

高等数值算法与应用(4)

- 最小二乘法 (chap5) -


喻文健

Outline

- ▶ 曲线拟合与逼近问题
- ▶ 线性最小二乘问题的解法
- ▶ 伪逆与不满秩情况
- ▶ 非线性最小二乘

最小二乘法

- ▶ 最小二乘法 (least squares)
 - 广泛用于数据拟合: 若误差的随机分布满足适当假设, 则通过最小二乘能得到参数的最大似然估计
 - 优化: 使估计误差的平方和最小化
 - “求解”一个超定的方程组 (优化剩余)



$$\min_{S(t)} \sum_{i=1}^m [y_i - y(t_i)]^2$$

▶ 拟合的模型

- 线性最小二乘: 设待求的 $y(t) \approx \beta_1 \phi_1(t) + \dots + \beta_n \phi_n(t)$

- ➡ 求 n 个基函数前的系数

超定方程组, 最小化剩余

- 定义设计矩阵 X ,
 $x_{i,j} = \phi_j(t_i)$
- $$\begin{bmatrix} \phi_1(t_1) & \phi_2(t_1) & \cdots & \phi_n(t_1) \\ \phi_1(t_2) & \phi_2(t_2) & \cdots & \phi_n(t_2) \\ \vdots & \vdots & \vdots & \vdots \\ \phi_1(t_m) & \phi_2(t_m) & \cdots & \phi_n(t_m) \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{bmatrix} \approx \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$
- $$X \hat{\beta} \approx y$$

最小二乘法

拟合的模型

- 线性最小二乘的常见拟合模型

- 直线: $y(t) \approx \beta_1 t + \beta_2$

- 多项式: $y(t) \approx \beta_1 t^{n-1} + \dots + \beta_{n-1} t + \beta_n$

- 对数线性: $y(t) \approx K e^{\lambda t}$

Matlab中polyfit命令

注意: 拟合目标发生了变化

$$\log y \approx \beta_1 t + \beta_2, \text{ with } \beta_1 = \lambda, \beta_2 = \log K$$

- 可分离的非线性最小二乘: 基函数中含额外参数

- 指数函数: $y(t) \approx \beta_1 e^{-\lambda_1 t} + \dots + \beta_n e^{-\lambda_n t}$

β_i 是线性组合系数, λ_i 是非线性参数

- 高斯函数: $y(t) \approx \beta_1 e^{-\left(\frac{t-\mu_1}{\sigma_1}\right)^2} + \dots + \beta_n e^{-\left(\frac{t-\mu_n}{\sigma_n}\right)^2}$

- 有理函数: $y(t) \approx \frac{\beta_1 t^{n-1} + \dots + \beta_{n-1} t + \beta_n}{\alpha_1 t^{n-1} + \dots + \alpha_{n-1} t + \alpha_n}$

最小二乘法

▶ 曲线拟合的例子

- 根据1900~2000年美国人口(每10年采样), 预测2010年人口

- 一种模型: $y \approx \beta_1 t^3 + \beta_2 t^2 + \beta_3 t + \beta_4$
- 直接构造的设计矩阵 X 比较病态, (各列近似线性相关), 求解时会导致较大误差

$$\begin{bmatrix} t_1^3 & t_1^2 & \cdots & 1 \\ \vdots & \vdots & \vdots & \vdots \\ t_n^3 & t_n^2 & \cdots & 1 \end{bmatrix}$$

- 改进策略**: 令 $s = (t - 1950)/50$


- 得到 s_i, y_i 对应关系, 列设计矩阵

- 演示程序censusgui

- 其中还包括插值模型

- 及对数线性 $y(t) \approx Ke^{\lambda t}$

- 程序无法回答“**哪个模型是最佳的?**”, 只能由使用者来决策



其他逼近问题

▶ 从范数的角度思考

- 剩余(residual)是观测值和模型值之差 $r_i = y_i - \sum_{j=1}^n \beta_j \phi_j(t_i, \alpha)$
- 做拟合就是希望剩余尽可能小
- “小”的标准不同对应不同的逼近问题

基函数带的参数

$$\text{即 } r = y - X(\alpha)\beta$$

- 插值：在所有观测点上剩余为0，且 $m=n$

- 最小二乘：最小化剩余的2-范数(平方和) $\|r\|^2 = \sum_{i=1}^m r_i^2$

- 加权最小二乘：某些观测值有更高权重(例如误差小的) ¹

- 若要最小化的是 $\|r\|_w^2 = \sum_{i=1}^m w_i^2 r_i^2$

- 只需将观测值 y_i 和设计矩阵 X 的第 i 行都乘以 w_i

- 1-范数：最小化剩余的绝对值之和

$$\|r\|_1 = \sum_{i=1}^m |r_i|$$

- ∞ -范数：最小化绝对值最大分量 $\|r\|_\infty = \max_i |r_i|$



压缩稀疏信号的恢复(Compressed sensing): min解的1范数

转化为
线性规
划问题

线性最小二乘问题的解法

» 概述

Householder反射

QR分解

利用QR分解解线性最小二乘

求解线性最小二乘问题

$$X\beta \approx y$$

▶ 概述

- 比非线性最小二乘、1-范数、 ∞ -范数逼近容易求解
- 若设计矩阵为X, 观测向量y, 在Matlab中 `>> beta = X\y`
- “\”处理“长条形”矩阵的算法基于对矩阵X作QR分解

非线性优化

▶ 法方程法

- 最小化的目标 $\|r\|^2$ 是关于参数 β_i 的二次函数
- 利用多元函数求极值方法可得取极小值的必要条件

$X^T X \beta = X^T y$ 若X列向量线性无关, 则为n阶非奇异矩阵

- 缺点是数值误差大, $X^T X$ 可能(近)奇异 $X^T X$ 往往病态

- 例: $X = \begin{pmatrix} 1 & 1 \\ \delta & 0 \\ 0 & \delta \end{pmatrix}$ 若 $|\delta| < 10^{-8}$, 则 $\kappa(X^T X) = \kappa(X)^2$

$$X^T X = \begin{pmatrix} 1 + \delta^2 & 1 \\ 1 & 1 + \delta^2 \end{pmatrix} \text{奇异}$$

$$\begin{matrix} m \\ \boxed{X} \\ n \end{matrix}$$

课后思考

基于矩阵QR分解的解法

▶ Householder反射

◦ 一种重要的矩阵变换. 矩阵 $H = I - \rho uu^T$

◦ u 为任意非零向量, 而 $\rho = 2/\|u\|^2$

◦ 或, $w = u/\|u\|$, 则 $H = I - 2ww^T$

◦ 性质: 对称阵、正交阵

$$H^T H = H^2 = I$$

$$H = \begin{bmatrix} 1 - 2w_1^2 & -2w_1w_2 & \cdots & -2w_1w_n \\ -2w_2w_1 & 1 - 2w_2^2 & \cdots & -2w_2w_n \\ \vdots & \vdots & \cdots & \vdots \\ -2w_nw_1 & -2w_nw_2 & \cdots & 1 - 2w_n^2 \end{bmatrix}$$

◦ Hx 对向量 x 做变换

$$Hx = (I - 2ww^T)x = x - 2ww^T x$$


$$ww^T x = (w^T x)w = v \quad \longrightarrow \quad Hx = x - 2v$$

◦ Hx 与 x 的2-范数相等, 镜面反射

◦ 提示1: 不显式构造 H , $Hx = x - \tau u$, $\tau = \rho u^T x$

◦ 提示2: 对任意 y , $\|x\| = \|y\|$, 都可构造 H , 使得 $Hx = y$

关键是让 u ,或 w 与 $x-y$ 同方向



基于矩阵QR分解的解法

▶ 用Householder变换进行消元

- 对向量 x , 可构造正交阵 H 使得向量 Hx 只有一个分量非零


$$\left\{ \begin{array}{l} \sigma = -\text{sign}(x_k) \|x\| \quad \text{希望 } Hx = \sigma e_k \\ \mathbf{u} = \mathbf{x} - \sigma \mathbf{e}_k \quad \leftarrow \text{可能同符号数相减! 修改后无抵消现象} \\ \mathbf{H} = \mathbf{I} - \rho \mathbf{u} \mathbf{u}^T, \quad \rho = 2 / \|\mathbf{u}\|^2 = -1 / (\sigma u_k) \end{array} \right.$$

- 与向量相乘 $H\mathbf{y} = \mathbf{y} + \frac{\mathbf{u} \mathbf{u}^T \mathbf{y}}{\sigma u_k}$ (2m次乘法计算量)

▶ 矩阵的QR分解

- “六大矩阵分解”之一, (两种形式)
- Q为正交阵, R为上三角阵
- 用Householder变换实现: 对X逐次消元得上三角阵R

$$H_n \cdots H_2 H_1 X = R \longrightarrow Q = (H_n \cdots H_2 H_1)^T$$



Householder变换实现QR分解

NCM演示 `>> qrsteps(randi(5,5,4))`

▶ 用Householder变换实现: $H_n \cdots H_2 H_1 A = R$

◦ 设 $A \in \mathbb{R}^{m \times n}$, $m \geq n$, $A = [a_1, a_2, \dots, a_n]$, 其中 a_j 为 m 维向量

构造 m 阶反射阵 H_1
消 A 的第 1 列:

$$A^{(2)} = H_1 A = \begin{bmatrix} -\sigma_1 & a_{12}^{(2)} & \cdots & a_{1n}^{(2)} \\ 0 & a_{22}^{(2)} & \cdots & a_{2n}^{(2)} \\ \vdots & \vdots & & \vdots \\ 0 & a_{m2}^{(2)} & \cdots & a_{mn}^{(2)} \end{bmatrix} = \begin{bmatrix} -\sigma_1 & | & & | \\ 0 & H_1 a_2 & \cdots & H_1 a_n \\ \vdots & | & & | \\ 0 & | & & | \end{bmatrix}$$

用 H_2 实现 $A^{(2)}$ 第 2 列的
消元, 同时不影响第 1 列

令 $H_2 = \begin{bmatrix} 1 & \mathbf{0}^T \\ \mathbf{0} & H'_2 \end{bmatrix}$

$$H_2 A^{(2)} = \begin{bmatrix} -\sigma_1 & r_1^T \\ \mathbf{0} & H'_2 A'^{(2)} \end{bmatrix} = \begin{bmatrix} -\sigma_1 & & & & r_1^T \\ 0 & -\sigma_2 & | & & | \\ 0 & 0 & H'_2 a_2'^{(2)} & \cdots & H'_2 a_{n-1}'^{(2)} \\ \vdots & \vdots & | & & | \\ 0 & 0 & | & & | \end{bmatrix}$$

记 $A^{(2)} = \begin{bmatrix} -\sigma_1 & r_1^T \\ \mathbf{0} & A'^{(2)} \end{bmatrix}$ 构造 H'_2

H_2 也是Householder阵(其向量 u 的第一个分量为 0). 后续 H_j 类似构造

基于矩阵QR分解的解法

▶ 利用QR分解求解

- 求解线性最小二乘问题，不需显式地算出Q
- Householder反射也作用于 $X\beta \approx y$ 的右端项
- $R\beta \approx z$ ，其中 $H_n \cdots H_2 H_1 y = z$ 正交变换不改变2-范数！
- 求 β ，使得 $\|z - R\beta\|$ 达到最小值

$$\text{设 } R = \begin{bmatrix} R_1 \\ \mathbf{0} \end{bmatrix}^{n \text{行}}, \quad z = \begin{bmatrix} z_1 \\ z_2 \end{bmatrix}^{n \text{行}}, \quad z - R\beta = \begin{bmatrix} z_1 - R_1\beta \\ z_2 \end{bmatrix}$$

$$\|z - R\beta\|_2^2 = \|z_1 - R_1\beta\|_2^2 + \|z_2\|_2^2 \geq \|z_2\|_2^2 \quad \text{取等号条件: } R_1\beta = z_1$$

▶ 例：美国人口预测 (pp.127)

- $y(s) \approx \beta_1 s^2 + \beta_2 s + \beta_3$
- 拟合1950开始后6个点
结果与 $\text{beta} = X \setminus y$ 一样

```
>> s = ((1950:10:2000) - 1950) / 50
>> X = [s.*s s ones(size(s))]
>> [R, z] = qrsteps(X, y)
>> beta = R(1:3, 1:3) \ z(1:3)
>> p2010 = polyval(beta, 1.2)
```

伪逆与不满秩情况

- » 矩阵的伪逆
- 设计矩阵不满秩?
- 基本解与最小二乘解
- 有关Matlab命令

伪逆与不满秩情况

▶ 矩阵的伪逆 (pseudo inverse)

- 矩阵的Frobenius范数

$$\|A\|_F = \left(\sum_i \sum_j a_{i,j}^2 \right)^{1/2}$$

```
>> norm(A, 'fro');
```

```
norm(A, 'fro') == norm(A(:))
```

- Moore-Penrose **伪逆** 将 **非奇异阵的逆** 推广到一般矩阵
矩阵A的伪逆记为 $Z = A^+$

```
>> Z = pinv(A);
```

- 若 **A列满秩**, $A^+ = (A^T A)^{-1} A^T \longrightarrow Ax \approx y$ 的解为 $x = A^+ y$
- A^+ 具有 A^{-1} 的一些性质, 例如: 它是”左逆” $A^+ A = I$
- 但不是”右逆” $AA^+ \neq I$
- 若 **列不满秩**, 有另外的定义 (矩阵的奇异值分解)

扩展矩阵的条件数: $\text{cond}(A) = \|A\| \cdot \|A^+\|$

伪逆与不满秩情况

▶ 矩阵的伪逆 (pseudo inverse)

- 定义一般矩阵伪逆的方式之一: 从“逼近右逆”的角度

- 伪逆 A^+ 是最逼近右逆条件的矩阵 Z :

- 且还是满足最小化条件 $\|AA^+ - I\|_F = \min_Z \|AZ - I\|_F$
的 Z 矩阵中 F -范数最小的那个

- 例: 标量 x 的伪逆(近似右逆)

- 要最小化 $|xz-1|$. 若 $x \neq 0$, 伪逆是 $1/x$, 是唯一的

- 若 $x=0$, $|xz-1|=1$, 伪逆取绝对值最小的那个 z , 即 0

▶ 设计矩阵不满秩 $X\beta \approx y$

思考: 行向量 a
的伪逆是?

- 问题的建模或误差导致

存在非零向量 η , 使得 $X\eta = 0$ (因此最小二乘解不唯一)

伪逆与不满秩情况

$$X\beta \approx y$$

▶ 设计矩阵X不满秩的情况 (rank deficiency)

◦ 还能用QR分解的方法求最小二乘解吗?



◦ Householder变换过程不会中断

◦ 得到R的列秩与X的一样, 因此R的对角元有0

$$\begin{bmatrix} Q^T \end{bmatrix} \begin{bmatrix} X \end{bmatrix} = \begin{bmatrix} R \end{bmatrix}$$

◦ $R_1\beta = z_1$ 有无穷多解 怎么求一个特殊性质的解?

◦ 设计矩阵X近似不满秩的例子

$$X = \begin{bmatrix} 0.641 & 0.242 \\ 0.321 & 0.121 \\ 0.962 & 0.363 \end{bmatrix} \xrightarrow{\text{QR分解}} R = \begin{bmatrix} -1.1997 & -0.4527 \\ 0 & 0.0002 \\ 0 & 0 \end{bmatrix} \rightarrow \begin{array}{l} \text{近似0} \\ \text{矩阵 } R_1 \text{ 近奇异} \end{array}$$


◦ “数值秩”为1; 求解最小二乘解时很敏感(误差大)

对敏感性问题, 怎么求数值秩?

列主元QR分解

- ▶ 做正交变换时适当地交换列

$$H_n \cdots H_1 X = \begin{bmatrix} R \\ O \end{bmatrix} \longrightarrow H_k \cdots H_1 X P_1 \cdots P_k = \begin{bmatrix} R & S \\ O & O \end{bmatrix}$$



- 在未消去的子矩阵中找2-范数最大的列，做列交换
- 若2-范数为0，则后续列均为0. 这发生在第k步变换后， $k = \text{rank}(X)$ (正交变换不改变列秩)

- 求最小二乘问题 $X\beta \approx y$ 的基本解 $Q^T X\beta \approx Q^T y$
- 列主元QR分解 $Q^T X = \begin{bmatrix} R & S \\ O & O \end{bmatrix} P^T$ 变换后的右端项 $Q^T y = \begin{bmatrix} z_1 \\ z_2 \end{bmatrix}$
- 等价于求解

$$\begin{bmatrix} R & S \\ O & O \end{bmatrix} P^T \beta \approx \begin{bmatrix} z_1 \\ z_2 \end{bmatrix} \text{ 设 } c = P^T \beta, \text{ 可取 } c = \begin{bmatrix} R^{-1} z_1 \\ 0 \end{bmatrix} \longrightarrow \beta = Pc$$

```
>> beta=X\y;
```

基本解：非零元数目不超过X的秩
同时算出X的数值秩

用SVD算最小范数解

$$X\beta \approx y$$

- ▶ 矩阵X的奇异值分解(singular value decomposition)
 - 任意 $m \times n$ 矩阵可分解为 $X = U\Sigma V^T$
 - 其中U, V为正交阵, Σ 为对角元 ≥ 0 (降序排列)的对角阵
 - 线性最小二乘问题: $\min \|y - X\beta\|_2 \iff \min \|y - U\Sigma V^T \beta\|_2$
 - 正交阵不改变2-范数 $\iff \min \|U^T y - \Sigma V^T \beta\|_2$
 - 设 $c = V^T \beta$, 最小化目标变为 $\|U^T y - \Sigma c\|_2$
 - 一个解是 $c = \begin{bmatrix} u_1^T y / \sigma_1 \\ \vdots \\ u_r^T y / \sigma_r \\ 0 \end{bmatrix}$, r 为非零奇异值个数(X的秩)
 - 所有可能的解中2-范数最小的
 - $\implies \beta = Vc$ 称为“最小范数解”
 - 按最一般的伪逆定义, 最小范数解就是 $\beta = X^+ y$
- 求最小范数解比求基本解计算量大些

```
>> beta=pinv(X)*y;
```

Matlab有关命令的说明

•qr命令

- 能处理稠密或“稀疏”矩阵, 允许 $m < n$ (列不满秩)
- $[Q,R] = qr(A)$; 完整的QR分解, Householder, Givens
- $[Q,R] = qr(A,0)$; 简化形式的QR分解, 若 $m < n$ 同上
- $[Q,R,E] = qr(A)$; E 为排列阵, $AE=QR$, R 对角元递减
- $[Q,R,E] = qr(A,0)$; E 为排列向量, $A(:, E)=QR$
- $R = qr(A)$; A 稠密时, 返回矩阵上三角部分为 R ; A 稀疏时, R 就是上三角阵, 且 $R^T R = A^T A$

•\命令

- 求解线性最小二乘问题, 列重排的Householder变换
- 列不满秩会报warning, 得到一个基本解

•polyfit命令

- 多项式最佳平方逼近: $p = polyfit(x,y,n)$

非线性最小二乘

» 可分离最小二乘问题

可分离最小二乘问题

例如, $y \approx \beta_1 e^{-\lambda_1 t} + \beta_2 e^{-\lambda_2 t}$

▶ 问题定义与求解思路

- 拟合公式中含非线性参数与线性参数

- 若已知非线性参数($\lambda_{1/2}$)的值, 则用 \ 可求线性参数值($\beta_{1/2}$)

- 需最小化的是剩余的2-范数 $\sum_{i=1}^m [y_i - (\beta_1 e^{-\lambda_1 t_i} + \beta_2 e^{-\lambda_2 t_i})]^2$


- ~ 非线性参数($\lambda_{1/2}$)的函数  求函数最小值问题

- 优化求解器 + 线性最小二乘求解器

比全看成非线性参数做优化的方法更有效/鲁棒

▶ 求多元实函数的最小值

- `fminsearch`, (无约束非线性优化, 直接搜索法)

- `[x, fval] = fminsearch(fun, x0, options)`  后面加给fun的参数

- 对于例子, 定义fun的输入为 λ_1, λ_2 , 返回值为最小剩余

可分离最小二乘问题


▶ 例子 $y \approx \beta_1 e^{-\lambda_1 t} + \beta_2 e^{-\lambda_2 t}$

(放射性物质衰变的观测)

- 数据: $t = (0:.1:2)'$
- $y = [5.8955 \ 3.5639 \ 2.5173 \ 1.9790$
- $\dots, 0.1370 \ 0.2211 \ 0.1704 \ 0.2636]'$;
- λ_1, λ_2 的初值为: $[3 \ 6]'$

▶ 求解过程与演示

- 线性最小二乘的解定义为函数:
`res = expfitfun(lambda, t, y)`
- 非线性最小化: `fminsearch(@expfitfun, lambda0, [], t, y)`
- 程序细节与动态演示程序
`expfitdemo`



将观测数据设为函数参数

```
>> edit expfitfun.m;  
>> edit expfitdemo.m;
```

非线性最小二乘及最优化问题

- ▶ `fminsearch`
 - 适合仅含几个变量的小规模优化问题
- ▶ Matlab优化工具箱(Toolbox)
 - 带约束极小化 `fmincon`
 - 无约束极小化 `fminunc`
 - 最小二乘问题也属于最优化问题
 - 特别针对最小二乘问题的函数: `lsqnonlin`, `lsqcurvefit`
- ▶ 曲线拟合工具箱
 - 方便解决曲线、曲面拟合问题的图形交互界面