

Optimización convexa:

(1)

Def: $C \subseteq \mathbb{R}^n$ es convexo si $\forall \alpha, \beta \in C \forall t \in [0, 1]$
 $(t\alpha + (1-t)\beta \in C.)$

Def: $C \subseteq \mathbb{R}^n$ es un cono convexo si C es convexo
y $\forall x \in C \forall t > 0 (tx \in C)$

Teorema: (del hiperplano de separación)

Si A, B son conjuntos convexos no vacíos en \mathbb{R}^n

$$A \cap B = \emptyset \Rightarrow \exists \begin{matrix} \vec{a} \neq 0 \\ \vec{a} \in \mathbb{R}^n \end{matrix} \quad \begin{matrix} b \in \mathbb{R} \\ \vec{a}^t x \leq b \quad \forall x \in A \\ \vec{a}^t x \geq b \quad \forall x \in B. \end{matrix}$$

Consecuencia

Todos conjunto cerrado y convexo es la intersección de los semiespacios que lo contienen.

$$C = \bigcap_{(x, H) \in I} \{x : H(x) \leq k\}$$

Def: Si C es un conjunto convexo y $z \in \overline{C} \setminus C^\circ$

y $\vec{a} \neq 0$ satisfacen $\vec{a}^t x \leq \vec{a}^t z \quad \forall x \in C$

$\Rightarrow \{x : \vec{a}^t x = \vec{a}^t z\}$ es un hiperplano de soporte de C

Consecuencia

Si $y, z \in \partial C \Rightarrow$ existe un hiperplano de soporte en z .

C es convexo y no vacío

Def: K es un cono propio si es convexo, cerrado, puntado y sólido.

$$x \preceq_K y \quad \text{ssi} \quad y - x \in K$$

$$K^* = \{y \in \mathbb{R}^n : y^t x \geq 0, \forall x \in K\}$$

Teorema: Si K es un cono propio \Rightarrow

$$(K^*)^* = K \quad \text{y el dual es propio}$$

Ejemplos: Def: Un V -poliedro es un conjunto de la forma $\text{Conv}(\{p_1, \dots, p_m\}) + \text{Cone}(\{q_1, \dots, q_s\})$ (2)

Def: Un poliedro es el conjunto de soluciones de una colección finita de desigualdades lineales $\{x \in \mathbb{R}^n : Ax \leq b\} = P$ \mathcal{H} -descripción

Teorema (Eliminación de Fourier-Motzkin): Todo \mathcal{H} -poliedro es un V -poliedro y sabemos pasar, algorítmicamente, de una descripción a la otra.

Consecuencia: Todo poliedro acotado es la clausura convexa de finitos puntos. $\#$

- Todo poliedro es la intersección de algún número positivo con un subespacio lineal.

Ejemplos:

$\{(x, t) \in \mathbb{R}^n \times \mathbb{R} : |x| \leq t\} = C_{\|\cdot\|}$

$\{(x, t) \in \mathbb{R}^n \times \mathbb{R} : |x|_* \leq t\} = C_{\|\cdot\|_*}$ $\|y\|_* = \sup\{y^t x : |x| \leq 1\}$

Si $\|\cdot\| = \|\cdot\|_2$ $C_{\|\cdot\|_2}$ se llama el cono de Lorentz.

Ejemp Los rayos externos de \mathcal{C} son los puntos de la bola unitaria $\{(x, 1) : |x|_2 = 1\}$.

Ejemplo. $S_+(V) = \{p(x) \in \text{Sym}^2(V) : p(x) \geq 0\}$ polinomios cuadráticos no negativos

$p(x) = x^t A x$, pa A simétrica $A \geq 0$. $\{x : x^t A x \leq 1\}$

Todo elemento de $S_+(V)$ es una suma de cuadrados $\sum v_i^t v_i$ $v_i \in \mathbb{R}^n$ y hay infinitos rayos externos. $\|\cdot\|$


Orden: $A \geq_s I \Leftrightarrow \lambda_{\min}(A) \geq s$. $A \leq B \Leftrightarrow \mathcal{E}_A \subseteq \mathcal{E}_B$

$\mathcal{E}_A = \{x : x^t A x \leq 1\}$

$(v, 1) \geq_{\mathcal{L}}$

II. Funciones convexas:

(3)



Def: $f: \mathbb{R}^n \longrightarrow \mathbb{R}$ es convexa ssi

① $\text{dom}(f)$ es un conjunto convexo

② $\forall \alpha, \beta \in \text{dom}(f) \quad \forall t \in [0, 1] \quad f(t\alpha + (1-t)\beta) \leq tf(\alpha) + (1-t)f(\beta)$

Obs: Si: $x \in \text{dom}(f)$ define $g_x(t) = f(x + tv)$, $v \in \mathbb{R}^n$
 f es convexa ssi g_x lo es $\forall x$. Def: $\text{Epi}(f) = \{(x, y) : y \geq f(x)\}$
Teo: f convexa

Teorema: Sea $f: \mathbb{R}^n \longrightarrow \mathbb{R}$ una función con dominio abierto y convexo.

① Si f es diferenciable entonces

f convexa ssi $\forall y, x \in \text{dom}(f) \quad (f(y) \geq f(x) + \nabla f(x)^T (y-x))$

② Si f es dos veces diferenciable entonces

f convexa ssi $H_f(x) \succeq 0 \quad \forall x \in \text{dom}(f)$.

③ f es convexa ssi $\{(x, y) : y \geq f(x)\}$ es convexo.

Obs: La desigualdad de Jensen es la definición de convexidad

$$f(\theta_1 x_1 + \dots + \theta_n x_n) \leq \theta_1 f(x_1) + \dots + \theta_n f(x_n)$$

$$f(\mathbb{E}[X]) \leq \mathbb{E}[f(X)].$$

Cómo construir funciones convexas?

Teorema:

① Si $\{g_\alpha: \mathbb{R}^n \longrightarrow \mathbb{R}, \text{dom}(g_\alpha) \text{ conv}\}$ son funciones convexas $\Rightarrow g(x) = \sup_{\alpha \in I} g_\alpha(x)$ es convexa

② Si $f(x, y): \mathbb{R}^{m_1} \times \mathbb{R}^{m_2} \longrightarrow \mathbb{R}$ es convexa $\Rightarrow g(x) = \inf_{y \in D} f(x, y)$ D convexo es una función convexa.

Reglas de composición:

(4)

$$\text{Si } h: \mathbb{R}^k \longrightarrow \mathbb{R}$$

después

$$f: \mathbb{R}^n \longrightarrow \mathbb{R}$$

$$g_i: \mathbb{R}^n \longrightarrow \mathbb{R}$$

diferenciables

$$f(x) = h(g_1(x), \dots, g_k(x))$$

tenemos:

$$\mathcal{H}(f)(x) = g'(x)^t [\mathcal{H}(h)(g(x))] g'(x) + \sum_{i=1}^k \frac{\partial h}{\partial y_i}(g(x)) \cdot \mathcal{H}(g_i)(x)$$

luego,

(Cuando la composición es convexa)

Teorema:

① Si h es convexa y no decreciente en cada argumento (i.e. $\frac{\partial h}{\partial y_i} \geq 0 \forall i$) y las g_i son convexas $\Rightarrow f$ es convexa

② Si h es convexa y no creciente en cada argumento (i.e. $\frac{\partial h}{\partial y_i} \leq 0 \forall i$) y las g_i son cóncavas $\Rightarrow f$ es convexa.

Convexidad respecto a conos:

Suponga $K \subseteq \mathbb{R}^m$ es un cono propio

Def: $f: \mathbb{R}^n \longrightarrow \mathbb{R}^m$ es una función K -convexa si

① $\text{dom}(f)$ es convexo

② $\forall \alpha, \beta \in \text{dom}(f), \forall t \in [0, 1]$

$$f(t\alpha + (1-t)\beta) \preceq_K t f(\alpha) + (1-t) f(\beta)$$

Note que Jensen también tiene sentido en conos

$$f(\mathbb{E}[X]) \preceq_K \mathbb{E}[f(X)]$$

Lema: (Reducido a convexidad usual)

$f: \mathbb{R}^n \longrightarrow \mathbb{R}^m$ es K -convexa ssi

$\forall \lambda \in K^*$ $h_\lambda: \mathbb{R}^n \longrightarrow \mathbb{R}$ es convexa

$$h_\lambda(x) = \lambda^t f(x)$$

Ejemplos:

(5)

① Las normas son convexas

② $f(x) = \log(e^{x_1} + \dots + e^{x_n})$ es convexa

[Note que $\max\{x_1, \dots, x_n\} \leq f(x) \leq \max\{x_1, \dots, x_n\} + \log(n)$
así que $f(x)$ es una "versión diferenciable" del máximo]

Dem de convexidad:

Calculamos

$$H(f)(x) = \frac{1}{\sum^2} \left[\sum \begin{bmatrix} e^{x_i} & 0 \\ 0 & e^{x_i} \end{bmatrix} - \begin{bmatrix} e^{x_i} & x_j \\ e^{x_i} & e^{x_j} \end{bmatrix} \right]$$

Vemos la forma cuadrática asociada $v^t H(f)(x) v$:

$$\frac{1}{\sum^2} \left[\left(\sum_{i=1}^n e^{x_i} \right) (v_1^2 e^{x_1} + \dots + v_n^2 e^{x_n}) - \left(\sum_{i=1}^n v_i e^{x_i} \right)^2 \right]$$

no negativa por Cauchy-Schwartz ó porque

$$v_1^2 \frac{e^{x_1}}{\sum} + \dots + v_n^2 \frac{e^{x_n}}{\sum} = \mathbb{E}[Z^2] \quad \text{Jensen}$$

$$\text{donde } \mathbb{P}\{Z = v_i\} = \frac{e^{x_i}}{\sum} \quad \text{y} \quad \mathbb{E}[Z^2] \geq (\mathbb{E}[Z])^2$$

③ $f(X) = \lambda_{\max}(X)$ para X una matriz simétrica.
es convexa

Dem: $\lambda_{\max}(X) = \sup \{ v^t X v : \|v\|_2 \leq 1 \}$

y la función $X \rightarrow v^t X v$ para v fijo
es lineal y luego convexa en X .

④ Lema del complemento de Schur: ⑥

Suponga que $X = \begin{bmatrix} A & B \\ B^t & C \end{bmatrix}$ simétrica

entonces $X \succ 0$ ssi $A \succ 0$ y $S = C - B^t A^{-1} B \succ 0$

↑
Complemento de Schur de C en X.

Dem: Si $A \succ 0$ entonces para todo v

la función $u^t A u + 2v^t B^t u + v^t C v = g(u)$

es convexa y por lo tanto alcanza su mínimo cuando

$\nabla g(u) = 0$, es decir si $u = -A^{-1} B v$.

substituyendo tenemos $\inf_u g(u) = v^t S v$.

Luego $A \succ 0$ y $S \succ 0 \Rightarrow X \succ 0$.

Recíprocamente, si $X \succ 0 \Rightarrow \begin{pmatrix} u \\ v \end{pmatrix}^t X \begin{pmatrix} u \\ v \end{pmatrix}$ es una

función convexa en (u, v) luego $\inf_u g(u) = v^t S v$

es convexa y concluimos $S \succ 0$. Como el mínimo

se alcanza $X \succ 0 \Rightarrow S \succ 0$.

para $v \in \mathbb{N}$ fijo

⑤ Si $g_1(x), \dots, g_k(x)$ son funciones convexas \forall de \mathbb{R}^n

$f(x) = [g(x)]_{[1]} + \dots + [g(x)]_{[r]}$ donde $\begin{cases} g(x)_{[i]} = \text{"i-ésima"} \\ \text{componente} \\ \text{más grande} \\ \text{del vector} \\ g(x) = (g_1(x), \dots, g_k(x)) \end{cases}$

$f(x)$ es convexa.

Dem: $h(z_1, \dots, z_k) := z_{[1]} + \dots + z_{[r]} = \max \left(z_{i_1} + \dots + z_{i_r} : \{i_1, \dots, i_r\} \subseteq [1, \dots, k] \right)$

es convexa porque es supremo de funciones lineales y

h es no decreciente en cada argumento.

Como las g_i son convexas la composición

$f(x) = h(g_1(x), \dots, g_k(x))$ es convexa.

⑥ La función $f(X) = XX^t$ con $X \in \mathbb{R}^{n \times m}$ ⑦
es $S_+^+(n)$ -convexa.

Dem: Basta probar que $\lambda^t f$ es convexa para
los rayos extremales del cono $S_+^*(n) = S_+(n)$.
éstos corresponden a las matrices zz^t

$$\lambda^t f = \text{tr} (zz^t XX^t) = \|Xz\|_2$$

ésta es una composición de la función convexa $\|\cdot\|_2$
y una función lineal $X \rightarrow Xz$ luego convexa en X
y el resultado se sigue.

Def: Un problema de optimización en \mathbb{R}^n (8)
 consiste en calcular $x \in \mathbb{R}^n$,

$$(P) \quad P_* = \inf \left\{ f_0(x) : \begin{array}{l} f_i(x) \leq 0, \quad 1 \leq i \leq m \\ h_i(x) = 0, \quad 1 \leq i \leq p \end{array} \right\}$$

$$D = \bigcap_{i=1}^m \text{dom}(f_i) \cap \bigcap_{i=1}^p \text{dom}(h_i) \quad // \quad F$$

El problema se dice factible si $\{x \in \mathbb{R}^n : \begin{array}{l} f_i(x) \leq 0 \\ h_i(x) = 0 \end{array}\} \neq \emptyset$
soluble si el infimo se alcanza en algún punto de F .

P_* es el valor óptimo y cualquier punto factible donde P_* se alcance es una solución óptima

Def: (P) es convexo si

- (i) $f_i(x), \quad 0 \leq i \leq m$ son funciones convexas
- (ii) $h_i(x), \quad 1 \leq i \leq p$ son funciones afines.

d En qué sentido son especiales los problemas convexos?

Teorema: Si (P) es un problema convexo, entonces

① Todo óptimo local es un óptimo global

(i.e. si x es factible y existe un $R > 0$:
 $f_0(x) = \inf \{ f_0(z) : z \text{ es factible } \|z-x\|_2 \leq R \}$
 $\Rightarrow x$ es una solución óptima)

② Si f_0 es diferenciable entonces un punto factible x es óptimo ssi

$$\nabla f_0(x)^t (y-x) \geq 0 \quad \forall y \in F$$

Ejemplos: (Condiciones de optimalidad permiten encontrar algunas veces la solución) (9)

① Sin restricciones, $f_0(x)$ ^{convexa y} diferenciable con dominio abierto.
 $x \in \text{dom}(f_0)$ es óptimo ssi $\nabla f(x_0) \equiv 0$ (equivalencia en dom(f_0))

Ej: $f_0(x) = - \sum_{i=1}^m \log(b_i - a_i^t x)$ $\nabla f(x_0)^t (y - x_0) \geq 0$
 $\forall y \in \text{dom}(f)$

con $\text{dom}(f_0) = \{x: Ax < b\} \leftarrow$ abierto.

x^* es óptimo ssi x^* satisface:

$Ax^* < b, \quad \nabla f_0(x^*) = \sum_{i=1}^m \frac{1}{b_i - a_i^t x^*} \vec{a}_i = 0$

② Optimización sobre el ortante positivo

$P_* = \inf \{ f_0(x) : x \geq 0 \},$ f_0 convexa $\text{dom}(f_0) = \mathbb{R}^n$
Optimalidad
 $\nabla f_0(x^*)^t (y - x^*) \geq 0 \quad \forall y \geq 0 \Rightarrow$ (i) $\nabla f_0(x^*) \geq 0$
(ii) $\nabla f_0(x^*)^t x^* \geq 0$

• Esta idea es muy útil para minimización parcial (sólo con respecto a algunas de las variables):

$y \geq x^* \geq 0$
 $\Rightarrow x_i^* \left(\nabla f_0(x^*) \right)_i = 0$

* Ejemplo: Si $\begin{bmatrix} P_{11} & P_{12} \\ P_{12}^t & P_{22} \end{bmatrix} \succ 0$, encuentre

$\min x_1^t P_{11} x_1 + 2x_1^t P_{12} x_2 + x_2^t P_{22} x_2$ s.a. $f_i(x_1) \leq 0 \quad 1 \leq i \leq m$

$\inf \{ f_0(x_1, x_2) : f_i(x_1) \leq 0, 1 \leq i \leq m \} = \inf \{ \tilde{f}_0(x_1) : f_i(x_1) \leq 0 \}$
con $\tilde{f}_0(x_1) = \inf_{x_2} f_0(x_1, x_2)$

en este caso $\inf_{x_2} f_0(x_1, x_2) \stackrel{\text{Cálculo analítico}}{=} x_1^t \begin{bmatrix} P_{11} - P_{12} P_{22}^{-1} P_{12}^t \\ P_{12}^t \end{bmatrix} x_1$

Porque $\nabla_{x_2} f_0(x_1, x_2) = 2 \begin{bmatrix} P_{22} x_2 + P_{12}^t x_1 \end{bmatrix} = 0$
 $\Rightarrow x_2^* = -P_{22}^{-1} P_{12}^t x_1 \Rightarrow \tilde{f}_0(x_1) = f_0(x_1, x_2^*)$

y el problema se reduce a:

$\min x_1^t \begin{bmatrix} P_{11} - P_{12} P_{22}^{-1} P_{12}^t \end{bmatrix} x_1 : f_i(x_1) \leq 0, 1 \leq i \leq m.$

Algunos problemas de optimización convexa: 10

I. Optimización lineal $\min \{c^t x : Ax \leq b\}$

Ejemplos: ① Problema de la dieta.

① (Centro de Chebyshev) ¿Cuál es la bola euclidiana de máximo radio que cabe en un polihedro?

Variables (\vec{x}_c, r) centro y radio de la bola.

$$B(\vec{x}_c, r) \subseteq \{x : a^t x \leq d\} \text{ ssi}$$

$$a^t(\vec{x}_c + ry) \leq d \quad \forall y : \|y\|_2 \leq 1 \text{ ssi}$$

$$\boxed{\forall \|a^t\|_2 \leq d - a^t \vec{x}_c}$$

↑
desigualdad LINEAL.

② (Desigualdades de Chebyshev para distribuciones discretas)


Si $p_i = P\{X = u_i\}$, $X(\omega) \in [n]$.

$\{(p_1, \dots, p_n) : p_i \geq 0, \sum_{i=1}^n p_i = 1\}$ es el simplex de probabilidad

y para cualquier función f , $E[f(X)] = \sum_{i=1}^n p_i f(u_i)$

es lineal dándonos: objetivo y restricciones.

③ (Max-flow)



¿Cuál es el máximo flujo de s a t si tenemos capacidades límite conocidas c_{ij} en cada arista?

II. Optimización cuadrática

$$\min \{x^t P x + q^t x + r : \begin{cases} q^t x \leq k \\ Ax = b \end{cases}\}$$

$$x^t b =$$

Ejemplos:

① (mínimos cuadrados) $\min \|Ax - b\|_2 = \langle Ax - b, Ax - b \rangle =: f_0(x) = x^t A^t A x - 2b^t A x + b^t b$

$$\nabla f_0(x) = 2A^t A x - 2b^t A$$

$$\nabla f_0(x) = 2A^t A x - 2b^t A = 0$$

$$x^* = [A^t A]^{-1} A^t b$$

$$x_1 p_{i+} + x_n p_n = \frac{p_i}{p_0} (p_i - p_0)$$

② (Markowitz)

n activos
 p_i — precio relativo
 x_i — monto en USD del patrimonio en cada activo.
 $\frac{p_i - p_0}{p_0}$ # unidades de riesgo i

Assumimos que p es V.A. con media \bar{p} y $\textcircled{11}$

$$\alpha \leq \mathbb{E} \left[\left[\sum_{i=1}^n d_i (p_i - \bar{p}_i) \right]^2 \right] = \alpha^t \Sigma \alpha$$

$(x_1, \dots, x_n) \in \mathbb{R}^n$

$$\min \left\{ \alpha^t \Sigma \alpha : \begin{array}{l} \bar{p}^t \alpha \geq q \\ x_i \geq 0 \\ \sum x_i = B \end{array} \right\}$$

$$\left[\sum_{i=1}^n d_i (p_i - \bar{p}_i) \right]^2 = \sum_{i,j} d_i d_j \mathbb{E}[(p_i - \bar{p}_i)(p_j - \bar{p}_j)]$$

ⓑ. Second order cone programs

$$\min \left\{ c^t x : \|Ax_i + b\|_2 \leq c_i^t x + d_i \right\}$$

$$Fx = g$$

Ejemplos:

① Robust Linear programming

$$\min \left\{ c^t x : a_i^t x \leq b_i \quad 1 \leq i \leq m \right\} +$$

Incertidumbre en los parámetros \vec{a}_i solo conocidas

Sabemos que $\vec{a}_i \in \mathcal{E}_i := \left\{ \vec{a}_i + \vec{P}_i u_i : \|u_i\|_2 \leq 1 \right\}$

(Programa lineal robusto)

$$\min c^t x$$

$$\text{s.t.} \quad \sup_{a_i \in \mathcal{E}_i} (a_i^t x) \leq b_i \quad u^t P^b x$$

$$\sup (a_i^t x : a_i \in \mathcal{E}_i) = \sup \left\{ \vec{a}_i^t x + (P_i u_i)^t x : \|u_i\|_2 \leq 1 \right\}$$

$$= \left[\vec{a}_i^t x + \|P_i^t x\|_2 \leq b_i \right]$$

Second order cone constraint en x .

② Superficies minimales:

Si $f: \mathbb{R}^2 \rightarrow \mathbb{R}$ es diferenciable

$$A = \iint_C \sqrt{1 + \|\nabla f\|^2} dA \quad \min \{ A(f) : f|_{\partial D} = g \}$$

Resolvamos mediante dualidad:

(12)

$$\nabla f(x) \approx \frac{1}{k} \begin{bmatrix} f_{i+1,j} - f_{i,j} \\ f_{i,j+1} - f_{i,j} \end{bmatrix} \quad \left\| \begin{pmatrix} \frac{f_{i+1,j} - f_{i,j}}{k} \\ \frac{f_{i,j+1} - f_{i,j}}{k} \end{pmatrix} \right\|$$

$$A(f) \approx \sum_{i,j=0}^{k-1} \frac{1}{k^2} \left\| \begin{pmatrix} 1 \\ \text{disc } \nabla f \end{pmatrix} \right\|$$

Valores de la frontera son restringidos en $f_{i,j}$.

$$\min \sum_{i,j} t_{i,j} :$$

$$\frac{1}{k^2} \left\| \begin{pmatrix} \text{disc } \nabla f \\ 1 \end{pmatrix} \right\| \leq t_{i,j} \quad i,j=0, \dots, k$$

$$\left. \begin{array}{l} f_{0,j} = l_j \\ f_{k,j} = r_j \end{array} \right\} \leftarrow \text{condiciones de frontera.}$$

$\lim_{k \rightarrow \infty} h$ es el óptimo.

IV Programación semidefinida Problemas manuales es igual?

$$\min \left\{ \text{tr}(CX) : \text{tr}(A_i X) = b_i, X \succeq 0 \right\}$$

$$\min \left\{ c^T x : x_1 A_1 + \dots + x_n A_n \preceq B \right\}$$

Ejemplo:

① Encuentra el valor mínimo que puede tener el máximo valor propio de una matriz simétrica en el espacio real $\langle A_1, \dots, A_n \rangle$.

$$\boxed{\begin{array}{l} \min s \\ x_1 A_1 + \dots + x_n A_n - sI \preceq 0 \end{array}}$$

② Si $(FMMC)$ es una matriz doblemente estocástica
 $(\sum_j A_{ij} = \sum_i A_{ij} = 1, A_{ij} \geq 0)$ ③

entonces el vecd de unos es un vecd propio con
 valor propio 1.

$$1 \geq \lambda_2 \geq \dots \geq \lambda_n$$

$$SLEM = \max (|\lambda_i| : i \geq 2)$$

Dado un grafo G .

P_{ij} sucesiva, no negativa $\mathbb{1}^t P = \mathbb{1}$

$P_{ij} = 0, i \neq j \in E(G)$.

$$P - \frac{1}{n} \mathbb{1}\mathbb{1}^t$$

min t :

$$-tI \leq P - \frac{1}{n} \mathbb{1}\mathbb{1}^t \leq tI$$

restamos al
 concepto original, sigue
 siendo sucesiva.

$$\begin{bmatrix} P \mathbb{1} = \mathbb{1} \\ P_{ij} \geq 0 \end{bmatrix} \leftarrow \text{requisitos a este.}$$

seal hall
 en \mathbb{R}^n $\begin{bmatrix} P \\ \vdots \\ \mathbb{1} \end{bmatrix} \geq 0 \Leftrightarrow P \geq 0$ y

$$\begin{bmatrix} n & \dots & \mathbb{1} \\ \vdots & P & \vdots \end{bmatrix} \geq P - \frac{\mathbb{1}\mathbb{1}^t}{n} \geq 0$$

~~PSI~~

Optimización vectorial

Fijo $K \in \mathbb{R}^m$ como
Propo

$$K\text{-min } \left\{ f_0(x) : \begin{array}{l} f_i(x) \leq 0, \quad 1 \leq i \leq m \\ h_i(x) = 0, \quad 1 \leq i \leq p \end{array} \right\} \quad (\text{PV})$$

$$O = \left\{ f_0(x) : x \in F \right\} \subseteq \mathbb{R}^m$$

Def: x^* es un punto óptimo si
 $f_0(x^*)$ es mínimo de O



Def: x^* es óptimo en el sentido de Pareto si
 $f_0(x^*)$ es minimal en O .

Como encontrar óptimo de Pareto?

Lema 1 Si $\lambda \in \text{int}(K^*)$ y el problema Escalar

$$\min \left\{ \lambda^t f_0(x) : \begin{array}{l} f_i(x) \leq 0, \quad 1 \leq i \leq m \\ h_i(x) = 0, \quad 1 \leq i \leq p \end{array} \right\}$$

tiene una solución óptima $x^* \Rightarrow x^*$
es óptimo de Pareto del problema vectorial.

② Si (PV) es convexo (i.e. f_0 K -convexo y

\Rightarrow todo óptimo de Pareto puede

calcularse a partir de escalarización

con algún $\lambda \in \text{int}(K^*)$.

Ejemplo:

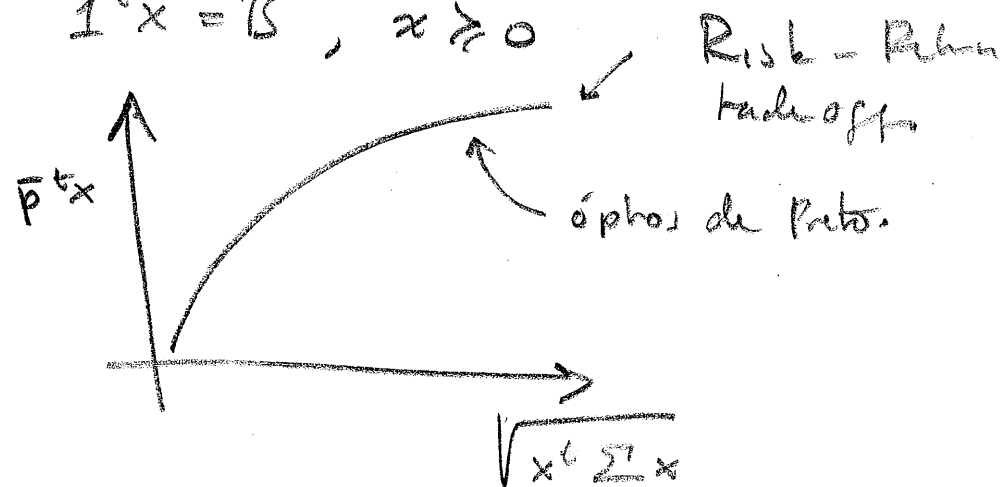
$$\min_{x \in \mathbb{R}_+^2} \left(\overset{\text{⑮ pérdida}}{\underbrace{-\bar{p}^t x}} , \underbrace{x^t \Sigma^t x}_{\text{riesgo}} \right)$$

s.a. $\mathbf{1}^t x = B, x \geq 0$

Escalamos:

$$\min \lambda_1 (-\bar{p}^t x) + \lambda_2 (x^t \Sigma^t x)$$

s.a. $\mathbf{1}^t x = B, x \geq 0$



Dualidad: Considere el problema de optimización general (6)

Def $P_* = \inf \left\{ f_0(x) : \begin{array}{l} f_i(x) \leq 0, 1 \leq i \leq m \\ h_i(x) = 0, 1 \leq i \leq p \end{array} \right\} \quad (PQ)$

$$\mathcal{D} = \bigcap_{i=0}^m \text{dom}(f_i) \cap \bigcap_{i=1}^p \text{dom}(h_i).$$

Def: • El Lagrangiano de (PQ) es

$$L(x, \lambda, \nu) : \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p \longrightarrow \mathbb{R}$$

$$f_0(x) + \sum \lambda_i f_i(x) + \sum \nu_i h_i(x)$$

sober TODO el dominio, no el caso factible.

• El problema dual Lagrangiano

$$d^* = \sup \left\{ g(\lambda, \nu) : \begin{array}{l} \lambda \geq 0 \text{ en } \mathbb{R}^m \\ \nu \in \mathbb{R}^p \end{array} \right.$$

$$g(\lambda, \nu) = \inf \left\{ L(x, \lambda, \nu) : x \in \mathcal{D} \right\}$$

Teorema

(Dualidad)

① $d^* \leq P_*$

(dualidad débil)

[El valor de la función objetivo en cualquier punto factible del dual Lagrangiano es $\leq P_*$]

② Si (PQ) es convexo y se cumple la hipótesis de Slater ($\exists \bar{x} \in \text{relint}(\mathcal{D}) : f_i(\bar{x}) < 0, 1 \leq i \leq m$) $\Rightarrow d^* = P_*$

Caso especial $\min f_0(x)$ s.a. $Ax \leq b$ con f_0 convexa.
Si el problema es factible \Rightarrow cumple la hipótesis de Slater \Rightarrow hay dualidad fuerte.

Dem:

(17)

$$J = \{ (f_1(x), \dots, f_m(x), h_1(x), \dots, h_p(x), f_0(x)) : x \in D \}$$

$$A = \left\{ (u, v, t) : \begin{array}{l} f_i(x) \leq u_i \\ h_i(x) = v_i \\ f_0(x) \leq t \end{array} \right\} \leftarrow \begin{array}{l} \text{Conexo} \\ \text{D} \text{ y } \text{univ.} \end{array}$$

$$B = \{ (0, 0, s) : s \leq p_* \} \leftarrow \text{Conexo}$$

Obs: $g(\lambda, \gamma) = \inf \{ (\lambda, \gamma, 1)^t (u, v, t) : (u, v, t) \in A \}$
(Support pts of B).

Is there a hyperplane which supports $(0, 0, p_*) \in \overline{A}$

$$g(\lambda, \gamma) \leq (\lambda, \gamma, 1)^t (0, 0, p_*) = p_* \quad \checkmark$$

Separate Thm + Slater's qualification imply that the supporting hyperplane $(\lambda', \gamma', \eta')$ has $\eta' \neq 0$
 $(\frac{\lambda'}{\eta'}, \frac{\gamma'}{\eta'}, 1) \checkmark$

Teorema (Pe-urbanismo de problemas convexos)
Suponga que hay dualidad fuerte y ambos son solubles.

$$P_*(u, v) := \inf \left\{ f_0(x) : \begin{array}{l} f_i(x) \leq u_i \quad 1 \leq i \leq m \\ h_i(x) = v_i \quad 1 \leq i \leq p \end{array} \right\}$$

$P_*(u, v)$ es convexa

$$P_*(u, v) \geq P_*(0, 0)$$

$$- (\lambda')^t u - (\gamma')^t v$$

P_* a pun order. Cuales son los terminos de orden superior?

$$\frac{\partial P_*}{\partial u_i} = -\lambda_i'$$
$$\frac{\partial P_*}{\partial v_i} = -\gamma_i'$$

Condiciones KKT:

Si el primal y el dual son solubles y no hay duality gap entonces:

$$f_0(x^*) = g(\lambda^*, \nu^*) = \inf \{ L(x, \lambda, \nu) : x \in \mathcal{D} \}$$

$$L(x^*, \lambda^*, \nu^*) \leq f_0(x^*)$$

\Rightarrow x^* minimizes the Lagrangian
 $\lambda^* f_i(x^*) = 0 \quad \forall i$

S: f_i y h_i son diferenciables

- KKT:
- ① Factibilidad primal y dual
 - ② Complementary slackness
 - ③ $\nabla_x [L(x, \lambda^*, \nu^*)]_{x^*} = 0$

si el problema es convexo
necesarios y suficientes.

Dualidad en el caso generalizado:

$$\inf \left\{ f_0(x) : \begin{matrix} f_i(x) \leq 0 \\ h_i(x) = 0 \end{matrix} \right\}$$

Def: $L(x, \lambda, \nu) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{j=1}^p \nu_j h_j(x)$

\uparrow vectores $\lambda_1, \dots, \lambda_m$ \uparrow vectores ν_1, \dots, ν_p

$$\inf \{ L(x, \lambda, \nu) : x \in \mathcal{D} \} = g(\lambda, \nu)$$

Problema dual: $d^* = \sup \{ g(\lambda, \nu) : \lambda \succeq_{K_i} \vec{0} \}$

Teorema de dualidad análogo.