

MAP 3121 - Métodos Numéricos e Aplicações

Método dos Mínimos Quadrados

Caso geral e discreto - Aula 1

Depto. Matemática Aplicada
Instituto de Matemática e Estatística
Universidade de São Paulo
São Paulo - SP

Abordaremos o problema de **aproximar** uma função f por outra g pertencente a uma **família** de funções G **previamente** escolhida.

- Ao **aproximar** f por g em G introduzimos um erro chamado **resíduo**:

$$r(x) = f(x) - g(x)$$

- É necessário **minimizar** r para que uma **boa** aproximação g seja **obtida**.

Mínimos Quadrados

Exigimos que a seguinte quantidade seja **mínima**:

$$\sum_x r(x)^2. \tag{1}$$

- Note que minimizar $\sum_x r(x)$ não é adequado pelo **cancelamento** de erros positivos e negativos.
- Poderíamos usar $\sum_x |r(x)|$. Por questões **geométricas/diferenciabilidade** escolhemos (1).

Abaixo vemos que o **método de mínimos quadrados** está associado a espaços vetoriais com **produto interno**. Na sequência estudamos métodos que são na verdade **casos particulares** deste resultado.

Formulação geométrica

Seja F um espaço vetorial real com **produto interno** $\langle \cdot, \cdot \rangle$

$$(f, g) \in F \times F \mapsto \langle f, g \rangle \in \mathbb{R},$$

$f \in F$ e $G \subset F$ um **subespaço** gerado pelos vetores g_0, g_1, \dots, g_m .

- Ache $g \in G$ que **melhor aproxime** f , ou seja, $g \in G$ tal que o erro quadrático

$$E(f, g) := \langle f - g, f - g \rangle = \|f - g\|_F^2$$

seja o **menor possível**.

Exemplos de **espaços** com produto interno:

- a) $\mathbb{R}^N = \{(x_1, x_2, \dots, x_N) : x_i \in \mathbb{R}, \quad i = 1, \dots, N\}$ com $\langle x, y \rangle = \sum_{i=1}^N x_i y_i$.

Assim:

$$E(x, y) = \sum_{i=1}^N (x_i - y_i)^2, \quad x, y \in \mathbb{R}^N.$$

Recordamos que este produto interno é muitas vezes chamado **produto escalar**

e define a norma **Euclidiana** em \mathbb{R}^N por $\|x\| = \sqrt{\langle x, x \rangle} = \sqrt{\sum_{i=1}^N x_i^2}$.

- b) Seja $F = \{\alpha_0 1 + \alpha_1 x + \dots + \alpha_n x^n : \alpha_i \in \mathbb{R}, \quad i = 0, 1, \dots, n\}$ o espaço dos **polinômios** de grau menor ou igual a n com


$$\langle f, g \rangle = \int_{-1}^1 f(x) g(x) dx.$$

Assim:

$$E(f, g) = \int_{-1}^1 \{f(x) - g(x)\}^2 dx.$$

Ortogonalidade

Em **espaços vetoriais** com produto interno podemos trabalhar com **ortogonalidade** e também minimizar distância.



O vetor de $g \in G$ que melhor **aproxima** f é o vetor tal que $f - g$ é **ortogonal** a G . Isto ocorre se, e somente se, $\langle f - g, g_j \rangle = 0$ para todo $j = 0, \dots, m$ onde¹

$$G = [g_0, g_1, \dots, g_m].$$

¹Lembre-se que o subespaço G é gerado pelos vetores g_0, g_1, \dots, g_m .

Como $g \in G$, existem números reais a_0, \dots, a_m tais que

$$g = a_0 g_0 + \dots + a_m g_m.$$

Assim, esses **números** devem resolver o seguinte **sistema**²

$$\begin{pmatrix} \langle g_0, g_0 \rangle & \dots & \langle g_0, g_m \rangle \\ \vdots & \ddots & \vdots \\ \langle g_m, g_0 \rangle & \dots & \langle g_m, g_m \rangle \end{pmatrix} \begin{pmatrix} a_0 \\ \vdots \\ a_m \end{pmatrix} = \begin{pmatrix} \langle g_0, f \rangle \\ \vdots \\ \langle g_m, f \rangle \end{pmatrix} \quad (2)$$

já que **para todo** j

$$\begin{aligned} 0 &= \langle f - g, g_j \rangle = \langle f - (a_0 g_0 + \dots + a_m g_m), g_j \rangle \\ &= \langle f, g_j \rangle - a_0 \langle g_0, g_j \rangle - \dots - a_m \langle g_m, g_j \rangle \\ &= \langle f, g_j \rangle - (\langle g_0, g_j \rangle, \dots, \langle g_m, g_j \rangle) \cdot (a_0, \dots, a_m). \end{aligned}$$

i) Particularmente **interessante** é o caso em que $\langle g_i, g_j \rangle = 0$ para $i \neq j$. Assim

$$a_j = \frac{\langle g_j, f \rangle}{\langle g_j, g_j \rangle} \quad j = 0, 1, \dots, m.$$

ii) **Note** que a matriz que define o sistema é **simétrica**.

²Este sistema é muitas vezes chamado **sistema normal**.

Chamamos o método de método dos mínimos quadrados **discreto** quando o espaço vetorial F **assume** a forma particular $F = \mathbb{R}^N$ para algum $N \in \mathbb{N}$.

O problema

Dados N pontos do gráfico de uma função

$$\{(x_1, y_1), \dots, (x_N, y_N)\} \subset \mathbb{R}^2$$

x_j distintos, $y_j = f(x_j)$ e $m + 1$ **funções**

$$g_0, \dots, g_m : I \rightarrow \mathbb{R}$$

em que $I \subset \mathbb{R}$ é um intervalo que contém x_1, \dots, x_N . **Encontre** a_0, a_1, \dots, a_m tais que

$$y(x) = a_0 g_0(x) + a_1 g_1(x) + \dots + a_m g_m(x)$$

seja a melhor função que **aproxime** esses pontos.

Para **resolvermos** este problema, definimos o seguinte **erro** quadrático:

$$E(a_0, a_1, \dots, a_m) = \sum_{i=1}^N |y_i - (a_0 g_0(x_i) + a_1 g_1(x_i) + \dots + a_m g_m(x_i))|^2.$$

Definimos também os **vetores**

$$f = (y_1, \dots, y_N) \quad \text{e} \quad g_j = (g_j(x_1), \dots, g_j(x_N)), \quad j = 0, 1, \dots, m$$

e usamos o seguinte **produto interno** em \mathbb{R}^N

$$\langle z, w \rangle = \sum_{i=1}^N z_i w_i, \quad z, w \in \mathbb{R}^N.$$

Se $g = a_0 g_0 + \dots + a_m g_m$ **temos** que

$$E(a_0, a_1, \dots, a_m) = \langle f - g, f - g \rangle.$$

Além disso, os **valores** a_0, a_1, \dots, a_m que **minimizam** E são soluções do sistema

$$\begin{aligned} & \begin{pmatrix} \sum_{j=1}^N g_0(x_j) g_0(x_j) & \cdots & \sum_{j=1}^N g_0(x_j) g_m(x_j) \\ \vdots & \ddots & \vdots \\ \sum_{j=1}^N g_m(x_j) g_0(x_j) & \cdots & \sum_{j=1}^N g_m(x_j) g_m(x_j) \end{pmatrix} \begin{pmatrix} a_0 \\ \vdots \\ a_m \end{pmatrix} \\ &= \begin{pmatrix} \sum_{j=1}^N g_0(x_j) y_j \\ \vdots \\ \sum_{j=1}^N g_m(x_j) y_j \end{pmatrix} \end{aligned}$$

já que

$$\langle g_j, g_k \rangle = \sum_{i=1}^N g_j(x_i) g_k(x_i), \quad 0 \leq j, k \leq m.$$

1) O **sinal** de um osciloscópio corresponde a superposição de efeitos oscilatório e crescente. Nestas condições o **aproximamos** por uma função do tipo

$$g(x) = ax + b \cos x.$$

Medindo alguns valores deste sinal obtemos

x	0	1.5	3.0	4.5	6.0
$f(x)$	1.0	1.57	2.0	4.3	7.0

Usando notações **anteriores** temos $g_0(x) = x$ e $g_1(x) = \cos x$.

$$f = (1.0, 1.57, 2.0, 4.3, 7.0), \quad g_0 = (0, 1.5, 3.0, 4.5, 6.0)$$
$$\text{e } g_1 = (\cos(0), \cos(1.5), \cos(3.0), \cos(4.5), \cos(6.0))$$

que nos leva ao **sistema**

$$\begin{pmatrix} \langle g_0, g_0 \rangle & \langle g_0, g_1 \rangle \\ \langle g_1, g_0 \rangle & \langle g_1, g_1 \rangle \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \langle g_0, f \rangle \\ \langle g_1, f \rangle \end{pmatrix}$$

que é igual a

$$\begin{pmatrix} 67.5 & 1.949 \\ 1.949 & 2.952 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} 69.71 \\ 4.946 \end{pmatrix}$$

cuja **solução** é: $(a, b) = (1.003, 1.013)$.

Observações dadas:

x	0	1.5	3.0	4.5	6.0
$f(x)$	1.0	1.57	2.0	4.3	7.0





Figura: Gráfico da função $g(x) = 1.003x + 1.013 \cos x$.

2) **Regressão linear.** Determine a **reta** que melhor ajusta a função abaixo segundo o método de **mínimos quadrados**

x	0	1	2	3	4
$f(x)$	0	1	1	4	4

Temos $g_0(x) = 1$ e $g_1(x) = x$.

$$f = (0, 1, 1, 4, 4), \quad g_0 = (1, 1, 1, 1, 1)$$

$$\text{e } g_1 = (0, 1, 2, 3, 4)$$

que nos leva ao **sistema**

$$\begin{pmatrix} \langle g_0, g_0 \rangle & \langle g_0, g_1 \rangle \\ \langle g_1, g_0 \rangle & \langle g_1, g_1 \rangle \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \langle g_0, f \rangle \\ \langle g_1, f \rangle \end{pmatrix}$$

que é igual a

$$\begin{pmatrix} 5 & 10 \\ 10 & 30 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} 10 \\ 31 \end{pmatrix}$$

cuja **solução** é: $(a, b) = (-1/5, 11/10)$.

Observações dadas:

x	0	1	2	3	4
$f(x)$	0	1	1	4	4





Figura: Gráfico da função $g(x) = -1/5 + (11/10)x$.

Note que a **Regressão linear** do conjunto

$$\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \subset \mathbb{R}^2$$

é o caso geral previamente discutido **assumindo**

$$m = 1, \quad g_0(x) = 1 \quad \text{e} \quad g_1(x) = x.$$

Logo, é **equivalente** a resolver o seguinte **sistema linear**

$$\begin{pmatrix} N & \sum_{i=1}^N x_i \\ \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_i y_i \end{pmatrix}$$

já que se

$$\langle g_j, g_k \rangle = \sum_{i=1}^N g_j(x_i) g_k(x_i), \quad 0 \leq j, k \leq 2$$

$$g_0 = (1, 1, \dots, 1), \quad g_1 = (x_1, x_2, \dots, x_N) \quad \text{e} \quad f = (y_1, y_2, \dots, y_N).$$

então

$$\langle g_0, g_0 \rangle = \sum_{i=1}^N 1^2, \quad \langle g_0, g_1 \rangle = \sum_{i=1}^N x_i \quad \text{e} \quad \langle g_1, g_1 \rangle = \sum_{i=1}^N x_i^2.$$