

Lección 10: Mínimos Cuadrados

Jesús Savage

Facultad de Ingeniería, UNAM

Trabajo realizado con el apoyo del Programa

UNAM-DGAPA-PAPIME PE100821

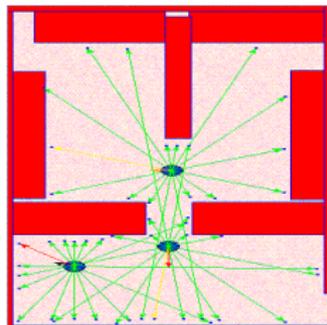
Derechos reservados, 2023

19 de junio de 2023

Mínimos Cuadrados

El robot cuenta con sensores de proximidad que le permiten calcular la distancia a la cual se encuentran los objetos. A las lecturas que hacen los sensores se les agregan señales de ruido v no deseadas a los valores reales r y se desea en lo posible eliminar este ruido:

$$x = r + v$$



Mínimos Cuadrados

Se colocan objetos enfrente de robot a una distancia conocida y se hacen lecturas de los sensores, obteniendose un grupo de datos

$$(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_n, f(x_n))$$

como el mostrado en la siguiente tabla:

<i>Valor Leído</i>	<i>Valor Real</i>	<i>Valor Estimado</i>
x_i	$f(x_i)$	$y_M(x_i)$
x_1	$f(x_1)$	$y_M(x_1)$
x_2	$f(x_2)$	$y_M(x_2)$
\cdot	\cdot	\cdot
\cdot	\cdot	\cdot
\cdot	\cdot	\cdot
x_i	$f(x_i)$	$y_M(x_i)$
\cdot	\cdot	\cdot
\cdot	\cdot	\cdot
\cdot	\cdot	\cdot
x_n	$f(x_n)$	$y_M(x_n)$

El objetivo es encontrar una función $y_m(x)$ que estime los valores reales a partir de las lecturas de los sensores.

Mínimos Cuadrados

Dada la lectura x de un sensor, si la función de estimación es de la siguiente forma:

$$y_m(x) = a_1 + a_2 x + a_3 x^2 + \dots + a_{m+1} x^m$$

El objetivo es encontrar los valores de las constantes a_1, a_2, \dots, a_{m+1} tal que el error cuadrático sea mínimo.

$$\begin{aligned} E &= \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (f(x_i) - y_m(x_i))^2 \\ &= \sum_{i=1}^n (f(x_i) - a_1 - a_2 x_i - a_3 x_i^2 - \dots - a_{m+1} x_i^{m+1})^2 \end{aligned}$$

Por ejemplo, para $y_1(x) = a_1 + a_2 x$ el error cuadrático se minimiza derivando la función del error con respecto a a_1 y a_2 .

Mínimos Cuadrados

$$\frac{\partial E}{\partial a_1} = \frac{\partial \sum_{i=1}^n e_i^2}{\partial a_1} = -2 \sum_{i=1}^n (f(x_i) - a_1 - a_2 x_i) = 0$$

$$a_1 \cdot n + a_2 \sum_{i=1}^n x_i = \sum_{i=1}^n f(x_i) \quad (1)$$

$$\frac{\partial E}{\partial a_2} = \frac{\partial \sum_{i=1}^n e_i^2}{\partial a_2} = 2 \sum_{i=1}^n (f(x_i) - a_1 - a_2 x_i)(-x_i) = 0$$

$$a_1 \sum_{i=1}^n x_i + a_2 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i \cdot f(x_i) \quad (2)$$

Mínimos Cuadrados

De (1)

$$a_1 = \frac{\sum_{i=1}^n f(x_i) - a_2 \sum_{i=1}^n x_i}{n} \quad (3)$$

(3) en (2)

$$\left(\frac{\sum_{i=1}^n f(x_i) - a_2 \sum_{i=1}^n x_i}{n} \right) \left(\sum_{i=1}^n x_i \right) + a_2 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i f(x_i)$$

Mínimos Cuadrados

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \sum_{i=1}^n x_i - \frac{1}{n} a_2 \sum_{i=1}^n x_i \sum_{i=1}^n x_i + a_2 \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n x_i f(x_i) \\ a_2 \left(\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \right) &= \sum_{i=1}^n x_i f(x_i) - \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \sum_{i=1}^n x_i \\ a_2 &= \frac{\sum_{i=1}^n x_i f(x_i) - \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \sum_{i=1}^n x_i}{\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2} \end{aligned}$$

Mínimos Cuadrados

$$a_1 \cdot n + \frac{\left(\sum_{i=1}^n x_i f(x_i) - \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \sum_{i=1}^n x_i \right) \sum_{i=1}^n x_i}{\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2} = \sum_{i=1}^n f(x_i)$$

$$\Rightarrow a_1 = \frac{1}{n} \left(\sum_{i=1}^n f(x_i) - \frac{\left(\sum_{i=1}^n x_i f(x_i) - \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \sum_{i=1}^n x_i \right) \sum_{i=1}^n x_i}{\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2} \right)$$

Mínimos Cuadrados

$$\begin{aligned} &= \frac{1}{n} \sum_{i=1}^n f(x_i) - \frac{\sum_{i=1}^n x_i f(x_i) \cdot \sum_{i=1}^n x_i + \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \left(\sum_{i=1}^n x_i\right)^2}{n \left(\sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2\right)} \\ &= \frac{\sum_{i=1}^n f(x_i) \sum_{i=1}^n x_i^2 - \sum_{i=1}^n \frac{f(x_i)}{n} \left(\sum_{i=1}^n x_i\right)^2 - \sum_{i=1}^n x_i f(x_i) \cdot \sum_{i=1}^n x_i + \sum_{i=1}^n \frac{f(x_i)}{n} \left(\sum_{i=1}^n x_i\right)^2}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2} \end{aligned}$$

Mínimos Cuadrados

$$a_1 = \frac{\sum_{i=1}^n f(x_i) \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i f(x_i) \cdot \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$
$$a_2 = \frac{\sum_{i=1}^n x_i f(x_i) - \frac{1}{n} \sum_{i=1}^n f(x_i) \cdot \sum_{i=1}^n x_i}{\sum_{i=1}^n x_i^2 - \frac{1}{n} (\sum_{i=1}^n x_i)^2}$$

Algoritmo

ALGORITMO para determinar el ajuste de mínimos cuadrados para un conjunto dado de datos, $(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_n, f(x_n))$.

1.- Ajustar un polinomio de primer grado

$$y_1(x) = a_1 + a_2 x$$

resolviendo las ecuaciones normales

$$\begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} \sum f(x_i) \\ \sum x_i f(x_i) \end{bmatrix}$$

2.- Calcular $E_1 = \sum_{i=1}^n (f(x_i) - a_1^* - a_2^* x_i)^2 / (n - 2)$

3.- Ajustar un polinomio de segundo grado

$$y_2(x) = b_1 + b_2 x + b_3 x^2$$

Algoritmo

Resolviendo las ecuaciones normales

$$\begin{bmatrix} n & \sum x_i & \sum x_i^2 \\ \sum x_i & \sum x_i^2 & \sum x_i^3 \\ \sum x_i^2 & \sum x_i^3 & \sum x_i^4 \end{bmatrix} \cdot \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix} = \begin{bmatrix} \sum f(x_i) \\ \sum x_i f(x_i) \\ \sum x_i^2 f(x_i) \end{bmatrix}$$

4.- Calcular $E_2 = \left[\sum_{i=1}^n (f(x_i) - b_1^* - b_2^* x_i^2) \right]^2 / (n - 3)$

5.- Si $E_2 > E_1$ concluye que $y_1^*(x) = a_1^* + a_2^* x$ representa adecuadamente los datos dados, de lo contrario, vaya al paso 6.

6.- Conjunto $k=3$.

7.- Ajustar el polinomio de grado k

$$y_k(x) = \sum_{j=1}^{k+1} \alpha_j x^{j-1}$$

Algoritmo

y resolviendo las ecuaciones normales

$$\begin{bmatrix} n & \sum x_i & \sum x_i^2 & \dots & \sum x_i^k \\ \sum x_i & \sum x_i^2 & \sum x_i^3 & \dots & \sum x_i^{k+1} \\ \sum x_i^2 & \sum x_i^3 & \sum x_i^4 & \dots & \sum x_i^{k+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum x_i^k & \sum x_i^{k+1} & \sum x_i^{k+2} & \dots & \sum x_i^{2k} \end{bmatrix} \cdot \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \vdots \\ \vdots \\ \alpha_{k+1} \end{bmatrix} = \begin{bmatrix} \sum f(x_i) \\ \sum x_i f(x_i) \\ \sum x_i^2 f(x_i) \\ \vdots \\ \vdots \\ \sum x_i^k f(x_i) \end{bmatrix}$$

8.- Calcular $E_k = \sum_{i=1}^n \left(f(x_i) - \sum_{j=1}^k \alpha_j^* x_i^{j-1} \right)^2 / (n - k - 1)$

9.- Si $|E_k - E_{k-1}| < \epsilon$ concluye que $y_{k-1}^*(x)$ representa los datos, de lo contrario vaya al paso 10.

10.- Aumente k en 1 y vaya al paso 7.

Regresión No Lineal

$$y = a_0 x^{a_1}$$

$$y = a_0 + x + \ln(1 + a_1 x)$$

$$y = a_0 x \operatorname{sen}(a, x)$$

$$z_i = \ln y_i = a_0 + a_1 \ln x_i$$

$$E = \sum_{i=1}^n (f(x_i) - a_0 - a_1 \ln x_i)^2$$

$$\frac{\partial E}{\partial a_0} = -2 \sum (f(x_i) - a_0 - a_1 \ln x_i) = 0$$

$$\frac{\partial E}{\partial a_1} = -2 \sum (f(x_i) - a_0 - a_1 \ln x_i) \ln x_i = 0$$

$$\sum f(x_i) - n \cdot a_0 - a_1 \sum \ln x_i = 0$$

Regresión No Lineal

$$a_0 = \frac{a_1 \sum \ln x_i - \sum f(x_i)}{N}$$

$$\sum f(x_i) \ln x_i - a_0 \sum \ln x_i - a_1 \sum (\ln x_i)^2 = 0$$

$$\sum \ln x_i (f(x_i) - a_0) - a_1 \sum (\ln x_i)^2 = 0$$

$$a_1 = \frac{\sum \ln x_i (f(x_i) - a_0)}{\sum (\ln x_i)^2}$$