



*Teoría y Algoritmia de Optimización*



*Métodos de Lagrange*



# Agenda

- Teorema de Lagrange: Condiciones necesarias
- El Lagrangeano
- Condiciones suficientes de optimalidad
- Análisis de sensibilidad
- Métodos basados en el Lagrangeano

*“Liberté, égalité, optimalité” - Joseph-Louis Lagrange  
También conocido como Giuseppe Lodovico Lagrangia*





*El Lagrangeano y las restricciones de igualdad*

 Geometría de problemas con restricciones de igualdad

$$\min_x f(x)$$

$$\text{sujeto a } h(x) = 0$$

*espacio reservado para dibujo: curvas de nivel*



# Direcciones de variación factibles

$$\min_x f(x)$$

$$\text{sujeto a } h(x) = 0$$

- $h(x)$  diferenciable

$$\{d : \nabla h(x^*)^T d = 0\}$$

*espacio reservado para dibujo: direcciones factibles*



## Optimalidad y direcciones factibles

$$\min_x f(x)$$

sujeto a  $h(x) = 0$

$x^*$  óptimo,  $f(\cdot)$  diferenciable,  $d$  dirección factible:

$$f(x^* + d) - f(x^*) = \nabla f(x^*)^T d + o(d) \rightarrow 0$$

En el límite:  $\nabla f(x^*)^T d = 0$



## Intuición, en resumen

1.  $h(\cdot)$  dif.,  $d$  dir. factible:  $\nabla h(x^*)^T d = 0$
2.  $x^*$  óptimo,  $f(\cdot)$  dif.,  $d$  dir. factible:  $\nabla f(x^*)^T d = 0$
3. Combinando 1 y 2:  $\nabla h(x^*) \parallel \nabla f(x^*)$

$$\exists \lambda^* : \nabla f(x^*) + \lambda^* \nabla h(x^*) = 0$$





# Intuición, en resumen

*espacio reservado para dibujo: intuición, en resumen*

$$\exists \lambda^* : \nabla f(x^*) + \lambda^* \nabla h(x^*) = 0$$



# Regularidad - Regularité

*espacio reservado para dibujo: regularidad*

$$\{\nabla h_i(x^*) : i = 1, \dots, m\} \text{ l.i.} \quad \exists \lambda : \nabla f(x) + \sum_{i=1}^m \lambda_i \nabla h_i(x) = 0$$



# Condiciones de segundo orden

*espacio reservado para dibujo: segundo orden*

$$d^T \left[ \nabla^2 f(x) + \sum_{i=1}^m \lambda_i \nabla^2 h_i(x) \right] d \geq 0 \quad \forall d : \nabla h_i(x^*)^T d = 0, i = 1, \dots, m$$



*Condiciones Necesarias de Optimalidad*



# Condiciones necesarias de optimalidad

## Primer orden

Si se cumple:

- $x^*$  es mínimo local
- $h(x)$  y  $f(x)$  diferenciables
- $\{\nabla h_i(x^*) : i = 1, \dots, m\}$  l.i.

Entonces:

- $\exists! \lambda : \nabla f(x) + \sum_{i=1}^m \lambda_i \nabla h_i(x) = 0$

## Segundo orden

Si además:

- $h(x)$  y  $f(x)$  doblemente dif.

Entonces:

$$d^T \left[ \nabla^2 f(x) + \sum_{i=1}^m \lambda_i \nabla^2 h_i(x) \right] d \geq 0$$

$$\forall d : \nabla h_i(x^*)^T d = 0, i = 1, \dots, m$$



## Condiciones necesarias: demostración

### Técnica

1. Aproximamos problema original **con restricciones**
2. Por sucesión de problemas auxiliares **sin restricciones**
3. Estudiamos **sucesión de soluciones**  $\{x^k\}$  **del problema auxiliar**
4. Comparamos las condiciones opt. de  $x^*$  y  $\{x^k\}$  en el límite



## Condiciones necesarias: paso 1: problema auxiliar

Por **hipótesis**:

$$x^* = \arg \min_x f(x) \text{ s.a. } h(x) = 0$$

Función de costo **auxiliar**:

$$F^k(x) = f(x) + \frac{k}{2} \|h(x)\|_2^2 + \frac{\alpha}{2} \|x - x^*\|_2^2$$

Definimos la bola:

$$S = \{x : \|x - x^*\|_2 \leq \epsilon\}$$

Definimos:

$$x^k = \arg \min_x F^k(x) \text{ s.a. } x \in S$$

*espacio reservado para dibujo*

## 道 Condiciones necesarias: paso 2: límites

Como  $x^k = \arg \min_x F^k(x)$  s.a.  $x \in S$ , se cumple:

$$F^k(x^k) = f(x^k) + \frac{k}{2} \|h(x^k)\|_2^2 + \frac{\alpha}{2} \|x^k - x^*\|_2^2 \leq F^k(x^*) = f(x^*)$$

Como  $f(x^*)$  es **acotada** en  $S$ :

$$\lim_k \|h(x^k)\| = 0$$

Por tanto, todo punto límite  $\bar{x}$  de  $\{x^k\}$  cumple  $h(\bar{x}) = 0$





## Condiciones necesarias: paso 2

Como  $x^k = \arg \min F^k(x)$  s.a  $x \in S$ , se cumple:

$$F^k(x^k) = f(x^k) + \frac{k}{2} \|h(x^k)\|_2^2 + \frac{\alpha}{2} \|x^k - x^*\|_2^2 \leq F^k(x^*) = f(x^*)$$

En particular

$$f(x^k) + \frac{\alpha}{2} \|x^k - x^*\|_2^2 \leq F^k(x^*) = f(x^*)$$

En el límite  $k \rightarrow \infty$

$$f(\bar{x}) + \frac{\alpha}{2} \|\bar{x} - x^*\|_2^2 \leq f(x^*)$$

## 道 Condiciones necesarias: paso 2

De lo anterior, tenemos **i)**  $f(\bar{x}) + \frac{\alpha}{2} \|\bar{x} - x^*\|_2^2 \leq f(x^*)$

Como  $h(\bar{x}) = 0$ ,  $\bar{x}$  es **factible**, y  $\bar{x} \in S$  tenemos que **ii)**  $f(x^*) \leq f(\bar{x})$

De **(i)** y **(ii)**:  $f(x^*) = f(\bar{x}) \Rightarrow \|x^* - \bar{x}\| = 0 \Rightarrow x^* = \bar{x}$

Entonces, efectivamente vemos que  $\{x^k\}$  **converge a**  $x^*$

Entonces  $x^k$  pertenece al **interior de**  $S$  para  $k$  suficientemente grande

O sea que  $x^k$  (a partir de cierto  $k$ ) es solución del problema **sin restricciones**:

$$\min_x F^k(x)$$



## Condiciones necesarias: paso 2: resumen

- Obtuvimos sucesión  $\{x^k\}$  que converge a  $x^*$
- A partir de cierto  $k$ ,  $x^k$  es solución del problema **sin restricciones**:  $\min_x F^k(x)$
- Ahora podemos analizar las condiciones de optimalidad **sin restricciones** de  $x^k$
- Como  $x^k$  converge a  $x^*$ , eso nos dará las condiciones del problema original **con restricciones**

*espacio reservado para dibujo*

## 道 Condiciones necesarias: paso 3

De la optimalidad de  $x^k$  tenemos **(i)**:

$$0 = \nabla F^k(x^k) = \nabla f(x^k) + \nabla h(x^k)kh(x^k) + \alpha(x^k - x^*)$$

Nuestro objetivo es llegar a **(ii)**:

$$0 = \nabla f(x^*) + \nabla h(x^*)\lambda^*$$

Cómo vamos de **(i)** a **(ii)**?

- En el límite de  $k$ , el último término ya vimos que va a 0
- Lo que resta es mostrar que:  $\lambda^* = kh(x^*)$



## Condiciones necesarias: paso 3

Vamos a despejar  $\lambda^* = kh(x^*)$

$$\nabla f(x^k) + \nabla h(x^k)kh(x^k) + \alpha(x^k - x^*) = 0$$

$$\nabla h(x^k)^T [\nabla f(x^k) + \nabla h(x^k)kh(x^k) + \alpha(x^k - x^*)] = 0$$

$$\nabla h(x^k)^T \nabla h(x^k)kh(x^k) = -\nabla h(x^k)^T [\nabla f(x^k) + \alpha(x^k - x^*)]$$



## Condiciones necesarias: paso 3

Teníamos

$$\nabla h(x^k)^T \nabla h(x^k) kh(x^k) = -\nabla h(x^k)^T [\nabla f(x^k) + \alpha(x^k - x^*)]$$

Como  $x^*$  es **regular**,  $\nabla h(x^*)$  tiene rango  $m$

Por continuidad,  $\nabla h(x^k)$  también tiene rango  $m$  para  $k$  suf. grande

Entonces  $\nabla h(x^k)^T \nabla h(x^k)$  es **invertible**, por lo que podemos despejar:

$$kh(x^k) = - [\nabla h(x^k)^T \nabla h(x^k)]^{-1} \nabla h(x^k)^T [\nabla f(x^k) + \alpha(x^k - x^*)]$$



## Condiciones necesarias: primer orden

Tomando el límite en  $k$  y definiendo  $\lambda^* = kh(x^*)$  llegamos a que:

$$\lambda^* = - [\nabla h(x^*)^T \nabla h(x^*)]^{-1} \nabla h(x^*)^T \nabla f(x^*)$$

Lo que prueba la condición necesaria de primer orden:

$$\exists! \lambda^* : \nabla f(x^*) + \lambda^{*T} \nabla h(x^*)$$

Nos queda ver las condiciones de segundo orden...



## Condiciones necesarias: segundo orden

- Ya vimos que, para  $k$  suficientemente grande,  $x^k$  es un mínimo local del problema **sin restricciones**:  $\min_x F^k(x)$
- Entonces, en esas condiciones, cumple las condiciones de segundo orden:

$$d^T \nabla^2 F^k(x^k) d \geq 0, \forall d$$

- Desarrollando la Hessiana, tenemos que, para cualquier  $d$ :

$$d^T \left[ \nabla^2 f^k(x^k) + \sum_{i=1}^m h_i(x^k) \nabla^2 h_i(x^k) + \alpha I \right] d \geq 0, \forall d$$





## Condiciones necesarias: segundo orden

- Tenemos que:  $d^T \left[ \nabla^2 f^k(\mathbf{x}^k) + \sum_{i=1}^m h_i(\mathbf{x}^k) \nabla^2 h_i(\mathbf{x}^k) + \alpha I \right] d \geq 0, \forall d$

- En particular, se cumple para:

$$d^T \left[ \nabla^2 f^k(\mathbf{x}^k) + \sum_{i=1}^m h_i(\mathbf{x}^k) \nabla^2 h_i(\mathbf{x}^k) + \alpha I \right] d \geq 0, \forall \{d : \nabla h(\mathbf{x}^k) d = 0\}$$

- Llevando  $k$  al límite, tenemos: i)  $\mathbf{x}^k \rightarrow \mathbf{x}^*$ , y ii)  $\lambda_i(\mathbf{x}^k) \rightarrow \lambda_i^*$ , o sea:

$$d^T \left[ \nabla^2 f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla^2 h_i(\mathbf{x}^*) + \alpha I \right] d \geq 0, \forall \{d : \nabla h(\mathbf{x}^*) d = 0\}$$



## Condiciones necesarias: segundo orden

- Tomando  $\alpha \rightarrow 0$  (algo que podemos hacer sin problemas) llegamos a la condición de segundo orden que queríamos demostrar:

$$d^T \left[ \nabla^2 f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla^2 h_i(x^*) \right] d \geq 0, \forall \{d : \nabla h(x^*)d = 0\}$$



*El Lagrangeano*



# El Lagrangeano

$$L(x, \lambda) = f(x) + \lambda h(x)$$

*Aplicaciones:*

1. Análisis de condiciones de optimalidad
2. Análisis de sensibilidad
3. Algoritmos de optimización
4. Dualidad



## El Lagrangeano: caso general

$$x^* = \arg \min_x f(x)$$

s. a.

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

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



## Lagrangiano y Condiciones necesarias

$$x^* = \arg \min_x f(x)$$

s. a.

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

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



## El Lagrangeano y condiciones necesarias

$$x^* = \arg \min_x f(x)$$

s. a.

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

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

$$i) \nabla_x L(x^*, \lambda^*) = 0$$

$$iii) d^T \nabla_{xx}^2 L(x^*, \lambda^*) d \geq 0$$

$$ii) \nabla_\lambda L(x^*, \lambda^*) = 0$$

$$\forall d : \nabla h_i(x^*)^T d = 0, \forall i$$



## El Lagrangeano y condiciones necesarias

### Observación:

$(x^*, \lambda^*)$  cumple con las condiciones necesarias del problema:

$$\min_{(x, \lambda)} L(x, \lambda) \text{ s.a. } h(x) = 0$$





*Condiciones Suficientes de Optimalidad*



## Condiciones suficientes de optimalidad

$$x^* = \arg \min_x f(x)$$

s. a.

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

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

$$i) \nabla_x L(x^*, \lambda^*) = 0$$

$$iii) d^T \nabla_{xx}^2 L(x^*, \lambda^*) d > 0$$

$$ii) \nabla_\lambda L(x^*, \lambda^*) = 0$$

$$\forall d \neq 0 : \nabla h(x^*)^T d = 0$$

**Nota:** No es necesario exigir **regularidad!**



## Condiciones suficientes: demostración

La **técnica** es muy similar a la que usamos para el caso de condiciones necesarias:

- Definimos una función auxiliar con **penalizaciones**
  - Se penaliza fuertemente alejarse de la restricción:  $h(x) = 0$
- Analizamos las condiciones suficientes de optimalidad de la función auxiliar en el caso **sin restricciones**
- Con la elección apropiada de parámetros, veremos que esas condiciones implican también la optimalidad para el problema objetivo **con restricciones**



## Condiciones suficientes: lema auxiliar

- Al igual que en el teorema anterior, necesitamos soluciones **únicas**
- Por eso, necesitamos construir un problema **estrictamente convexo**
- El siguiente resultado nos muestra cómo hacerlo (no lo vamos a demostrar)

Lema de la “positividad definida complementaria”

$$\left. \begin{array}{l} P = P^T, Q = Q^T, Q \succcurlyeq 0 \\ x^T P x > 0, \forall x : x^T Q x = 0 \end{array} \right\} \Rightarrow \exists c : P + cQ \succ 0$$



“Positividad definida complementaria”

*espacio reservado para dibujo: positividad complementaria*



# El Lagrangeano aumentado


El Lagrangeano Aumentado es la función:

$$L_c(x, \lambda) = f(x) + \lambda^T h(x) + \frac{c}{2} \|h(x)\|_2^2$$

Es el Lagrangeano del **problema**

$$\min f(x) + \frac{c}{2} \|h(x)\|_2^2 \text{ s.a. } h(x) = 0$$

(el valor de **c** es el que nos va a dar la positividad complementaria más adelante)





## *Demostración (1)*

**Primera observación: el problema auxiliar**

$$\min f(x) + \frac{c}{2} \|h(x)\|_2^2 \text{ s.a. } h(x) = 0$$

es (trivialmente) equivalente al **problema original**:

$$\min f(x) \text{ s.a. } h(x) = 0$$



## Demostración (2)

- Gradiente de  $L_c(x, \lambda)$ :

$$\nabla_x L_c(x, \lambda) = \nabla f(x) + \nabla h(x)[\lambda + ch(x)]$$

- Por hipótesis tenemos que i)  $h(x^*) = 0$  y ii)  $\nabla_x L(x^*, \lambda^*) = 0$
- Sustituyendo en el gradiente:

$$\nabla_x L_c(x^*, \lambda^*) = \nabla f(x^*) + \nabla h(x^*)^T \lambda^* = \nabla_x L(x^*, \lambda^*) = 0$$





## Demostración (3)

- Hessiana de  $L_c(x, \lambda)$  :

$$\nabla_{xx}^2 L_c(x, \lambda) = \nabla^2 f(x) + \sum_{i=1}^m (\lambda_i + c h_i(x)) \nabla^2 h(x) + c \nabla h(x) \nabla h(x)^T$$

- Por hipótesis tenemos que i)  $h(x^*) = 0$  y ii)  $\nabla_x L(x^*, \lambda^*) = 0$ . Sustituyendo:

$$\nabla_{xx}^2 L_c(x^*, \lambda^*) = \nabla^2 f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla^2 h(x^*) + c \nabla h(x^*) \nabla h(x^*)^T$$

$$\nabla_{xx}^2 L_c(x^*, \lambda^*) = \nabla_{xx}^2 L(x^*, \lambda^*) + c \nabla h(x^*) \nabla h(x^*)^T$$



## *Demostración (24)*

Sigamos con la Hessiana. Llegamos a que:

$$\nabla_{xx}^2 L_c(x^*, \lambda^*) = \nabla_{xx}^2 L(x^*, \lambda^*) + c \nabla h(x^*) \nabla h(x^*)^T$$

También por hipótesis, tenemos que:

$$d^T \nabla_{xx}^2 L(x^*, \lambda^*) d > 0 \quad \forall d \neq 0 : h(x^*)^T d = 0$$

O lo que es lo mismo:

$$d^T \nabla_{xx}^2 L(x^*, \lambda^*) d > 0 \quad \forall d \neq 0 : d^T \nabla h(x^*) \nabla h(x^*)^T d = 0$$



## Demostración (5)

Siguiendo con la Hessiana, ahora tenemos:

$$\nabla_{xx}^2 L_c(x^*, \lambda^*) = \nabla_{xx}^2 L(x^*, \lambda^*) + c \nabla h(x^*) \nabla h(x^*)^T$$

$$d^T \nabla_{xx}^2 L(x^*, \lambda^*) d > 0 \quad \forall d \neq 0 : d^T \nabla h(x^*) \nabla h(x^*)^T d = 0$$

Identificando:

$$P = \nabla_{xx}^2 L(x^*, \lambda^*), \quad Q = \nabla h(x^*) \nabla h(x^*)^T$$

Estamos en las condiciones del lema de “positividad definida complementaria”:

$$\exists c_0 : \nabla_{xx}^2 L_c(x^*, \lambda^*) \succ 0, \quad \forall c > c_0$$



## Demostración (6)

Llegamos a que:

$$L_c(x) \geq L_c(x^*) + \frac{\gamma}{2} \|x - x^*\|_2^2, \quad \forall x : \|x - x^*\| \leq \epsilon$$

Nuevamente, por hipótesis:  $h(x^*) = 0 \Rightarrow L_c(x^*, \lambda^*) = f(x^*)$

De esas dos cosas, es inmediato que:

$$f(x) \geq f(x^*) + \frac{\gamma}{2} \|x - x^*\|_2^2, \quad \forall x : h(x) = 0 \text{ y } \|x - x^*\| \leq \epsilon$$

O sea,  $x^*$  es un mínimo local estricto del problema original **con restricciones**.



*Análisis de Sensibilidad*



*Condiciones de desigualdad*



## Condiciones de desigualdad

Vamos a estudiar la optimalidad de problemas del tipo

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \\ & g_1(x) \leq 0, g_2(x) \leq 0, \dots, g_r(x) \leq 0 \end{array}$$

Nuevamente, la estrategia será reducir este escenario a un caso que ya conocemos, el de restricciones de igualdad.



## El conjunto de restricciones activas (active set)

Para un punto factible cualquiera  $x$ , el *active set* se define como:

$$A(x) = \{j : g_j(x) = 0\}$$

*espacio reservado para dibujo: active set*





## Restricciones activas y optimalidad

### Definición

Si  $j \notin A(x)$  decimos que la restricción  $g_j(x)$  está *inactiva*

### Observación

Si  $x^*$  es un mínimo local, entonces:

- Las restricciones inactivas *no importan* (es como si no existieran)
- Las restricciones activas son como **restricciones de igualdad**



## Restricciones activas y optimalidad

Si  $x^*$  es un mínimo local, entonces:

- Las restricciones inactivas *no importan* (**es como si no existieran**)
- Las restricciones activas son como **restricciones de igualdad**

Observación:  $x^*$  también es mínimo local del problema:

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \\ & g_j(x) = 0, j \in A(x^*) \end{array}$$



## Restricciones activas y optimalidad

Si  $x^*$  es un mínimo local y es además es regular de:

$$\begin{aligned} &\text{minimizar} && f(x) \\ &\text{sujeto a} && h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \\ &&& g_j(x) = 0, j \in A(x^*) \end{aligned}$$

Entonces cumple las condiciones de optimalidad de Lagrange, es decir,

existen  $\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*, \mu_j^*, j \in A(x^*)$  tales que:

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



## Hacia las condiciones de optimalidad

Si  $x^*$  es un mínimo local y es además es regular, tenemos que

existen  $\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*, \mu_j^*, j \in A(x^*)$  tales que:

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

Ahora definimos  $\mu_j^* = 0, j \notin A(x^*)$ , lo que nos permite expresar lo anterior como:

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



# Hacia las condiciones de optimalidad

**Importante:**  $\mu_j^* \geq 0$

*espacio reservado para dibujo: no negatividad de los  $\mu$*



# Condiciones de Karush-Kuhn-Tucker (KKT)

Sea  $x^*$  min. local regular del problema:

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \\ & g_1(x) \leq 0, g_2(x) \leq 0, \dots, g_r(x) \leq 0 \end{array}$$

Entonces existen  $\lambda^* = (\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*)$ ,  $\mu^* = (\mu_1^*, \mu_2^*, \dots, \mu_r^*)$  tales que

$$\begin{array}{ll} \nabla_x L(x^*, \lambda^*, \mu^*) = 0 & \mu_j^* \geq 0, \quad j \in A(x^*) \\ & \mu_j^* = 0, \quad j \notin A(x^*) \end{array}$$

Si, además,  $f, g, h$  son  $C^2$ , entonces se cumple

$$d^T \nabla^2 L(x^*, \lambda^*, \mu^*) d \geq 0, \quad \forall d : \begin{cases} \nabla h_i(x^*)^T d = 0, & \forall i \\ \nabla g_j(x^*)^T d = 0, & \forall j \in A(x^*) \end{cases}$$



## Conversión de desigualdad en igualdad

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \\ & g_1(x) \leq 0, g_2(x) \leq 0, \dots, g_r(x) \leq 0 \end{array}$$

Introducimos variables auxiliares  $z_1, z_2, \dots, z_r$ :

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \\ & g_1(x) + z_1^2 = 0, g_2(x) + z_2^2 = 0, \dots, g_r(x) + z_r^2 = 0 \end{array}$$



## Conversión de igualdad en desigualdad

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \end{array}$$

Lo podemos reescribir como:

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & h_1(x) \leq 0, h_2(x) \leq 0, \dots, h_m(x) \leq 0 \\ & -h_1(x) \leq 0, -h_2(x) \leq 0, \dots, -h_m(x) \leq 0 \end{array}$$



## *Comentarios finales sobre condiciones de optimalidad*

- La mayor limitante del método de Lagrange es la exigencia de **regularidad**
- Existen numerosos resultados (desde 1948 en adelante) que definen condiciones similares a las de Lagrange para casos particulares de problemas no regulares.
- No vamos a entrar en esos casos; el lector interesado puede recurrir al libro del curso (Bertsekas, Sección 3.3.3 en adelante).



*Métodos de Optimización basados en el Lagrangeano*



## Métodos de Multiplicadores de Lagrange

- Vimos que podemos *caracterizar* el óptimo de un problema **con restricciones...**
- ... como el límite de una secuencia de problemas **sin restricciones**
- ¿Podemos usar esa misma idea para *hallar* ese óptimo?
- Concretamente: ¿podemos obtener el óptimo del problema con restricciones...
- ... como el límite de una secuencia de óptimos de problemas sin restricciones?

Spoiler: *si estamos en este slide, obviamente es porque la respuesta es sí*



# *Métodos basados en los multiplicadores de Lagrange*

## **Tres tipos**

- Métodos de barrera / punto interior
- Métodos de penalización (cuadrática)
- Método de los multiplicadores

## **Dos variantes**

- Métodos exactos
- Métodos inexactos



*Métodos de barrera*



## *Métodos de punto interior*

### **Idea**

- Se aplican a problemas con restricciones de **desigualdad**
- Obtener una secuencia de soluciones que convergen a la solución
- Los puntos de la secuencia son **interiores** al conjunto factible



## Métodos de barrera

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeto a} & g_1(x) \leq 0, g_2(x) \leq 0, \dots, g_r(x) \leq 0 \end{array}$$

Resolvemos secuencia de problemas:

$$\text{minimizar } f(x) + \epsilon^k B_i(x)$$

Donde  $0 < \epsilon^k < \epsilon^{k+1}$  y la *función de barrera*  $B_i(x)$  es tal que

$$B_i(x) \rightarrow \infty \text{ cuando } g_i(x) \rightarrow 0^-$$

$$\text{Ejemplos más comunes: } B_i(x) = -\log(-g_i(x)) \quad B_i(x) = -1/g_i(x)$$



# Métodos de punto interior

## Intuición

*espacio reservado para dibujo: métodos de barrera*





## Método de barrera: aspectos prácticos

- Bastante fácil de implementar

- **Warm-restarts:**

- Usar solución del paso  $k$  como punto inicial para el paso  $k+1$ !
- Clave para la eficiencia!
- Esto se aplica a todos los métodos que siguen (y a muchos otros)

- Al igual que otros métodos de penalización, puede sufrir de problemas de estabilidad numérica en los bordes



*Método de penalización cuadrática*



# Métodos de penalización

## Idea

- Se aplican a problemas con restricciones de **igualdad**
- Obtener una secuencia de soluciones que convergen a la solución
- Se sustituye la restricción por un término que penaliza su violación
- Cada nuevo problema hace pesar más la violación de la restricción



# Método de penalización cuadrática exacto

## Intuición

- Para  $c$  muy grande, el valor de  $h(x)$  en  $L_c(x, \lambda) = f(x) + \lambda^T h(x) + \frac{c}{2} \|h(x)\|_2^2$  va a tener un peso relativo muy grande
- Entonces, el mínimo global  $x_c = \arg \min_x L_c(x, \lambda)$  va a estar muy cerca de  $x^* = \arg \min_x f(x, \lambda)$  s.a.  $h(x) = 0$  para *cualquier* valor de  $\lambda$
- De hecho, se puede usar  $\lambda = 0$ 
  - (en sus orígenes (1960s), sólo se usaba  $\lambda = 0$ )



# Método de penalización cuadrática exacto

## Pseudocódigo

1. Resolver  $x_k = \arg \min_x L_{c^k}(x, \lambda^k)$  para  $L_c(x, \lambda) = f(x) + \lambda^T h(x) + \frac{c}{2} \|h(x)\|_2^2$
2. Verificar condiciones de optimalidad (KKT)
  - a. Se cumplen: terminar
  - b. No se cumplen: incrementar  $k$ ; aumentar  $c^k$ ; volver a paso 1



# Métodos de penalización

## Aspectos prácticos

- Muy fácil de implementar
- Mal condicionado cuando  $c$  se hace muy grande



## Método de penalización cuadrática *inexacto*

- El método de penalización cuadrática exacto converge a un óptimo local del problema original
- La demostración es muy simple
- Sin embargo, en la práctica, lo más común es se llegar a un  $x_k$  que cumple

$$\|\nabla_x L_{c^k}(x^k, \lambda^k)\| \leq \epsilon^k$$

- Veremos que, también en este caso, se llega al óptimo del problema original
  - (en el límite, por supuesto).



# Convergencia del método de penalización *inexacto*

## Si se cumple

- $f(\cdot)$  y  $g(\cdot)$   $C^2$
- $\|\nabla_x L_{c^k}(x^k, \lambda^k)\| \leq \epsilon^k$  donde:
  - $\{\lambda^k\}$  es acotada
  - $0 < c^k < c^{k+1}$   $c^k \rightarrow \infty$
  - $\epsilon^k \rightarrow 0$
- $\{x^k\} \rightarrow x^*$  con  $\text{ran}(\nabla h(x^*)) = m$

## Entonces

- $\{\lambda^k + c^k h(x^k)\}_K \rightarrow \lambda^*$
- $\nabla f(x^*) + \lambda^* \nabla h(x^*) = 0, \quad h(x^*) = 0$





## Demostración

1. Desarrollamos:  $\nabla L_c^k(x^k, \lambda^k) = \nabla f(x^k) + (\lambda^k + ch(x^k))\nabla h(x^k)$
2. Definimos:  $\tilde{\lambda}^k = \lambda^k + ch(x^k)$
3. Reescribimos  $\nabla L_c^k(x^k, \lambda^k) = \nabla f(x^k) + \tilde{\lambda}^k \nabla h(x^k)$
4. Despejamos  $\tilde{\lambda}^k = [\nabla h(x^k)^t \nabla h(x^k)]^{-1} \nabla h(x^k)^T [\nabla L_c^k(x^k, \lambda^k) - \nabla f(x^k)]$



## Demostración

5. Teníamos:  $\tilde{\lambda}^k = [\nabla h(x^k)^t \nabla h(x^k)]^{-1} \nabla h(x^k)^T [\nabla L_c^k(x^k, \lambda^k) - \nabla f(x^k)]$

6. Por hipótesis:  $\nabla L_c^k(x^k, \lambda^k) \rightarrow 0$  entonces  $\tilde{\lambda}^k \rightarrow \lambda^*$  en donde

$$\tilde{\lambda}^* = - [\nabla h(x^*)^t \nabla h(x^*)]^{-1} \nabla h(x^*)^T \nabla f(x^*)$$

7. En el límite:  $\nabla L_c^k(x^*, \lambda^*) = \nabla f(x^*) + \lambda^* \nabla h(x^*) = 0$



## Demostración

8. Como  $\{\lambda^k\}$  es acotada, y  $\{\lambda^k + c^k h(x^k)\} \rightarrow \lambda^*$ , entonces  $\{c^k h(x^k)\}$  también es acotada.
9. Como  $c^k \rightarrow \infty$ , se debe cumplir  $h(x^k) \rightarrow 0$
10. Como  $\{x^k\} \rightarrow x^*$  entonces, en el límite,  $h(x^*) = 0$



*Método de los multiplicadores*



# Métodos de los multiplicadores

## Idea

- Se aplican a problemas con restricciones de **igualdad**
- Obtener una secuencia de soluciones que convergen a la solución
- Se sustituye la restricción por un término que penaliza su violación
- Cada nuevo problema tiene una mejor estimación del vector de multiplicadores
- En el límite, con los multiplicadores óptimos, la solución es tb. la óptima



# Métodos de los multiplicadores

## Intuición (ma non troppo)

- De la demostración anterior, vimos que  $\tilde{\lambda}^k = \lambda^k + ch(x^k) \rightarrow \lambda^*$
- Entonces, podemos definir  $\lambda^{k+1} = \lambda^k + ch(x^k) \approx \lambda^*$
- Eso es todo!
- **Mucho** más estable que el anterior
- Convergencia *lineal*
- Combinado con  $c$  creciente, convergencia *superlineal*



# Método de penalización cuadrática exacto

## Pseudocódigo

1. Elegir punto, constante y multiplicador iniciales y poner  $k=0$
2. Resolver  $x_k = \arg \min_x L_{c^k}(x, \lambda^k)$  para  $L_c(x, \lambda) = f(x) + \lambda^T h(x) + \frac{c}{2} \|h(x)\|_2^2$
3. Verificar condiciones de optimalidad (KKT)
  - a. Se cumplen: TERMINAR
4. Incrementar  $k$
5. Incrementar  $c^k$ , actualizar  $\lambda^{k+1} = \lambda^k + ch(x^k)$
6. Volver a 1



*Comentarios finales*





## Métodos de los multiplicadores

- Vimos los tres métodos más básicos (y usados)
- Hay **muchos** otros métodos. Por ejemplo:
  - Métodos de penalización *exponencial* (resuelven problema de pen. cuadrática)
  - Métodos de penalización / multiplicadores de segundo orden
  - Métodos de penalización *exactos*
  - Resolución directa del sistema de ecuaciones de optimalidad
- En particular, en el **Tema 3** del curso veremos los **métodos duales**
- Al final del **Tema 4**, combinaremos el método de multiplicadores con los **métodos proximales** para desarrollar el método **ADMM**, de mucha vigencia