



Optimización no lineal

José María Ferrer Caja
Universidad Pontificia Comillas

Planteamiento general

$$\begin{aligned} \min_x & f(x) \\ g_i(x) & \leq 0 \quad \forall i = 1, \dots, m \\ f, g_i & : \mathbb{R}^n \rightarrow \mathbb{R} \end{aligned}$$

- ❑ La teoría se desarrolla para problemas de **minimización**, los problemas de maximización se tratan de forma análoga
- ❑ En un mismo problema puede haber restricciones de **igualdad** y de **desigualdad**
- ❑ Las funciones **f**, **g_i** pueden ser diferenciables o no serlo
- ❑ La resolución es **más difícil y costosa** que en **optimización lineal**
- ❑ Existen **algoritmos específicos** para ciertos problemas

Clasificación (1)

□ Optimización sin restricciones

$$\min_x f(x)$$

- ✓ Es importante distinguir si f es o no continua y/o diferenciable

□ Optimización con restricciones lineales

$$\min_x f(x) \\ Ax = b$$

- ✓ Existe una extensión del algoritmo simplex para resolverlo

□ Programación cuadrática

$$\min_x c^T x + \frac{1}{2} x^T Q x \quad (Q \in \mathbb{R}^{n \times n}) \\ Ax = b$$

- ✓ Aparece en muchas situaciones. Existen algoritmos eficientes

Clasificación (2)

□ Programación convexa

$$f, g_i \text{ convexas}$$

- ✓ Todo mínimo local es global
- ✓ Si el problema es de maximización, las funciones deben ser cóncavas

□ Programación separable

$$f(x) = \sum_{j=1}^n f_j(x_j)$$
$$g_i(x) = \sum_{j=1}^n g_{ij}(x_j)$$

- ✓ Cumple la hipótesis de aditividad de la PL

Clasificación (3)

□ Programación geométrica

$$f(x), g_i(x) = \sum_{j=1}^n c_j P_j(x)$$

$$P_j(x) = x_1^{a_{j1}} x_2^{a_{j2}} \dots x_n^{a_{jn}}, \quad j = 1, \dots, n$$

✓ Problemas de diseño en ingeniería

□ Programación fraccional

$$f(x) = \frac{f_1(x)}{f_2(x)}$$

Expansión en serie de Taylor

□ Aproximación del valor de una función por un polinomio

✓ Se conoce $f(x_0)$. Se desea obtener $f(x)$

$$f(x) = f(x_0 + p) \simeq f(x_0) + \nabla f(x_0)^T p + \frac{1}{2} p^T \nabla^2 f(x_0) p$$

$$x, x_0 \in \mathbb{R}^n$$

$$p = x - x_0$$

∇f ← Gradiente de la función

$\nabla^2 f$ ← Matriz hessiana de la función

✓ Una función polinómica coincide con su polinomio de Taylor

Expansión en serie de Taylor. Ejemplo

- ❑ Obtener el polinomio de Taylor de grado 2 de $f(x, y) = e^{2x-y}$
- ❑ Calcular aproximadamente $f(0.1, -0.2)$
 - ✓ Usamos el punto $(x_0, y_0) = (0, 0) \Rightarrow p^T = (x, y) - (0, 0) = (x, y)$

$$f(x, y) = e^{2x-y} \Rightarrow f(0, 0) = 1$$

$$\nabla f(x, y) = \begin{pmatrix} f_x \\ f_y \end{pmatrix} = \begin{pmatrix} 2e^{2x-y} \\ -e^{2x-y} \end{pmatrix} \Rightarrow \nabla f(0, 0) = \begin{pmatrix} 2 \\ -1 \end{pmatrix}$$

$$\nabla^2 f(x, y) = \begin{pmatrix} f_{xx} & f_{yx} \\ f_{xy} & f_{yy} \end{pmatrix} = \begin{pmatrix} 4e^{2x-y} & -2e^{2x-y} \\ -2e^{2x-y} & e^{2x-y} \end{pmatrix} \Rightarrow \nabla^2 f(0, 0) = \begin{pmatrix} 4 & -2 \\ -2 & 1 \end{pmatrix}$$

$$f(x, y) \simeq f(0, 0) + \nabla f(0, 0)^T p + \frac{1}{2} p^T \nabla^2 f(0, 0) p =$$

$$= 1 + \begin{pmatrix} 2 & -1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} + \frac{1}{2} \begin{pmatrix} x & y \end{pmatrix} \begin{pmatrix} 4 & -2 \\ -2 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \boxed{1 + 2x - y + 2x^2 - 2xy + \frac{1}{2}y^2}$$

$$f(0.1, -0.2) \simeq 1 + 0.2 + 0.2 + 0.02 + 0.04 + 0.02 = \boxed{1.48}$$

Matrices simétricas. Menores

- ❑ Se llaman **menores** de una matriz a los determinantes de las submatrices cuadradas de la matriz
- ❑ **Menores principales** de una matriz (cuadrada): se obtienen cruzando **k** filas cualesquiera con sus respectivas columnas
 - ✓ Existen $2^n - 1$ menores principales en una matriz de orden **n**
- ❑ **Menores de esquina** de una matriz (cuadrada): se obtienen cruzando las **k** primeras filas con sus respectivas columnas
 - ✓ Existen **n** menores de esquina en una matriz de orden **n**
- ❑ La matriz cuadrada **A** (de orden **n**) es **simétrica** si $A^t = A$

Matrices definidas y semidefinidas positivas

- La matriz simétrica **A** (de orden **n**) es **semidefinida positiva** si $x^T A x \geq 0 \quad \forall x \in \mathbb{R}^n$

o bien

todos sus **autovalores** son **no negativos**

o bien

todos sus **menores principales** son **no negativos**

- La matriz simétrica **A** (de orden **n**) es **definida positiva** si

$$x^T A x > 0 \quad \forall x \in \mathbb{R}^n - \{0\}$$

o bien

todos sus **autovalores** son **positivos**

o bien

todos sus **menores de esquina** son **positivos**

Matrices definidas y semidefinidas negativas

- La matriz simétrica A (de orden n) es **semidefinida negativa** si $x^T A x \leq 0 \quad \forall x \in \mathbb{R}^n$

o bien

todos sus **autovalores** son **no positivos**

o bien

$-A$ es semidefinida positiva

- La matriz simétrica A (de orden n) es **definida negativa** si

$$x^T A x < 0 \quad \forall x \in \mathbb{R}^n - \{0\}$$

o bien

todos sus **autovalores** son **negativos**

o bien


sus menores de esquina son alternativamente <0 , >0 , etc.

o bien


$-A$ es definida positiva

Funciones convexas y cóncavas


- ❑ La función f es **convexa** en un conjunto X si
$$\forall x, y \in X, \forall \lambda \in [0, 1] \quad f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y)$$
- ❑ La función f es **cóncava** si $-f$ es convexa
- ❑ La función f es **convexa** (**cóncava**) en un punto x_0 si existe un entorno X de en el que la función es convexa (**cóncava**)



Convexa



Cóncava




Convexa

Cóncava

Funciones convexas y cóncavas. Hessiano

- ❑ La función f es **convexa** en el punto x_0 si la matriz hessiana es **semidefinida positiva** en x_0
- ❑ La función f es **cóncava** en el punto x_0 si la matriz hessiana es **semidefinida negativa** en x_0
- ❑ La **región** $f(x) \leq 0$ es **convexa** si la matriz hessiana es semidefinida positiva en todos sus puntos
- ❑ La **región** $f(x) \leq 0$ es **cóncava** si la matriz hessiana es semidefinida negativa en todos sus puntos



$$f(x, y) = x^2 - y$$

$$\nabla^2 f(x, y) = \begin{pmatrix} 2 & 0 \\ 0 & 0 \end{pmatrix}$$

Semidefinida positiva



Región convexa

Optimización sin restricciones y diferenciabilidad

- ❑ Condición **necesaria** de optimalidad (para funciones diferenciables)

$$x^* \text{ es mínimo local de } f(x) \Rightarrow \nabla f(x^*) = 0$$

- ❑ Condición **necesaria** de optimalidad (para funciones dos veces diferenciables)

$$x^* \text{ es mínimo local de } f(x) \Rightarrow \begin{cases} \nabla f(x^*) = 0 \\ \nabla^2 f(x^*) \text{ semidefinida positiva} \end{cases}$$

- ❑ Condición **suficiente** de optimalidad (para funciones dos veces diferenciables)

$$\left. \begin{array}{l} \nabla f(x^*) = 0 \\ \nabla^2 f(x^*) \text{ definida positiva} \end{array} \right\} \Rightarrow x^* \text{ es mínimo local estricto de } f(x)$$

Optimización sin restricciones y convexidad

- Condición **necesaria y suficiente** de optimalidad (para funciones **convexas** y dos veces diferenciables)

$$x^* \text{ es mínimo global de } f(x) \Leftrightarrow \nabla f(x^*) = 0$$

✓ Ejemplo: $\min f(x, y) = x^2 + 3y^2 + 2xy - 4y$

$$\nabla f(x, y) = \begin{pmatrix} 2x + 2y \\ 6y + 2x - 4 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Rightarrow (x, y) = (-1, 1)$$

$$\nabla^2 f(x, y) = \begin{pmatrix} 2 & 2 \\ 2 & 6 \end{pmatrix} \text{ definida positiva } \forall (x, y)$$

f es convexa

En **$(-1, 1)$** se alcanza el mínimo global de **f**: **$f(-1, 1) = -2$**

Optimización con restricciones. Lagrangiano (1)

- Se tiene el problema

$$\begin{aligned} \min_x f(x) \\ g_i(x) \leq 0 \quad i = 1, \dots, m \\ h_j(x) = 0 \quad j = 1, \dots, l \\ x \in X \subseteq \mathbb{R}^n \end{aligned}$$

- Su **función lagrangiana** o **lagrangiano** es:

$$L(x, \lambda, \mu) = f(x) + \sum_{i=1}^m \lambda_i g_i(x) + \sum_{j=1}^l \mu_j h_j(x)$$

- $\lambda \in \mathbb{R}^m, \mu \in \mathbb{R}^l$  **Multiplicadores de Lagrange**

- ✓ $L(x, \lambda, \mu)$ proporciona una cota inferior de $f(x)$ para $\lambda \geq 0, \mu$
- ✓ Interesa la cota inferior más ajustada $\max_{\lambda \geq 0, \mu} L(x, \lambda, \mu)$

- **Relajación lagrangiana**

$$\min_{x \in X} \left\{ \max_{\lambda \geq 0, \mu} L(x, \lambda, \mu) \right\}$$

Optimización con restricciones. Lagrangiano (2)

□ Si **todas las restricciones son de igualdad**:

- ✓ El mínimo del lagrangiano coincide con el mínimo de la función
- ✓ En el mínimo, el gradiente de la función objetivo es combinación lineal de los gradientes de las restricciones
- ✓ Los coeficientes de la c.l. son los multiplicadores

□ Para el **problema lineal**

$$\begin{array}{l} \min_x c^T x \\ Ax = b \end{array}$$

- ✓ **Lagrangiano:** $L(x, \mu) = c^T x + \mu^T (Ax - b)$
- ✓ Aplicando la condición necesaria $\nabla L(x^*, \mu^*) = 0$

$$\nabla_x L(x, \mu) = c + A^T \mu$$

$$\nabla_\mu L(x, \mu) = Ax - b$$



$$c + A^T \mu = 0 \Rightarrow c = -A^T \mu$$

$$Ax - b = 0 \Rightarrow Ax = b$$



- ✓ **Los multiplicadores son las variables duales cambiadas de signo**

Condiciones de optimalidad de KKT (1)

□ Condiciones necesarias de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad

✓ Sea el problema **P**

$$\begin{array}{l} \min_x f(x) \\ g_i(x) \leq 0 \quad i = 1, \dots, m \\ x \in X \end{array}$$

- ✓ $X \subseteq \mathbb{R}^n$ es abierto y no vacío
- ✓ Sea x^* un punto factible (verifica las restricciones)
- ✓ Sea $I = \{i / g_i(x^*) = 0\}$
- ✓ Sean $f, \{g_i, i \in I\}$ diferenciables en x^*
- ✓ Sean $\{g_i, i \notin I\}$ continuas en x^*
- ✓ Sean $\{\nabla g_i(x^*)\}_{i \in I}$ linealmente independientes

Condiciones de optimalidad de KKT (2)

□ Condiciones necesarias de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad

✓ x^* es mínimo local de $\mathbf{P} \Rightarrow$ existen escalares $\{\lambda_i, i \in I\}$ tales que

$$\begin{aligned}\nabla f(x^*) + \sum_{i \in I} \lambda_i \nabla g_i(x^*) &= 0 \\ \lambda_i &\geq 0 \quad \forall i \in I\end{aligned}$$

✓ Si además $\{g_i, i \notin I\}$ son diferenciables en x^*

$$\begin{aligned}\nabla f(x^*) + \sum_{i=1}^m \lambda_i \nabla g_i(x^*) &= 0 \\ \lambda_i g_i(x^*) &= 0 \quad i = 1, \dots, m \\ \lambda_i &\geq 0 \quad i = 1, \dots, m\end{aligned}$$

✓ Las condiciones necesarias para **máximo local** son idénticas salvo el signo de los multiplicadores: $\lambda_i \leq 0$

Condiciones de KKT. Ejemplo (1)

$$\min_{x,y} f(x,y) = 9y - (x - 5)^2$$

$$-x^2 + y \leq 0$$

$$-x - y \leq 0$$

$$x - 1 \leq 0$$

□ Condiciones de KKT 

$$\begin{cases} -2(x - 5) - 2x\lambda_1 - \lambda_2 + \lambda_3 = 0 \\ 9 + \lambda_1 - \lambda_2 = 0 \\ \lambda_1(-x^2 + y) = 0 \\ \lambda_2(-x - y) = 0 \\ \lambda_3(x - 1) = 0 \\ \lambda_1, \lambda_2, \lambda_3 \geq 0 \end{cases}$$

□ Además se deben cumplir las restricciones originales de factibilidad

$$\begin{cases} -x^2 + y \leq 0 \\ -x - y \leq 0 \\ x - 1 \leq 0 \end{cases}$$

Condiciones de KKT. Ejemplo (2)

□ Se resuelve distinguiendo para cada multiplicador que sea nulo o no

✓ $\lambda_2 = 0 \Rightarrow \lambda_1 = -9 < 0$ Imposible. Luego se tiene $\lambda_2 \neq 0$

✓ $\lambda_2 \neq 0 \Rightarrow y = -x$

• $\lambda_1 = 0 \Rightarrow \lambda_2 = 9$. Queda el sistema
$$\begin{cases} -2x + 10 - 9 + \lambda_3 = 0 \\ \lambda_3(x - 1) = 0 \end{cases}$$

■ $\lambda_3 = 0 \Rightarrow A = (1/2, -1/2), \lambda_A = (0, 9, 0)$

■ $\lambda_3 \neq 0 \Rightarrow B = (1, -1), \lambda_B = (0, 9, 1)$

• $\lambda_1 \neq 0 \Rightarrow y = x^2 \Rightarrow x^2 = -x \Rightarrow x(x + 1) = 0$

■ $x = 0 \Rightarrow y = 0 \Rightarrow C = (0, 0), \lambda_C = (1, 10, 0)$

■ $x = -1 \Rightarrow y = 1 \Rightarrow \lambda_3 = 0 \Rightarrow \lambda_1 = -3, \lambda_2 = 6$ **Imposible**

□ Se han obtenido 3 puntos KKT candidatos a mínimos:

$$A = (1/2, -1/2), \quad B = (1, -1), \quad C = (0, 0)$$

Condiciones de KKT. Ejemplo (3)

□ Análisis gráfico:

$$\nabla f(x, y) = \begin{pmatrix} 10 - 2x \\ 9 \end{pmatrix}$$

$$\nabla f(A) = \nabla f(1/2, -1/2) = \begin{pmatrix} 9 \\ 9 \end{pmatrix}$$


$$\nabla f(B) = \nabla f(1, -1) = \begin{pmatrix} 8 \\ 9 \end{pmatrix}$$

$$\nabla f(C) = \nabla f(0, 0) = \begin{pmatrix} 10 \\ 9 \end{pmatrix}$$

□ B y C son mínimos locales estrictos

□ A no es nada

□ No existe mínimo global, la función no es acotada



Condiciones de optimalidad de KKT (3)

□ Condiciones suficientes de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad

- ✓ Sea x^* un punto factible (verifica las restricciones) de **P**
- ✓ Sea $I = \{i / g_i(x^*) = 0\}$
- ✓ Sean $f, \{g_i, i \in I\}$ **convexas** y diferenciables en x^*

Si existen $\{\lambda_i, i \in I\}$ tales que

$$\begin{cases} \nabla f(x^*) + \sum_{i \in I} \lambda_i \nabla g_i(x^*) = 0 \\ \lambda_i \geq 0 \quad \forall i \in I \end{cases}$$

entonces x^* es mínimo local de **P**

Si además $f, \{g_i, i \in I\}$ son convexas y diferenciables en **todo el conjunto factible**, entonces x^* es el **mínimo global** de **P**

- Para el caso de **maximización**, la función objetivo debe ser **cóncava** y los escalares $\lambda_i \leq 0 \quad \forall i \in I$

Condiciones de optimalidad de KKT (4)

□ Condiciones suficientes de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad

- ✓ Como alternativa a la convexidad se puede usar el lagrangiano restringido

$$L(x) = f(x) + \sum_{i \in I} \lambda_i^* g_i(x)$$

- ✓ Si la matriz hessiana en el candidato x^*

$$\nabla^2 L(x^*) = \nabla^2 f(x^*) + \sum_{i \in I} \lambda_i^* \nabla^2 g_i(x^*)$$

es semidefinida positiva , entonces x^* es un mínimo local de **P**

- ✓ Si la matriz hessiana anterior es definida positiva, entonces x^* es un mínimo local estricto de **P**

Condiciones de optimalidad de KKT (5)

□ Condiciones necesarias de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad e igualdad

✓ Sea el problema **P'**

$$\begin{array}{l} \min_x f(x) \\ g_i(x) \leq 0 \quad i = 1, \dots, m \\ h_j(x) = 0 \quad j = 1, \dots, l \\ x \in X \end{array}$$

- ✓ $X \subseteq \mathbb{R}^n$ es abierto y no vacío
- ✓ Sea x^* un punto factible (verifica las restricciones)
- ✓ Sea $I = \{i / g_i(x^*) = 0\}$
- ✓ Sean $f, \{g_i, i \in I\}$ diferenciables en x^*
- ✓ Sean $\{g_i, i \notin I\}$ continuas en x^*
- ✓ Sean $\{h_j, j = 1, \dots, l\}$ continuamente diferenciables en x^*
- ✓ Sean $\{\nabla g_i(x^*), i \in I; \nabla h_j(x^*), j = 1, \dots, l\}$ l.i.

Condiciones de optimalidad de KKT (6)

□ Condiciones necesarias de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad e igualdad

✓ x^* es mínimo local de P' \Rightarrow existen escalares

$$\{\lambda_i, i \in I; \mu_j, j = 1, \dots, l\}$$

tales que

$$\nabla f(x^*) + \sum_{i \in I} \lambda_i \nabla g_i(x^*) + \sum_{j=1}^l \mu_j \nabla h_j(x^*) = 0$$

$$\lambda_i \geq 0 \quad \forall i \in I$$

✓ Si además $\{g_i, i \notin I\}$ son diferenciables en x^*

$$\nabla f(x^*) + \sum_{i=1}^m \lambda_i \nabla g_i(x^*) + \sum_{j=1}^l \mu_j \nabla h_j(x^*) = 0$$

$$\lambda_i g_i(x^*) = 0 \quad i = 1, \dots, m$$

$$\lambda_i \geq 0 \quad i = 1, \dots, m$$

Condiciones de optimalidad de KKT (7)

□ Condiciones suficientes de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad e igualdad

- ✓ Sea x^* un punto factible (verifica las restricciones) de P'
- ✓ Sea $I = \{i / g_i(x^*) = 0\}$
- ✓ Sean $f, \{g_i, i \in I\}$ **convexas** y diferenciables en x^*

Si existen escalares $\{\lambda_i, i \in I; \mu_j, j = 1, \dots, l\}$ tales que

$$\nabla f(x^*) + \sum_{i \in I} \lambda_i \nabla g_i(x^*) + \sum_{j=1}^l \mu_j \nabla h_j(x^*) = 0$$

$$\lambda_i \geq 0 \quad \forall i \in I$$

de modo que h_j sea convexa en x^* si $\mu_j > 0$

ó h_j sea cóncava en x^* si $\mu_j < 0$

entonces x^* es mínimo local de P'

Condiciones de optimalidad de KKT (8)

- Condiciones suficientes de Karush-Kuhn-Tucker para problemas con restricciones de desigualdad e igualdad

Si además, las condiciones sobre las funciones $f, \{g_i, i \in I\}, h_j$ se cumplen en **todo el conjunto factible**, entonces x^* es el **mínimo global de P'**