

# Multiplicadores de Lagrange y dualidad



# Problemas con solo restricciones de igualdad

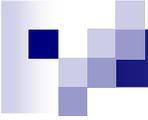
minimize  $f(x)$

subject to  $h_i(x) = 0, \quad i = 1, \dots, m$

- Sea  $x^*$  un mínimo local y regular ( $\nabla h_i(x^*)$ : son linealmente independientes), entonces existen  $\lambda_1^*, \dots, \lambda_m^*$  tales que:

$$\nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(x^*) = 0$$

- Interpretación y ejemplos.



# Problemas con restricciones de igualdad y desigualdad

$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & h(x) = 0, \quad g(x) \leq 0 \end{array}$$

donde  $f: \mathcal{R}^n \rightarrow \mathcal{R}$ ,  $h: \mathcal{R}^n \rightarrow \mathcal{R}^m$ ,  $g: \mathcal{R}^n \rightarrow \mathcal{R}^r$   
son funciones continuas diferenciables.

Asumimos que el dominio  $D = \bigcap_{i=1}^m \text{dominio}(f_i) \cap \bigcap_{i=1}^r \text{dominio}(g_i)$  es no vacío

Construimos el Lagrangiano  $L: \mathcal{R}^n \times \mathcal{R}^m \times \mathcal{R}^r \rightarrow \mathcal{R}$   
asociado al problema anterior como:

$$L(x, \lambda, \nu) = f(x) + \sum_{i=1}^m \lambda_i h_i(x) + \sum_{i=1}^r \nu_i g_i(x)$$

$\lambda_i$ : multiplicadores de Lagrange asociados con la restricción de igualdad  $i$

$\nu_i$ : multiplicadores de Lagrange asociados con la restricción de desigualdad  $i$



# La función dual de Lagrange

Es una función  $d: \mathcal{R}^m \times \mathcal{R}^r \rightarrow \mathcal{R}$

$$d(\lambda, \nu) = \inf_x L(x, \lambda, \nu) = \inf_x \left( f(x) + \sum_{i=1}^m \lambda_i h_i(x) + \sum_{i=1}^r \nu_i g_i(x) \right)$$

como  $d(\lambda, \nu)$  es el mínimo puntual de una familia de funciones lineales de  $(\lambda, \nu)$  es una función cóncava aún cuando el problema no sea convexo.

# Cota inferior del óptimo

Para todo  $(\lambda, \nu \geq 0)$ , sea  $p^*$  el valor óptimo del problema de optimización entonces,

$$d(\lambda, \nu) \leq p^*$$

Si  $\bar{x}$  es un punto factible del problema de optimización, entonces:

$$\left( \sum_{i=1}^m \lambda_i h_i(\bar{x}) + \sum_{i=1}^r \nu_i g_i(\bar{x}) \right) \leq 0$$

por lo tanto

$$L(\bar{x}, \lambda, \nu) \leq f(\bar{x})$$



por lo tanto:

$d(\lambda, \nu) \leq f(\bar{x})$ , como vale para cualquier punto factible vale para el óptimo

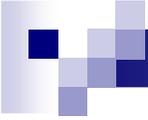
$$d(\lambda, \nu) \leq p^*$$

$$\text{Dominio}(g) = \{ \lambda, \nu : d(\lambda, \nu) > -\infty \}$$

$\lambda, \nu$  son factibles del dual si  $\nu \geq 0, \lambda, \nu \in \text{Dom}(d)$



El Lagrangiano y la cota inferior se pueden interpretar como una linealización de la función indicatriz de las restricciones



# El problema dual de Lagrange

- ¿Cuál es la mejor cota inferior que puede ser obtenida a través de la función dual de Lagrange?

maximizar  $d(\lambda, \nu)$

*sujeto*  $\nu \geq 0$

a los valores óptimos  $(\lambda^*, \nu^*)$  se los llama óptimos del dual o multiplicadores de Lagrange óptimos.

Este problema es siempre un problema de optimización convexa



## Dualidad débil

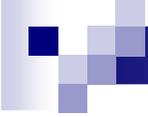
- Esta propiedad se deduce de la cota inferior vista antes

Si llamamos  $d^*$  al óptimo del problema dual

$$d^* \leq p^* \text{ (dualidad débil)}$$

habitualmente se denomina a  $p^* - d^*$  como la diferencia (gap) de dualidad.

Esta diferencia es siempre positiva.



# Dualidad fuerte. Teorema de Slater

- La pregunta es cuando ¿ $d^*$  será igual a  $p^*$ ?
- Esto en general no es cierto pero si el problema es convexo con restricciones convexas, habitualmente (pero no siempre) se tiene dualidad fuerte.
- Lo que establece el teorema de Slater es una condición adicional a la convexidad para que se verifique la dualidad fuerte. Hay otros resultados.



## Slater. Dualidad fuerte

- Se considera el siguiente problema convexo ( $f_0, f_i$  convexas,  $h_i$  funciones lineales)

$$\begin{array}{ll} \text{minimize} & f_0(x) \\ \text{subject to} & f_i(x) \leq 0, \quad i = 1, \dots, m \\ & h_i(x) = 0, \quad i = 1, \dots, p \end{array}$$

- La condición de Slater para que en un problema convexo sea válida la dualidad fuerte es que

Exista  $x$  un punto del dominio  $D$  tal que verifique:

$$f_i(x) < 0 \quad i = 1, \dots, m \quad \text{y} \quad h_i(x) = 0$$



# Ejemplos de dualidad

$$f(x) = 1/2(x_1^2 + x_2^2)$$

*s.t.*

$$g(x) = x_1 - 1 \leq 0,$$

$$x \in X = \mathbb{R}^2$$

Optimización discreta:

$$f(x) = -x$$

$$g(x) = x - 1/2 \leq 0$$

$$x \in X = \{0, 1\}$$

Optimización sobre un simplex:

$$\min f(x)$$

$$\sum_{i=1}^n x_i = r$$

$$x_i \geq 0$$



# Interpretación de la dualidad y los multiplicadores de Lagrange

- Interpretación económica.

# Condiciones de optimalidad

- Complementariedad de la relajación
- Cuando existe dualidad fuerte:

$$\begin{aligned} f_0(x^*) &= g(\lambda^*, \nu^*) \\ &= \inf_x \left( f_0(x) + \sum_{i=1}^m \lambda_i^* f_i(x) + \sum_{i=1}^p \nu_i^* h_i(x) \right) \\ &\leq f_0(x^*) + \sum_{i=1}^m \lambda_i^* f_i(x^*) + \sum_{i=1}^p \nu_i^* h_i(x^*) \\ &\leq f_0(x^*). \end{aligned}$$

$$f_0(x^*) = f_0(x^*) + \sum_{i=1}^m \lambda_i^* f_i(x^*) + \sum_{i=1}^p \nu_i^* h_i(x^*)$$

# Complementariedad de la relajación

- Lo cual implica:  $\sum_{i=1}^m \lambda_i^* f_i(x^*) = 0$
- Como cada término es no-positivo, se tiene la propiedad:

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

- Lo que es equivalente a:  
$$\lambda_i^* > 0 \implies f_i(x^*) = 0,$$
$$f_i(x^*) < 0 \implies \lambda_i^* = 0.$$
- Si el multiplicador de Lagrange es 0, la restricción puede estar activa (no es biyectivo)

$$\lambda_i^* = 0 \not\leftrightarrow f_i(x^*) < 0 \quad f_i(x^*) = 0 \not\leftrightarrow \lambda_i^* > 0$$

# Condiciones Karush-Kuhn-Tucker (KKT) para el caso no convexo.

- Asumiendo que hay dualidad fuerte y que las  $f_0, f_i, h_i$  son diferenciables, como  $x^*$  minimizes  $L(x, \lambda^*, \nu^*)$  el gradiente debe ser 0 en  $x^*$

$$\nabla f_0(x^*) + \sum_{i=1}^m \lambda_i^* \nabla f_i(x^*) + \sum_{i=1}^p \nu_i^* \nabla h_i(x^*) = 0.$$

- Por lo tanto juntando todo lo visto se tienen las siguientes condiciones necesarias de optimalidad

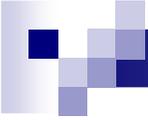
$$f_i(x^*) \leq 0, \quad i = 1, \dots, m$$

$$h_i(x^*) = 0, \quad i = 1, \dots, p$$

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

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

$$\nabla f_0(x^*) + \sum_{i=1}^m \lambda_i^* \nabla f_i(x^*) + \sum_{i=1}^p \nu_i^* \nabla h_i(x^*) = 0,$$



# Condiciones KKT (caso convexo)

- En este caso también son suficientes para que sean el óptimo del primal y el dual sin diferencia de dualidad.

$$\begin{aligned} f_i(\tilde{x}) &\leq 0, & i = 1, \dots, m \\ h_i(\tilde{x}) &= 0, & i = 1, \dots, p \\ \tilde{\lambda}_i &\geq 0, & i = 1, \dots, m \\ \tilde{\lambda}_i f_i(\tilde{x}) &= 0, & i = 1, \dots, m \\ \nabla f_0(\tilde{x}) + \sum_{i=1}^m \tilde{\lambda}_i \nabla f_i(\tilde{x}) + \sum_{i=1}^p \tilde{\nu}_i \nabla h_i(\tilde{x}) &= 0, \end{aligned}$$

- Ejemplos

# Análisis de sensibilidad

Consideramos el problema:


$$\begin{array}{ll} \text{minimize} & f_0(x) \\ \text{subject to} & f_i(x) \leq u_i, \quad i = 1, \dots, m \\ & h_i(x) = v_i, \quad i = 1, \dots, p, \end{array}$$

Si  $p^*(u, v)$  es la solución óptima del problema perturbado, es decir:

$$p^*(u, v) = \inf \{ f_0(x) \mid \exists x \in \mathcal{D}, f_i(x) \leq u_i, i = 1, \dots, m, h_i(x) = v_i, i = 1, \dots, p \}.$$

Si  $p^*(u, v)$  es diferenciable en  $(0, 0)$  y existe dualidad fuerte, entonces las variables duales óptimas  $\lambda^*, \nu^*$  cumplen que

$$\lambda_i^* = -\frac{\partial p^*(0, 0)}{\partial u_i}, \quad \nu_i^* = -\frac{\partial p^*(0, 0)}{\partial v_i}$$





## Idea general de los métodos de barrera.

$$\begin{array}{ll} \text{minimize} & f_0(x) \\ \text{subject to} & f_i(x) \leq 0, \quad i = 1, \dots, m \\ & Ax = b, \end{array}$$


- Aproximar las restricciones por una función barrera (una aproximación de la indicatriz)

$$\begin{array}{ll} \text{minimize} & f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ \text{subject to} & Ax = b, \end{array}$$

$$I_-(u) = \begin{cases} 0 & u \leq 0 \\ \infty & u > 0 \end{cases}$$

# Idea general de los métodos de barrera.

$$\begin{array}{ll} \text{minimize} & f_0(x) - (1/t) \sum_{i=1}^m \log(-f_i(x)) \\ \text{subject to} & Ax = b \end{array}$$



- A medida que  $t$  se hace más grande la aproximación mejora.