

第 3 章

曲线拟合与函数逼近

在第 2 章中介绍了函数逼近的一种方法——函数的插值或多项式插值,其显著的特点就是要求近似函数(插值函数)在节点处与函数同值,即满足插值条件.在实际工程计算中,由于误差的存在,要求近似函数严格满足插值条件(几何上即相应的曲线通过点 (x_i, y_i))是不现实的.

在科学实验和统计分析中,往往需要从一组实验数据或观测数据 (x_i, y_i) 出发,找出变化规律,求出函数 $y=f(x)$ 的近似表达式.如果利用插值方法,由于数据很多,得到的插值函数很复杂,缺少实用价值;且实验数据往往有误差,没有必要要求它们相等.曲线拟合是从给出的一大堆数据中找出规律,即设法构造一条曲线,不要求该曲线严格地通过每个数据点,只要求它能更加合理地反映数据点总的趋势,在某种意义上与这些数据点的总体偏差最小.这类方法称为曲线(数据)拟合法.

对连续点也有类似问题.设 $f(x)$ 是定义在区间 $[a, b]$ 上的连续函数,但太复杂,应用不便,希望用简单函数 $p(x)$ 去近似 $f(x)$.通常取 $p(x)$ 为多项式、有理分式等,要求在某种意义上 $p(x)$ 与 $f(x)$ 在整个区间 $[a, b]$ 上的总体偏差最小.这类方法称为函数逼近法.

3.1 曲线拟合的最小二乘法

对于一组给定的数据

x	x_1	x_2	...	x_m
y	y_1	y_2	...	y_m

记通过点 (x_i, y_i) 的规律为 $y=f(x)$,即 $y_i=f(x_i)(i=1, 2, \dots, m)$.假设“逼近”规律的近似函数为 $y=\varphi(x)$,即 $y_i^*=\varphi(x_i)(i=1, 2, \dots, m)$.它与观测值 y_i 之差

$$\delta_i = y_i^* - y_i = \varphi(x_i) - y_i, \quad i = 1, 2, \dots, m$$

称为残差.残差的大小可作为衡量近似函数好坏的标准.

由于观测数据总有误差,所以不要求 $y=\varphi(x)$ 通过已知点 $(x_i, y_i)(i=1, 2, \dots, m)$.在给定点 $x_i(i=1, 2, \dots, m)$ 上,按照使残差的平方和 $\sum_{i=1}^m \delta_i^2$ 最小的规则求得近似函数 $y=\varphi(x)$ 的方法称为最佳平方逼近,也称为曲线拟合的最小二乘法.

曲线拟合的最小二乘问题一般提法:根据给定的数据组 $(x_i, y_i)(i=1, 2, \dots, m)$,选取近

似函数形式,即给定函数类 $\Phi = \text{Span}\{\varphi_0, \varphi_1, \dots, \varphi_n\}$, 求函数 $\varphi(x) \in \Phi$, 即

$$\varphi(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_n\varphi_n(x) \quad (3.1)$$

使得

$$\begin{aligned} I(a_0, a_1, \dots, a_n) &= \sum_{i=1}^m \rho_i [\varphi(x_i) - y_i]^2 \\ &= \sum_{i=1}^m \rho_i \left[\sum_{j=0}^n a_j \varphi_j(x_i) - y_i \right]^2 \end{aligned} \quad (3.2)$$

达到最小. 这里 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x) \in C[a, b]$ 是线性无关的函数族, $\rho_i > 0$ ($i=1, 2, \dots, m$) 为权系数, m 一般比 n 大得多.

求式(3.2)的最小值就是求多元函数 $I(a_0, a_1, \dots, a_n)$ 的极值. 记 $I = I(a_0, a_1, \dots, a_n)$, 由极值的必要条件可得

$$\frac{\partial I}{\partial a_j} = 2 \sum_{i=1}^m \rho_i \left[\sum_{k=0}^n a_k \varphi_k(x_i) - y_i \right] \varphi_j(x_i) = 0, \quad j = 0, 1, \dots, n$$

即

$$\sum_{k=0}^n a_k \left[\sum_{i=1}^m \rho_i \varphi_k(x_i) \varphi_j(x_i) \right] = \sum_{i=1}^m \rho_i y_i \varphi_j(x_i), \quad j = 0, 1, \dots, n \quad (3.3)$$

引入内积定义(带权内积)

$$\begin{cases} (\varphi_j, \varphi_k) = \sum_{i=1}^m \rho_i \varphi_j(x_i) \varphi_k(x_i) \\ (y, \varphi_j) = \sum_{i=1}^m \rho_i y_i \varphi_j(x_i) \end{cases} \quad (3.4)$$

则式(3.3)可改写为

$$(\varphi_0, \varphi_j) a_0 + (\varphi_1, \varphi_j) a_1 + \dots + (\varphi_n, \varphi_j) a_n = (y, \varphi_j), \quad j = 0, 1, \dots, n$$

这是关于参数 a_0, a_1, \dots, a_n 的线性方程组, 用矩阵表示为

$$\begin{pmatrix} (\varphi_0, \varphi_0) & (\varphi_0, \varphi_1) & \cdots & (\varphi_0, \varphi_n) \\ (\varphi_1, \varphi_0) & (\varphi_1, \varphi_1) & \cdots & (\varphi_1, \varphi_n) \\ \vdots & \vdots & \ddots & \vdots \\ (\varphi_n, \varphi_0) & (\varphi_n, \varphi_1) & \cdots & (\varphi_n, \varphi_n) \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} (y, \varphi_0) \\ (y, \varphi_1) \\ \vdots \\ (y, \varphi_n) \end{pmatrix} \quad (3.5)$$

线性方程组(3.5)称为法方程.

函数族 $\{\varphi_j(x)\} (j=0, 1, \dots, n)$ 线性无关不能保证式(3.5)的系数矩阵非奇异. 因此, 要使法方程(3.5)有唯一解 a_0, a_1, \dots, a_n , 必须加上另外的条件(本书略去, 读者可参见文献[1]).

3.2 最小二乘法的求法

3.2.1 多项式拟合

在最小二乘拟合中, 若取 $\varphi_j(x) = x^j (j=0, 1, \dots, n)$, 则 $\varphi(x) \in \text{Span}\{1, x, \dots, x^n\}$, 即

$$\varphi(x) = a_0 + a_1 x + \dots + a_n x^n \quad (3.6)$$

此时关于系数 a_0, a_1, \dots, a_n 的法方程(3.5)是病态方程,通常当 $n \geq 3$ 时都不直接取 $\varphi_k(x) = x^k$ 作为基. 这里只给出 $n=2, \rho_i \equiv 1$ 时的情形. 由法方程(3.5)可得

$$\begin{cases} ma_0 + a_1 \sum_{i=1}^m x_i + a_2 \sum_{i=1}^m x_i^2 = \sum_{i=1}^m y_i \\ a_0 \sum_{i=1}^m x_i + a_1 \sum_{i=1}^m x_i^2 + a_2 \sum_{i=1}^m x_i^3 = \sum_{i=1}^m y_i x_i \\ a_0 \sum_{i=1}^m x_i^2 + a_1 \sum_{i=1}^m x_i^3 + a_2 \sum_{i=1}^m x_i^4 = \sum_{i=1}^m y_i x_i^2 \end{cases} \quad (3.7)$$

解出 a_0, a_1, a_2 , 就得到拟合公式 $y = a_0 + a_1 x + a_2 x^2$.

例 3.1 已知某单位 2001—2007 年的利润为

时间/年	2001	2002	2003	2004	2005	2006	2007
利润/万元	72	108	140	150	174	196	208

试预测 2008 年的利润.

解 由已知数据作出散点图(如图 3.1 所示),可见该单位的年利润几乎直线上升. 我们选择一次多项式作为拟合函数来预测 2008 年的利润. 为简化计算,将年份记为 $x_i = 2000 + t_i$, 相应年份的利润记作 $y_i (i=1, 2, \dots, 7)$, 则所求的拟合函数为 $y = a + bt$. 计算得

$$\sum_{i=1}^7 t_i = 28, \quad \sum_{i=1}^7 t_i^2 = 140, \quad \sum_{i=1}^7 y_i = 1048, \quad \sum_{i=1}^7 t_i y_i = 4810$$

从而得方程组

$$\begin{cases} 7a + 28b = 1048 \\ 28a + 140b = 4810 \end{cases}$$

解得 $a = \frac{430}{7}, b = \frac{309}{14}$. 于是所求拟合函数为




图 3.1 散点图

$$y = \frac{430}{7} + \frac{309}{14}t$$

将 $t=8$ 代入, 得 2008 年的利润为

$$y = \frac{430}{7} + \frac{309}{14} \times 8 = \frac{1666}{7} = 238 \text{ (万元)}$$

例 3.2 求下列数据的最小二乘二次拟合多项式.

x_i	-1	-0.75	-0.5	-0.25	0	1	0.75	0.5	0.25
y_i	-0.2209	0.3295	0.8826	1.4392	2.0003	2.5645	3.1334	3.7601	4.2836

解 依题意, 设二次拟合多项式为 $p_2(x) = a_0 + a_1x + a_2x^2$, 将数据代入式(3.7)得线性方程组

$$\begin{cases} 9a_0 + 0 + 3.75a_2 = 18.1723 \\ 0 + 3.75a_1 + 0 = 8.4842 \\ 3.75a_0 + 0 + 2.7656a_2 = 7.6173 \end{cases}$$

解得 $a_0 = 2.0034, a_1 = 2.2625, a_2 = 0.0378$. 所以此数据组的最小二乘二次拟合多项式为

$$p_2(x) = 2.0034 + 2.2625x + 0.0378x^2$$

3.2.2 可化为线性拟合的非线性拟合

使用最小二乘逼近时, 模型的选择是很重要的, 通常模型 $y = \varphi(x)$ 是由物理规律或数据分布情况确定的, 不一定是线性模型. 但有的非线性拟合曲线可以经过适当的变换转化为线性曲线, 从而用线性拟合进行处理. 对于一个实际的曲线拟合问题, 一般先按观测值在直角坐标平面上描出散点图, 然后根据散点图选用相接近的模型(曲线拟合方程), 再通过适当的变量替换化为线性拟合问题. 按线性拟合解出后要再还原为原变量所表示的曲线拟合方程.

例如, 指数函数 $y = ae^{bx}$ 关于系数 a, b 并非线性, 但对它两端取对数得到

$$\ln y = \ln a + bx$$

若令 $\bar{y} = \ln y, A = \ln a$, 则上式转化为 $\bar{y} = A + bx$, 它是线性模型, 仍可按上面介绍的方法求 $y = \varphi(x)$.

表 3.1 列举了可线性化的几类曲线方程.

表 3.1 曲线拟合方程及变换关系

拟合曲线	变换关系	变换后方程
$y = ax^b$	$\bar{y} = \ln y, \bar{x} = \ln x, \bar{a} = \ln a$	$\bar{y} = \bar{a} + b\bar{x}$
$y = a + \frac{b}{x}$	$\bar{x} = \frac{1}{x}$	$\bar{y} = a + b\bar{x}$
$y = \frac{x}{ax+b}$	$\bar{y} = \frac{1}{y}, \bar{x} = \frac{1}{x}$	$\bar{y} = a + b\bar{x}$

续表

拟合曲线	变换关系	变换后方程
$y = a + b \ln x$	$\bar{x} = \ln x$	$y = a + b \bar{x}$
$y = \frac{1}{a + b e^{-x}}$	$\bar{y} = \frac{1}{y}, \bar{x} = e^{-x}$	$\bar{y} = a + b \bar{x}$

例 3.3 给定数据如下,用最小二乘法求形如 $y = ax^b$ 的拟合曲线.

x_i	1.2	2.8	4.3	5.4	6.8	7.9
\bar{y}_i	2.1	11.5	28.1	41.9	72.3	91.4

解 对 $y = ax^b$ 两端取对数得 $\ln y = \ln a + b \ln x$. 令 $\bar{y} = \ln y, \bar{x} = \ln x, A = \ln a$, 则有 $\bar{y} = A + b \bar{x}$, 它是线性最小二乘拟合问题. 为求得 A, b , 先将 (x_i, y_i) 化为 (x_i, \bar{y}_i) . 转化后的数据列入表 3.2.

表 3.2 转化后的数据表

x_i	1.2	2.8	4.3	5.4	6.8	7.9
$\bar{x}_i = \ln x_i$	0.1823	1.0296	1.4586	1.6864	1.9169	2.0669
y_i	2.1	11.5	28.1	41.9	72.3	91.4
$\bar{y}_i = \ln y_i$	0.7419	2.4423	3.3358	3.7353	4.2808	4.5152

根据表 3.2 计算得到对应的法方程为

$$\begin{cases} 6.0000A + 8.3407b = 19.0514 \\ 8.3407A + 14.0114b = 31.3532 \end{cases}$$

解得 $A = 0.3743, b = 2.0149$, 即 $a = e^A = 1.4540$. 于是得最小二乘拟合曲线

$$y = 1.4540x^{2.0149}$$

3.2.3 正交多项式拟合的最小二乘法

在最小二乘曲线拟合中,若 $\Phi = \text{Span}\{1, x, \dots, x^n\}$, 模型取为式(3.6)时,法方程是病态方程. 怎样避免求解病态方程呢? 我们先给出关于给定点的正交多项式的定义.

定义 3.1 设给定拟合数据 (x_i, y_i) 及权 $\rho_i (i=1, 2, \dots, m)$, 若函数族 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x) \in C[a, b]$ 满足

$$(1) \sum_{i=1}^m \rho_i \varphi_k(x_i) \varphi_j(x_i) = 0 (k \neq j);$$

$$(2) (\varphi_k, \varphi_k) = \sum_{i=1}^m \rho_i \varphi_k^2(x_i) > 0;$$

则称 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)$ 是 $[a, b]$ 上关于点集 $\{x_i\}$ 、带权 $\rho_i (i=1, 2, \dots, m)$ 的正交函数族. 若 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)$ 是多项式, 则称其为正交多项式函数族.

在最小二乘法中取正交多项式族 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)$ 为基函数, 则线性方程组(3.5)的系数矩阵为对角矩阵, 方程组的解为

$$a_j = \frac{(y, \varphi_j)}{(\varphi_j, \varphi_j)} = \frac{\sum_{i=1}^m \rho_i y_i \varphi_j(x_i)}{\sum_{i=1}^m \rho_i \varphi_j^2(x_i)}, \quad j = 0, 1, \dots, n \quad (3.8)$$

最小二乘拟合函数为

$$\varphi(x) = \sum_{j=0}^n \frac{(y, \varphi_j)}{(\varphi_j, \varphi_j)} \varphi_j(x) \quad (3.9)$$

可以证明, 若令

$$\begin{aligned} \varphi_0(x) &= 1, & \varphi_1(x) &= x - \alpha_1 \\ \varphi_k(x) &= (x - \alpha_k) \varphi_{k-1}(x) - \beta_k \varphi_{k-2}(x) \quad (k = 2, 3, \dots, n) \end{aligned} \quad (3.10)$$

其中

$$\begin{cases} \alpha_k = \frac{(x\varphi_{k-1}, \varphi_{k-1})}{(\varphi_{k-1}, \varphi_{k-1})}, & k = 1, 2, \dots, n \\ \beta_k = \frac{(\varphi_{k-1}, \varphi_{k-1})}{(\varphi_{k-2}, \varphi_{k-2})}, & k = 2, 3, \dots, n \end{cases} \quad (3.11)$$

则 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)$ 是正交多项式函数族.

例 3.4 利用正交函数族求例 3.2 所给数据的最小二乘二次拟合多项式.

解 取 $\varphi_0(x) = 1$, 由式(3.11)计算得

$$\alpha_1 = \frac{(x\varphi_0, \varphi_0)}{(\varphi_0, \varphi_0)} = \frac{\sum_{i=1}^9 x_i}{\sum_{i=1}^9 1} = \frac{0}{9} = 0$$

故 $\varphi_1(x) = x - \alpha_1 = x$. 又由式(3.11)计算得

$$\alpha_2 = \frac{(x\varphi_1, \varphi_1)}{(\varphi_1, \varphi_1)} = \frac{\sum_{i=1}^9 x_i^3}{\sum_{i=1}^9 x_i^2} = 0, \quad \beta_2 = \frac{(\varphi_1, \varphi_1)}{(\varphi_0, \varphi_0)} = \frac{\sum_{i=1}^9 x_i^2}{\sum_{i=1}^9 1} = \frac{3.75}{9} = 0.41667$$

故

$$\varphi_2(x) = (x - \alpha_2) \varphi_1(x) - \beta_2 \varphi_0(x) = x^2 - 0.41667$$

所以由式(3.8)得

$$\begin{aligned} a_0 &= \frac{(y, \varphi_0)}{(\varphi_0, \varphi_0)} = \frac{\sum_{i=1}^9 y_i}{\sum_{i=1}^9 1} = \frac{18.1723}{9} = 2.01914 \\ a_1 &= \frac{(y, \varphi_1)}{(\varphi_1, \varphi_1)} = \frac{\sum_{i=1}^9 y_i x_i}{\sum_{i=1}^9 x_i^2} = \frac{8.4842}{3.75} = 2.2625 \end{aligned}$$

$$a_2 = \frac{(y, \varphi_2)}{(\varphi_2, \varphi_2)} = \frac{\sum_{i=1}^9 y_i (x_i^2 - 0.41667)}{\sum_{i=1}^9 (x_i^2 - 0.41667)^2} = \frac{0.04545}{1.2031} = 0.0378$$

将上述结果代入式(3.9),得最小二乘二次拟合多项式为

$$\begin{aligned} \varphi(x) &= a_0 \varphi_0(x) + a_1 \varphi_1(x) + a_2 \varphi_2(x) \\ &= 2.01914 + 2.2625x + 0.0378(x^2 - 0.41667) \\ &= 0.0378x^2 + 2.2625x + 2.0034 \end{aligned}$$

这与例 3.2 计算结果相同.

3.3 最佳平方逼近

从离散点的最小二乘曲线拟合,可以很自然地过渡到连续函数的最佳平方逼近.类似于离散情形,我们先给出正交多项式的概念.

3.3.1 正交多项式

定义 3.2 若函数 $\rho(x)$ 满足

(1) 当 $x \in (a, b)$ 时, $\rho(x) \geq 0$ 且 $\rho(x)$ 几乎处处不为零;

(2) $\int_a^b \rho(x) dx > 0$,

则称 $\rho(x)$ 为区间 $[a, b]$ 上的权函数.

定义 3.3 设函数 $f(x), g(x) \in C[a, b]$, $\rho(x)$ 是 $[a, b]$ 上给定的权函数,定义 $f(x)$ 与 $g(x)$ 的内积为

$$(f, g) = \int_a^b \rho(x) f(x) g(x) dx \quad (3.12)$$

若 $(f, g) = 0$, 则称 $f(x)$ 与 $g(x)$ 在 $[a, b]$ 上关于权函数 $\rho(x)$ 正交.

定义 3.4 如果函数系 $\{\varphi_k(x)\}$ 中每个函数 $\varphi_k(x)$ 在区间 $[a, b]$ 上连续, 不恒等于零, 且满足条件

$$\int_a^b \rho(x) \varphi_i(x) \varphi_j(x) dx = \begin{cases} 0, & i \neq j \\ (\varphi_i, \varphi_i) > 0, & i = j \end{cases} \quad (i, j = 0, 1, 2, \dots) \quad (3.13)$$

则称函数系 $\{\varphi_k(x)\}$ 在 $[a, b]$ 上关于权函数 $\rho(x)$ 为正交函数系.

例如, 三角函数系 $1, \cos x, \sin x, \cos 2x, \sin 2x, \dots$ 在 $[-\pi, \pi]$ 上关于权函数 $\rho(x) \equiv 1$ 是正交函数系.

定义 3.5 若函数系 $\{\varphi_k(x)\}$ 在 $[a, b]$ 上关于权函数 $\rho(x)$ 正交, $\varphi_k(x)$ 是首项系数非零的 k 次多项式, 则称多项式函数系 $\{\varphi_k(x)\}$ 在 $[a, b]$ 上关于权函数 $\rho(x)$ 正交, $\varphi_k(x)$ 称为 k 次正交多项式.

性质 1 设 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)$ 是在 $[a, b]$ 上关于权函数 $\rho(x)$ 正交多项式, 则它在

$[a, b]$ 上线性无关.

性质 2 关于权函数 $\rho(x)$ 和 $[a, b]$ 上的 k 次正交多项式 $\varphi_k(x)$ 在 (a, b) 内具有 k 个互异实零点.

下面介绍几个常用的正交多项式.

1. 勒让德(Legendre)多项式

n 次勒让德多项式为

$$P_n(x) = \frac{1}{2^n n!} \frac{d^n}{dx^n} (x^2 - 1)^n \quad (n = 0, 1, 2, \dots) \quad (3.14)$$

其最高次项系数为 $\frac{(2n)!}{2^n (n!)^2}$. 勒让德多项式 $\{P_n(x)\}$ 在区间 $[-1, 1]$ 上关于权函数 $\rho(x) \equiv 1$ 是正交的, 即

$$(P_n, P_m) = \int_{-1}^1 P_n(x) P_m(x) dx = \begin{cases} 0, & m \neq n \\ \frac{2}{2n+1}, & m = n \end{cases}$$

具有递推公式

$$\begin{cases} P_0(x) = 1, \\ P_{i+1}(x) = \frac{2i+1}{i+1} x P_i(x) - \frac{i}{i+1} P_{i-1}(x) \end{cases} \quad (i = 1, 2, \dots)$$

勒让德多项式的奇偶性可表示为

$$P_n(-x) = (-1)^n P_n(x)$$

2. 切比雪夫(Chebyshev)多项式

n 次切比雪夫多项式为

$$T_n(x) = \cos(n \arccos x), \quad -1 \leq x \leq 1 \quad (3.15)$$

其最高次项系数为 2^{n-1} ($n \geq 1$). 切比雪夫多项式满足正交关系:

$$\int_{-1}^1 \frac{T_i(x) T_j(x)}{\sqrt{1-x^2}} dx = \begin{cases} 0, & i \neq j \\ \pi, & i = j = 0 \\ \frac{\pi}{2}, & i = j \neq 0 \end{cases}$$

具有递推关系

$$\begin{cases} T_0(x) = 1, \quad T_1(x) = x \\ T_{i+1}(x) = 2x T_i(x) - T_{i-1}(x) \end{cases} \quad (i = 1, 2, \dots)$$

此外, 切比雪夫多项式还具有性质:

- (1) $T_n\left(\cos \frac{k\pi}{n}\right) = (-1)^k, k = 0, 1, \dots, n;$
- (2) $T_n\left(\cos \frac{2k+1}{2n}\pi\right) = 0, k = 0, 1, \dots, n-1;$
- (3) 当 $|x| \leq 1$ 时, $|T_n(x)| \leq 1;$
- (4) 在最高次项的系数为 1 的所有 n 次多项式中, $2^{1-n} T_n(x)$ 对零的逼近误差最小.

3. 拉盖尔(Laguerre)多项式

n 次拉盖尔多项式为

$$L_n(x) = e^x \frac{d^n(x^n e^{-x})}{dx^n} \quad (n = 0, 1, 2, \dots) \quad (3.16)$$

其最高次项的系数为 $(-1)^n$. 拉盖尔多项式满足正交关系

$$\int_0^{+\infty} e^{-x} L_i(x) L_j(x) dx = \begin{cases} 0, & i \neq j \\ (i!)^2, & i = j \end{cases}$$

具有递推关系

$$\begin{cases} L_0(x) = 1, & L_1(x) = 1 - x \\ L_{i+1}(x) = (2i + 1 - x)L_i(x) - i^2 L_{i-1}(x) \end{cases} \quad (i = 1, 2, \dots)$$

4. 埃尔米特(Hermite)多项式

n 次埃尔米特多项式为

$$H_n(x) = (-1)^n e^{x^2} \frac{d^n(e^{-x^2})}{dx^n} \quad (n = 0, 1, 2, \dots) \quad (3.17)$$

其最高次项的系数为 2^n . 埃尔米特多项式满足正交关系

$$\int_{-\infty}^{+\infty} e^{-x^2} H_i(x) H_j(x) dx = \begin{cases} 0, & i \neq j \\ 2^i i! \sqrt{\pi}, & i = j \end{cases}$$

具有递推关系

$$\begin{cases} H_0(x) = 1, & H_1(x) = 2x \\ H_{i+1}(x) = 2xH_i(x) - 2iH_{i-1}(x) \end{cases} \quad (i = 1, 2, \dots) \quad (3.18)$$

3.3.2 最佳平方逼近

定义 3.6 设函数 $f(x) \in C[a, b]$, 称 $\|f\|_2 = \sqrt{(f, f)}$ 为 $f(x)$ 的欧氏范数(2-范数).

设 $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x) \in C[a, b]$ 是一族在 $[a, b]$ 上线性无关的连续函数, 以它们为基底构成的线性空间为 $\Phi = \text{span}\{\varphi_0, \varphi_1, \dots, \varphi_n\}$. 所谓最佳平方逼近问题就是求广义多项式 $p(x) \in \Phi$, 即确定

$$p(x) = a_0 \varphi_0(x) + a_1 \varphi_1(x) + \dots + a_n \varphi_n(x) \quad (3.19)$$

的系数 $a_j (j=0, 1, \dots, n)$, 使函数

$$I(a_0, a_1, \dots, a_n) = \int_a^b \rho(x) [p(x) - f(x)]^2 dx \quad (3.20)$$

取最小值, 这里 $\rho(x)$ 为权函数.

显然, 使 $I(a_0, a_1, \dots, a_n)$ 达到最小的 a_0, a_1, \dots, a_n 必须满足方程组

$$\frac{\partial I}{\partial a_j} = 2 \int_a^b \rho(x) [p(x) - f(x)] \varphi_j(x) dx = 0$$

或写成

$$\int_a^b \rho(x) p(x) \varphi_j(x) dx = \int_a^b \rho(x) f(x) \varphi_j(x) dx \quad (j = 0, 1, \dots, n) \quad (3.21)$$

把式(3.19)代入式(3.21)得

$$\sum_{k=0}^n a_k \int_a^b \rho(x) \varphi_k(x) \varphi_j(x) dx = \int_a^b \rho(x) f(x) \varphi_j(x) dx \quad (j = 0, 1, \dots, n) \quad (3.22)$$

利用内积定义及范数定义将式(3.21)和式(3.22)改写成

$$\begin{aligned} (p - f, \varphi_j) &= 0 \quad (j = 0, 1, \dots, n) \\ \sum_{k=0}^n a_k (\varphi_k, \varphi_j) &= (f, \varphi_j) \quad (j = 0, 1, \dots, n) \end{aligned} \quad (3.23)$$

所以若 $p(x)$ 使 $I(a_0, a_1, \dots, a_n)$ 为极小, 其系数 a_k 必须满足式(3.23). 而式(3.23)的系数行列式必不等于 0, 从而方程组(3.23)有唯一解. 我们称方程组(3.23)为法方程.

此外容易证明 $p(x)$ 就是使 $I(a_0, a_1, \dots, a_n)$ 取极小值的函数. 特别当 $\{\varphi_k(x)\}$ 为 $[a, b]$ 上关于权函数 $\rho(x)$ 的正交函数系时, 可由式(3.23)求出

$$a_j = \frac{(f, \varphi_j)}{(\varphi_j, \varphi_j)} \quad (j = 0, 1, \dots, n)$$

而最佳平方逼近函数为

$$p(x) = \sum_{j=0}^n \frac{(f, \varphi_j)}{(\varphi_j, \varphi_j)} \varphi_j(x) \quad (3.24)$$

直接求解法方程是相当困难的, 通常采用正交多项式做基来求解. 我们称上述求最佳平方逼近函数的方法为按正交多项式展开的方法. 关于误差估计有下面的结论.

定理 3.1 设 $f(x) \in C[a, b]$, $p(x) = \sum_{j=0}^n c_j \varphi_j(x)$ 是 $f(x)$ 在 $[a, b]$ 上的最佳平方逼近函数, 则误差 $R = f - p$ 满足

$$\|R\|_2 = \left[\|f\|_2^2 - (f, p) \right]^{\frac{1}{2}} = \left[\|f\|_2^2 - \sum_{j=0}^n c_j (f, \varphi_j) \right]^{\frac{1}{2}} \quad (3.25)$$

例 3.5 求函数 $y = \arctan x$ 在 $[0, 1]$ 上的一次最佳平方逼近多项式.

解 方法一(直接法) 设 $\varphi_0(x) = 1, \varphi_1(x) = x$, 所求函数为 $p(x) = a_0 + a_1 x$. 首先计算各内积

$$(\varphi_0, \varphi_0) = \int_0^1 1 dx = 1, \quad (\varphi_0, \varphi_1) = \int_0^1 x dx = \frac{1}{2}, \quad (\varphi_1, \varphi_1) = \int_0^1 x^2 dx = \frac{1}{3}$$

$$(\varphi_0, y) = \int_0^1 \arctan x dx = \frac{\pi}{4} - \frac{1}{2} \ln 2, \quad (\varphi_1, y) = \int_0^1 x \arctan x dx = \frac{\pi}{4} - \frac{1}{2}$$

于是得法方程

$$\begin{cases} a_0 + \frac{1}{2} a_1 = \frac{\pi}{4} - \frac{1}{2} \ln 2 \\ \frac{1}{2} a_0 + \frac{1}{3} a_1 = \frac{\pi}{4} - \frac{1}{2} \end{cases}$$

解得

$$a_0 = 3 - 2 \ln 2 - \frac{\pi}{2} \approx 0.0430, \quad a_1 = \frac{3\pi}{2} - 6 + 3 \ln 2 \approx 0.7917$$

故所求一次最佳平方逼近多项式为