

Apontamentos das aulas

Método dos Mínimos Quadrados

Pedro R. S. Antunes (2005)

Em muitas aplicações estamos interessados em obter aproximações de uma dada função f por uma outra função g em geral mais simples. Uma possibilidade é considerar $g \equiv p_n$, o (único) polinómio de grau menor ou igual a n que interpola f em $n + 1$ pontos distintos de um intervalo $[a, b]$. No entanto, em muitas situações não é conveniente que a função aproximadora seja uma função interpoladora. Suponhamos que a função f traduz uma relação física entre duas grandezas x e $f(x)$. Experimentalmente podemos efectuar medições de $f(x)$ em pontos x_i , $i = 0, 1, \dots, n$ de forma a obter um conjunto de dados $(x_0, f_0), (x_1, f_1), \dots, (x_n, f_n)$. No entanto, nesse caso apenas dispomos dos valores $f_i = f(x_i) + \epsilon_i$, $i = 0, 1, \dots, n$, ou seja os valores f_i não correspondem exactamente aos valores $f(x_i)$, pois estão "contagiados" por um erro ϵ_i associado à imprecisão da medição. Ao tentar encontrar uma função g que constitua uma boa aproximação de f seria inadequado exigir que a função aproximadora interpolasse esses pontos.

Nesta secção vamos considerar outros tipos de funções aproximadoras para f , sem a exigência de que elas interpoem f . Uma solução mais adequada será definir uma base de funções

$$B = \{\phi_0(x), \phi_1(x), \dots, \phi_m(x)\}$$

e tomar para função aproximadora uma combinação linear das funções da base B , ou seja, definir

$$g(x) = \alpha_0\phi_0(x) + \alpha_1\phi_1(x) + \dots + \alpha_m\phi_m(x). \quad (1)$$

Pretendemos que a função g se aproxime "o mais possível" de f . Assim, vamos determinar os coeficientes $\alpha_0, \alpha_1, \dots, \alpha_m$ de forma a que os desvios

$$d_i = f_i - g(x_i), \quad i = 0, 1, \dots, n$$

sejam tão pequenos quanto possível, segundo algum critério¹. Para isso precisamos de uma noção de "distância", pelo que iremos considerar normas vectoriais. Designando por \vec{d} , \vec{f} e \vec{g} os vectores de \mathbb{R}^{n+1} com componentes d_i , f_i e g_i e escolhendo uma norma vectorial $\|\cdot\|$, os coeficientes $\alpha_0, \alpha_1, \dots, \alpha_m$ deverão ser determinados de

¹Se obtivermos $d_i = 0$, $i = 0, 1, \dots, n$ obtemos um caso de interpolação.

modo a que $\|\vec{d}\| = \|\vec{f} - \vec{g}\|$ seja mínima.

Como exemplos de normas de \mathbb{R}^{n+1} temos

$$\|\vec{d}\|_1 = \sum_{i=0}^n |d_i|, \quad \|\vec{d}\|_\infty = \max_{0 \leq i \leq n} |d_i| \quad \text{ou} \quad \|\vec{d}\|_2 = \left[\sum_{i=0}^n (d_i^2) \right]^{\frac{1}{2}}$$

A norma que vulgarmente é escolhida neste contexto é a norma $\|\cdot\|_2$, pelo que os parâmetros $\alpha_0, \alpha_1, \dots, \alpha_m$ são determinados de modo a minimizar

$$\|\vec{d}\|_2 = \left[\sum_{i=0}^n (d_i)^2 \right]^{\frac{1}{2}} = \left[\sum_{i=0}^n (f_i - g_i)^2 \right]^{\frac{1}{2}}.$$

Isto equivale a minimizar a quantidade

$$D = \|\vec{d}\|_2^2 = \sum_{i=0}^n (f_i - g_i)^2 \quad (2)$$

o que justifica a designação de *método dos mínimos quadrados*.

Um caso em que se aplicam estes conceitos é o da teoria da regressão linear. Em muitas aplicações de estatística, dada uma lista de pontos tentamos determinar a recta que melhor se ajusta aos pontos, ou seja, a recta que minimiza a soma dos quadrados dos desvios d_i . Isto corresponde a considerar $g(x) = \alpha_0\phi_0(x) + \alpha_1\phi_1(x)$ com $\phi_0(x) = 1$ e $\phi_1(x) = x$ (Figura 1).




Figura 1: A recta que, no sentido dos mínimos quadrados, melhor se ajusta à lista de pontos.

Exemplo

Consideramos a tabela de valores de uma função f

x_i	0	1	2	3
$f(x_i)$	0	0.2	1	5

Vamos determinar a recta $g(x) = \alpha_0 + \alpha_1 x$ que melhor se ajusta aos pontos da tabela segundo o critério dos mínimos quadrados. Consideramos

$$D = \left\| \vec{d} \right\|_2^2 = \sum_{i=0}^3 (f_i - g_i)^2 \quad (3)$$

como função de α_0 e α_1 . Pretende-se os valores α_0 e α_1 que tornam D mínima. Assim, vamos impor que

$$\frac{\partial D}{\partial \alpha_0} = 0 \quad e \quad \frac{\partial D}{\partial \alpha_1} = 0$$

Calculando directamente as derivadas parciais a partir da expressão (3) obtemos

$$\frac{\partial D}{\partial \alpha_0} = \sum_{i=0}^3 \frac{\partial}{\partial \alpha_0} [(f_i - \alpha_0 - \alpha_1 x_i)^2] = \sum_{i=0}^3 2(f_i - \alpha_0 - \alpha_1 x_i) \times (-1) = 0$$

Assim

$$\frac{\partial D}{\partial \alpha_0} = 0 \iff \sum_{i=0}^3 (\alpha_0 + \alpha_1 x_i) = \sum_{i=0}^3 f_i \quad (4)$$

Da mesma forma

$$\frac{\partial D}{\partial \alpha_1} = \sum_{i=0}^3 \frac{\partial}{\partial \alpha_1} [(f_i - \alpha_0 - \alpha_1 x_i)^2] = \sum_{i=0}^3 2(f_i - \alpha_0 - \alpha_1 x_i) \times (-x_i) = 0$$

pelo que

$$\frac{\partial D}{\partial \alpha_1} = 0 \iff \sum_{i=0}^3 (\alpha_0 x_i + \alpha_1 x_i^2) = \sum_{i=0}^3 x_i f_i \quad (5)$$

As relações (4) e (5) conduzem a um sistema linear de duas equações nas duas incógnitas α_0 e α_1 . Matricialmente temos

$$\begin{pmatrix} \sum_{i=0}^3 1 & \sum_{i=0}^3 x_i \\ \sum_{i=0}^3 x_i & \sum_{i=0}^3 x_i^2 \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} \sum_{i=0}^3 f_i \\ \sum_{i=0}^3 x_i f_i \end{pmatrix}$$

e substituindo os valores obtemos

$$\begin{pmatrix} 4 & 6 \\ 6 & 14 \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} 6.2 \\ 17.2 \end{pmatrix} \Rightarrow \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} -0.82 \\ 1.58 \end{pmatrix}$$

pele que a recta que melhor se ajusta aos pontos da tabela, segundo o critério dos mínimos quadrados é $g(x) = -0.82 + 1.58x$.

Na Figura 2 apresentamos dois possíveis ajustamentos de uma recta aos pontos da tabela. No primeiro caso consideramos uma recta arbitrária; no segundo caso temos o melhor ajustamento, no sentido dos mínimos quadrados. No primeiro caso obtivemos $D \approx 6157.1$, no segundo $D \approx 3.95$ um valor inferior como seria de esperar.




Figura 2: dois possíveis ajustamentos por uma recta

Caso Geral - As equações normais

Consideramos agora o caso geral de obter uma função da forma (1) onde os coeficientes $\alpha_0, \alpha_1, \dots, \alpha_m$ são obtidos de forma a minimizar a função

$$D = \left\| \vec{d} \right\|_2^2 = \sum_{i=0}^n (f_i - g_i)^2 \quad (6)$$

pele que é natural impor as condições

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

Assim obtemos

$$\frac{\partial D}{\partial \alpha_0} = \sum_{i=0}^n 2(f_i - \alpha_0 \phi_0(x_i) - \dots - \alpha_m \phi_m(x_i)) \times (-\phi_0(x_i)) = 0$$

$$\frac{\partial D}{\partial \alpha_1} = \sum_{i=0}^n 2(f_i - \alpha_0 \phi_0(x_i) - \dots - \alpha_m \phi_m(x_i)) \times (-\phi_1(x_i)) = 0$$

$$\begin{array}{c} \cdot \\ \cdot \\ \cdot \end{array}$$

$$\frac{\partial D}{\partial \alpha_m} = \sum_{i=0}^n 2(f_i - \alpha_0 \phi_0(x_i) - \dots - \alpha_m \phi_m(x_i)) \times (-\phi_m(x_i)) = 0$$

e passando para o membro direito os termos que dependem dos valores f_i obtemos

$$\alpha_0 \sum_{i=0}^n \phi_0(x_i) \phi_0(x_i) + \alpha_1 \sum_{i=0}^n \phi_0(x_i) \phi_1(x_i) + \dots + \alpha_m \sum_{i=0}^n \phi_0(x_i) \phi_m(x_i) = \sum_{i=0}^n f_i \phi_0(x_i)$$

$$\alpha_0 \sum_{i=0}^n \phi_1(x_i) \phi_0(x_i) + \alpha_1 \sum_{i=0}^n \phi_1(x_i) \phi_1(x_i) + \dots + \alpha_m \sum_{i=0}^n \phi_1(x_i) \phi_m(x_i) = \sum_{i=0}^n f_i \phi_1(x_i)$$

$$\begin{array}{c} \cdot \\ \cdot \\ \cdot \end{array}$$

$$\alpha_0 \sum_{i=0}^n \phi_m(x_i) \phi_0(x_i) + \alpha_1 \sum_{i=0}^n \phi_m(x_i) \phi_1(x_i) + \dots + \alpha_m \sum_{i=0}^n \phi_m(x_i) \phi_m(x_i) = \sum_{i=0}^n f_i \phi_m(x_i)$$

Chegamos assim a um sistema linear de $m + 1$ equações nas $m + 1$ incógnitas $\alpha_0, \alpha_1, \dots, \alpha_m$ a que se chama sistema de equações normais ou sistema normal.

Vamos definir os vectores de \mathbb{R}^{n+1}

$$\vec{\phi}_0 = [\phi_0(x_0), \dots, \phi_0(x_n)]^T; \vec{\phi}_1 = [\phi_1(x_0), \dots, \phi_1(x_n)]^T; \dots; \vec{\phi}_m = [\phi_m(x_0), \dots, \phi_m(x_n)]^T.$$

Podemos agora reparar que, por exemplo o termo $\sum_{i=0}^n \phi_0(x_i) \phi_1(x_i)$ não é mais do que o produto interno² (usual) de \mathbb{R}^{n+1} dos vectores $\vec{\phi}_0$ e $\vec{\phi}_1$. Assim o sistema de

²dados dois vectores $\vec{u}, \vec{v} \in \mathbb{R}^{n+1}$ definimos o produto interno $\langle \vec{u}, \vec{v} \rangle = \sum_{i=0}^n u_i v_i$

equações normais toma a forma

$$\begin{pmatrix} \langle \vec{\phi}_0, \vec{\phi}_0 \rangle & \langle \vec{\phi}_0, \vec{\phi}_1 \rangle & \dots & \langle \vec{\phi}_0, \vec{\phi}_m \rangle \\ \langle \vec{\phi}_1, \vec{\phi}_0 \rangle & \langle \vec{\phi}_1, \vec{\phi}_1 \rangle & \dots & \langle \vec{\phi}_1, \vec{\phi}_m \rangle \\ \dots & \dots & \dots & \dots \\ \langle \vec{\phi}_m, \vec{\phi}_0 \rangle & \langle \vec{\phi}_m, \vec{\phi}_1 \rangle & \dots & \langle \vec{\phi}_m, \vec{\phi}_m \rangle \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_m \end{pmatrix} = \begin{pmatrix} \langle \vec{f}, \vec{\phi}_0 \rangle \\ \langle \vec{f}, \vec{\phi}_1 \rangle \\ \dots \\ \langle \vec{f}, \vec{\phi}_m \rangle \end{pmatrix} \quad (7)$$

Podemos facilmente ver que a matriz do sistema é simétrica, pois por comutatividade do produto em \mathbb{R}

$$\langle \vec{\phi}_k, \vec{\phi}_j \rangle = \sum_{i=0}^n \phi_k(x_i) \phi_j(x_i) = \sum_{i=0}^n \phi_j(x_i) \phi_k(x_i) = \langle \vec{\phi}_j, \vec{\phi}_k \rangle.$$

Prova-se que se a funções $\phi_0(x), \phi_1(x), \dots, \phi_m(x)$ forem linearmente independentes, então o sistema tem uma solução única, precisamente a função g que minimiza D .

Exemplo

Se considerarmos a aproximação através de funções polinomiais temos como funções base $\phi_0(x) = 1$; $\phi_1(x) = x$; ... ; $\phi_m(x) = x^m$ e o sistema de equações normais (7) toma a forma

$$\begin{pmatrix} n+1 & \sum_{i=0}^n x_i & \dots & \sum_{i=0}^n x_i^m \\ \sum_{i=0}^n x_i & \sum_{i=0}^n x_i^2 & \dots & \sum_{i=0}^n x_i^{m+1} \\ \dots & \dots & \dots & \dots \\ \sum_{i=0}^n x_i^m & \sum_{i=0}^n x_i^{m+1} & \dots & \sum_{i=0}^n x_i^{2m} \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_m \end{pmatrix} = \begin{pmatrix} \sum_{i=0}^n f_i \\ \sum_{i=0}^n x_i f_i \\ \dots \\ \sum_{i=0}^n x_i^m f_i \end{pmatrix}. \quad (8)$$

Voltemos ao exemplo ilustrado na Figura 1. Para uma dada lista de pontos pretendemos adequar um polinómio. Na Figura 1 considerámos um polinómio de grau 1. Vamos agora considerar ajustamentos por polinómios de grau superior. Na Figura 3 calculámos pelo método dos mínimos quadrados os polinómios de grau 8 e de grau 12 que melhor se ajustam aos pontos apresentados. Para cada um dos exemplos calculámos D e obtivemos respectivamente no caso de polinómios de grau 1, 8 e 12 os valores $D_1 \approx 0.21$, $D_8 \approx 0.1$ e $D_{12} = 0$. Observamos que quando consideramos polinómios de grau superior, na verdade o que estamos a fazer é aumentar o número

de funções base ϕ_j e conseqüentemente "alargar" o conjunto de funções que podem ser geradas pela base de funções. Sobre cada conjunto de funções base, a aproximação dos mínimos quadrados é aquela que minimiza o valor de D . Assim basta pensar que se tivermos dois conjuntos $A, B \subset \mathbb{R}$, então

$$A \subseteq B \Rightarrow \min(A) \geq \min(B)$$

para concluir que aumentar o número de funções de base, em geral diminui o valor de D . No caso em que consideramos polinômios de grau $n + 1$, obtemos exactamente o polinômio interpolador e nesse caso $D = 0$ (Figura 3). No entanto como é visível no segundo gráfico da Figura 3 o polinômio interpolador apresenta grandes oscilações nos extremos do intervalo o que indicia que considerar ajustamento por polinômios de grau elevado, em geral, não será uma boa estratégia.




Figura 3: dois possíveis ajustamentos (respect.) por polinômios de grau 8 e grau 12.

Exercício

Consideremos a tabela de valores obtidos numa dada experiência

x_i	-2	-1	0	1	2
f_i	0	0	1	3	7

Determine a função da forma $g(x) = \alpha_0 x + \alpha_1 x^2$ que melhor se ajusta aos pontos da tabela segundo o critério dos mínimos quadrados.

Resolução

Neste caso temos as funções de base $\phi_0(x) = x$ e $\phi_1(x) = x^2$ e o sistema de equações normais (7) toma a forma

$$\begin{pmatrix} \sum_{i=0}^4 x_i^2 & \sum_{i=0}^4 x_i^3 \\ \sum_{i=0}^4 x_i^3 & \sum_{i=0}^4 x_i^4 \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} \sum_{i=0}^4 x_i f_i \\ \sum_{i=0}^4 x_i^2 f_i \end{pmatrix}$$

e substituindo os valores obtemos

$$\begin{pmatrix} 10 & 0 \\ 0 & 34 \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} 17 \\ 31 \end{pmatrix} \Rightarrow \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} \frac{17}{10} \\ \frac{31}{34} \end{pmatrix}$$

pele que a função que melhor se ajusta aos pontos da tabela, segundo o critério dos mínimos quadrados é $g(x) = \frac{17}{10}x + \frac{31}{34}x^2$. Na Figura 4 representamos os pontos da tabela e função g obtida.




Figura 4: A função da forma $g(x) = \alpha_0 x + \alpha_1 x^2$ que se melhor se ajusta aos pontos.

Exercício

Consideremos o conjunto de pontos $\{x_0, x_1, x_2, x_3, x_4\} = \{-2, -1, 0, 1, 2\}$. Calcule

$$\min_{\alpha_0, \alpha_1 \in \mathbb{R}} \left(\sum_{i=0}^4 (x_i^2 - \alpha_0 - \alpha_1 x_i)^2 \right) \quad (9)$$

Resolução

Podemos resolver este problema usando a teoria do método dos mínimos quadrados. De facto se definirmos $f(x) = x^2$ e $g(x) = \alpha_0 + \alpha_1 x$ temos

$$\min_{\alpha_0, \alpha_1 \in \mathbb{R}} \left(\sum_{i=0}^4 (x_i^2 - \alpha_0 - \alpha_1 x_i)^2 \right) = \min_{\alpha_0, \alpha_1 \in \mathbb{R}} \left(\sum_{i=0}^4 (f(x_i) - g(x_i))^2 \right) \quad (10)$$

Assim, para uma dada função g o somatório

$$D = \sum_{i=0}^4 (f(x_i) - g(x_i))^2$$

é a soma dos quadrados dos desvios de g à função f nos pontos x_i . Já vimos que D tem o valor mínimo quando g é aproximação dada pelo método dos mínimos quadrados. Assim

$$\min_{\alpha_0, \alpha_1 \in \mathbb{R}} \left(\sum_{i=0}^4 (f(x_i) - g(x_i))^2 \right)$$

é atingido nos valores α_0 e α_1 que são solução do sistema de equações normais.

Definimos a tabela de valores

x_i	-2	-1	0	1	2
f_i	4	1	0	1	4

Pretendemos agora determinar a função da forma $g(x) = \alpha_0 + \alpha_1 x$ que melhor se ajusta aos pontos da tabela segundo o critério dos mínimos quadrados. Neste caso o sistema de equações normais (8) toma a forma

$$\begin{pmatrix} 5 & 0 \\ 0 & 10 \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} 10 \\ 0 \end{pmatrix} \Rightarrow \begin{pmatrix} \alpha_0 \\ \alpha_1 \end{pmatrix} = \begin{pmatrix} 2 \\ 0 \end{pmatrix}$$

e portanto $g(x) = 2$. Assim

$$\min_{\alpha_0, \alpha_1 \in \mathbb{R}} \left(\sum_{i=0}^4 (f(x_i) - g(x_i))^2 \right) = \sum_{i=0}^4 (f_i - 2)^2 = 14$$

Na Figura 5 apresentamos a função g e os pontos da tabela.




Figura 5: A função da forma $g(x) = \alpha_0 + \alpha_1 x$ que se melhor se ajusta aos pontos.