

# Optimización Continua

Daniel Espinoza, Dpto. Ingeniería Industrial

Universidad de Chile

7 de marzo de 2011

# Contenidos

- 1 Introducción
- 2 Optimización no constreñida
- 3 Optimización con Restricciones

# Buscando Problemas más generales

- Pensemos en el problema

$$\text{mín } f(x) : x \in \mathbb{R}^n,$$

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

- Podemos decir algo si  $f$  no es continua?
  - Ejemplo:  $f(x) = \begin{cases} x^2 & \text{si } x \in \mathbb{Q} \\ x^2 - \pi & \text{si } x \in \mathbb{R} \setminus \mathbb{Q} \end{cases}$ .
  - Cómo podemos asegurar si algún punto es óptimo (global o local)?
- Necesitamos algún tipo de **regularidad** de  $f$  para poder **resumir** su comportamiento.
- Algunas condiciones comunes son  $f \in \mathcal{C}^1$  o  $f \in \mathcal{C}^2$ .
  - Veremos que bajo los supuestos anteriores podremos dar condiciones suficientes y necesarias para optimalidad local.
- Para asegurar optimalidad global necesitamos **condiciones globales**.
  - Convexidad de  $f$  asegurará mínimos locales son mínimos globales.

# Anticipando el comportamiento de $f$

## Teorema de Taylor

Sea  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $x, p \in \mathbb{R}^n$ .

- Si  $f \in \mathcal{C}^1(\mathbb{R}^n)$  entonces  $f(x + p) = f(x) + \nabla f(x + tp)^t p$ , para algún  $t \in (0, 1)$ .
- Si  $f \in \mathcal{C}^2(\mathbb{R}^n)$  entonces

$$f(x + p) = f(x) + \nabla f(x)^t p + \frac{1}{2} p^t \nabla^2 f(x + tp) p,$$

para algún  $t \in (0, 1)$ .

- El teorema de Taylor permite anticipar el comportamiento de  $f$  en torno a un punto dado  $x \in \mathbb{R}^n$ .
- Si asumimos optimalidad local de  $x$ , entonces podemos deducir condiciones sobre  $\nabla f(x)$  y sobre  $\nabla^2 f(x)$ .

# Condiciones Necesarias de Optimalidad

## Teorema de condiciones de primer orden

Si  $x^* \in \mathbb{R}^n$  es un mínimo local y  $f \in \mathcal{C}^1(B(x^*, \varepsilon))$ , entonces  $\nabla f(x^*) = 0$ .

### Demostración.

- Si  $x^*$  es mínimo local,  $\exists \varepsilon \geq 0 : f(x^*) \leq f(x), \forall x \in B(x^*, \varepsilon)$ .
- Por Taylor  $f(x) = f(x^*) + \nabla f(x^* + t(x - x^*))^t(x - x^*)$ .
- Entonces  $\forall x \in B(x^*, \varepsilon)$  existe  $t \in (0, 1)$  tal que  $\nabla f(x^* + t(x - x^*))^t(x - x^*) \geq 0$ .
- Tomando limite de  $x \rightarrow x^*$  y por continuidad de  $\nabla f(x)$ , tenemos que  $\nabla f(x^*) = 0$



### Definición Punto estacionario

Para  $f \in \mathcal{C}^1$ ,  $x$  se dice un **punto estacionario** de  $f$  si  $\nabla f(x) = 0$ .

# Condiciones Suficientes

## Teorema condiciones necesarias de segundo orden

Si  $x^*$  es un mínimo local de  $f$  y  $f \in \mathcal{C}^2(B(x^*, \varepsilon))$  entonces  $\nabla f(x^*) = 0$  y  $\nabla^2 f(x^*) \geq 0$ .

### Demostración.

- Por las condiciones de primer orden  $\nabla f(x^*) = 0$
- Sea  $p \in \mathbb{R}^n \setminus \{0\}$ , entonces  
 $f(x^* + \varepsilon p) = f(x^*) + \varepsilon^2 \frac{1}{2} p^t \nabla^2 f(x^* + \tilde{\varepsilon} p) p$  para algún  $0 < \tilde{\varepsilon} < \varepsilon$ .
- Por mínimo local se tiene  $0 \leq \frac{1}{2} p^t \nabla^2 f(x^* + \tilde{\varepsilon} p) p$ , y tomando límite de  $\varepsilon \rightarrow 0$   $p^t \nabla^2 f(x^*) p \geq 0$ .



## Teorema condiciones suficientes de segundo orden

Si  $f \in \mathcal{C}^2(B(x^*, \varepsilon))$ ,  $\nabla f(x^*) = 0$  y  $\nabla^2 f(x^*) > 0$ , entonces  $x^*$  es un óptimo local.



# De óptimo local a óptimo global

## Demostración.

Use el argumento de que  $\nabla^2 f(x)$  es continua en torno a  $x^*$ .

## Teorema óptimos globales para funciones convexas

Si  $f$  es una función convexa, cualquier mínimo local es un mínimo global. Si además  $f \in \mathcal{C}^1$ , entonces cualquier punto estacionario es un óptimo global.

## Demostración.

- Para la primera parte, razone por contradicción.
- Para la segunda, use que

$$\nabla f(x^*)(z - x^*) = \lim_{\lambda \rightarrow 0} \frac{f(x^* + \lambda(z - x^*)) - f(x^*)}{\lambda}.$$



# Algoritmo Básico

- Dado los teoremas anteriores sólo podemos:
  - Encontrar óptimos locales si  $\nabla^2 f(x^*) > 0$ .
  - Buscar puntos estacionarios.
  - En el caso de  $f$  convexa, tenemos óptimos globales.
- La mayoría de los algoritmos buscan condición necesaria de primer orden:
  - $\nabla f(x^*) = 0$ .
  - En la práctica buscamos  $\|\nabla f(x^*)\| \leq \varepsilon$ .
  - ¿Qué podemos asegurar en esas condiciones?

## Algoritmos de descenso

**Require:**  $x^0 \in \mathbb{R}^n$ ,  $f \in \mathcal{C}^1(\mathbb{R}^n)$ ,  $\varepsilon > 0$ .

- 1:  $k \leftarrow 0$ ,  $\delta^k \leftarrow \|\nabla f(x^k)\|$ .
- 2: **while**  $\delta^k > \varepsilon$  **do**
- 3:   Buscar  $x^{k+1} : f(x^k) > f(x^{k+1})$ .
- 4:    $\delta^{k+1} \leftarrow \|\nabla f(x^{k+1})\|$ .
- 5:    $k \leftarrow k + 1$ .
- 6: **return**  $x^* = x^k$ .



# Buscando $x^{k+1}$

- Sabemos que  $f(x + d) = f(x) + \nabla f(x + \lambda d)^t d$  para algún  $\lambda \in (0, 1)$ .
- Por continuidad de  $\nabla f(x)$ , para  $d$  suficientemente pequeño, sabemos que  $\nabla f(x) \approx \nabla f(x + \lambda d)$ .
- Podríamos aproximar  $f(x + d) \approx f(x) + \nabla f(x)^t d$ .
- Bajo este supuesto, si escogemos  $x^{k+1} = x^k + d$  tenemos como condición necesaria  $\nabla f(x)^t d < 0$ .

## Definición dirección de descenso

Dada  $f \in \mathcal{C}^1$ ,  $x \in \mathbb{R}^n$ ,  $\nabla f(x) \neq 0$  se dice que  $d \in \mathbb{R}^n$  es una **dirección de descenso** si  $\nabla f(x)^t d < 0$ .

## Teorema

Para cualquier dirección de descenso  $d$ , existe  $\alpha > 0$  tal que  $x' := x + \alpha d$  satisface  $f(x') < f(x)$ .

Buscando  $x^{k+1}$ 

- Dado  $d$  dirección de descenso, ¿Cómo buscamos  $\alpha$ ?

## Algoritmo de búsqueda binaria exacta:

**Require:**  $x, d \in \mathbb{R}^n$ ,  $\varepsilon > 0$ ,  $f$  convexa.

- 1:  $\alpha_{\min} \leftarrow 0$ ,  $\alpha_{\max} \leftarrow 1$
- 2: **while**  $f(x + \alpha_{\max}d) < f(x)$  **do**
- 3:      $\alpha_{\max} \leftarrow 2\alpha_{\max}$ .
- 4: **while**  $|\alpha_{\min} - \alpha_{\max}| > \varepsilon$  **do**
- 5:      $x_1 \leftarrow x + \frac{1}{3}(\alpha_{\max} - \alpha_{\min})d$ ,  $x_2 \leftarrow x + \frac{2}{3}(\alpha_{\max} - \alpha_{\min})d$ .
- 6:     **if**  $f(x_1) > f(x_2)$  **then**
- 7:          $\alpha_{\min} \leftarrow \frac{1}{3}(\alpha_{\max} - \alpha_{\min})$ .
- 8:     **else**
- 9:          $\alpha_{\max} \leftarrow \frac{2}{3}(\alpha_{\max} - \alpha_{\min})$ .
- 10: **return**  $\alpha_{\min}$ .

- ¿Por qué el algoritmo es correcto?
- ¿Y si  $f$  no es convexa?
- ¿Podríamos terminar antes?



# Buscando $x^{k+1}$

- El algoritmo anterior resuelve  $\min f(x + \alpha d)$ 
  - Existen otros algoritmos para caso no convexo.
- ¿Cómo escogemos  $d$ ?
  - Podemos hacer un análogo a simplex:
  - Buscar dirección de descenso máximo
  - $\min \nabla f(x)^t d : \|d\| = 1$ , i.e.  $d = -\nabla f(x) / \|\nabla f(x)\|$ .
  - Note que dada  $D \in \mathbb{R}^{n \times n} > 0$ , podemos escoger  $d = -D\nabla f(x)$ .
- Si  $d = -\nabla f(x) / \|\nabla f(x)\|$ , el algoritmo se llama **algoritmo de máximo descenso**.
  - Este algoritmo es simple, y si  $f$  es convexa, existe óptimo, y se usa búsqueda exacta, converge a alguna solución óptima.
  - Convergencia es lenta para problemas muy **elipsoidales...**
  - Tasa de convergencia lineal  $\|x_{k+1} - x^*\| / \|x_k - x^*\| \leq M < 1$ .
- ¿Qué alternativa tenemos?
  - Lo anterior se derivó usando aproximación de Taylor de primer orden.
  - ¿Y si consideramos una aproximación de segundo orden?



# Método de Newton

- Por Taylor de segundo orden:  

$$f(x + d) = f(x) + \nabla f(x)^t d + \frac{1}{2} d^t \nabla^2 f(x + \lambda d) d$$
 para algún  $\lambda \in (0, 1)$
- Por continuidad, y para  $d$  **pequeños**, aproximamos  $\nabla^2 f(x + \lambda d) = \nabla^2 f(x)$ .
- Asumimos  $\nabla^2 f(x) > 0$  y minimizamos  $f(x + d) = f(x) + \nabla f(x)^t d + \frac{1}{2} d^t \nabla^2 f(x) d$ .
  - Óptimo es  $d = -(\nabla^2 f(x)^{-1}) \nabla f(x)$ .
  - Note que  $d^t \nabla f(x) = -\nabla f(x)^t (\nabla^2 f(x))^{-t} \nabla f(x)$ .
  - i.e. Si  $\nabla^2 f(x) > 0$ ,  $d$  es dirección de descenso.
- Si la aproximación cuadrática de  $f$  es **buena**, deberíamos poder usar  $\alpha^k = 1$ , a esto se le llama **iteración de Newton pura**.
- Si además se hace una búsqueda unidireccional (i.e. buscamos  $\alpha^k$ ), se le llama **iteración de Newton**.
- ¿Cómo se interpreta  $d$ ?

# Método de Newton

- **Ventajas de Newton:**
  - Para funciones cuadráticas y estrictamente convexas, Algoritmo de descenso de Newton termina en una iteración.
  - Convergencia cuadrática:  $\|x_{k+1} - x^*\| / \|x_k - x^*\|^2 \leq M$ .
  - En la práctica muy pocas iteraciones.
- **Desventajas de Newton:**
  - Computar  $\nabla^2 f(x^k)$  en cada iteración.
  - Luego invertir  $\nabla^2 f(x^k)$ .
  - Muy caro computacionalmente.
- **¿Podemos mejorar?**
  - Existen varios métodos para aproximar  $\nabla^2 f(x)$ :
  - Sólo computar  $\partial^2 f(x) / \partial x_i^2$  y usar matriz diagonal asociada.
  - Usar  $\nabla f(x^k)$  anteriores para estimar  $\nabla^2 f(x^k)$ .
  - Computar  $\nabla^2 f(x)$  cada  $m$  iteraciones....
- Estos métodos se llaman **Métodos Quasi-Newton**.
  - Si  $f$  estrictamente convexa, existen soluciones óptimas, y se usa búsqueda exacta, converge a alguna solución óptima.



# Definiciones Básicas

Problema bajo dominio restringido:

Consideramos problemas del tipo:

$$(P) : \quad \text{mín } f(x) : x \in \Omega \subseteq \mathbb{R}^n$$

donde  $f : \Omega \rightarrow \mathbb{R}$ ,  $f \in \mathcal{C}^1(\Omega)$ ,  $\Omega$  es un conjunto cerrado. Todo  $x \in \Omega$  se dice **factible** para  $(P)$ .

## Definición Óptimo Global

$x^* \in \Omega$  es un **óptimo global** para  $(P)$  si  $f(x^*) \leq f(x)$ ,  $\forall x \in \Omega$ .

## Definición Óptimo Local

$x^* \in \Omega$  es un **óptimo local** para  $(P)$  si  $\exists \varepsilon > 0$  tal que  $f(x^*) \leq f(x)$ ,  $\forall x \in \Omega \cap B(x^*, \varepsilon)$ .

# Resultados Básicos

## Definición Problema Convexo

( $P$ ) se dice un **problema convexo** si  $f$  es función convexa y si  $\Omega$  es conjunto convexo.

## Teorema de Óptimos Globales para Problemas Convexos

Si ( $P$ ) es un problema convexo, entonces todos los óptimos locales para ( $P$ ) son óptimos globales para ( $P$ ).

- ¿Qué debemos pedir de  $\Omega$ ?
  - Conexidad.... ¿si no?
  - Regularidad (¿Cómo es  $\Omega$  en torno a  $x_0$ ?)... ¿si no?
  - En términos de complejidad.... ¿Cómo representamos  $\Omega$ ?
    - Debemos ser capaces de responder  $x \in \Omega$  de forma rápida.
  - Una forma clásica es definir

$$\Omega := \{x \in \mathbb{R}^n : g_i(x) \leq 0, \forall i \in I\},$$

donde  $g_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $g_i \in \mathcal{C}^1(\mathbb{R}^n)$  y donde  $|I| = m \in \mathbb{Z}$ .

# Resultados Básicos

## Conjuntos Convexos a partir de Funciones Convexas

Sea  $\Omega := \{x \in \mathbb{R}^n : g_i(x) \leq 0, i = 1, \dots, m\}$ , si  $g_i$  es convexa en  $\mathbb{R}^n$ , entonces  $\Omega$  es un conjunto convexo.

- ¿Cómo caracterizamos optimalidad local **sin tener** que evaluar todos los vecinos?

## Definición de restricciones activas en un punto

Dado  $x^0 \in \Omega := \{x \in \mathbb{R}^n : g_i(x) \leq 0 \forall i \in I\}$ , una restricción  $i \in I$  se dice **activa en  $x^0$**  si  $g_i(x^0) = 0$ . Se define el **conjunto de restricciones activas** en  $x^0$  como  $I(x^0) := \{i \in I : g_i(x^0) = 0\}$ .

## Definición de direcciones factibles en un punto

Dado  $x^0 \in \Omega := \{x \in \mathbb{R}^n : g_i(x) \leq 0 \forall i \in I\}$ ,  $d \in \mathbb{R}^n$  se dice una **dirección factible en  $x^0$** , si existe  $\varepsilon > 0$  tal que  $x^0 + \varepsilon' d \in \Omega$  para todo  $0 \leq \varepsilon' \leq \varepsilon$ . Se define el **conjunto de direcciones factibles** en  $x^0$  como  $\mathcal{D}(x^0) := \{d \in \mathbb{R}^n : d \text{ dirección factible para } x^0\}$ .

# Optimalidad y direcciones factibles

- Para definir el algoritmo de Simplex, redujimos la condición de optimalidad en una vecindad a una condición con las direcciones factibles, ¿podemos hacer lo mismo en nuestro caso?

## Condición Necesaria de Direcciones Factibles

Si  $x^*$  es un óptimo local, entonces  $\nabla f(x^*)^t d \geq 0$  para todo  $d \in \mathcal{D}$ .

## Demostración.

Use definición de óptimo local y aproximación de Taylor de primer orden. □

- El opuesto no es cierto en general, es decir, si  $x^*$  es tal que existe  $\varepsilon > 0$  tal que  $f(x^*) \leq f(x^* + d)$ ,  $\forall d \in \mathcal{D}(x^*) \cap B(0, \varepsilon)$ ,  $x^*$  no es necesariamente óptimo local.
  - Ejemplo: Considere  $\Omega = \{x \in \mathbb{R}^2 : -x_2 + x_1^5 \leq 0\}$  y  $f(x_1, x_2) = x_2$ .
  - Note que  $f \in \mathcal{C}^2(\mathbb{R}^2)$  y  $g_1 \in \mathcal{C}^1(\mathbb{R}^2)$ .
  - El punto  $(0, 0)$  satisface condición anterior pero no es óptimo local.
- Note que si  $\Omega$  y  $f$  son convexas, esto es imposible!

# Caracterizando Direcciones Factibles y Óptimos Locales

- ¿Cómo caracterizamos  $\mathcal{D}(x)$  en general?
- Buscamos una forma **sucinta** para esto.

## Sobre-estimando $\mathcal{D}(x)$

Consideremos  $\tilde{\mathcal{D}}(x) := \{d \in \mathbb{R}^n : \nabla g_i(x)^t d \leq 0 \forall i \in I(x)\}$ .

- Demuestre que  $\mathcal{D}(x) \subseteq \tilde{\mathcal{D}}(x)$ .
- Note que si  $\Omega$  es convexo y  $\nabla g_i(x) \neq 0 \forall i \in I(x)$ , entonces  $\overline{\mathcal{D}(x)} = \tilde{\mathcal{D}}(x)$ .

## ¿Qué nos gustaría?

Nos gustaría decir que si  $x^*$  es óptimo local entonces

$$\{d \in \mathbb{R}^n : \nabla f(x^*)^t d < 0\} \cap \tilde{\mathcal{D}}(x) = \emptyset$$

- En general no es cierto.
- Si  $\Omega, f$  convexas y  $\nabla g_i(x) \neq 0 \forall i \in I(x)$ , entonces sí es cierto.

# Calificación de Restricciones

## Definición calificación de restricciones

Se dice que  $x \in \Omega$  satisface las **condiciones de calificación de restricciones** (CCR) si  $\overline{\mathcal{D}(x)} = \widetilde{\mathcal{D}}(x)$ .

## Teorema Condiciones necesarias de Primer Orden

Sea  $x^* \in \Omega$  óptimo local satisfaciendo CCR, entonces existe  $\lambda \in \mathbb{R}_+^I$  tal que :

- 1  $\nabla f(x^*) + \sum (\lambda_i \nabla g_i(x^*)) : i \in I) = 0$ .
- 2  $\lambda_i g_i(x^*) = 0 \forall i \in I$ .

- El teorema anterior se debe a Karush-Kuhn-Tucker, 1939, y se denominan condiciones de KKT.

## Demostración.

Use CCR, el teorema anterior y Lema de Farkas. □