

Aspectos matemáticos y computacionales de los métodos de optimización de descenso coordinado

Juan Pablo Soto Quirós

jusoto@tec.ac.cr

Escuela de Matemática
Instituto Tecnológico de Costa Rica

12 de agosto del 2019

- 1 Introducción
- 2 Problema de Optimización para una Función Multivariable
- 3 Método de Descenso Coordinado
 - Optimización Alternada
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques
- 4 Aplicación: Aproximación de Matrices de Rango Reducido

- 1 Introducción
- 2 Problema de Optimización para una Función Multivariable
- 3 Método de Descenso Coordinado
 - Optimización Alternada
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques
- 4 Aplicación: Aproximación de Matrices de Rango Reducido

- La presente charla explicará algunos aspectos matemáticos y computacionales sobre un conjunto de métodos iterativos para resolver problemas de minimización para funciones en varias variables, usando la técnica de **descenso coordinado**.
- En especial, daremos énfasis en tres métodos basados en el descenso coordinado:
 - Optimización Alternada
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques
- Al final, se mostrará una aplicación en un problema de optimización de matrices con rango restringido, utilizando la norma de Frobenius

- La presente charla explicará algunos aspectos matemáticos y computacionales sobre un conjunto de métodos iterativos para resolver problemas de minimización para funciones en varias variables, usando la técnica de **descenso coordinado**.
- En especial, daremos énfasis en tres métodos basados en el descenso coordinado:
 - Optimización Alternada
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques
- Al final, se mostrará una aplicación en un problema de optimización de matrices con rango restringido, utilizando la norma de Frobenius

1 Introducción

2 Problema de Optimización para una Función Multivariable

3 Método de Descenso Coordinado

- Optimización Alternada
- Mejora Máxima por Bloques
- Proyección del Gradiente de Coordenadas por Bloques

4 Aplicación: Aproximación de Matrices de Rango Reducido

Función multivariable

Una función escalar de n variables $f : \mathbb{R}^n \rightarrow \mathbb{R}$, asigna a cada punto $(x_1, \dots, x_n) \in \mathbb{R}^n$, un único número real denotado con $f(x_1, \dots, x_n) \in \mathbb{R}$.

Problema

Sea $\mathbf{x} = (x_1, \dots, x_n)$. El objetivo de esta presentación es explicar un conjunto de métodos iterativos que permitirán dar una solución al problema de minimización

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}).$$

- En resumen, los pasos para resolver el problema

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

en un curso de cálculo en varias variables son los siguientes:

- 1 Calcular los puntos críticos (Gradiente).
- 2 Calcular el Hessiano Orlado (Hessiano Orlado).
- 3 Evaluar puntos críticos en el Hessiano Orlado.
- 4 Calcular determinantes de las submatrices principales.
- 5 Interpretar resultado.

- La solución del problema $\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$ se realizará a través de métodos iterativos.
- Es decir, dado un valor inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$, cada método iterativo generará una sucesión de puntos

$$\{\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(k)}, \dots\},$$

donde $\mathbf{x}^{(j)} \in \mathbb{R}^n$, para todo $j = 1, 2, \dots$


- La sucesión de puntos puede tener tres criterios de convergencia:
 - 1 La sucesión converge a la solución del problema.
 - 2 La sucesión converge a a un punto que no es solución del problema.
 - 3 La sucesión no converge.

- 1 Introducción
- 2 Problema de Optimización para una Función Multivariable
- 3 Método de Descenso Coordinado**
 - Optimización Alternada
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques
- 4 Aplicación: Aproximación de Matrices de Rango Reducido

- Los métodos de descenso coordinado son un conjunto de algoritmo de optimización que minimiza sucesivamente a lo largo de las direcciones de coordenadas para encontrar el mínimo de una función.
- En cada iteración, el algoritmo determina una coordenada a través de una regla de selección de coordenadas
- Luego minimiza de manera exacta mientras fija todas las demás coordenadas o bloques de coordenadas.

- Sea $f(\mathbf{x})$ definida como $f : \mathbb{R}^n \rightarrow \mathbb{R}$ y sea $\mathbf{x}^{(0)} = (x_1^{(0)}, \dots, x_n^{(0)})$ un valor inicial.
- Sea $j = 1, 2, \dots, n$. La idea general de los métodos de descenso coordinado consiste en los siguientes pasos
 - 1 Definir una función de variable real $f_{x_j} : \mathbb{R} \rightarrow \mathbb{R}$, de la forma $f_{x_j}(x_j)$.
 - 2 Calcular el mínimo de la función f_{x_j} .
 - 3 Basado en algún criterio, se obtiene $x_j^{(1)}$.
- El proceso se repite para generar una sucesión $\{\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(k)}, \dots\}$.

- Daremos énfasis en tres métodos basados en el descenso coordinado:
 - Optimización Alternada
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques



- 1 Introducción
- 2 Problema de Optimización para una Función Multivariable
- 3 **Método de Descenso Coordinado**
 - **Optimización Alternada**
 - Mejora Máxima por Bloques
 - Proyección del Gradiente de Coordenadas por Bloques
- 4 Aplicación: Aproximación de Matrices de Rango Reducido

- El método de Optimización Alternativa (OA) actualiza solo una de las variables mientras las otras variables son “fijadas”. El método OA también es conocido con el nombre de **descenso coordinado por bloques**.
- Existen varias reglas para seleccionar cual variable es actualizadas. Las tres reglas más utilizadas son:
 1. **Regla de Jacobian:** en cada iteración k , las n variables son actualizadas, utilizando exactamente los valores de la iteración anterior $k - 1$.

$$x_j^{(k)} \in \arg \min_{x_j \in \mathbb{R}} f \left(x_1^{(k-1)}, \dots, x_{j-1}^{(k-1)}, x_j, x_{j+1}^{(k-1)}, \dots, x_n^{(k-1)} \right),$$

para $j = 1, \dots, p$. Esta actualización se puede hacer en paralelo.

2. **Reglas de Gauss-Seidel:** en cada iteración k , las n variables son actualizadas, utilizando exactamente los valores de la iteración anterior $k - 1$, y los valores de la iteración k calculados anteriormente.

$$x_j^{(k)} \in \arg \min_{x_j \in \mathbb{R}} f \left(x_1^{(k)}, \dots, x_{j-1}^{(k)}, x_j, x_{j+1}^{(k-1)}, \dots, x_n^{(k-1)} \right),$$

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

3. **Reglas Aleatorizada:** es una variación de la regla de Gauss-Seidel, pero la selección de la variable se hace de manera aleatoria, sin seguir un orden establecido.

Observación: De las 3 reglas mencionadas, la regla de Gauss-Seidel es la más utilizada.

Algorithm 1 Método de Optimización Alternada

Requires: $\mathbf{x}^{(0)} = (x_1^{(0)}, \dots, x_n^{(0)}) \in \mathbb{R}^n$


Returns: $\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_n^{(k)}) \in \mathbb{R}^n$

```
1: for  $k = 1, 2, \dots$  do
2:   for  $j = 1, \dots, n$  do
3:      $x_j^{(k)}$  = Usando la regla de Jacobi o Gauss-Seidel
4:   end
5:   if el criterio de parada se cumple then
6:     return  $x^{(k)} = (x_1^{(k)}, \dots, x_n^{(k)})$ 
7:   end
8: end
```

Ejemplo 1

Considere la función $f(x, y) = (x - 2)^2 + (y + 3)^2 + xy$. Aplicando el método OA con la regla de Gauss-Seidel y $\mathbf{x}^{(0)} = (1, 1)$, obtenemos los siguientes resultados.

k	$\mathbf{x}^{(k)}$	$f(\mathbf{x}^{(k)})$
0	(1, 1)	18
1	(1.5, -3.75)	4.8125
2	(3.875, -4.9375)	11.8633
3	(4.4688, -5.2344)	12.3040
\vdots	\vdots	\vdots
9	(4.666, -5.333)	12.3333



Ejemplo 2

Considere la función $f(x, y, z) = x^3 + y^3 + z^3 - 2xy - 2xz - 2yz$.
 Aplicando el método OA con la regla de Gauss-Seidel y $\mathbf{x}^{(0)} = (1, 1, 1)$,
 obtenemos los siguientes resultados.

k	$\mathbf{x}^{(k)}$	$f(\mathbf{x}^{(k)})$
0	(1, 1, 1)	3
1	(1.1547, 1.1985, 1.2525)	3.4366
2	(1.2641, 1.2953, 1.3062)	3.5392
\vdots	\vdots	\vdots
8	(1.333, 1.333, 1.333)	3.5556

Observaciones:

- El método converge a (1.333, 1.333, 1.333), el cual no es un mínimo absoluto, sino un mínimo local.
- Si el valor inicial cambia a $\mathbf{x}^{(0)} = (-1, -1, -1)$, el método diverge.


- Lo anterior nos pone a pensar en dos preguntas:
 - 1 **¿Cuándo el método AO converge?**
 - 2 **¿Si converge, a que valor converge?**

Algunas definiciones

Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$.

- El **epigrafo** de f se define como el conjunto

$$\text{epi}(f) = \{(\mathbf{x}, \gamma) : f(\mathbf{x}) \leq \gamma, \forall \mathbf{x} \in \mathbb{R}^n, \gamma \in \mathbb{R}\}.$$



- Una función f es **cerrada** si su epigrafo es cerrado.

Algunas definiciones (continuación)

- f es una función **apropiada** si no existe ningún punto \mathbf{x} tal que $f(\mathbf{x}) = -\infty$ y cuyo dominio no es vacío.
- Un punto $\mathbf{x}^* \in \mathbb{R}^n$ se llama **mínimo coordenado** si

$$f(\mathbf{x}^*) \leq f(\mathbf{x}^* + \alpha \cdot \mathbf{e}_j),$$

para $j = 1, \dots, n$ y $\alpha \in \mathbb{R}$. Aquí, $\{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ es la base canónica en \mathbb{R}^n .




Figura: Gráfica de la función $f(x, y) = |x - 2y| + |3x + 4y|$.

Teorema de Convergencia del Método AO

Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ una función apropiada y cerrada, la cual es continua en su dominio. Si se cumple que

- 1 el problema $\min_{x_j \in \mathbb{R}} f \left(x_1^{(k)}, \dots, x_{j-1}^{(k)}, x_j, x_{j+1}^{(k-1)}, \dots, x_n^{(k-1)} \right)$ tiene una solución única, para todo $j = 1, \dots, n$
- 2 para cualquier $\mathbf{x}^{(0)}$, el conjunto $\{\mathbf{x} \in \mathbb{R}^n : f(\mathbf{x}) \leq f(\mathbf{x}^{(0)})\}$ es un conjunto acotado

entonces la sucesión generada por el método AO converge a un mínimo coordinado.

Nota: Si $f(\mathbf{x}) = g(\mathbf{x}) + \sum_{i=1}^n h_i(x_i)$, donde g es una función convexa y diferenciable, y cada h_i es convexa (no necesariamente diferenciable), entonces un mínimo coordinado de f es también un mínimo global de f .

- 1 Introducción
- 2 Problema de Optimización para una Función Multivariable
- 3 Método de Descenso Coordinado**
 - Optimización Alternada
 - Mejora Máxima por Bloques**
 - Proyección del Gradiente de Coordenadas por Bloques
- 4 Aplicación: Aproximación de Matrices de Rango Reducido

- Otro método iterativo de optimización por bloques es el método conocido como **mejora máxima por bloques** (MMB).
- El método MMB actualiza cada variable usando un enfoque tipo *greddy*.
- El método MMB actualiza el bloque de variables correspondiente al bloque de mejora máxima usando la regla de Jacobi, pero compara el error de cada una de las actualizaciones.
- Al final, la actualización con el error mínimo es el nuevo elemento de la sucesión

Algorithm 2 Método de Mejora Máxima por Bloques

Requires: $\mathbf{x}^{(0)} = (x_1^{(0)}, \dots, x_n^{(0)}) \in \mathbb{R}^n$

Returns: $\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_n^{(k)}) \in \mathbb{R}^n$

```

1: for  $k = 1, 2, \dots$  do
2:   for  $j = 1, \dots, n$  do
3:      $\tilde{x}_j^{(k)}$  = Usando la regla de Jacobi
4:      $e_j^{(k)} = f(x_1^{(k-1)}, \dots, x_{j-1}^{(k-1)}, \tilde{x}_j^{(k)}, x_{j+1}^{(k-1)}, \dots, x_n^{(k-1)})$ 
5:   end
6:    $i = \arg \min_{j=1, \dots, p} \{e_j^{(k)}\}$ 
7:   for  $j = 1, \dots, n$  do
8:     if  $j = i$  then
9:        $x_j^{(k)} = \tilde{x}_j^{(k)}$ 
10:    else
11:       $x_j^{(k)} = x_j^{(k-1)}$ 
12:    end
13:  end
14:  if el criterio de parada se cumple then
15:    return  $\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_n^{(k)})$ 
16:  end
17: end

```

Ejemplo 2

Considere la función

$$f(x, y, z) = (x - 2)^2 + (y + 3)^2 + (x + y + z)^2.$$

Aplicando el método MMB con un valor inicial $\mathbf{x}^{(0)} = (1, 1, 1)$, obtenemos los siguientes resultados.

k	$\mathbf{x}^{(k)}$	$f(\mathbf{x}^{(k)})$
0	(1, 1, 1)	30
1	(1, -2.5, 1)	5.5
2	(1, -2.5, 0.25)	4.375
3	(1.75, -2.5, 0.25)	2.125
4	1.75, -2.5, (-0.125)	1.8438
\vdots	\vdots	\vdots
27	(2.5, -2.5, -0.5)	1

- Una desventaja del método MMB es el exceso de cálculo, lo cual hace que el método converja más lento, comparado con el método OA.
- Sin embargo, esta desventaja se puede reducir si se implementa en paralelo.
- Otra ventaja es que este método es menos restrictivo, en términos de convergencia.

Convergencia del Método MMB

Si el conjunto $\{\mathbf{x} \in \mathbb{R}^n : f(\mathbf{x}) \leq f(\mathbf{x}^{(0)})\}$ es un conjunto acotado, entonces la sucesión generada por el método MMB converge a un mínimo coordinado de f .

1 Introducción

2 Problema de Optimización para una Función Multivariable

3 Método de Descenso Coordinado

- Optimización Alternada
- Mejora Máxima por Bloques
- Proyección del Gradiente de Coordenadas por Bloques

4 Aplicación: Aproximación de Matrices de Rango Reducido

- El método de proyección del gradiente de coordenadas por bloques (PGCB) se basa en el método del descenso del gradiente.
- El método PGCB consiste en realizar un paso de proyección de gradiente con respecto a variable, tomado en un orden cíclico.
- Para implementar este método, se necesita conocer dos conceptos: Gradiente de una función y constante de Lipschitz.

Definiciones

- El **gradiente** de una función f se define como el vector

$$\nabla f(\mathbf{x}) = \left(\frac{\partial f(\mathbf{x})}{dx_1}, \dots, \frac{\partial f(\mathbf{x})}{dx_n} \right).$$

- La **constante de Lipschitz** es el menor número real L que satisface

$$\|\nabla f(\mathbf{x}) - \nabla f(\mathbf{y})\| \leq L\|\mathbf{x} - \mathbf{y}\|,$$

para cada $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$.

Algorithm 2 Método de proyección del gradiente de coordenadas por bloques

Requires: $\mathbf{x}^{(0)} = (x_1^{(0)}, \dots, x_n^{(0)}) \in \mathbb{R}^n$

Returns: $\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_n^{(k)}) \in \mathbb{R}^n$

```

1: for  $k = 1, 2, \dots$  do
2:    $\mathbf{x}_{[0]}^{(k-1)} = \mathbf{x}^{(k-1)}$ 
3:   for  $j = 1, \dots, n$  do
4:      $\mathbf{x}_{[j]}^{(k-1)} = \mathbf{x}_{[j-1]}^{(k-1)} - \frac{1}{L} e_j e_j^T \nabla f(\mathbf{x}_{[j-1]}^{(k-1)})$ 
5:   end
6:    $\mathbf{x}^{(k)} = \mathbf{x}_{[p]}^{(k-1)}$ 
7:   if stopping criterion is satisfied then
8:     return  $\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_p^{(k)})$ 
9:   end
10: end

```

Convergencia del método PGCB

Sea f una función continua convexa con constante de Lipschitz, tal que exista un mínimo global \mathbf{x}^* . Entonces, la sucesión generada por el método PGCB converge a \mathbf{x}^* .

Observaciones:

- Los métodos explicados fueron diseñados para funciones $f : \mathbb{R}^n \rightarrow \mathbb{R}$.
- En el caso que se desea minimizar la función f bajo ciertas restricciones, el problema se interpreta de la siguiente manera: Sea $f : \mathbb{A} \rightarrow \mathbb{R}$, donde $\mathbb{A} \in \mathbb{R}^n$. Se desea resolver el siguiente problema de optimización

$$\min_{\mathbf{x} \in \mathbb{A}} f(\mathbf{x}).$$

- El método OA y PGCB incrementan las restricciones para garantizar la convergencia: necesitan que \mathbb{A} sea convexo y cerrados. Además, utilizan proyecciones ortogonales al espacio \mathbb{A} , lo cual no siempre es fácil de obtener.
- Sin embargo, el método MMB no necesita agregar más restricciones en el caso de trabajar un problema con restricciones.

1 Introducción

2 Problema de Optimización para una Función Multivariable

3 Método de Descenso Coordinado

- Optimización Alternada
- Mejora Máxima por Bloques
- Proyección del Gradiente de Coordenadas por Bloques

4 Aplicación: Aproximación de Matrices de Rango Reducido

Sea $\mathbb{R}_r^{m \times n}$ el conjunto de todas las matrices de tamaño $m \times n$, cuyo rango no es más grande que r .

Problema 1

Sean $A \in \mathbb{R}^{p \times q}$, $B_j \in \mathbb{R}^{p \times m_j}$ y $C_j \in \mathbb{R}^{n_j \times q}$, para $j = 1, 2, \dots, k$. El problema consiste en calcular $\hat{X}_j \in \mathbb{R}_{r_j}^{m_j \times n_j}$ tal que

$$\left\| A - \sum_{i=1}^k B_i \hat{X}_i C_i \right\|_{fr} = \min_{X_1, \dots, X_p} \left\| A - \sum_{i=1}^k B_i X_i C_i \right\|_{fr}$$

sujeito a $X_1 \in \mathbb{R}_{r_1}^{m_1 \times n_1}, \dots, X_p \in \mathbb{R}_{r_p}^{m_p \times n_p}$. Aquí, $\|\cdot\|_{fr}$ representa la norma de Frobenius.

Se sabe además lo siguiente:

$$X \in \mathbb{R}_r^{m \times n} \text{ si y solo si existen } M \in \mathbb{R}^{m \times r} \text{ and } N \in \mathbb{R}^{r \times n} \text{ tales que}$$

$$T = MN.$$

Por lo tanto, el Problema 1 se puede re-escribir de la siguiente manera:

Problema 2

Sean $A \in \mathbb{R}^{p \times q}$, $B_j \in \mathbb{R}^{p \times m_j}$ y $C_j \in \mathbb{R}^{n_j \times q}$, para $j = 1, 2, \dots, k$. El problema consiste en calcular $\widehat{M}_j \in \mathbb{R}^{m_j \times r_j}$ y $\widehat{N}_j \in \mathbb{R}^{r_j \times n_j}$ tal que

$$\left\| A - \sum_{i=1}^k B_i \widehat{M}_i \widehat{N}_i C_i \right\|_{fr} = \min_{M_1, N_1, \dots, M_k, N_k} \left\| A - \sum_{i=1}^k B_i M_i N_i C_i \right\|_{fr}$$

sujeto a $M_1 \in \mathbb{R}^{m_1 \times r_1}$ y $R_j \in \mathbb{R}^{r_j \times n_j}$, para todo $j = 1, 2, \dots, k$.

Consideremos las funciones $f_1 : \mathbb{R}_{r_1}^{m_1 \times n_1} \times \dots \times \mathbb{R}_{r_k}^{m_k \times n_k} \rightarrow \mathbb{R}$ definida por

$$f_1(X_1, \dots, X_p) = \left\| A - \sum_{j=1}^k B_j X_j C_j \right\|_{fr}$$

y $f_2 : \mathbb{R}^{m_1 \times r_1} \times \mathbb{R}^{r_1 \times n_1} \times \dots \times \mathbb{R}^{m_k \times r_k} \times \mathbb{R}^{r_k \times n_k} \rightarrow \mathbb{R}$ definida por

$$f_2(M_1, N_1, \dots, M_p, N_p) = \left\| A - \sum_{j=1}^k B_j M_j N_j C_j \right\|_{fr}.$$

En el siguiente ejemplo, aplicaremos los métodos OA, BBM y PGCB, para resolver el problema. Para eso, se debe saber que la solución al problema

$$\min_{X \in \mathbb{R}_r^{m \times n}} \|A - BXC\|_{fr}$$

está dado por $X = B^\dagger [BB^\dagger AC^\dagger C]_r C^\dagger$.

Algorithm 1 AO method for solving Problem (1)

Requires: $A \in \mathbb{R}^{p \times q}$, $B_j \in \mathbb{R}^{p \times m_j}$, $C_j \in \mathbb{R}^{n_j \times q}$, $X_j^{(0)} \in \mathbb{R}_{r_j}^{m_j \times n_j}$, for $j = 1, \dots, p$, and $tol \in \mathbb{R}^+$ **Returns:** $X_j^{(i+1)} \in \mathbb{R}_{r_j}^{m_j \times n_j}$, for $j = 1, \dots, p$



```


1: for  $i = 0, 1, 2, \dots$  do
2:   for  $j = 1, \dots, p$  do
3:      $A_j = A$ 
4:     for  $k = 1, \dots, p$  do
5:       if  $k \neq j$  then
6:          $A_j = A_j - B_k X_k^{(i)} C_k$ 
7:       end
8:     end
9:      $P_B = B_j B_j^\dagger$  and  $P_C = C_j^\dagger C_j$ 
10:     $X_j^{(i+1)} = B_j^\dagger [P_B A_j P_C]_{r_j} C_j^\dagger$ 
11:  end
12:  if  $f_1(X_1^{(i+1)}, \dots, X_p^{(i+1)}) < tol$  then
13:    return  $X_1^{(i+1)}, \dots, X_p^{(i+1)}$ 
14:  end
15: end

```

Ejemplo 1

Sean $A \in \mathbb{R}^{5 \times 6}$, $B_j \in \mathbb{R}^{5 \times 8}$, $C_j \in \mathbb{R}^{9 \times 6}$, y $r_j = 4$, para $j = 1, 2, 3, 4, 5$.
 Aplicando los métodos anteriores a los Problemas 1 y 2 obtenemos la siguiente gráfica de errores






- Problema 1 - OA Método:
 $error = 1.9748 \times 10^{-9}$.
- Problema 1 - BCGP Método:
 $error = 6.1916 \times 10^4$.
- Problema 2 - AO Método:
 $error = 6.4526 \times 10^{-10}$.
- Problema 1 - MBI Método:
 $error = 7.8744 \times 10^{-10}$.

Observación: Después de 300 iteraciones, the método BCGP produce un error de 4.9256×10^{-4} .

Ejemplo 2

Sean $A \in \mathbb{R}^{50 \times 60}$, $B_j \in \mathbb{R}^{50 \times 80}$, $C_j \in \mathbb{R}^{90 \times 60}$, y $r_j = 40$, para $j = 1, 2, 3, 4, 5$. Aplicando los métodos anteriores a los Problemas 1 y 2 obtenemos la siguiente gráfica de errores



- Problema 1 - OA Método:
 $error = 1.8235 \times 10^{-6}$.
- Problema 1 - BCGP Método:
 $error = 2.6819 \times 10^8$.
- Problema 2 - AO Método:
 $error = 7.6174 \times 10^{-7}$.
- Problema 1 - MBI Método:
 $error = 6.9444 \times 10^{-5}$.