



Universidad Nacional Autónoma de México

FACULTAD DE CIENCIAS

ANALISIS DE ALTERNATIVAS AL METODO DE
GRADIENTE CONJUGADO PARA
MATRICES NO SIMETRICAS

T E S I S
QUE PARA OBTENER EL TITULO DE
M A T E M A T I C O
P R E S E N T A
GRACIELA DEL SOCORRO HERRERA ZAMARRON

MEXICO, D.

TESIS CON
FALLA DE ORIGEN

1989



UNAM – Dirección General de Bibliotecas

Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Contenido

Introducción	1
Capítulo 1: Método tradicional de gradiente conjugado	2
1.1 Introducción	2
1.2 Conceptos fundamentales	3
1.3 Planteamiento general del problema	5
1.4 Minimización de la función cuadrática F en n -planos	11
1.5 Método de gradiente conjugado	14
Capítulo 2: Modificaciones para el caso no simétrico	18
2.1 Introducción	18
2.2 Extensión natural a matrices no simétricas	18
2.3 Método de residuo conjugado generalizado (GCR)	20
2.4 Métodos GCR(k) y ORTHOMIN(k)	22
Capítulo 3: Nuevo método para el caso no simétrico	23
3.1 Introducción	23
3.2 Planteamiento general de problema	23
3.3 Explicación del método	26
3.4 Construcción para la matriz no simétrica	32
Capítulo 4: Resultados numéricos y conclusiones	34
4.1 Introducción	34
4.2 Solución numérica de un problema específico	34
4.3 Resultados numéricos	37
4.4 Discusión y conclusiones	38
Apéndice: programas	58
Referencias	70

Introducción

El método de gradiente conjugado ha sido utilizado ampliamente en los últimos años. A pesar de que su formulación original fue hecha en 1952 por Hestenes y Stiefel [8], el interés actual se dió a partir de que Reid lo planteara como un método iterativo en 1971 [12], que es la forma en que se le utiliza con mayor frecuencia en la actualidad.

El método de gradiente conjugado (CG) se aplica para la ecuación $\mathbf{A}\mathbf{u} = \mathbf{b}$ cuando \mathbf{A} es una matriz positiva definida y simétrica. Sin embargo, se han formulado varios métodos basados en el de gradiente conjugado para eliminar esta restricción y extender el método a matrices no simétricas. De estos métodos, el primero en aparecer, que fuera formulado por los mismos Hestenes y Stiefel [8], se basa en la idea de resolver la ecuación $\mathbf{P}\mathbf{u} = \mathbf{a}$, donde \mathbf{P} es no simétrica y no singular, aplicando el método de gradiente conjugado a la ecuación equivalente $\mathbf{P}^\top\mathbf{P}\mathbf{u} = \mathbf{P}^\top\mathbf{a}$. Nos referiremos a este método como la extensión natural del gradiente conjugado. Entre los métodos más recientes, se ha trabajado ampliamente con ORTHOMIN(k) y GCR(k), formulados en 1976 por Vinsome [11].

En esta tesis se expone un nuevo método, propuesto por I. Herrera [10], basado en CG, que se puede aplicar al caso no simétrico. Los objetivos que nos proponemos son, por un lado, explicar de forma clara y detallada el método, y por otro hacer un análisis de la eficiencia de éste comparada con la de ORTHOMIN(k), GCR(k) y la extensión natural del gradiente conjugado en varios problemas particulares de transporte con difusión.

En el capítulo 1 se presentan algunos conceptos básicos del álgebra y el análisis que se utilizarán en el texto, además de una presentación del CG, siguiendo el texto de Hestenes [9]. El capítulo 2 presenta los métodos ORTHOMIN(k), GCR(k) y la extensión natural del GC. El capítulo 3 se inicia con una exposición del CG desde una óptica distinta a la planteada por Hestenes, siguiendo el mismo artículo de Herrera [10], con base en la cual se introduce el nuevo método. El capítulo 4 presenta los resultados numéricos y las conclusiones.

Capítulo 1

Método tradicional de gradiente conjugado

1.1 Introducción

En este capítulo revisaremos el método de gradiente conjugado, que en su forma original [8], se utiliza para resolver la ecuación

$$Au = b,$$

donde A es una matriz $N \times N$ dimensional positiva definida y simétrica. Expondremos el método siguiendo a Hestenes [9] (otras presentaciones del método se pueden encontrar en [1], [2], [4] o [6]), el cual lo desarrolla al minimizar la función cuadrática

$$F(u) = \frac{1}{2} u^T A u - b^T u + c$$

positiva definida. La idea básica consiste en construir aproximaciones al vector solución u_s , tomándolas como el mínimo de la función F sobre ciertos hiperplanos anidados de \mathbb{R}^N ,

$$H_1 \subset H_2 \subset \dots \subset H_N,$$

donde el subíndice corresponde a la dimensión.

Para expresar las aproximaciones es necesario construir una base A -ortogonal de cada hiperplano. El método que se utiliza usualmente para ortogonalizar vectores es el de Gram-Schmidt. Sin embargo, al seleccionar un nuevo elemento de la base, se requiere garantizar la ortogonalidad con respecto a todos los construidos anteriormente. En contraste con esto, los hiperplanos seleccionados en el método de gradiente conjugado, permiten asegurar que al escoger un nuevo elemento de la base baste con verificar la ortogonalidad con respecto al último que se ha construido para que, automáticamente, esta condición se cumpla con respecto a todos los anteriores. Esta forma de proceder permite construir la base iterativamente, de tal forma que cada nueva aproximación dependa únicamente de la precedente. En términos computacionales esto es una gran ventaja.

1.2 Conceptos Fundamentales

En esta sección introduciremos notación y terminología que se utilizará en el transcurso del texto, además revisaremos conceptos básicos sobre los que se desarrollará la teoría ulterior [5], [11].

Trabajaremos con funciones vectoriales de valor real en \mathbb{R}^N . Las componentes de los vectores se designarán por medio de subíndices cuando sea necesario, de tal forma que u_i es la i -ésima componente de u . Cuando se hagan operaciones matriciales el vector u se considerará como un vector columna. Denotaremos (u, v) a un producto escalar cualquiera y

$$u * v = \sum_{i=1}^N u_i * v_i$$

al producto interior asociado a la norma euclíadiana de u y v en \mathbb{R}^N . La norma del vector u respecto a un producto escalar cualquiera es $\|u\| = (u, u)^{\frac{1}{2}}$. Específicamente, denotaremos $\|u\|_2$ a la norma euclíadiana del vector u y será

$$\|u\|_2 = \left(\sum_{i=1}^N u_i^2 \right)^{\frac{1}{2}}.$$

La distancia entre dos vectores u y v es $\|u - v\|$. Una vecindad de u^1 de radio δ es el conjunto de todos los puntos u tales que $\|u - u^1\| < \delta$. Un conjunto S es abierto si todo punto u^1 de S tiene una vecindad, contenida en éste, en la que está u^1 .

Es necesario introducir también algunas relaciones entre matrices y funciones cuadráticas. $A^T = (\alpha_{ji})$ será la traspuesta de la matriz $A = (\alpha_{ij})$. Una matriz cuadrada es no singular si su determinante es distinto de cero. En este caso la inversa de A existe y se denota A^{-1} . Dado un producto interior ($,$), la adjunta A^* de la matriz A es aquella que satisface $(u, A^*v) = (v, Au)$. Utilizando esta noción decimos que una matriz A es autoadjunta si $A^* = A$. Si $A^T = A$ decimos que A es simétrica. Una matriz autoadjunta es no negativa si la desigualdad $(u, Au) \geq 0$ se cumple para todo vector u y es positiva definida si $(u, Au) > 0$ cuando $u \neq 0$. Si una matriz A es positiva definida, A^{-1} también lo es. La parte simétrica de la matriz A está dada por $M = \frac{1}{2}(A + A^T)$. Trabajaremos con funciones definidas por medio del producto interno $*$. La igualdad $Au * v = u * Av$ siempre se cumple y si A es simétrica $Au * v = u * Av$. La función $Q(u) = u * Au$ es llamada forma cuadrática y es positiva definida si A lo es. Una función F expresable en la forma

$$F(u) = \frac{1}{2}u * Au - b * u + c$$

donde A es simétrica es llamada función cuadrática.

Utilizaremos algunos conceptos del cálculo para minimizar a la función cuadrá-

tica F . Consideremos una función continua f de valor real en un conjunto abierto S que tenga derivadas parciales continuas de primer y segundo orden en S . Una función tal se dice que es de clase $C^{(2)}$. La primera diferencial $f'(\mathbf{u}, \mathbf{v})$ y segunda diferencial $f''(\mathbf{u}, \mathbf{v})$ de f en \mathbf{u} están dadas por las fórmulas

$$f'(\mathbf{u}, \mathbf{v}) = \sum_{i=1}^N \frac{\partial f(\mathbf{u})}{\partial u_i} v_i = f'(\mathbf{u}) \cdot \mathbf{v}$$

y

$$f''(\mathbf{u}, \mathbf{v}) = \sum_{i=1}^N \sum_{j=1}^N \frac{\partial^2 f(\mathbf{u})}{\partial u_i \partial u_j} v_i v_j$$

respectivamente. El vector

$$f'(\mathbf{u}) = \left(\frac{\partial f(\mathbf{u})}{\partial u_i} \right) \quad (i = 1, \dots, N)$$

es el gradiente de f en \mathbf{u} y se denotará $\nabla f(\mathbf{u})$. La matriz

$$f''(\mathbf{u}) = \left(\frac{\partial^2 f(\mathbf{u})}{\partial u_i \partial u_j} \right) \quad (i, j = 1, \dots, N)$$

es el hessiano de f en \mathbf{u} .

Un punto \mathbf{u}^0 proporciona un mínimo local de f en S si \mathbf{u}^0 está en S y la desigualdad $f(\mathbf{u}) \geq f(\mathbf{u}^0)$ se cumple para toda \mathbf{u} en S que esté en una vecindad V de \mathbf{u}^0 . Si $f(\mathbf{u}) \geq f(\mathbf{u}^0)$ para toda \mathbf{u} en S , entonces \mathbf{u}^0 minimiza a f globalmente en S . En cada caso el mínimo es estricto si la igualdad es válida sólo si $\mathbf{u} = \mathbf{u}^0$. Si f es dos veces diferenciable en un conjunto abierto S , entonces las relaciones

$$f'(\mathbf{u}^0) = \mathbf{0}, \quad f''(\mathbf{u}^0, \mathbf{v}) \geq 0 \quad \forall \mathbf{v} \neq \mathbf{0}$$

se cumplen en un punto mínimo local \mathbf{u}^0 de f . Inversamente, si

$$f'(\mathbf{u}^0) = \mathbf{0}, \quad f''(\mathbf{u}^0, \mathbf{v}) > 0 \quad \forall \mathbf{v} \neq \mathbf{0},$$

entonces \mathbf{u}^0 proporciona un mínimo local estricto de f . Un punto \mathbf{u}^0 en donde $f'(\mathbf{u}^0) = \mathbf{0}$ es un punto crítico de f y $f(\mathbf{u}^0)$ es el correspondiente valor crítico de f .

1.3 Planteamiento General del Problema

Supongamos que queremos minimizar una función $f : \mathbb{R}^N \rightarrow \mathbb{R}$. Una forma de hacerlo es minimizarla en hiperplanos anidados

$$\Pi_1 \subset \Pi_2 \subset \dots \subset \Pi_N,$$

donde el subíndice indica la dimensión. Llamaremos a Π_n n -plano. Si en cada uno de estos hiperplanos el mínimo u^t en Π_t es único, tendremos una sucesión de aproximaciones u^1, \dots, u^N tales que

$$f(u^1) \geq f(u^2) \geq \dots \geq f(u^N)$$

de tal forma que, a lo más, en N pasos encontramos el punto $u_s = u^N$ que proporciona un mínimo estricto de f en \mathbb{R}^N , ya que, $\Pi_N = \mathbb{R}^N$.

En este caso queremos minimizar la función cuadrática

$$F(u) = \frac{1}{2}u \cdot \mathbf{A}u - \mathbf{b} \cdot u + c$$

en \mathbb{R}^N , donde \mathbf{A} es una matriz simétrica positiva definida ($N \times N$)-dimensional, \mathbf{b} es un vector fijo N -dimensional y c es un real. El valor de la constante c no jugará un papel importante en los algoritmos, por lo que no aparecerá más.

Para minimizar a la función F debemos encontrar los puntos en los que el gradiente de F se anula, es decir,

$$\nabla F(u) \equiv F'(u) = \mathbf{A}u - \mathbf{b} = 0.$$

Entonces u es un punto crítico de F si y solo si es solución del sistema lineal de ecuaciones

$$\mathbf{A}u = \mathbf{b}. \quad (1.3.1)$$

Como \mathbf{A} no es singular (por ser positiva definida), existe exactamente una solución a esta ecuación, que es

$$u_s = \mathbf{A}^{-1}\mathbf{b},$$

y por lo tanto un solo punto crítico de F . El hessiano es $F''(u) = \mathbf{A}$, por lo que

$$F''(u_s, v) = \mathbf{v} \cdot \mathbf{A} \mathbf{v} > 0 \quad \forall \mathbf{v} \neq 0$$

y u_s es un mínimo estricto de F .

En el estudio de sistemas de ecuaciones lineales se acostumbra definir el residuo del sistema (1.3.1) en \mathbf{u} como el vector

$$\mathbf{r} = \mathbf{b} - \mathbf{A}\mathbf{u},$$

o bien,

$$\mathbf{r} = \mathbf{A}(\mathbf{u}_0 - \mathbf{u}).$$

En nuestro caso, el vector \mathbf{r} es el gradiente negativo

$$\mathbf{r} = -\nabla F(\mathbf{u})$$

de la función cuadrática F .

Hablaremos de puntos y vectores en un hiperplano. Definimos al hiperplano Π_n como el conjunto de puntos \mathbf{u} que satisfacen las siguientes ecuaciones

$$\mathbf{q}^i \cdot \mathbf{u} = \rho_i \quad (i = 1, \dots, N-n, 1 \leq n \leq N),$$

donde los vectores $\mathbf{q}^1, \dots, \mathbf{q}^{N-n}$ son linealmente independientes y $\rho_1, \dots, \rho_{N-n}$ son escalares dados. Si \mathbf{u}^0 es un punto en Π_n estas relaciones se pueden escribir como

$$\mathbf{q}^i \cdot (\mathbf{u} - \mathbf{u}^0) = 0 \quad (i = 1, \dots, N-n)$$

que explícitamente establece que Π_n pasa por \mathbf{u}^0 . Diremos que un vector \mathbf{w} está en Π_n si y solo si

$$\mathbf{q}^i \cdot \mathbf{w} = 0, \quad (i = 1, \dots, N-n). \quad (1.3.2)$$

La ecuación (1.3.2) tiene n soluciones linealmente independientes. Por lo que todo vector \mathbf{u} en Π_n se puede expresar como una combinación lineal

$$\mathbf{u} = \alpha_1 \mathbf{u}^1 + \dots + \alpha_n \mathbf{u}^n$$

de $\mathbf{u}^1, \dots, \mathbf{u}^n$, si estos son vectores linalmente independientes en Π_n . Sean \mathbf{u}^0 y $\tilde{\mathbf{u}}$ dos puntos en Π_n . El vector $\mathbf{u} = \mathbf{u} - \mathbf{u}^0$ está en Π_n y $\tilde{\mathbf{u}} = \mathbf{u} + \mathbf{u}^0$ se puede expresar en la forma

$$\tilde{\mathbf{u}} = \mathbf{u}^0 + \alpha_1 \mathbf{u}^1 + \dots + \alpha_n \mathbf{u}^n. \quad (1.3.3)$$

para alguna elección de los parámetros $\alpha_1, \dots, \alpha_n$. La ecuación (1.3.3) con $\alpha_1, \dots, \alpha_n$ parámetros arbitrarios se llama representación paramétrica de Π_n .

Conviene ahora dar una caracterización de los puntos mínimos de F sobre un n -plano Π_n , que sirva como guía para encontrarlos. Sea \mathbf{U} la matriz con columnas

$\mathbf{u}^1, \mathbf{u}^2, \dots, \mathbf{u}^n$. Entonces (1.3.3) se puede escribir como

$$\mathbf{u} = \mathbf{u}^0 + \mathbf{U}\mathbf{v},$$

donde \mathbf{v} es el vector cuyas componentes son $\alpha_1, \dots, \alpha_n$.

En el n -plano Π_n la función F es una función cuadrática, ya que si G es la función F restringida al n -plano Π_n tenemos

$$\begin{aligned} G(\mathbf{v}) &= F(\mathbf{u}^0 + \mathbf{U}\mathbf{v}) = \frac{1}{2}(\mathbf{u}^0 + \mathbf{U}\mathbf{v})^T \mathbf{A}(\mathbf{u}^0 + \mathbf{U}\mathbf{v}) - \mathbf{b} \cdot (\mathbf{u}^0 + \mathbf{U}\mathbf{v}) \\ &= \frac{1}{2}\mathbf{u}^0 \mathbf{A} \mathbf{u}^0 - \mathbf{b} \cdot \mathbf{u}^0 + \frac{1}{2}\mathbf{v}^T \mathbf{U}^T \mathbf{A} \mathbf{U} \mathbf{v} + (\mathbf{A} \mathbf{u}^0 - \mathbf{b}) \cdot \mathbf{U} \mathbf{v} \\ &= \frac{1}{2}\mathbf{v}^T \mathbf{B} \mathbf{v} - \mathbf{g} \cdot \mathbf{v} + F(\mathbf{u}^0) \end{aligned}$$

donde

$$\mathbf{B} = \mathbf{U}^T \mathbf{A} \mathbf{U},$$

$$\mathbf{g} = -\mathbf{U}^T F'(\mathbf{u}^0).$$

Debido a que \mathbf{A} es positiva definida y simétrica también lo es \mathbf{B} . El punto

$$\bar{\mathbf{v}} = \mathbf{B}^{-1} \mathbf{g}$$

es solución de la ecuación $\mathbf{B}\bar{\mathbf{v}} = \mathbf{g}$ y, por lo tanto, es un mínimo estricto de G . Entonces el punto

$$\bar{\mathbf{u}} = \mathbf{u}^0 + \mathbf{U}\bar{\mathbf{v}}$$

es un punto mínimo estricto de F en Π_n . Además, de la relación

$$\mathbf{0} = G'(\bar{\mathbf{v}}) = \mathbf{U}^T F'(\mathbf{u}^0 + \mathbf{U}\bar{\mathbf{v}}) = \mathbf{U}^T F'(\bar{\mathbf{u}}),$$

obtenemos que, el punto mínimo de F en Π_n se caracteriza por las ecuaciones

$$\mathbf{u}^i \cdot F'(\bar{\mathbf{u}}) = 0, \quad (i = 1, \dots, n),$$

o por la condición de que $F'(\bar{\mathbf{u}})$ sea ortogonal a Π_n .

Los resultados descritos se resumen en la siguiente Proposición.

PROPOSICIÓN 1.3.1 *Supongamos que el hessiano \mathbf{A} de una de una función cuadrática F es positivo definido. Un punto $\bar{\mathbf{u}}$ en un n -plano minimiza a F en Π_n si el gradiente $F'(\bar{\mathbf{u}})$ es ortogonal a Π_n , además existe un único punto mínimo de F en Π_n .*

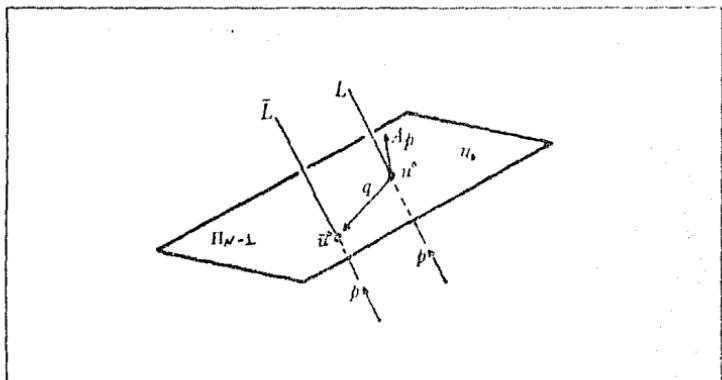


FIGURA 1. Puntos mínimos de F sobre dos líneas paralelas L y \bar{L} .

Ahora veamos como desarrollar un procedimiento para encontrar los mínimos de F en $\Pi_1, \Pi_2, \dots, \Pi_N$, hiperplanos dados.

PROPOSICIÓN 1.3.2 *Los puntos mínimos de F en líneas paralelas están sobre un hiperplano $\hat{\Pi}_{N-1}$ que pasa por el punto mínimo u_s de F . El $(N-1)$ -plano $\hat{\Pi}_{N-1}$ se define por medio de la ecuación*

$$\mathbf{p} * (\mathbf{A}\mathbf{u} - \mathbf{b}) = 0, \quad (1.3.4)$$

donde \mathbf{p} es un vector dirección para estas líneas paralelas. El vector \mathbf{Ap} es normal a $\hat{\Pi}_{N-1}$.

Demarcación:

Sean u^0 y \bar{u}^0 puntos mínimos de F sobre dos líneas paralelas L y \bar{L} respectivamente, como se muestra en la Figura 1. La dirección de estas líneas se puede representar por medio de un vector \mathbf{p} no nulo. En el punto mínimo de F en L , el gradiente $F'(u^0) = \mathbf{Au}^0 - \mathbf{b}$ es ortogonal a L y por lo tanto a \mathbf{p} . El punto u^0 satisface, entonces, la ecuación (1.3.4). De igual forma, \bar{u}^0 satisface la ecuación, la cual representa un $(N-1)$ -plano $\hat{\Pi}_{N-1}$, cuya normal es \mathbf{Ap} , ya que

$$0 = \mathbf{p} * (\mathbf{Au} - \mathbf{b}) = \mathbf{p} * \mathbf{A}(\mathbf{u} - \mathbf{u}_s) = \mathbf{Ap} * (\mathbf{u} - \mathbf{u}_s),$$

además la ecuación indica explícitamente que u_s está en el plano $\hat{\Pi}_{N-1}$.

Como se demostró antes, \mathbf{Ap} es ortogonal a $\hat{\Pi}_{N-1}$; cuando esto sucede se dice que \mathbf{p} es conjugado (\mathbf{A} -ortogonal) a $\hat{\Pi}_{N-1}$ y que $\hat{\Pi}_{N-1}$ es conjugado a \mathbf{p} .

La representación paramétrica de una línea L es de la forma $\mathbf{u} = \mathbf{u}^0 + \alpha \mathbf{p}$, donde \mathbf{u}^0 es un punto en L y α es un parámetro que toma valores de $-\infty$ a ∞ . El residuo

de u^0 es

$$\mathbf{r}^0 = -F'(u^0) = \mathbf{b} - \mathbf{A}u^0,$$

entonces

$$\begin{aligned} F(u^0 + \alpha p) &= \frac{1}{2}(u^0 + \alpha p)^T \mathbf{A}(u^0 + \alpha p) - \mathbf{b} \cdot (u^0 + \alpha p) \\ &= F(u^0) + \alpha p \cdot (\mathbf{A}u^0 - \mathbf{b}) + \frac{1}{2}\alpha^2 p \cdot \mathbf{A}p \\ &= F(u^0) + \alpha p \cdot \mathbf{r}^0 + \frac{1}{2}\alpha^2 p \cdot \mathbf{A}p. \end{aligned} \quad (1.3.5)$$

La función (1.3.5) de α tiene un valor mínimo cuando $\alpha = p \cdot \mathbf{r}^0 / p \cdot \mathbf{A}p$. Tenemos el siguiente resultado.

PROPOSICIÓN 1.3.3 *El punto mínimo u^1 de F en la línea $u = u^0 + \alpha p$ está dado por la ecuación*

$$u^1 = u^0 + \alpha_1 p,$$

donde

$$\alpha_1 = \frac{c}{d}, \quad c = p \cdot \mathbf{r}^0, \quad d = p \cdot \mathbf{A}p, \quad \mathbf{r}^0 = -F'(u^0) = \mathbf{b} - \mathbf{A}u^0.$$

Una Proposición relacionada con 1.3.2 es

PROPOSICIÓN 1.3.4 *Los puntos mínimos de F en $(N-1)$ -planos Π_{N-1} paralelos están en una línea L , conjugada a estos hiperplanos y que pasa por el punto mínimo u_s de F .*

Demonstración:

Por la PROPOSICIÓN 1.3.1 el gradiente $F'(u^0) = \mathbf{A}u^0 - \mathbf{b}$ del punto mínimo u^0 de F en Π_{N-1} es ortogonal a este hiperplano y por lo tanto debe ser múltiplo de la normal \mathbf{q} de Π_{N-1} . De acuerdo con esto existe un número α tal que

$$\mathbf{A}u^0 - \mathbf{b} = \alpha \mathbf{q},$$

o bien,

$$u^0 = \mathbf{A}^{-1}\mathbf{b} + \alpha \mathbf{A}^{-1}\mathbf{q} = u_s + \alpha \mathbf{A}^{-1}\mathbf{q}. \quad (1.3.6)$$

La ecuación (1.3.6) representa paramétricamente a una línea que pasa por el punto mínimo u_s de F en \mathbb{R}^N . Además el vector $p = \mathbf{A}^{-1}\mathbf{q}$ tiene la propiedad de ser conjugado a Π_{N-1} por ser \mathbf{q} la normal de este hiperplano \blacksquare .

Como una extensión de la PROPOSICIÓN 1.3.4 tenemos

PROPOSICIÓN 1.3.5 Los puntos mínimos de F en n -planos paralelos están en un $(N-n)$ -plano conjugado a estos n -planos que pasa por el punto mínimo u_s de F . En otras palabras dado un conjunto de $N-n$ vectores linealmente independientes q^1, \dots, q^{N-n} , para cualquier conjunto de números reales $\rho_1, \dots, \rho_{N-n}$, el punto mínimo u^0 de F en el n -plano

$$\Pi_n : q^i * u = \rho_i \quad (i = 1, \dots, N-n)$$

está sobre el $(N-n)$ -plano

$$\hat{\Pi}_{N-n} : u = u_s + \alpha_1 W^{-1} q^1 + \dots + \alpha_{N-n} W^{-1} q^{N-n}$$

que pasa por el punto mínimo u_s de F . $\hat{\Pi}_{N-n}$ es conjugado a Π_n .

La demostración es muy parecida a la de la PROPOSICIÓN 1.3.3 por lo que no la desarrollaremos.

PROPOSICIÓN 1.3.6 Dado un n -plano Π_n y un vector w , el conjunto $\Pi_n + w$ de puntos u expresables como $u = u + w$ con u en Π_n es un n -plano $\tilde{\Pi}_n$ paralelo a Π_n . Inversamente, si $\tilde{\Pi}_n$ es un n -plano paralelo a Π_n y $w = \tilde{u} - u$ es un vector que une un punto u en Π_n a un punto \tilde{u} en $\tilde{\Pi}_n$, entonces $\tilde{\Pi}_n = \Pi_n + w$ por lo que existe un vector único p conjugado a Π_n tal que $\tilde{\Pi}_n = \Pi_n + p$. Si u^0 minimiza a F en Π_n , entonces $\tilde{u}^0 = u^0 + p$ minimiza a F en $\tilde{\Pi}_n$.

Demarcación:

Sea u^0 un punto en Π_n y u^1, \dots, u^n vectores linealmente independientes en Π_n . Entonces Π_n se puede representar paramétricamente como

$$u = u^0 + \alpha_1 u^1 + \dots + \alpha_n u^n.$$

Si \tilde{u}^0 es un punto en un segundo n -plano $\tilde{\Pi}_n$, entonces este hiperplano es paralelo a Π_n si y solo si se puede representar paramétricamente por medio de la ecuación

$$\tilde{u} = \tilde{u}^0 + \alpha_1 u^1 + \dots + \alpha_n u^n.$$

El conjunto $\Pi_n + w$ será

$$\begin{aligned} \tilde{u} &= u^0 + \alpha_1 u^1 + \dots + \alpha_n u^n + w \\ &= \tilde{u}^0 + \alpha_1 u^1 + \dots + \alpha_n u^n. \end{aligned}$$

donde $\tilde{u}^0 = u^0 + w$ por lo que $\tilde{\Pi}_n$ es paralelo a Π_n . Ahora si $\tilde{\Pi}_n$ es paralelo a Π_n y $w = \tilde{u}^0 - u^0$ donde \tilde{u}^0 es un punto en $\tilde{\Pi}_n$ y u^0 en Π_n , entonces $\tilde{u}^0 = w + u^0$ y un

punto \bar{u} en $\bar{\Pi}_n$ se puede escribir como

$$\begin{aligned}\bar{u} &= u^0 + \alpha_1 u^1 + \dots + \alpha_n u^n \\ &\approx w + u^0 + \alpha_1 u^1 + \dots + \alpha_n u^n \\ &= w + u,\end{aligned}$$

donde u es un punto de Π_n . Si u^0 y u^n son, respectivamente, los puntos mínimos de Π_n y $\bar{\Pi}_n$, entonces el vector $p = \bar{u}^0 - u^0$ está en el H_{N-n} plano conjugado a Π_n y a $\bar{\Pi}_n$ (PROPOSICIÓN 1.3.5) y es conjugado a estos n -planos. Además $\bar{\Pi}_n = \Pi_n + p$. Inversamente, supongamos que p es conjugado a Π_n y que $\bar{\Pi}_n = \Pi_n + p$. Si u^0 minimiza F en Π_n , entonces $F'(u^0)$ y βp son ambos ortogonales a Π_n , de tal forma que $F'(u^0 + p) = F'(u^0) + \beta p$ es ortogonal a Π_n y entonces al n -plano paralelo $\bar{\Pi}_n = \Pi_n + p$. Se sigue que el punto $u^0 + p$ es el punto mínimo u^0 de F en Π_n . Esto establece la última parte de la Proposición **6**.

PROPOSICIÓN 1.3.7 *Dado un n -plano Π_n y un vector w fuera de éste, el conjunto $\Pi_n + \beta w$ de todos los puntos $u + \beta w$, determinados por los puntos u en Π_n y los números reales β , es un $(n+1)$ -plano Π_{n+1} que expande a Π_n y a $\bar{\Pi}_n = \Pi_n + w$. Existe un vector único p conjugado a Π_n tal que $\bar{\Pi}_n = \Pi_n + p$ y $\Pi_{n+1} = \Pi_n + \beta p$, el punto mínimo u^1 de F en Π_{n+1} está en la línea $u = u^0 + \alpha p$, donde u^0 es el punto mínimo de F en Π_n .*

Demostración:

Si u^0 es el punto mínimo de F en Π_n y u^1, \dots, u^n son vectores linealmente independientes en Π_n , entonces Π_n se puede representar paramétricamente por medio de la ecuación $u = u^0 + \alpha_1 u^1 + \dots + \alpha_n u^n$. Si w no está en Π_n , los vectores u^1, \dots, u^n, w son linealmente independientes y la ecuación $v = u^0 + \alpha_1 u^1 + \dots + \alpha_n u^n + \beta w$ con parámetros arbitrarios $\alpha_1, \dots, \alpha_n, \beta$ definen un $(n+1)$ -plano Π_{n+1} que cumple las condiciones descritas en la Proposición. Por la PROPOSICIÓN 1.3.6 existe un vector único p conjugado a Π_n tal que $\bar{\Pi}_n = \Pi_n + p$. En virtud de la PROPOSICIÓN 1.3.4 con Π_{n+1} jugando el papel \mathbb{R}^N , el punto mínimo u^1 de F en Π_{n+1} está en la línea $u = u^0 + \alpha p$ que pasa por el punto mínimo de Π_n y es conjugada al mismo **6**.

1.4 Minimización de la Función Cuadrática F en n -Planos

Sea $\{p^1, \dots, p^n\}$ un conjunto de vectores no nulos mutuamente conjugados, es decir, se satisfacen las relaciones

$$p^i \cdot \beta p^j = 0 \quad (i \neq j, i = 1, \dots, n). \quad (1.4.1)$$

PROPOSICIÓN 1.4.1 *Sia*

$$\Pi_n : u = u^0 + \alpha_1 p^1 + \dots + \alpha_n p^n$$

el n -plano que contiene al punto u^0 y está determinado por un sistema conjugado p^1, \dots, p^n . El punto mínimo u^n de F en Π_n está dado por la fórmula

$$u^n = u^0 + \alpha_1 p^1 + \dots + \alpha_n p^n, \quad (1.4.2a)$$

donde

$$\alpha_i = \frac{c_i}{d_i}, \quad c_i = p^i * r^0, \quad d_i = p^i * Ap^i, \quad (i = 1, \dots, n) \quad (1.4.2b)$$

y $r^0 = -F'(u^0) = b - Au^0$ es el residuo de F en u^0 . El residuo de $r^n = -F'(u^n)$ de F en u^n está determinado por

$$r^n = r^0 - \alpha_1 Ap^1 - \dots - \alpha_n Ap^n, \quad (1.4.3)$$

y es ortogonal a Π_n , de tal forma que

$$p^i * r^n = 0 \quad (i = 1, \dots, n). \quad (1.4.4)$$

El valor mínimo de F en Π_n es

$$F(u^n) = F(u^0) - \frac{1}{2}(\alpha_1 c_1 + \dots + \alpha_n c_n). \quad (1.4.5)$$

Demarcación:

Por la PROPOSICIÓN 1.3.1 el punto mínimo u^n de F en Π_n se caracteriza por el hecho de que su residuo $r^n = -F'(u^n)$ es ortogonal a Π_n y por lo tanto a los vectores p^1, \dots, p^n en Π_n . Como

$$r^n = b - Au^n = b - A(u^0 + \alpha_1 p^1 + \dots + \alpha_n p^n),$$

la fórmula (1.4.3) se satisface. Combinando (1.4.3) y (1.4.4) con las relaciones (1.4.1) encontramos que para $i = 1, \dots, n$

$$0 = p^i * r^n = p^i * r^0 - \sum_{j=1}^n \alpha_j p^i * Ap^j = c_i - \alpha_i d_i$$

por lo que

$$\alpha_i = \frac{c_i}{d_i}.$$

Para obtener (1.4.5) usamos la identidad

$$F(u + p) - F(u) = p * F'(u) + \frac{1}{2}p * Ap$$

con $u = u^n$ y

$$p = u^0 - u^n = -\alpha_1 p^1 - \dots - \alpha_{n+1} p^{n+1}.$$

Ya que p es un vector sobre Π_n , es ortogonal a $F'(u^n) = -r^n$, de tal forma que

$$\begin{aligned} F(u^0) - F(u^n) &= p * F'(u^n) + \frac{1}{2} p * A p \\ &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j p^i * A p^j \\ &= \frac{1}{2} \sum_{i=1}^n \alpha_i^2 p^i * A p^i = \frac{1}{2} \sum_{i=1}^n \alpha_i^2 d_i = \frac{1}{2} \sum_{i=1}^n \alpha_i c_i, \end{aligned}$$

por las relaciones de conjugación (1.4.1) y (1.4.2b) \square

PROPOSICIÓN 1.4.2 *Sea $\{p^1, \dots, p^m\}$ un sistema conjugado de vectores. Para un punto dado u^0 , sean u^1, \dots, u^m los puntos definidos recursivamente por el hecho de que para cada $n+1$, $1 \leq n+1 \leq m$, el punto u^{n+1} minimice a F sobre la línea*

$$u = u^n + \alpha p^n. \quad (1.4.6)$$

Entonces u^n y el residuo $r^n = -F'(u^n)$ son

$$\begin{aligned} u^n &= u^{n-1} + \alpha_n p^n, \\ r^n &= r^{n-1} - \alpha_n A p^n, \end{aligned} \quad (1.4.7a)$$

donde

$$\alpha_n = \frac{c_n}{d_n}, \quad c_n = p^n * r^{n-1}, \quad d_n = p^n * A p^n. \quad (1.4.7b)$$

El punto u^n minimiza a F en el n -plano

$$\Pi_n : u = u^0 + \alpha_1 p^1 + \dots + \alpha_n p^n.$$

Tenemos las relaciones

$$\begin{aligned} p^n * r^j &= c_n \quad (j < n \leq m), \\ p^n * r^j &= 0, \quad (n+1 \leq j \leq m). \end{aligned} \quad (1.4.8)$$

Demonstración:

Como u^n minimiza a F en el n -plano (1.4.6), se sigue de la PROPOSICIÓN 1.4.1, con u^{n-1} tomando el papel de u^0 , que u^n y r^n se pueden escribir como en (1.4.7) y que

$$p^n \cdot r^n = 0, \quad (n = 1, \dots, m).$$

Por las relaciones de conjugación $p^n \cdot \Delta p^j = 0, (n \neq j)$ tenemos

$$p^n \cdot r^{j+1} = p^n \cdot (r^j - \alpha_j \Delta p^j) = p^n \cdot r^j, \quad (j \neq n, j = 1, \dots, m).$$

En consecuencia, usando $j = 0, \dots, n-2$

$$p^n \cdot r^0 = p^n \cdot r^1 = \dots = p^n \cdot r^{n-1} = c_n \quad (n \leq m),$$

tomando $j = n, \dots, m-1$

$$p^n \cdot r^m = p^n \cdot r^{m-1} = \dots = p^n \cdot r^n = 0 \quad (n \leq m).$$

Esto demuestra la relación (1.4.8). Como $c_j = p^j \cdot r^0$, se sigue de la PROPOSICIÓN 1.4.1 que u^n minimiza a F en el n -plano \blacksquare

1.5 Método de Gradiente Conjugado

Como consecuencia de los resultados anteriores, para minimizar la función cuadrática F se puede utilizar una rutina iterativa en la que habiendo encontrado un punto u^{n-1} que minimice a la función F sobre Π_{n-1} y una dirección p^n conjugada a Π_{n-1} , encontramos el punto mínimo u^n en Π_n minimizando la función sobre la línea $u = u^{n-1} + \alpha p^n$.

Este método, llamado de direcciones conjugadas, se puede formalizar como sigue.

Algoritmo 1.5

PASO INICIAL: Seleccionar una estimación inicial u^0 del punto mínimo u_* . Calcular el residuo

$$r^0 = b - \Delta u^0$$

y seleccionar una dirección inicial $p^1 \neq 0$.

PASOS ITERATIVOS: Habiendo obtenido la estimación u^{n-1} de u_* , su residuo r^{n-1} y la dirección p^n , calcular una nueva aproximación u^n y su residuo r^n por medio

de las fórmulas

$$\begin{aligned}\alpha_n &= \frac{\mathbf{p}^n \cdot \mathbf{r}^{n+1}}{\mathbf{p}^n \cdot \mathbf{A}\mathbf{p}^n}, & \{1, 5, 6\} \\ \mathbf{u}^n &= \mathbf{u}^{n-1} + \alpha_n \mathbf{p}^n, \\ \mathbf{r}^n &= \mathbf{r}^{n-1} + \alpha_n, \\ \mathbf{A}\mathbf{p}^n &= \mathbf{b} - \mathbf{A}\mathbf{u}^n.\end{aligned}\quad (1.5.1b)$$

Seleccionar entonces un vector \mathbf{p}^{n+1} conjugado a $\mathbf{p}^1, \dots, \mathbf{p}^n$, es decir, un vector \mathbf{p}^{n+1} tal que se cumplan las relaciones

$$\mathbf{p}^j \cdot \mathbf{A}\mathbf{p}^{n+1} = 0, \quad (j = 1, \dots, n). \quad (1.5.1c)$$

TERMINACIÓN: Terminar en el m -ésimo paso si

$$\mathbf{r}^m = \mathbf{0}.$$

Hasta ahora no hemos definido cuáles direcciones conjugadas $\mathbf{p}^1, \dots, \mathbf{p}^n$ utilizaremos, ni cómo las obtendremos. A continuación desarrollaremos un conjunto de direcciones conjugadas partiendo de vectores $\mathbf{w}^0, \dots, \mathbf{w}^n$ linealmente independientes utilizando el método de Gram-Schmidt:

$$\mathbf{p}^1 = \mathbf{w}^0 \quad (1.5.2a)$$

$$\mathbf{p}^{n+1} = \mathbf{w}^n + \sum_{j=1}^n \beta_{n+1,j} \mathbf{p}^j, \quad (1.5.2b)$$

donde, para $j = 1, \dots, n$,

$$\beta_{n+1,j} = -\frac{\mathbf{p}^j \cdot \mathbf{A}\mathbf{w}^n}{d_j}, \quad d_j = \mathbf{p}^j \cdot \mathbf{A}\mathbf{p}^j. \quad (1.5.2c)$$

El método de Gram-Schmidt asegura que se satisfacen las relaciones conjugadas [5].

$$\mathbf{p}^j \cdot \mathbf{A}\mathbf{p}^n = 0, \quad (j \neq n).$$

El algoritmo (1.5.2) tiene la propiedad de que el vector \mathbf{w}^n se puede seleccionar después de que los vectores $\mathbf{p}^1, \dots, \mathbf{p}^n$ se han calculado. Por supuesto que \mathbf{w}^n se debe escoger de tal forma que $\mathbf{w}^0, \dots, \mathbf{w}^n$ o equivalentemente $\mathbf{p}^1, \dots, \mathbf{p}^n, \mathbf{w}^n$ sean linealmente independientes.

En el algoritmo CD se han seleccionado los puntos \mathbf{u}^n de tal forma que su residuo \mathbf{r}^n sea ortogonal a \mathbf{p}^n . ¿Cómo podemos utilizar este hecho para generar las direcciones $\mathbf{p}^1, \dots, \mathbf{p}^{n+1}$? Supongamos que hemos escogido el punto \mathbf{u}^0 y la dirección \mathbf{p}^1 , además hemos calculado \mathbf{r}^0 , entonces $\mathbf{u}^1 = \mathbf{u}^0 + \alpha_1 \mathbf{p}^1$ donde α_1 se define por medio de la ecuación (1.5.1a). Esta información permite calcular $\mathbf{r}^1 = \mathbf{b} - \mathbf{A}\mathbf{u}^1$, como habíamos señalado antes \mathbf{r}^1 es ortogonal a \mathbf{p}^1 y por lo tanto estos dos vectores son linealmente independientes. Es por esto que podemos generar $\mathbf{p}^2 = \mathbf{r}^1 - \beta_{2,1} \mathbf{p}^1$, donde $\beta_{2,1}$ está definido por la fórmula (1.5.2c). Así \mathbf{p}^2 será un vector conjugado a \mathbf{p}^1 . Siguiendo así podemos generar la base $\mathbf{p}^1, \dots, \mathbf{p}^{n+1}$. Formalizando:

$$\mathbf{p}^1 = \mathbf{r}^0 \quad (1.5.3a)$$

$$\mathbf{p}^{n+1} = \mathbf{r}^n + \sum_{j=1}^n \beta_{n+1,j} \mathbf{p}^j, \quad (1.5.3b)$$

donde, para $j = 1, \dots, n$,

$$\beta_{n+1,j} = -\frac{\mathbf{p}^j \cdot \mathbf{A}\mathbf{r}^n}{\mathbf{p}^j \cdot \mathbf{A}\mathbf{p}^j}. \quad (1.5.3c)$$

Es importante recalcar que el hiperplano H_n se puede escribir paramétricamente como

$$H_{n+1} : \mathbf{u} = \mathbf{u}^0 + a_0 \mathbf{r}^0 + \dots + a_n \mathbf{r}^n,$$

es decir, $H_{n+1} = \mathbf{u}^0 + \text{gen}\{\mathbf{r}^0, \dots, \mathbf{r}^n\}$. Estos hiperplanos son conocidos como espacios afines de Krylov. Por otro lado sabemos que \mathbf{r}^{n+1} es ortogonal a este hiperplano o, lo que es lo mismo, es ortogonal a $\mathbf{r}^0, \dots, \mathbf{r}^n$. Como esto sucede para cualquier n tenemos las relaciones

$$\mathbf{r}^i \cdot \mathbf{r}^j = 0, \quad (i \neq j).$$

El costo computacional del algoritmo (1.5.3) es muy alto porque es necesario guardar la información de todos los vectores $\mathbf{p}^1, \dots, \mathbf{p}^{n+1}$ que se van generando. Veámos si podemos reducir la expresión general del vector \mathbf{p}^{n+1} .

PROPOSICIÓN 1.5.1 En el algoritmo (1.5.3) $\mathbf{p}^j \cdot \mathbf{A}\mathbf{r}^n = 0$ si $j < n$.

Demostración:

De (1.4.7a) sabemos que $\mathbf{r}^j = \mathbf{r}^{j-1} - \alpha_j \mathbf{A}\mathbf{p}^j$, entonces $\alpha_j \mathbf{A}\mathbf{p}^j = \mathbf{r}^{j-1} - \mathbf{r}^j$ y tenemos

$$\alpha_j \mathbf{p}^j \cdot \mathbf{A}\mathbf{r}^n = \alpha_j \mathbf{A}\mathbf{p}^j \cdot \mathbf{r}^n = (\mathbf{r}^{j-1} - \mathbf{r}^j) \cdot \mathbf{r}^n = 0,$$

si $j < n$. Como α_j no es cero, $\mathbf{p}^j \cdot \mathbf{A}\mathbf{r}^n = 0$ es

Como consecuencia de esta Proposición, modificamos el siguiente término del algoritmo (1.5.3): $p^{n+1} = r^n + \beta_{n+1}p^n$, donde $\beta_{n+1} = -\frac{p^n \cdot A p^n}{p^n \cdot p^n}$.

Es importante observar que el valor de la función (1.3.1) en un vector u es igual a un medio de la norma (asociada al producto interior $(v, w) = v \cdot A^{-1}w$) de su residuo $r = A(u_s - u)$ más una constante, ya que

$$\begin{aligned} F(u) + \frac{1}{2}u_s \cdot b &= \frac{1}{2}(u_s - u) \cdot A(u_s - u) \\ &= \frac{1}{2}Ae \cdot A^{-1}Ae = \frac{1}{2}r \cdot A^{-1}r \\ &= \frac{1}{2}\|r\|_{A^{-1}}^2. \end{aligned}$$

Entonces, al minimizar la función (1.3.1) sobre el n -ésimo espacio afín de Krylov, implicitamente estamos minimizando la norma del residuo.

El algoritmo de gradiente conjugado que ya incluye el cálculo de la base conjugada es:

Algoritmo CG

PASO INICIAL: Seleccionar un punto u^0 y calcular

$$p^1 = r^0 = b - Au^0.$$

PASOS ITERATIVOS: Habiendo obtenido u^{n-1}, r^{n-1} y p^n calcular u^n, r^n y p^{n+1} por medio de las fórmulas

$$\alpha_n = \frac{c_n}{d_n},$$

$$d_n = p^n \cdot A p^n,$$

$$c_n = r^{n-1} \cdot r^{n-1} = p^n \cdot r^{n-1}$$

$$u^n = u^{n-1} + \alpha_n p^n,$$

$$r^n = b - Au^n,$$

$$\beta_{n+1} = -\frac{p^n \cdot Ar^n}{d_n},$$

$$p^{n+1} = r^n + \beta_{n+1}p^n.$$

TERMINACIÓN: Terminar en el m -ésimo paso si $r^m = 0$.

Capítulo 2

Modificaciones para el caso no simétrico

2.1 Introducción

Discutiremos cuatro métodos derivados del método de gradiente conjugado para sistemas de ecuaciones lineales no simétricos, que en su forma matricial escribirímos como

$$\mathbf{P}\mathbf{u} = \mathbf{a}, \quad (2.1.1)$$

donde \mathbf{P} es no simétrica y no singular. Primero discutiremos una extensión obvia o natural [8] a matrices no simétricas, que se obtiene al aplicar el método de gradiente conjugado a la ecuación resultante de aplicar \mathbf{P}^T a la ecuación (2.1.1); i.e.,

$$\mathbf{R}\mathbf{u} = \mathbf{P}^T\mathbf{a} = \mathbf{b}, \quad (2.1.2)$$

en la que $\mathbf{R} = \mathbf{P}^T\mathbf{P}$. Obsérvese que la matriz \mathbf{R} así definida, es necesariamente de dimensión $N \times N$, positiva definida y simétrica. Por esto mismo, el método de gradiente conjugado es aplicable a la ecuación (2.1.2). Ya que la ecuación (2.1.2) es equivalente^{*} a la original (2.1.1), esta es una forma de extender el método de gradiente conjugado a matrices no simétricas.

Los otros tres métodos son el de residuo conjugado generalizado (GCR), GCR(k) y ORTHOMIN(k). En realidad GCR es el método básico, mientras que GCR(k) y ORTHOMIN(k) son dos simplificaciones (y en cierto sentido aproximaciones de GCR), que disminuyen el trabajo de procesamiento y el espacio de memoria requeridos en cada paso de iteración. Desde luego, estas simplificaciones tienen un precio: necesitan que con GCR, si no existieran errores de redondeo, la solución se obtendría en N iteraciones; cuando más, en cambio con ORTHOMIN(k) o GCR(k), no hay una garantía similar.

2.2 Extensión natural a matrices no simétricas

Sea \mathbf{u}_n la aproximación enésima a la solución \mathbf{u}_* del sistema de ecuaciones lineales (2.1.1), donde \mathbf{P} es una matriz $N \times N$ dimensional no simétrica. Sea \mathbf{r}^n el residuo

Dos sistemas de ecuaciones son equivalentes cuando toda solución \mathbf{u}_ de una de ellas, es también solución de la otra.

correspondiente, dado por

$$\mathbf{r}^n = \mathbf{a} - \mathbb{P}\mathbf{u}^n.$$

Si aplicamos CG a (2.1.2) obtenemos el algoritmo siguiente:

Algoritmo EN

PASO INICIAL: Escoger una aproximación \mathbf{u}^0 y calcular

$$\mathbf{r}^0 = \mathbf{a} - \mathbb{P}\mathbf{u}^0, \quad \mathbf{p}^1 = \mathbb{P}^T \mathbf{r}^0 = \mathbb{P}^T(\mathbf{a} - \mathbb{P}\mathbf{u}^0).$$

PASOS ITERATIVOS: Habiendo obtenido \mathbf{u}^{n+1} , \mathbf{r}^{n+1} y \mathbf{p}^n calcular \mathbf{u}^n , \mathbf{r}^n y \mathbf{p}^{n+1} por medio de las fórmulas

$$\alpha_n = \frac{c_n}{d_n},$$

$$d_n = \mathbb{P}\mathbf{p}^n + \mathbb{P}\mathbf{p}^n,$$

$$c_n = \mathbb{P}^T \mathbf{r}^{n+1} + \mathbb{P}^T \mathbf{r}^{n+1} = \mathbb{P}^T \mathbf{p}^n + \mathbf{r}^{n+1}, \quad (2.2.1a)$$

$$\mathbf{u}^n = \mathbf{u}^{n+1} + \alpha_n \mathbf{p}^n, \quad (2.2.1b)$$

$$\mathbf{r}^n = \mathbf{a} - \mathbb{P}\mathbf{u}^n = \mathbf{r}^{n+1} - \alpha_n \mathbb{P}\mathbf{p}^n, \quad (2.2.1b)$$

$$\beta_{n+1} = -\frac{\mathbb{P}\mathbf{p}^n + \mathbb{P}\mathbf{p}^n}{d_n}, \quad (2.2.1c)$$

$$\mathbf{p}^{n+1} = \mathbb{P}^T \mathbf{r}^n + \beta_{n+1} \mathbf{p}^n. \quad (2.2.1d)$$

TERMINACIÓN Terminar al m -ésimo paso si $\mathbf{r}^m = 0$.

Este algoritmo es aplicable a una matriz \mathbb{P} no simétrica y no singular cualquiera. Sin embargo tiene la desventaja de que la n -ésima aproximación \mathbf{u}^n minimiza a la función (1.3.1) sobre el espacio

$$\text{gen}\{\mathbb{P}^T \mathbf{r}^0, \dots, \mathbb{P}^T \mathbf{r}^{n+1}\} = \text{gen}\{(\mathbb{P}^T \mathbb{P})^0 \mathbf{v}^0, \dots, (\mathbb{P}^T \mathbb{P})^n \mathbf{v}^0\}.$$

Es decir que para generar los espacios de búsqueda se ha utilizado la matriz $\mathbb{P}^T \mathbb{P}$ en lugar de \mathbb{P} . Esta multiplicación por \mathbb{P}^T tiene el efecto de disminuir la velocidad de convergencia del método.

2.3 Método de residuo conjugado generalizado (GCR)

El método GCR minimiza a la función (1.3.1) sobre los espacios

$$\text{gen } \{\mathbf{r}^0, \dots, \mathbf{r}^{n-1}\} = \text{gen } \{\mathbf{P}\mathbf{e}^0, \dots, \mathbf{P}\mathbf{e}^{n-1}\} = \text{gen } \{\mathbf{P}\mathbf{e}^0, \dots, \mathbf{P}^n\mathbf{e}^0\}. \quad (2.3.1)$$

El algoritmo para realizar esta minimización es similar al (2.2.1), pero más laborioso. Supongamos que hemos tomado $\mathbf{p}^1 = \mathbf{r}^0 = \mathbf{a} - \mathbf{P}\mathbf{u}^0$ y hemos calculado

$$\mathbf{p}^i = \mathbf{r}^{i-1} + \sum_{j=1}^{i-1} \beta_{ij} \mathbf{p}^j \quad (i = 1, \dots, n)$$

donde

$$\beta_{ij} = -\frac{\mathbf{P}\mathbf{r}^{i-1} \cdot \mathbf{P}\mathbf{p}^j}{\mathbf{P}\mathbf{p}^j \cdot \mathbf{P}\mathbf{p}^j}$$

y \mathbf{r}^i ha sido calculado por medio de las fórmulas (2.2.1a), (2.2.1b). El método de gradiente conjugado asegura que el vector $\mathbf{P}^T\mathbf{r}^n$ es ortogonal a $\mathbf{p}^1, \dots, \mathbf{p}^n$ y por lo tanto a $\mathbf{r}^0, \dots, \mathbf{r}^{n-1}$. Para generar un vector \mathbf{p}^{n+1} ortogonal a $\mathbf{p}^1, \dots, \mathbf{p}^n$ necesitamos que \mathbf{r}^n sea linealmente independiente de $\mathbf{r}^0, \dots, \mathbf{r}^{n-1}$. ¿Qué condiciones necesitamos imponer sobre \mathbf{P} para que el vector \mathbf{r}^n cumpla con esta condición?

Sería $\alpha_0\mathbf{r}^0 + \dots + \alpha_n\mathbf{r}^n = 0$, ya que $\mathbf{P}^T\mathbf{r}^i$ es ortogonal a \mathbf{r}^i si i es mayor que j tenemos

$$\mathbf{P}^T\mathbf{r}^n \cdot (\alpha_0\mathbf{r}^0 + \dots + \alpha_n\mathbf{r}^n) = \alpha_n\mathbf{r}^n \cdot \mathbf{P}^T\mathbf{r}^n = 0,$$

si $\mathbf{r}^n \cdot \mathbf{P}^T\mathbf{r}^n$ es distinto de cero, $\alpha_n = 0$. Entonces

$$\alpha_0\mathbf{r}^0 + \dots + \alpha_{n-1}\mathbf{r}^{n-1} = 0,$$

por lo que $\alpha_0 = \dots = \alpha_{n-1} = 0$ porque $\mathbf{r}^0, \dots, \mathbf{r}^{n-1}$ son linealmente independientes. Entonces basta con pedir que $\mathbf{u} \cdot \mathbf{P}^T\mathbf{u}$ sea distinto de cero para toda $\mathbf{u} \neq 0$ para que \mathbf{r}^n sea linealmente independiente de $\mathbf{r}^0, \dots, \mathbf{r}^{n-1}$. Si suponemos que la parte simétrica de \mathbf{P} es positiva definida tenemos

$$0 < \mathbf{u} \cdot \frac{1}{2}(\mathbf{P}^T + \mathbf{P})\mathbf{u} = \frac{1}{2}(\mathbf{u} \cdot \mathbf{P}^T\mathbf{u} + \mathbf{u} \cdot \mathbf{P}\mathbf{u}) = \mathbf{u} \cdot \mathbf{P}^T\mathbf{u}$$

y la condición se cumple.

En el método de gradiente conjugado inicialmente aparecieron los términos β_{ij} pero en ese caso simplificamos la expresión (1.5.4) porque β_{ij} era cero si $j < i - 1$.

Ahora tenemos

$$\beta_{ij} = -\frac{\mathbf{P}r^{i-1} \cdot \mathbf{P}p^j}{\mathbf{P}p^j \cdot \mathbf{P}p^j} \quad (j = 1, \dots, i-1)$$

desarrollando el término $\mathbf{P}r^{i-1} \cdot \mathbf{P}p^j$, utilizando (2.2.1b), obtenemos

$$\begin{aligned}\mathbf{P}r^{i-1} \cdot \mathbf{P}p^j &= \alpha_j \mathbf{P}^T r^{i-1} + (r^{i-1} - \mathbf{P}r^i) \\ &= r^{i-1} \cdot (\mathbf{P}^T r^{i-1} - \mathbf{P}^T \mathbf{P}r^i).\end{aligned}$$

Sabemos que $r^i \cdot \mathbf{P}^T \mathbf{P}r^i$ es cero si $j > i-1$ pero eso no sucede en este caso.

Si \mathbf{P} es una matriz no simétrica con parte simétrica positiva definida obtenemos el algoritmo del residuo conjugado generalizado (GCR)

Algoritmo GCR

PASO INICIAL: Escoger una aproximación u^0 . Calcular $p^0 = r^0 = a - \mathbf{P}u^0$.

PASOS ITERATIVOS: Habiendo obtenido u^{n-1}, r^{n-1} y p^n calcular u^n, r^n y p^{n+1} como sigue

$$\begin{aligned}\alpha_n &= \frac{\mathbf{P}p^n \cdot r^{n-1}}{\mathbf{P}p^n \cdot \mathbf{P}p^n}, \\ u^n &= u^{n-1} + \alpha_n p^n, \\ r^n &= a - \mathbf{P}u^n = r^{n-1} - \alpha_n \mathbf{P}p^n \\ \beta_{n+1,j} &= -\frac{\mathbf{P}r^n \cdot \mathbf{P}p^j}{\mathbf{P}p^j \cdot \mathbf{P}p^j}, \\ p^{n+1} &= r^n + \sum_{j=1}^n \beta_{n+1,j} p^j\end{aligned}$$

TERMINACIÓN: Terminar en el m -ésimo paso si $r^m = 0$

Si no existieran errores de redondeo, GCR obtendría la solución exacta, al igual que gradiente conjugado, en a lo más N iteraciones. Sin embargo al trabajar con el sistema de vectores (2.3.1) es necesario mantener en la memoria de la máquina a la base de vectores del espacio generado por éstos, por lo que el trabajo y espacio de memoria requeridos en cada iteración es muy grande si N lo es. Los métodos de GCR(k) y ORTHOMIN(k) son dos modificaciones a GCR para disminuir el trabajo de procesamiento y el espacio de memoria requeridos.

A diferencia de lo dicho en la Sección 1.5, en el método de GCR se minimiza la norma euclídea del residuo de la función (1.3.1) sobre cada subespacio así de

Krylov en cada paso del algoritmo, ya que en este caso

$$F(u) + \frac{1}{2}u_k \cdot b = \frac{1}{2}\mathbf{P}^T e \cdot \mathbf{P}^T e = \frac{1}{2}\|r\|_2^2.$$

2.4 Métodos GCR(k) y ORTHOMIN(k)

Vinsome [14] propuso un método llamado ORTHOMIN(k) que es significativamente menos costoso por iteración. En vez de hacer p^{n+1} $\mathbf{P}^T\mathbf{P}$ -ortogonal a todas las direcciones precedentes $\{p^1, \dots, p^n\}$, se puede hacer $\mathbf{P}^T\mathbf{P}$ -ortogonal únicamente a los últimos k vectores $\{p^{n-k+1}, \dots, p^n\}$, de tal forma que

$$p^{n+1} = r^n + \sum_{j=n-k+1}^n \beta_{n+1,j} p^j,$$

con $\beta_{n+1,j}$, $j = n - k + 1, \dots, n$ definidos como en GCR. Así, únicamente tenemos que guardar la información de, a lo más, k vectores.

Otra posibilidad es reempezar en cada $k+1$ iteraciones, tomando como aproximación inicial al último vector encontrado. Nuevamente, a lo más k vectores dirección tienen que ser salvados, de tal forma que el espacio de memoria utilizado es el mismo que el de ORTHOMIN(k). Sin embargo el costo por iteración es menor ya que en general un número menor que k vectores se usan para encontrar p^{n+1} . Este método se conoce como GCR(k).

Capítulo 3

Nuevo método para el caso no simétrico

3.1 Introducción

Revisaremos nuevamente el método de gradiente conjugado bajo una óptica distinta, que nos permitirá introducir una idea propuesta por I. Herrera [10] y cuyo desarrollo, análisis y puesta a prueba como método de solución de sistemas no simétricos, es uno de los objetivos centrales de esta tesis. Se construirán aproximaciones a la solución de la ecuación

$$Au = b$$

(A positiva definida y simétrica) que minimizan el error directamente, sin utilizar la función auxiliar (1.3.1) definida en el capítulo 1. Minimizaremos la ecuación en subespacios anidados

$$H_1 \subset \dots \subset H_N,$$

de la siguiente manera; suponiendo que el vector u_s es conocido, encontraremos el vector u^0 en H_n que da el mínimo error $e^0 = u_s - u^0$ en ese subespacio. Para esto haremos uso de un producto escalar cualquiera (\cdot, \cdot) y al encontrar la expresión general del algoritmo definiremos cuál es el producto interior que convendrá utilizar, para que, todos los términos que aparezcan se puedan calcular.

En el caso no simétrico modificaremos únicamente el producto escalar a utilizar, es decir, los espacios de búsqueda serán los mismos que en el caso simétrico, pero tendremos la ventaja de que el producto interior determinado por la norma euclíadiana, al que hemos denominado $\langle \cdot, \cdot \rangle$, permitirá conocer todos los términos que necesitamos para iniciar el algoritmo.

En este Capítulo modificaremos el lenguaje que se ha utilizado, propio del cálculo y la geometría analítica, pues es más cómodo para el enfoque escogido utilizar ahora el lenguaje del álgebra lineal.

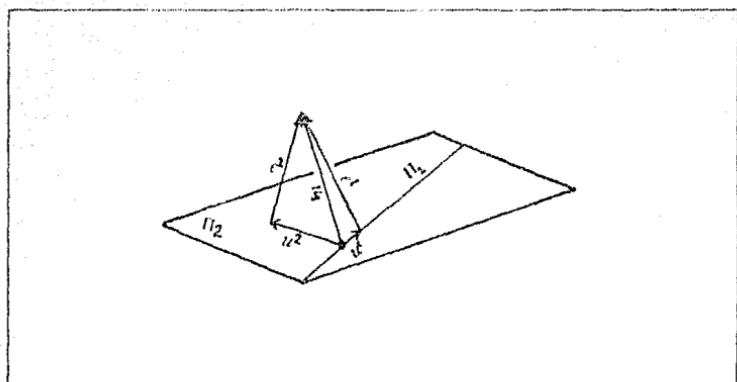
3.2 Planteamiento general del problema

Queremos resolver la ecuación

$$Au = b, \quad (3.2.1)$$

donde A es una matriz positiva definida y simétrica de $N \times N$.

Sea u_s la solución de la ecuación (3.2.1) (Vic. 2). Tomemos un subespacio vectorial H_1 de \mathbb{R}^N de una dimensión y supongamos que (\cdot, \cdot) es un producto escalar que permite calcular la proyección u^1 de u_s sobre H_1 . u^1 es la primera aproximación a la solución u_s . Es importante hacer notar que u^1 es el vector de H_1 que da el

FIGURA 2. u^1 y u^2 , proyecciones de u_s sobre H_1 y H_2 , respectivamente.

error de magnitud menor respecto al producto escalar (\cdot, \cdot) . Es decir si el error que corresponde a u^1 es

$$e^1 = u_s - u^1$$

y v es un elemento de H_1 con error

$$e = u_s - v, \quad (3.2.2)$$

entonces $|e^1| \leq |e|$, donde $\|u\|^2 = (u, u)$.

Ahora queremos encontrar un vector u^2 tal que la norma del error correspondiente e^2 sea menor que la de e^1 . Para esto necesitamos considerar un espacio H_2 distinto de H_1 , ya que ningún vector de éste último cumple con esta condición. Sea H_2 un subespacio de \mathbb{R}^N de dimensión dos que contenga a H_1 y u^2 la proyección de u_s sobre H_2 . Aseguraremos que u^2 satisface la condición pedida. Veámoslo:

Sean $\beta_1 = \{p^1\}$ y $\beta_2 = \{p^1, p^2\}$ bases ortogonales de H_1 y H_2 respectivamente, entonces

$$u^1 = \frac{(u_s, p^1)}{(p^1, p^1)} p^1,$$

$$u^2 = \frac{(u_s, p^1)}{(p^1, p^1)} p^1 + \frac{(u_s, p^2)}{(p^2, p^2)} p^2.$$

Usando la ecuación (3.2.2) tenemos

$$\mathbf{e}^1 = \mathbf{u}_s - \frac{(\mathbf{u}_s, \mathbf{p}^1)}{(\mathbf{p}^1, \mathbf{p}^1)} \mathbf{p}^1.$$

$$\mathbf{e}^2 = \mathbf{u}_s - \frac{(\mathbf{u}_s, \mathbf{p}^1)}{(\mathbf{p}^1, \mathbf{p}^1)} \mathbf{p}^1 - \frac{(\mathbf{u}_s, \mathbf{p}^2)}{(\mathbf{p}^2, \mathbf{p}^2)} \mathbf{p}^2.$$

Las normas al cuadrado de \mathbf{e}^1 y \mathbf{e}^2 son

$$\|\mathbf{e}^1\|^2 = (\mathbf{u}_s, \mathbf{u}_s) - \frac{(\mathbf{u}_s, \mathbf{p}^1)^2}{(\mathbf{p}^1, \mathbf{p}^1)},$$

$$\|\mathbf{e}^2\|^2 = (\mathbf{u}_s, \mathbf{u}_s) - \frac{(\mathbf{u}_s, \mathbf{p}^1)^2}{(\mathbf{p}^1, \mathbf{p}^1)} - \frac{(\mathbf{u}_s, \mathbf{p}^2)^2}{(\mathbf{p}^2, \mathbf{p}^2)}$$

entonces

$$\|\mathbf{e}^2\|^2 = \|\mathbf{e}^1\|^2 - \frac{(\mathbf{u}_s, \mathbf{p}^2)^2}{(\mathbf{p}^2, \mathbf{p}^2)}. \quad (3.2.3)$$

Como $\frac{(\mathbf{u}_s, \mathbf{p}^2)^2}{(\mathbf{p}^2, \mathbf{p}^2)} \geq 0$ se desprende de (3.2.3) que

$$\|\mathbf{e}^2\| \leq \|\mathbf{e}^1\|.$$

De esta forma podemos construir una sucesión de aproximaciones $\mathbf{u}^1, \dots, \mathbf{u}^n$ tales que:

$$\mathbf{u}^k \in \Pi_k \quad (k = 1, \dots, n)$$

y cuyos errores correspondientes cumplen con la siguiente relación

$$\|\mathbf{e}^1\| \geq \|\mathbf{e}^2\| \geq \dots \geq \|\mathbf{e}^n\|. \quad (3.2.4)$$

Además

$$\dim(\Pi_k) = k \quad (k = 1, \dots, n), \quad (3.2.5)$$

$$\Pi_1 \subset \Pi_2 \subset \dots \subset \Pi_n. \quad (3.2.6)$$

Si construyéramos N aproximaciones, \mathbf{u}^N sería la solución exacta.

Una manera de resolver la ecuación (3.2.1) que se basa en la misma idea es

tomar una primera aproximación \mathbf{u}^0 a la solución y calcular su error

$$\mathbf{e}^0 = \mathbf{u}_s - \mathbf{u}^0. \quad (3.2.7)$$

Sabemos entonces que $\mathbf{u}_s = \mathbf{u}^0 + \mathbf{e}^0$. Si encontramos aproximaciones \mathbf{w}^k a \mathbf{e}^0 por medio de las proyecciones de este último a los espacios H_k , como lo hicimos anteriormente con \mathbf{u}_s , y en este caso

$$\mathbf{u}^k = \mathbf{u}^0 + \mathbf{w}^k, \quad \mathbf{w}^k \in H_k \quad (3.2.8)$$

estos vectores son aproximaciones a \mathbf{u}_s .

Todo lo demostrado para \mathbf{u}^k es válido para \mathbf{w}^k , a saber:

$$\mathbf{w}^N = \mathbf{e}^0,$$

es decir,

$$\mathbf{u}^N = \mathbf{u}_s;$$

$$\|\mathbf{e}^0 - \mathbf{w}^k\| \geq \|\mathbf{e}^0 - \mathbf{w}^{k+1}\|. \quad (3.2.9)$$

Pero, ¿qué pasa con $\mathbf{e}^k = \mathbf{u}_s - \mathbf{u}^k$? Por (3.2.8)

$$\mathbf{e}^k = \mathbf{u}_s - \mathbf{u}^0 - \mathbf{w}^k = \mathbf{e}^0 - \mathbf{w}^k \quad (3.2.10)$$

y su norma, tomando en cuenta (3.2.9), satisface

$$\|\mathbf{e}^k\| = \|\mathbf{e}^0 - \mathbf{w}^k\| \geq \|\mathbf{e}^0 - \mathbf{w}^{k+1}\| = \|\mathbf{e}^{k+1}\|.$$

Se cumple la condición (3.2.4) impuesta sobre \mathbf{e}^k . Esta última será la forma de proceder en este trabajo.

Planteado así el problema quedan varios puntos fundamentales por resolver:

1) ¿Qué espacios vectoriales conviene escoger?

2) ¿Cómo podemos construir las bases de estos espacios de forma eficiente?

3) ¿Qué productos escalares permiten encontrar la proyección de \mathbf{u}_s sobre H_k ?

La forma de responder a estas preguntas es lo que caracteriza al método de gradiente conjugado.

3.3 Explicación del método

Queremos escoger los espacios H_n de tal forma que construir la base ortogonal $\{\mathbf{p}^1, \dots, \mathbf{p}^n\}$ de cada uno de ellos requiera poco trabajo computacional. Analicemos

los espacios de Krylov definidos como sigue

$$\Pi_n = \text{gen} \{ \mathbf{A}\mathbf{e}^0, \mathbf{A}^2\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0 \} \quad (3.3.1)$$

PROPOSICIÓN 3.3.1 Los vectores $\mathbf{A}\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0$ son linealmente independientes y, por lo tanto, la dimensión del n -ésimo espacio de Krylov es n si no se ha encontrado la solución.

Demotación:

Supongamos que $\mathbf{A}\mathbf{e}^0, \mathbf{A}^2\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0$ son linealmente dependientes. Entonces existen a_1, a_2, \dots, a_n no todos cero tales que

$$a_1\mathbf{A}\mathbf{e}^0 + a_2\mathbf{A}^2\mathbf{e}^0 + \dots + a_n\mathbf{A}^n\mathbf{e}^0 = 0$$

y

$$\mathbf{A}(a_1\mathbf{e}^0 + a_2\mathbf{A}\mathbf{e}^0 + \dots + a_n\mathbf{A}^{n-1}\mathbf{e}^0) = 0. \quad (3.3.2)$$

Debido a que \mathbf{A} es una matriz no singular (por ser positiva definida)

$$a_1\mathbf{e}^0 + a_2\mathbf{A}\mathbf{e}^0 + \dots + a_n\mathbf{A}^{n-1}\mathbf{e}^0 = 0.$$

Si $a_1 \neq 0$ (si fuera cero haríamos el paso (3.3.2) nuevamente hasta encontrar $a_k \neq 0$)

$$\mathbf{e}^0 = -\frac{a_2}{a_1}\mathbf{A}\mathbf{e}^0 - \dots - \frac{a_n}{a_1}\mathbf{A}^{n-1}\mathbf{e}^0.$$

Tomando en cuenta la ecuación (3.2.7) tenemos

$$\mathbf{u}_s = \mathbf{u}^0 + \frac{a_2}{a_1}\mathbf{A}\mathbf{e}^0 + \dots + \frac{a_n}{a_1}\mathbf{A}^{n-1}\mathbf{e}^0.$$

Tenemos, entonces, a \mathbf{u}_s en el espacio trasladado de Krylov de orden $n-1$, lo que implica que $\mathbf{u}^{n-1} = \mathbf{u}_s$, que contradice nuestra hipótesis. Por lo cual $\mathbf{A}\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0$ son linealmente independientes y la dimensión de Π_n es n .

Si las proyecciones \mathbf{w}^n de \mathbf{e}^0 están en Π_n las aproximaciones

$$\mathbf{u}^n = \mathbf{u}^0 + \mathbf{w}^n$$

pertenecen al espacio trasladado (espacio afín) de Krylov

$$\Pi_{n+1} = \mathbf{u}^0 + \Pi_n.$$

Comprobemos que estos espacios satisfacen las condiciones (3.2.4) y (3.2.5) impuestas sobre los Π_n :

PROPOSICIÓN 3.3.2 Los espacios de Krylov están anidados, es decir

$$\Pi_1 \subset \Pi_2 \subset \dots \subset \Pi_N.$$

Demostración:

Por (3.3.1)

$$\Pi_n = \text{gen} \{ \mathbf{A}\mathbf{e}^0, \mathbf{A}^2\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0 \},$$

$$\Pi_{n+1} = \text{gen} \{ \mathbf{A}\mathbf{e}^0, \mathbf{A}^2\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0, \mathbf{A}^{n+1}\mathbf{e}^0 \}$$

entonces $\Pi_n \subset \Pi_{n+1}$ y por lo tanto

$$\Pi_1 \subset \Pi_2 \subset \dots \subset \Pi_N. \blacksquare$$

Para demostrar las propiedades de los espacios de Krylov que nos interesan necesitamos usar varios resultados que presentamos a continuación.

PROPOSICIÓN 3.3.3 La transformación del espacio n -ésimo de Krylov, bajo \mathbf{A} , está contenida en el espacio de Krylov una dimensión mayor. Es decir

$$\mathbf{A}\Pi_n \subset \Pi_{n+1}$$

Demostración:

$$\Pi_n = \text{gen} \{ \mathbf{A}\mathbf{e}^0, \dots, \mathbf{A}^n\mathbf{e}^0 \}$$

o, lo que es lo mismo

$$\Pi_n = \{ \alpha_1 \mathbf{A}\mathbf{e}^0 + \dots + \alpha_n \mathbf{A}^n\mathbf{e}^0 / \alpha_i \in \mathbb{R}, \quad i = 1, \dots, n \}$$

entonces

$$\mathbf{A}\Pi_n = \{ \alpha_1 \mathbf{A}^2\mathbf{e}^0 + \dots + \alpha_n \mathbf{A}^{n+1}\mathbf{e}^0 / \alpha_i \in \mathbb{R}, \quad i = 1, \dots, n \}$$

$$\subset \{ \beta_0 \mathbf{A}\mathbf{e}^0 + \beta_1 \mathbf{A}^2\mathbf{e}^0 + \dots + \beta_n \mathbf{A}^{n+1}\mathbf{e}^0 / \beta_i \in \mathbb{R}, \quad i = 0, \dots, n \} = \Pi_{n+1}. \blacksquare$$

PROPOSICIÓN 3.3.4 Si el transformado de \mathbf{e}^0 bajo \mathbf{A} es elemento de Π_n , entonces la solución \mathbf{u}_s es elemento de $\Pi_{n,T}$.

Demostración:

Se demuestra de forma análoga a la PROPOSICIÓN 3.3.1, pero en este caso

obtenemos

$$\begin{aligned} \mathbf{u}_s &= \mathbf{u}^n + \frac{a_1}{a_{n+1}} \mathbf{e}^0 + \dots + \frac{a_n}{a_{n+1}} \mathbf{A}^{n-1} \mathbf{e}^0 \\ &= \mathbf{u}^0 + \mathbf{w}^n + \frac{a_1}{a_{n+1}} \mathbf{e}^0 + \dots + \frac{a_n}{a_{n+1}} \mathbf{A}^{n-1} \mathbf{e}^0, \end{aligned}$$

como \mathbf{w}^n es elemento de Π_n , entonces \mathbf{u}_s está en $\Pi_{n,T}$ ■

Con esto podemos demostrar la dos propiedades de los espacio de Krylov antes mencionadas.

PROPOSICIÓN 3.3.5. *Propiedad de ortogonalidad. Si \mathbf{v} es ortogonal a Π_n entonces \mathbf{Av} es ortogonal a Π_{n-1} .*

Demuestração:

Sea \mathbf{w}^{n-1} un elemento de Π_{n-1} . Tenemos, entonces,

$$(\mathbf{Av}, \mathbf{w}^{n-1}) = (\mathbf{v}, \mathbf{Aw}^{n-1}) = 0$$

ya que \mathbf{Aw}^{n-1} es elemento de Π_n por la PROPOSICIÓN 3.3.3. Así \mathbf{Av} es ortogonal a Π_n como queríamos demostrar ■

PROPOSICIÓN 3.3.6 Propiedad de pertenencia. Sea $\mathbf{e} = \mathbf{u}_s - \mathbf{u}^n$, donde \mathbf{u}^n es elemento de $\Pi_{n,T}$. Entonces \mathbf{Re} pertenece a Π_{n+1} .

Demuestração:

Ya que $\mathbf{u}^n \in \Pi_{n,T}$, $\mathbf{u}^n = \mathbf{u}^0 + \mathbf{w}^n$ para algún $\mathbf{w}^n \in \Pi_n$.

$$\mathbf{Re} = \mathbf{R}(\mathbf{u}_s - \mathbf{u}^0 - \mathbf{w}^n) = \mathbf{R}(\mathbf{u}_s - \mathbf{u}^0) - \mathbf{R}\mathbf{w}^n = \mathbf{Re}^0 - \mathbf{Aw}^n.$$

Tenemos $\mathbf{Re}^0 \in \Pi_{n+1}$ por (3.3.1) y $\mathbf{Aw}^n \in \Pi_{n+1}$ por la PROPOSICIÓN 3.3.3, esto indica que \mathbf{Re} es elemento de Π_{n+1} ■

Como habíamos visto antes, construiremos aproximaciones \mathbf{u}^n con elementos del espacio trasladado de Krylov correspondiente. El error de estas aproximaciones es un vector ortogonal a este espacio, que parte de éste y va hasta la solución exacta \mathbf{u}_s de la ecuación (3.2.1). Las propiedades de pertenencia y ortogonalidad nos dicen que en esta clase de aproximaciones el transformado del error es ortogonal a los espacios de Krylov de orden menor y pertenece al siguiente de estos espacios. Veámos como estos resultados permiten construir iterativamente la base ortogonal que buscábamos.

Sabemos, entonces, que

$$\mathbf{Re}^n \perp \Pi_{n-1} \quad (3.3.3)$$

y

$$\mathbf{Re}^n \in \Pi_{n+1} \quad (3.3.4)$$

Supongamos que $\{p^1, \dots, p^n\}$ es una base ortogonal de H_n , donde p^m pertenece a H_m , $m = 1, \dots, n$. Queremos encontrar un vector $p^{n+1} \in H_{n+1}$ que sea ortogonal a p^m , $m = 1, \dots, n$ y tal que $\{p^1, \dots, p^{n+1}\}$ genere a H_{n+1} .

p^n es un elemento de H_{n+1} por ser H_n subespacio de H_{n+1} ; Ae^n pertenece también a ese espacio por (3.3.4). Además, tanto p^n como Ae^n son ortogonales a H_{n-1} por (3.3.3) y son finalmente independientes (suponiendo que no hemos encontrado la solución) por la PROPOSICIÓN 3.3.5. Entonces cualquier elemento en el espacio generado por estos dos vectores es ortogonal a H_{n-1} y pertenece a H_{n+1} . Proporcionemos p^{n+1} como

$$p^{n+1} = Ae^n + \beta_{n+1}p^n. \quad (3.3.5)$$

Definido así, el único requisito que falta satisfacer es que p^{n+1} sea ortogonal a p^n . Esto lo logramos haciendo $(p^{n+1}, p^n) = 0$, veamos:

$$(p^{n+1}, p^n) = (Ae^n, p^n) + \beta_{n+1}(p^n, p^n) = 0$$

de lo que resulta

$$\beta_{n+1} = -\frac{(Ae^n, p^n)}{(p^n, p^n)} \quad (3.3.6)$$

Podemos construir la base de H_n aplicando la construcción anterior iterativamente. Como primer elemento tomaremos

$$p^1 = b - Au^0.$$

Con esto hemos respondido las dos primeras preguntas de la sección anterior. Para responder la tercera, veamos cómo se expresan las aproximaciones u^{n+1} en esta base.

Ya que $u^{n+1} = u^n + w^{n+1}$, donde w^{n+1} es la proyección de e^0 sobre H_{n+1} , tenemos

$$\begin{aligned} u^{n+1} &= u^n + \sum_{i=1}^{n+1} \frac{(e^0, p^i)}{(p^i, p^i)} p^i \\ &= u^n + \sum_{i=1}^n \frac{(e^0, p^i)}{(p^i, p^i)} p^i + \frac{(e^0, p^{n+1})}{(p^{n+1}, p^{n+1})} p^{n+1} = u^n + \alpha_{n+1} p^{n+1} \end{aligned} \quad (3.3.7)$$

donde

$$\alpha_{n+1} = \frac{(e^0, p^{n+1})}{(p^{n+1}, p^{n+1})}. \quad (3.3.8)$$

Para obtener las aproximaciones iterativamente conviene expresar $(\mathbf{e}^0, \mathbf{p}^{n+1})$ en términos de $(\mathbf{e}^n, \mathbf{p}^{n+1})$, trataremos de establecer una relación entre estos términos. De (3.2.10) obtenemos

$$\mathbf{e}^0 = \mathbf{e}^n + \mathbf{w}^n,$$

por tanto

$$(\mathbf{e}^0, \mathbf{p}^{n+1}) = (\mathbf{e}^n, \mathbf{p}^{n+1}) + (\mathbf{w}^n, \mathbf{p}^{n+1}).$$

\mathbf{w}^n es elemento de H_n y \mathbf{p}^{n+1} es ortogonal a este espacio por lo cual $(\mathbf{w}^n, \mathbf{p}^{n+1}) = 0$ y

$$\therefore (\mathbf{e}^0, \mathbf{p}^{n+1}) = (\mathbf{e}^n, \mathbf{p}^{n+1}).$$

Substituyendo (3.3.5) en esta ecuación obtenemos

$$(\mathbf{e}^n, \mathbf{p}^{n+1}) = (\mathbf{e}^n, \mathbf{Ae}^n) + \beta_{n+1} (\mathbf{e}^n, \mathbf{p}^n) = (\mathbf{e}^n, \mathbf{Ae}^n)$$

ya que $(\mathbf{e}^n, \mathbf{p}^n) = 0$ porque \mathbf{e}^n es ortogonal a H_n . La nueva expresión para (3.3.8) es

$$\alpha_{n+1} = \frac{(\mathbf{e}^n, \mathbf{Ae}^n)}{(\mathbf{p}^{n+1}, \mathbf{p}^{n+1})} \quad (3.3.9).$$

Para obtener β_{n+1} podríamos utilizar cualquier producto escalar, pues cada término en la expresión (3.3.6) es conocido. No es el caso para α_{n+1} ya que en (3.3.9) aparece el vector desconocido \mathbf{e}^n .

¿Qué productos escalares permiten conocer $(\mathbf{e}^n, \mathbf{Ae}^n)$?

Cuando \mathbf{A} es una matriz simétrica y positiva definida, \mathbf{A} y cada una de sus potencias definen productos interiores que hacen posible calcular α_{n+1} . Utilizaremos el más sencillo de ellos, dado por

$$(\mathbf{u}, \mathbf{v}) = \mathbf{u} * \mathbf{Av}$$

donde $*$ es el producto interior usual en los reales.

Con esto las ecuaciones (3.3.6) y (3.3.9) se transforman en

$$\alpha_{n+1} = \frac{\mathbf{r}^n * \mathbf{r}^n}{\mathbf{p}^{n+1} * \mathbf{Ap}^{n+1}},$$

$$\beta_{n+1} = -\frac{\mathbf{p}^n * \mathbf{Ar}^n}{\mathbf{p}^n * \mathbf{Ap}^n},$$

donde $\mathbf{r}^n = \mathbf{Ae}^n$.

Al hacer el planteamiento general del problema únicamente suponiendo la condición de que el producto escalar (\cdot, \cdot) permitiera calcular la proyección de \mathbf{e}^n sobre los Π_n . Al hacer el desarrollo del método hemos presupuesto que si la magnitud de \mathbf{e}^n decrece con respecto a la norma dada por (\cdot, \cdot) , también decrece con respecto a la dada por $*$. Esta condición no se expuso explícitamente para no complicar el texto, sin embargo, el producto escalar $u \cdot \mathbf{Av}$ permite asegurar que esto sucede.

3.4 Construcción para la matriz no simétrica

Ismael Herrera ha observado que en aplicaciones a matrices no simétricas es posible minimizar directamente la norma euclídea del error y no solamente el residuo, como se hizo en el Capítulo II (Sección 2.3). Esto da lugar a simplificaciones importantes en los cálculos y aceleración de la convergencia, cuyo análisis y prueba a prueba, como se ha dicho, ha sido uno de los objetivos principales de esta tesis.

Consideremos nuevamente la ecuación (2.1.1), entonces todos los desarrollos anteriores son aplicables a la ecuación (2.1.2) asociada con ésta, incluyendo (3.3.5), (3.3.6), (3.3.7) y (3.3.9). Si definimos

$$\mathbf{r}^n = \mathbf{a} - \mathbf{P}\mathbf{u}^n = \mathbf{P}\mathbf{e}^n, \quad \mathbf{q}^1 = \mathbf{r}^0, \quad \mathbf{q}^{n+1} = \mathbf{P}\mathbf{e}^n + \beta_{n+1}\mathbf{q}^n,$$

entonces $\mathbf{p}^{n+1} = \mathbf{P}^T \mathbf{q}^{n+1}$ y podemos reescribir estas ecuaciones como

$$\mathbf{p}^1 = \mathbf{P}^T \mathbf{q}^1,$$

$$\mathbf{p}^{n+1} = \mathbf{A}\mathbf{e}^n + \beta_{n+1}\mathbf{p}^n = \mathbf{P}^T(\mathbf{P}\mathbf{e}^n + \beta_{n+1}\mathbf{q}^n);$$

$$\beta_{n+1} = -\frac{\langle \mathbf{A}\mathbf{e}^n, \mathbf{p}^n \rangle}{\langle \mathbf{p}^n, \mathbf{p}^n \rangle} = -\frac{\langle \mathbf{P}^T \mathbf{P}\mathbf{e}^n, \mathbf{P}^T \mathbf{q}^n \rangle}{\langle \mathbf{P}^T \mathbf{q}^n, \mathbf{P}^T \mathbf{q}^n \rangle} = -\frac{\langle \mathbf{P}^T \mathbf{r}^n, \mathbf{P}^T \mathbf{q}^n \rangle}{\langle \mathbf{P}^T \mathbf{q}^n, \mathbf{P}^T \mathbf{q}^n \rangle},$$

$$\mathbf{u}^{n+1} = \mathbf{u}^n + \alpha_{n+1}\mathbf{P}^T \mathbf{q}^{n+1},$$

$$\alpha_{n+1} = \frac{\langle \mathbf{e}^n, \mathbf{A}\mathbf{e}^n \rangle}{\langle \mathbf{p}^{n+1}, \mathbf{p}^{n+1} \rangle} = \frac{\langle \mathbf{e}^n, \mathbf{P}^T \mathbf{r}^n \rangle}{\langle \mathbf{P}^T \mathbf{q}^{n+1}, \mathbf{P}^T \mathbf{q}^{n+1} \rangle} = \frac{\langle \mathbf{r}^n, \mathbf{r}^n \rangle}{\langle \mathbf{P}^T \mathbf{q}^{n+1}, \mathbf{P}^T \mathbf{q}^{n+1} \rangle}.$$

En este caso todos los términos que aparecen al calcular α_n y β_n son conocidos por lo que se pueden calcular independientemente del producto interno que se utilice, es por esto que podemos utilizar el producto interior $*$ y minimizar directamente la norma euclídea del error sobre cada subespacio afín de Krylov.

Algoritmo NM

PASO INICIAL: Seleccionar un punto \mathbf{u}^0 y calcular

$$\mathbf{q}^1 = \mathbf{r}^0 = \mathbf{a} - \mathbf{P}\mathbf{u}^0.$$

PASOS ITERATIVOS: Dadoiendo obtenido u^{n+1}, r^{n+1} y q^n calcular u^n, r^n y q^{n+1} por medio de las fórmulas

$$\alpha_n = \frac{r^{n+1} + r^n}{P^T q^n + P^T q^n}$$

$$u^n = u^{n+1} + \alpha_n P^T q^n,$$

$$r^n = b - P u^n,$$

$$\beta_{n+1} = -\frac{P^T r^n + P^T q^n}{P^T q^n + P^T q^n},$$

$$q^{n+1} = r^n + \beta_{n+1} q^n.$$

TERMINACIÓN: Terminar en el m -ésimo paso si $r^m = 0$.

En el trabajo numérico de esta tesis obtendremos soluciones aproximadas dando un margen máximo al residuo r^n . Esto es necesario porque el error mismo e^n se desconoce. Sin embargo, es conveniente observar que el residuo constituye una medida indirecta del error, ya que, bajo las hipótesis establecidas en esta tesis (P no singular) siempre existe un número M tal que

$$\|e\|_2 \leq M \|r\|_2.$$

Así, al dar una cota a $\|r^n\|_2$ ella conlleva otra de $\|e^n\|_2$.

Capítulo 4

Resultados numéricos y conclusiones

4.1 Introducción

Probaremos el nuevo método (NM) con un problema de transporte con difusión en estado estacionario y compararemos resultados numéricos con GCR(3), ORTHOMIN(3) y la extensión natural del método de gradiente conjugado.

4.2 Solución numérica de un problema específico

Trabajaremos con un problema de transporte con difusión [1]:

$$\frac{\partial c}{\partial t} + \nabla \cdot \mathbf{v}c - \sum_{i=1}^3 \frac{\partial}{\partial x_i} \left(K \frac{\partial c}{\partial x_i} \right) = 0, \quad (4.2.1)$$

donde c es la concentración, \mathbf{v} es la velocidad, y K el coeficiente de difusión. La concentración será independiente del tiempo y K constante, igual a uno, con lo que la ecuación (4.2.1) se transforma en

$$\nabla \cdot \mathbf{v}c - \sum_{i=1}^3 \left(\frac{\partial^2 c}{\partial x_i^2} \right) = 0. \quad (4.2.2)$$

Las condiciones en la frontera están dadas como se muestran en la Figura 3.

Resolveremos la ecuación (4.2.2) sobre una región cúbica con celdas de lado h , tomando constante la velocidad en la dirección $(1,1,1)$ y con $\|\mathbf{v}\|_2 = Pe/h$, donde Pe es el número de Peclet.

Discretizaremos la ecuación usando el método de celdas. Sean x_{ijk} ($i, j, k = 1, \dots, N$) los puntos en los que queremos aproximar el valor de la concentración cada uno de los cuales es centro de la celda E_{ijk} . Denotaremos $x_{i+\frac{1}{2},j,k}$, $x_{i-\frac{1}{2},j,k}$, $x_{i,j+\frac{1}{2},k}$, $x_{i,j-\frac{1}{2},k}$, $x_{i,j,k+\frac{1}{2}}$ y $x_{i,j,k-\frac{1}{2}}$ a los puntos sobre los lados de la celda, que están colocados como se ilustra en la Figura 4.

Por el teorema de la divergencia

$$\int_{E_{ijk}} \nabla \cdot \mathbf{v}c \, dx = \int_{\partial E_{ijk}} \mathbf{v}c \cdot \mathbf{n} \, dx,$$

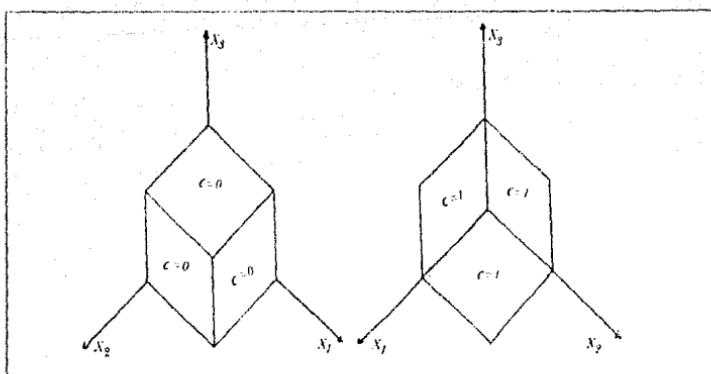


FIGURA 3. Condiciones a la frontera para el problema de transporte con difusión.

donde \mathbf{n} es un vector normal en cada punto de la frontera δE_{ijk} . En este caso E_{ijk} es un cubo y la integral sobre C_1 , uno de sus caras (como se muestra en el Figura 3) está determinada por el vector $\mathbf{n} = (1, 0, 0)$, por lo que

$$\int_{C_1} cv \cdot \mathbf{n} dx = \int_{C_1} cv dx,$$

donde el vector $\mathbf{v} = (v, v, v)$. Si aproximamos el valor de c sobre la cara C_1 con el valor en el punto medio $x_{i+\frac{1}{2},j,k}$ obtenemos

$$\int_{C_1} cv \cdot \mathbf{n} dx \approx vh^2 c_{i+\frac{1}{2},j,k}$$

y, por lo tanto,

$$\int_{C_1} cv \cdot \mathbf{n} dx + \int_{C_2} cv \cdot \mathbf{n} dx \approx vh^2 \{c_{i+\frac{1}{2},j,k} - c_{i-\frac{1}{2},j,k}\}.$$

Sin embargo en esta ecuación aparecen los términos desconocidos $c_{i+\frac{1}{2},j,k}$ y $c_{i-\frac{1}{2},j,k}$ por lo que los aproximaremos utilizando el promedio de los valores $c_{i+1,j,k}$ y $c_{i,j,k}$ o $c_{i-1,j,k}$ y $c_{i,j,k}$ según sea el caso, con esto obtenemos la siguiente aproximación al valor de la integral

$$\int_{C_1} cv \cdot \mathbf{n} dx + \int_{C_2} cv \cdot \mathbf{n} dx \approx v \frac{h^2}{2} \{c_{i+1,j,k} - c_{i-1,j,k}\}. \quad (4.2.3)$$

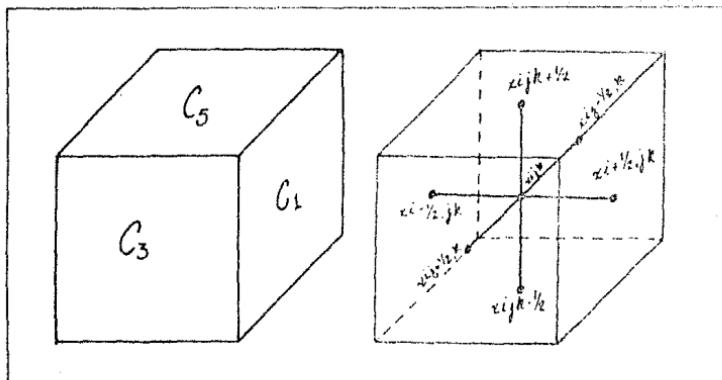


FIGURA 4. Notación utilizada para el método de celdas.

Por otro lado, si integramos la segunda parcial de la concentración con respecto a una de las variables, por ejemplo x_1 , tenemos

$$\begin{aligned} \int_{E_{ijk}} \frac{\partial^2 c}{\partial x_1^2} dx &= \int_{E_{ijk}} \frac{\partial c}{\partial x_1}(x_{i+\frac{1}{2},j,k}) - \frac{\partial c}{\partial x_1}(x_{i-\frac{1}{2},j,k}) dx \\ &\approx h(c_{i+1,j,k} + c_{i-1,j,k} - 2c_{ijk}), \end{aligned} \quad (4.2.4)$$

si aproximamos la $\frac{\partial c}{\partial x_1}(x_{i+\frac{1}{2},j,k})$ por medio de la pendiente de la cuerda que une las concentraciones en los puntos $x_{i+1,j,k}$ con x_{ijk} y análogamente para $\frac{\partial c}{\partial x_1}(x_{i-\frac{1}{2},j,k})$. Si unimos los resultados (4.2.3) y (4.2.4) para cada una de las variables x_1 , x_2 y x_3 obtenemos la ecuación

$$\begin{aligned} \int_{E_{ijk}} \left(\nabla \cdot \mathbf{v} c - \sum_{i=1}^3 \frac{\partial^2 c}{\partial x_i^2} \right) dx &\approx -h^2 \left(\frac{v}{2} + \frac{1}{h} \right) c_{i,j,k+1} \\ &\quad - h^2 \left(\frac{v}{2} + \frac{1}{h} \right) c_{i,j-1,k} - h^2 \left(\frac{v}{2} + \frac{1}{h} \right) c_{i-1,j,k} \\ &\quad + 6hc_{ijk} + h^2 \left(\frac{v}{2} - \frac{1}{h} \right) c_{i+1,j,k} + h^2 \left(\frac{v}{2} - \frac{1}{h} \right) c_{i,j+1,k} \\ &\quad + h^2 \left(\frac{v}{2} - \frac{1}{h} \right) c_{i,j,k+1} \quad (i, j, k = 1, \dots, N) \quad (4.2.5) \end{aligned}$$

Hemos formulado nuestro problema en términos de un sistema de ecuaciones lineales, que podemos escribir por medio de una matriz heptadiagonal de dimensión N^3 . La matriz \mathbb{P} será

$$\mathbb{P} = \begin{pmatrix} \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots \\ \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots \\ 0 & \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots \\ 0 & \cdots & 0 & \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 \\ \gamma & 0 & \cdots & 0 & \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 \\ 0 & \gamma & 0 & \cdots & 0 & \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \ddots & \ddots & \ddots & \ddots \\ 0 & \cdots & 0 & \gamma & 0 & \cdots & 0 & \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 \\ \gamma & 0 & \cdots & 0 & \gamma & 0 & \cdots & 0 & \gamma & \beta & \alpha & 0 & \cdots & 0 & \alpha & 0 & \cdots & 0 & \alpha & 0 \\ 0 & \cdots & \vdots \end{pmatrix}$$

donde

$$\beta = \frac{6}{h}, \quad \alpha = \frac{v}{2} - \frac{1}{h}, \quad \gamma = -\frac{v}{2} - \frac{1}{h}, \quad v = \sqrt{\frac{Pe}{3h}}.$$

4.3 Resultados numéricos

Damos los valores $h = 0.1$ y $u^0 = 0$ para todos los casos. Variamos la velocidad, cambiando el número de Pelet ($Pe=10,100,1000,10000$) como se hizo en el artículo de Celia *et al.* [3]. El criterio para terminar los algoritmos es $\|r^k\|_2^2 \leq 10^{-4}$. Todos los experimentos se realizaron en una microcomputadora Tandy de 8 MHz, utilizando doble precisión. Los programas están escritos en FORTRAN.

La siguiente Tabla resume el trabajo (número de operaciones en cada iteración) y memoria requeridos por cada método.

	MÉTODO NUEVO	ORTHOMIN(3)	GCR(3)	EXT. NAT
RAM (bytes)	$120 N^3$	$136 N^3$	$136 N^3$	$120 N^3$
No. It.	$20 N^3$	$69 N^3$	$69 N^3$	$55 N^3$

PRIMERA PRUEBA

$P_e = 10$, $N = 3, 4, 5, 6, 7, 8$. Contamos iteraciones y tiempo de CPU.

En la primera prueba se varió la dimensión de la matriz para obtener una gráfica que muestra como crece el número de iteraciones con respecto a la dimensión (Figs. 5 y 6). Por otro lado, se midió el tiempo que tarda cada algoritmo en encontrar la aproximación (Figs. 7 y 8). Otra forma de medir el tiempo, independiente de la computadora utilizada, consiste en medir el número de operaciones (multiplicaciones) para cada algoritmo (Fig. 9).

SEGUNDA PRUEBA

$N = 8$, $P_e = 10, 100, 1000, 10000$. Contamos iteraciones y tiempo de CPU.

La segunda prueba consistió en trabajar con matrices de dimensión fija y variar el número de Pelet, de tal forma que las matrices obtenidas tuvieran simetrías distintas, esto es, que $\gamma - \alpha$ tenga distintas magnitudes. Nuevamente medimos iteraciones, tiempo de CPU y operaciones (Figs. 10-12).

TERCERA PRUEBA

$N = 8$, $P_e = 10$. Medimos $\|\mathbf{r}^k\|_2^2$ en la k -ésima iteración.

En la tercera prueba dejamos fija $N = 8$, $P_e = 10$ y medimos la magnitud del residuo $\|\mathbf{r}^k\|_2$ a la k -ésima iteración. Graficamos operaciones contra $\|\mathbf{r}^k\|_2^2$ (Figs. 13-17) y, calculando el error utilizando alguna de las aproximaciones obtenidas, operaciones contra $\|e\|_2^2$ (Fig. 18 y 19).

4.4 Discusión y conclusiones

Las Tablas 2-7 presentan los valores graficados en las Figuras 5-19.

De la gráfica 5 se obtiene que $I \approx 4.2N$ para ORTHOMIN(3) y GCR(3), mientras que de la gráfica 6 obtenemos $I \approx KN^{1.8}$ (K constante) para NM y EN. Entonces, ORTHOMIN(3) y GCR(3) requieren menos iteraciones para obtener una aproximación cuyo residuo $\|\mathbf{r}^k\|_2$ cumple la condición $\|\mathbf{r}^k\|_2^2 \leq 10^{-4}$, que NM y EN, sin embargo, el tiempo y trabajo que utiliza NM es siempre menor de la mitad que el utilizado por cualquiera de los otros métodos (Figs. 7,9). Esto se debe al número de operaciones que realiza cada método en una iteración (ver Tabla 1). Al graficar el logaritmo natural de las iteraciones contra el del tiempo (Fig. 8) obtenemos cuatro curvas que se pueden considerar rectas con pendiente aproximada de 4.7, por lo que, $T \approx KN^{4.7}$ para los cuatro métodos, y el valor más pequeño lo toma K en el método nuevo.

Al variar el número de Pelet, la cantidad de iteraciones que requiere cada método para terminar también varía (Fig. 10), sin embargo, mientras que NM y EN tienen una variación máxima de alrededor de quince iteraciones, los métodos GCR(3) y ORTHOMIN(3) la tienen de alrededor de veintena iteraciones, esto indica que NM y EN son más estables con respecto a simetrías que GCR(3) y ORTHOMIN(3). Esto se refleja también en el tiempo utilizado y el trabajo realizado por cada algoritmo

<i>N</i>	NM	ORTHOMIN(3)	GCR(3)	EN
	<i>I</i>	<i>I</i>	<i>I</i>	<i>I</i>
3	10	8	7	10
4	16	13	13	19
5	24	17	17	28
6	33	21	22	40
7	44	26	26	53
8	56	30	30	66

TABLA 2. Valores de *N* contra iteraciones para cada método. Ver Figura 5.

$\ln N$	NM	ORTHOMIN(3)	GCR(3)	EN
	$\ln I$	$\ln I$	$\ln I$	$\ln I$
1.0986	2.3026	2.0794	1.9459	2.3026
1.3863	2.7726	2.5649	2.5649	2.9444
1.6091	3.1780	2.8332	2.8332	3.3322
1.7917	3.4965	3.0445	3.0910	3.6889
1.9459	3.7842	3.2581	3.2581	3.9703
2.0791	4.0253	3.4012	3.4012	4.1896

TABLA 3. Valores de $\ln N$ contra $\ln I$ para cada uno de los métodos. Ver Figura 6.

para terminar el proceso (Figs 11, 12). El tiempo utilizado en el caso del NM nunca es mayor a veinte minutos y en cualquiera de los otros métodos nunca es menor de treinta y cinco minutos. GCR(3) y ORTHOMIN(3) llegan a tardar alrededor de dos horas cuando el número de Picet vale 10000.

Se graficaron juntos los datos obtenidos para NM y ORTHOMIN(3) (Figs. 13-15), GCR(3) no se graficó porque su tabla de resultados es muy parecida a la de ORTHOMIN(3). La gráfica de EN (Figs. 16-17) se hizo aparte debido a que las magnitudes de las normas de sus residuos son muy disímiles. En la gráfica 13 podemos observar la diferencia que existe entre el descenso de la norma del residuo en los métodos GCR(3) y NM, ya que $\|r^n\|_2$ decrece monótonamente en el caso de GCR(3), cosa que no sucede para NM, más aún, la norma del residuo en este método da saltos abruptos. A pesar de esto y de que en un inicio la norma del residuo de NM es mucho mayor que la de GCR(3), conforme el número de operaciones aumenta, la norma del NM disminuye más rápidamente que la de ORTHOMIN(3) (Figs. 14, 15). Este comportamiento tan distinto se debe a la diferencia estructural de los métodos: GCR minimiza a $\|r^n\|_2$, por lo que está obligada a decrecer monótonamente y NM minimiza a $\|e^n\|_2$ por lo que $\|r^n\|_2$ puede tener un comportamiento distinto. Lo mismo se observa en el caso de EN (Figs. 16-17), ya que este método minimiza el residuo respecto a la norma $\|A^{-1}y - r^n\|$ puede tener también saltos (aunque en este caso no se presentan tan marcados como en NM). Al graficar operaciones contra $\|e^n\|_2^2$ se confirma que la norma del error en NM (Figs. 18-19) decrece monótonamente y siempre es más pequeña que la del error de ORTHOMIN(3).

Los resultados obtenidos muestran al nuevo método como un método competitivo e inclusive superior a ORTHOMIN(*k*), GCR(*k*) y por supuesto a la extensión

<i>N</i>	NM		ORTHOMIN(3)		GCR(3)		EN	
	<i>T</i>	$\ln T$	<i>T</i>	$\ln T$	<i>T</i>	$\ln T$	<i>T</i>	$\ln T$
3	0:11		0.21		0:17		0:20	
4	0.36		1.26		1.23		1.31	
5	1.44		3.47		3.37		4.29	
6	4.08		8.18		8.21		10.15	
7	8.48		16.39		15.50		23.57	
8	16.45		29.01		27.44		45.01	

TABLA 4. Valores de *N* contra tiempo para cada uno de los métodos. Ver Figura 7.

$\ln N$	NM		ORTHOMIN(3)		GCR(3)		EN	
	$\ln T$	<i>T</i>	$\ln T$	<i>T</i>	$\ln T$	<i>T</i>	$\ln T$	<i>T</i>
1.0980	-1.7148		-1.6498		-1.2730		-1.1087	
1.3863	-0.5108		0.3577		0.3221		0.4187	
1.6094	0.5481		1.3297		1.2865		1.4996	
1.7917	1.4183		2.1162		2.1223		2.3273	
1.9450	2.1747		2.8124		2.7619		3.1760	
2.0794	2.8184		3.368		3.3225		3.8971	

TABLA 5. Valores de $\ln N$ contra $\ln T$ para cada uno de los métodos. Ver Figura 8.

natural del gradiente conjugado. Además, como se mencionó anteriormente, NM es más adecuado para problemas no simétricos debido a su estabilidad ante cambios en la asimetría de las matrices. Sin embargo no se puede aún establecer una conclusión definitiva al respecto porque es necesario analizar un número más amplio de casos y también introducir precondicionadores, ya que esta es la forma que con mayor frecuencia se utiliza los métodos comparados en esta tesis. Por otro lado, falta incluir comparaciones con el método GMRES de Saad y Schultz [13]. Sin embargo, como se muestra en el trabajo de Susana Gómez y José Luis Morales [7], tiene eficiencia muy cercana a ORTHOMIN(*k*) y GCR(*k*).

I	NM	ORTHOMIN(3)	GCR(3)	EN
1	40748 07948077800000	11.306 40018123000000	11.305 50011207000000	4.433 152 31577000000000
2	50324 22312774600000	5730 51449176000000	5730 51449176000000	9.655 457 45272130000000
3	58815 50075785000000	3484 78384615200000	3484 78384615200000	75 311 645 54779350000000
4	51095 50075784000000	2381 31516257350000	2381 31516257350000	5626 142 65436160000000
5	48174 5051917914000000	1721 119443566400000	1721 119443566400000	4123038 4 004 4660000000
6	44473 7307657630000000	1276 61509463700000	1276 61509463700000	2919616 127 746000000000
7	39604 50266128500000	956 170361533500000	956 170361533500000	2473180 16270000000000
8	43641 8511609770000000	713 1097624616750000	713 1097624616750000	2345469 8737624616750000
9	36828 9546514870000000	520 8313765148700000	520 8313765148700000	1554 431 93476670000000
10	20734 8610841410000000	366 2811645159700000	366 2811645159700000	1746613 6190911560000000
11	30387 6451115320000000	243 147591115600000	243 147591115600000	1010921 110103260000000
12	42991 3761279560000000	147 566440714650000	147 445227323200000	1017625 157482300000000
13	38880 8419162320000000	79 211061761311000	79 1713529707181000	4165841 66041407600000
14	38449 8946414520000000	37 540114927472000	37 5156686670000000	744554 984951600000000
15	37751 4466448890000000	18 345219765600000	18 345219765600000	688045 572670110000000
16	34704 4264029300000000	7 042929134534000	6 942929134534000	55 31198 837200000000000
17	26642 3104218150000000	3 34610840227400	3 277961865330300	413241 455272600000000
18	23971 4264451100000000	1 968981146197000	1 912176511313000	513402 3492472000000000
19	21430 1094588200000000	1 385611815127500	1 37751442044800	570255 1044591200000000
20	11229 6652222700000000	9 783192097407E-001	6 452747615259E-001	761241 5049952600000000
21	7614 3757605450000000	5 768911779224E-001	5 2672935474412E-001	760935 63734141060000
22	7859 3870001760000000	2 114857649253E-001	3 081294010527E-001	444341 520237000000000
23	68446 45624410000000	7 356245460183E-002	7 105726281729E-002	310727 1616410000000000
24	9606 7674739125000000	3 627340406011E-002	2 67070604042E-002	213866 7136279000000000
25	14710 1118072014000000	1 3707597475247E-002	1 18230165115197E-002	162883 8300891600000000
26	7784 3573907592000000	7 2844651056451E-003	6 92240455045E-003	218711 9016511600000000
27	4101 4632187150000000	5 1563302017642E-003	5 0105847822403E-003	206546 8454502200000000
28	2504 7674711931400000	3 21271244854010E-003	2 83203072650342E-003	308056 5865637000000000
29	1565 0553247833000000	1 85865102668422E-003	1 4120134192413E-003	2503448 1613711000000000
30	1348 3207593365000000	7 93773095965937E-004	7 20246091579356E-004	196574 7365747400000000
31	645 7412117524700			233601 1851890000000000
32	472 354915151263000			116753 5446211620000000
33	267 484959767823000			8963 2655933510000000
34	2970 31204783793000			63659 0301646432000000
35	192 3102826730000			54521 4134372330000000
36	180 220115404220000			20501 9223115600000000
37	166 0615915193000000			19359 6285450147000000
38	92 9351194565000000			22273 1153574930000000
39	41 342622342496000			14051 9055658500000000
40	26 2028525737613000			1572 10154312996000000
41	7 316725609765000			8510 7134642930000000
42	3 20730488611030			4321 5143434663000000
43	8 8195516197692E-001			850 9035711250000000
44	3 184701617142E-001			292 2249717830000000
45	2 4944234094894E-001			95 6036474905600000
46	2 362447218522E-001			54 8665637166455000
47	9 4039371630192E-002			87 1675874722000000
48	4 4366868714741E-002			56 29191540599000000
49	5 3671600574927E-002			23 944920169258000000
50	2 016525945234E-002			12 004065856767000000
51	6 8170112652902E-003			6 6153435110072000
52	4 197619367023E-003			4 7401411655110000
53	5 3384415974935E-003			2 0573649569724900
54	2 5558515341483E-003			1 0350500852827500
55	2 72558124512712E-003			7 63061779215012E-003
56	7 5421591271362E-004			4 91471761515872E-003
57				2 54012942491230000000
58				2 40613437671472000000
59				6 2467121018157E-003
60				3 993615261472372E-003
61				5 4676261472372E-003
62				1 95367586227742E-003
63				8 474x10-0020000000000000
64				5 72065245126830E-003
65				2 1352 50431174E-003
66				5 4350 30353154E-003

TABLA 6. Número de iteraciones I contra $\|r^I\|_2^2$ para cada uno de los métodos. Ver Figuras 13-17.

I	NM	ORTHOMIN(3)	EN
1	274.4741376e+000	233.45577606719000	289.03040571327000
2	247.1474019e+000	176.03145348849000	264.50925829520000
3	225.03763651675000	133.01675597328000	253.22711181803000
4	207.20161922721000	100.21379533704000	237.76944670320000
5	191.34374464542000	73.96732713142700	233.79120518316000
6	176.32364956311000	62.59424531334800	210.55618328200000
7	161.20856303110000	55.46938111111111	197.46957778820000
8	147.69489033911000	22.40578401407400	186.43575526533000
9	136.37856855640000	12.41962694827500	176.74023858000000
10	123.49185030334900	8.74325150702750	163.82028580000000
11	114.66310459041000	5.021670016644710	154.43277046793000
12	101.92518612851600	1.119177260511950	147.03135544240000
13	91.230753320981900	3.86028793773500E-001	137.97402600784000
14	80.110273211612500	1.37923544811900E-001	129.22051402940000
15	69.474654441991000	1.0846038817684700E-001	131.23030332446700
16	59.729262305833000	8.73662235365390E-002	112.95372344560000
17	49.945157910523750	7.04068194498681E-002	102.95030353404300
18	39.671853041673460	5.88154326452900E-002	92.73214681818160
19	31.71921420841800	4.103457714100E-002	82.470769413300
20	25.73998746330100	2.00621050741940E-002	67.7271676782348500
21	22.4367614554242400	6.13335974729980E-003	53.45246496346400
22	20.19441614594800	1.02411602642640E-003	44.40372663080000
23	17.33366647705700	3.61320331972830E-004	37.40069377520000
24	14.3645412916800	3.31896952529930E-004	33.47916441124400
25	10.82990061750000	3.19172161009820E-004	30.92894063022000
26	6.61208262341620	2.3064823720492400E-004	26.51682794924100
27	4.048876147070050	1.70737802907970E-004	20.21773424554200
28	2.6481107216360	8.14966172721286E-005	13.63103676305000
29	1.85504065642320	2.61872485154840E-005	6.69453513111120
30	1.25982011427260	4.01318517234340E-006	5.7730905945580000
31	6.17560078191467E-001		3.09199595733440
32	6.1335713727207E-001		1.8449911523590
33	6.7444920979727E-001		1.1880250746610
34	3.17157021514600E-001		7.95447451329981E-001
35	2.733207961193521E-001		5.453444355212E-001
36	1.90911161787191E-001		4.0667703001471E-001
37	1.060305571495E-001		2.91086270381478E-001
38	0.610777470160E-002		1.83059734977778E-001
39	2.36463356596092E-002		0.096401794811E-002
40	9.56143491587481E-003		4.49779479101459E-002
41	3.497479576196E-003		1.04649010408079E-002
42	1.34150164000227E-003		3.06532789043740E-003
43	0.998147626242E-004		7.42104901363430E-004
44	0.958691495127E-004		4.53694151467580E-004
45	2.7020616972127E-004		3.33609229967223E-004
46	1.5442144319765E-004		4.80944557212414E-004
47	1.1225500492636E-005		1.2265501721321E-004
48	2.8322721503094E-005		7.17279420797681E-003
49	1.0720248164810E-005		3.58692287109087E-003
50	1.113487530068780E-005		1.078127015130252E-003
51	6.44497237110081E-006		9.7430382401347E-006
52	3.72611483643871E-006		8.77335092313162E-007
53	2.17776674166311E-006		6.06879401263765E-007
54	1.14120657604000E-006		2.05814022152614E-007
55	4.30032443306397E-007		1.4721166404532E-006
56		4.64449717101512E-007	
57		1.57100717322561E-007	
58		1.915761115300772E-007	
59		2.36522220645750E-007	
60		3.01115731248777E-007	
61		3.80712965016980E-007	
62		3.44646732092924E-007	
63		4.22419992060461E-007	
64		6.3865034558831E-007	
65		4.77232776452161E-007	

TABLA 7. Número de iteraciones I contra $\|e^I\|_2^2$ para NM, ORTHOMIN(3) y EN. Ver Figuras 18 y 19.

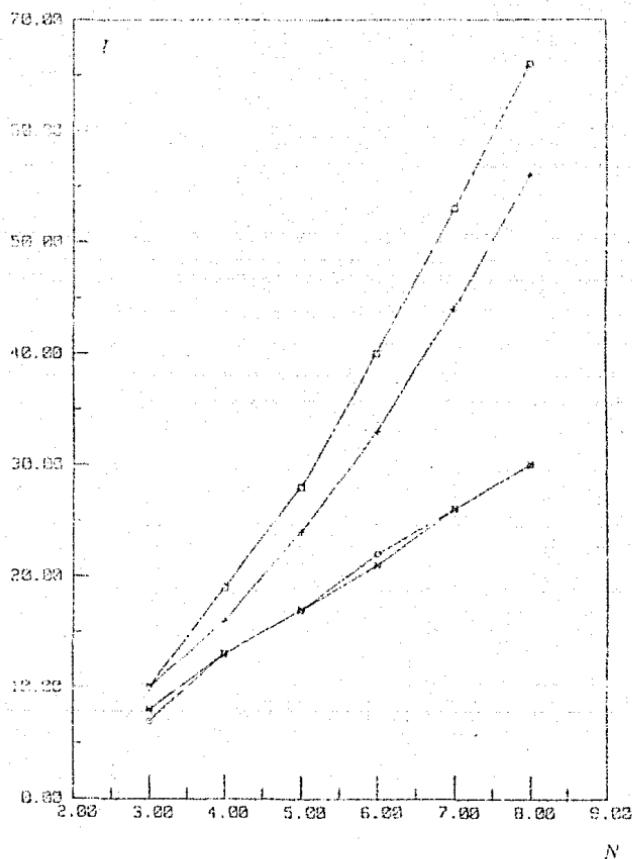


FIGURA 5. Gráfica de N^3 contra I (iteraciones) para los cuatro métodos, donde N^3 es la dimensión de la matriz. (+: NM; *: ORTHOMIN(3); O: GCR(3); □: EN)

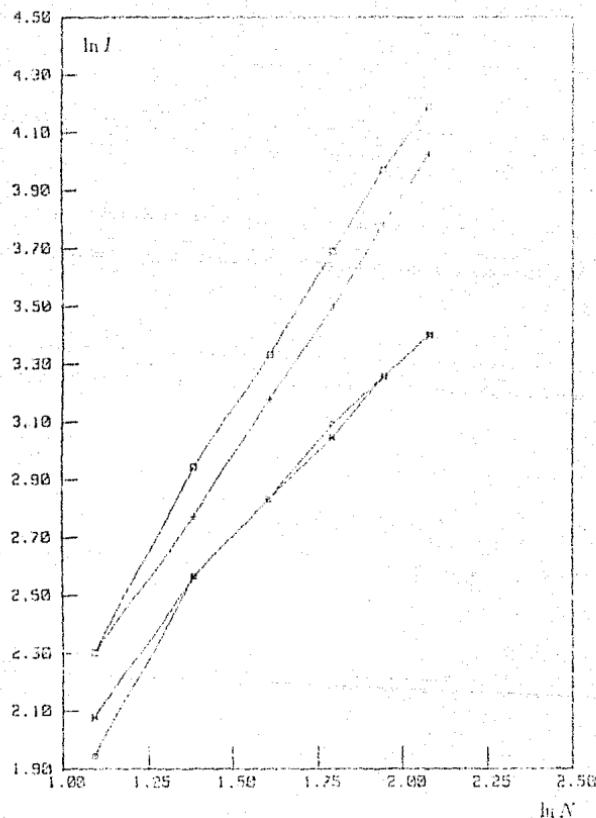


FIGURA 6. Gráfica de $\ln I$ contra $\ln N$ para los cuatro métodos, donde N^3 es la dimensión de la matriz. (+: NM; *: ORTHOMIN(3); ○: GM(3); □: EL).

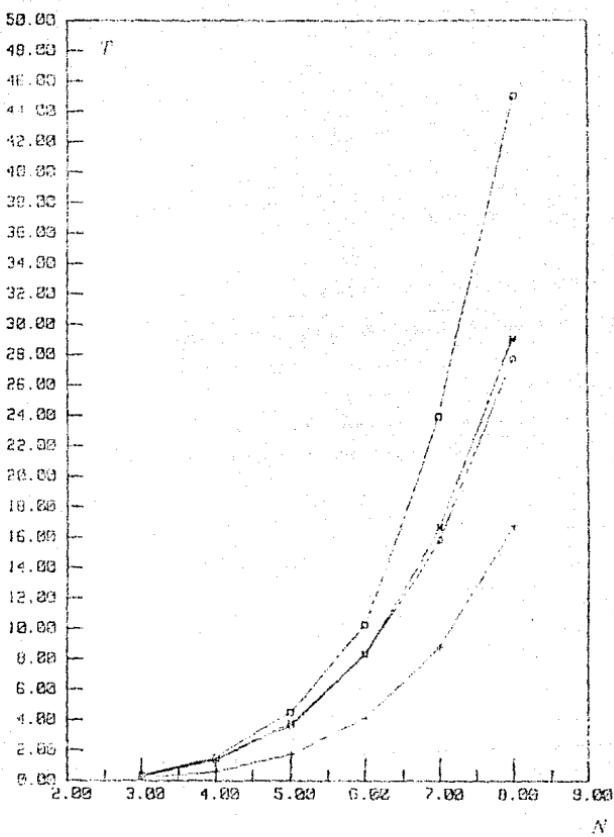


FIGURA 7. Gráfica de N contra T (tiempo) para los cuatro métodos, donde N^3 es la dimensión de la matriz. (+: NM; *: ORTHOMIN(3); O: GCR(3); □: EN)

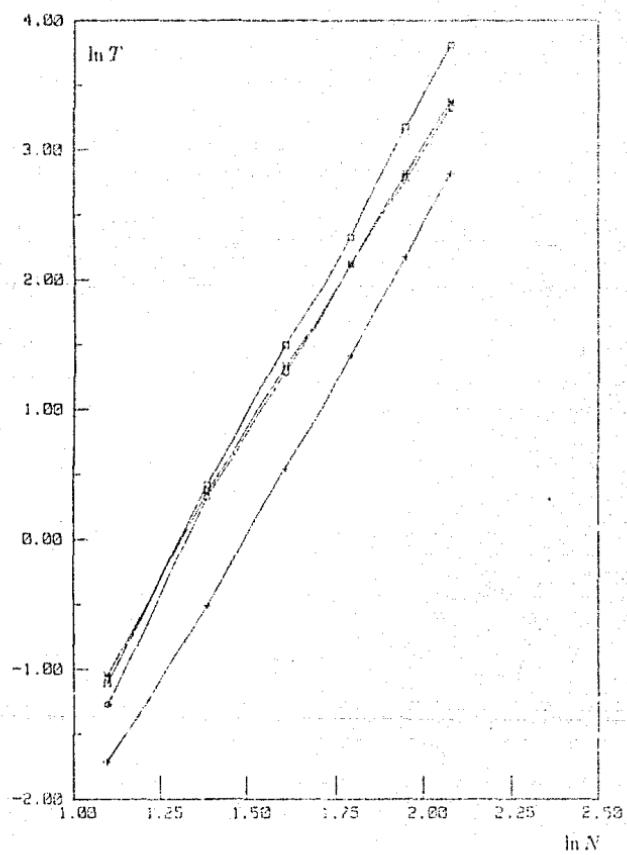


FIGURA 8. Gráfica de $\ln N$ contra $\ln T$ para los cuatro métodos, donde N^3 es la dimensión de la matriz. (+: NM; *: ORTHOMIN(3); ○: GCR(3); □: EN)

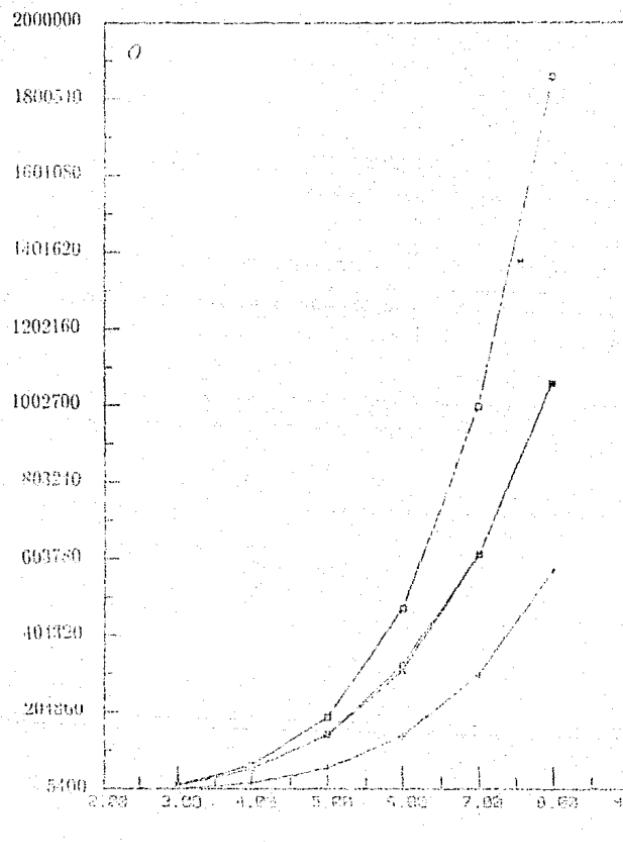


FIGURA 9. Gráfica de N contra O (número de operaciones) para los cuatro métodos. (Δ: NM; ○: ORTHOMIN(3); □: GCR(6); ◆: ES)

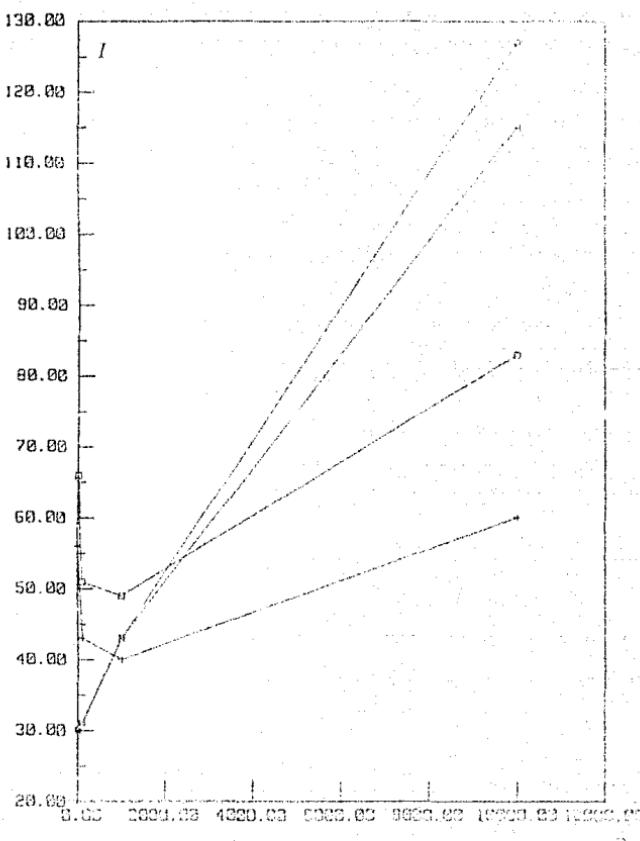


FIGURA 10. Gráfica de Pc (número de Peclét) contra I (iteraciones) para los cuatro métodos. (+: NM; *: ORTHOMIN(3); O: GCR(3); □: GS)

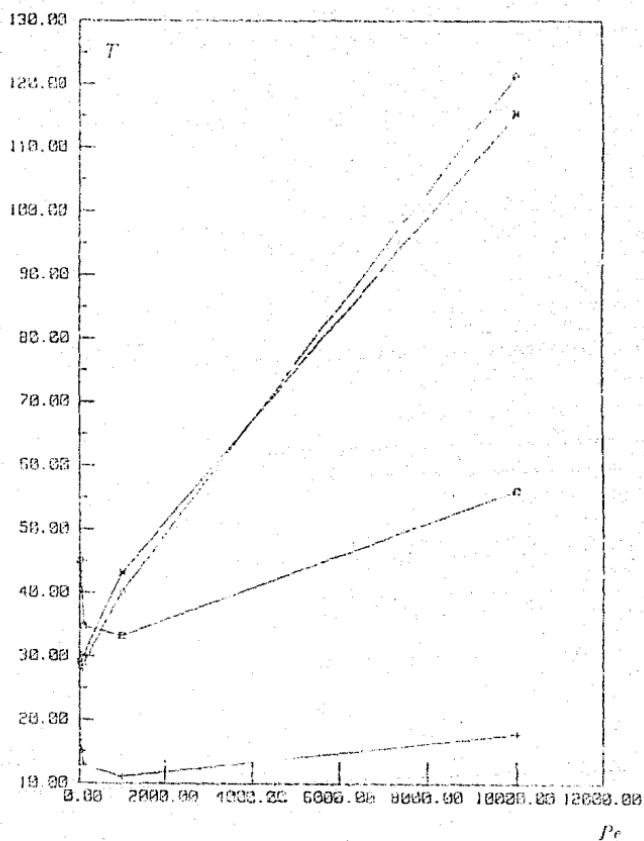


FIGURA 11. Gráfica de Pe (número de Peclet) contra T (tiempo) para los cuatro métodos. (+: NM; *: ORTHOMIN(3); ○: GCR(3); □: EN)

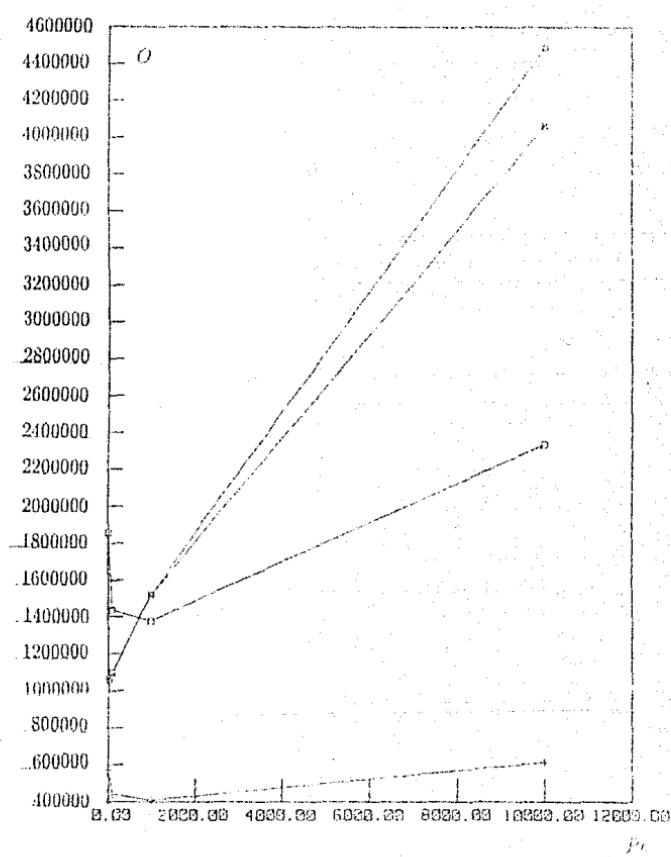


FIGURA 12. Gráfica de Pe (número de Pelet) contra O (número de operaciones) para los cuatro métodos. (+: NM; x: ORTHOMIN(4); ○: GEN(3); □: ES)

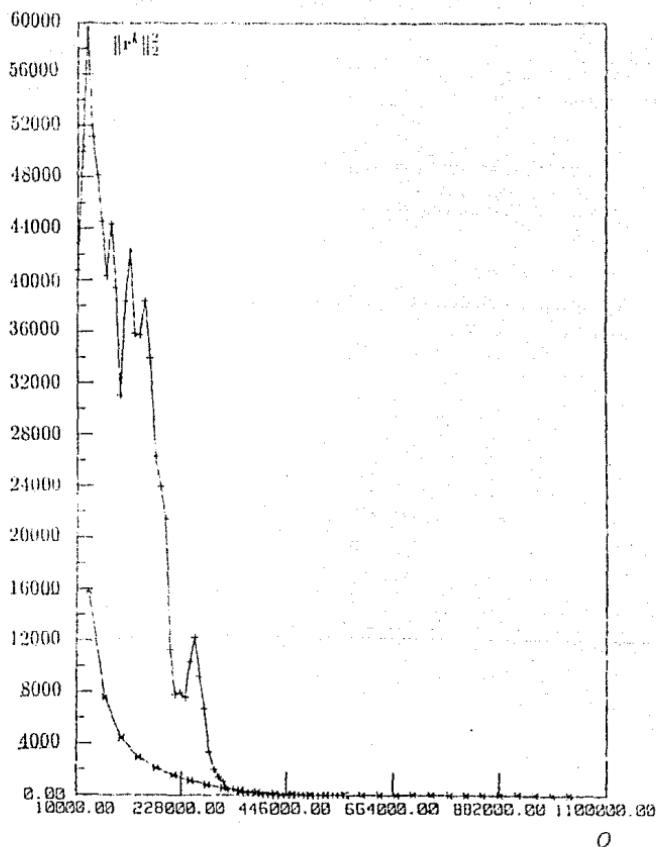


FIGURA 13. Gráfica de O (número de operaciones a la k -ésima iteración) contra $\|r^k\|^2$ (norma del residuo al cuadrado) para NM y ORTHOMIN(3). (+: NM; *: ORTHOMIN(3))

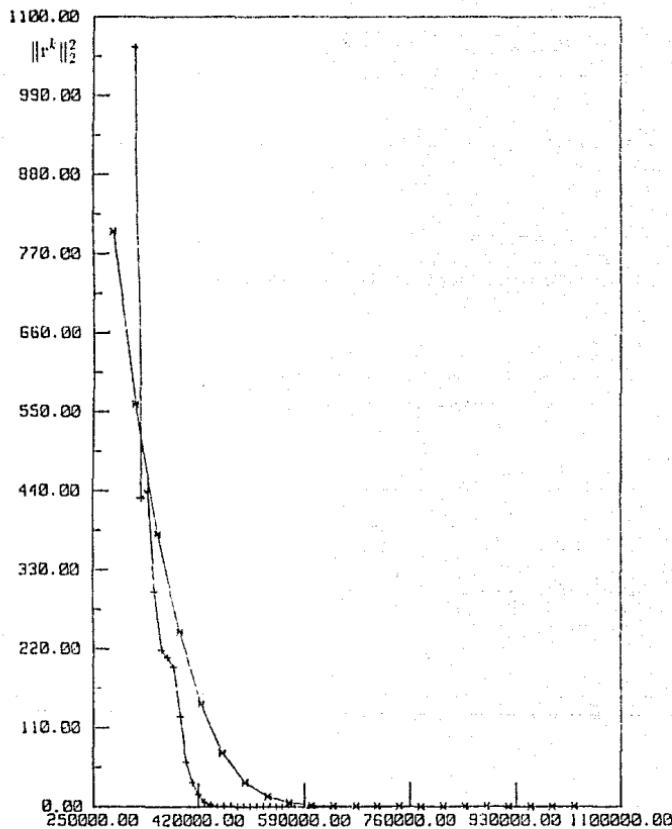


FIGURA 14. Acreamiento de la Figura 13.

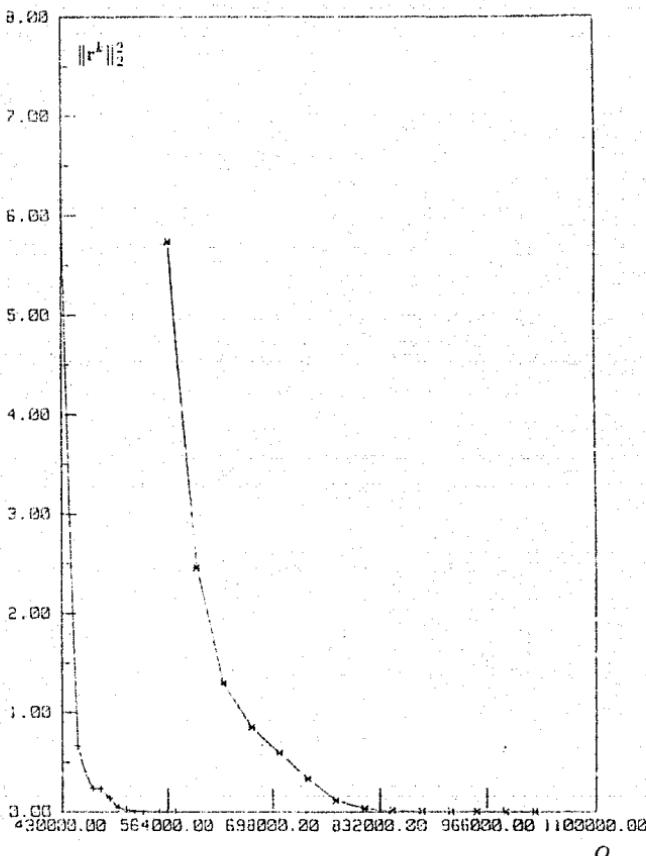


FIGURA 15. Acercamiento de la Figura 13.

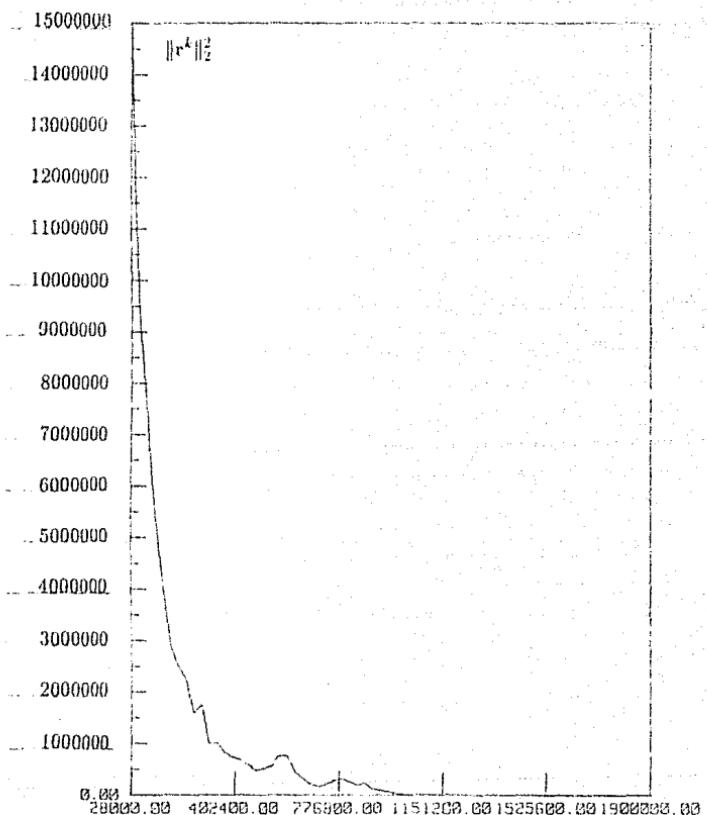


FIGURA 16. Gráfica de O (número de operaciones a la k -ésima iteración) contra $\|r^k\|_2^2$ (norma del residuo al cuadrado) para EN.

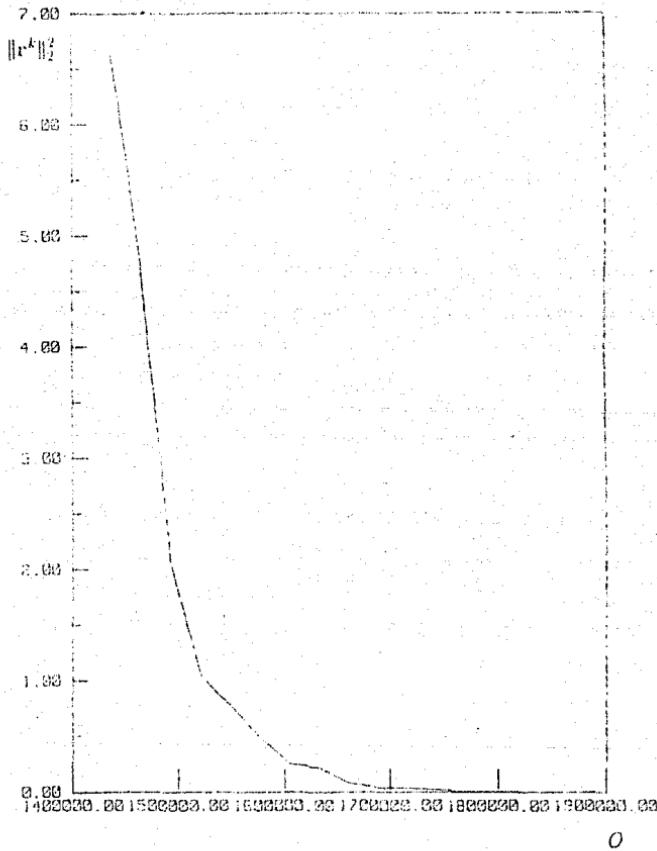


FIGURA 17. Acercamiento de la Figura 16.

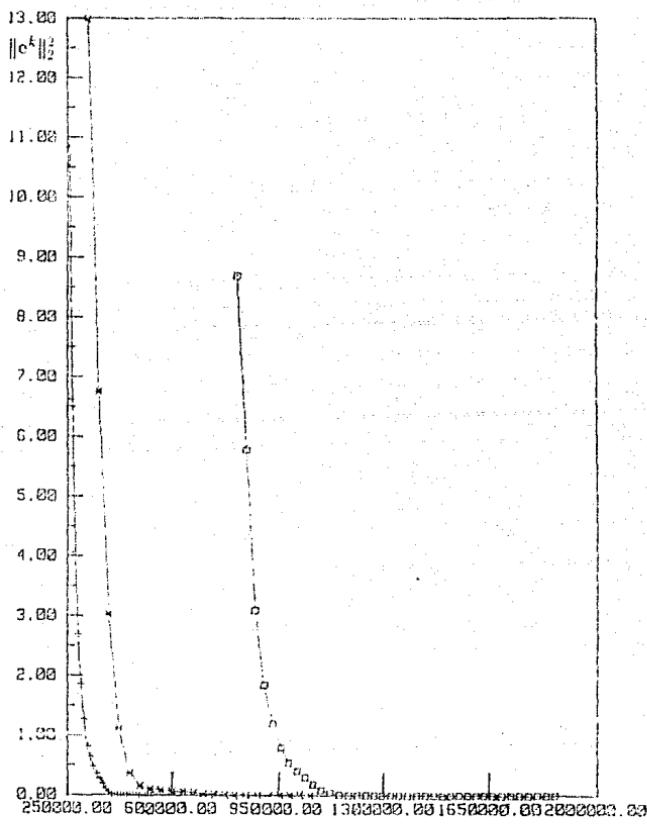


FIGURA 19. Acercamiento de la Figura 18.

Apéndice: programas

Los programas son versiones originales, tomando como referencia un programa desarrollado por el Dr. Robert Yates para el nuevo método. Están escritos en FORTRAN, utilizando las instrucciones básicas, a sugerencia del mismo Dr. Yates.

```
C*****+
C*****+
C**          PROGRAMA PROPGCHS.FOR
C**
C**+
C*****+
C*****+ RESUELVE EL PROBLEMA AU=B, CON A UNA MATRIZ NO SIMETRICA,
C UTILIZANDO EL METODO TRADICIONAL DE GRADIENTE CONJUGADO PARA
C EL SISTEMA AT*AU=AT*B, PERO UTILIZANDO EL PRODUCTO ESCALAR USUAL
C DE LOS REALES. LA MATRIZ A DEBE SER HEPTAGONAL CON ELEMENTOS
C IGUALES EN CADA REGLON.
C IMPLICIT REAL*8 (A-N,O-Z)
C DIMENSION A1(30000)
C OPEN(UNIT=1,FILE='MATRIZ.DAT',STATUS='OLD',FORM='BINARY')
C OPEN(UNIT=2,FILE='VECTOR.DAT',STATUS='OLD',FORM='BINARY')
C OPEN(UNIT=3,FILE='PIOPR.OH',STATUS='NEW')
C WRITE(*,*) 'CUAL ES LA DIMENSION X,Y,Z'
C READ(*,*) II,JJ,KK
C IJ=IJ*JJ
C IJ=IJ*KK
C IULT=1
C IA=IULT
C IU=IA+NP*7
C IB=IB+NP
C IW=IW+NP
C IR=IR+NP
C IV=IV+NP
C IP=IP+NP
C IS=IS+NP
C IULT=IS+NP
C IF(IULT.GT.30000) CALL EXIT
C CALL GRAL(IJ,IJ,NP,A1(IA),A1(IU),A1(IB),A1(IW),A1(IR),A1(IV),
C & A1(IP),A1(IS))
C CLOSE(UNIT=1)
C CLOSE(UNIT=2)
C CLOSE(UNIT=3)
C END
C *****
C LEE LAS ENTRADAS DE LA MATRIZ A DEL ARCHIVO 1 Y LAS DE B
C DEL ARCHIVO 2. DEFINE U=0 COMO PRIMERA APROXIMACION. LLAMA
C A LA SUBRUTINA
C SUBROUTINE GRAL(IJ,IJ,NP,A,U,B,W,R,V,P,S)
C IMPLICIT REAL*8 (A-N,O-Z)
```

```

DIMENSION A(NP,I),U(NP),B(NP),W(NP),R(NP),V(NP),P(NP),
* S(NP)
READ(2) (B(I),I=1,NP)
READ(1) ((A(I,J), J=1,7),I=1,NP)
DO 200 I=1,NP
200 U(I)=0.D0
CALL ASYNH(NP,IJ,II,A,U,B,R,P,V,W,S)
RETURN
END
C*****DESARROLLA EL ALGORITMO DE GRADIENTE CONJUGADO MODIFICADO.
C DEFINIMOS U COMO LA N-ESIMA APROXIMACION, R SU RESIDUO, P LA
C DIRECCION DE BUSQUEDA Y Q1 LA NORMA DE R. EL FIN DE LA SUBRUTINA
C SE DA DESDE DE LA PANTALLA.
SUBROUTINE ASYNH(NP,IJ,II,A,U,B,R,P,V,W,S)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A(NP,7),U(NP),B(NP),R(NP),P(NP),W(NP),V(NP),S(NP)
READ(*,*) H
N=0
10 CALL MUL3D(NP,IJ,II,A,U,W)
DO 20 I=1,NP
R(I)=B(I)-W(I)
P(I)=0.D0
20 CONTINUE
CALL MUL3DA(NP,II,II,A,B,S)
BETA=0.D0
30 DO 40 I=1,NP
V(I)=P(I)
P(I)=S(I)-BETA*P(I)
40 CONTINUE
ALPHA=0.D0
D=0.D0
DO 50 I=1,NP
ALPHA=ALPHA+R(I)*R(I)
D=D+P(I)*P(I)
50 CONTINUE
ALPHA=ALPHA/D
DO 60 I=1,NP
U(I)=U(I)+ALPHA*P(I)
60 CONTINUE
CALL MUL3D(NP,IJ,II,A,U,W)
Q1=0.D0
DO 70 I=1,NP
R(I)=B(I)-W(I)
Q1=Q1+R(I)**2
70 CONTINUE
CALL MUL3DA(NP,II,II,A,B,S)
N=N+1
WRITE(*,*) 'RESID',N,Q1
WRITE(*,*) N*20*NP,Q1
IF((N.GT.200).OR.(Q1.LEQ.1.0E-04)) RETURN
BETA=0.D0
DO 80 I=1,NP
BETA=BETA+S(I)*P(I)
80 CONTINUE

```

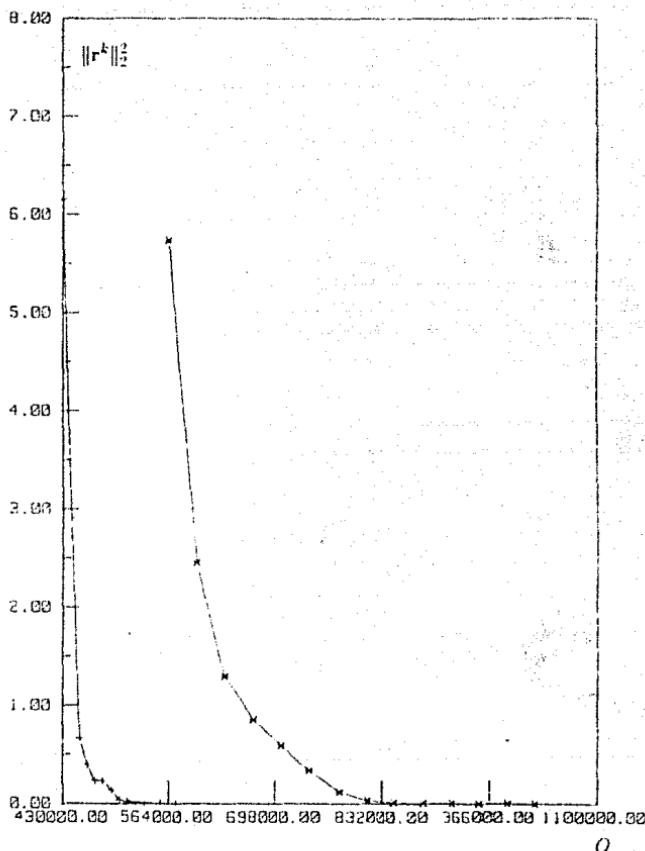


FIGURA 15. Acercamiento de la Figura 13.

```

CALL ORTHOMIN(NP,IJ,II,K,A,U,B,R,P,V,S,AP,V1)
RETURN
END
C*****DEFINIMOS U COMO LA N-ESIMA APROXIMACION, R SU RESIDUO, P LA
C MATRIZ QUE GUARDA A LA BASE Y Q1 LA NORMA DE R. EL FIN DE LA
C SUBRUTINA SE DA DESDE DE LA PANTALLA. LLAMA A LA SUBRUTINA
C BASE CADA VEZ QUE CONSTRUYE UNA NUEVA APROXIMACION.
SUBROUTINE ORTHOMIN(NP,IJ,II,K,A,U,B,R,P,V,S,AP,V1)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A(NP,7),U(NP),B(NP),R(NP),P(K,NP),V(NP),S(NP),
* AP(NP),V1(NP)
READ(*,*)
N=0
10 CALL MUL3D(NP,IJ,II,A,U,V)
DO 20 I=1,NP
R(I)=B(I)-V(I)
P(K,I)=R(I)
DO 25 J=1,K-1
P(J,I)=0.D0
25 CONTINUE
20 CONTINUE
30 DO 40 I=1,NP
V(I)=P(K,I)
40 CONTINUE
ALPHA=0.D0
D=0.D0
CALL MUL3D(NP,IJ,II,A,V,AP)
DO 50 I=1,NP
ALPHA=ALPHA+R(I)*AP(I)
D=D+AP(I)*AP(I)
50 CONTINUE
ALPHA=ALPHA/D
DO 60 I=1,NP
U(I)=U(I)+ALPHA*P(K,I)
60 CONTINUE
Q1=0.D0
DO 70 I=1,NP
R(I)=R(I)-ALPHA*AP(I)
Q1=Q1+R(I)**2
70 CONTINUE
N=N+1
WRITE(3,*) N,Q1
WRITE(*,*) 'RESIDU',N,Q1
IF((N.EQ.200).OR.(Q1.LE.10E-04)) RETURN
CALL BASE(NP,IJ,II,K,A,R,S,AP,P,V,V1)
GOTO 30
END

```

```

C*****+
C*****+
C**          PROGRAMA GCRK.FOR
C**          **
C**          **
C*****+
C*****+
C      RESUELVE EL PROBLEMA AU=B, CON A UNA MATRIZ NO SIMETRICA,
C      UTILIZANDO EL METODO TRADICIONAL DE RESIDUO CONJUGADO GENERALIZADO E
C      (GCR(K)). K ES EL NUMERO DE ELEMENTOS DE LA BASE A UTILIZAR. LA
C      MATRIZ A DERE SER EPTADIAGONAL CON ELEMENTOS IGUALES EN CADA REngLO.
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A1(30000)
OPEN(UNIT=1,FILE='MATRIZ.DAT',STATUS='OLD',FORM='BINARY')
OPEN(UNIT=2,FILE='VECTOR.DAT',STATUS='OLD',FORM='BINARY')
OPEN(UNIT=3,FILE='P1000GCR.DAT',STATUS='NEW')
WRITE(*,*) 'QUALES SON LAS DIMENSIONES X,Y,Z?'
READ(*,*) I1,JJ,KK
WRITE(*,*) 'CUAL ES EL VALOR DE K?'
READ(*,*) K
IJ=I1*JJ
NP=IJ*KK
IULT=1
IA=IA+NP*7
IU=IA+NP*7
IB=IB+NP
IR=IR+NP
IV=IV+NP
IP=IV+NP
IS=IS+NP*K
IAP=IS+NP
IV1=IAP+NP
IULT=IV1+NP
IF(IULT.LE.30000) GO TO 100
WRITE(*,*) 'NO CABE'
CALL EXIT
100 CALL GRAL(NP,IJ,I1,K,A1(IA),A1(IU),A1(IB),A1(IR),A1(IV),
* A1(IP),A1(IS),A1(IAP),A1(IV1))
CLOSE(UNIT=1)
CLOSE(UNIT=2)
CLOSE(UNIT=3)
END
C*****+
C      LEE LAS ENTRADAS DE LA MATRIZ A DEL ARCHIVO 1 Y LAS DE B
C      DEL ARCHIVO 2. DEFINE U=0 COMO PRIMERA APROXIMACION. LLAMA
C      A LA SUBRUTINA GCRK.
SUBROUTINE GRAL(NP,IJ,I1,K,A,U,B,R,V,P,S,AP,V1)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A(NP,7),U(NP),B(NP),R(NP),V(NP),P(K,NP),
* S(NP),AP(NP),VP(NP)
READ(2) (B(I),I=1,NP)
READ(1) ((A(I,J),J=1,7),I=1,NP)
DO 200 I=1,NP
200 U(I)=0.0D0
WRITE(*,*) 'SOL'

```

```

CALL GCRK(NP,IJ,II,K,A,U,B,R,P,V,S,AP,V1)
RETURN
END

C*****+
C  CADA K ITERACIONES (CONTADAS POR LA VARIABLE IC) TODOS LOS ELEMENTOS
C  DE LA BASE SE HACEN CERO EXCEPTO EL K-ESIMO QUE PASA A SER EL
C  PRIMERO. DEFINIMOS U COMO LA N-ESIMA APROXIMACION, R SU RESIDUO,
C  P LA DIRECCION DE BUSQUEDA Y Q1 LA BORNA DE R. EL FIN DE LA
C  SUBRUTINA SE DA DESDE DE LA PANTALLA. LLAMA A LA SUBRUTINA BASE
C  CADA VEZ QUE CONSTRUYE UNA NUEVA APROXIMACION.
SUBROUTINE GCRK(NP,IJ,II,E,A,U,B,R,P,V,S,AP,V1)
IMPLICIT REAL*8 (A-N,Z)
DIMENSION A(NP,7),U(NP),B(NP),R(NP),P(K,NP),V(NP),S(NP),
* AP(NP),V1(NP)
READ(*,*) 
N=0
CALL MUL3D(NP,IJ,II,A,U,V)
DO 20 I=1,NP
R(I)=B(I)-V(I)
P(K,I)=R(I)
20 CONTINUE
IC=K
30 IF (IC.NE.K) GO TO 32
DO 35 J=1,K-1
DO 37 I=1,NP
P(J,I)=0.D0
37 CONTINUE
35 CONTINUE
IC=5
32 IC=IC+1
DO 40 I=1,NP
V(I)=V(K,I)
40 CONTINUE
Q=0.D0
ALPHA=0.D0
D=0.D0
CALL MUL3D(NP,IJ,II,A,V,AP)
DO 50 I=1,NP
ALPHA=ALPHA+R(I)*AP(I)
D=D+AP(I)*AP(I)
50 CONTINUE
ALPHA=ALPHA/D
DO 60 I=1,NP
U(I)=U(I)+ALPHA*P(K,I)
60 CONTINUE
Q1=0.D0
DO 70 I=1,NP
R(I)=R(I)-ALPHA*AP(I)
Q1=Q1+R(I)*e2
70 CONTINUE
N=N+1
WRITE(*,*)'RESID',N,Q1
WRITE(9,*) N,Q1
IF ((N.EQ.200).OR.(Q1.LE.10E-04)) RETURN
CALL BASE(NP,IJ,II,K,A,R,S,AP,P,V,V1)

```

```

      GO TO 30
      END

C*****
C**          PROGRAMA GRADSG.FOR
C**
C**          RESUELVE EL PROBLEMA AU=B, CON A UNA MATRIZ NO SIMÉTRICA,
C**          UTILIZANDO EL MÉTODO TRADICIONAL DE GRADIENTE CONJUGADO PARA
C**          EL SISTEMA AT*AUX=A*B. LA MATRIZ A DEBE SER EPTADIAGONAL.
C**          CON ELEMENTOS IGUALES EN CADA REngLOn
      IMPLICIT REAL*8 (A-H,O-Z)
      DIMENSION A1(30000)
      OPEN(UNIT=1,FILE='MATRIZ.DAT',STATUS='OLD',FORM='BINARY')
      OPEN(UNIT=2,FILE='VECTOR.DAT',STATUS='OLD',FORM='BINARY')
      OPEN(UNIT=3,FILE='P10000G.DAT',STATUS='NEW')
      WRITE(*,*) 'CUAL ES LA DIMENSIÓN X,Y,Z'
      READ(*,*) II,JJ,KK
      IJ=II*JJ
      NP=IJ*KK
      IULT=1
      IA=IULT
      IU=IA+NP*7
      IB=IU+NP
      IW=IB+NP
      IR=IW+NP
      IV=IR+NP
      IP=IV+NP
      IS=IP+NP
      IAP=IS+NP
      IULT=IAP+NP
      IF(IULT.LE.30000) GO TO 100
      WRITE(*,*) 'NO CABE'
      CALL EXIT
100   CALL GRADSG(II,IJ,NP,A1(IA),A1(IU),A1(IB),A1(IW),A1(IR),
      * A1(IV),A1(IF),A1(IS),A1(IAP))
      CLOSE (UNIT=1)
      CLOSE (UNIT=2)
      CLOSE (UNIT=3)
      END

C*****          LEE LAS ENTRADAS DE LA MATRIZ A DEL ARCHIVO 1 Y LAS DE B
C**          DEL ARCHIVO 2. DEFINE U=0 COMO PRIMERA APROXIMACION. LLAMA
C**          A LA SUBRUTINA SVR.
      SUBROUTINE GRADSG(II,IJ,NP,U,R,W,V,P,S,RF)
      IMPLICIT REAL*8 (A-H,O-Z)
      DIMENSION A(NP,7),U(NP),V(NP),W(NP),R(NP),S(NP),P(NP),
      * RF(NP),AP(NP)
      READ(2) (V(I),I=1,NP)
      READ(1) ((A(I,J), J=1,7),I=1,NP)
      CALL MUL3DA(NP,IJ,II,A,V,B)
      DO 200 I=1,NP
      U(I)=0.00
200   CONTINUE

```

```

200 CONTINUE
CALL SYM(NP,IJ,II,A,U,B,P,V,W,S,AP)
RETURN
END

C*****DESARROLLA EL ALGORITMO DE GRADIENTE CONJUGADO. DEFINIMOS U
C COMO LA N-ESTIMA APROXIMACION, R SU RESIDUO, P LA DIRECCION
C DE BUSQUEDA Y Q1 LA NORMA DE R. EL FIN DE LA SUBRUTINA SE DA
C DESDE LA PANTALLA.
SUBROUTINE SYM(NP,IJ,II,A,U,B,P,V,W,S,AP)
IMPLICIT REAL=8 (I-H,O-Z)
DIMENSION A(NP,7),U(NP),B(NP),P(NP),W(NP),V(NP),S(NP),
- AP(NP)
READ(*,*)
N=0
CALL MUL3D(NP,IJ,II,A,U,V)
CALL MUL3DA(NP,IJ,II,A,V,V)
DO 20 I=1,NP
R(I)=B(I)-W(I)
P(I)=0.D0
20 CONTINUE
BETA=0.D0
30 DO 40 I=1,NP
V(I)=P(I)
P(I)=R(I)-BETA*P(I)
40 CONTINUE
ALPHA=0.D0
D=0.D0
CALL MUL3D(NP,IJ,II,A,P,V)
CALL MUL3DA(NP,IJ,II,A,V,AP)
DO 50 I=1,NP
ALPHA=ALPHA+R(I)*R(I)
D=D+P(I)*AP(I)
50 CONTINUE
ALPHA=ALPHA/0
DO 60 I=1,NP
U(I)=U(I)+ALPHA*P(I)
60 CONTINUE
CALL MUL3D(NP,IJ,II,A,U,V)
CALL MUL3DA(NP,IJ,II,A,V,W)
Q1=0.D0
DO 70 I=1,NP
R(I)=B(I)-W(I)
Q1=Q1+R(I)**2
70 CONTINUE
CALL MUL3D(NP,IJ,II,A,R,V)
CALL MUL3DA(NP,IJ,II,A,V,S)
N=N+1
WRITE(*,*)'RESID',N,Q1
WRITE(3,*) N,Q1
IF((N.EQ.200).OR.(Q1.LE.10E-04)) RETURN
200 BETA=0.D0
DO 80 I=1,NP
BETA=BETA+S(I)*P(I)
80 CONTINUE

```

```
BETA=BETA/D
GOTO 30
END
```

Subrutinas

```
C*****+
C*
C*          BASE
C*
C*****+
C  CONSTRUYE UN VECTOR P(K,J) ORTOGONAL A P(1,J), P(2,J), ..., P(K-1,J).
C  J=1,...,NP, POR MEDIO DEL METODO GRAH-SCHMIDT.
SUBROUTINE BASE(NP,IJ,II,K,A,R,S,AP,P,V,V1)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A(NP,7),P(K,NP),R(NP),S(NP),AP(NP),V(NP),V1(NP)
DO 10 J=1,NP
DO 20 I=1,K-1
P(I,J)=P(I+1,J)
20 CONTINUE
P(K,J)=0.D0
10 CONTINUE
DO 30 I=1,K-1
BETA=0.D0
D=0.D0
DO 40 J=1,NP
V(J)=P(I,J)
40 CONTINUE
CALL MUL3D(NP,IJ,II,A,V,AP)
CALL MUL3D(NP,IJ,II,A,R,S)
DO 50 J=1,NP
BETA=BETA+S(J)*AP(J)
D=D*AP(J)**2
50 CONTINUE
IF (D.EQ.0.D0) BETA=0.D0
IF (D.NE.0.D0) BETA=BETA/D
DO 60 J=1,NP
P(K,J)=P(K,J)-BETA*P(I,J)
60 CONTINUE
30 CONTINUE
DU 70 J=1,NP
P(K,J)=P(K,J)+R(J)
70 CONTINUE
DU 75 I=1,NP
V(I)=P(K,I)
75 CONTINUE
CALL MUL3D(NP,IJ,II,A,V,AP)
DO 90 I=1,K-1
DO 100 J=1,NP
V(J)=P(I,J)
100 CONTINUE
BETA=0.D0
```

```

CALL MUL3D(NP,II,II,A,V,V1)
DO 95 J=1,NP
  BETA=BETA+V1(J)*AP(J)
95 CONTINUE
90 CONTINUE
RETURN
END

C*****+
C*
C*                               MUL3D
C*
C*****+
C  MULTIPLICA AM LA MATRIZ AM POR X Y EL RESULTADO SERA Y. AN
C  ES UNA MATRIZ NP X 7 - DIMENSIONAL. LA DIMENSION EN X ES II,
C  LA DIMENSION DE X POR LA DE Y ES IJ.
SUBROUTINE MUL3D(NP,II,II,AM,X,Y)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION AM(NP,7),X(NP),Y(NP)
NP1=NP-11
NP2=NP-1J
Y(I)=AM(1,4)*X(1)+AM(1,5)*X(2)+AM(1,6)*X(II+1)+AM(1,7)*X(IJ+1)
Y(NP)=AM(NP,4)*X(NP)+AM(NP,5)*X(NP1)+AM(NP,3)*X(NP2)
* +AM(NP,1)*X(NP)
DO 100 K=2,NP-1
  Y(K)=AM(K,4)*X(K)+AM(K,3)*X(K-1)+AM(K,5)*X(K+1)
  IF(K.GT.II) Y(K)=Y(K)+AM(K,2)*X(K-II)
  IF(K.GT.IJ) Y(K)=Y(K)+AM(K,1)*X(K-IJ)
  IF(K.LE.NP2) Y(K)=Y(K)+AM(K,7)*X(K+IJ)
  IF(K.LE.NP1) Y(K)=Y(K)+AM(K,6)*X(K+II)
100 CONTINUE
RETURN
END

C*****+
C*
C*                               MUL3DA
C*
C*****+
C  MULTIPLICA AM LA MATRIZ ANT POR X Y EL RESULTADO SERA Y. AN
C  ES UNA MATRIZ NP X 7 - DIMENSIONAL. LA DIMENSION EN X ES II,
C  LA DIMENSION DE X POR LA DE Y ES IJ.
SUBROUTINE MUL3DA(NP,II,II,AM,X,Y)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION AM(NP,7),X(NP),Y(NP)
NP1=NP-11
NP2=NP-1J
Y(I)=AM(1,4)*X(1)+AM(2,3)*X(2)+AM(II+1,2)*X(II+1)
* +AM(JI+1,1)*X(IJ+1)
Y(NP)=AM(NP,4)*X(NP)+AM(NP1,6)*X(NP1)+AM(NP-1,5)*X(NP2)
* +AM(NP2,7)*X(NP2)
DO 100 K=2,NP-1
  Y(K)=AM(K,4)*X(K)+AM(K-1,5)*X(K-1)+AM(K+1,3)*X(K+1)
  IF(K.GT.II) Y(K)=Y(K)+AM(K-II,6)*X(K-II)
  IF(K.GT.IJ) Y(K)=Y(K)+AM(K-IJ,7)*X(K-IJ)
  IF(K.LE.NP2) Y(K)=Y(K)+AM(K+IJ,1)*X(K+IJ)
  IF(K.LE.NP1) Y(K)=Y(K)+AM(K+II,2)*X(K+II)
100 CONTINUE

```

```
100  CONTINUE
      RETURN
      END
C*****+
C.*****+
C**          PROGRAMA GENMAT.FOR
C**          ++
C**          ++
C*****+
C*****+
C      DA VALORES A LAS ENTRADAS DE LA MATRIZ A EN BASE A LA ECUACION
C      DE TRANSPORTE CON DIFUSION EN ESTADO ESTACIONARIO.
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A1(30000)
OPEN(UNIT=1,FILE='MATTRIZ.DAT',FORM='BINARY')
OPEN(UNIT=2,FILE='VECTOR.DAT',FORM='BINARY')
WRITE(*,*) 'QUEALES SON LAS DIMENSIONES X,Y,Z'
READ(*,*) II,JJ,KK
IJ=II*JJ
NP=IJ*KK
IULT=1
IA=IULT
IU=IA+NP*7
IB=IU+NP
IULT=IB+NP
IF(IULT.GT.30000) CALL EXIT
CALL GENMAT(NP,IJ,II,A1(IA),A1(IU),A1(IB))
CLOSE(UNIT=1)
CLOSE(UNIT=2)
END
C*****+
C      DA VALORES A LAS ENTRADAS DE LA MATRIZ A, DEFINE B=AU DONDE
C      U TINE VALOR 1 EN TODAS SUS COMPONENTES. DEFINE U=0 COMO
C      PRIMERA APROXIMACION. LLAMA A LA SUBRUTINA GCRK.
SUBROUTINE GENMAT(NP,IJ,II,A,U,B)
IMPLICIT REAL*8 (A-H,O-Z)
DIMENSION A(NP,7),U(NP),B(NP)
WRITE(*,*) 'CUAL ES EL NUMERO DE PECLET?'
READ(*,*) PE
WRITE(*,*) 'DE QUE TAMAÑO SON LOS LADOS DE LAS CELDAS DE LA RED?'
READ(*,*) H
T=3.0D0*H
V=SQRT(PE/T)
Q=-V/2.0D0-1.0D0/H
X1=0
X2=0
X3=Q
A=0 DO/H
Q=V/2.0D0-1.0D0/H
X5=Q
X6=Q
X7=Q
WRITE(*,*) X1,X2,X3,X4,X5,X6,X7
DO 100 I=1,NP
A(I,4)=X4
```

```

      A(I,3)=X3
      A(I,5)=X5
      A(I,2)=X2
      A(I,1)=X1
      A(I,7)=X7
      A(I,6)=X6
      B(I)=0.00
      IF(I.GE.IJ+1) GO TO 10
      B(I)=B(I)-1.00*A(I,1)
      A(I,1)=0.00
10     IF(MOD(I-1,IJ).GE.1) GO TO 20
      B(I)=B(I)-1.00*A(I,2)
      A(I,2)=0.00
20     IF(MOD(I,IJ).NE.1) GO TO 30
      B(I)=B(I)-1.00*A(I,3)
      A(I,3)=0.00
30     IF(MOD(I-1,IJ).LE.IJ-1I-1) GO TO 40
      A(I,6)=0.00
40     IF(MOD(I,IJ).NE.0) GO TO 50
      A(I,5)=0.00
50     IF(I.LE.NP-IJ) GO TO 100
      A(I,7)=0.00
100    CONTINUE
      DO 150 I=1,NP
      WRITE(2) B(I)
      DO 200 J=1,7
      WRITE(1) A(I,J)
200    CONTINUE
150    CONTINUE
      RETURN
      END
C*****
```

ESTA TESIS NO DEBE
SALIR DE LA BIBLIOTECA

Referencias

- [1] Allen, M.B., Herrera, I. and Pinder, G.F., *Numerical Modeling in Science and Engineering*, John Wiley and Sons, 1988.
- [2] Birkhoff, G. and Lynch, R.E., *Numerical Solution of Elliptic Problems*, Philadelphia: SIAM, 1973.
- [3] Celia, M.A., Herrera I., Bouloutas, E.T., and Kindred, J.S., A New Numerical Approach for the Advection-Diffusive Transport Equation, *Numer. Methods for Partial Differential Equations* 5 no.3, 1989.
- [4] Eisenstat, S.C., Elman, H.C. and Schultz, M.H., Variational Iterative Methods for Nonsymmetric Systems of Linear Equations, *SIAM J. Numer. Anal.* vol. **20**, no.2, April 1983.
- [5] Freidberg, S.H., Iusel, A.J. y Spence, L.E., *Álgebra Lineal*, Publicaciones Cultura, S.A., 1982.
- [6] Golub, G.H., Van Loan, C.F. *Matrix Computations*, Baltimore: Johns Hopkins University Press, 1983.
- [7] Gómez, S. and Morales, J.L., Performance of the Chebyshev Iterative Method, GMRES and Orthomin on a Set of Oil Reservoir Simulation Problems, in: *Mathematics for Large Scale Computing*, capítulo 11, Díaz, J.C., ed., 1989.
- [8] Hestenes, M.R. and Stiefel, E., Metodos de Conjugate Gradients for Solving Linear Systems, *J. Res. Natl. Bur. Standards*, **49** (1952) pp. 409-436.
- [9] Hestenes, M.R., *Applications of Mathematics Conjugate Direction Methods in Optimization*, Springer-Verlag, 1980.
- [10] Herrera, I., Un Análisis del Método de Gradiente Conjugado, *Comunicaciones Técnicas del Instituto de Geofísica*, UNAM, Serie Investigación, no.7, 1988.
- [11] Maltsev, A.I., *Fundamentos del Álgebra Lineal*, Sielsa Veintimila Editores S. A., 1970.
- [12] Reid, J.K., On the Method of Conjugate Gradients for the Solution of Large Sparse Systems of Linear Equations, in: *Large Sparse Sets of Linear Equations*, J.K. Reid, ed., Academic Press, New York, 1971, pp. 231-264.
- [13] Saad, Y. and Schultz M.H. GMRES: A generalized Residual Algorithm for Solving Nonsymmetric Linear Systems, *SIAM J. Sci. Stat. Comput.* **7**, no.3, 1986.
- [14] Vinsome, P.K.W., ORTHOMIN, an Iterative Method for Solving Sparse Sets of Simultaneous Linear Equations, in: *Proc. Fourth Symposium on Reservoir Simulation*, Society of Petroleum Engineers of AIME, 1976.