

Resumen que puede usarse en el examen

Tema 2. Optimización sobre un conjunto convexo.

Min $f(x)$

s.a. $x \in X$ f continuamente diferenciable sobre $X \subseteq \mathbb{R}^n$, convexo, cerrado no vacío.

Propiedad 1

Sea C un convexo de \mathbb{R}^n no vacío y $f : C \rightarrow \mathbb{R}$ una función convexa, entonces los conjuntos de nivel inferior $L_f(\alpha) = \{x \in C : f(x) \leq \alpha\}$ son convexos para cualquier escalar $\alpha \in \mathbb{R}$.

Propiedad 2

Dada una colección de convexos $\{C_i : i \in I\}$, su intersección $\bigcap_{i \in I} C_i$ es un convexo.

Condiciones de optimalidad.

Proposición

(a) Si x^* es un mínimo local de f sobre el convexo X , entonces

$$\nabla f(x^*)^T (x - x^*) \geq 0 \quad \forall x \in X$$

(b) Si además f es convexa sobre X , la condición anterior es suficiente para asegurar que x^* minimiza f sobre X .

Proyección sobre un convexo cerrado X .

Teorema

(a) Para cada $z \in \mathbb{R}^n$ existe un único $x^* \in X$ que minimiza $\|z - x\|$ sobre X . Éste vector es la proyección de z sobre X y se denota mediante $[z]^+$.

(b) Dado $z \in \mathbb{R}^n$, un vector $x^* \in X$ es la proyección de z sobre X , si y solo si:

$$(z - x^*)^T (x - x^*) \leq 0 \quad \forall x \in X.$$

(c) La aplicación $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ definida por $f(x) = [x]^+$ es continua y no expansiva.

(d) Si X es un subespacio, un vector $x^* \in X$ es la proyección de z si y solo si

$$(z - x^*)^T x = 0 \quad \forall x \in X$$

Métodos de direcciones factibles

Definición. Dado x^k , una dirección factible en x^k es un vector $d^k \neq 0_n$ tal que $\exists \delta > 0 : \forall \alpha \in [0, \delta], x^k + \alpha d^k \in X$.

En estos métodos se comienza desde una solución factible x^0 y se genera una sucesión de vectores factibles $\{x^k\}$ como $x^{k+1} = x^k + \alpha^k d^k$ siendo d^k una dirección de descenso factible en x^k y α^k la longitud de salto adecuada.

Métodos de proyección del gradiente

El más sencillo genera una sucesión de iterados de la siguiente forma:

$$x^{k+1} = x^k + \alpha^k (\bar{x}^k - x^k) \quad \alpha^k \in (0, 1], \text{ siendo } \bar{x}^k = [x^k - s^k \nabla f(x^k)]^+ \text{ y } s^k > 0, \forall k$$

Para calcular la longitud de salto puede utilizarse la regla de minimización limitada o la regla de Armijo para direcciones factibles.

Suboptimización en variedades

Min $f(x)$

s.a. $a_j^T x \leq b_j \quad j = 1, \dots, r$

Hipótesis: Para cada $x \in X$ el conjunto de vectores $\{a_j : j \in A(x)\}$ es linealmente independiente, siendo $A(x) = \{j : a_j^T x = b_j\}$ (conjunto de índices de las restricciones activas)

Esquema general

Dado $x^k \in X$ se busca una dirección factible de descenso d^k en el subespacio

$$S(x^k) = \{d : a_j^T d = 0 \quad \forall j \in A(x^k)\}$$

(a) Si existe dicha dirección $d^k \in S(x^k)$ factible de descenso, $x^{k+1} = x^k + \alpha^k d^k$ y α^k se calcula en el intervalo $\{\alpha > 0 : x^k + \alpha d^k \in X\}$

(b) Si no existe ninguna, x^k es estacionario sobre la variedad $x^k + S(x^k)$

- b1) Si x^k es estacionario sobre $X = \{x : a_j^T x \leq b_j \quad j = 1, \dots, r\}$ el algoritmo para.
- b2) Si x^k no es estacionario sobre X , puede relajarse una de las restricciones \bar{j} y se obtiene una dirección factible de descenso en el subespacio

$$\bar{S}(x^k) = \{d : a_j^T d = 0 \quad \forall j \in A(x^k) \sim \{\bar{j}\}\}$$

Para determinar $d^k \in S(x^k)$ dirección factible de descenso se resuelven problemas cuadráticos de la forma:

$$(P1) \text{ Min } \nabla f(x^k)^T d + \frac{1}{2} d^T H^k d$$

s.a. $a_j^T d = 0 \quad j \in A(x^k)$

con H^k matriz simétrica definida positiva.

La solución óptima de éste problema puede verse como la proyección a escala H^k del gradiente $\nabla f(x^k)$ sobre el subespacio $S(x^k)$, entonces $d^k = -(H^k)^{-1}(\nabla f(x^k) + (A^k)^T \mu)$, donde $\mu = -A^k (H^k)^{-1} (A^k)^T)^{-1} A^k (H^k)^{-1} \nabla f(x^k)$ y A^k es una matriz cuyas filas son los vectores a_j $j \in A(x^k)$.

Tenemos que: $d^k = 0_n \Leftrightarrow \nabla f(x^k) + (A^k)^T \mu = 0_n \Leftrightarrow \exists \mu_j, j \in A(x^k) : \nabla f(x^k) + \sum_{j \in A(x^k)} \mu_j a_j = 0_n$

Entonces x^k es estacionario sobre X si y solo si $\mu_j \geq 0, \forall j \in A(x^k)$.

Por tanto, si $d^k = 0_n$ y x^k no es estacionario, existirá algún índice \bar{j} tal que $\mu_{\bar{j}} < 0$

Proposición

En las condiciones actuales ($\nabla f(x^k) + (A^k)^T \mu = 0_n, \mu_{\bar{j}} < 0$), sea \bar{d}^k la única solución óptima del problema :

$$(P2) \text{ Min } \nabla f(x^k)^T d + \frac{1}{2} d^T \bar{H}^k d$$

$$\text{s.a. } a_j^T d = 0 \quad j \in A(x^k) \sim \{\bar{j}\}$$

\bar{H}^k matriz definida positiva

Entonces \bar{d}^k es una dirección factible de descenso en x^k .

Programación Cuadrática

$$\text{Min } \frac{1}{2} x^T Q x + c^T x$$

$$\text{s.a. } a_j^T x \leq b_j \quad j = 1, \dots, r$$

Las matrices H^k y \bar{H}^k se toman iguales a Q .

Acerca del cálculo de la longitud de salto a lo largo de una dirección de descenso:

Si $d^k \neq 0_n$, comprobaremos si $x^k + d^k \in X$, en cuyo caso $x^{k+1} = x^k + d^k$, si $x^k + d^k \notin X$,

entonces $x^{k+1} = x^k + \alpha^k d^k$, siendo $\alpha^k = \max \{ \alpha > 0 : x^k + \alpha d^k \in X \}$, por tanto

$$\alpha^k = \min_i \left\{ \frac{\hat{b}_i}{\hat{d}_i} : \hat{d}_i > 0 \right\}$$

siendo $\hat{d}_j = a_j^T d^k$ $j \notin A(x^k)$, $\hat{b}_j = b_j - a_j^T x^k$.

¿Por que no puede suceder que $\hat{d}_j \leq 0 \quad \forall j \notin A(x^k)$?

Tema 3. Teoría de los multiplicadores de Lagrange.

Condiciones necesarias para restricciones de igualdad

Consideremos el problema:

$$(P) \text{ Min } f(x) \quad f: \mathbb{R}^n \rightarrow \mathbb{R}, \quad h_i: \mathbb{R}^n \rightarrow \mathbb{R} \text{ continuamente diferenciables.} \\ \text{s.a. } h_i(x) = 0 \quad i=1, \dots, m$$

Teorema de los multiplicadores de Lagrange

Sea x^* un mínimo local de (P) y supongamos que los gradientes de las restricciones $\{\nabla h_i(x^*) : i=1, \dots, m\}$ son linealmente independientes.

(i) Entonces, existe un único vector $\lambda^* = (\lambda_1^*, \dots, \lambda_m^*)^T$ llamado vector de los

multiplicadores de Lagrange, tal que $\nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(x^*) = 0_n$

(ii) Si, además f y h son dos veces continuamente diferenciables, se tiene que:

$$y^T (\nabla^2 f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla^2 h_i(x^*)) y \geq 0 \quad \forall y \in V(x^*), \text{ siendo } V(x^*) \text{ el subespacio}$$

de las variaciones factibles de primer orden: $V(x^*) = \{y : \nabla h_i(x^*)^T y = 0 \quad i=1, \dots, m\}$

Definición. Función lagrangiana

$$L: \mathbb{R}^{n+m} \rightarrow \mathbb{R}, \text{ definida como } L(x, \lambda) = f(x) + \sum_{i=1}^m \lambda_i h_i(x)$$

Condiciones suficientes para restricciones de igualdad

Proposición.

Supongamos que f y h son dos veces continuamente diferenciables. Sean $x^* \in \mathbb{R}^n$ y

$\lambda^* \in \mathbb{R}^m$, que satisfacen:

$$\nabla_x L(x^*, \lambda^*) = 0_n \quad \nabla_\lambda L(x^*, \lambda^*) = 0_m \quad (1)$$

$$y^T \nabla_{xx}^2 L(x^*) y > 0 \quad \forall y \neq 0_n \text{ tal que } \nabla h(x^*)^T y = 0 \quad (2)$$

Entonces x^* es un mínimo local estricto de f restringido a $h(x) = 0_m$. De hecho, existen escalares $\gamma > 0$ y $\varepsilon > 0$ tales que

$$f(x) \geq f(x^*) + \frac{\gamma}{2} \|x - x^*\|^2 \quad \forall x: h(x) = 0_m \text{ y } \|x - x^*\| < \varepsilon$$

La función lagrangiana aumentada

Dado cualquier escalar c , se define la función lagrangiana aumentada

$$L_c(x, \lambda) = f(x) + \sum_{i=1}^m \lambda_i h_i(x) + \frac{c}{2} \|h(x)\|^2$$

Restricciones de desigualdad: condiciones de K-K-T

Consideremos el problema más general:

$$\begin{aligned} \text{(ICP) Min } & f(x) && f, h_i \text{ y } g_j \text{ funciones continuamente diferenciables.} \\ \text{s.a. } & h_i(x) = 0 \quad i=1, \dots, m \\ & g_j(x) \leq 0 \quad j=1, \dots, r \end{aligned}$$

- Dada una solución factible x el conjunto de restricciones de desigualdad activas se denota $A(x) = \{j : g_j(x) = 0\}$.
- Una solución factible es regular si el conjunto de vectores siguiente es linealmente independiente: $\{\nabla h_i(x), i=1, \dots, m, \nabla g_j(x), j \in A(x)\}$
- Para (ICP) la función lagrangiana se define: $L(x, \lambda, \mu) = f(x) + \sum_{i=1}^m \lambda_i h_i(x) + \sum_{j=1}^r \mu_j g_j(x)$

Condiciones necesarias de optimalidad

Sea x^* un mínimo local de (ICP) que es regular.

(1) Entonces, existe un único vector (λ^*, μ^*) , siendo $\lambda^* = (\lambda_1^*, \dots, \lambda_m^*)^T$,

$\mu^* = (\mu_1^*, \dots, \mu_r^*)^T$ llamado vector de los multiplicadores de Lagrange, tal que

$$\nabla_x L(x^*, \lambda^*, \mu^*) = 0_n \quad \mu_j \geq 0 \quad j=1, \dots, r \text{ y } \mu_j = 0 \text{ si } j \notin A(x^*)$$

$[(x^*, \lambda^*, \mu^*)$ es un punto de Karush, Kuhn y Tucker para (ICP)]

(2) Si, además f, g y h son dos veces continuamente diferenciables, se tiene que:

$$\begin{aligned} & y^T \nabla_{xx}^2 L(x^*, \lambda^*, \mu^*) y \geq 0 \quad \forall y \in V(x^*) \text{ siendo} \\ V(x^*) &= \{y : \nabla h_i(x^*)^T y = 0 \quad i=1, \dots, m, \nabla g_j(x^*)^T y = 0, j \in A(x^*)\} \end{aligned}$$

Condiciones suficientes de optimalidad

Sean $x^* \in \mathbb{R}^n, \lambda^* \in \mathbb{R}^m, \mu^* \in \mathbb{R}^r$ tales que:

$$h(x^*) = 0_m, g(x^*) \leq 0_r$$

$$\nabla_x L(x^*, \lambda^*, \mu^*) = 0_n \quad \mu_j \geq 0 \quad j=1, \dots, r \text{ y } \mu_j = 0 \text{ si } j \notin A(x^*)$$

y también verifican que

$$\begin{aligned} & y^T \nabla_{xx}^2 L(x^*, \lambda^*, \mu^*) y > 0 \quad \forall y \in V(x^*) \text{ y } y \neq 0_n \text{ siendo} \\ V(x^*) &= \{y : \nabla h_i(x^*)^T y = 0 \quad i=1, \dots, m, \nabla g_j(x^*)^T y = 0, j \in A(x^*)\}. \end{aligned}$$

Supongamos que $\mu_j > 0 \quad \forall j \in A(x^*)$, entonces x^* es mínimo local estricto de (ICP).

Tema 4. Métodos basados en el uso de las penalizaciones.

1. Métodos de barrera

$$(P) \quad \begin{array}{l} \text{Min } f(x) \\ \text{s.a. } g_j(x) \leq 0 \quad j=1, \dots, r \\ x \in X \quad X \subseteq \mathbb{R}^n \text{ cerrado} \end{array} \quad f \text{ y } g_j \text{ continuas}$$

Sucesión de parámetros $\{\varepsilon^k\}$ que verifican $0 < \varepsilon^{k+1} < \varepsilon^k$, $k = 0, 1, \dots$, con $\varepsilon^k \rightarrow 0$

Hallar $x(\varepsilon^k) := \arg \min_{x \in S} \{f(x) + \varepsilon^k B(x)\}$ $k = 0, 1, \dots$, siendo

$S = \{x \in X : g_j(x) < 0, j = 1, \dots, r\}$ y $B(x)$ la función barrera que está definida en $S \neq \emptyset$, es continua y tiende a ∞ si alguna de las restricciones se aproxima a 0. Las más habituales:

$$B(x) = -\sum_{j=1}^r \ln(-g_j(x)) \quad \text{y} \quad B(x) = -\sum_{j=1}^r \frac{1}{g_j(x)}$$

Proposición.

Cada punto límite de la sucesión $\{x^k\}_{k \geq 0}$ generada mediante un método de barrera es un mínimo global de (P)

2. Métodos de penalización y de los multiplicadores

$$(P) \quad \begin{array}{l} \text{Min } f(x) \\ \text{s.a. } h_i(x) \leq 0 \quad i=1, \dots, m \\ x \in X \quad X \subseteq \mathbb{R}^n \end{array}$$

Lagrangiano aumentado: $L_c(x, \lambda) = f(x) + \lambda^T h(x) + \frac{c}{2} \|h(x)\|^2$, $c > 0$

Proposición.

Supongamos que f y h son continuas y X un conjunto cerrado, también suponemos que $\{x \in X : h(x) = 0_m\} \neq \emptyset$. Para $k=0, 1, \dots$, sea x^k un mínimo global del problema

$$\text{Min } L_{c^k}(x, \lambda^k)$$

s.a. $x \in X$

siendo $\{\lambda^k\}$ una sucesión acotada, $0 < c^k < c^{k+1} \forall k$ y $\{c^k\} \rightarrow \infty$.

Entonces cada punto límite de la sucesión $\{x^k\}$ es un mínimo global de (P).

Esquema numérico del SUMT

Inicializar: Elegir $\varepsilon > 0$, $\beta \in [4, 10]$, $c^0 > 0$ y $x^0 \in \mathbb{R}^n$. Hacer $k = 0$

Etapas: Empezando en x^k resolver el problema

$$\text{Min } L_{c^k}(x, 0) = f(x) + \frac{c^k}{2} \|h(x)\|^2$$

Llamar x^{k+1} a la solución óptima del problema irrestringido

Etapas: Si $\frac{c^k}{2} \|h(x^{k+1})\|^2 < \varepsilon$, entonces parar.

En otro caso hacer $c^{k+1} = \beta c^k$, $k = k+1$ y repetir la etapa 1.

Esquema numérico del método de los multiplicadores (ALAG)

Inicializar: Elegir $\varepsilon > 0$, $\beta \in [5, 10]$, $c^0 > 0$, $\lambda^0 \in \mathbb{R}^m$. Tomar $x^0 = 0_n$ Hacer $k = 0$

Minimización de la función de penalización

Tomando como solución inicial x^k , resolver el problema $\text{Min } L_{c^k}(x, \lambda^k)$ y llamar x^{k+1} a la solución óptima obtenida

Si $\|h(x^{k+1})\| < \varepsilon$, parar y $x^{k+1} = x^*$ es mínimo local del problema restringido.

Si $\|h(x^{k+1})\| \geq 0.25 \|h(x^k)\|$, reemplazar c^k por $c^{k+1} = \beta c^k$, $\lambda^{k+1} = \lambda^k$ y repetir ésta etapa.

Si $\|h(x^{k+1})\| < 0.25 \|h(x^k)\|$, actualizar los multiplicadores $\lambda^{k+1} = \lambda^k + c^k h(x^k)$, y $c^{k+1} = c^k$ y

repetir ésta etapa. $L_{c^k}(x, \lambda^k) = f(x) + (\lambda^k)^T h(x) + \frac{c^k}{2} \|h(x)\|^2$

3. Métodos de Lagrange-Newton y programación cuadrática secuencial.

Método tipo Newton para problemas con restricciones de igualdad

Resolver el sistema lagrangiano:

$$\left. \begin{array}{l} \nabla f(x) + \nabla h(x)\lambda = 0_n \\ h(x) = 0_m \end{array} \right\} \Leftrightarrow \nabla L(x, \lambda) = 0_{n+m}$$

mediante el método de Newton : $x^{k+1} = x^k + \Delta x^k$ y $\lambda^{k+1} = \lambda^k + \Delta \lambda^k$, donde (x^k, λ^k) se obtiene resolviendo el sistema de ecuaciones:

$$\nabla^2 L(x^k, \lambda^k) \begin{pmatrix} \Delta x^k \\ \Delta \lambda^k \end{pmatrix} = -\nabla L(x^k, \lambda^k) \quad (1)$$

Bajo ciertas condiciones sobre x^* (mínimo local regular) se puede asegurar que, en un entorno suyo, los puntos generados mediante (1) están bien definidos. En éste caso

$$\nabla L(x^k, \lambda^k) = \begin{pmatrix} \nabla_x L(x^k, \lambda^k) \\ h(x^k) \end{pmatrix} \text{ y } \nabla^2 L(x^k, \lambda^k) = \begin{pmatrix} H^k & N^k \\ (N^k)^T & 0_{m \times m} \end{pmatrix}$$

siendo

$$H^k = \nabla_{xx}^2 L(x^k, \lambda^k) = \nabla^2 f(x^k) + \sum_{i=1}^m \lambda_i^k \nabla^2 h_i(x^k) \text{ y } N^k = \nabla h(x^k) = (\nabla h_1(x^k), \dots, \nabla h_m(x^k))$$

Si H^k es invertible y el rango de N^k es m , podemos obtener una expresión más explícita para la iteración de Newton:

$$\lambda^{k+1} = ((N^k)^T (H^k)^{-1} (N^k))^{-1} (h(x^k) - (N^k)^T (H^k)^{-1} \nabla f(x^k))$$

$$x^{k+1} = x^k - (H^k)^{-1} \nabla_x L(x^k, \lambda^{k+1})$$

Programación Cuadrática Secuencial (SQP)

Conocido (x^k, λ^k) se determina $(\Delta x^k, \lambda^{k+1})$ resolviendo el problema cuadrático:

$$\text{PC}(x^k, \lambda^k) \text{ Min } \nabla f(x^k)^T \Delta x + \frac{1}{2} \Delta x^T H^k \Delta x$$

$$\text{s.a. } h(x^k) + (N^k)^T \Delta x = 0_m$$

Extensión para incluir restricciones de desigualdad:

$$\text{PC}(x^k, \lambda^k, \mu^k) \text{ Min } \nabla f(x^k)^T \Delta x + \frac{1}{2} \Delta x^T H^k \Delta x$$

$$\text{s.a. } h_i(x^k) + \nabla h_i(x^k)^T \Delta x = 0 \quad i = 1, \dots, m$$

$$g_j(x^k) + \nabla g_j(x^k)^T \Delta x \leq 0 \quad j = 1, \dots, r$$

$$\text{siendo } H^k = \nabla_{xx}^2 L(x^k, \lambda^k) = \nabla^2 f(x^k) + \sum_{i=1}^m \lambda_i^k \nabla^2 h_i(x^k) + \sum_{j=1}^r \mu_j^k \nabla^2 g_j(x^k)$$