



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



回顾与补充

- **Richardson iteration**

- 两个视角：矩阵多项式、梯度最速下降
- 思考：如果换作其它范数下面的最速下降？
- 收敛性：当且仅当 $\rho(I - \alpha A) = \max\{|1 - \alpha\lambda_1|, |1 - \alpha\lambda_n|\} < 1$
- 记 $x_k = p_k(A)b \in \text{span}\{b, Ab, A^2b, \dots, A^{k-1}b\}$ ；Krylov子空间
- $x_* - x_k = (I - p_k(A)A)x_* = q_k(A)x_*$
- 收敛所需迭代次数正比于条件数 $\frac{\lambda_n}{\lambda_1}$

- **Conjugate gradients**（共轭梯度方法）

- 记Krylov子空间 $K_0 = \{0\}, K_i = \text{span}\{b, Ab, \dots, A^{i-1}b\}$
- $x_i = \arg \min_{x \in K_i} \|x - x_*\|_A^2$ ，其中 x_* 满足 $Ax_* = b$
- **CG**的收敛所需迭代次数正比于 $\sqrt{\frac{\lambda_n}{\lambda_1}}$ ，依然取决于条件数
- 精确数值：最多迭代 $n+1$ 次；有限精度：也需要选择合适的停止条件

- 对稀疏矩阵，或者有好的初始猜测时，迭代比高斯消元更加适合



预条件(Preconditioning)

要解 $Ax = b$, 选取矩阵 M , 改为解 $M^{-1}Ax = M^{-1}b$

$$\text{cond}(M^{-1}A) \neq \text{cond}(A)$$

注意: **Richardson iteration**和**CG**都需要正定矩阵
 $M^{-1}A$ 可能不再是正定的, 甚至可能不是对称的

假设 M 是对称正定, 则有**Cholesky**分解: $M = EE^T$, 并且
 $\text{cond}(M^{-1}A) = \text{cond}(E^{-1}AE^{-T})$



预条件(Preconditioning)

假设 M 是对称正定，则有Cholesky分解： $M = EE^T$ ，并且

$$\text{cond}(M^{-1}A) = \text{cond}(E^{-1}AE^{-T})$$

证明： $E^{-1}AE^{-T}$ 是对称正定的，有完整的特征基，因此只需要证明 $M^{-1}A$ 和 $E^{-1}AE^{-T}$ 有着一样的特征值即可。任取 $E^{-1}AE^{-T}$ 的特征向量和特征值

$$\begin{aligned} E^{-1}AE^{-T}v &= \lambda v \Rightarrow E^{-T}E^{-1}AE^{-T}v = \lambda E^{-T}v \Rightarrow M^{-1}Ay \\ &= \lambda y \end{aligned}$$

因为它们的奇异值一样，它们的条件数也是一样的

因此，可以先解 $E^{-1}AE^{-T}y = E^{-1}b$ ，这是对称正定的系统
然后解得 $x = E^{-T}y$



计算特征值与特征向量

最小化 $f(x) = x^T A x$, subject to $x^T x = 1$

$\det(xI - A)$: 关于 x 的多项式

- n 个根, A 的特征值
- 可能不稳定: 多项式 $(x - 1)(x - 2) \dots (x - 20)$
- 注: $\det(\lambda I - A)$ 非常接近 0 并不意味着 λ 是一个近似特征值
- 牛顿法求根: 需要导数
- 截弦法求根: 也需要计算 $\det(xI - A)$

迭代法?

- 解 $Ax = b$: 写出不动点方程, 使用不动点迭代
- 解 $Ax = \lambda x$: 同时有两个变量: λ 和 x



对特征值的估计

Gershgorin circle theorem

- 令 A 为 $n \times n$ 矩阵, $R_i := \sum_{j \neq i} |a_{ij}|$
- 则 A 的所有特征值都在复平面上的某个圆盘 $D(a_{ii}, R_i)$ 之中

证明: 任取 A 的一个特征值 λ 对应特征向量 v , 设 i 使得 v_i 为 v 中绝对值最大的元素。

由 $Av = \lambda v \Rightarrow \sum_j a_{ij} v_j = \lambda v_i \Rightarrow \sum_{j \neq i} a_{ij} v_j = (\lambda - a_{ii}) v_i$
因此

$$|(\lambda - a_{ii})| = \left| \sum_{j \neq i} \frac{a_{ij} v_j}{v_i} \right| \leq \sum_{j \neq i} \left| \frac{a_{ij} v_j}{v_i} \right| \leq \sum_{j \neq i} |a_{ij}| = R_i$$



幂迭代 Power method

考虑可对角化的方阵 A . 假设 A 有 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 满足 $|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n|$. 记它们对应的特征向量为 v_1, v_2, \dots, v_n . 假设它们是线性无关的。

- λ_1 被称为占优特征值 (dominating eigenvalue)
- v_1 : 占优特征向量

考虑任意向量 $x \in R^n$, 由于 v_1, v_2, \dots, v_n 是线性无关的, 所以可以展开

$$\begin{aligned}x &= \alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_n v_n \\Ax &= \lambda_1 \alpha_1 v_1 + \lambda_2 \alpha_2 v_2 + \dots + \lambda_n \alpha_n v_n \\A^2 x &= \lambda_1^2 \alpha_1 v_1 + \lambda_2^2 \alpha_2 v_2 + \dots + \lambda_n^2 \alpha_n v_n \\A^3 x &= \lambda_1^3 \alpha_1 v_1 + \lambda_2^3 \alpha_2 v_2 + \dots + \lambda_n^3 \alpha_n v_n \\&\vdots \\A^k x &= \lambda_1^k \alpha_1 v_1 + \lambda_2^k \alpha_2 v_2 + \dots + \lambda_n^k \alpha_n v_n \\&= \lambda_1^k \left(\alpha_1 v_1 + \frac{\lambda_2^k}{\lambda_1^k} \alpha_2 v_2 + \dots + \frac{\lambda_n^k}{\lambda_1^k} \alpha_n v_n \right)\end{aligned}$$

随着 $k \rightarrow \infty, A^k x \rightarrow \lambda_1^k \alpha_1 v_1$, 如果 $\alpha_1 \neq 0$



幂迭代 Power method

$$\begin{aligned} A^k x &= \lambda_1^k \alpha_1 v_1 + \lambda_2^k \alpha_2 v_2 + \cdots + \lambda_n^k \alpha_n v_n \\ &= \lambda_1^k \left(\alpha_1 v_1 + \frac{\lambda_2^k}{\lambda_1^k} \alpha_2 v_2 + \cdots + \frac{\lambda_n^k}{\lambda_1^k} \alpha_n v_n \right) \end{aligned}$$

随着 $k \rightarrow \infty$, $A^k x \rightarrow \lambda_1^k \alpha_1 v_1$, 如果 $\alpha_1 \neq 0$

收敛速度: $|\lambda_2|/|\lambda_1|$

可能导致浮点数上溢或下溢: 如果 $|\lambda_1| > 1$, $A^k x \rightarrow \infty$; 如果 $|\lambda_1| < 1$, $A^k x \rightarrow 0$

解决办法: 每次迭代都进行归一化

$$\begin{aligned} w_{k+1} &= A x_k, \\ x_{k+1} &= \frac{w_{k+1}}{\|w_{k+1}\|}. \end{aligned}$$

思考: 归一化可以使用什么样的范数? 为什么不除上 λ_1^k 进行归一化?



Power method

$$\begin{aligned} A^k x &= \lambda_1^k \alpha_1 v_1 + \lambda_2^k \alpha_2 v_2 + \cdots + \lambda_n^k \alpha_n v_n \\ &= \lambda_1^k \left(\alpha_1 v_1 + \frac{\lambda_2^k}{\lambda_1^k} \alpha_2 v_2 + \cdots + \frac{\lambda_n^k}{\lambda_1^k} \alpha_n v_n \right) \end{aligned}$$

随着 $k \rightarrow \infty$, $A^k x \rightarrow \lambda_1^k \alpha_1 v_1$

随着幂迭代的进行, 得到了一个近似的特征向量方向之后, 如何求解近似的特征值?

即, 给定 A 和近似特征向量 x , 求 λ 使得 $Ax \approx \lambda x$

最小二乘法: 求 λ 以最小化 $\|Ax - \lambda x\|_2^2$

$$\|Ax - \lambda x\|_2^2 = \|Ax\|_2^2 + \lambda^2 \|x\|_2^2 - 2\lambda x^T Ax$$

法线方程 $\lambda = x^T Ax / x^T x$, Rayleigh quotient!

练习: 使用扰动方法, 从 $\|Ax - (\lambda + \delta\lambda)x\|_2^2 \geq \|Ax - \lambda x\|_2^2, \forall \delta\lambda \in \mathbf{R}$ 推导



Power method

最小二乘法：求 λ 以最小化 $\|Ax - \lambda x\|_2^2$

$$\|Ax - \lambda x\|_2^2 = \|Ax\|_2^2 + \lambda^2 \|x\|_2^2 - 2\lambda x^T Ax$$

法线方程 $\lambda = x^T Ax / x^T x$, Rayleigh quotient!

定理：对于实数对称矩阵 A ，假设近似特征向量 x 满足 $\|x\|_2 = 1$ ，并且实数 λ 满足 $\|Ax - \lambda x\|_2 < \epsilon$ ，则有 $\min_{1 \leq j \leq n} |\lambda_j - \lambda| < \epsilon$

证明：对于实数对称矩阵，可以选择特征向量 v_1, v_2, \dots, v_n 使得它们是正交且归一化的。展开 $x = \alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_n v_n$

$$\begin{aligned} \|Ax - \lambda x\|_2^2 &= \left\| \sum_{j=1}^n \alpha_j (\lambda_j - \lambda) v_j \right\|_2^2 \\ &= \sum_{j=1}^n |\alpha_j|^2 |\lambda_j - \lambda|^2 \|v_j\|_2^2 \\ &= \sum_{j=1}^n |\alpha_j|^2 |\lambda_j - \lambda|^2 \\ &\geq \min_{1 \leq j \leq n} |\lambda_j - \lambda|^2 \sum_{j=1}^n |\alpha_j|^2 \end{aligned}$$

其中 $\sum_{j=1}^n |\alpha_j|^2 = \|x\|_2^2 = 1$ ，所以 $\epsilon > \|Ax - \lambda x\|_2 \geq \min_{1 \leq j \leq n} |\lambda_j - \lambda|$



Inverse Power method

幂迭代告诉我们如何找到 λ_1 与 v_1
其它特征值和特征向量呢？

给定方阵 A . 假设 A 有 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 和线性无关的特征向量为 v_1, v_2, \dots, v_n

A^{-1} 的特征值？

$$\frac{1}{\lambda_1}, \frac{1}{\lambda_2}, \dots, \frac{1}{\lambda_n}$$

特征向量？

$$v_1, v_2, \dots, v_n$$

迭代需要使用到 A^{-1} ？ 只需要解线性方程：LU分解



Inverse Power method

幂迭代告诉我们如何找到 λ_1 与 v_1
其它特征值和特征向量呢?

给定方阵 A . 假设 A 有 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 和线性无关的特征向量为 v_1, v_2, \dots, v_n

$(A - qI)^{-1}$ 的特征值?

$$\frac{1}{\lambda_1 - q}, \frac{1}{\lambda_2 - q}, \dots, \frac{1}{\lambda_n - q}$$

特征向量?

$$v_1, v_2, \dots, v_n$$



Inverse Power method

给定方阵 A . 假设 A 有 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 和线性无关的特征向量为 v_1, v_2, \dots, v_n

$(A - qI)^{-1}$ 的特征值?

$$\frac{1}{\lambda_1 - q}, \frac{1}{\lambda_2 - q}, \dots, \frac{1}{\lambda_n - q}$$

特征向量?

$$v_1, v_2, \dots, v_n$$

如果对 $(A - qI)^{-1}$ 使用幂迭代呢?

$$\text{即 } x_k = (A - qI)^{-1} x_{k-1}$$

注意: 可以通过高斯消元, 先求出矩阵 $B = (A - qI)^{-1}$ 的LU分解, 再进行迭代; 对于迭代次数远远比 n 小的稀疏矩阵, 也可以尝试每一次迭代都解一次线性方程组

$$\text{收敛到 } \frac{1}{\lambda_k - q} = \max_{1 \leq j \leq n} \frac{1}{|\lambda_j - q|}$$

如何选择 q ? 可以结合Rayleigh quotient \Rightarrow Rayleigh quotient iteration



Rayleigh Quotient Iteration

$$\sigma_k = \frac{\mathbf{x}_{k-1}^T A \mathbf{x}_{k-1}}{\mathbf{x}_{k-1}^T \mathbf{x}_{k-1}},$$
$$\mathbf{w}_k = (A - \sigma_k I)^{-1} \mathbf{x}_{k-1},$$
$$\mathbf{x}_k = \frac{\mathbf{w}_k}{\|\mathbf{w}_k\|}$$

注意 $(A - \sigma_k I)$ 不再是固定的

迭代次数更少，但是每一次迭代的计算代价更多



Power method

幂迭代告诉我们如何找到 λ_1 与 v_1
其它特征值和特征向量呢？

$$x = \alpha_1 v_1 + \alpha_2 v_2 + \cdots + \alpha_n v_n$$

如果 $\alpha_1 \neq 0$ ，随着 $k \rightarrow \infty$, $A^k x \rightarrow \lambda_1^k \alpha_1 v_1$

如果 $\alpha_1 = 0$ 呢？

• 如果 $\alpha_2 \neq 0$ ，随着 $k \rightarrow \infty$, $A^k x \rightarrow \lambda_2^k \alpha_2 v_2$

• 如果 $\alpha_2 = 0, \alpha_3 \neq 0$ ，随着 $k \rightarrow \infty$, $A^k x \rightarrow \lambda_3^k \alpha_3 v_3$



Power method

幂迭代告诉我们如何找到 λ_1 与 v_1
其它特征值和特征向量呢？

如果 $\alpha_1 \neq 0$ ，随着 $k \rightarrow \infty$, $A^k x \rightarrow \lambda_1^k \alpha_1 v_1$

如果 $\alpha_1 = 0$ 呢？

每一次迭代，通过投影确保与已知的特征向量
都是正交的



QR分解与同时迭代

如何同时找出所有的特征值与特征向量？

假设 A 是实数对称矩阵。同时进行幂迭代，并保持向量两两正交。

回忆：正交化，即QR分解

最开始

$$\left[A \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \mid A \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix} \mid \cdots \mid A \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{bmatrix} \right] = \left[\bar{q}_1^1 \mid \cdots \mid \bar{q}_m^1 \right] \begin{bmatrix} r_{11}^1 & r_{12}^1 & \cdots & r_{1m}^1 \\ & r_{22}^1 & & \vdots \\ & & \ddots & \vdots \\ & & & r_{mm}^1 \end{bmatrix}$$

$$\begin{aligned} A\bar{Q}_1 &= \left[A\bar{q}_1^1 \mid A\bar{q}_2^1 \mid \cdots \mid A\bar{q}_m^1 \right] \\ &= \left[\bar{q}_1^2 \mid \bar{q}_2^2 \mid \cdots \mid \bar{q}_m^2 \right] \begin{bmatrix} r_{11}^2 & r_{12}^2 & \cdots & r_{1m}^2 \\ & r_{22}^2 & & \vdots \\ & & \ddots & \vdots \\ & & & r_{mm}^2 \end{bmatrix} \\ &= \bar{Q}_2 R_2. \end{aligned}$$



QR分解与同时迭代

如何同时找出所有的特征值与特征向量？

假设 A 是实数对称矩阵。同时进行幂迭代，并保持向量两两正交。

$$\begin{aligned} A\bar{Q}_1 &= [A\bar{q}_1 | A\bar{q}_2 | \cdots | A\bar{q}_m] \\ &= [\bar{q}_1^2 | \bar{q}_2^2 | \cdots | \bar{q}_m^2] \begin{bmatrix} r_{11}^2 & r_{12}^2 & \cdots & r_{1m}^2 \\ & r_{22}^2 & & \vdots \\ & & \ddots & \vdots \\ & & & r_{mm}^2 \end{bmatrix} \\ &= \bar{Q}_2 R_2. \end{aligned}$$

算法:

```
Set  $\bar{Q}_0 = I$   
for  $j = 1, 2, 3, \dots$   
     $A\bar{Q}_j = \bar{Q}_{j+1}R_{j+1}$   
end
```



QR分解与同时迭代

对于一般的可对角化矩阵， A 和 $Q^{-1}AQ$ 有相同的特征值

$$A = QR,$$
$$Q^{-1}A Q = RQ$$

QR迭代的等价形式:

- $A_1 = A$
- 分解 $A_k = Q_k R_k$
- $A_{k+1} = R_k Q_k$

如果收敛，则 $A_\infty = Q_\infty R_\infty = R_\infty Q_\infty$



奇异值 (singular values)

对于一般的 $m \times n$ 实数非方阵 A , 可以有奇异值分解

$$A = U S V^T$$

A 的形状: $m \times n$

U 的形状: $m \times m$

S 的形状: $m \times n$

V 的形状: $n \times n$

$$U^T U = I_m, \quad V^T V = I_n$$

观察:

$$A A^T = U S S^T U^T$$

$$A^T A = V S^T S V^T$$

$A A^T$ 和 $A^T A$ 都是实数对称阵, 可做特征值分解!



SVD

定理： AA^T 和 $A^T A$ 有着相同的非零特征值。

证明：考虑 AA^T 的特征值 $\lambda \neq 0$ 和特征向量 v ： $AA^T v = \lambda v$

$$A^T A(A^T v) = A^T (AA^T v) = A^T (\lambda v) = \lambda(A^T v)$$

可见，只要 $A^T v \neq 0$ ，则 $A^T v$ 为 $A^T A$ 的一个特征向量，特征值也是 λ 。不妨假设 $A^T v = 0$ ，则 $AA^T v = A(A^T v) = 0$ ，与 $\lambda \neq 0$ 矛盾。

类似地，考虑 $A^T A$ 的特征值 $\lambda \neq 0$ 和特征向量 v ： $A^T A v = \lambda v$ ，也有 $AA^T(Av) = A(A^T A v) = A(\lambda v) = \lambda(Av)$ 。

同理有 $Av \neq 0$ ，因此 Av 为 AA^T 的一个特征向量，特征值也是 λ 。



Operator norm and Condition number

2 to 2 operator norm of A : $\sigma_{max}(A)$

2-condition number of A : $\frac{\sigma_{max}(A)}{\sigma_{min}(A)}$

Corollary. If matrices A and B have the same non-zero singular values, they also have the same condition number