



Cálculo Numérico / Métodos Numéricos

Sistemas lineares


Minimos Cuadrados - Caso discreto

Caso discreto

- Vamos inicialmente considerar o caso em que sabemos a função a aproximar em apenas alguns pontos:

x	x_1	x_2	x_3	...	x_m
$f(x)$	$f(x_1)$	$f(x_2)$	$f(x_3)$...	$f(x_m)$


Exemplo gráfico



Vemos que os pontos parecem uma reta.

A pergunta é: qual a melhor reta que os aproximaria ?

Reta (regressão linear)



$$f(x) \approx g(x) = a_1 g_1(x) + a_2 g_2(x)$$

$$f(x) \approx g(x) = a_1 x + a_2$$

$$g_1(x) = x$$

$$g_2(x) = 1$$

tarefa: escolher a_1 e a_2 de modo que o erro seja mínimo!

Mínimos quadrados

- Como vimos, usamos os "mínimos quadrados".

$$\text{Min } \sum_{i=1}^m e(x_i)^2$$

=

$$\text{Min } \sum_{i=1}^m (f(x_i) - g(x_i))^2$$

E queremos o mínimo em referência aos parâmetros a_1 e a_2

Do cálculo diferencial, se a função $e(a_1, a_2) = \sum_{i=1}^m e(x_i)^2$ tem mínimo, então:

$$\frac{\partial E}{\partial a_1} = 0 \quad \text{e} \quad \frac{\partial E}{\partial a_2} = 0$$

Derivando em relação a a_1

$$\begin{aligned}\frac{\partial E}{\partial a_1} &= \frac{\partial}{\partial a_1} \left(\sum_{i=1}^m e(x_i)^2 \right) \\ &= \frac{\partial}{\partial a_1} \left(\sum_{i=1}^m (a_1 x_i + a_2 - f(x_i))^2 \right) \\ &= \sum_{i=1}^m 2(a_1 x_i + a_2 - f(x_i)) x_i \\ &= 2 \left[a_1 \sum_{i=1}^m x_i^2 + a_2 \sum_{i=1}^m x_i \right] - 2 \left[\sum_{i=1}^m x_i f(x_i) \right] = 0\end{aligned}$$

Assim:

$$i) \quad \left(\sum_{i=1}^m x_i^2 \right) a_1 + \left(\sum_{i=1}^m x_i \right) a_2 = \sum_{i=1}^m x_i f(x_i)$$

Derivando em relação a a_2

$$\begin{aligned}\frac{\partial E}{\partial a_2} &= \frac{\partial}{\partial a_2} \left(\sum_{i=1}^m e(x_i)^2 \right) \\ &= \frac{\partial}{\partial a_2} \left(\sum_{i=1}^m (a_1 x_i + a_2 - f(x_i))^2 \right) \\ &= \sum_{i=1}^m 2(a_1 x_i + a_2 - f(x_i)) \\ &= 2 \left[a_1 \sum_{i=1}^m x_i + m \cdot a_2 - \sum_{i=1}^m f(x_i) \right] = 0\end{aligned}$$

Assim:

$$\text{ii) } \left(\sum_{i=1}^m x_i \right) a_1 + m \cdot a_2 = \sum_{i=1}^m f(x_i)$$

Sistema

- Portanto, os parâmetros que minimizam $E(a_1, a_2)$ obrigatoriamente respeitam o sistema abaixo:

$$\begin{cases} \left(\sum_{i=1}^m x_i^2 \right) a_1 + \left(\sum_{i=1}^m x_i \right) a_2 = \sum_{i=1}^m x_i f(x_i) \\ \left(\sum_{i=1}^m x_i \right) a_1 + m \cdot a_2 = \sum_{i=1}^m f(x_i) \end{cases}$$



Sistema de equações normais.

Note que a matriz A é simétrica e definida positiva
(podemos aplicar Cholesky)

pode-se provar que o ponto obtido realmente minimiza a função $E(a_1, a_2)$

Exemplo

- Obter a reta que melhor ajusta os dados:

x	0	1	2	3	4
f(x)	0.98	-3.01	-6.99	-11.01	-15

Solução:

Como vimos, a reta $g(x) = a_1x + a_2$ que melhor se ajusta é aquela cujos parâmetros resolve o sistema:

$$\begin{cases} \left(\sum_{i=1}^m x_i^2 \right) a_1 + \left(\sum_{i=1}^m x_i \right) a_2 = \sum_{i=1}^m x_i f(x_i) \\ \left(\sum_{i=1}^m x_i \right) a_1 + m \cdot a_2 = \sum_{i=1}^m f(x_i) \end{cases}$$

Exemplo (solução)

Sistema:

$$\begin{bmatrix} \sum_{k=1}^5 x_i^2 & \sum_{k=1}^5 x_i \\ \sum_{k=1}^5 x_i & 5 \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} \begin{bmatrix} \sum_{k=1}^5 f(x_i)x_i \\ \sum_{k=1}^5 f(x_i) \end{bmatrix}$$

	xi	f(xi)	xi^2	f(xi)xi	
	0.00	0.98	0.00	0.00	
	1.00	-3.01	1.00	-3.01	
	2.00	-6.99	4.00	-13.98	
	3.00	-11.01	9.00	-33.03	
	4.00	-15.00	16.00	-60.00	
soma:	10.00	-35.03	30.00	-110.02	

$$\begin{bmatrix} 30 & 10 \\ 10 & 5 \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} \begin{bmatrix} -110.02 \\ -35.03 \end{bmatrix} \longrightarrow \begin{aligned} a_1 &= -3.9960 \\ a_2 &= 0.9860 \end{aligned}$$

Exemplo (solução)

Logo:

$$f(x) \approx g(x) = -3.9960 x + 0.9860$$

Erro:

$$e(x_1)^2 = (f(0) - g(0))^2 = 0.0000$$

$$e(x_2)^2 = (f(1) - g(1))^2 = 0.0000$$

$$e(x_3)^2 = (f(2) - g(2))^2 = 0.0003$$


$$e(x_4)^2 = (f(3) - g(3))^2 = 0.0001$$

$$e(x_5)^2 = (f(4) - g(4))^2 = 0.0000$$

$$\sum_{i=1}^5 e(x_i)^2 = 0.0004$$

Outras funções

- Obviamente, nem toda função que desejaremos aproximar será uma reta.
- Por exemplo:



Nesse caso: $g(x) = a_1g_1(x) + a_2g_2(x) + a_3g_3(x)$

$g_1(x) = x^2$, $g_2(x) = x$ e $g_3(x) = 1$

Caso geral:

$$g(x) = a_1g_1(x) + a_2g_2(x) + \dots + a_ng_n(x)$$

Procedendo de maneira análoga, temos que derivar a função de erro parcialmente em relação a cada um dos n parâmetros e igualar a zero (condição necessária para que seja um ponto de mínimo):

$$\frac{\partial E}{\partial a_1} = 0 \iff (\sum_{i=1}^m g_1(x_i)g_1(x_i))a_1 + (\sum_{i=1}^m g_2(x_i)g_1(x_i))a_2 \dots +$$

$$+ \dots + (\sum_{i=1}^m g_n(x_i)g_1(x_i))a_n = \sum_{i=1}^m f(x_i)g_1(x_i)$$

$$\frac{\partial E}{\partial a_2} = 0 \iff (\sum_{i=1}^m g_1(x_i)g_2(x_i))a_1 + (\sum_{i=1}^m g_2(x_i)g_2(x_i))a_2 \dots +$$

$$+ \dots + (\sum_{i=1}^m g_n(x_i)g_2(x_i))a_n = \sum_{i=1}^m f(x_i)g_2(x_i)$$

...

$$\frac{\partial E}{\partial a_n} = 0 \iff (\sum_{i=1}^m g_1(x_i)g_n(x_i))a_1 + (\sum_{i=1}^m g_2(x_i)g_n(x_i))a_2 \dots +$$

$$+ \dots + (\sum_{i=1}^m g_n(x_i)g_n(x_i))a_n = (\sum_{i=1}^m f(x_i)g_n(x_i))$$

Sistema

- E obtemos o sistema:

$$\left\{ \begin{array}{l} (\sum_{i=1}^m g_1(x_i)g_1(x_i))a_1 + (\sum_{i=1}^m g_2(x_i)g_1(x_i))a_2 \dots + (\sum_{i=1}^m g_n(x_i)g_1(x_i))a_n = \sum_{i=1}^m f(x_i)g_1(x_i) \\ (\sum_{i=1}^m g_1(x_i)g_2(x_i))a_1 + (\sum_{i=1}^m g_2(x_i)g_2(x_i))a_2 \dots + (\sum_{i=1}^m g_n(x_i)g_2(x_i))a_n = \sum_{i=1}^m f(x_i)g_2(x_i) \\ \dots \\ (\sum_{i=1}^m g_1(x_i)g_n(x_i))a_1 + (\sum_{i=1}^m g_2(x_i)g_n(x_i))a_2 \dots + (\sum_{i=1}^m g_n(x_i)g_n(x_i))a_n = \sum_{i=1}^m f(x_i)g_n(x_i) \end{array} \right.$$

Exemplo

- Considere a função $f(x)$ definida conforme a tabela:

x	-2	-1	0	1	2	3
$f(x)$	19.01	3.99	-1.00	4.01	18.99	45.00

ao traçarmos o gráfico, vemos que os pontos se assemelham a uma parábola. Encontre, pois, o polinômio de grau dois que melhor se ajusta aos pontos.

$$g(x) = a_1x^2 + a_2x + a_3$$

$$\text{isto é: } g_1 = x^2, \quad g_2 = x \quad \text{e} \quad g_3 = 1$$

Exemplo (solução)

- Temos o sistema de equações normais:

$$\begin{bmatrix} \sum_{i=1}^6 x_i^4 & \sum_{i=1}^6 x_i^3 & \sum_{i=1}^6 x_i^2 \\ \sum_{i=1}^6 x_i^3 & \sum_{i=1}^6 x_i^2 & \sum_{i=1}^6 x_i \\ \sum_{i=1}^6 x_i^2 & \sum_{i=1}^6 x_i & 6 \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix} \begin{bmatrix} \sum_{i=1}^6 f(x_i)x_i^2 \\ \sum_{i=1}^6 f(x_i)x_i \\ \sum_{i=1}^6 f(x_i) \end{bmatrix}$$

$\sum_{i=1}^6 g_1(x_i) g_1(x_i)$

$\sum_{i=1}^6 g_3(x_i) g_2(x_i)$

e assim por diante...

Numericamente

	xi	xi ²	xi ³	xi ⁴	f(xi)	xif(xi)	xi ² f(xi)
	-2.00	4.00	-8.00	16.00	19.01	-38.02	76.04
	-1.00	1.00	-1.00	1.00	3.99	-3.99	3.99
	0.00	0.00	0.00	0.00	-1	0	0
	1.00	1.00	1.00	1.00	4.01	4.01	4.01
	2.00	4.00	8.00	16.00	18.99	37.98	75.96
	3.00	9.00	27.00	81.00	45.00	135	405
soma:	3.00	19.00	27.00	115.00	90.00	134.98	565.00

$$\begin{bmatrix} 115 & 27 & 19 \\ 27 & 19 & 3 \\ 19 & 3 & 6 \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix} \begin{bmatrix} 565 \\ 134.98 \\ 90.00 \end{bmatrix}$$

$$\begin{aligned} a_1 &= 5.0893 \\ a_2 &= 0.0515 \\ a_3 &= -1.1403 \end{aligned}$$

Função $g(x)$

- $g(x) = 5.0893x^2 + 0.0515x - 1.1403$
- Nenhuma outra função quadrática apresentará um menor erro quadrático para aqueles pontos.