

线性方程组的迭代法

李小舟

xiaozhouli@uestc.edu.cn

<http://xiaozhouli.com>

对称正定矩阵

定义 如果 $A^T = A$ ，则 $n \times n$ 矩阵 A 是对称矩阵。如果对于所有向量 $x \neq 0$ ， $x^T A x > 0$ ，则矩阵 A 是正定矩阵。

推论： $n \times n$ 矩阵 A 是对称矩阵，则 A 是正定矩阵，当且仅当所有特征值是正数。

推论： A 是正定矩阵，当且仅当 A 的各阶主子式均为正

对称正定矩阵的方法

- Cholesky分解
- 最速下降法
- 共轭梯度法

Cholesky分解

定理 如果 A 是 $n \times n$ 对称正定矩阵。则存在下三角矩阵 $\tilde{L}$ 满足 $A = \tilde{L}\tilde{L}^T$ 。

证：

回顾知识

n 维向量空间 $\mathbb{R}^n$ 中内积的概念

$$(x, y) = x^T y, \quad x, y \in \mathbb{R}^n$$

- $(x, y) = (y, x)$
- $(ax + by, z) = a(x, z) + b(y, z), \quad a, b \in \mathbb{R}$
- $x \neq 0 \Leftrightarrow (x, x) > 0$

若 $(x, y) = 0$ ，则称向量 x 和 y 为正交的。

内积空间的推广

定义 令 A 是 $n \times n$ 对称正定矩阵, 对于两个是 n 维向量 x 和 y , 定义 A 内积

$$(x, y)_A = x^T A y, \quad x, y \in \mathbb{R}^n$$

- $(x, y)_A = (y, x)_A$
- $(ax + by, z)_A = a(x, z)_A + b(y, z)_A, \quad a, b \in \mathbb{R}$
- $x \neq 0 \Leftrightarrow (x, x)_A > 0$

若 $(x, y)_A = 0$, 则称向量 x 和 y 为 A 共轭的。

内积空间的推广

定义 令 A 是 $n \times n$ 对称正定矩阵, 对于两个是 n 维向量 x 和 y , 定义 A 内积

$$(x, y)_A = x^T A y, \quad x, y \in \mathbb{R}^n$$

- $(x, y)_A = (y, x)_A$
- $(ax + by, z)_A = a(x, z)_A + b(y, z)_A, \quad a, b \in \mathbb{R}$
- $x \neq 0 \Leftrightarrow (x, x)_A > 0$

若 $(x, y)_A = 0$, 则称向量 x 和 y 为 A 共轭的。

初等变分原理

定理4.10 令 A 是 $n \times n$ 的实对称正定矩阵,
 $x, b \in \mathbb{R}^n$, 则 x 是二次函数

$$f(x) = \frac{1}{2}x^T A x - b^T x$$

的极小值点 $\iff x$ 是线性方程组 $Ax = b$ 的解。

证:

另外一种迭代思想

不动点迭代：通过迭代计算 $x^{(k+1)} = \varphi(x^{(k)})$,
产生序列满足 $\lim_{k \rightarrow \infty} x^{(k)} = \varphi(x^*) = x^*$

产生序列 $x^{(0)}, x^{(1)}, \dots$ 使得 $\lim_{k \rightarrow \infty} f(x^{(k)}) = f(x^*)$

最速下降的思想

在 x 处, 梯度方向 $\nabla f(x)$ 是增长最快方向 $\implies$ 负梯度方向是 $f(x)$ 下降最快方向

- 从初值点 x 出发, 以负梯度方向 r 为搜索方向, 即 $r = -\nabla f(x) = b - Ax$
- 搜索步长 t , 选择 t 使得 $\min_{t \in \mathbb{R}} f(x + tr)$, 即
$$t = (r, r)/(Ar, r)$$

最速下降法 (Gradient Descent)

最速下降方向 + 最优步长 = 最优算法?

- 最速下降法思想简单, 但是收敛速度慢。本质上是因为负梯度方向函数下降快是局部性质。

共轭梯度法

(Conjugate Gradient)

共轭梯度的思想

全局概念：

- n 维空间的任意向量可以由 n 个线性无关的向量线性表示。
- 构造一组两两共轭的方向（即一组线性无关向量）。共轭方向可以由上次搜索方向和当前的梯度方法之组合来产生。

共轭梯度法

Conjugate Gradient Method

```
 $x_0 = \text{initial guess}$   
 $d_0 = r_0 = b - Ax_0$   
for  $k = 0, 1, 2, \dots, n - 1$   
    if  $r_k = 0$ , stop, end  
     $\alpha_k = \frac{r_k^T r_k}{d_k^T A d_k}$   
     $x_{k+1} = x_k + \alpha_k d_k$   
     $r_{k+1} = r_k - \alpha_k A d_k$   
     $\beta_k = \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k}$   
     $d_{k+1} = r_{k+1} + \beta_k d_k$   
end
```

共轭梯度法的思想

- x_k 新的近似解, d_k 新的搜索方向
- r_k ? $r_0 = b - Ax_0 \Rightarrow Ax_0 + r_0 = b$

$$\begin{aligned} Ax_{k+1} + r_{k+1} &= A(x_k + \alpha_k d_k) + r_k - \alpha_k A d_k \\ &= Ax_k + r_k \end{aligned}$$

- r_k 为近似解 x_k 的余项
- 关键是要让余项 r_k 两两正交

共轭梯度法的思想

- 选择 α_k 使得 r_{k+1} 和 d_k 正交

$$x_{k+1} = x_k + \alpha_k d_k$$

$$b - Ax_{k+1} = b - A(x_k + \alpha_k d_k)$$

$$r_{k+1} = r_k - \alpha_k A d_k$$

$$0 = d_k^T r_{k+1} = d_k^T r_k - \alpha_k d_k^T A d_k$$

$$\Rightarrow \alpha_k = \frac{d_k^T r_k}{d_k^T A d_k}, \quad \text{且 } r_k^T (d_k - r_k) = r_k^T \beta_{k-1} d_{k-1} = 0$$

共轭梯度法的思想

- 选择 β_k 使得 d_k 两两 A 共轭

$$d_{k+1} = r_{k+1} + \beta_k d_k$$

$$0 = d_k^T A d_{k+1} = d_k^T A r_{k+1} + \beta_k d_k^T A d_k$$

$$\Rightarrow \beta_k = -\frac{d_k^T A r_{k+1}}{d_k^T A d_k}, \quad \text{且}$$

$$r_{k+1}^T r_{k+1} = r_{k+1}^T r_k - \alpha_k r_{k+1}^T A d_k = -\frac{r_k^T r_k}{d_k^T A d_k} r_{k+1}^T A d_k$$

定理 如果 A 是 $n \times n$ 对称正定矩阵, $b \neq 0$ 是一个向量, 在共轭梯度法中, 假设 $r_k \neq 0$, 其中 $k < n$ 。则对于每个 $1 \leq k \leq n$,

- 下面三个子空间等价

$$\{x_1, \dots, x_k\} = \{r_0, \dots, r_{k-1}\} = \{d_0, \dots, d_{k-1}\}$$

- 余项 r_k 两两正交 $r_k^T r_j = 0, j < k$

- 方向 d_k 两两 A 共轭 $d_k^T A d_j = 0, j < k$

共轭梯度法

- 严格来说，共轭梯度法是一个直接法，最多 n 步就能得到方程的解
- 也可以作为迭代法， $b - Ax_k = r_k$ 逐渐减小
- 作为直接法不如高斯消元法
- 作为迭代法，若 A 是稀疏矩阵，

小结：求解线性方程组

- 中小规模矩阵：直接法
- 大规模稀疏矩阵：
 - 非对称正定矩阵
 - SOR, GMRES
 - 对称正定矩阵
 - SOR, CG, PCG
- 其他方法：多重网格等

谢谢！