

hsj-75014(ff)
hyl-75.10
内 部

科学技术成果报告

用样条函数和 统计技术作拟合曲线

刘 瑞 哲

核 数 据 编 辑 组

一九七六年五月

用样条函数和 统计技术作拟合曲线

本文介绍了B-样条及其主要性质,讨论了一般样条加权拟合公式,以及除对各实验值分配权重外,对各家实验数据也分配适当权重,两次应用正态分布给出的样条加权拟合公式,并给出了拟合误差和最佳拟合判据公式。最后简单分析了样条节点的选择对拟合曲线的影响。

在核数据评价工作中,要广泛收集各实验工作的数据。由于测量方法、技术以及其他条件的不同,得到的数据也往往各不相同。需要对这些数据经过分析比较和一定的数学处理,求出最佳值,以便应用。在许多情况下,需要找出一个最佳拟合函数,作为一系列实验点的描述。因此,必须对数据及其分布规律进行分析。

如果收集来的数据的误差服从高斯定律,即:

- 1.小误差比大误差出现的机会多;
- 2.大小相等、符号相反的正负误差的数目近于相等;
- 3.极大的正误差与负误差出现的机率均非常小;

则求最佳值就相当于求出现的机率极大,也就是相当于求分布密度函数对数的极值。

设某实验数据为 $\{x_i, y_i, \Delta y_i\} \quad i=1, 2, \dots, M$, 其中 x_i 为自变量, y_i 为 x_i 点的测量值, Δy_i 为 y_i 的标准偏差。

如果数据的最佳拟合函数为多项式

$$f(x) = \sum_{j=0}^n a_j x^j \quad a_n \neq 0,$$

则

$$\sum_{i=1}^M [y_i - f(x_i)]^2 / \Delta y_i^2$$

应为极小值。

一般都可以用上述形式的多项式 $f(x)$ 作拟合函数,但是因为 $f(x)$ 在整个区间 $[a, b]$ 上都是同一个多项式,所以任何一点的大误差都会牵涉到全局。对于较复杂的图形,要想达到一定的拟合程度,往往需要次数 n 很高,而次数过高,计算量增大,又不易算准。

用样条函数代替 $f(x)$, 就会使误差局部化,个别误差过大也不会影响全局,并且计算也较简单。

一、三次B-样条函数⁽¹⁾

三次样条函数 $S(x)$ 是分段三次多项式, 即在区间 $[a, b]$ 上给定分割

$$\Delta: a = \xi_1 < \xi_2 < \dots < \xi_N = b.$$

在每个子区间 $[\xi_i, \xi_{i+1}]$ $i = 1, 2, \dots, N-1$ 上, $S(x)$ 是一个三次多项式。在整个区间 $[a, b]$ 上, $S(x)$ 及其一阶、二阶导数处处连续。点 ξ_i ($i = 1, 2, \dots, N$) 称为样条节点, 一般来说在不同的子区间, 有不同的三次多项式。

这样的三次样条函数有多种形式, 我们用的是一种叫做三次B-样条函数, 即用下面所定义的函数 $M_l(x)$ 作为一组基底构成的样条函数 $S(x)$ 。

$M_l(x)$ 的定义是这样的:

对于分割 Δ , 在点

$$\xi_l, \xi_{l+1}, \dots, \xi_{l+4} \quad l = 1, 2, \dots, N-4$$

作函数 $\psi(x, t) = 4(t-x)_+^3$ 的四次差商 (x 为参数, 对 t 差商), 得

$$M_l(x) = 4 \sum_{r=0}^4 (\xi_{l+r} - x)_+^3 / w(\xi_{l+r}), \quad (1)$$

其中

$$w(\xi_{l+r}) = \prod_{\substack{j=0 \\ j \neq r}}^4 (\xi_{l+r} - \xi_{l+j}), \quad (2)$$

$$(\xi_{l+r} - x)_+^3 = \begin{cases} (\xi_{l+r} - x)^3, & \xi_{l+r} > x \\ 0, & \xi_{l+r} \leq x \end{cases} \quad (3)$$

这样构成的 $M_l(x)$ 具有明确的局部化意义: 对于每个节点上的B-样条只有三个非零, 且当 $|t-l| \geq 4$ 时,

$$M_l(x) \cdot M_t(x) = 0, \quad x \in [a, b] \quad (4)$$

以等距节点为例, 当

$$\xi_l = -2, \xi_{l+1} = -1, \xi_{l+2} = 0, \xi_{l+3} = 1, \xi_{l+4} = 2 \text{ 时}$$

$$M_l(x) = \frac{1}{6} \{ (x+2)_+^3 - 4(x+1)_+^3 + 6x_+^3 - 4(x-1)_+^3 + (x-2)_+^3 \}. \quad (5)$$

将 $M_l(x)$ 展成三次多项式, 即

$$M_l(x) = \begin{cases} 0, & x \leq -2 \\ \frac{1}{6}(x+2)^3, & -2 \leq x \leq -1 \\ \frac{1}{6}(x+2)^3 - \frac{4}{6}(x+1)^3, & -1 \leq x \leq 0 \\ \frac{1}{6}(-x+2)^3 - \frac{4}{6}(-x+1)^3, & 0 \leq x \leq 1 \\ \frac{1}{6}(-x+2)^3, & 1 \leq x \leq 2 \\ 0, & x \geq 2 \end{cases} \quad (6)$$




图1 等距节点函数 $M_l(x)$ 图形

它的函数图形如图1。非等距节点也类似，只是图形不象那么左右对称而已。

由图可见，当 $|t-l| \geq 4$ 时， $M_l(x)$ 和 $M_t(x)$ 至少有一个为零，所以公式(4)成立。

既然 $M_l(x)$ 是三次样条函数的一组基底，那么，在 $[a, b]$ 上以 $\xi_i (i=1, 2, \dots, N)$ 为节点的样条函数可以唯一地写成

$$S(x) = \sum_{l=1}^{N-4} C_l M_l(x), \quad (7)$$

其中 C_l 为待定系数。

二、用样条函数作拟合曲线(2)

对于离散点 $\{x_i, y_i, \Delta y_i\} \quad i=1, 2, \dots, M$ ，其中 x_i 为自变量， y_i 为在 x_i 的测量值， Δy_i 为 y_i 在点 x_i 的标准偏差。样条节点沿 x 轴取在点集

$$\xi_j \quad j=1, 2, \dots, N$$

当 $x \in [\xi_l, \xi_{N-3}]$ 时，

$$\text{令} \quad \chi^2 = \sum_{i=1}^M [y_i - S(x_i)]^2 / \Delta y_i^2, \quad (8)$$

其中 $S(x)$ 用公式(7)代入，由

$$\frac{\partial \chi^2}{\partial C_l} = 0, \quad l=1, 2, \dots, N-4 \quad (9)$$

$$\text{得} \quad \sum_{l=1}^{N-4} C_l \sum_{i=1}^M (\Delta y_i)^{-2} M_l(x_i) M_t(x_i) = \sum_{i=1}^M (\Delta y_i)^{-2} y_i M_t(x_i) \quad (10)$$

$$t=1, 2, \dots, N-4$$

解线性方程组(10)得 $C_l (l=1, 2, \dots, N-4)$ ，然后代入公式(7)， $S(x)$ 就是所求拟合曲线的函数。

由公式(4)知方程组(10)的系数矩阵是七对角线矩阵，即一行的非零元素最多只有七个，计算简单。

三、多家数据的一种拟合方法

为了评价和推荐一条曲线,往往需要收集许多家的数据,这些数据很可能是彼此偏离的。引起这种偏离的原因往往是不清楚的,但经过仔细地分析比较,会使评价者对各家数据得到一个“可信程度”的印象,并合理地分配每家的权重。一般各家对于一个物理量 y 的测量,都给出一个标准偏差 Δy , 它出现的可能性用权重 $1/\Delta y^2$ 表示。另外,在评价者看来,不同的实验类型 C_i 有不同的标准偏差 Σc_i 。如果某家实验数据属于类型 C_i , 那么, 它的所有测量值都具有偏差 b_k 。 b_k 是具有零中项和标准偏差 $\Sigma_k (= \Sigma c_i)$ 的高斯变量, 它出现的可能性用权重 $1/\Sigma_k^2$ 表示。

设有实验数据

$$(x_{i,k}, y_{i,k}, \Delta y_{i,k}, \Sigma_k) \quad i=1,2,\dots,n_k, \quad k=1,2,\dots,K.$$

脚标 “ ik ” 表示第 k 家数据的第 i 次测量, Σ_k 是评价者自己给的。如果这些数据能被样条函数 $S(x)$ 表示, 那么, 对于每个 $x_{i,k}$ 和 $y_{i,k}$, $y_{i,k} - S(x_{i,k})$ 是一个具有中项 b_k 和标准偏差 $\Delta y_{i,k}$ 的高斯变量。对于固定的 b_k , 第 k 家各数据同时出现的似然函数与

$$\prod_{i=1}^{n_k} \exp \left\{ -\frac{1}{2} (\Delta y_{i,k})^{-2} [y_{i,k} - b_k - S(x_{i,k})]^2 \right\} \quad (11)$$

成正比。

但是, 因为 b_k 也是一个高斯变量, 所以这些点混合出现的似然函数的对数去掉一个常数就是

$$F = -\frac{1}{2} \sum_{k=1}^K \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} \left\{ y_{i,k} - b_k - S(x_{i,k}) \right\}^2 - \frac{1}{2} \sum_{k=1}^K (b_k^2 / \Sigma_k^2). \quad (12)$$

$$\text{令} \quad \frac{\partial F}{\partial b_k} = 0, \quad (13)$$

得

$$b_k = \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} \left\{ y_{i,k} - S(x_{i,k}) \right\} \cdot \left[\sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} + \Sigma_k^2 \right]^{-1}. \quad (14)$$

将 (14) 式代入 (12) 式, 得

$$F' = -\frac{1}{2} \sum_{k=1}^K \left[\sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} \left\{ y_{i,k} - S(x_{i,k}) \right\}^2 - \left\{ \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} [y_{i,k} - S(x_{i,k})] \right\}^2 \cdot \left\{ \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} + \Sigma_k^2 \right\}^{-1} \right]. \quad (15)$$

$$\text{令} \quad \frac{\partial F'}{\partial C_i} = 0, \quad i=1,2,\dots,N-4 \quad (16)$$

$S(x)$ 用 (7) 式代入, 得

$$\begin{aligned}
& \sum_{k=1}^K \sum_{l=1}^{N-4} C_l \left[\frac{\left\{ \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} M_l(x_{i,k}) \right\} \cdot \left\{ \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} M_l(x_{i,k}) \right\}}{\sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} + \sum_k^{-2}} \right. \\
& \quad \left. - \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} M_l(x_{i,k}) M_l(x_{i,k}) \right] \\
& = \sum_{k=1}^K \left[\frac{\left\{ \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} y_{i,k} \right\} \cdot \left\{ \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} M_l(x_{i,k}) \right\}}{\sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} + \sum_k^{-2}} \right. \\
& \quad \left. - \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} y_{i,k} M_l(x_{i,k}) \right] \cdot \\
& \quad t = 1, 2, \dots, N-4 \quad (17)
\end{aligned}$$

(17) 式是一个关于 C_l 的 $N-4$ 个线性方程组成的方程组。解 (17) 式得 C_l ($l=1, 2, \dots, N-4$)，代入 (7) 式得拟合曲线的函数 $S(x)$ 。

Σ_i 是未知的系统误差，它使曲线移动一常量 b_i ，但一般系统误差是使曲线按某一百分数移动，所以 (17) 式有待改进。

如果参加计算的只有一家数据，或者几家数据 $\Sigma_i = 0$ ，(17) 式同 (13) 式，所以 (13) 式可看成是 (17) 式的特殊情况。

四、拟合误差和最佳拟合的判据

把公式 (10) 和公式 (17) 写成如下形式：

$$\mathbf{AC} = \mathbf{D} \quad (18)$$

其中 $\mathbf{A}$ 为 $N-4$ 阶方阵， $\mathbf{C}$ 、 $\mathbf{D}$ 为 $N-4$ 列的列矩阵。这样，在特殊点 x' 的拟合方差为

$$\sigma^2(x') = \mathbf{u}' \mathbf{A}^{-1} \mathbf{u} \quad (19)$$

其中 $\mathbf{A}^{-1}$ 为 (18) 式中矩阵 $\mathbf{A}$ 的逆矩阵，也叫误差矩阵。

$$\mathbf{u}' = \left(\frac{\partial S(x')}{\partial C_1} \quad \frac{\partial S(x')}{\partial C_2} \quad \dots \quad \frac{\partial S(x')}{\partial C_{N-4}} \right) \quad (20)$$

拟合程度的提高是通过选择节点实现的，通过选择节点，使

$$\frac{\sum_{i=1}^M \left[y_i - S(x_i) \right]^2 (\Delta y_i)^{-2}}{M - N + 4} \quad (21)$$

或

$$\frac{\sum_{k=1}^K \sum_{i=1}^{n_k} (\Delta y_{i,k})^{-2} \left[y_{i,k} - b_k - S(x_{i,k}) \right]^2}{\sum_{k=1}^K n_k - N + 4} \quad (22)$$

达到极小值，这时即为最佳拟合。但是，因为用机器自动调节点的问题尚未解决，所以要找(21)、(22)式的极小值也是不容易的。尽管如此，计算这些量对于人工调节点还是可以提供一些依据的。

五、具体例子

曲线拟合程度如何，与合理选择节点的位置和个数关系很大。节点一般取在曲线变化复杂的地方。如果节点取得太少，逼近程度不好，应有的峰或谷往往被拉平；如果节点取得过多，又可能出现不应有的峰或谷。




图2 节点选择对拟合程度的影响

▲○●—— ${}^6\text{Li}(n,\alpha)$ 截面数据；+×——节点选择位置。

我们用第二节中的方法作了 ^{239}Pu 在10千电子伏—20兆电子伏能区裂变截面的拟合曲线^[3],也作了 ^6Li 在1—1700千电子伏能区 (n,α) 截面和全截面的拟合曲线^[4],均拟合得较好。

在图2上举例说明了节点选择对拟合程度的影响。由于 $^6\text{Li}(n,\alpha)$ 反应在100—400千电子伏能区有共振,所以对节点的位置反应很灵敏。图中实线是以“+”为节点的拟合曲线。节点B取在峰值的横坐标位置,节点A和C取在与B有适当距离的左右两侧,这样做拟合较好。若A与B和B与C之间的距离过远或过近,拟合曲线的峰值将会不适当地下降或上升。图中虚线是以“×”为节点的拟合曲线,节点只取在峰值横坐标两侧,拟合得不好。

对 $^6\text{Li}(n,\alpha)$ 截面数据拟合的情况说明,因两节点间是以三次多项式逼近的,曲线走向不能太复杂,因此节点应取在曲线走向有突变的位置,使两节点间的曲线走向较平滑,这样可以得到较好的拟合。

总之,节点的选择是很重要的,在这方面我们还缺乏经验,有待进一步探索。

参 考 文 献

- [1]孙家昶, 计算机应用与应用数学, 6, 1 (1974)。
- [2]J.B.Ahorsley et al., *Nucl. Instrum. Methods*, 62, 29 (1968)。
- [3]刘继才, 1千电子伏—20兆电子伏 ^{239}Pu 的裂变截面评价, hsj-75005/hyl-75.10, 核数据编辑组, 1976年。
- [4]周德林, 1.7兆电子伏以下 ^6Li 核中子数据评价, hsj-75006/hyl-75.10, 核数据编辑组, 1976年。