

Análisis Numérico

Primer cuatrimestre 2023

Cuadrados mínimos

- 1 Aproximación en un espacio con producto interno
- 2 Ejemplo 1: aproximación de funciones continuas por polinomios
- 3 Ejemplo 2: ajuste en L^2 por funciones de forma dadas
- 4 Data-fitting

- 1 Aproximación en un espacio con producto interno
- 2 Ejemplo 1: aproximación de funciones continuas por polinomios
- 3 Ejemplo 2: ajuste en L^2 por funciones de forma dadas
- 4 Data-fitting

Producto interno

Sea V un espacio vectorial. Recordemos que

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$$

es un *producto interno* en V si para todo $x, y, z \in V$, $\alpha \in \mathbb{R}$ tenemos

- $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$
- $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$
- $\langle x, y \rangle = \langle y, x \rangle$
- $\langle x, x \rangle > 0$ si $x \neq 0$

Producto interno

Sea V un espacio vectorial. Recordemos que

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$$

es un *producto interno* en V si para todo $x, y, z \in V$, $\alpha \in \mathbb{R}$ tenemos

- $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$
- $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$
- $\langle x, y \rangle = \langle y, x \rangle$
- $\langle x, x \rangle > 0$ si $x \neq 0$

Algunos ejemplos:

Producto interno

Sea V un espacio vectorial. Recordemos que

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$$

es un *producto interno* en V si para todo $x, y, z \in V$, $\alpha \in \mathbb{R}$ tenemos

- $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$
- $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$
- $\langle x, y \rangle = \langle y, x \rangle$
- $\langle x, x \rangle > 0$ si $x \neq 0$

Algunos ejemplos:

- $V = \mathbb{R}^n$, $\langle x, y \rangle = x_1y_1 + x_2y_2 + \cdots + x_ny_n$

Producto interno

Sea V un espacio vectorial. Recordemos que

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$$

es un *producto interno* en V si para todo $x, y, z \in V$, $\alpha \in \mathbb{R}$ tenemos

- $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$
- $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$
- $\langle x, y \rangle = \langle y, x \rangle$
- $\langle x, x \rangle > 0$ si $x \neq 0$

Algunos ejemplos:

- $V = \mathbb{R}^n$, $\langle x, y \rangle = x_1y_1 + x_2y_2 + \cdots + x_ny_n$
- $V = \mathbb{R}^n$, $\langle x, y \rangle = w_1x_1y_1 + w_2x_2y_2 + \cdots + w_nx_ny_n$ (con $w_i > 0 \forall i$)

Producto interno

Sea V un espacio vectorial. Recordemos que

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$$

es un *producto interno* en V si para todo $x, y, z \in V$, $\alpha \in \mathbb{R}$ tenemos

- $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$
- $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$
- $\langle x, y \rangle = \langle y, x \rangle$
- $\langle x, x \rangle > 0$ si $x \neq 0$

Algunos ejemplos:

- $V = \mathbb{R}^n$, $\langle x, y \rangle = x_1y_1 + x_2y_2 + \cdots + x_ny_n$
- $V = \mathbb{R}^n$, $\langle x, y \rangle = w_1x_1y_1 + w_2x_2y_2 + \cdots + w_nx_ny_n$ (con $w_i > 0 \forall i$)
- $V = \mathcal{C}([a, b])$, $\langle f, g \rangle = \int_a^b f(x)g(x) dx$

Producto interno

Sea V un espacio vectorial. Recordemos que

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$$

es un *producto interno* en V si para todo $x, y, z \in V$, $\alpha \in \mathbb{R}$ tenemos

- $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$
- $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$
- $\langle x, y \rangle = \langle y, x \rangle$
- $\langle x, x \rangle > 0$ si $x \neq 0$

Algunos ejemplos:

- $V = \mathbb{R}^n$, $\langle x, y \rangle = x_1y_1 + x_2y_2 + \cdots + x_ny_n$
- $V = \mathbb{R}^n$, $\langle x, y \rangle = w_1x_1y_1 + w_2x_2y_2 + \cdots + w_nx_ny_n$ (con $w_i > 0 \forall i$)
- $V = \mathcal{C}([a, b])$, $\langle f, g \rangle = \int_a^b f(x)g(x) dx$
- $V = \mathcal{C}([a, b])$, $\langle f, g \rangle = \int_a^b w(x)f(x)g(x) dx$ si $w(x) > 0$ en $[a, b]$

Desigualdad de Cauchy–Schwartz

Si $x, y \in V$ entonces

$$|\langle x, y \rangle| \leq \langle x, x \rangle^{\frac{1}{2}} \langle y, y \rangle^{\frac{1}{2}}$$

Desigualdad de Cauchy–Schwartz

Si $x, y \in V$ entonces

$$|\langle x, y \rangle| \leq \langle x, x \rangle^{\frac{1}{2}} \langle y, y \rangle^{\frac{1}{2}}$$

Norma

La función

$$\|\cdot\| : V \rightarrow \mathbb{R}, \quad \|x\| = \langle x, x \rangle^{\frac{1}{2}}$$

es una *norma* sobre V . La llamamos *norma inducida por el producto interno* en V

Ortogonalidad

- Si $\langle x, y \rangle = 0$ decimos que x e y son *ortogonales* y escribimos $x \perp y$
- $A, B \subset V$ son ortogonales ($A \perp B$) si $x \perp y$ para todo $x \in A, y \in B$

Proyección ortogonal

Dado un subespacio \mathcal{S} del espacio con producto interno V , sean $x \in V, y \in \mathcal{S}$. Entonces son equivalentes

- a $\|x - y\| = \min\{\|x - s\| : s \in \mathcal{S}\}$
- b $\langle x - y, s \rangle = 0$ para todo $s \in \mathcal{S}$

Proyección ortogonal

Dado un subespacio \mathcal{S} del espacio con producto interno V , sean $x \in V, y \in \mathcal{S}$. Entonces son equivalentes

- a $\|x - y\| = \min\{\|x - s\| : s \in \mathcal{S}\}$
- b $\langle x - y, s \rangle = 0$ para todo $s \in \mathcal{S}$

Si existe $y \in \mathcal{S}$ verificando (a) o (b) entonces es único


Problemas de aproximación

Proyección ortogonal

Dado un subespacio \mathcal{S} del espacio con producto interno V , sean $x \in V, y \in \mathcal{S}$. Entonces son equivalentes

- a $\|x - y\| = \min\{\|x - s\| : s \in \mathcal{S}\}$
- b $\langle x - y, s \rangle = 0$ para todo $s \in \mathcal{S}$

Si existe $y \in \mathcal{S}$ verificando (a) o (b) entonces es único



Proyección ortogonal

Si $y \in V$ verifica (a) o (b), decimos que y es la **proyección ortogonal de x sobre S en V** y anotamos $y = P_S x$

Proyección ortogonal

Si $y \in V$ verifica (a) o (b), decimos que y es la **proyección ortogonal de x sobre \mathcal{S} en V** y anotamos $y = P_{\mathcal{S}}x$

En lo que sigue veremos que si el subespacio \mathcal{S} es de dimensión finita siempre existe la proyección ortogonal sobre \mathcal{S} para cada x de V , y cómo construirla.

Proyección ortogonal

Si $y \in V$ verifica (a) o (b), decimos que y es la **proyección ortogonal de x sobre S en V** y anotamos $y = P_S x$

En lo que sigue veremos que si el subespacio S es de dimensión finita siempre existe la proyección ortogonal sobre S para cada x de V , y cómo construirla.

Un subconjunto A de un espacio vectorial con producto interno V se dice *ortonormal* si

- $\|x\| = 1$ para todo $x \in A$, y
- $x \perp y$ para todo par $x, y \in A$ con $x \neq y$

Existencia de la proyección ortogonal

Sea \mathcal{S} un subespacio de dimensión finita del e.v.c.p.i. V . Entonces $P_{\mathcal{S}}x$ existe y es única para cada $x \in V$. Además si $\{v_1, v_2, \dots, v_m\}$ es una base ortonormal de \mathcal{S} entonces

$$P_{\mathcal{S}}x = \sum_{i=1}^m \langle x, v_i \rangle v_i$$

Existencia de la proyección ortogonal

Sea \mathcal{S} un subespacio de dimensión finita del e.v.c.p.i. V . Entonces $P_{\mathcal{S}}x$ existe y es única para cada $x \in V$. Además si $\{v_1, v_2, \dots, v_m\}$ es una base ortonormal de \mathcal{S} entonces

$$P_{\mathcal{S}}x = \sum_{i=1}^m \langle x, v_i \rangle v_i$$

De esta manera, podemos hallar $P_{\mathcal{S}}x \in \mathcal{S}$ que minimiza

$$\|x - P_{\mathcal{S}}x\| = \min \{\|x - s\| : s \in \mathcal{S}\}$$

si contamos con una base ortonormal de \mathcal{S} . Para ello podemos usar el método de Gram–Schmidt

Método de Gram–Schmidt

Sea $\{r_1, r_2, \dots, r_m\}$ una base \mathcal{S} . Entonces definimos

$$u_1 = r_1, \quad v_1 = \frac{u_1}{\|u_1\|}$$

y para $k = 2, \dots, m$

$$u_k = r_k - \sum_{i=1}^{k-1} \langle r_k, v_i \rangle v_i, \quad v_k = \frac{u_k}{\|u_k\|}$$

Entonces

- El conjunto $\{u_1, \dots, u_m\}$ es ortogonal
- $\{v_1, \dots, v_m\}$ es una base ortonormal de \mathcal{S} .

- 1 Aproximación en un espacio con producto interno
- 2 Ejemplo 1: aproximación de funciones continuas por polinomios
- 3 Ejemplo 2: ajuste en L^2 por funciones de forma dadas
- 4 Data-fitting

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

Problema

Dada $f \in \mathcal{C}([a, b])$ y $m \in \mathbb{N}$ hallar un polinomio p en \mathcal{P}_m que minimice

$$\int_a^b w(x) [f(x) - p(x)]^2 dx$$

donde $w(x)$ es una función de peso positiva en $[a, b]$.

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

Problema

Dada $f \in \mathcal{C}([a, b])$ y $m \in \mathbb{N}$ hallar un polinomio p en \mathcal{P}_m que minimice

$$\int_a^b w(x) [f(x) - p(x)]^2 dx$$

donde $w(x)$ es una función de peso positiva en $[a, b]$.

Si definimos el producto interno en $V = \mathcal{C}([a, b])$ por

$$\langle g, h \rangle_w = \int_a^b w(x)g(x)h(x) dx$$

y $\|\cdot\|_w$ es la norma inducida, entonces podemos reescribir el problema como: hallar $p_m^* \in \mathcal{P}_m$ tal que

$$\|f - p_m^*\|_w = \min\{\|f - p\|_w : p \in \mathcal{P}_m\}$$

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

Para hallar p_m^* basta encontrar una base ortonormal $\{p_0, p_1, \dots, p_m\}$ del subespacio $\mathcal{S} = \mathcal{P}_m$ de $V = \mathcal{C}([a, b])$ (notar que $m + 1 = \dim \mathcal{P}_m$), y definir

$$p_m^* = \sum_{i=0}^m \langle f, p_i \rangle_w p_i$$

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

Para hallar p_m^* basta encontrar una base ortonormal $\{p_0, p_1, \dots, p_m\}$ del subespacio $\mathcal{S} = \mathcal{P}_m$ de $V = \mathcal{C}([a, b])$ (notar que $m + 1 = \dim \mathcal{P}_m$), y definir

$$p_m^* = \sum_{i=0}^m \langle f, p_i \rangle_w p_i$$

Para esto podemos aplicar GS a la base $\{1, x, x^2, \dots, x^m\}$ de \mathcal{P}_m

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

Para hallar p_m^* basta encontrar una base ortonormal $\{p_0, p_1, \dots, p_m\}$ del subespacio $\mathcal{S} = \mathcal{P}_m$ de $V = \mathcal{C}([a, b])$ (notar que $m + 1 = \dim \mathcal{P}_m$), y definir

$$p_m^* = \sum_{i=0}^m \langle f, p_i \rangle_w p_i$$

Para esto podemos aplicar GS a la base $\{1, x, x^2, \dots, x^m\}$ de \mathcal{P}_m

GS para polinomios

Aplicamos GS a la base $\{1, x, x^2, \dots, x^m\}$ de \mathcal{P}_m :

$$q_0 = 1, \quad p_0 = 1 / \|q_0\|_w,$$

y para $k = 1, \dots, m$

$$q_k(x) = x^k - \sum_{i=0}^{k-1} \langle x^k, p_i \rangle_w p_i, \quad p_k = q_k / \|q_k\|_w$$

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

GS aplicado a la base canónica de polinomios

Los polinomios q_k verifican las siguientes propiedades:

- q_k es un polinomio mónico de grado k
- $\{q_0, q_1, \dots, q_m\}$ es una base ortogonal de \mathcal{P}_m
- $q_k \perp \mathcal{P}_{k-1}$ (q_k es ortogonal a todo polinomio de grado $< k$)

Ejemplo 1: aproximación polinomial en $\mathcal{C}([a, b])$

GS aplicado a la base canónica de polinomios

Los polinomios q_k verifican las siguientes propiedades:

- q_k es un polinomio mónico de grado k
- $\{q_0, q_1, \dots, q_m\}$ es una base ortogonal de \mathcal{P}_m
- $q_k \perp \mathcal{P}_{k-1}$ (q_k es ortogonal a todo polinomio de grado $< k$)

Como consecuencia del teorema de Weierstrass obtenemos fácilmente el siguiente resultado

Convergencia de los polinomios minimizantes

La sucesión de polinomios minimizantes p_m^* converge a f en la norma $\|\cdot\|_w$, es decir

$$\|f - p_m^*\|_w \rightarrow 0, \quad m \rightarrow \infty$$

- 1 Aproximación en un espacio con producto interno
- 2 Ejemplo 1: aproximación de funciones continuas por polinomios
- 3 Ejemplo 2: ajuste en L^2 por funciones de forma dadas
- 4 Data-fitting

Ejemplo 2: ajuste en L^2 por funciones de forma dadas

Problema

Hallar (numéricamente) la mejor aproximación en norma $L^2([1, 2])$ de la función $f(x) = x^{-1}$ por una combinación lineal de las funciones e^x , $\sin x$ y $\Gamma(x)$.

Ejemplo 2: ajuste en L^2 por funciones de forma dadas

Problema

Hallar (numéricamente) la mejor aproximación en norma $L^2([1, 2])$ de la función $f(x) = x^{-1}$ por una combinación lineal de las funciones e^x , $\sin x$ y $\Gamma(x)$.

Podemos utilizar el comando `quad` para calcular numéricamente las integrales involucradas en GS


Ejemplo 2: ajuste en L^2 por funciones de forma dadas

```
1 # calcula la proyeccion L2([a,b]) de f sobre el subespacio
2 # generado por las funciones definidas en la estruc fcs
3 f = @(x) 1./x;
4 a = 1;
5 b = 2;
6 fcs = {@exp, @sin , @gamma};
7 # ortonormalizamos fcs
8 bon = {}; # base ortonormal
9 for i = 1:length(fcs)
10     gi = @(x) fcs{i}(x);
11     for k = 1:(i-1)
12         integ = @(x) gi(x).*bon{k}(x);
13         c = quad(integ,a,b);
14         gi = @(x) gi(x) - c*bon{k}(x);
15     endfor
16     integ = @(x) gi(x).^2;
17     n = sqrt(quad(integ,a,b));
18     bon{i} = @(x) gi(x)/n;
19 endfor
```


Ejemplo 2: ajuste en L^2 por funciones de forma dadas

```
1 # proyectamos f sobre el espacio <fcs{i}: i=1:length(fcs)>
2 p = @(x) 0;
3 for i = 1:length(fcs)
4     integ = @(x) f(x)*bon{i}(x);
5     c = quad(integ,a,b);
6     p = @(x) p(x) + c*bon{i}(x);
7 endfor
8 # graficamos f y p en [a,b]
9 N = 100;
10 x = a + [0:N]/N*(b-a);
11 figure
12 plot(x,f(x),'b');
13 hold on
14 plot(x,p(x),'r');
15 hold off
16
```

Ejemplo 2: ajuste en L^2 por funciones de forma dadas



- 1 Aproximación en un espacio con producto interno
- 2 Ejemplo 1: aproximación de funciones continuas por polinomios
- 3 Ejemplo 2: ajuste en L^2 por funciones de forma dadas
- 4 Data-fitting

Problema de cuadrados mínimos

Dada $A \in \mathbb{R}^{m \times n}$ con $m > n$ y $b \in \mathbb{R}^m$, hallar $x \in \mathbb{R}^n$ tal que

$$\|b - Ax\|_2$$

sea mínimo.

Problema de cuadrados mínimos

Dada $A \in \mathbb{R}^{m \times n}$ con $m > n$ y $b \in \mathbb{R}^m$, hallar $x \in \mathbb{R}^n$ tal que

$$\|b - Ax\|_2$$

sea mínimo.

- Como $m > n$, el sistema $Ax = b$ es sobredeterminado, y en general no tiene solución

Problema de cuadrados mínimos

Dada $A \in \mathbb{R}^{m \times n}$ con $m > n$ y $b \in \mathbb{R}^m$, hallar $x \in \mathbb{R}^n$ tal que

$$\|b - Ax\|_2$$

sea mínimo.

- Como $m > n$, el sistema $Ax = b$ es sobredeterminado, y en general no tiene solución
- $r = b - Ax$ se llama *residuo*, y es lo que se quiere minimizar

Problema de cuadrados mínimos

Dada $A \in \mathbb{R}^{m \times n}$ con $m > n$ y $b \in \mathbb{R}^m$, hallar $x \in \mathbb{R}^n$ tal que

$$\|b - Ax\|_2$$

sea mínimo.

- Como $m > n$, el sistema $Ax = b$ es sobredeterminado, y en general no tiene solución
- $r = b - Ax$ se llama *residuo*, y es lo que se quiere minimizar
- $\|\cdot\|_2$ es la norma euclídea, pero podría considerarse otras normas inducidas por un producto interno en \mathbb{R}^m , por ejemplo, norma ℓ_2 con pesos

Problema de cuadrados mínimos

Dada $A \in \mathbb{R}^{m \times n}$ con $m > n$ y $b \in \mathbb{R}^m$, hallar $x \in \mathbb{R}^n$ tal que

$$\|b - Ax\|_2$$

sea mínimo.

- Como $m > n$, el sistema $Ax = b$ es sobredeterminado, y en general no tiene solución
- $r = b - Ax$ se llama *residuo*, y es lo que se quiere minimizar
- $\|\cdot\|_2$ es la norma euclídea, pero podría considerarse otras normas inducidas por un producto interno en \mathbb{R}^m , por ejemplo, norma ℓ_2 con pesos
- El problema puede plantearse en \mathbb{C} casi sin cambios, solo cambiar t (traspuesta) por $*$ (conjugada traspuesta)

Sistemas sobredeterminados

- Si definimos $\mathcal{S} = \text{Rg}(A) = \{Ax : x \in \mathbb{R}^n\}$, entonces podemos resolver el problema en dos pasos:

- 1 Encontrar $y \in \mathcal{S}$ tal que

$$\|b - y\|_2 = \min\{b - s : s \in \mathcal{S}\} \quad (1)$$

- 2 Hallar x tal que $Ax = y$

Sistemas sobredeterminados

- Si definimos $\mathcal{S} = \text{Rg}(A) = \{Ax : x \in \mathbb{R}^n\}$, entonces podemos resolver el problema en dos pasos:

- 1 Encontrar $y \in \mathcal{S}$ tal que

$$\|b - y\|_2 = \min\{b - s : s \in \mathcal{S}\} \quad (1)$$

- 2 Hallar x tal que $Ax = y$

- Sabemos que $y \in \mathcal{S}$ resuelve (1) si y solo si

$$\langle b - y, s \rangle = 0 \quad \forall s \in \mathcal{S}$$

Sistemas sobredeterminados

- Si definimos $\mathcal{S} = \text{Rg}(A) = \{Ax : x \in \mathbb{R}^n\}$, entonces podemos resolver el problema en dos pasos:

- 1 Encontrar $y \in \mathcal{S}$ tal que

$$\|b - y\|_2 = \min\{b - s : s \in \mathcal{S}\} \quad (1)$$

- 2 Hallar x tal que $Ax = y$

- Sabemos que $y \in \mathcal{S}$ resuelve (1) si y solo si

$$\langle b - y, s \rangle = 0 \quad \forall s \in \mathcal{S}$$

- Así podemos plantear: Hallar $x \in \mathbb{R}^n$ tal que

$$\langle b - Ax, Az \rangle = 0 \quad \forall z \in \mathbb{R}^n$$

Sistemas sobredeterminados

- Si definimos $\mathcal{S} = \text{Rg}(A) = \{Ax : x \in \mathbb{R}^n\}$, entonces podemos resolver el problema en dos pasos:

- 1 Encontrar $y \in \mathcal{S}$ tal que

$$\|b - y\|_2 = \min\{b - s : s \in \mathcal{S}\} \quad (1)$$

- 2 Hallar x tal que $Ax = y$

- Sabemos que $y \in \mathcal{S}$ resuelve (1) si y solo si

$$\langle b - y, s \rangle = 0 \quad \forall s \in \mathcal{S}$$

- Así podemos plantear: Hallar $x \in \mathbb{R}^n$ tal que

$$\langle b - Ax, Az \rangle = 0 \quad \forall z \in \mathbb{R}^n \quad \text{ó, } r \perp \text{Rg}(A)$$

Sistemas sobredeterminados

- Si definimos $\mathcal{S} = \text{Rg}(A) = \{Ax : x \in \mathbb{R}^n\}$, entonces podemos resolver el problema en dos pasos:

- 1 Encontrar $y \in \mathcal{S}$ tal que

$$\|b - y\|_2 = \min\{b - s : s \in \mathcal{S}\} \quad (1)$$

- 2 Hallar x tal que $Ax = y$

- Sabemos que $y \in \mathcal{S}$ resuelve (1) si y solo si

$$\langle b - y, s \rangle = 0 \quad \forall s \in \mathcal{S}$$

- Así podemos plantear: Hallar $x \in \mathbb{R}^n$ tal que

$$\langle b - Ax, Az \rangle = 0 \quad \forall z \in \mathbb{R}^n \quad \text{ó, } r \perp \text{Rg}(A)$$

- Como $\langle b - Ax, Az \rangle = \langle A^t b - A^t Ax, z \rangle$, $x \in \mathbb{R}^n$ debe verificar

$$\langle A^t b - A^t Ax, z \rangle = 0 \quad \forall z \in \mathbb{R}^n \quad (2)$$

Sistemas sobredeterminados

- Si definimos $\mathcal{S} = \text{Rg}(A) = \{Ax : x \in \mathbb{R}^n\}$, entonces podemos resolver el problema en dos pasos:

- 1 Encontrar $y \in \mathcal{S}$ tal que

$$\|b - y\|_2 = \min\{b - s : s \in \mathcal{S}\} \quad (1)$$

- 2 Hallar x tal que $Ax = y$

- Sabemos que $y \in \mathcal{S}$ resuelve (1) si y solo si

$$\langle b - y, s \rangle = 0 \quad \forall s \in \mathcal{S}$$

- Así podemos plantear: Hallar $x \in \mathbb{R}^n$ tal que

$$\langle b - Ax, Az \rangle = 0 \quad \forall z \in \mathbb{R}^n \quad \text{ó, } r \perp \text{Rg}(A)$$

- Como $\langle b - Ax, Az \rangle = \langle A^t b - A^t Ax, z \rangle$, $x \in \mathbb{R}^n$ debe verificar

$$\langle A^t b - A^t Ax, z \rangle = 0 \quad \forall z \in \mathbb{R}^n \quad (2)$$

- (2) es equivalente a

$$A^t Ax = A^t b$$

Ecuaciones normales

$x \in \mathbb{R}^n$ es solución de

$$\|b - Ax\|_2 = \min\{\|b - Az\|_2 : z \in \mathbb{R}^n\}$$

si y solo si

$$A^t Ax = A^t b \quad (3)$$

Ecuaciones normales

$x \in \mathbb{R}^n$ es solución de

$$\|b - Ax\|_2 = \min\{\|b - Az\|_2 : z \in \mathbb{R}^n\}$$

si y solo si

$$A^t Ax = A^t b \quad (3)$$

- Las ecuaciones (3) se llaman *ecuaciones normales*

Ecuaciones normales

$x \in \mathbb{R}^n$ es solución de

$$\|b - Ax\|_2 = \min\{\|b - Az\|_2 : z \in \mathbb{R}^n\}$$

si y solo si

$$A^t Ax = A^t b \quad (3)$$

- Las ecuaciones (3) se llaman *ecuaciones normales*
- $A^t A$ es no singular si y solo si A es full-rank

Ecuaciones normales

$x \in \mathbb{R}^n$ es solución de

$$\|b - Ax\|_2 = \min\{\|b - Az\|_2 : z \in \mathbb{R}^n\}$$

si y solo si

$$A^t Ax = A^t b \quad (3)$$

- Las ecuaciones (3) se llaman *ecuaciones normales*
- $A^t A$ es no singular si y solo si A es full-rank
- La solución x es única si y solo si A es full-rank

Pseudoinversa

Si $A \in \mathbb{R}^{m \times n}$ es full-rank, la matriz

$$A^+ = (A^t A)^{-1} A^t$$

se llama pseudoinversa de A

Pseudoinversa

Si $A \in \mathbb{R}^{m \times n}$ es full-rank, la matriz

$$A^+ = (A^t A)^{-1} A^t$$

se llama pseudoinversa de A

- Vimos que si A es full-rank, la solución (única) $x \in \mathbb{R}^n$ del problema de cuadrados mínimos es

$$x = A^+ b$$

Tres algoritmos para resolver cuadrados mínimos

Cuadrados mínimos vía ecuaciones normales

Como $A^t A$ es simétrica definida positiva (si A es full-rank), tiene una factorización de Cholesky $R^t R$ con R triangular superior (usamos R^t en lugar de L para usar la notación de Octave)

Cuadrados mínimos vía ecuaciones normales

Como $A^t A$ es simétrica definida positiva (si A es full-rank), tiene una factorización de Cholesky $R^t R$ con R triangular superior (usamos R^t en lugar de L para usar la notación de Octave)

Algoritmo

- 1 Formar la matriz $A^t A$ y el vector $A^t b$
- 2 Calcular la factorización de Cholesky $A^t A = R^t R$
- 3 Resolver el sistema triangular inferior $R^t w = A^t b$ para w
- 4 Resolver el sistema triangular superior $R x = w$ para x

Cuadrados mínimos vía ecuaciones normales

Como $A^t A$ es simétrica definida positiva (si A es full-rank), tiene una factorización de Cholesky $R^t R$ con R triangular superior (usamos R^t en lugar de L para usar la notación de Octave)

Algoritmo

- 1 Formar la matriz $A^t A$ y el vector $A^t b$
- 2 Calcular la factorización de Cholesky $A^t A = R^t R$
- 3 Resolver el sistema triangular inferior $R^t w = A^t b$ para w
- 4 Resolver el sistema triangular superior $R x = w$ para x

El comando `R = chol(B)` de Octave calcula la factorización de Cholesky $B = R R^t$

Tres algoritmos para resolver cuadrados mínimos

Cuadrados mínimos vía factorización QR

Suponemos A full-rank. Si A tiene la factorización QR reducida $A = \hat{Q}\hat{R}$ entonces

$$A^t A x = A^t b \iff \hat{R}^t \hat{Q}^t \hat{Q} \hat{R} x = \hat{R}^t \hat{Q}^t b \iff \hat{R} x = \hat{Q}^t b$$

Tres algoritmos para resolver cuadrados mínimos

Cuadrados mínimos vía factorización QR

Suponemos A full-rank. Si A tiene la factorización QR reducida $A = \hat{Q}\hat{R}$ entonces

$$A^tAx = A^tb \iff \hat{R}^t\hat{Q}^t\hat{Q}\hat{R}x = \hat{R}^t\hat{Q}^tb \iff \hat{R}x = \hat{Q}^tb$$

Algoritmo

- 1 Calcular la factorización QR reducida $A = \hat{Q}\hat{R}$
- 2 Calcular el vector \hat{Q}^tb
- 3 Resolver el sistema triangular superior $\hat{R}x = \hat{Q}^tb$ para x

Tres algoritmos para resolver cuadrados mínimos

Cuadrados mínimos vía factorización QR

Suponemos A full-rank. Si A tiene la factorización QR reducida $A = \widehat{Q}\widehat{R}$ entonces

$$A^tAx = A^tb \iff \widehat{R}^t\widehat{Q}^t\widehat{Q}\widehat{R}x = \widehat{R}^t\widehat{Q}^tb \iff \widehat{R}x = \widehat{Q}^tb$$

Algoritmo

- 1 Calcular la factorización QR reducida $A = \widehat{Q}\widehat{R}$
 - 2 Calcular el vector \widehat{Q}^tb
 - 3 Resolver el sistema triangular superior $\widehat{R}x = \widehat{Q}^tb$ para x
- Notar que el vector $y \in \mathbb{R}^m$ de (1), que es la proyección ortogonal de b sobre $\text{Rg}(A) = \text{Rg}(\widehat{Q})$ puede calcularse como $y = \widehat{Q}\widehat{Q}^tb$
 - Como $y \in \text{Rg}(A)$, el sistema $Ax = y$, o $\widehat{Q}\widehat{R}x = \widehat{Q}\widehat{Q}^tb$, tiene solución, que puede encontrarse premultiplicando por \widehat{Q}^t y resolviendo el sistema triangular del algoritmo

Tres algoritmos para resolver cuadrados mínimos

Cuadrados mínimos vía SVD

Supongamos A full-rank

Cuadrados mínimos vía SVD

Supongamos A full-rank

- Si $A = \hat{U}\hat{\Sigma}V^t$ es la descomposición svd reducida de A , entonces $\text{Rg}(A) = \text{Rg}(\hat{U})$, y por lo tanto, el vector y de (1) es

$$y = \hat{U}\hat{U}^t b$$

Cuadrados mínimos vía SVD

Supongamos A full-rank

- Si $A = \hat{U}\hat{\Sigma}V^t$ es la descomposición svd reducida de A , entonces $\text{Rg}(A) = \text{Rg}(\hat{U})$, y por lo tanto, el vector y de (1) es

$$y = \hat{U}\hat{U}^t b$$

- Por lo tanto, basta hallar $x \in \mathbb{R}^n$ tal que

$$\hat{U}\hat{\Sigma}V^t = \hat{U}\hat{U}^t b \quad \text{ó} \quad \hat{\Sigma}V^t = \hat{U}^t b$$

Cuadrados mínimos vía SVD

Supongamos A full-rank

- Si $A = \hat{U}\hat{\Sigma}V^t$ es la descomposición svd reducida de A , entonces $\text{Rg}(A) = \text{Rg}(\hat{U})$, y por lo tanto, el vector y de (1) es

$$y = \hat{U}\hat{U}^t b$$

- Por lo tanto, basta hallar $x \in \mathbb{R}^n$ tal que

$$\hat{U}\hat{\Sigma}V^t = \hat{U}\hat{U}^t b \quad \text{ó} \quad \hat{\Sigma}V^t = \hat{U}^t b$$

Algoritmo

- 1 Calcular la factorización SVD reducida $A = \hat{U}\hat{\Sigma}V^t$
- 2 Calcular el vector $\hat{U}^t b$
- 3 Resolver el sistema diagonal $\hat{\Sigma}w = \hat{U}^t b$ para w
- 4 Definir $x = Vw$

Tres algoritmos para resolver cuadrados mínimos

Algunas observaciones

- La matriz $A^t A$ suele ser mal condicionada, por lo que la resolución de las ecuaciones normales puede tener problemas de estabilidad respecto de los errores de redondeo
- En general el algoritmo "recomendado" es el que usa la factorización QR
- Si las columnas de A son "casi linealmente dependientes", entonces conviene usar el algoritmo basado en la SVD, aunque es el más costoso computacionalmente

Ejemplo: polinomial data-fitting

Problema: Hallar un polinomio p de grado ≤ 7 que minimice el error cuadrático

$$\sum_{i=0}^{10} |p(x_i) - y_i|^2$$

si x_i, y_i están dados por la tabla

x_i	-5	-4	-3	-2	-1	0	1	2	3	4	5
y_i	0	0	0	1	1	1	0	0	0	0	0

Comparar con el polinomio de interpolación en los 11 puntos x_i

Ejemplo: polinomial data-fitting

Problema: Hallar un polinomio p de grado ≤ 7 que minimice el error cuadrático

$$\sum_{i=0}^{10} |p(x_i) - y_i|^2$$

si x_i, y_i están dados por la tabla

x_i	-5	-4	-3	-2	-1	0	1	2	3	4	5
y_i	0	0	0	1	1	1	0	0	0	0	0


Comparar con el polinomio de interpolación en los 11 puntos x_i

Si denotamos $a = (a_0, a_1, \dots, a_7)^t$ los coeficientes del polinomio $p(x) = \sum_{k=0}^7 a_k x^k$ buscado, notemos que se trata de hallar el vector a que minimice $\|Aa - b\|_2$, si

$A \in \mathbb{R}^{11 \times 8}$ y $b \in \mathbb{R}^{11}$ están dados por

$$A = \begin{pmatrix} 1 & x_0 & x_0^2 & \cdots & x_0^7 \\ 1 & x_1 & x_1^2 & \cdots & x_1^7 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 1 & x_{10} & x_{10}^2 & \cdots & x_{10}^7 \end{pmatrix} \quad b = \begin{pmatrix} y_0 \\ y_1 \\ \vdots \\ y_{10} \end{pmatrix}$$

Ejemplo 3: polinomial data-fitting



El vector a de coeficientes calculado es

$$a = (8.0995e-01, -6.5462e-01, -1.3943e-01, 1.3735e-01, 7.5540e-03, -8.8235e-03, -1.3072e-04, 1.7507e-04)$$

Ejemplo 4: data-fitting con funciones generales

Problema: Similarmente al Ejemplo 2, hallar una combinación lineal

$$h(x) = a_0 e^x + a_1 \sin(x) + a_2 \Gamma(x)$$

tal que si $x_i = 1 + i/10$, $i = 0, \dots, 10$ se minimice el error

$$E = \sum_{i=0}^{10} |f(x_i) - h(x_i)|^2$$

para $f(x) = 1/x$. Graficar $h(x)$ y comparar con el resultado del ejemplo 2

Ejemplo 4: data-fitting con funciones generales

Problema: Similarmente al Ejemplo 2, hallar una combinación lineal

$$h(x) = a_0 e^x + a_1 \sin(x) + a_2 \Gamma(x)$$

tal que si $x_i = 1 + i/10$, $i = 0, \dots, 10$ se minimice el error

$$E = \sum_{i=0}^{10} |f(x_i) - h(x_i)|^2$$


para $f(x) = 1/x$. Graficar $h(x)$ y comparar con el resultado del ejemplo 2

Si definimos la matriz $A \in \mathbb{R}^{11 \times 3}$ y $b \in \mathbb{R}^{11}$ por

$$A = \begin{pmatrix} e^{x_0} & \sin(x_0) & \Gamma(x_0) \\ e^{x_1} & \sin(x_1) & \Gamma(x_1) \\ \vdots & \vdots & \vdots \\ e^{x_{10}} & \sin(x_{10}) & \Gamma(x_{10}) \end{pmatrix} \quad b = \begin{pmatrix} f(x_0) \\ f(x_1) \\ \vdots \\ f(x_{10}) \end{pmatrix}$$

se trata de hallar $a = (a_0, a_1, a_2)^t$ que minimice $\|Aa - b\|_2$

Ejemplo 4: data-fitting con funciones generales



El vector a de coeficientes calculado es

$$a = (-0.107619, 0.010815, 1.284665)$$

y el error cuadrático obtenido es de $E = 2.2718e - 03$