

# Optimización bajo Incertidumbre

## B. Revisión

Carlos Testuri – Germán Ferrari

Departamento de Investigación Operativa – Instituto de Computación  
Facultad de Ingeniería – Universidad de la República

2003-2022

# Contenido

- 1 Probabilidad
- 2 Álgebra lineal y geometría
- 3 Convexidad
- 4 Optimización (Programación matemática)

## Espacio de probabilidad

Espacio de probabilidad:  $(\Omega, \mathcal{A}, P)$

- Espacio muestral: conjunto  $\Omega$ , de resultados posibles  $\omega \in \Omega$  de un experimento aleatorio.
- $\sigma$ -álgebra en conjunto  $\Omega$ : clase  $\mathcal{A}$  de subconjuntos  $A \in \mathcal{A}$  (denominados eventos) del conjunto  $\Omega$ .
- Medida de probabilidad en  $\mathcal{A}$ :  $P(A) : \mathcal{A} \rightarrow [0, 1]$ .

Un espacio de probabilidad se dice que es:

- *finito*, si su espacio muestral es finito,
- *discreto*, si su espacio muestral es finito o infinito numerable,
- *general*, si su espacio muestral no es numerable.

## Variable aleatoria

Se define *variable aleatoria* en un espacio de probabilidad  $(\Omega, \mathcal{A}, P)$  como la función

$$\xi : \Omega \rightarrow \mathbb{R}.$$

Dado que el conjunto  $\xi^{-1}(r)$  (elementos de  $\Omega$  cuya imagen por  $\xi$  es el real  $r$ ) es un elemento de  $\mathcal{A}$ , entonces este tiene una probabilidad asociada  $P(\xi^{-1}(r)) = P(\xi = r)$ .

## Función de [distribución de] probabilidad

Según sea la función de probabilidad:

*Variable discreta*  $\xi$  con realizaciones  $\xi^k, k \in K$ ,

$$f(\xi^k) = P(\xi = \xi^k).$$

*Variable continua*  $\xi$  se define como

$$F_\xi(x) = P(\xi \leq x) = P(\{\omega | \xi(\omega) \leq x\}).$$

$$P(\xi \leq x) = \int_{-\infty}^x f(\xi) d\xi = \int_{-\infty}^x dF(\xi),$$

donde  $f(\xi) = \frac{dF(\xi)}{d\xi}$  es la función de densidad.

## Eventos casi seguros

Sea el espacio de probabilidad  $(\Omega, \mathcal{A}, P)$ , el evento  $A$  ocurre *casi seguramente* (abreviado “a.s.”) si  $P(A) = 1$ .

Casi-seguramente vs. seguramente

Un evento ocurre *seguramente* si siempre ocurre; es decir, ningún otro evento (aún eventos con probabilidad cero) puede ocurrir.

Si un evento ocurre *casi seguramente*, entonces otros eventos con probabilidad cero pueden ocurrir (casi nunca).

## Momentos de una variable aleatoria

El  $r$ -ésimo *momento* de la variable  $\xi$  es

$$\mu'_r = \mathbb{E}[\xi^r] = \int_{-\infty}^{\infty} \xi^r f(\xi) d\xi$$

donde  $\mu'_1 = \mu = \mathbb{E}[\xi]$  se denomina *media*.

El  $r$ -ésimo *momento central* de la variable  $\xi$  es

$$\mu_r = \mathbb{E}[(\xi - \mu)^r] = \int_{-\infty}^{\infty} (\xi - \mu)^r f(\xi) d\xi$$

donde  $\mu_2 = \mathbb{E}[(\xi - \mu)^2] = \text{Var}(\xi)$  se denomina *varianza*.

## Propiedades de esperanza y varianza

Sean  $a, b$  y  $c$  constantes,  $\xi, \xi_1$  y  $\xi_2$  variables aleatorias

- Invariante esperanza:  $\mathbb{E}[c] = c$
- Linealidad:  $\mathbb{E}[a\xi_1 + b\xi_2] = a\mathbb{E}[\xi_1] + b\mathbb{E}[\xi_2]$
- Invariante varianza:  $\text{Var}(a\xi + b) = a^2\text{Var}(\xi)$
- Vínculo esperanza y varianza:  $\text{Var}(\xi) = \mathbb{E}[\xi^2] - (\mathbb{E}[\xi])^2$
- No linealidad:  $\text{Var}(\xi_1 + \xi_2) = \text{Var}(\xi_1) + \text{Var}(\xi_2) + 2\text{cov}(\xi_1, \xi_2)$ ;  
 $\text{cov}(\xi_1, \xi_2) = \mathbb{E}[(\xi_1 - \mathbb{E}[\xi_1])(\xi_2 - \mathbb{E}[\xi_2])] = \mathbb{E}[\xi_1\xi_2] - \mathbb{E}[\xi_1]\mathbb{E}[\xi_2]$
- ¿Cuándo se dice que  $\xi_1$  y  $\xi_2$  son independientes?  
En caso de serlo su covarianza es cero y  $\mathbb{E}[\xi_1\xi_2] = \mathbb{E}[\xi_1]\mathbb{E}[\xi_2]$

## Teorema Central del Límite

Si las variables aleatorias  $X_1, \dots, X_n$  son independientes y tienen la misma distribución (iid) con esperanza  $\mu$  finita y varianza  $\sigma^2$  finita, no nula, entonces la variable aleatoria

$$Z_n = \frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}}$$

es asintóticamente normal, es decir su función de distribución  $F_n(z)$  cumple para todo  $z$

$$\lim_{n \rightarrow \infty} F_n(z) = \lim_{n \rightarrow \infty} P\left(\frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}} \leq z\right) = \mathcal{N}(0, 1).$$

## Producto interno [escalar]

El producto interno de los vectores  $v, w \in \mathbb{R}^n$  tiene como resultado el escalar

$$v \cdot w = v_1 w_1 + \dots + v_n w_n = \sum_{i=1}^n v_i w_i = v^T w.$$

Para el caso del espacio Euclidiano, el producto interno de los vectores es

$$v^T w = \|v\| \|w\| \cos(\theta),$$

donde  $\| \cdot \|$  establece la norma de los vectores y  $\theta$  el ángulo entre ellos.

¿Cuándo vale cero el producto interno de dos vectores?

¿Cuándo es positivo o negativo el producto?

## Producto interno y ecuaciones (1/2)

Dado el vector constante  $a \in \mathbb{R}^n$ .

¿Qué región del espacio describe el vector variable  $x \in \mathbb{R}^n$  tal que

1.  $a^T x = 0$  ?

2.  $a^T x \geq 0$  ?

3.  $a^T x \leq 0$  ?

## Producto interno y ecuaciones (2/2)

Dados los vectores constantes  $a, d \in \mathbb{R}^n$ .

¿Qué región del espacio describe el vector variable  $x \in \mathbb{R}^n$  tal que

$$a^T(x + d) = 0 ?$$

Equivalentemente:

$$a^T x = -a^T d$$

Sea  $b := -a^T d$ ,

$$a^T x = b$$

## Hiperplano y semiespacio

Dados el vector  $a \in \mathbb{R}^n$ , el escalar  $b \in \mathbb{R}$  y el vector variable  $x \in \mathbb{R}^n$  se define el *hiperplano afín*

$$a^T x = \sum_{i=1}^n a_i x_i = b,$$

y los *semiespacios afines*

$$a^T x = \sum_{i=1}^n a_i x_i \leq b,$$

$$a^T x = \sum_{i=1}^n a_i x_i \geq b.$$

## Conjunto convexo

Sea  $C$  un subconjunto de  $\mathbb{R}^n$ . Se dice que  $C$  es *convexo* si para todo  $x, y \in C$ , y para todo  $\lambda \in [0, 1]$ , se cumple

$$\lambda x + (1 - \lambda)y \in C.$$

## Combinación convexa y Casco convexo

Sean  $x_1, \dots, x_k$  vectores de  $\mathbb{R}^n$ , y  $\lambda_1, \dots, \lambda_k$  escalares no negativos cuya suma es uno,

- se denomina *combinación convexa* de  $x_1, \dots, x_k$  al vector  $\sum_{i=1}^k \lambda_i x_i$
- se denomina *casco convexo* de los vectores de  $x_1, \dots, x_k$ , al conjunto de todas sus combinaciones convexas. Dicho conjunto se denota  $\text{conv}(\{x_1, \dots, x_k\})$ .

## Convexidad: propiedades

- La intersección de conjuntos convexos es convexa.
- El conjunto  $P = \{x \in \mathbb{R}^n : Ax \leq b\}$ , denominado *poliedro*, es un conjunto convexo.
- La combinación convexa de un número finito de elementos de un conjunto convexo pertenece al conjunto.
- El casco convexo de un número finito de vectores es un conjunto convexo.

## Función convexa

Sea  $C$  subconjunto convexo de  $\mathbb{R}^n$ . Se dice que la función  $f : C \rightarrow \mathbb{R}$  es *convexa* si para todo  $x, y \in C$ , y para todo  $\lambda \in [0, 1]$ , se cumple

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y).$$

## Desigualdad de Jensen

Establece una cota de una función convexa de una integral con la integral de la función convexa.

Ejemplo: la transformación convexa de la media es menor o igual a la media de la transformación convexa.

Sean la variable aleatoria  $\xi$  y la función convexa  $f(\cdot)$  se cumple

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

## Optimización Lineal

Caso funciones lineales en términos de variables continuas.

Dados los parámetros: matriz  $A \in \mathbb{R}^{m \times n}$ , y los vectores columnas  $b \in \mathbb{R}^m$  y  $c \in \mathbb{R}^n$  y la variable de decisión: vector columna  $x \in \mathbb{R}^n$ ,

$$\begin{array}{ll} \min & c^T x \\ \text{s.a} & Ax = b \\ & x \geq 0. \end{array}$$

Donde  $x^*$  es  $\left\{ \begin{array}{ll} \text{solución,} & \text{si } Ax^* = b \\ \text{solución factible,} & \text{si es solución y } x^* \geq 0 \\ \text{solución óptima,} & \text{si es factible y } c^T x^* \leq c^T x, \forall x \text{ factible.} \end{array} \right.$

Problemas *factible*, *no factible* y *no acotado*.

# Optimización Lineal: Equivalencias y reducciones en formulación

## Equivalencias

Sea la fila  $i$ -ésima de la matriz  $A$ ,  $a_i$ ,

1. la restricción de igualdad  $a_i^T x = b_i$  es equivalente a las restricciones  $a_i^T x \leq b_i$  y  $a_i^T x \geq b_i$ ,
2. la restricción  $a_i^T x \leq b_i$  es equivalente a  $-a_i^T x \geq -b_i$ ,
3. el objetivo  $\min c^T x$  es equivalente al objetivo  $-\max -c^T x$ .

## Reducciones

1. *eliminación de variable libre*: la variable  $x_j$  no restringida en signo se reemplaza por la diferencia de dos variables no negativas,  $x_j^+ - x_j^-$ .
2. *eliminación de restricción de desigualdad*: dada  $\sum_{j=1}^n a_{ij}x_j \leq b_i$ , se agrega una nueva variable (de *holgura*),  $s_i \geq 0$ , tal que  $\sum_{j=1}^n a_{ij}x_j + s_i = b_i$ . Similarmente, para la otra desigualdad, se agrega una variable de *exceso* que se resta a la restricción.

## Optimización Lineal: condiciones de optimalidad

En el poliedro  $P = \{x : Ax = b, x \geq 0\}$  las soluciones están determinadas por los puntos extremos y rayos extremos.

Particionando  $A = [B, N]$ , donde  $B$  es base; además,  $x = [x_B, x_N]$  y  $c = [c_B, c_N]$  se tiene la solución básica  $x_B = B^{-1}b, x_N = 0$ , con valor  $c_B^T B^{-1}b$ .

Condición de *factibilidad*, dada por  $x_B = B^{-1}b \geq 0$

Condición de *optimalidad*, dada por  $c_N^T - c_B^T B^{-1}N \geq 0$ .

## Optimización Lineal: Dualidad

Propiedad algebraica que establece problemas equivalentes:

$$\begin{array}{c}
 \textit{Primal} \\
 \hline
 \min \quad c^\top x \\
 \text{s.a} \quad Ax = b \\
 \quad \quad x \geq 0.
 \end{array}
 \rightarrow
 \begin{array}{c}
 \textit{Dual} \\
 \hline
 \max \quad \pi^\top b \\
 \text{s.a} \quad \pi^\top A \leq c^\top.
 \end{array}$$

## Optimización Lineal: Propiedades de dualidad

- *Dualidad débil*

Sean  $\hat{x}$  primal factible y  $\hat{\pi}$  dual factible  $\Rightarrow c^T \hat{x} \geq \hat{\pi}^T b$

- *Dualidad fuerte*

Existe  $x^*$  sol. óptima  $\Leftrightarrow$  existe  $\pi^*$  sol. óptima, con  $c^T x^* = (\pi^*)^T b$ .

## Optimización Lineal: relación valor objetivo entre primal y dual

<b>Primal \ Dual</b>	Finito	No-acotado	No-factible
Finito	✓	×	×
No-acotado	×	×	✓
No-factible	×	✓	✓

# Algoritmos

Los problemas de optimización se resuelven mediante algoritmos.

Una *instancia* de un problema se define a partir de datos que la especifican.

El problema comprende la colección de todas sus instancias.

Un *algoritmo* de resolución es un conjunto finito y ordenado de instrucciones que se diseña para un problema pero se aplica a sus instancias.

Los algoritmos emplean los recursos tiempo y espacio (memoria). El uso de los recursos depende de la dificultad y tamaño de las instancias.

## Optimización Lineal: Algoritmo simplex (resumen)

El método itera de una solución (punto extremo) a otra reduciendo el valor de la función objetivo hasta que llega a la solución óptima.

La codificación computacional del método pone especial énfasis en el cálculo de la inversa de la base y en evitar quedar atrapado en secuencias de iteración con cambio de base sin reducción de valor en la función objetivo, debido a la presencia de *degeneración*.

La complejidad computacional teórica (peor caso) es exponencial en el número de variables y restricciones.

En la práctica es muy eficiente, en promedio la complejidad es proporcional al número de restricciones.

## Optimización Lineal: Algoritmo simplex

### Iteración de algoritmo simplex

1. Obtener la base  $B := A_{B(1)}, \dots, A_{B(m)}$ , calcular su inversa  $B^{-1}$  y su solución básica  $x_B := B^{-1}b$ .
2. Calcular el valor dual  $\pi^\tau := c_B^\tau B^{-1}$  y los costos reducidos  $\hat{c}_j := c_j - \pi^\tau A_j$ , para todo  $j$ . Si todo  $\hat{c}_j \geq 0$ , la solución es óptima, *Parar*; sino, seleccionar algún  $j$  para el que  $\hat{c}_j < 0$ .
3. Calcular  $u := B^{-1}A_j$ . Si ningún componente de  $u$  es positivo, el valor óptimo es  $-\infty$ , el problema es no acotado, *Parar*.
4. Si alguno de los componentes de  $u$  es positivo, calcular  $\theta^* := \min_{\{i=1, \dots, m: u_i > 0\}} x_{B(i)} / u_i$ .
5. Sea  $k$  el índice donde  $\theta^* = x_{B(k)} / u_k$ . Construir la nueva base reemplazando  $A_{B(k)}$  con  $A_j$ . Ir al paso 1.

## Optimización No Lineal

Caso funciones no lineales de variables continuas.

Dadas la variable de decisión  $x \in \mathbb{R}^n$  y las funciones  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  y  $h : \mathbb{R}^n \rightarrow \mathbb{R}^l$ . Se asume que  $f(x)$  es convexa y que la región factible es cerrada y convexa,

$$\begin{aligned} \min \quad & f(x) \\ \text{s.a} \quad & g_j(x) \leq 0, \quad j = 1, \dots, m, \\ & h_i(x) = 0, \quad i = 1, \dots, l. \end{aligned}$$

Si existen derivadas direccionales de  $f(x)$ , entonces es diferenciable, con gradiente  $\nabla f(x)$ ; en caso contrario, se establecen subgradienes, cuyo conjunto es el subdiferencial  $\partial f(x)$ .

## Optimización No Lineal: condiciones de optimalidad

Condición necesaria: Karush-Kuhn-Tucker (KKT)

Sea  $x^*$  mínimo local regular, donde  $f$ ,  $g$  y  $h$  son diferenciables continuas. Entonces existen multiplicadores de Lagrange únicos  $\lambda^*$  y  $\mu^*$  tales que

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

$$\mu_j^* g_j(x^*) = 0, \quad j = 1, \dots, m$$

$$\mu_j^* \geq 0, \quad j = 1, \dots, m.$$

# Optimización Entera

Trata del modelado y resolución de problemas con variables discretas:

- enteras: indivisibilidad,
- binarias: decisiones.

Características:

- Formulaciones más representativas y flexibles del problema
- Explosión combinatoria de soluciones factibles
- Resolución más difícil que optimización lineal; no se conoce método eficiente general de resolución.