostrar la propiedad II). Note que:

$$\text{gen}(p_0, \dots, p_{k+1}) = \text{gen}(p_0, \dots, p_k, r_{k+1}) \quad (8)$$

$$= \text{gen}(r_0, \dots, A^k r_0, r_{k+1}) \quad (9)$$

$$= \text{gen}(r_0, \dots, r_k, r_{k+1}) \quad (10)$$

$$= \text{gen}(p_0, \dots, A^k r_0, A^{k+1} r_0) \quad (11)$$

Donde (8) se obtiene por la forma de calcular  $p_{k+1}$ , (9) y (10) suceden por la hipótesis inductiva y (11) por la demostración anterior.

Para demostrar la propiedad III) de nuevo usamos inducción matemática. Tomando  $k = 1$  vemos que

$$p_1^T = -r_1^T + \beta_1 p_0^T = -r_1^T + \frac{r_1^T Ap_0}{p_0^T Ap_0} p_0^T$$

$$\text{Multiplicando por } Ap_0 \text{ obtenemos } p_1^T Ap_0 = -r_1^T Ap_0 + \frac{r_1^T Ap_0}{p_0^T Ap_0} p_0^T Ap_0 = 0.$$

Ahora suponemos que se cumple para algún  $k$  y lo demostraremos para  $k + 1$ , así nuestra hipótesis de inducción es que  $p_k^T Ap_i = 0$  para  $i = 0, 1, \dots, k - 1$  y demostraremos que  $p_{k+1}^T Ap_i = 0$  para  $i = 0, 1, \dots, k$

$$p_{k+1}^T Ap_i = -r_{k+1}^T Ap_i + \beta_{k+1} p_k^T Ap_i \quad (12)$$

Notemos que si  $i = k$  tenemos que

$$p_{k+1}^T Ap_k = -r_{k+1}^T Ap_k + \frac{r_{k+1}^T Ap_k}{p_k^T Ap_k} p_k^T Ap_k = 0$$

Ahora veamos que ocurre cuando  $i \leq k - 1$ . Por la de inducción podemos observar que la expresión (12) se reduce

$$p_{k+1}^T A p_i = -r_{k+1}^T A p_i$$

y como demostramos antes  $p_i \in \text{gen}(r_0, A r_0, \dots, A^i r_0)$  por lo que

$$A p_i \in \text{gen}(A r_0, A^2 r_0, \dots, A^{i+1} r_0) \subset \text{gen}(r_0, A r_0, A^2 r_0, \dots, A^{i+1} r_0) = \text{gen}(p_0, p_1, \dots, p_{i+1})$$

Usando está relación y el Teorema 2 tenemos que  $r_{k+1}^T A p_i = 0$ . Por la tanto  $p_{k+1}^T A p_i = 0$  para toda  $i = 0, 1, \dots, k$  y la demostración para la propiedad III) queda concluida.

Por último se demuestra la propiedad IV) por argumentos no inductivos. Dado que el conjunto de direcciones es conjugado, por el Teorema 2 tenemos que  $r_k^T p_i = 0 \quad \forall i = 0, \dots, k-1$ . Recordemos que:

$$p_i = -r_i + \beta_i p_{i-1},$$

multiplicando esta expresión por  $r_k^T$ , tenemos entonces

$$r_k^T p_i = -r_k^T r_i + \beta_i r_k^T p_{i-1}$$

y por el Teorema 2,

$$\Rightarrow r_k^T r_i = 0 \quad \forall i = 0, \dots, k-1.$$

Por lo tanto queda demostrada dicha propiedad.