

– Typeset by GMNI & Foil<sub>E</sub>TEX –

# MÉTODOS SEMI-ITERATIVOS: Direcciones Conjugadas. Gradientes Conjugados

F. Navarrina, I. Colominas, M. Casteleiro, H. Gómez, J. París



GMNI — GRUPO DE MÉTODOS NUMÉRICOS EN INGENIERÍA

Departamento de Métodos Matemáticos y de Representación  
Escuela Técnica Superior de Ingenieros de Caminos, Canales y Puertos  
Universidad de A Coruña, España

e-mail: [fnavarrina@udc.es](mailto:fnavarrina@udc.es)

página web: <http://caminos.udc.es/gmni>





# ÍNDICE

- ▶ Direcciones Conjugadas
- ▶ Métodos de Direcciones Conjugadas
- ▶ Método de Gradientes Conjugados [CG]





## Direcciones Conjugadas (Ia)

Sea el sistema

$$\underline{A}\bar{x} = \bar{b}, \quad \text{con} \quad \begin{cases} \underline{A} = \underline{A}^T & (\underline{A} \text{ SIMÉTRICA}), \\ \bar{v}^T \underline{A}\bar{v} > 0 \quad \forall \bar{v} \neq \bar{0} & (\underline{A} \text{ DEF. +}). \end{cases}$$

Sean los vectores conjugados respecto a la matriz  $\underline{A}$  (o  $\underline{A}$ -conjugados),

$$\{\bar{s}_i\}_{i=1,n}, \quad \text{tales que} \quad \bar{s}_i^T \underline{A}\bar{s}_j \begin{cases} = 0 & \text{si } i \neq j, \\ \neq 0 & \text{si } i = j, \end{cases}$$

$\implies$  **FORMAN UNA BASE.**





## Direcciones Conjugadas (Ib)

Pues...

### REDUCCIÓN AL ABSURDO

Hipótesis:  $\sum_{i=1}^n \lambda_i \bar{s}_i = \bar{0}$  con algún  $\lambda_j \neq 0$ ,

$$\text{entonces } \bar{s}_j^T A \left( \sum_{i=1}^n \lambda_i \bar{s}_i \right) = \sum_{i=1}^n \lambda_i \left( \bar{s}_j^T A \bar{s}_i \right) = \lambda_j \underbrace{\bar{s}_j^T A \bar{s}_j}_{>0} = 0,$$

luego  $\lambda_j = 0 \quad \forall j$  (ABSURDO).

Por tanto, los vectores conjugados son linealmente independientes y (puesto que su número  $n$  iguala al orden de la matriz) forman una base del correspondiente espacio vectorial.





## Direcciones Conjugadas (IIa)

### EXPRESIÓN DE LA SOLUCIÓN

Sean

$$\bar{x} = \underset{\sim}{A}^{-1}\bar{b} \quad \text{la solución del problema, y}$$
$$\bar{x}_0 \quad \text{una aproximación a } \bar{x}.$$

El vector  $(\bar{x} - \bar{x}_0)$  se puede escribir como combinación lineal de los elementos de la base de vectores conjugados.

Luego,

$$\bar{x} - \bar{x}_0 = \sum_{i=1}^n \alpha_i \bar{s}_i \implies \boxed{\bar{x} = \bar{x}_0 + \sum_{i=1}^n \alpha_i \bar{s}_i.}$$





## Direcciones Conjugadas (IIb)

Pero,

$$\begin{aligned}\underline{A}\bar{x} = \bar{b} &\implies \underline{A} \left( \bar{x}_0 + \sum_{i=1}^n \alpha_i \bar{s}_i \right) = \bar{b} \\ &\implies \sum_{i=1}^n \alpha_i \underline{A}\bar{s}_i = (\bar{b} - \underline{A}\bar{x}_0)\end{aligned}$$

y premultiplicando por  $\bar{s}_j^T$  obtenemos

$$\begin{aligned}\bar{s}_j^T \left( \sum_{i=1}^n \alpha_i \underline{A}\bar{s}_i \right) &= \bar{s}_j^T (\bar{b} - \underline{A}\bar{x}_0) \implies \sum_{i=1}^n \alpha_i \left( \bar{s}_j^T \underline{A}\bar{s}_i \right) = \bar{s}_j^T (\bar{b} - \underline{A}\bar{x}_0), \\ &\implies \alpha_j \left( \bar{s}_j^T \underline{A}\bar{s}_j \right) = \bar{s}_j^T (\bar{b} - \underline{A}\bar{x}_0).\end{aligned}$$

Por tanto

$$\alpha_j = \frac{\bar{s}_j^T (\bar{b} - \underline{A}\bar{x}_0)}{\bar{s}_j^T \underline{A}\bar{s}_j}, \quad j = 1, \dots, n.$$



# Métodos de Direcciones Conjugadas (I)

## FORMULACIÓN SEMI-ITERATIVA:

$$\begin{aligned} \text{Dados } \bar{x}_0 \quad \text{y } \bar{s}_1 &\longrightarrow \bar{x}_1 = \bar{x}_0 + \alpha_1 \bar{s}_1, & \text{con } \alpha_1 &= \frac{\bar{s}_1^T (\bar{b} - \underline{A} \bar{x}_0)}{\bar{s}_1^T \underline{A} \bar{s}_1}, \\ \bar{x}_1 \quad \text{y } \bar{s}_2 &\longrightarrow \bar{x}_2 = \bar{x}_1 + \alpha_2 \bar{s}_2, & \text{con } \alpha_2 &= \frac{\bar{s}_2^T (\bar{b} - \underline{A} \bar{x}_0)}{\bar{s}_2^T \underline{A} \bar{s}_2}, \\ &\vdots & & \\ \bar{x}_{n-1} \quad \text{y } \bar{s}_n &\longrightarrow \bar{x}_n = \bar{x}_{n-1} + \alpha_n \bar{s}_n, & \text{con } \alpha_n &= \frac{\bar{s}_n^T (\bar{b} - \underline{A} \bar{x}_0)}{\bar{s}_n^T \underline{A} \bar{s}_n}. \end{aligned}$$

Finalmente

$$\begin{aligned} \bar{x}_n &= \left( \left( \dots \left( (\bar{x}_0 + \alpha_1 \bar{s}_1) + \alpha_2 \bar{s}_2 \right) + \dots \right) + \alpha_n \bar{s}_n \right) \\ &= \bar{x}_0 + \sum_{i=1}^n \alpha_i \bar{s}_i = \bar{x} = \underline{A}^{-1} \bar{b}. \end{aligned}$$







# Métodos de Direcciones Conjugadas (IIa)

EN GENERAL:

Dados  $\bar{x}_0$ ,  $\{\bar{s}_i\}_{i=1,n}$

$$\bar{x}_{k+1} = \bar{x}_k + \alpha_{k+1}\bar{s}_{k+1}, \quad \text{con } \alpha_{k+1} = \frac{\bar{s}_{k+1}^T (\bar{b} - \underline{A}\bar{x}_0)}{\bar{s}_{k+1}^T \underline{A}\bar{s}_{k+1}}, \quad k = 0, \dots, n-1$$

y  $\bar{x}_n = \bar{x} = \underline{A}^{-1}\bar{b}$  (SALVO ERRORES DE REDONDEO).

Pero también,

$$\alpha_{k+1} = \frac{\bar{s}_{k+1}^T (\bar{b} - \underline{A}\bar{x}_0)}{\bar{s}_{k+1}^T \underline{A}\bar{s}_{k+1}} = \frac{\bar{s}_{k+1}^T (\bar{b} - \underline{A}\bar{x}_k)}{\bar{s}_{k+1}^T \underline{A}\bar{s}_{k+1}},$$

pues

$$\bar{x}_k = \bar{x}_0 + \alpha_1\bar{s}_1 + \dots + \alpha_k\bar{s}_k \implies \bar{s}_{k+1}^T \underline{A}\bar{x}_k = \bar{s}_{k+1}^T \underline{A}\bar{x}_0 + \underbrace{\alpha_1 \bar{s}_{k+1}^T \underline{A}\bar{s}_1}_0 + \dots + \underbrace{\alpha_k \bar{s}_{k+1}^T \underline{A}\bar{s}_k}_0.$$





## Métodos de Direcciones Conjugadas (IIb)

Y FINALMENTE:

Dados  $\bar{x}_0, \{\bar{s}_i\}_{i=1,n}$

$$\left. \begin{aligned} \bar{r}_k &= \bar{b} - \underline{A}\bar{x}_k, & \alpha_{k+1} &= \frac{\bar{s}_{k+1}^T \bar{r}_k}{\bar{s}_{k+1}^T \underline{A}\bar{s}_{k+1}}, \\ \bar{x}_{k+1} &= \bar{x}_k + \alpha_{k+1} \bar{s}_{k+1}, \end{aligned} \right\} k = 0, \dots, n-1,$$

y  $\bar{x}_n = \bar{x} = \underline{A}^{-1}\bar{b}$  (SALVO ERRORES DE REDONDEO).

PROBLEMA:

¿Cómo se genera la base de vectores conjugados  $\{\bar{s}_i\}_{i=1,n}$ ?





# Métodos de Direcciones Conjugadas (IIa)

OBTENCIÓN DE UNA BASE DE VECTORES CONJUGADOS  $\{\bar{s}_i\}_{i=1,n}$

- ▶ **MÉTODO DE GRAM-SCHMIT**
- ▶ **MÉTODO DE GRADIENTES CONJUGADOS**  
(caso particular de Gram-Schmit)





# Métodos de Direcciones Conjugadas (IIIb)

## Método de Gram-Schmit

Se eligen los vectores  $\{\bar{v}_i\}_{i=1,n}$  **linealmente independientes**.

Se obtienen los vectores conjugados  $\{\bar{s}_i\}_{i=1,n}$  en la forma:

$$\left\{ \begin{array}{l} \bar{s}_1 = \bar{v}_1 \\ \bar{s}_2 = \bar{v}_2 + \beta_1^2 \bar{s}_1 \\ \bar{s}_3 = \bar{v}_3 + \beta_1^3 \bar{s}_1 + \beta_2^3 \bar{s}_2 \\ \dots \\ \bar{s}_k = \bar{v}_k + \beta_1^k \bar{s}_1 + \beta_2^k \bar{s}_2 + \dots + \beta_{k-1}^k \bar{s}_{k-1} \\ \dots \\ \bar{s}_n = \bar{v}_n + \beta_1^n \bar{s}_1 + \beta_2^n \bar{s}_2 + \dots + \beta_{n-1}^n \bar{s}_{n-1} \end{array} \right.$$

con las condiciones (que permiten calcular los coeficientes  $\{\beta_i^k\}_{i=1,k-1}$ )

$$\bar{s}_j^T \underline{A} \bar{s}_k = 0, \quad j = 1, \dots, k-1.$$





## Métodos de Direcciones Conjugadas (IIIc)

Luego

$$\left. \begin{array}{l} \bar{s}_k = \bar{v}_k + \sum_{i=1}^{k-1} \beta_i^k \bar{s}_i \\ \bar{s}_j^T \underline{\underline{A}} \bar{s}_k = 0, \end{array} \right\} \Rightarrow \bar{s}_j^T \underline{\underline{A}} \left( \bar{v}_k + \sum_{i=1}^{k-1} \beta_i^k \bar{s}_i \right) = 0, \quad j = 1, \dots, k-1,$$

y por consiguiente

$$\bar{s}_j^T \underline{\underline{A}} \bar{v}_k + \underbrace{\sum_{i=1}^{k-1} \beta_i^k \left( \bar{s}_j^T \underline{\underline{A}} \bar{s}_i \right)}_{\beta_j^k \left( \bar{s}_j^T \underline{\underline{A}} \bar{s}_j \right)} = 0 \quad \Rightarrow \quad \beta_j^k = -\frac{\bar{s}_j^T \underline{\underline{A}} \bar{v}_k}{\bar{s}_j^T \underline{\underline{A}} \bar{s}_j} \quad j = 1, \dots, k-1.$$





## Métodos de Direcciones Conjugadas (IIId)

Y FINALMENTE:

Dados  $\{\bar{v}_i\}_{i=1,n}$

$$\bar{s}_1 = \bar{v}_1,$$

$$\left\{ \begin{array}{l} \beta_j^k = -\frac{\bar{s}_j^T A \bar{v}_k}{\bar{s}_j^T A \bar{s}_j}, \quad j = 1, \dots, k-1, \\ \bar{s}_k = \bar{v}_k + \sum_{i=1}^{k-1} \beta_i^k \bar{s}_i, \end{array} \right\} \quad k = 2, \dots, n.$$

**PROBLEMA: Gran coste computacional,  $\mathcal{T}(n^3)$ .**





## Métodos de Direcciones Conjugadas (IV)

PREGUNTA:

¿Es posible elegir (hábilmente) los vectores  $\{\bar{v}_i\}_{i=1,n}$  de forma que la mayor parte de los coeficientes  $\{\beta_i^k\}_{i=1,k-1; k=2,n}$  sean nulos?

Respuesta:

SÍ: Método de Gradientes Conjugados





## Método de Gradientes Conjugados [CG] (Ia)

Dado el sistema

$$\underline{A}\bar{x} = \bar{b},$$

definimos la función cuadrática

$$f(\bar{x}) = \frac{1}{2}\bar{x}^T \underline{A}\bar{x} - \bar{b}^T \bar{x} + c,$$

cuyo gradiente es

$$\bar{\nabla} f = \left( \frac{df}{d\bar{x}} \right)^T = \underline{A}\bar{x} - \bar{b}.$$

Luego,

$$\bar{\nabla} f(\bar{x}_i) = -\bar{r}_i, \quad \text{siendo } \bar{r}_i = \bar{b} - \underline{A}\bar{x}_i \text{ el residuo en la aproximación } \bar{x}_i.$$







## Método de Gradientes Conjugados [CG] (Ib)

Si elegimos como vectores  $\{\bar{v}_i\}_{i=1,n}$  los gradientes (cambiados de signo)

$$\left\{ \begin{array}{l} \bar{v}_1 = -\bar{\nabla} f(\bar{x}_0) = \bar{r}_0 = (\bar{b} - \underline{A}\bar{x}_0) \\ \bar{v}_2 = -\bar{\nabla} f(\bar{x}_1) = \bar{r}_1 = (\bar{b} - \underline{A}\bar{x}_1) \\ \bar{v}_3 = -\bar{\nabla} f(\bar{x}_2) = \bar{r}_2 = (\bar{b} - \underline{A}\bar{x}_2) \\ \dots \\ \bar{v}_k = -\bar{\nabla} f(\bar{x}_{k-1}) = \bar{r}_{k-1} = (\bar{b} - \underline{A}\bar{x}_{k-1}) \\ \dots \\ \bar{v}_n = -\bar{\nabla} f(\bar{x}_{n-1}) = \bar{r}_{n-1} = (\bar{b} - \underline{A}\bar{x}_{n-1}) \end{array} \right.$$

entonces sucede que (\*)

$$\beta_j^k = -\frac{\bar{s}_j^T \underline{A} \bar{r}_{k-1}}{\bar{s}_j^T \underline{A} \bar{s}_j} \left\{ \begin{array}{l} = 0, \quad j = 1, \dots, k-2 \\ \neq 0, \quad j = k-1 \end{array} \right.$$

(\*) Se comprueba que esto es así aunque no es evidente (ver equivalencias).





## Método de Gradientes Conjugados [CG] (Ic)

FINALMENTE, LA BASE DE GRADIENTES CONJUGADOS ES (\*):

$$\left\{ \begin{array}{l} \bar{r}_0 = \bar{b} - \underline{A}\bar{x}_0 \\ \bar{s}_1 = \bar{r}_0, \\ \\ \bar{r}_{k-1} = \bar{b} - \underline{A}\bar{x}_{k-1} \\ \beta_{k-1}^k = -\frac{\bar{s}_{k-1}^T \underline{A} \bar{r}_{k-1}}{\bar{s}_{k-1}^T \underline{A} \bar{s}_{k-1}}, \\ \\ \bar{s}_k = \bar{r}_{k-1} + \beta_{k-1}^k \bar{s}_{k-1}, \end{array} \right. \quad k = 2, \dots, n.$$

(\*) EN LO SUCESIVO PRESCINDIREMOS DEL SUPERÍNDICE  $k$  EN  $\beta_{k-1}^k$   
(ya que no es necesario).





# Método de Gradientes Conjugados [CG] (IIa)

PRIMERA ITERACIÓN  $k = 0$

$$\text{Dado } \bar{x}_0 \longrightarrow \bar{r}_0 = \bar{b} - \underline{A}\bar{x}_0,$$

$$\bar{s}_1 = \bar{r}_0, \quad \longrightarrow \alpha_1 = \frac{\bar{s}_1^T \bar{r}_0}{\bar{s}_1^T \underline{A} \bar{s}_1},$$

$$\bar{x}_1 = \bar{x}_0 + \alpha_1 \bar{s}_1.$$





## Método de Gradientes Conjugados [CG] (IIb)

ITERACIONES SIGUIENTES  $k = 1, \dots, n - 1$

$$\begin{aligned} \text{Dado } \bar{x}_k &\longrightarrow \bar{r}_k = \bar{b} - \underline{A}\bar{x}_k, & \longrightarrow \beta_k = -\frac{\bar{s}_k^T \underline{A} \bar{r}_k}{\bar{s}_k^T \underline{A} \bar{s}_k}, \\ & & \bar{s}_{k+1} = \bar{r}_k + \beta_k \bar{s}_k, & \longrightarrow \alpha_{k+1} = \frac{\bar{s}_{k+1}^T \bar{r}_k}{\bar{s}_{k+1}^T \underline{A} \bar{s}_{k+1}}, \\ & & & \bar{x}_{k+1} = \bar{x}_k + \alpha_{k+1} \bar{s}_{k+1}, \end{aligned}$$

Y  $\bar{x}_n$  verifica  $\underline{A}\bar{x}_n = \bar{b}$  (SALVO ERRORES DE REDONDEO).





## Método de Gradientes Conjugados [CG] (IIc)

El algoritmo se detendrá al finalizar el paso  $k \dots$

- ▶ si  $k = n - 1$ , pues  $\bar{x}_{k+1} = \bar{x}_n$  y por tanto verifica

$$\bar{r}_{k+1} = \bar{b} - \underline{A}\bar{x}_{k+1} = 0 \quad (\text{salvo errores de redondeo } *),$$

- ▶ o si ha convergido según un criterio tipo

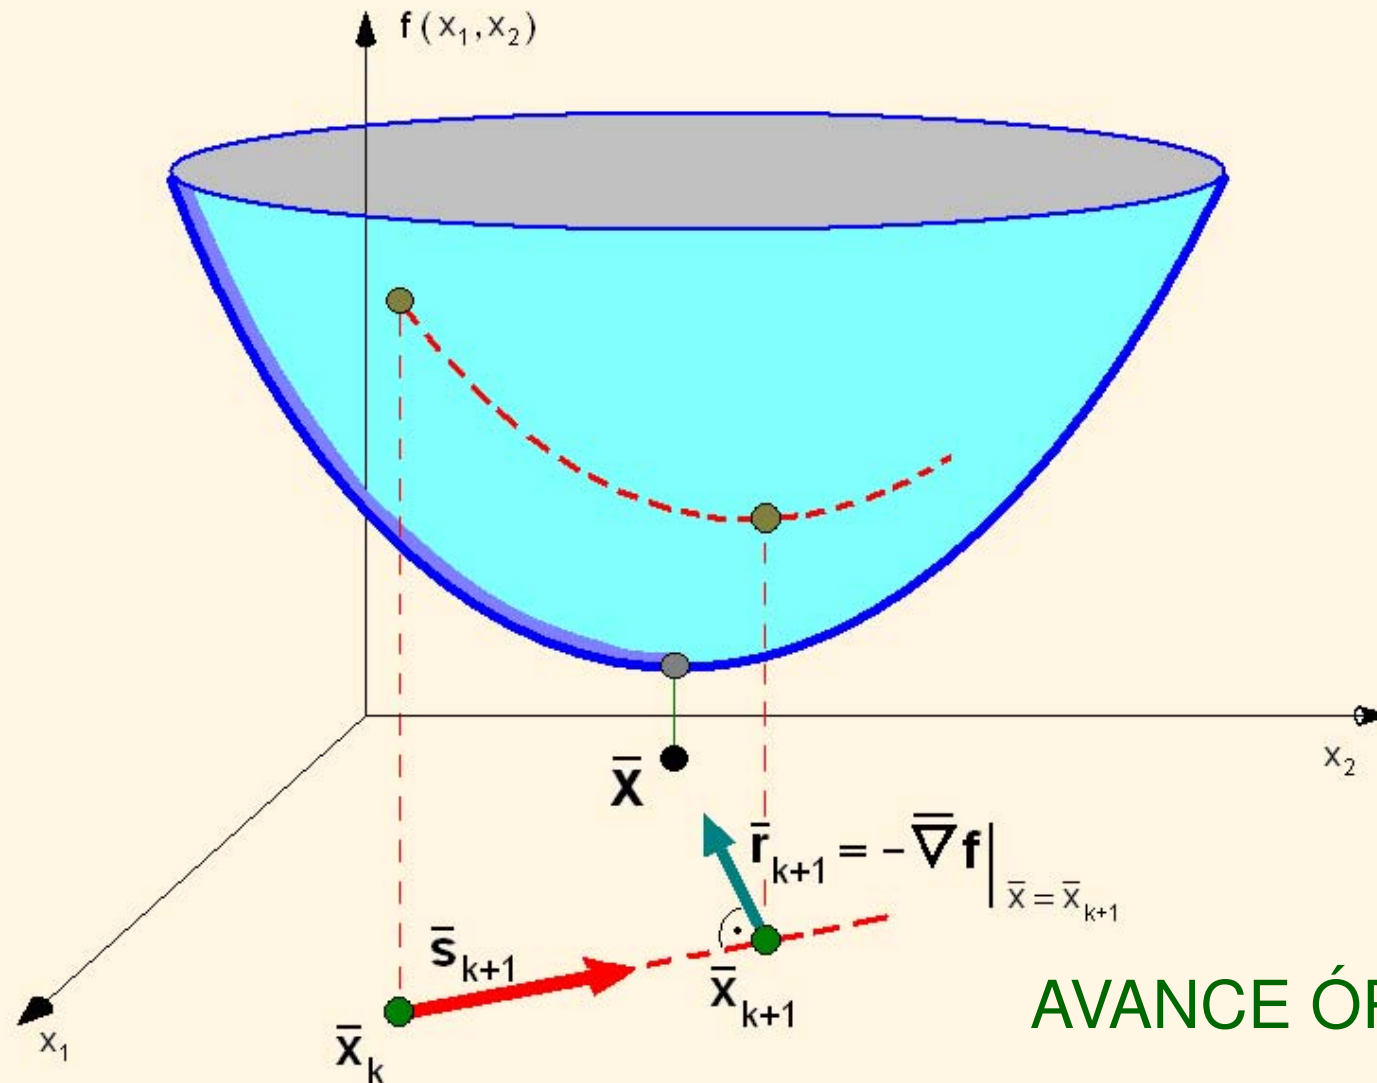
$$\begin{cases} \|\bar{x}_{k+1} - \bar{x}_k\| \leq \max\{\varepsilon_x, r_x \|\bar{x}_k\|\} & \text{y} \\ \|\bar{r}_{k+1}\| \leq \max\{\varepsilon_r, r_r \|\bar{b}\|\} \end{cases}$$

(\*) Se suelen realizar algunas iteraciones más para refinar la solución.





# Método de Gradientes Conjugados [CG] (IIIe)



AVANCE ÓPTIMO





## Método de Gradientes Conjugados [CG] (IV)

Fórmulas equivalentes para el cálculo del coeficiente  $\beta_k$

$$\beta_k = -\frac{\bar{s}_k^T \underline{A} \bar{r}_k}{\bar{s}_k^T \underline{A} \bar{s}_k}$$

$$\beta_k = \frac{[\bar{r}_k - \bar{r}_{k-1}]^T \bar{r}_k}{-[\bar{r}_k - \bar{r}_{k-1}]^T \bar{s}_k}$$

$$\beta_k = \frac{\bar{r}_k^T \bar{r}_k}{\bar{r}_{k-1}^T \bar{r}_{k-1}}$$

$$\beta_k = \frac{[\bar{r}_k - \bar{r}_{k-1}]^T \bar{r}_k}{\bar{r}_{k-1}^T \bar{r}_{k-1}}$$

$$\beta_k = \frac{\bar{r}_k^T \bar{r}_k}{-[\bar{r}_k - \bar{r}_{k-1}]^T \bar{s}_k}$$

HESTENES-STIEFEL

FLETCHER-REEVES

POLAK-RIBIERE

MYERS

