

# 第四章-插值与逼近

## (4) 最佳平方逼近和最小二乘拟合

# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结

# 问题背景

---

问题： 找到一个函数  $P_n$  (比如多项式) 使得  $P_n \approx f$

插值法的思路： 我们对于部分节点数据  $(x_i, f_i)$ ， 我们找到多项式  $P_n(x_i) = f_i$


我们需要量化距离， 比如使用  $D_\infty(P_n, f)$ ， 就此引出一致收敛的概念

插值法在实际问题中的限制：

- ▶ 对于带噪声的数据点不友好： 如果  $\tilde{f}_i = f_i + \text{噪声}$ ， 则插值  $P_n(x_i) = \tilde{f}_i$  显得不是很合理
- ▶ 直接的插值法不太直接适合高维问题
- ▶ ...

# 例子

---



# 目标

---

逼近部分需要解决的问题：

- ▶ 对于既定的函数  $f$ ，找到**最优**的近似函数
- ▶ 基于数据，找到**最优**的近似函数

我们可以考虑不同类型的函数族，在本门课中，我们主要会集中于多项式

此处的知识可以延展到偏微分方程的数值解、以及机器学习问题

# 具体情景

---

**问题：** 我们不想使用任何高次多项式（高次往往意味着高代价）；给定最高  $n$  次，最佳的近似函数是什么？

**参数化：**  $P_n(x) = a_0 + a_1x + \cdots + a_nx^n$ ；需要找到最好的系数  $a_0, a_1, \cdots, a_n$

**方法：** 求解如下的优化问题

$$\min_{a_0, a_1, \cdots, a_n} D(P_n, f)$$

其中  $D(\cdot, \cdot)$  代表两个函数之间的距离/差异。

函数插值部分我们大量使用了  $D_\infty$ ：

**优势** 代表最大可能的误差

**缺点** 该选择不是很好求导

出于易于求导数的原因，后续我们将使用  $D_2$

将所有次数不超过  $n$  次多项式集合为  $H_n$ ；我们希望求解

$$\begin{aligned}\|f - P_n^*\|_2 &= \min_{P \in H_n} \|f - P\|_2 \\ &= \min_{P \in H_n} \sqrt{\int_a^b (f(x) - P(x))^2 dx}\end{aligned}$$

最小化平方距离的函数  $P_n^*$  被称为  $f$  在区间  $[a, b]$  上的最佳平方逼近

注：若我们使用  $D_\infty$ ，此处类似的最佳多项式被称为最佳一致逼近多项式（课本 3.2 节）（不要求）。

# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结



## 核心思路

考虑基函数  $\varphi_k(x) = x^k$ , 目标函数  $f \in C[0, 1]$ 。我们解如下的优化问题:

$$\begin{aligned} & \min_{\{a_k\}_{k=0}^n} \int_0^1 \left( f(x) - \sum_{k=0}^n a_k \varphi_k(x) \right)^2 dx \\ &= \min_{\{a_k\}_{k=0}^n} \int_0^1 f(x)^2 dx - 2 \sum_{k=0}^n a_k \int_0^1 f(x) \varphi_k(x) dx + \sum_{j,k=0}^n a_j a_k \int_0^1 \varphi_k(x) \varphi_j(x) dx \end{aligned}$$

为了简化符号, 我们标记  $G_{j,k} = \int_0^1 \varphi_k(x) \varphi_j(x) dx$ ,  $d_k = \int_0^1 f(x) \varphi_k(x) dx$ :

上述问题等价于求解

$$\min_{\{a_k\}_{k=0}^n} -2 \sum_{k=0}^n a_k d_k + \sum_{j,k=0}^n a_j a_k G_{j,k}$$

**问题:** 为什么  $\int_0^1 f(x)^2 dx$  在找最佳系数的过程可以被扔掉?

我们需要优化的函数其实是一个二次函数：

$$\min_{\{a_k\}_{k=0}^n} -2 \sum_{k=0}^n a_k d_k + \sum_{j,k=0}^n a_j a_k G_{j,k} = L(a_0, a_1, \dots, a_n)$$

关于  $a_k$  求导可知，

$$\frac{dL(a_0, a_1, \dots, a_n)}{da_k} = -2d_k + 2a_k G_{k,k} + 2 \sum_{j \neq k} a_j G_{k,j} = -2d_k + 2 \sum_{j=0}^n G_{k,j} a_j$$

局部极小值满足对于任何的  $k$ ， $\frac{dL(a_0, a_1, \dots, a_n)}{da_k} = 0$ ；再通过简化可得，

$$\mathbf{G} \mathbf{a} = \mathbf{d}$$

$$\mathbf{G} = \begin{bmatrix} G_{00} & G_{01} & \cdots & G_{0n} \\ \vdots & \vdots & \vdots & \vdots \\ G_{n0} & G_{n1} & \cdots & G_{nn} \end{bmatrix} \quad \mathbf{a} = \begin{bmatrix} a_0 \\ \vdots \\ a_n \end{bmatrix} \quad \mathbf{d} = \begin{bmatrix} d_0 \\ \vdots \\ d_n \end{bmatrix}$$

在这里我们需要计算

$$G_{j,k} = \int_0^1 \varphi_k(x)\varphi_j(x) dx \quad d_k = \int_0^1 f(x)\varphi_k(x) dx$$

对于  $\varphi_k(x) = x^k$  的例子，我们可知

$$G_{j,k} = \frac{1}{k+j+1}$$

对应的矩阵  $\mathbf{G} = \begin{bmatrix} \frac{1}{1} & \frac{1}{2} & \cdots & \frac{1}{1+n} \\ \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{2+n} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{1}{n+1} & \frac{1}{n+2} & \cdots & \frac{1}{2n+1} \end{bmatrix}$  是 Hilbert 矩阵

## 练习

---


考虑  $f(x) = 1 + x^3$ ，求它在区间  $[0, 1]$  上的一次最佳平方逼近多项式。请用基函数  $\varphi_0(x) = x^0$ ,  $\varphi_1(x) = x^1$ ，计算法方程中的  $\mathbf{G}$  和  $\mathbf{d}$ 。

## 练习


考虑  $f(x) = 1 + x^3$ ，求它在区间  $[0, 1]$  上的一次最佳平方逼近多项式。请用基函数  $\varphi_0(x) = x^0$ ,  $\varphi_1(x) = x^1$ ，计算法方程中的  $\mathbf{G}$  和  $\mathbf{d}$ 。

答案:  $\mathbf{G} = \begin{bmatrix} 1 & 1/2 \\ 1/2 & 1/3 \end{bmatrix}$ ,  $\mathbf{d} = \begin{bmatrix} 5/4 \\ 7/10 \end{bmatrix}$

使用  $\{1, x\}$  为基函数



使用  $\{1, x, x^2\}$  为基函数



对于两个函数  $f, g$ ，计算

$$\int_a^b f(x)g(x) dx$$

是一个常见的数学场景，它背后具有更多的基础理论

# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结

# 函数的内积

根据对于不同节点  $i$  的权重，我们可以定义一般的内积

$$\langle \mathbf{x}, \mathbf{y} \rangle_w = \sum_{i=1}^n x_i y_i w_i$$

其中  $w_i > 0$  代表权重

向量的大小

$$\begin{aligned} & \|\mathbf{x}\|_2 \\ &= \sqrt{x_1^2 w_1 + x_2^2 w_2 + \cdots + x_n^2 w_n} \\ &= \sqrt{\langle \mathbf{x}, \mathbf{x} \rangle_w} \end{aligned}$$

假设在区间  $[a, b]$  上， $\rho$  是一个非负函数，则  $\rho$  可以类似承担权重的作用。函数  $f, g$  的内积可以被定义为：

$$\langle f, g \rangle_\rho = \int_a^b f(x)g(x)\rho(x) dx.$$

函数的  $L^2$  范数：

$$\|f\|_2 = \sqrt{\int_a^b f^2(x)\rho(x) dx} = \sqrt{\langle f, f \rangle_\rho}$$

注：当权重  $\rho$  可从上下文看出，或权重可以是任意的，或  $\rho = 1$  时，我们为简化有时用  $\langle f, g \rangle$  来代替  $\langle f, g \rangle_\rho$



对于向量,

$$\langle \mathbf{x}, \mathbf{y} \rangle = \langle \mathbf{y}, \mathbf{x} \rangle$$

$$\langle c\mathbf{x}, \mathbf{y} \rangle = c\langle \mathbf{x}, \mathbf{y} \rangle$$

$$\langle \mathbf{x}_1 + \mathbf{x}_2, \mathbf{y} \rangle = \langle \mathbf{x}_1, \mathbf{y} \rangle + \langle \mathbf{x}_2, \mathbf{y} \rangle$$

$$\langle \mathbf{x}, \mathbf{x} \rangle \geq 0$$

当且仅当  $\mathbf{x} = \mathbf{0}$ ,  $\langle \mathbf{x}, \mathbf{x} \rangle = 0$ .

Cauchy-Schwarz 不等式

$$|\langle \mathbf{x}, \mathbf{y} \rangle| \leq \|\mathbf{x}\|_2 \|\mathbf{y}\|_2$$

三角不等式

$$\|\mathbf{x} + \mathbf{y}\|_2 \leq \|\mathbf{x}\|_2 + \|\mathbf{y}\|_2$$

对于函数,

$$\langle f, g \rangle = \langle g, f \rangle$$

$$\langle cf, g \rangle = c\langle f, g \rangle$$

$$\langle f_1 + f_2, g \rangle = \langle f_1, g \rangle + \langle f_2, g \rangle$$

$$\langle f, f \rangle \geq 0$$

当且仅当  $f = 0$ ,  $\langle f, f \rangle = 0$ .

Cauchy-Schwarz 不等式

$$|\langle f, g \rangle| \leq \|f\|_2 \|g\|_2$$

三角不等式

$$\|f + g\|_2 \leq \|f\|_2 + \|g\|_2$$

对于向量, 若  $\langle \mathbf{x}, \mathbf{y} \rangle = 0$ , 我们称  $\mathbf{x}, \mathbf{y}$  正交 (或者垂直)

对于函数, 若  $\langle f, g \rangle = 0$ , 我们称  $f, g$  正交 (或者垂直)

为了强调权重  $\rho$ , 我们也会讲  $f, g$  在  $[a, b]$  上带权  $\rho$  正交

若向量  $\mathbf{x}_1, \mathbf{x}_2, \dots$  满足两两互相垂直, 则称为正交向量组

若函数  $\varphi_0, \varphi_1, \dots$  满足两两互相垂直, 则称为正交函数族

若我们进一步有  $\langle \varphi_j, \varphi_k \rangle = \delta_{j,k}$ , 则称  $\{\varphi_k\}$  为标准正交函数族

例子: 在区间  $[0, 1]$  上,  $\varphi_k(x) = \cos(2\pi kx)$ ,  $k = 0, 1, 2, \dots$ , 组成正交函数族。

## 一些性质

---

若

$$a_1 \mathbf{x}_1 + \cdots + a_n \mathbf{x}_n = 0$$

当且仅当  $a_1 = a_2 = \cdots = a_n = 0$ ,  
则称向量  $\mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_n$  线性无关

假设  $\varphi_0, \varphi_1, \cdots, \varphi_{n-1}$  在区间  $[a, b]$   
上连续, 若

$$a_0 \varphi_0 + a_1 \varphi_1 + \cdots + a_{n-1} \varphi_{n-1} = 0$$

当且仅当  $a_0 = a_1 = \cdots = a_{n-1} = 0$   
时成立, 则称  $\varphi_0, \varphi_1, \cdots, \varphi_{n-1}$  在  
 $[a, b]$  上线性无关。

## 定理

$\varphi_0, \varphi_1, \dots, \varphi_{n-1}$  在  $[a, b]$  上线性无关的充要条件是 *Cramer* 行列式  $\det(\mathbf{G}_{n-1}) \neq 0$ ,

$$\mathbf{G}_{n-1} = \begin{bmatrix} \langle \varphi_0, \varphi_0 \rangle & \langle \varphi_0, \varphi_1 \rangle & \cdots & \langle \varphi_0, \varphi_{n-1} \rangle \\ \langle \varphi_1, \varphi_0 \rangle & \langle \varphi_1, \varphi_1 \rangle & \cdots & \langle \varphi_1, \varphi_{n-1} \rangle \\ \vdots & \vdots & \vdots & \vdots \\ \langle \varphi_{n-1}, \varphi_0 \rangle & \langle \varphi_{n-1}, \varphi_1 \rangle & \cdots & \langle \varphi_{n-1}, \varphi_{n-1} \rangle \end{bmatrix}$$

# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结

## 问题 1: 改写函数逼近的一般情况

考虑基函数  $\varphi_k$ , 权重函数  $\rho$ , 目标函数  $f \in C[a, b]$ 。希望解如下的优化问题:

$$\begin{aligned} & \min_{\{a_k\}_{k=0}^n} \int_a^b \left( f(x) - \sum_{k=0}^n a_k \varphi_k(x) \right)^2 \rho(x) dx \\ &= \min_{\{a_k\}_{k=0}^n} \langle f, f \rangle_\rho - 2 \sum_{k=0}^n a_k \langle f, \varphi_k \rangle_\rho + \sum_{j,k=0}^n a_j a_k \langle \varphi_j, \varphi_k \rangle_\rho \end{aligned}$$

为了简化符号, 标记  $G_{j,k} = \langle \varphi_j, \varphi_k \rangle_\rho$ ,  $d_k = \langle f, \varphi_k \rangle_\rho$ :

上述问题等价于求解

$$\min_{\{a_k\}_{k=0}^n} -2 \sum_{k=0}^n a_k d_k + \sum_{j,k=0}^n a_j a_k G_{j,k}$$

最后通过求导可知，我们仅需求解

$$\sum_{j=0}^n G_{k,j} a_j = d_k \quad \text{法方程}$$

即求解

$$\mathbf{Ga} = \mathbf{d}$$

## 问题 2: 计算误差

---

若已经求解到最佳的系数  $a_0^*, a_1^*, \dots$ , 且最佳的近似函数标记为  $P_n^*$

$$\begin{aligned}\|f - P_n^*\|_2^2 &= \langle f - P_n^*, f - P_n^* \rangle \\ &= \langle f, f \rangle - 2\mathbf{d}^T \mathbf{a}^* + (\mathbf{a}^*)^T \mathbf{G} \mathbf{a}^*,\end{aligned}$$

由于最佳系数满足法方程

$$\mathbf{G} \mathbf{a}^* = \mathbf{d}$$

因而

$$\|f - P_n^*\|_2^2 = \langle f, f \rangle - \mathbf{d}^T \mathbf{a}^* = \langle f, f \rangle - \sum_{k=0}^n d_k a_k^*$$



# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结

# 最小二乘

---

假设我们有数据点  $(x_i, y_i)$ ,  $i = 0, 1, 2, \dots, m$ , 我们希望找到一个函数  $S$  使得误差  $\delta_i = S(x_i) - y_i$  最小化

$\|\delta\|_\infty$  的问题: 计算困难

$$\|\delta\|_\infty = \max_{0 \leq i \leq m} |\delta_i| \rightarrow \text{导数不好求}$$

$$\|\delta\|_2 = \sqrt{\delta_0^2 + \delta_1^2 + \dots + \delta_m^2} \rightarrow \text{导数好求}$$

我们假设  $S(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \cdots + a_n\varphi_n(x)$  ( $n < m$ )

$$\min_S \|\delta\|_2^2 = \min_S \sum_{i=0}^m [S(x_i) - y_i]^2 = \min_S \sum_{i=0}^m \left[ \sum_{j=0}^n a_j \varphi_j(x_i) - y_i \right]^2$$

最优的函数（即最小化误差）标记为  $S^*$

更一般地，

$$\|\delta\|_2^2 = \sum_{i=0}^m \underbrace{\omega(x_i)}_{\text{权重}} \left( \sum_{j=0}^n a_j \varphi_j(x_i) - y_i \right)^2 = L(a_0, a_1, \dots, a_n)$$

$\omega$  的选择取决于具体的问题；比如可以根据数据的可信度、重复实验的次数等因素来附上权重  $\omega$

$$\frac{\partial L}{\partial a_k} = 2 \sum_{i=0}^m \omega(x_i) \left( \sum_{j=0}^n a_j \varphi_j(x_i) - y_i \right) \varphi_k(x_i) = 0$$

我们引入一些符号来简化一下：

$$\langle \varphi_j, \varphi_k \rangle \stackrel{\text{定义为}}{=} \sum_{i=0}^m \omega(x_i) \varphi_j(x_i) \varphi_k(x_i)$$

$$\langle \mathbf{f}, \varphi_k \rangle \stackrel{\text{定义为}}{=} \sum_{i=0}^m \omega(x_i) y_i \varphi_k(x_i) \stackrel{\text{标记为}}{=} d_k$$

上述的方程可以写成矩阵的形式  $\mathbf{G}\mathbf{a} = \mathbf{d}$

$$\mathbf{a} = \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix} \quad \mathbf{d} = \begin{pmatrix} d_0 \\ d_1 \\ \vdots \\ d_n \end{pmatrix} \quad \mathbf{G} = \begin{pmatrix} \langle \varphi_0, \varphi_0 \rangle & \langle \varphi_0, \varphi_1 \rangle & \cdots & \langle \varphi_0, \varphi_n \rangle \\ \langle \varphi_1, \varphi_0 \rangle & \langle \varphi_1, \varphi_1 \rangle & \cdots & \langle \varphi_1, \varphi_n \rangle \\ \vdots & \vdots & & \vdots \\ \langle \varphi_n, \varphi_0 \rangle & \langle \varphi_n, \varphi_1 \rangle & \cdots & \langle \varphi_n, \varphi_n \rangle \end{pmatrix}$$

由于基函数  $\varphi_0, \varphi_1, \dots, \varphi_n$  线性无关，因而  $|\mathbf{G}| \neq 0$ ，故而方程组有唯一解

---

备注（不要求）：若函数的最佳平方逼近中  $\rho = \sum_{i=0}^n \omega(x_i) \delta(x - x_i)$ ，则变成了这里的最小二乘逼近；课本 (3.4) 节和 (3.6) 节讲的是一回事。

## 非多项式的最小二乘拟合

---

若我们希望拟合  $y(x) = ae^{b/x}$ ,  $a, b$  为参数

$$\ln y = \ln a + \frac{b}{x}$$

$$\text{令 } t = \frac{1}{x}$$

$$\ln y = \ln a + bt$$

可以先将数据变成  $(\frac{1}{x_i}, \ln y_i)$  再做线性拟合 (详见例题 3.6)。

# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结

## 多元函数的最小二乘拟合

给定  $m + 1$  个  $d$  维的数据  $\mathbf{x}_i = [x_{i,1} \ x_{i,2} \ \cdots \ x_{i,d}]$  和函数值  $y_i$  ( $0 \leq i \leq m$ )

我们可以类似推广：对于一个多元函数  $f(x_1, x_2, \cdots, x_d)$ ，希望找到最佳的

$$S_n(x_1, x_2, \cdots, x_d) = \sum_{k=0}^n a_k \varphi_k(x_1, x_2, \cdots, x_d), \quad n \leq m$$

使得如下的误差最小

$$\min_{a_0, a_1, \cdots, a_n} \sum_{i=0}^m \omega_i \left( y_i - S_n(x_{1,i}, x_{2,i}, \cdots, x_{d,i}) \right)^2$$

此处的最小二乘拟合的参数化方式对于高维数据并不高效。对于高维问题，所需要的基函数的个数可能关于  $d$  呈现指数递增关系（维数灾难）



给定  $m+1$  个  $d$  维的数据  $\mathbf{x}_i = [x_{i,1} \ x_{i,2} \ \cdots \ x_{i,d}]$  和函数值  $y_i$  ( $0 \leq i \leq m$ )

例子:  $d$  是维数,  $\mathbf{x}_i$  是一张图片,  $y_i$  是某个属性 (比如图片的类别); 则我们希望找到一个带参数的函数族  $S_\theta$  使得如下的误差最小化:

$$\min_{\theta} \sum_{i=0}^m \omega_i \left( y_i - S_\theta(x_{1,i}, x_{2,i}, \cdots, x_{d,i}) \right)^2$$

常见的例子是  $\omega_i = \frac{1}{m+1}$ 。这其实就是一个十分典型的机器学习问题; 只是  $S_\theta$  一般是用非线性的神经网络来构造。

前面提到的最小二乘可以被理解为一个参数线性化的网络。

# 目录

---

1. 背景
2. 多项式逼近（核心例子）
3.  $L^2$  函数空间
4. 多项式逼近（一般情况）
5. 最小二乘：基于数据
6. 多元函数的最小二乘拟合
7. 总结

# 总结

---

- ▶ 我们希望找到  $n$  次多项式  $P_n^*$  来近似  $f$ :

$$\|f - P_n^*\|_2 = \min_P \|f - P\|_2$$

- ▶ 该问题变成求解法方程（一个线性方程组）:

$$\mathbf{G}\mathbf{a} = \mathbf{d}$$

- ▶ 基于数据的最小二乘拟合具有类似的形式

解线性方程组如果想要解比较精确，我们会希望  $\text{cond}(\mathbf{G})$  不是很大。而  $\varphi_k(x) = x^k$  对应的 Hilbert 矩阵  $\mathbf{G}$  的条件数随着  $n$  快速变大，那么我们该如何解决？