



计算方法

刘景铨

计算机软件新技术国家重点实验室
南京大学



回顾

上节课:

- Chebyshev插值
- Chebyshev多项式
- 由函数/多项式亦可组成的向量空间

这节课:

- **最小二乘法-离散线性版本**: 给定矩阵 A , 向量 b , 求 x 使得 $\|Ax - b\|_2^2$ 最小



课程计划

最小二乘法

- 建模和应用讨论：图像拼接
- 三角级数近似



最小二乘法—求解线性方程

给定矩阵 $A \in \mathbb{R}^{m \times n}$ ，向量 $b \in \mathbb{R}^m$ ，求 $x \in \mathbb{R}^n$ 使得 $Ax = b$

只有三种情况

- 对任意的向量 b ，存在唯一解
- 不可解，或方程不一致 (inconsistent, over-determined)
- 存在无穷多组解 (under-determined)

性质：只要存在两个不同的解，则一定存在无穷多组解。

接下来：对于方程不一致的情况，我们讨论**最小二乘法**
最佳平方逼近




最小二乘法-离散线性版本

从最简单的设定开始。我们想要找出一个线性拟合，使误差的2-范数最小化：

- 给定矩阵 A ，向量 b ，求 x 使得 $\|Ax - b\|_2^2$ 最小

$$\begin{pmatrix} \vdots & \vdots & \vdots & \vdots \\ A_1 & A_2 & A_3 & \dots & A_n \\ \vdots & \vdots & \vdots & \vdots & \vdots \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = x_1 A_1 + x_2 A_2 + \dots + x_n A_n$$


- 右边是 A_1, A_2, \dots, A_n 能够生成的线性子空间



向量 b 不一定在该子空间内，此时，应该找“最接近”的



最小二乘法建模：图像拼接



照片来源：由本人拍摄于2022-03-18



最小二乘法建模：图像拼接

- 在图片上选取一些参考点（比如同一个建筑，对应的树）
- 希望找到矩阵 $A \in \mathbb{R}^{2 \times 2}$ 和向量 $b \in \mathbb{R}^2$
- 使得对于每一个参考点都有



\approx

$A \times$




$+ b$

- 未知量是什么？
- 思考：值得注意的是这里的量词的顺序
 - 如果，对于每一个参考点，都要求找到一个矩阵 $A \in \mathbb{R}^{2 \times 2}$ 和向量 $b \in \mathbb{R}^2$ 最小化误差呢？



最小二乘法-几何解释

从最简单的设定开始。我们想要找出一个线性拟合，使误差的2-范数最小化：



最接近的点记为 $A\bar{x}$ ，则 $(A\bar{x} - b) \perp \{A x : x \in R^n\}$
即 $\forall x \in R^n, (A x)^\top (A\bar{x} - b) = 0$ ，或者 $x^\top A^\top (A\bar{x} - b) = 0$

要 $\forall x \in R^n$ 同时成立，只有一种可能： $A^\top (A\bar{x} - b) = 0$
因此 $A^\top A\bar{x} = A^\top b$ 法线方程



最小二乘法-微积分解释

注意到最小化 $\|x\|_2$ 和最小化 $\|x\|_2^2$ 是等价的（单调性）

记 $\bar{x} = \operatorname{argmin}_x \|Ax - b\|_2^2$

对 x 求梯度

$$\begin{aligned}\nabla \|Ax - b\|_2^2 &= \left(\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n} \right) \|Ax - b\|_2^2 \\ &= \left(\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n} \right) (x^\top A^\top Ax + b^\top b - b^\top Ax - x^\top A^\top b) \\ &= 2A^\top A x - 2A^\top b\end{aligned}$$

把梯度设为0，亦可得到法线方程 $A^\top A \bar{x} = A^\top b$

注：一般不会直接通过 $\bar{x} = (A^\top A)^{-1} A^\top b$ 来运算
解线性方程组，与矩阵求逆是两回事，以后会展开讨论



最小二乘法-变分法解释

记误差函数为 $E(x) := \|Ax - b\|_2^2$

则 \bar{x} 满足法线方程 $A^T A \bar{x} = A^T b$ 当且仅当

$$\forall y, E(\bar{x}) \leq E(\bar{x} + y)$$

证明(Sketch):

$$E(\bar{x} + y) = E(x) + (Ay)^T (Ay) + 2y^T A^T (A\bar{x} - b)$$

注意到

$$(\forall y, y^T A^T (A\bar{x} - b) = 0) \iff A^T (A\bar{x} - b) = 0$$

考虑逆反命题:

$$(\exists y, y^T A^T (A\bar{x} - b) \neq 0) \iff (\exists y, y^T A^T (A\bar{x} - b) < 0)$$

进而, 通过取足够短的向量 y , 可以令

$$(Ay)^T (Ay) + 2y^T A^T (A\bar{x} - b) < 0$$

进而得到 $E(\bar{x}) > E(\bar{x} + y)$




最小二乘法与正交性

给定矩阵 A ，向量 b ，求 x 使得 $\|Ax - b\|_2^2$ 最小。

由法线方程 $A^T A \bar{x} = A^T b$ ，得出 $\bar{x} = (A^T A)^{-1} A^T b$

- 但是，一般数值算法中不会直接求解法线方程
- 更不会求 $(A^T A)^{-1}$



- 如图所示，不管选 A_1 还是 A_2 ，都能给出对 b 不错的近似，但是对应的 x 是非常不一样的



最小二乘法-Gram-Schmidt正交化

一个更好的做法是通过Gram-Schmidt求 $A = QR$ 分解

- 如果 A 的每一列是正规化的(orthonormal)?

$$A = \begin{pmatrix} \vdots & \vdots & \vdots & \vdots \\ A_1 & A_2 & A_3 & \dots & A_n \\ \vdots & \vdots & \vdots & \vdots & \vdots \end{pmatrix}$$
$$A_i^\top A_j = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$$

则 $A^\top A = I$

法线方程 $A^\top A \bar{x} = A^\top b$ 简化为 $\bar{x} = A^\top b$



最小二乘法-Gram-Schmidt正交化

- 给定A，如何找出一组正规化的(orthonormal)基？

$$A = \begin{pmatrix} \vdots & \vdots & \vdots & \dots & \vdots \\ A_1 & A_2 & A_3 & \dots & A_n \\ \vdots & \vdots & \vdots & \dots & \vdots \end{pmatrix}$$

- $y_1 = A_1, q_1 = y_1/\|y_1\|_2$
- $y_2 = A_2 - q_1(A_2^\top q_1), q_2 = y_2/\|y_2\|_2$
- 类似地
- $y_j = A_j - q_1(A_j^\top q_1) - q_2(A_j^\top q_2) - \dots, q_j = y_j/\|y_j\|_2$



最小二乘法-Gram-Schmidt正交化

- 给定A，如何找出一组正规化的(orthonormal)基？

$$A = \begin{pmatrix} \vdots & \vdots & \vdots & \dots & \vdots \\ A_1 & A_2 & A_3 & \dots & A_n \\ \vdots & \vdots & \vdots & \dots & \vdots \end{pmatrix}$$

Classical Gram-Schmidt orthogonalization

Let $A_j, j = 1, \dots, n$ be linearly independent vectors.

for $j = 1, 2, \dots, n$

$y = A_j$

for $i = 1, 2, \dots, j - 1$

$r_{ij} = q_i^T A_j$

$y = y - r_{ij} q_i$

end

$r_{jj} = \|y\|_2$

$q_j = y/r_{jj}$

end



最小二乘法-Gram-Schmidt正交化

- 给定A，如何找出一组正规化的(orthonormal)基？

$$A = \begin{pmatrix} \vdots & \vdots & \vdots & \dots & \vdots \\ A_1 & A_2 & A_3 & \dots & A_n \\ \vdots & \vdots & \vdots & \dots & \vdots \end{pmatrix}$$

Modified Gram-Schmidt orthogonalization

Let $A_j, j = 1, \dots, n$ be linearly independent vectors.

```
for  $j = 1, 2, \dots, n$   
   $y = A_j$   
  for  $i = 1, 2, \dots, j - 1$   
     $r_{ij} = q_i^T y$   
     $y = y - r_{ij} q_i$   
  end  
   $r_{jj} = \|y\|_2$   
   $q_j = y / r_{jj}$   
end
```



最小二乘法与正交性

通过Gram-Schmidt求 $A = QR$ 分解

$$\begin{pmatrix} \vdots & \vdots & \vdots & & \vdots \\ A_1 & A_2 & A_3 & \dots & A_n \\ \vdots & \vdots & \vdots & & \vdots \end{pmatrix} = \begin{pmatrix} \vdots & \vdots & \vdots & & \vdots \\ q_1 & q_2 & q_3 & \dots & q_n \\ \vdots & \vdots & \vdots & & \vdots \end{pmatrix} \begin{pmatrix} r_{11} & \dots & r_{1n} \\ 0 & \ddots & \vdots \\ 0 & 0 & r_{nn} \end{pmatrix}$$

- 其中 Q 为正交阵: $Q^T Q = I$
 - 这意味着 $\langle q_i, q_j \rangle = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$
- R 为上三角阵

通过QR分解, $A^T A \bar{x} = A^T b \Rightarrow \bar{x} = R^{-1} Q^T b$


并不需要计算 $A^T A$

实践中, 更常用, 更数值稳定的是Householder反射子, 而不是Gram-Schmidt




最小二乘法与正交性

正交变换



非正交变换





最小二乘法与正交性

若 Q 为正交阵： $Q^T Q = I$ ，则 $\|Qx\|_2 = \|x\|_2$

Isometry: 保距映射

思考：除了长度，还可以考虑角度

$$\langle Qx, Qy \rangle = ?$$



最小二乘法-方程不一致的情形

- $(A^T A)^{-1} A^T$ 是 A 的一个 *pseudoinverse*
只要 A 的列是线性无关的, 则 $A^T A$ 可逆
$$\bar{x} = (A^T A)^{-1} A^T b$$

思考: 如果是方程数不足呢 (under-determined)?

- $Ax = b$ 的解并不唯一, 有无穷多组解
- 能否找到长度最短的解?
- 下次作业: A 的行是线性无关的话, 亦可写出一个 *pseudoinverse*
- Bonus: 验证这样找到的, 是长度最短的解



回顾：向量空间的范数

\mathbb{R}^n 上的无穷范数，对于向量 $x = (x_1, x_2, \dots, x_n)^\top$

$$\|x\|_\infty := \max_i |x_i|$$

\mathbb{R}^n 上的2-范数，对于向量 $x = (x_1, x_2, \dots, x_n)^\top$

$$\|x\|_2 := \left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} = \sqrt{\langle x, x \rangle}$$

函数 f 的无穷范数 (∞ -norm):

$$\|f\|_\infty := \sup |f|$$

函数 f 的2-范数 (2-norm):

$$\|f\|_2 := \sqrt{\int |f(x)|^2 dx}$$

如果要找到函数 f 的最佳2-范数近似（最佳平方逼近），要比最佳无穷范数的近似容易得多：最小二乘法



内积空间

内积 $\langle \cdot, \cdot \rangle$

- 对称性 $\langle x, y \rangle = \langle y, x \rangle$
- 线性 $\langle a x + b y, z \rangle = a \langle x, z \rangle + b \langle y, z \rangle$
- 正定性 $\langle x, x \rangle > 0, \forall x \neq 0$

函数的内积:

$$\langle f, g \rangle := \int f(x)g(x)dx$$

带权重的函数内积

$$\langle f, g \rangle_w := \int f(x)g(x)w(x)dx$$

内积天然自带范数的定义: $\|x\| = \sqrt{\langle x, x \rangle}$



正交函数族与正交多项式

称函数族 $\phi_1(x), \phi_2(x), \dots$ 是正交化的, 如果它们满足:

$$\langle \phi_i, \phi_j \rangle = \begin{cases} C_i, & i = j \\ 0, & i \neq j \end{cases}$$

- 如果 $\phi_1(x), \phi_2(x), \dots$ 是多项式, 也称之为正交多项式

Chebyshev 多项式也是多项式的一组基

它关于 $w(x) = \frac{1}{\sqrt{1-x^2}}$ 所定义的内积是正交的:

$$\langle f, g \rangle_w := \int_{-1}^1 f(x)g(x) \frac{dx}{\sqrt{1-x^2}}$$



正交系统中的最小二乘法：傅里叶级数

给定函数 f 和一组基函数 ϕ_i ，能否找到系数 $\{c_i\}$ 使得

$$f(x) \approx \sum_i c_i \phi_i(x)$$

设 $\phi_0 = \frac{1}{2}$,

$$\phi_k(x) = \cos(kx), k = 1, 2, \dots, n,$$

$$\phi_{n+k}(x) = \sin(kx), k = 1, 2, \dots, n - 1$$

则函数族 $\phi_0(x), \phi_1(x), \dots$ 在 $[-\pi, \pi]$ 上是正交的

证明： $\cos(kx)$ 和 $\sin(kx)$ 在 $[-\pi, \pi]$ 上的积分都为0，再由积化和差公式即可得：

$$\begin{aligned} \sin(y) \cos(x) &= \frac{1}{2} (\sin(y-x) + \sin(y+x)) \\ \cos(y) \cos(x) &= \frac{1}{2} (\cos(y-x) + \cos(y+x)) \\ \sin(y) \sin(x) &= \frac{1}{2} (\cos(y-x) - \cos(y+x)) \end{aligned}$$



正交系统中的最小二乘法：傅里叶级数（选讲）

给定函数 f ，能否找到系数 $\{a_i, b_i\}$ 使得

$$f(x) \approx \frac{a_0}{2} + a_n \cos nx + \sum_{k=1}^{n-1} (a_k \cos kx + b_k \sin kx)$$

这里也可以使用最小二乘法（sketch）：

- 记误差函数为

$$E(x) := f(x) - \left(\frac{a_0}{2} + a_n \cos nx + \sum_{k=1}^{n-1} (a_k \cos kx + b_k \sin kx) \right)$$

- 考虑 $\|E(x)\|_2^2 = \langle E(x), E(x) \rangle = \int_{-\pi}^{\pi} E(x)^2 dx$
- 对 $\|E(x)\|_2^2$ 关于系数 $\{a_i, b_i\}$ 求偏导并设为0，即得到法线方程
- 由于正交性，可推导出

$$a_k = \frac{\langle f, \cos kx \rangle}{\langle \cos kx, \cos kx \rangle}$$
$$b_k = \frac{\langle f, \sin kx \rangle}{\langle \sin kx, \sin kx \rangle}$$