

# Métodos dos quadrados mínimos no caso contínuo e no caso não linear

MS211 – Cálculo Numérico

Giuseppe Romanazzi

1 Dezembro 2020

# Conteúdo

- 1 Problemas dos quadrados mínimos no caso contínuo
- 2 Problema dos quadrados mínimos no caso não linear

# Problemas dos quadrados mínimos

Analisaremos nesta aula os problemas e métodos de quadrados mínimos no caso contínuo. Estes problemas aparecem quando se quer aproximar ou ajustar uma curva disponibilizada  $f(x)$  dentro um padrão de curvas possíveis minimizando a distancia da curva dada do padrão de curvas considerado. A melhor curva neste padrão será obtida através um método dos quadrados mínimos no caso contínuo.

Além disso vamos ver como se pode aproximar uma curva, ou uma sequência de dados discretos, usando um modelo não linear com o método dos quadrados mínimos.

# Ajuste de uma curva no caso contínuo

Suponhamos de ter uma função contínua real  $f(x) : [a, b] \rightarrow \mathbb{R}$  que queremos aproximar ou ajustar usando uma combinação linear de funções  $\varphi(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x)$  que modela o problema observado.

O método dos quadrados mínimos vai encontrar os melhores  $\alpha_i$  tais que minimizam a distância ao quadrado entre  $f(x)$  e a  $\varphi(x)$ .

A distância (ao quadrado) entre as duas curvas contínuas  $f(x)$  e  $\varphi(x)$  em  $[a, b]$  é medida usando

$$d = \int_a^b (f(x) - \varphi(x))^2 dx$$

Esta distância generaliza a distancia discreta em  $m$  pontos

$$\sum_{k=1}^m (f(x_k) - \varphi(x_k))^2$$

usada nos problemas de quadrados mínimos para o caso contínuo onde  $m \rightarrow \infty$ , ou seja quando temos observações (infinitas) contínuas.

O integral que como sabemos generaliza o conceito de soma no caso contínuo

$$\sum_{k=1}^m (f(x_k) - \varphi(x_k))^2 \rightarrow \text{para } k \text{ infinito} \rightarrow \int_a^b (f(x) - \varphi(x))^2 dx$$

# Métodos dos quadrados mínimos no caso contínuo

O método de quadrados mínimos no caso contínuo consiste no minimizar ao variar dos  $\alpha_j$  a função distância ao quadrado

$$F(\alpha_1, \dots, \alpha_n) = \int_a^b (f(x) - \varphi(x))^2 dx$$

onde  $\varphi(x) = \sum_{j=1}^n \alpha_j g_j(x)$ . Procederemos como no caso discreto: minimizar  $F$  ao variar dos  $\alpha_j$  equivale a encontrar os  $\alpha_j$  tais que

$$\frac{\partial F}{\partial \alpha_i}(\alpha_1, \dots, \alpha_n) = 0 \quad \text{para cada } i = 1, \dots, n \quad (1)$$

Cada uma das  $n$  equações em cima será uma equação linear nos  $n$  coeficientes incógnitos  $\alpha_j$ . Portanto (1) é equivalente a resolver um sistema linear  $A\alpha = b$ , onde  $\alpha = (\alpha_1, \dots, \alpha_n)^t$

# Sistema linear associado ao método dos quadrados mínimos no caso contínuo

Observamos que para cada  $i = 1, \dots, n$ ,

$$\frac{\partial F}{\partial \alpha_i} = \frac{\partial}{\partial \alpha_i} \int_a^b (f(x) - \sum_{j=1}^n \alpha_j g_j(x))^2 dx =$$

$$2 \int_a^b (f(x) - \sum_{j=1}^n \alpha_j g_j(x)) \cdot \left(-\frac{\partial}{\partial \alpha_i} \sum_{j=1}^n \alpha_j g_j(x)\right) dx$$

Note que  $\frac{\partial}{\partial \alpha_i} \sum_{j=1}^n \alpha_j g_j(x) = g_i(x)$ . Portanto multiplicando por  $-2$

$$\frac{\partial F}{\partial \alpha_i} = 0 \iff \int_a^b (f(x) - \sum_{j=1}^n \alpha_j g_j(x)) g_i(x) dx = 0$$

A última igualdade pode ser escrita como a seguinte equação linear nos coeficientes  $\alpha_j$ :

$$\sum_{j=1}^n \left( \int_a^b g_i(x) g_j(x) dx \right) \alpha_j = \int_a^b f(x) g_i(x) dx \quad \text{para cada } i = 1, \dots, n$$

# Expressão do sistema linear usando o produto escalar de funções contínuas

Indicado com  $(\phi, \psi) := \int_a^b \phi(x)\psi(x)dx$  o produto escalar de duas funções contínuas genéricas  $\phi$  e  $\psi$  temos que as equações lineares para cada  $j = 1, \dots, n$

$$\sum_{j=1}^n \int_a^b g_j(x)g_j(x)dx \alpha_j = \int_a^b f(x)g_j(x)dx$$


podem ser escritas todas juntas como  $A\alpha = b$  com  $A = (a_{ij})$  onde  $a_{ij} = (g_i, g_j)$  e  $b_i = (f, g_i)$ . Portanto o sistema linear para resolver tem dimensão  $n$  e matriz  $A$  simétrica e o vetor  $b$  dados por

$$A = \begin{pmatrix} (g_1, g_1) & (g_1, g_2) & \cdots & (g_1, g_n) \\ (g_2, g_1) & (g_2, g_2) & \cdots & (g_2, g_n) \\ \vdots & \vdots & \cdots & \vdots \\ (g_n, g_1) & (g_n, g_2) & \cdots & (g_n, g_n) \end{pmatrix}, b = \begin{pmatrix} (f, g_1) \\ (f, g_2) \\ \vdots \\ (f, g_n) \end{pmatrix}$$



## Exemplo

Queremos achar a melhor reta  $\varphi(x) = ax + b$  que aproxima a função  $f(x) = 2x^2$  no intervalo  $[0, 2]$



Para determinar a melhor reta  $\varphi(x) = a + bx$  usamos o método dos quadrados mínimos contínuo com  $n = 2$  que usa  $g_1(x) = 1$ ,  $g_2(x) = x$ . Assim teremos  $\varphi(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x)$  com  $\alpha_1 = a$  e  $\alpha_2 = b$ . O sistema linear  $A\alpha = b$  para resolver tem dimensão 2

$$A = \begin{pmatrix} (g_1, g_1) & (g_1, g_2) \\ (g_2, g_1) & (g_2, g_2) \end{pmatrix} = \begin{pmatrix} \int_0^2 g_1^2(x) dx & \int_0^2 g_1(x)g_2(x) dx \\ \int_0^2 g_2(x)g_1(x) dx & \int_0^2 g_2(x)^2 dx \end{pmatrix}$$

$$\text{Observamos que } a_{11} = \int_0^2 g_1^2(x) dx = \int_0^2 1 dx = 2,$$

$$a_{21} = a_{12} = \int_0^2 g_1(x)g_2(x) dx = \int_0^2 x dx = \frac{x^2}{2} \Big|_0^2 = 2,$$

$$a_{22} = \int_0^2 x^2 dx = \frac{x^3}{3} \Big|_0^2 = \frac{8}{3}.$$


$$b_1 = \int_0^2 f(x)g_1(x) dx = \int_0^2 2x^2 \cdot 1 dx = \frac{16}{3},$$

$$b_2 = \int_0^2 f(x)g_2(x) dx = \int_0^2 2x^2 \cdot x dx = \frac{2x^4}{4} \Big|_0^2 = 2 \frac{16}{4} = 8.$$

O sistema para resolver é então

$$\begin{pmatrix} 2 & 2 \\ 2 & \frac{8}{3} \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \alpha_2 \end{pmatrix} = \begin{pmatrix} \frac{16}{3} \\ 8 \end{pmatrix}$$

A solução é  $\alpha_1 = -\frac{4}{3}$  e  $\alpha_2 = 4$ , portanto a melhor reta que a proxima a parábola dada é  $\varphi(x) = -\frac{4}{3} + 4x$



$$y = -\frac{4}{3} + 4x$$

## Problema dos quadrados mínimos no caso não linear

Não sempre o ajuste de uma função  $f(x)$  em  $[a, b]$  ou de um número finito de pontos  $(x_k, y_k)$  satisfaz um modelo linear. Por exemplo pode ser que o fenômeno/problema estudado satisfaz uma relação não linear, como aquela exponencial  $\varphi(x) = \alpha_1 + e^{\alpha_2 x}$ . Notamos que esta  $\varphi(x)$  é não linear respeito  $\alpha_2$  porque este coeficiente incógnito é argumento da função não linear exponencial. Suponhamos de ter observado o fenômeno  $m$  vezes e de ter medido os valores  $(x_k, y_k)$  com  $k = 1, \dots, m$ . Então: achar os melhores  $\alpha_1, \alpha_2$  que minimizam a soma das distancias(erros) ao

quadrado  $\sum_{k=1}^m (y_k - \varphi(x_k))^2$  com  $\varphi$  não linear nos  $\alpha_j$  é chamado

**problema dos quadrados mínimos no caso discreto não linear.**

Em vez se procuramos os melhores  $\alpha_1, \alpha_2$  que minimizam

$\int_a^b (f(x) - \varphi(x))^2 dx$  com  $\varphi$  uma função não linear nos  $\alpha_j$ , é dito

**problema dos quadrados mínimos no caso contínuo não linear.**

# Problema dos quadrados mínimos no caso não linear, necessitam na maior parte dos casos da resolução de sistemas não lineares

Se estivessemos no caso discreto e quiséssemos minimizar

$F(\alpha_1, \alpha_2) := \sum_{k=1}^m (y_k - \varphi(x_k))^2$ , com  $\varphi(x) = \alpha_1 + e^{\alpha_2 x}$ , teremos de

resolver um sistema não linear de  $n = 2$  incógnitas  $\alpha_1, \alpha_2$ . Isso porque

$$\frac{\partial F}{\partial \alpha_1} = 0 \iff 2 \sum_{k=1}^m (y_k - \alpha_1 - e^{\alpha_2 x_k})(-1) = 0 \iff$$

$$\sum_{k=1}^m (y_k - \alpha_1 - e^{\alpha_2 x_k}) = 0;$$

$$\frac{\partial F}{\partial \alpha_2} = 0 \iff 2 \sum_{k=1}^m (y_k - \alpha_1 - e^{\alpha_2 x_k})(-e^{\alpha_2 x_k} x_k) = 0 \iff$$

$$\sum_{k=1}^m (y_k - \alpha_1 - e^{\alpha_2 x_k})(e^{\alpha_2 x_k} x_k) = 0;$$

Então teremos de resolver o seguinte sistema não linear em  $\alpha_1, \alpha_2$

$$\left\{ \begin{array}{l} \sum_{k=1}^m (y_k - \alpha_1 - e^{\alpha_2 x_k}) = 0 \\ \sum_{k=1}^m (y_k - \alpha_1 - e^{\alpha_2 x_k})(e^{\alpha_2 x_k} x_k) = 0 \end{array} \right.$$

Que pode ser resolvido com o método de Newton para sistemas não lineares, ver Aula 14.

## PQM no caso geral discreto não linear

No caso geral discreto não linear com a função do modelo do fenômeno  $\varphi(x) = \phi(x, \alpha_1, \dots, \alpha_n)$  que depende dos  $n$  parâmetros incógnitos  $\alpha_j$  teremos de resolver o seguinte sistema não linear de  $n$  equações

$$\left\{ \begin{array}{l} \sum_{k=1}^m (y_k - \phi(x_k, \alpha_1, \dots, \alpha_n)) \cdot \frac{\partial \phi}{\partial \alpha_1}(x_k, \alpha_1, \dots, \alpha_n) = 0 \\ \sum_{k=1}^m (y_k - \phi(x_k, \alpha_1, \dots, \alpha_n)) \cdot \frac{\partial \phi}{\partial \alpha_2}(x_k, \alpha_1, \dots, \alpha_n) = 0 \\ \dots \\ \sum_{k=1}^m (y_k - \phi(x_k, \alpha_1, \dots, \alpha_n)) \cdot \frac{\partial \phi}{\partial \alpha_n}(x_k, \alpha_1, \dots, \alpha_n) = 0 \end{array} \right.$$



## PQM no caso geral contínuo não linear

Analogamente no caso contínuo onde temos ajustar a função contínua  $f(x)$  num modelo não linear  $\varphi(x) = \phi(x, \alpha_1, \dots, \alpha_n)$  que depende dos  $n$  parâmetros  $\alpha_j$  teremos de resolver o seguinte sistema não linear de  $n$  equações

$$\left\{ \begin{array}{l} \int_a^b (f(x) - \phi(x, \alpha_1, \dots, \alpha_n)) \cdot \frac{\partial \phi}{\partial \alpha_1}(x, \alpha_1, \dots, \alpha_n) dx = 0 \\ \int_a^b (f(x) - \phi(x, \alpha_1, \dots, \alpha_n)) \cdot \frac{\partial \phi}{\partial \alpha_2}(x, \alpha_1, \dots, \alpha_n) dx = 0 \\ \dots \\ \int_a^b (f(x) - \phi(x, \alpha_1, \dots, \alpha_n)) \cdot \frac{\partial \phi}{\partial \alpha_n}(x, \alpha_1, \dots, \alpha_n) dx = 0 \end{array} \right.$$

# Linearização de algum problema dos quadrados mínimos não lineares

Algum problema dos quadrados mínimos não linear pode ser linearizado permitindo de resolver ele também através a resolução de um sistema linear, que pode ser resolvido usando um método numérico que é normalmente mais eficiente de resolver numericamente sistemas não lineares.

Isso porque necessita menos memória e um menor custo computacional respeito ao resolver numericamente sistemas não lineares.

Por exemplo considere de ter  $m$  dados  $(x_k, y_k)$  de um problema descrito por  $\varphi(x) = \alpha_1 e^{\alpha_2 x}$  onde se desconhecem os parâmetros  $\alpha_1$  e  $\alpha_2$ . Se continuássemos a trabalhar com a  $\varphi(x)$  deste tipo teremos um problema não linear, que pode ser resolvido através a resolução numérica de um sistema não linear de duas equações obtido como na slide 16 anterior.

Mas observamos que

$$y_k \approx \varphi(x_k) = \alpha_1 e^{\alpha_2 x_k}$$

portanto teremos também que aplicando o logaritmo  $\ln$  em base  $e$

$$\ln(y_k) \approx \ln(\varphi(x_k)) = \ln(\alpha_1) + \alpha_2 x_k$$

Se denotamos  $a_1 := \ln(\alpha_1)$  e  $a_2 := \alpha_2$  teremos uma modelo linear que descreve o problema

$$\ln(y_k) \approx a_1 + a_2 x_k$$

- Agora com os  $m$  dados  $(x_k, \ln(y_k))$  queremos achar os melhores  $a_1$  e  $a_2$  tais que a soma das distâncias ao quadrado de  $z_k := \ln(y_k)$  respeito  $a_1 + a_2 x_k$  seja a menor possível no sentido dos quadrados

$$\text{mínimos: } \min_{a_1, a_2} \sum_{k=1}^m (z_k - (a_1 + a_2 x_k))^2$$

Note que este é um problema da reta dos mínimos quadrados (ver aula 20) portanto  $a_1, a_2$  serão obtidos resolvendo o sistema linear

$$\begin{pmatrix} m & \sum_{k=1}^m x_k \\ \sum_{k=1}^m x_k & \sum_{k=1}^m x_k^2 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} \sum_{k=1}^m z_k \\ \sum_{k=1}^m x_k z_k \end{pmatrix}$$

- Uma vez achados os melhores  $a_1$  e  $a_2$  do item anterior os melhores  $\alpha_1$  e  $\alpha_2$  que minimizam a soma dos quadrados  $\sum_{k=1}^m (y_k - \varphi(x_k))^2$  serão necessariamente  $\alpha_1 = e^{a_1}$  e  $\alpha_2 = a_2$ . Isso porque a função exponencial é contínua e vale que

$$a_1 = \ln(\alpha_1) \iff \alpha_1 = e^{a_1}$$

e por definição  $a_2 = \alpha_2$ .


## Exemplo não linear

$x_k$	-1.0	-0.8	-0.5	-0.2	0.1	0.4	0.7	1.0
$y_k$	0.246	0.406	0.860	1.82	3.852	8.155	17.264	36.547

Queremos achar os melhores  $\alpha_1$   $\alpha_2$  que minimizam a soma dos

quadrados das distâncias  $\sum_{k=1}^m (y_k - \varphi(x_k))^2$  onde  $\varphi(x) = \alpha_1 e^{\alpha_2 x}$  é a

função não linear que descreve o fenômeno analisado.



Para poder linearizar o problema, é suficiente aplicar o logaritmo e obteremos  $\ln(\varphi(x)) = \ln(\alpha_1) + \alpha_2 x = a_1 + a_2 x$ . Por isso obtemos uma função linear agora  $\phi(x) = a_1 + a_2 x$  que descreve as

$z_k := \ln(y_k)$  porque

$$y_k \approx \varphi(x_k) \iff z_k = \ln(y_k) \approx \ln(\varphi(x_k)) = a_1 + a_2 x_k.$$

Computamos os  $z_k = \ln(y_k)$  usando os dados em cima

$x_k$	-1.0	-0.8	-0.5	-0.2	0.1	0.4	0.7	1.0
$z_k$	-1.402	-0.901	-0.151	0.599	1.349	2.099	2.849	3.599

O sistema linear para resolver será

$$\begin{pmatrix} m & \sum_{k=1}^m x_k \\ \sum_{k=1}^m x_k & \sum_{k=1}^m x_k^2 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} \sum_{k=1}^m z_k \\ \sum_{k=1}^m x_k z_k \end{pmatrix}$$

ou seja com os dados do nosso problema

$$\begin{pmatrix} 8 & -0.3 \\ -0.3 & 3.59 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} 8.041 \\ 8.6463 \end{pmatrix}$$

Obtemos então  $a_1 = 1.099$  e  $a_2 = 2.5$ . Determinamos os parâmetros  $\alpha_1, \alpha_2$  do problema original. Sendo  $a_1 = \ln(\alpha_1)$  teremos  $\alpha_1 = e^{a_1} = e^{1.099} = 3.001$  e  $a_2 = \alpha_2 = 2.5$ . Então a melhor curva exponencial que passa perto dos pontos  $(x_k, y_k)$  dados é  $\varphi(x) = 3.001e^{2.5x}$ .

## Problemas não linearizáveis

Tem de tomar um certo cuidado na linearização, porque não todas as  $\varphi(x) = \Phi(x, \alpha_1, \dots, \alpha_2)$  são linearizáveis. Por exemplo:

- $\varphi(x) = \alpha_1 + e^{\alpha_2 x}$  não é linearizável aplicando o logaritmo  
 $\ln \varphi(x) = \ln(\alpha_1 + e^{\alpha_2 x}) \neq a + bx$ .
- $\varphi(x) = \alpha_1 + \cos(\alpha_2 x)$  não é linearizável aplicando arccos
- $\varphi(x) = \alpha_1 \sin(\alpha_2 x)$  não é linearizável aplicando arcsin
- $\varphi(x) = \alpha_1 \log_{10}(\alpha_2 x)$  não é linearizável aplicando a função exponencial  $10^x$



## Problemas PQM linearizáveis

São poucos os casos de problemas dos quadrados mínimos que podem ser linearizados simplesmente

- $\varphi(x) = \frac{1}{\alpha_1 + \alpha_2 x}$  pode ser linearizada usando a  $g(y) = \frac{1}{y}$ . Assim  $g(\varphi(x)) = g\left(\frac{1}{\alpha_1 + \alpha_2 x}\right) = \alpha_1 + \alpha_2 x$ .
- $\varphi(x) = \alpha_1 \alpha_2^x$ , aplicando  $g(y) = \ln(y)$ , obtemos  $\ln(\varphi(x)) = \ln(\alpha_1) + x \ln(\alpha_2)$  esta nova função  $\tilde{\varphi}(x) = \ln(\alpha_1) + x \ln(\alpha_2)$  é linear em  $a_1 = \ln(\alpha_1)$  e  $a_2 = \ln(\alpha_2)$  portanto  $\tilde{\varphi}(x)$  é linear e podemos aplicar o problema dos mínimos quadrados nos pontos  $(x_k, z_k) = (x_k, g(y_k)) = (x_k, \ln(y_k))$  achar  $a_1, a_2$  usando o método da reta dos quadrados mínimos, e depois podemos por  $\alpha_1 = e^{a_1}, \alpha_2 = e^{a_2}$ .
- $\varphi(x) = \tan(\alpha_1 + \alpha_2 x)$  é linearizável usando  $g(y) = \arctan(y)$
- $\varphi(x) = \alpha_1 e^{-\alpha_2 x}$  é linearizável usando  $g(y) = \ln(y)$   
 $\tilde{\varphi}(x) = g(\varphi(x)) = a_1 + a_2 x$  com  $a_1 = \ln(\alpha_1)$  e  $a_2 = -\alpha_2$ .