

MS211 - Cálculo Numérico

Ajuste de Curvas e o Método dos Quadrados Mínimos:
Caso Discreto
(Slides Modificados de M. E. Valle)

O Método dos Quadrados Mínimos

O *Método dos Quadrados Mínimos* é um método de *otimização* que serve para encontrar um vetor $\mathbf{x}^* \in \mathbb{R}^n$ que minimiza

$$\|\mathbf{Ax} - \mathbf{b}\|_2, \text{ sendo } \mathbf{A} \in \mathbb{R}^{m \times n} \text{ e } \mathbf{b} \in \mathbb{R}^m.$$

Sob certas condições, existe um único $\mathbf{x}^* \in \mathbb{R}^n$ tal que

$$\|\mathbf{Ax}^* - \mathbf{b}\|_2 = \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|_2.$$

Note que

$$\|\mathbf{Ax}^* - \mathbf{b}\|_2 = \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|_2 \Leftrightarrow \|\mathbf{Ax}^* - \mathbf{b}\|_2^2 = \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|_2^2.$$

Este método *pode* ser usado para *ajustar uma curva de uma certa forma a dados*.

Ajuste de Curvas – Caso Discreto

Suponha que temos uma tabela

| | | | | |
|-----|-------|-------|---------|-------|
| x | x_1 | x_2 | \dots | x_m |
| y | y_1 | y_2 | \dots | y_m |

com x_1, x_2, \dots, x_m em um intervalo $[a, b]$. Escolhidas funções g_1, g_2, \dots, g_n , geralmente contínuas, nosso objetivo será encontrar coeficientes $\alpha_1, \alpha_2, \dots, \alpha_n$ de modo que a função

$$g(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x),$$

satisfaça

$$g(x_k) \approx y_k, \quad \forall k = 1, \dots, m.$$

As funções g_1, g_2, \dots, g_n podem ser escolhidas observando o gráfico dos pontos tabelados ou baseando-se em conceitos teóricos do experimento que forneceu a tabela.

O modelo matemático

$$g(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x),$$

é chamado **linear** porque os coeficientes $\alpha_1, \dots, \alpha_n$ aparecem linearmente. As funções g_1, \dots, g_n , porém, não precisam ser funções lineares; elas podem ser polinômios, funções trigonométricas, exponenciais, logaritmos, etc.

Podemos pensar que

$$y_k = f(x_k), \quad \forall k = 1, \dots, m,$$

para alguma função desconhecida f . Nesse caso, a função g fornece uma aproximação para f com base nos pontos amostrados $(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$.

Exemplo 1

Considere a tabela

| | | | | | | | | | | | |
|---|-------|-------|-------|-------|-------|------|------|------|------|------|------|
| x | -1.00 | -0.75 | -0.60 | -0.50 | -0.30 | 0.00 | 0.20 | 0.40 | 0.50 | 0.70 | 1.00 |
| y | 2.05 | 1.15 | 0.45 | 0.40 | 0.50 | 0.00 | 0.20 | 0.60 | 0.51 | 1.20 | 2.05 |

Podemos colocar os pontos tabelados $(x_1, y_1), \dots, (x_{11}, y_{11})$ em um gráfico cartesiano chamado **diagrama de dispersão**.

O diagrama de dispersão sugere que os pares (x_k, y_k) pertencem à uma parábola. Portanto, escolhermos


$$g_1(x) = x^2, \quad g_2(x) = x \quad \text{e} \quad g_3(x) = 1.$$

Dessa forma,

$$\begin{aligned} g(x) &= \alpha_1 g_1(x) + \alpha_2 g_2(x) + \alpha_3 g_3(x) \\ &= \alpha_1 x^2 + \alpha_2 x + \alpha_3, \end{aligned}$$

descreve uma parábola.

Diagrama de Dispersão



Formulação Matemática

Escolhidas as funções g_1, \dots, g_n , no problema de quadrados mínimos, queremos determinar $\alpha_1, \dots, \alpha_n$ tais que

$$g(x) \approx f(x) \Leftrightarrow g(x) - f(x) \approx 0 \quad \text{para } x = x_1, \dots, x_m.$$

Equivalentemente, obtemos

$$\begin{bmatrix} g(x_1) \\ g(x_2) \\ \vdots \\ g(x_m) \end{bmatrix} \approx \begin{bmatrix} f(x_1) \\ f(x_2) \\ \vdots \\ f(x_m) \end{bmatrix}$$

Queremos que a soma dos quadrados dos desvios $g(x_k) - y_k$ seja mínima, ou seja, queremos minimizar

$$E(\alpha_1, \dots, \alpha_n) = \|\bar{g} - \bar{f}\|^2 = \sum_{k=1}^m (g(x_k) - y_k)^2;$$

Chegando a uma Forma Matricial

$$\text{Seja } g(x) = \alpha_1 g_1(x) + \dots + \alpha_n g_n(x)$$

$$\begin{pmatrix} g(x_1) \\ \vdots \\ g(x_m) \end{pmatrix} \approx \begin{pmatrix} f(x_1) \\ \vdots \\ f(x_m) \end{pmatrix}$$

$$\Leftrightarrow \underbrace{\begin{pmatrix} g_1(x_1) \\ \vdots \\ g_1(x_m) \end{pmatrix}}_{\bar{g}_1} \dots \underbrace{\begin{pmatrix} g_n(x_1) \\ \vdots \\ g_n(x_m) \end{pmatrix}}_{\bar{g}_n} \cdot \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} \approx \begin{pmatrix} f(x_1) \\ \vdots \\ f(x_m) \end{pmatrix}$$

$$\Leftrightarrow \begin{pmatrix} | & & | \\ \bar{g}_1 & \dots & \bar{g}_n \\ | & & | \end{pmatrix} \cdot \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} \approx \begin{pmatrix} f(x_1) \\ \vdots \\ f(x_m) \end{pmatrix}$$

$$\text{onde } \bar{g}_i = \begin{pmatrix} g_i(x_1) \\ \vdots \\ g_i(x_m) \end{pmatrix} \quad i=1, \dots, n$$

Resumo da Forma Matricial

Queremos minimizar
a distância entre Ax e b ,
onde euclidiana

$$A = \begin{pmatrix} \dot{g}_1 & \dots & \dot{g}_n \\ \vdots & & \vdots \end{pmatrix}, x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

$$e \ b = \begin{pmatrix} f(x_1) \\ \vdots \\ f(x_m) \end{pmatrix}$$

Dica para lembrar:

$$Ax^* = b$$

$$\Leftrightarrow A^t A x^* = A^t b$$

Seja $m > n$, $\text{posto}(A) = n$

$$\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^n} \|Ax - b\|_2$$

$$\Leftrightarrow A^t A x^* = A^t b$$

Justificativa

No curso de Cálculo II, vimos que o mínimo de $E(\alpha_1, \dots, \alpha_n)$ deve satisfazer

$$\frac{\partial E}{\partial \alpha_j} = 0, \quad \forall j = 1, \dots, n.$$

Pela regra da cadeia, a derivada parcial é

$$\frac{\partial E}{\partial \alpha_j} = 2 \sum_{k=1}^m \left(\alpha_1 \mathbf{g}_1(\mathbf{x}_k) + \dots + \alpha_n \mathbf{g}_n(\mathbf{x}_k) - \mathbf{y}_k \right) \mathbf{g}_j(\mathbf{x}_k).$$

Dessa forma, devemos ter

$$\sum_{k=1}^m \left(\alpha_1 \mathbf{g}_1(\mathbf{x}_k) + \dots + \alpha_n \mathbf{g}_n(\mathbf{x}_k) - \mathbf{y}_k \right) \mathbf{g}_j(\mathbf{x}_k) = 0, \quad \forall j = 1, \dots, n.$$

Equações Normais

Alternativamente, podemos escrever

$$\left\{ \begin{array}{l} \left(\sum_{k=1}^m g_1(x_k)g_1(x_k) \right) \alpha_1 + \dots + \left(\sum_{k=1}^m g_n(x_k)g_1(x_k) \right) \alpha_n = \sum_{k=1}^m y_k g_1(x_k), \\ \left(\sum_{k=1}^m g_1(x_k)g_2(x_k) \right) \alpha_1 + \dots + \left(\sum_{k=1}^m g_n(x_k)g_2(x_k) \right) \alpha_n = \sum_{k=1}^m y_k g_2(x_k), \\ \vdots \\ \left(\sum_{k=1}^m g_1(x_k)g_n(x_k) \right) \alpha_1 + \dots + \left(\sum_{k=1}^m g_n(x_k)g_n(x_k) \right) \alpha_n = \sum_{k=1}^m y_k g_n(x_k), \end{array} \right.$$

que é um sistema linear com n equações e incógnitas

$\alpha_1, \dots, \alpha_n$.

Em termos matriciais, essas equações podem ser escritas como

$$\mathbf{B}\alpha = \mathbf{b},$$

em que $\mathbf{B} = (b_{ij}) \in \mathbb{R}^{n \times n}$, $\alpha = (\alpha_j) \in \mathbb{R}^n$ e $\mathbf{b} = (b_i) \in \mathbb{R}^n$, com

$$b_{ij} = \sum_{k=1}^m g_i(x_k)g_j(x_k) \quad \text{e} \quad b_i = \sum_{k=1}^m y_k g_i(x_k), \quad \forall i, j = 1, \dots, n.$$

O sistema linear acima é chamado **equação normal**.

Note que \mathbf{B} e \mathbf{b} do slide anterior são dados por:

$$\blacksquare \mathbf{B} = \mathbf{A}^T \mathbf{A},$$

$$\blacksquare \mathbf{b} = \mathbf{A}^T \mathbf{y},$$

sendo

$$\mathbf{A} = \begin{bmatrix} g_1(x_1) & g_2(x_1) & \dots & g_n(x_1) \\ g_1(x_2) & g_2(x_2) & \dots & g_n(x_2) \\ \vdots & \vdots & \vdots & \vdots \\ g_1(x_m) & g_2(x_m) & \dots & g_n(x_m) \end{bmatrix} \in \mathbb{R}^{m \times n} \quad \text{e} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix}.$$

Pode-se mostrar que o sistema linear

$$\mathbf{B}\alpha = \mathbf{b},$$

possui uma **única solução** $\alpha^* = [\alpha_1^*, \dots, \alpha_n^*]^T$ se os vetores $\bar{\mathbf{g}}_1, \dots, \bar{\mathbf{g}}_n$ forem **linearmente independentes**, ou -
equivalentemente - se $\text{posto}(\mathbf{B}) = n$.

Sobretudo, os coeficientes $\alpha_1^*, \dots, \alpha_n^*$ obtidos fornecem o valor mínimo de

$$E(\alpha_1, \dots, \alpha_n) = \sum_{k=1}^m \left(g(x_k) - y_k \right)^2.$$

Exemplo 2

Considere a tabela

| | | | | | | | | | | | |
|---|-------|-------|-------|-------|-------|------|------|------|------|------|------|
| x | -1.00 | -0.75 | -0.60 | -0.50 | -0.30 | 0.00 | 0.20 | 0.40 | 0.50 | 0.70 | 1.00 |
| y | 2.05 | 1.15 | 0.45 | 0.40 | 0.50 | 0.00 | 0.20 | 0.60 | 0.51 | 1.20 | 2.05 |

e as funções

$$g_1(x) = x^2, \quad g_2(x) = x \quad \text{e} \quad g_3(x) = 1.$$

Nesse caso, temos os vetores

| | | | | | | | | | | | |
|----------------|-------|-------|-------|-------|-------|------|------|------|------|------|------|
| \mathbf{g}_1 | 1.00 | 0.56 | 0.36 | 0.25 | 0.09 | 0.00 | 0.04 | 0.16 | 0.25 | 0.49 | 1.00 |
| \mathbf{g}_2 | -1.00 | -0.75 | -0.60 | -0.50 | -0.30 | 0.00 | 0.20 | 0.40 | 0.50 | 0.70 | 1.00 |
| \mathbf{g}_3 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 |

Além disso, temos

$$\mathbf{A}^T = \begin{bmatrix} 1.00 & 0.56 & 0.36 & \dots & 1.00 \\ -1.00 & -0.75 & -0.60 & \dots & 1.00 \\ 1.00 & 1.00 & 1.00 & \dots & 1.00 \end{bmatrix}$$

Dessa forma, temos as equações normais

$$\underbrace{\begin{bmatrix} 2.85 & -0.25 & 4.20 \\ -0.25 & 4.20 & -0.35 \\ 4.20 & -0.35 & 11.00 \end{bmatrix}}_{\mathbf{A}^T \mathbf{A}} \underbrace{\begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \end{bmatrix}}_{\boldsymbol{\alpha}} = \underbrace{\begin{bmatrix} 5.87 \\ -0.11 \\ 9.11 \end{bmatrix}}_{\mathbf{A}^T \mathbf{y}},$$

cuja solução é

$$\boldsymbol{\alpha}^* = [1.94 \quad 0.10 \quad 0.09]^T.$$

Concluindo, a parábola que melhor se ajusta aos dados é


$$g(x) = 1.94x^2 + 0.10x + 0.09.$$

O mínimo da soma dos quadrados dos desvios, também chamado **resíduo**, é

$$E(\alpha_1^*, \alpha_2^*, \alpha_3^*) = \sum_{k=1}^m \left((1.94x_k^2 + 0.10x_k + 0.09) - y_k \right)^2 = 0.24.$$

O gráfico a seguir ilustra os dados tabelados e a parábola obtida:

Ajuste de curva



O Caso Não Linear: Um Exemplo de Linearização

Em alguns casos, o método dos quadrados mínimos linear pode ser usado para ajustar uma função g **não linear** nos coeficientes. Suponha que queremos ajustar uma função exponencial

$$g(x) = \beta_1 e^{\beta_2 x}.$$

Nesse caso, podemos linearizar o problema usando uma transformação conveniente:

$$y \approx \beta_1 e^{\beta_2 x} \implies z = \ln(y) \approx \ln(\beta_1) + \beta_2 x.$$

Dessa forma, temos um problema linear

$$z \approx \alpha_1 + \alpha_2 x,$$


em que $\alpha_1 = \ln(\beta_1)$ e $\alpha_2 = \beta_2$.

Exemplo 3

Considere a tabela

| | | | | | | | | |
|---|-------|-------|-------|-------|------|------|------|------|
| x | -1.00 | -0.70 | -0.40 | -0.10 | 0.20 | 0.50 | 0.80 | 1.00 |
| y | 36.54 | 17.26 | 8.15 | 3.85 | 1.82 | 0.86 | 0.40 | 0.24 |

cujo diagrama de dispersão é



Linearizando do Problema

O diagrama de dispersão sugere um ajuste

$$y \approx \beta_1 e^{\beta_2 x}.$$

Fazendo a linearização $z = \ln(y)$, obtemos


$$Z \approx \alpha_1 + \alpha_2 X,$$

em que $\beta_1 = e^{\alpha_1}$ e $\beta_2 = \alpha_2$.

Portanto, podemos considerar a tabela seguinte referente o problema linearizado:

| | | | | | | | | |
|---|-------|-------|-------|-------|------|-------|-------|-------|
| x | -1.00 | -0.70 | -0.40 | -0.10 | 0.20 | 0.50 | 0.80 | 1.00 |
| z | 3.60 | 2.85 | 2.10 | 1.35 | 0.60 | -0.15 | -0.92 | -1.43 |

Diagrama de Dispersão do Problema Linearizado



Teste de Alinhamento

Teste de Alinhamento

Supor que vc escolheu $g(x)$ com
parâmetros $\alpha_1, \dots, \alpha_n$ para fazer
ajuste de curva.

teste de alinhamento para ver
se a escolha foi boa:

(a) "Linearização" de $g(x)$
($y \approx g(x) \Rightarrow z \approx$ ^{com somação} ~~função~~ linear)

(b) "Diagrama de dispersão" dos z_i

(c) Se os pts no diagrama emb)
estiverem alinhados (~~numa linha~~)

\Rightarrow boa escolha

Resolução do Problema Linearizado

Considerando a seguinte matriz \mathbf{A} e o seguinte vetor \mathbf{z} :

$$\mathbf{A} = \begin{bmatrix} 1 & -1.00 \\ 1 & -0.70 \\ \vdots & \vdots \\ 1 & 1.00 \end{bmatrix}, \quad \mathbf{z} = \ln(\mathbf{y}) = \begin{bmatrix} 3.6 \\ 2.85 \\ \vdots \\ -1.43 \end{bmatrix},$$

as equações normais do problema linearizado podem ser expressados como segue:

$$\underbrace{\begin{bmatrix} 8.00 & 0.30 \\ 0.30 & 3.59 \end{bmatrix}}_{\mathbf{B}=\mathbf{A}^T\mathbf{A}} \underbrace{\begin{bmatrix} \alpha_1 \\ \alpha_2 \end{bmatrix}}_{\boldsymbol{\alpha}} = \underbrace{\begin{bmatrix} 8.00 \\ -8.68 \end{bmatrix}}_{\mathbf{b}=\mathbf{A}^T\mathbf{z}},$$

cuja solução é

$$\boldsymbol{\alpha}^* = [1.09 \quad -2.51]^T.$$

Concluindo, o problema linearizado fornece

$$z \approx 1.09 - 2.51x.$$

$$E_{\text{linearizado}}(\alpha_1^*, \alpha_2^*) = \sum_{k=1}^m \left((1.09 - 2.51x_k) - z_k \right)^2 = 3.2 \times 10^{-4}.$$


Retornando ao problema original, temos

$$\begin{aligned} \beta_1^* &= e^{\alpha_1} = 2.99 \quad \text{e} \quad \beta_2^* = \alpha_2 = -2.51. \\ \Rightarrow \quad y &\approx 2.99e^{-2.51x}. \end{aligned}$$

O resíduo do problema original, quer dizer, a soma dos quadrados dos desvios do problema original, é

$$E(\beta_1^*, \beta_2^*) = \sum_{k=1}^m \left(2.99e^{-2.51x_k} - y_k \right)^2 = 0.038.$$

Visualização do Ajuste de Curva Obtido



Observação

É importante observar que os parâmetros β_1^* e β_2^* não minimizam necessariamente

$$E(\beta_1, \beta_2) = \sum_{k=1}^m \left(\beta_1 e^{\beta_2 x_k} - y_k \right)^2,$$

pois eles foram obtidos através do problema linearizado, não do problema original!

Outros Exemplos de Linearização

Outros exemplos:

(1) Hipérbole

$$y \approx \frac{1}{\alpha_1 + \alpha_2 x} = g(x)$$

$$\Rightarrow z = \frac{1}{y} \approx \alpha_1 + \alpha_2 x$$

(2) Curva exponencial

$$y \approx \alpha_1 \alpha_2^x = g(x)$$

onde $y > 0$

$$\Rightarrow z = \ln(y) \approx \underbrace{\ln(\alpha_1)}_{a_1} + x \underbrace{\ln(\alpha_2)}_{a_2}$$

(3) Curva geométrica

$$y \approx \alpha_1 x^{\alpha_2} = g(x)$$

onde $x, y > 0$

$$\Rightarrow z = \ln(y) \approx \underbrace{\ln(\alpha_1)}_{a_1} + \underbrace{\alpha_2}_{a_2} \underbrace{\ln(x)}_t$$

(4) Curva trigonométrica

$$y \approx \alpha_1 + \alpha_2 \underbrace{\cos(\omega x)}_t, \text{ onde } \omega \text{ é constante}$$

Considerações Finais

O método dos quadrados mínimos linear é usado para encontrar

$$g(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x),$$

que melhor se ajusta a uma tabela

| | | | | |
|-----|-------|-------|---------|-------|
| x | x_1 | x_2 | \dots | x_m |
| y | y_1 | y_2 | \dots | y_m |

com x_1, x_2, \dots, x_m em um intervalo $[a, b]$.

Os coeficientes $\alpha_1^*, \dots, \alpha_n^*$ são obtidos resolvendo o sistema

$$(\mathbf{A}^T \mathbf{A})\alpha = \mathbf{A}^T \mathbf{y},$$

conhecido como **equação normal**.

Muito grato pela atenção!