

## **MÉTODOS DE KRYLOV II: MINRES, FOM, GMRES.**

ALAN REYES-FIGUEROA  
MÉTODOS NUMÉRICOS II

(AULA 11) 11.AGOSTO.2021

# Métodos de Krylov

El método de ARNOLDI y el método de LANCZOS proporcionan una técnica económica para calcular vectores base ortogonales para el subespacio de Krylov  $\mathcal{K}_k(A, \mathbf{r}^{(0)})$ .

Vimos que la aproximación  $\mathbf{x}^{(k)}$  se escribe como

$$\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)},$$

donde  $\mathbf{y}^{(k)}$  se determina de forma que o bien se minimiza

$$f(\mathbf{x}^{(k)}) = \|\mathbf{x}^{(k)} - \mathbf{x}\|_A^2 = (\mathbf{x}^{(k)} - \mathbf{x})^T A (\mathbf{x}^{(k)} - \mathbf{x}), \quad (1)$$

respecto de la norma inducida por  $A$  ( $A$  simétrica y positiva definida) o bien minimizan

$$g(\mathbf{x}^{(k)}) = \|A(\mathbf{x}^{(k)} - \mathbf{x})\|_2^2 = \mathbf{r}^{(k)T} \mathbf{r}^{(k)}, \quad (2)$$

esto es, se minimiza la norma del residuo.

Veremos ahora algunos detalles desde este punto de vista de minimizar residuos.

# Métodos de Krylov

Si se considera la minimización del error en la  $A$ -norma:

$$\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)} \quad f(\mathbf{x}^{(k)}) = (\mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)} - \mathbf{x})^T A (\mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)} - \mathbf{x}).$$

Calculando la derivada respecto de  $\mathbf{y}^{(k)}$ , resulta

$$\nabla_{\mathbf{y}^{(k)}} f(\mathbf{x}^{(k)}) = 2Q_k^T A (\mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)} - \mathbf{x}) = \mathbf{0},$$

de modo que  $Q_k^T A Q_k \mathbf{y}^{(k)} = Q_k^T A (\mathbf{x} - \mathbf{x}^{(0)}) = Q_k^T A \mathbf{r}^{(0)}$ .

Como  $Q_k^T A Q_k = H_k$ , y  $\mathbf{r}^{(0)} = \|\mathbf{r}^{(0)}\| \mathbf{q}_1$ , se tiene que

$$H_k \mathbf{y}^{(k)} = \|\mathbf{r}^{(0)}\| \mathbf{e}_1,$$

donde  $\mathbf{e}_1$  es el primer vector de la base canónica de  $\mathbb{R}^n$ .

A partir de lo anterior, se deduce que los residuos son orgonales a los vectores base

$$\mathbf{r}^{(k)} = \mathbf{r}^{(0)} - A Q_k \mathbf{y}^{(k)} \implies Q_k^T \mathbf{r}^{(k)} = Q_k^T \mathbf{r}^{(0)} - Q_k^T A Q_k \mathbf{y}^{(k)} = \mathbf{0}.$$

Esta condición es equivalente a minimizar  $f(\mathbf{x}^{(k)})$  cuando  $A$  es simétrica y positiva definida. En este caso se obtiene el llamado **método del gradiente conjugado**.

# Métodos de Krylov

El gradiente conjugado minimiza la A-norma del error.

Otra forma de construir una aproximación óptima  $\mathbf{x}^{(k)}$  es minimizar el residuo (2)

$$g(\mathbf{x}^{(k)}) = \|A(\mathbf{x}^{(k)} - \mathbf{x})\|_2^2 = \mathbf{r}^{(k)T} \mathbf{r}^{(k)},$$

sobre todos los  $\mathbf{x}^{(k)} \in \{\mathbf{x}^{(0)}\} \cup \mathcal{K}(A, \mathbf{b})$ .

Definiendo, como en el método de LANCZOS

$$H_k = \begin{pmatrix} \alpha_1 & \beta_2 & & & \\ \beta_2 & \alpha_2 & \ddots & & \\ & \ddots & \ddots & \beta_k & \\ & & & \beta_k & \alpha_k \end{pmatrix}.$$

Tenemos que  $AQ_k = Q_{k+1}H_k$ .

Ahora, la minimización se reduce a encontrar  $\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)}$  tal que  $\|\mathbf{r}^{(k)}\|_2$  sea mínima. Como

$$\mathbf{r}^{(k)} = \mathbf{b} - A\mathbf{x}^{(k)} = \mathbf{r}^{(0)} - AQ_k \mathbf{y}^{(k)} = \|\mathbf{r}^{(0)}\| \mathbf{q}_1 - AQ_k \mathbf{y}^{(k)},$$

# Métodos de Krylov

entonces se debe minimizar

$$\|\mathbf{r}^{(k)}\|_2 = \|\|\|\mathbf{r}^{(0)}\|\mathbf{q}_1 - A\mathbf{Q}_k\mathbf{y}^{(k)}\|\| = \|\|\|\mathbf{r}^{(0)}\|\mathbf{Q}_{k+1}\mathbf{e}_1 - \mathbf{Q}_{k+1}H_k\mathbf{y}^{(k)}\|\| = \|\|\|\mathbf{r}^{(0)}\|\mathbf{e}_1 - H_k\mathbf{y}^{(k)}\|\|.$$

Resolviendo el sistema sobredeterminado  $H_k\mathbf{y}^{(k)} = \|\|\|\mathbf{r}^{(0)}\|\mathbf{e}_1$  se obtienen las iteraciones

$$\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + \mathbf{Q}_k\mathbf{y}^{(k)}$$

que minimizan el residuo. El algoritmo resultante se llama **MINRES** (o residuo conjugado).

# Métodos de Krylov

**Algoritmo:** (MINRES).

*Inputs:*  $A \in \mathbb{R}^{n \times n}$ , simétrica y positiva definida.

*Outputs:* Secuencia de residuos  $\{\mathbf{r}^{(k)}\}$ ,  $H \in \mathbb{R}^{n \times n}$  en la forma de Hessemberg.

Initialize  $H = \mathbf{0}$ , choose  $\mathbf{r}^0 = \mathbf{b} - A\mathbf{x}^{(0)}$ ,  $\mathbf{p}_0 = \mathbf{r}^{(0)}$ .

For  $k = 1, 2, \dots$ :

$$\alpha_k = \frac{(\mathbf{r}^{(k)})^T A \mathbf{r}^{(k)}}{(\mathbf{A} \mathbf{p}_k)^T (\mathbf{A} \mathbf{p}_k)}.$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{p}_k,$$

$$\mathbf{r}^{(k+1)} = \mathbf{r}^{(k)} - \alpha_k \mathbf{A} \mathbf{p}_k,$$

$$\beta_k = \frac{(\mathbf{r}^{(k+1)})^T A \mathbf{r}^{(k+1)}}{(\mathbf{r}^{(k)})^T A \mathbf{r}^{(k)}},$$

$$H_{k+1,k} = \|\mathbf{v}\|_2,$$

$$\mathbf{p}_{k+1} = \mathbf{r}^{(k+1)} + \beta_k \mathbf{r}^{(k)},$$

$$\mathbf{A} \mathbf{p}_{k+1} = A \mathbf{r}^{(k+1)} + \beta_k A \mathbf{r}^{(k)}.$$

# Métodos de Krylov

Al igual que el método de LANCZOS, el método de ARNOLDI nos da una base ortogonal para el subespacio de Krylov  $\mathcal{K}(A, \mathbf{r}^{(0)})$ , esta vez para  $A$  no simétrica.

Al igual que antes, se tiene la aproximación

$$\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)},$$

donde  $\mathbf{y}^{(k)}$  es tal que se minimiza el error (1)

$$f(\mathbf{x}^{(k)}) = \|\mathbf{x}^{(k)} - \mathbf{x}\|_A^2 = (\mathbf{x}^{(k)} - \mathbf{x})^T A (\mathbf{x}^{(k)} - \mathbf{x}),$$

respecto de la norma inducida por  $A$ , o bien se minimiza el residuo (2)

$$g(\mathbf{x}^{(k)}) = \|A(\mathbf{x}^{(k)} - \mathbf{x})\|_2^2 = \mathbf{r}^{(k)T} \mathbf{r}^{(k)}.$$

Cuando  $A$  no es simétrica y positiva definida, la  $A$ -norma no está bien definida.

Imponiendo ahora que los residuos sean ortogonales a  $Q_k$ , se tiene

$$Q_k^T (\mathbf{r}^{(0)} - A Q_k \mathbf{y}^{(k)}) = \mathbf{0} \implies \|\mathbf{r}^{(0)}\| \mathbf{e}_1 - H_k \mathbf{y}^{(k)} = \mathbf{0}.$$

Resolviendo el sistema  $\mathbf{y}^{(k)} = \|\mathbf{r}^{(0)}\| H_k^{-1} \mathbf{e}_1$ ,  $\mathbf{x}^{(k)} = Q_k \mathbf{y}^{(k)}$ , se obtiene el llamado **método FOM** (*Full Orthogonalization Method*).

# Métodos de Krylov

Observaciones:

- FOM es equivalente al gradiente conjugado si  $A$  es simétrica y positiva definida. Pero tiene inconvenientes:
- FOM no trata de forma eficiente la memoria:  $Q_k$  se tiene que guardar completa. En cada iteración, un nuevo vector base se tiene que calcular y guardar.
- FOM no tiene una propiedad de optimalidad.
- FOM no es robusto ya que  $H_k$  puede ser no singular.

El método FOM para obtener  $\mathbf{x}^{(k)}$  es parte de una familia de técnicas para extraer una solución aproximada a partir de un espacio de búsqueda  $Q_k$  haciendo que el residuo sea ortogonal a un espacio test  $W_k$ , así: Dada  $\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)}$ , se busca  $\mathbf{y}^{(k)}$  tal que

$$W_k^T (\mathbf{r}^{(0)} - A Q_k \mathbf{y}^{(k)}) = \mathbf{0}. \quad (3)$$

Estas son las condiciones de PETROV-GALERKIN.

Un segundo método para obtener un mínimo del residuo es el siguiente. Observe que el problema de minimizar

$$g(\mathbf{x}^{(k)}) = \|A(\mathbf{x}^{(k)} - \mathbf{x})\|_2^2 = (\mathbf{r}^{(k)})^T \mathbf{r}^{(k)},$$

está siempre bien definido incluso si  $A$  es no simétrica.

El problema es encontrar  $\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)}$  tal que  $\|\mathbf{r}^{(k)}\|_2$  es mínimo. Como  $\mathbf{r}^{(k)} = \mathbf{b} - A\mathbf{x}^{(k)} = \mathbf{r}^{(0)} - AQ_k \mathbf{y}^{(k)} = \|\mathbf{r}^{(0)}\| \mathbf{q}_1 - AQ_k \mathbf{y}^{(k)}$ , tenemos

$$\|\mathbf{r}^{(k)}\|_2 = \|\|\mathbf{r}^{(0)}\| \mathbf{q}_1 - AQ_k \mathbf{y}^{(k)}\| = \|\|\mathbf{r}^{(0)}\| Q_{k+1} \mathbf{e}_1 - Q_{k+1} H_k \mathbf{y}^{(k)}\| = \|\|\mathbf{r}^{(0)}\| \mathbf{e}_1 - H_k \mathbf{y}^{(k)}\|.$$

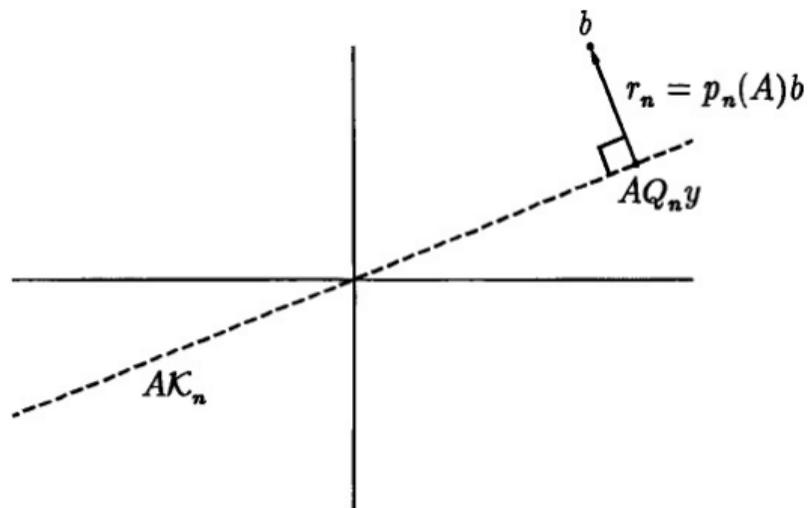
Al resolver el sistema sobredeterminado  $H_k \mathbf{y}^{(k)} = \|\mathbf{r}^{(0)}\| \mathbf{e}_1$ , se obtienen las iteraciones

$$\mathbf{x}^{(k)} = \mathbf{x}^{(0)} + Q_k \mathbf{y}^{(k)}$$

que minimizan el residuo.

El algoritmo resultante se llama **GMRES** (*General Minimal Residual Method*). GMRES, es uno de los métodos más populares para resolver sistemas no simétricos.

# Métodos de Krylov



GMRES minimiza la norma del residuo  $\|r^{(n)}\|$ .

# Métodos de Krylov

Observaciones:

- El método GMRES es equivalente al MINRES, cuando  $A$  es simétrica.
- GMRES no tiene limitada la memoria:  $Q_k$  se ha de guardar completamente. En cada iteración se ha de calcular y guardar un nuevo vector de la base. La ortogonalización de un nuevo vector se hace cada vez más cara al aumentar  $k$ .
- GMRES minimiza la norma del residuo.
- GMRES es robusto: el sistema  $H_k \mathbf{y}^{(k)} = \|\mathbf{r}^{(0)}\| \mathbf{e}_1$  tiene siempre una solución de mínimos cuadrados.

**Algoritmo:** (GMRES)

$$\mathbf{q}_1 = \mathbf{b} / \|\mathbf{b}\|,$$

For  $k = 1, 2, 3, \dots$

(step  $k$  of Arnoldi iteration)

Find  $\mathbf{y}^{(k)}$  to minimize  $\|H_k \mathbf{y}^{(k)} - \|\mathbf{b}\| \mathbf{e}_1\| = \|\mathbf{r}^{(k)}\|,$

$$\mathbf{x}^{(k)} = Q_k \mathbf{y}^{(k)}.$$

# Métodos de Krylov

Otros métodos:

- Bi-Lanczos,
- BICG (Bi-graiente conjugado),
- QMR
- Algoritmo GC cuadrado
- Método Bi-CGSTAB