

MA57B Optimización No Lineal. Semestre 2007-1
 Profesor: Héctor Ramírez C. Auxiliar: Oscar Peredo.

Clase Auxiliar #1 Optimización Irrestringida

15 de Marzo del 2007

1. Optimización Irrestringida

Teorema 1.1. Sea S convexo abierto no vacío en \mathbb{R}^n y $f : S \rightarrow \mathbb{R}$, diferenciable en S . Entonces f es convexa si y solo si $\forall \bar{x} \in S$

$$f(x) \geq f(\bar{x}) + \nabla f(\bar{x})^t(x - \bar{x}) \quad \forall x \in S$$

Teorema 1.2 (Valor Medio en \mathbb{R}^n). Sea $f : S \subset \mathbb{R}^n \rightarrow \mathbb{R}$ diferenciable en S , con S abierto convexo no vacío. Entonces para todo par de puntos $x_1, x_2 \in S$ existe $\tilde{x} \in]x_1, x_2[$, donde $]x_1, x_2[= \{\lambda x_1 + (1 - \lambda)x_2 : \lambda \in (0, 1)\}$, tal que:

$$f(x_2) - f(x_1) = \nabla f(\tilde{x})^t(x_2 - x_1)$$

Problema 1.1. Utilizando las hipótesis del teorema anterior, pruebe que f es convexa si y solo si $\forall x_1, x_2 \in S$

$$(\nabla f(x_2) - \nabla f(x_1))^t(x_2 - x_1) \geq 0$$

Solución 1.1. Probemos las dos implicancias:

\Rightarrow Supongamos f convexa. Sean $x_1, x_2 \in S$. Por el teorema 1, se tiene que

$$\begin{aligned} f(x_1) &\geq f(x_2) + \nabla f(x_2)^t(x_1 - x_2) \\ f(x_2) &\geq f(x_1) + \nabla f(x_1)^t(x_2 - x_1) \end{aligned}$$

Sumando ambas inecuaciones:

$$\begin{aligned} f(x_1) + f(x_2) &\geq f(x_1) + f(x_2) + (\nabla f(x_2) - \nabla f(x_1))^t(x_1 - x_2) \\ 0 &\geq (\nabla f(x_2) - \nabla f(x_1))^t(x_1 - x_2) \\ 0 &\leq (\nabla f(x_2) - \nabla f(x_1))^t(x_2 - x_1) \end{aligned}$$

\Leftarrow Sean $x_1, x_2 \in S$. Por el teorema del valor medio (teorema 1.2), existe $x = \lambda x_1 + (1 - \lambda)x_2 \in S$ tal que

$$f(x_2) - f(x_1) = \nabla f(x)^t(x_2 - x_1) \quad (*)$$

Por hipótesis:

$$\begin{aligned} 0 &\leq (\nabla f(x) - \nabla f(x_1))^t(x - x_1) \\ 0 &\leq (\nabla f(x) - \nabla f(x_1))^t(\lambda x_1 + (1 - \lambda)x_2 - x_1) \\ 0 &\leq (\nabla f(x) - \nabla f(x_1))^t((1 - \lambda)(x_2 - x_1)) \\ 0 &\leq (\nabla f(x) - \nabla f(x_1))^t(x_2 - x_1) \\ \nabla f(x_1)^t(x_2 - x_1) &\leq \nabla f(x)^t(x_2 - x_1) \\ \nabla f(x_1)^t(x_2 - x_1) &\leq \underbrace{f(x_2) - f(x_1)}_{(*)} \\ f(x_1) + \nabla f(x_1)^t(x_2 - x_1) &\leq f(x_2) \end{aligned}$$

Utilizando el teorema 1.1, se concluye que f es convexa. \square

Problema 1.2 (Bertsekas, página 19). Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ de clase C^2 que satisfice

$$m\|y\|^2 \leq y^T \nabla^2 f(x) y \leq M\|y\|^2, \quad \forall x, y \in \mathbb{R}^n$$

donde $\nabla^2 f(x)$ es la matriz hessiana evaluada en x y $m, M \geq 0$. Pruebe que f tiene un único mínimo global x^* que satisfice

$$\frac{1}{2M} \|\nabla f(x)\|^2 \leq f(x) - f(x^*) \leq \frac{1}{2m} \|\nabla f(x)\|^2, \quad \forall x \in \mathbb{R}^n$$

y

$$\frac{m}{2} \|x - x^*\|^2 \leq f(x) - f(x^*) \leq \frac{M}{2} \|x - x^*\|^2, \quad \forall x \in \mathbb{R}^n$$

HINT: Use expansión de segundo orden y la siguiente relación:

$$\min_{y \in \mathbb{R}^n} \{ \nabla f(x)^T (y - x) + \frac{\alpha}{2} \|y - x\|^2 \} = -\frac{1}{2\alpha} \|\nabla f(x)\|^2$$

Solución 1.2. <http://www.athenasc.com/nlpsol1.pdf>

2. Condiciones de Optimalidad y Coercividad

Teorema 2.1 (Condición necesaria de Primer Orden, una vez diferenciable). Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ diferenciable en $x \in \text{int}(\text{Dom}(f))$. Si x es óptimo local de f entonces $\nabla f(x) = 0$.

Teorema 2.2 (Condiciones necesarias de Primer Orden y Segundo Orden, dos veces diferenciable). Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ dos veces diferenciable en $x \in \text{int}(\text{Dom}(f))$. Si x es óptimo local de f entonces $\nabla f(x) = 0$ y $H_f(x)$ es semidefinida positiva.

Teorema 2.3 (Condición Suficiente). Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ dos veces diferenciable en $x \in \text{int}(\text{Dom}(f))$. Si $\nabla f(x) = 0$ y $H_f(x)$ es definida positiva, entonces x es mínimo local de f .

Teorema 2.4 (Coercividad y Continuidad). Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ continua y coerciva (i.e. $\lim_{\|x\| \rightarrow \infty} f(x) = \infty$). Entonces f tiene al menos un mínimo.

Demostración. Consideremos la sucesión z_k tal que $\lim_{k \rightarrow \infty} f(z_k) = \inf_x f(x)$ (el ínfimo puede ser finito o $-\infty$). Como f es coerciva, la sucesión z_k debe ser acotada, pues de no serlo se tendría $\lim_{j \rightarrow \infty} f(z_{k_j}) = \infty$ para alguna subsucesión z_{k_j} que satisface $\|z_{k_j}\| \rightarrow \infty$, lo cual indicaría que $\inf_x f(x) = \infty$. Ahora bien, como z_k es acotada, tiene al menos un punto de acumulación, $z \in \mathbb{R}^n$, y por continuidad de f se tiene que $f(z) = \lim_{k \rightarrow \infty} f(z_k) = \inf_x f(x)$. \square

3. Discretización del Método de Máximo Descenso

Sea H un Hilbert y Φ función diferenciable y convexa. El Método de Máximo Descenso (Steepest Descent)

■ Caso Explícito:

$$x^{k+1} = x^k - \lambda_k \nabla \Phi(x^k) \quad (E)$$

con $\lambda_k > 0$. El principal resultado es el siguiente teorema:

Teorema 3.1. Sea $\Phi : H \rightarrow \mathbb{R}$ una función diferenciable y convexa tal que $\text{Argmin}\{\Phi\}$ es distinto de vacío y $\nabla \Phi$ es Lipschitz sobre acotados. Sea la iteración definida por

$$x^{k+1} = x^k - \lambda_k \frac{\nabla \Phi(x^k)}{\|\nabla \Phi(x^k)\|}$$

donde $\sum_k \lambda_k = +\infty$ y $\sum_k \lambda_k^2 < +\infty$, entonces

1. $\forall z \in \text{Argmin}\{\Phi\}$, el límite $\lim_{k \rightarrow +\infty} \|x^k - z\|$ existe.
2. Existe una subsucesión de x^k tal que $x^{k_i} \rightarrow x^\infty \in \text{Argmin}\{\Phi\}$.
3. Si además $\dim H < +\infty$, entonces $x^k \rightarrow x^\infty$.

Demostración. :

1. Sea $z \in \text{Argmin}\{\Phi\}$. Definamos $\varphi_k := \|x^k - z\|^2$. Notemos que:

$$\begin{aligned}
\varphi_{k+1} &= \|x^{k+1} - z\|^2 \\
&= \|x^{k+1} - x^k + x^k - z\|^2 \\
&= \|x^{k+1} - x^k\|^2 + 2 \langle x^{k+1} - x^k, x^k - z \rangle + \varphi_k \\
&= \|\lambda_k \frac{\nabla\Phi(x^k)}{\|\nabla\Phi(x^k)\|}\|^2 + 2 \langle x^{k+1} - x^k, x^k - z \rangle + \varphi_k \\
&= \lambda_k^2 + 2 \langle x^{k+1} - x^k, x^k - z \rangle + \varphi_k \\
&= \lambda_k^2 - \frac{2\lambda_k}{\|\nabla\Phi(x^k)\|} \langle \nabla\Phi(x^k), x^k - z \rangle + \varphi_k
\end{aligned}$$

Por el teorema 1.1 (debido a la convexidad y diferenciabilidad de Φ) se tiene:

$$\langle \nabla\Phi(x^k), x^k - z \rangle \leq \Phi(x^k) - \Phi(z)$$

Con esto se tiene la siguiente desigualdad:

$$\begin{aligned}
\varphi_{k+1} &\leq \varphi_k + \lambda_k^2 - \frac{2\lambda_k}{\|\nabla\Phi(x^k)\|} \underbrace{(\Phi(x^k) - \Phi(z))}_{\geq 0} \\
&\leq \varphi_k + \lambda_k^2
\end{aligned}$$

Probemos el lema:

Lema 3.1. Si (φ_k) es una sucesión acotada inferiormente y tal que existe (δ_k) con $\sum \delta_k < +\infty$ de modo que $\varphi_{k+1} \leq \varphi_k + \delta_k$. Entonces φ_k converge.

Demostración. Sumando $\sum_{j=k+1}^{\infty} \delta_j$ a ambos lados de la desigualdad, se obtiene $\theta_k \leq \theta_{k+1}$, con $\theta_k := \varphi_k + \sum_{j=k}^{\infty} \delta_j$. Como φ_k es acotado inferiormente, θ_k también, luego θ_k converge, y como $\sum_{j=k}^{\infty} \delta_j \rightarrow_{k \rightarrow \infty} 0$ obtenemos que φ_k converge, y además $\lim_{k \rightarrow \infty} \theta_k = \lim_{k \rightarrow \infty} \varphi_k$. \square

Como se tiene que $\sum \lambda_k^2 < \infty$ por hipótesis, se concluye que $\lim_{k \rightarrow +\infty} \|x^k - z\|$ existe (en particular, x^k es acotado).

2. Por negación, supongamos que toda sucesión satisface lo contrario, es decir, $\exists \varepsilon > 0$ tal que $\forall k \in \mathbb{N}$, $\Phi(x^k) > \min \Phi + \varepsilon$. De la primera parte:

$$\varphi_{k+1} \leq \varphi_k + \lambda_k^2 + \frac{2\lambda_k}{\|\nabla\Phi(x^k)\|} (\underbrace{\Phi(z)}_{=\min \Phi} - \Phi(x^k))$$

obtendríamos

$$\frac{2\varepsilon\lambda_k}{\|\nabla\Phi(x^k)\|} \leq \varphi_k - \varphi_{k+1} + \lambda_k^2$$

sumando sobre k se tiene

$$2\varepsilon \sum_k \frac{\lambda_k}{\|\nabla\Phi(x^k)\|} \leq \varphi_0 - \underbrace{\varphi_\infty}_{=\lim_{k \rightarrow \infty} \varphi_k} + \underbrace{\sum_k \lambda_k^2}_{< \infty}$$

es decir $\sum_k \frac{\lambda_k}{\|\nabla\Phi(x^k)\|} < \infty$. Por hipótesis, se tiene que $\sum \lambda_k = \infty$, luego $\lim_{k \rightarrow \infty} \frac{1}{\|\nabla\Phi(x^k)\|} = 0$. Como

$\nabla\Phi$ es Lipschitz sobre acotados y x^k es acotada, tenemos

$$\begin{aligned}
\|\nabla\Phi(x^k)\| &\leq L\|x^k\| \\
&\leq \underbrace{LM}_{cte.}
\end{aligned}$$

con $(x^k) \subset B(0, M)$. Es decir, $\nabla\Phi(x^k)$ es uniformemente acotado, lo cual contradice $\lim_{k \rightarrow \infty} \frac{1}{\|\nabla\Phi(x^k)\|} = 0$. Por lo tanto, existe una subsucesión de x^k convergente a $x^\infty \in \text{Argmin}\{\Phi\}$, o equivalentemente $\lim_{k \rightarrow \infty} \Phi(x^k) = \min \Phi$.

3. Propuesto. \square

■ Caso Implícito:

$$x^{k+1} = x^k - \lambda_k \nabla \Phi(x^{k+1}) \quad (I)$$

con $\lambda_k > 0$. Si Φ es convexa, la función $\Phi(x) + \frac{1}{2\lambda_k} \|x - x^k\|^2$ es convexa y coerciva, y por teorema anterior, $\text{Argmin}\{\Phi\}$ tiene al menos un elemento (ver Problema siguiente).

El problema (I) anterior es equivalente a

$$x^{k+1} = \text{Argmin}_{x \in H} \left\{ \Phi(x) + \frac{1}{2\lambda_k} \|x - x^k\|^2 \right\}$$

el cual recibe el nombre de Algoritmo del Punto Proximal (PROX).

Problema 3.1. Sea $f : \mathbb{R}^n \rightarrow \mathbb{R}$ una función convexa, con derivada continua y $\lambda > 0$. Definamos la función

$$\phi_\lambda(x) = f(x) + \frac{\lambda}{2} \|x\|^2$$

Demuestre que existe un único mínimo global de ϕ_λ .

Solución 3.1. La función φ_λ es trivialmente continua. Probemos que es coerciva. Del teorema 1.1, se tiene que

$$\varphi_\lambda(x) \geq f(0) + \nabla f(0)^T x + \frac{\lambda}{2} x^T x$$

Supongamos $\exists(x_k) \subset \mathbb{R}^n, \|x_k\| \rightarrow \infty$ y $\exists M > 0$ tal que $\varphi_\lambda(x_k) \leq M$ para todo k :

$$\begin{aligned} M &\geq f(0) + \nabla f(0)^T x_k + \frac{\lambda}{2} x_k^T x_k \\ \underbrace{M - f(0)}_{\tilde{M}} &\geq \nabla f(0)^T x_k + \frac{\lambda}{2} x_k^T x_k \\ \tilde{M} &\geq (\nabla f(0) + \frac{\lambda}{2} x_k)^T x_k \end{aligned}$$

Geométricamente se tiene que $(\nabla f(0) + \frac{\lambda}{2} x_k)^T x_k = \|\nabla f(0) + \frac{\lambda}{2} x_k\| \|x_k\| \cos \theta_k$, con θ_k el ángulo entre ambos vectores. Como $\|x_k\| \rightarrow \infty$, se tendrá que $\cos \theta_k \rightarrow_{k \rightarrow \infty} 1$, con lo cual se llega a la contradicción, pues $\exists k_0$ tal que $\forall k \geq k_0, \|\nabla f(0) + \frac{\lambda}{2} x_k\| \|x_k\| \cos \theta_k > \tilde{M} + 1$, luego $\tilde{M} > \tilde{M} + 1$.

Luego, por teorema 2.4, existe al menos un mínimo de φ_λ . La función φ_λ es estrictamente convexa pues si $x, y \in \mathbb{R}^n, x \neq y$:

$$\begin{aligned} \|x - y\|^2 &> 0 \\ \|x\| - 2x^T y + \|y\|^2 &> 0 \\ \frac{\lambda}{2} \|x\|^2 &> -\frac{\lambda}{2} \|y\|^2 + \lambda x^T y \\ f(x) + \frac{\lambda}{2} \|x\|^2 &> f(x) - \frac{\lambda}{2} \|y\|^2 + \lambda x^T y \\ \varphi_\lambda(x) &> f(x) - \frac{\lambda}{2} \|y\|^2 + \lambda x^T y \\ \varphi_\lambda(x) &> f(y) + \nabla f(y)^T (x - y) - \frac{\lambda}{2} \|y\|^2 + \lambda x^T y \\ \varphi_\lambda(x) &> f(y) + \nabla f(y)^T (x - y) + \frac{\lambda}{2} \|y\|^2 + \lambda x^T y - \lambda y^T y \\ \varphi_\lambda(x) &> f(y) + \frac{\lambda}{2} \|y\|^2 + \nabla f(y)^T (x - y) + \lambda y^T (x - y) \\ \varphi_\lambda(x) &> \varphi_\lambda(y) + (\nabla f(y) + \lambda y)^T (x - y) \\ \varphi_\lambda(x) &> \varphi_\lambda(y) + (\nabla f(y) + \nabla(\frac{\lambda}{2} \|y\|^2))^T (x - y) \\ \varphi_\lambda(x) &> \varphi_\lambda(y) + \nabla(f(y) + \frac{\lambda}{2} \|y\|^2)^T (x - y) \\ \varphi_\lambda(x) &> \varphi_\lambda(y) + \nabla \varphi_\lambda(y)^T (x - y) \end{aligned}$$

Por teorema 1.1, se concluye la convexidad estricta. Luego, el mínimo es único. \square