

# 第四讲 线性方程组迭代方法

 目录

4.1 定常迭代法

4.2 收敛性分析

4.3 经典迭代法的收敛性

**4.4 共轭梯度法**

<https://math.ecnu.edu.cn/~jypan/Teaching/NA>

# 4-4 | 共轭梯度法

## 4.4 共轭梯度法

4.4.1 最速下降法

4.4.2 共轭梯度法

<https://math.ecnu.edu.cn/~jypan/Teaching/NA>

(预处理) 共轭梯度法是当前求解 **大规模 (稀疏) 对称正定** 方程组的首选方法

# 线性方程组与二次规划问题

**定理** 设  $A \in \mathbb{R}^{n \times n}$  对称正定, 则  $x_*$  是  $Ax = b$  的解当且仅当  $x_*$  是最小化问题

$$\min_{x \in \mathbb{R}^n} \Phi(x) \triangleq \frac{1}{2} x^\top A x - b^\top x$$

的解, 即  $\Phi(x)$  的最小值点.

(板书)

求解  $Ax = b \iff$  计算  $\Phi(x)$  的最小值点

# 求解最小化问题的线搜索方法

## 线搜索方法

求解最小化问题  $\min_{x \in \mathbb{R}^n} \Phi(x)$  的一类常用方法是 **线搜索方法**:

给定初始值  $x^{(0)}$ , 确定一个使得  $\Phi(x)$  变小的方向  $p_1 \in \mathbb{R}^n$ , 即 **下降方向**, 满足  $\|p_1\| = 1$ , 然后计算步长  $\alpha_1 \in \mathbb{R}_+$ , 使得  $\Phi(x)$  沿该下降方向达到最小, 即


$$x^{(1)} = x^{(0)} + \alpha_1 p_1, \quad \text{其中} \quad \alpha_1 = \operatorname{argmin}_{\alpha > 0} \Phi(x^{(0)} + \alpha p_1).$$

# 怎么计算步长

由于  $A$  对称正定, 直接计算可得

$$\begin{aligned}\Phi(x^{(0)} + \alpha p_1) &= \frac{1}{2}(x^{(0)} + \alpha p_1)^\top A(x^{(0)} + \alpha p_1) - b^\top(x^{(0)} + \alpha p_1) \\ &= \frac{1}{2}\alpha^2 p_1^\top A p_1 + \alpha p_1^\top A x^{(0)} + \frac{1}{2}(x^{(0)})^\top A x^{(0)} - b^\top x^{(0)} - \alpha b^\top p_1 \\ &= \frac{1}{2}\alpha^2 p_1^\top A p_1 - \alpha p_1^\top r_0 + \Phi(x^{(0)}),\end{aligned}$$

其中  $r_0 = b - Ax^{(0)}$ .

 这是关于  $\alpha$  的一元二次函数, 且二次项系数为正, 所以

$$\alpha_1 = \operatorname{argmin}_{\alpha > 0} \Phi(x^{(0)} + \alpha p_1) = \frac{p_1^\top r_0}{p_1^\top A p_1}.$$


# 4-4-1 | 最速下降法

根据多元函数的 Taylor 展开公式, 我们有

$$\Phi(x) = \Phi(x^{(0)}) + (x - x^{(0)})^T \nabla \Phi(x^{(0)}) + o(\|x - x^{(0)}\|).$$

记  $p$  为  $x - x^{(0)}$  所在的方向, 即  $p = \frac{x - x^{(0)}}{\|x - x^{(0)}\|}$ , 则

$$(x - x^{(0)})^T \nabla \Phi(x^{(0)}) = \|x - x^{(0)}\| \cdot p^T \nabla \Phi(x^{(0)}).$$

 因此, 只要满足  $p^T \nabla \Phi(x^{(0)}) < 0$ , 则  $p$  就是 **下降方向**.

# 最速下降法

## 最速下降方向与最速下降法

下降速度最快的方向  $\rightarrow p^T \nabla \Phi(x^{(0)})$  最小.

 由 Cauchy-Schwarz 不等式可知

$$|p^T \nabla \Phi(x^{(0)})| \leq \|p\| \cdot \|\nabla \Phi(x^{(0)})\|,$$

等号当且仅当  $p$  与  $\nabla \Phi(x^{(0)})$  共线时成立.

因此当  $p = -\frac{\nabla \Phi(x^{(0)})}{\|\nabla \Phi(x^{(0)})\|}$  时,  $p^T \nabla \Phi(x^{(0)})$  达到最小.

我们称该下降方向为**最速下降方向**, 相应的线搜索方法为**最速下降法**.

由于最速下降方向就是  $\Phi(x)$  在当前迭代点处的负梯度方向, 因此也称为**负梯度方向法**.

注: 讲义中  $p = -\frac{\nabla \Phi(x^{(0)})}{\nabla \Phi(x^{(0)})}$ , 分母漏写了范数.

# 最速下降法的迭代格式



最速下降法的一般格式可表示为

$$x^{(k)} = x^{(k-1)} + \alpha_k p_k, \quad k = 1, 2, \dots,$$

$$\text{其中 } p_k = -\nabla\Phi(x^{(k-1)}) = b - Ax^{(k-1)} = r_{k-1}, \quad \alpha_k = \frac{p_k^\top r_{k-1}}{p_k^\top A p_k} = \frac{r_{k-1}^\top r_{k-1}}{r_{k-1}^\top A r_{k-1}}$$

实际计算时, 我们无需对下降方向  $p_k$  进行单位化

## 算法 最速下降法 (Steepest Descent Algorithm)

- 1: 给定初值  $x^{(0)}$ , 令  $k = 1$
- 2: **while** not converge **do**
- 3:     计算负梯度方向 (残量)  $r_{k-1} = b - Ax^{(k-1)}$  和步长  $\alpha_k = (r_{k-1}^\top r_{k-1}) / (r_{k-1}^\top A r_{k-1})$
- 4:     计算  $x^{(k)} = x^{(k-1)} + \alpha_k p_k$ , 其中  $p_k = r_{k-1}$
- 5:     令  $k = k + 1$
- 6: **end while**



# 最速下降法的收敛性

**定理** 设  $A \in \mathbb{R}^{n \times n}$  对称正定, 则对任意初值  $x^{(0)}$ , 最速下降法都收敛, 且

$$\frac{\|x^{(k+1)} - x_*\|_A}{\|x^{(k)} - x_*\|_A} \leq \frac{\kappa - 1}{\kappa + 1},$$

其中  $\kappa$  为  $A$  的谱条件数, 范数  $\|x\|_A \triangleq \sqrt{x^T A x}$ .

(留作课外自习, 可以参见矩阵计算或最优化方法的相关教材)

# 最速下降法举例

例 用最速下降法求解  $Ax = b$ , 其中  $A = \begin{bmatrix} 15 & 2 \\ 2 & 15 \end{bmatrix}$ ,  $b = \begin{bmatrix} 17 \\ 17 \end{bmatrix}$ , 初值  $x^{(0)} = \begin{bmatrix} -0.5 \\ 0 \end{bmatrix}$ .


$k$	$x$	relres
1	[0.94896898, 1.06454864]	3.54e-02
2	[0.99757851, 0.99838567]	1.61e-03
3	[0.99991762, 1.00010420]	5.71e-05
4	[0.99999609, 0.99999739]	2.61e-06
5	[0.99999987, 1.00000017]	9.21e-08

“relres” 表示相对残量

$$\text{relres} = \frac{\|b - Ax^{(k)}\|_2}{\|b - Ax^{(0)}\|_2}$$

(Iter\_steepest\_descent\_01.m)

# 最速下降法的局部最优性

 由步长的选取方法可知, 最速下降法的迭代解具有下面的最优性

$$x^{(k)} = \operatorname{argmin}_{x \in x^{(k-1)} + \operatorname{span}\{p_k\}} \Phi(x)$$

由于舍弃了 Taylor 展开式中的高阶项, 因此最速下降方向是局部最优的

# 4-4-2

## 共轭梯度法

### 最速下降法的不足


最速下降法每次选取下降方向时只考虑局部最优, 无法保证下降方向  $p_1, p_2, \dots$  线性无关, 这意味着迭代过程可能会出现“之”字型, 即同一个下降方向可能会多次出现, 这就会导致收敛速度变得非常缓慢.

# 最速下降法的不足

例 用最速下降法求解  $Ax = b$ , 其中  $A = \begin{bmatrix} 2 & 1 \\ 1 & 3 \end{bmatrix}$ ,  $b = \begin{bmatrix} 3 \\ 4 \end{bmatrix}$ , 初值  $x^{(0)} = \begin{bmatrix} -3 \\ 0.5 \end{bmatrix}$ .

$k$	$x$	relres
1	$[-0.3498, 2.2148]$	$2.70\text{e-}01$
2	$[0.4784, 0.9348]$	$1.30\text{e-}01$
3	$[0.8240, 1.1584]$	$3.52\text{e-}02$
4	$[0.9320, 0.9915]$	$1.70\text{e-}02$
$\vdots$	$\vdots$	$\vdots$
14	$[1.0000, 1.0000]$	$6.41\text{e-}07$

(Iter\_steepest\_descent\_02.m)



# A-共轭

为了改善最速下降法的收敛性质, 需要对下降方向进行改进, 由此, **共轭方向法**应运而生.

**定义** 设  $A \in \mathbb{R}^{n \times n}$  对称正定, 若非零向量  $x, y \in \mathbb{R}^n$  满足

$$y^T Ax = 0,$$

则称  $x$  和  $y$  是 **A-共轭**的, 也称 **A-正交**的.

# 为什么 $A$ -共轭

## 为什么选取 $A$ -共轭的向量作为下降方向

设  $p_1, p_2, \dots, p_n$  相互  $A$ -共轭, 则  $p_1, p_2, \dots, p_n$  线性无关, 因此构成  $\mathbb{R}^n$  的一组基.  
对任意给定的初值  $x^{(0)}$ , 我们可以设

$$x_* - x^{(0)} = \alpha_1 p_1 + \alpha_2 p_2 + \cdots + \alpha_n p_n.$$

两边分别左乘  $p_k^\top A$ , 可得

$$\alpha_k = \frac{p_k^\top A(x_* - x^{(0)})}{p_k^\top A p_k} = \frac{p_k^\top (b - A x^{(0)})}{p_k^\top A p_k}, \quad k = 1, 2, \dots, n.$$

这意味着可以通过下降方向  $p_1, p_2, \dots, p_n$  和右端项  $b$ , 以及  $x^{(0)}$  将方程组的解表示出来.



如果采用一组正交基作为下降方向, 也可以得到类似结论, 但  $\alpha_i$  的表达式中包含  $x_*$ .

# 共轭方向法

考虑到算法的实用性, 当  $n$  很大时, 通常不需计算所有的  $\alpha_k$ , 而只要计算前面部分, 得到一个满足精度要求的近似解即可. 因此, 我们把  $x_* = x^{(0)} + \alpha_1 p_1 + \cdots$  看作是一个迭代过程:

$$x^{(k)} = x^{(k-1)} + \alpha_k p_k, \quad k = 1, 2, \dots$$

## 共轭方向法

以相互  $A$ -共轭的向量作为下降方向的线搜索方法就称为 **共轭方向法**.

🔴 改写  $\alpha_k$  的计算公式: 由于  $x^{(k-1)} - x^{(0)} = \alpha_1 p_1 + \alpha_2 p_2 + \cdots + \alpha_{k-1} p_{k-1}$ , 所以  $p_k^\top A(x^{(k-1)} - x^{(0)}) = 0$ , 即  $p_k^\top A x^{(0)} = p_k^\top A x^{(k-1)}$ , 因此

$$\alpha_k = \frac{p_k^\top (b - A x^{(0)})}{p_k^\top A p_k} = \frac{p_k^\top (b - A x^{(k-1)})}{p_k^\top A p_k} = \frac{p_k^\top r_{k-1}}{p_k^\top A p_k}.$$



# 共轭方向法的全局最优性



相比于最速下降法的局部最优性:

$$x^{(k)} = \operatorname{argmin}_{x \in x^{(k-1)} + \operatorname{span}\{p_k\}} \Phi(x),$$

共轭方向法具有全局最优性.

**定理** 设  $x^{(k)}$  是由共轭方向法得到的迭代解, 则

$$x^{(k)} = \operatorname{argmin}_{x \in x^{(0)} + \operatorname{span}\{p_1, p_2, \dots, p_k\}} \Phi(x).$$

(留作课外自习, 可以参见最优化方法的相关教材)

共轭方向法有限步终止性质: 若不考虑舍入误差, 则至多  $n$  次迭代后,  $x^{(k)}$  就是精确解.

# 共轭方向的构造方法

## 如何构造相互 $A$ -共轭的下降方向

- ▶ 首先需要指出的是, 这样的向量组并不唯一.

事实上, 与 Gram-Schmidt 正交化过程类似, 任何一组线性无关的向量组都可以构造出一组相互  $A$ -共轭的向量组.

- ▶ 目前最成功的是共轭梯度 (Conjugate Gradient) 下降方向.

它是在最速下降方向的基础上, 通过递推方法来构造的, 可以看作是将最速下降方向进行  $A$ -共轭化, 或者是对最速下降方向的改进.

# 共轭梯度下降方向的构造

① 给定  $x^{(0)}$ , 取  $\Phi(x)$  在  $x^{(0)}$  处的负梯度方向:

$$p_1 = -\nabla\Phi(x^{(0)}) = r_0 = b - Ax^{(0)}$$

② 以  $p_1$  为下降方向, 计算近似解  $x^{(1)}$ :

$$x^{(1)} = x^{(0)} + \alpha_1 p_1, \text{ 其中 } \alpha_1 = \frac{p_1^\top r_0}{p_1^\top A p_1}$$

③ 计算  $\Phi(x)$  在  $x^{(1)}$  处的负梯度方向:  $-\nabla\Phi(x^{(1)}) = r_1 = b - Ax^{(1)} = r_0 - \alpha_1 A p_1$ ,

将其与  $p_1$  进行  $A$ -共轭化, 得到下降方向  $p_2$ :

$$p_2 = r_1 + \beta_1 p_1, \text{ 其中 } \beta_1 = -\frac{r_1^\top A p_1}{p_1^\top A p_1}$$

▶ 以此类推, 我们就可以得到相互  $A$ -共轭的下降方向  $p_1, p_2, \dots, p_k, \dots$

该过程同时也把近似解  $x^{(k)}$  和残量  $r_k$  计算出来了.

# 简化运算

在计算  $p_{k+1}$  时, 需要将  $r_k$  与所有  $p_1, p_2, \dots, p_k$  进行  $A$ -共轭化, 计算量较大. 事实上, 由于  $A$  对称正定, 我们只需将  $r_k$  与  $p_k$  进行  $A$ -共轭化即可, 即

$$p_{k+1} = r_k + \beta_k p_k, \quad \text{其中} \quad \beta_k = -\frac{r_k^\top A p_k}{p_k^\top A p_k}.$$

这样不仅可以简化计算, 同时可以证明  $p_{k+1}$  与  $p_1, p_2, \dots, p_{k-1}$  都  $A$ -共轭.

**定理** 设  $A \in \mathbb{R}^{n \times n}$  对称正定, 共轭梯度法迭代  $m$  步后 ( $m < n$ ), 对任意  $k$  ( $k \leq m$ ) 有

- (1)  $r_k^\top r_i = 0, \quad i = 0, 1, 2, \dots, k-1;$
- (2)  $r_k^\top p_i = 0, \quad i = 1, 2, \dots, k;$
- (3)  $p_{k+1}^\top A p_i = 0, \quad i = 1, 2, \dots, k;$
- (4)  $\text{span}\{r_0, r_1, \dots, r_k\} = \text{span}\{p_1, p_2, \dots, p_{k+1}\} = \text{span}\{r_0, A r_0, \dots, A^k r_0\}.$

(留作课外自习, 可以参见矩阵计算或最优化方法的相关教材)

# 共轭梯度法迭代格式

于是共轭梯度法可描述为

$$\begin{cases} x^{(k)} = x^{(k-1)} + \alpha_k p_k, & \text{其中 } \alpha_k = \frac{p_k^\top r_{k-1}}{p_k^\top A p_k}, \\ r_k = b - A x^{(k)} = r_{k-1} - \alpha_k A p_k, \\ p_{k+1} = r_k + \beta_k p_k, & \text{其中 } \beta_k = -\frac{r_k^\top A p_k}{p_k^\top A p_k}, \end{cases}$$

$k = 1, 2, \dots,$

 进一步简化计算: 利用  $r_k$  的正交性和  $p_k$  的  $A$ -共轭性, 可得

**推论** 共轭梯度法中的  $\alpha_k$  和  $\beta_k$  可以通过下面的公式计算

$$\alpha_k = \frac{r_{k-1}^\top r_{k-1}}{p_k^\top A p_k}, \quad \beta_k = \frac{r_k^\top r_k}{r_{k-1}^\top r_{k-1}}.$$

# 共轭梯度法的算法描述

---

## 算法 共轭梯度法 (Conjugate Gradient Algorithm)

---

- 1: 给定初值  $x^{(0)}$
  - 2: 计算  $r_0 = b - Ax^{(0)}$ , 并令  $p_1 = r_0, k = 1$
  - 3: **while** not converge **do**
  - 4:     计算  $x^{(k)} = x^{(k-1)} + \alpha_k p_k$ , 其中  $\alpha_k = \frac{r_{k-1}^\top r_{k-1}}{p_k^\top A p_k}$
  - 5:     计算  $r_k = r_{k-1} - \alpha_k A p_k$
  - 6:     计算  $p_{k+1} = r_k + \beta_k p_k$ , 其中  $\beta_k = \frac{r_k^\top r_k}{r_{k-1}^\top r_{k-1}}$
  - 7: **end while**
-


# 共轭梯度法的收敛性

**定理** 设  $A \in \mathbb{R}^{n \times n}$  对称正定, 则对任意初值  $x^{(0)}$ , 共轭梯度法都收敛, 且

$$\frac{\|x^{(k)} - x_*\|_A}{\|x^{(0)} - x_*\|_A} \leq 2 \left( \frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^k,$$

其中  $\kappa$  为  $A$  的谱条件数, 范数  $\|x\|_A \triangleq \sqrt{x^T A x}$ .

(留作课外自习, 可以参见矩阵计算的相关教材)


 由此可知, 共轭梯度法每次迭代的误差下降率为  $\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1}$ .

# 共轭梯度法举例（一）

例 用共轭梯度法求解  $Ax = b$ , 其中  $A = \begin{bmatrix} 2 & 1 \\ 1 & 3 \end{bmatrix}$ ,  $b = \begin{bmatrix} 3 \\ 4 \end{bmatrix}$ , 初值  $x^{(0)} = \begin{bmatrix} -3 \\ 0.5 \end{bmatrix}$ .

$k$	$x$	relres
1	$[-0.3498, 2.2148]$	2.70e-01
2	$[1.0000, 1.0000]$	4.39e-17

(Iter\_CG\_01.m)


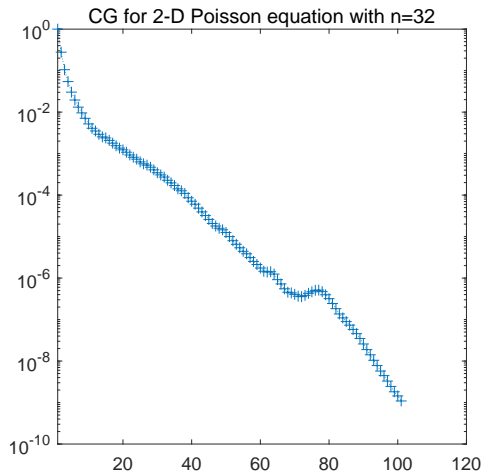




# 共轭梯度法举例（二）

例 用共轭梯度法求解离散二维 Poisson 方程.

(Iter\_CG\_gallery.m), (Iter\_CG\_Jacobi\_GS\_SOR\_Poisson2D.m)



谢谢  
THANK YOU

