

高等数值算法与应用(5)

– 特征值与奇异值 (chap10) –

喻文健

Outline

- ▶ 矩阵的特征值与奇异值分解
- ▶ 特征值计算问题的敏感性
- ▶ 奇异值分解的存在性与性质
- ▶ 计算特征值、奇异值的算法
- ▶ 低秩近似与主分量分析
- ▶ 圆生成器



特征值与奇异值分解

- » 特征值相关概念
- 奇异值相关概念
- 例子与Matlab

特征值与奇异值

▶ 方阵A的特征值

$$Ax = \lambda x$$

λ 为特征值(eigenvalue),
非零向量 x 为(右)特征向量(eigenvector)

- 若矩阵表示向量空间到自身的变换, 则特征值很重要
- 特征向量有无穷多. 实对称阵, 一般设 $\|x\|_2 = 1$ 的为**标准**

$$\iff (A - \lambda I)x = 0, \quad x \neq 0$$

- **特征方程**: $\det(\lambda I - A) = \lambda^n - \left(\sum_{j=1}^n a_{jj} \right) \lambda^{n-1} + \dots = 0$ (共轭成对)
- \implies n 阶方阵有 n 个特征值(含重根). 一般, 可能是虚数

$$AX = X\Lambda \xrightarrow{\text{若}n\text{个特征向量线性无关}} A = X\Lambda X^{-1} \quad (\text{特征值分解})$$

- 相似变换 $B = T^{-1}AT$ 保特征值不变 **注意前提条件!**
- **实对称阵A**: 特征值均为实数, 可正交对角化 $A = Q\Lambda Q^T$
- 实矩阵A: 实特征值 \Leftrightarrow 实特征向量, 虚特征值 \Leftrightarrow 非实特征向量
- 所有特征值集合称为**特征值谱** $\lambda(A)$, 则 $\lambda(A) = \lambda(A^T)$

特征值与奇异值


▶ $m \times n$ 矩阵的奇异值

- $\begin{cases} Av = \sigma u \\ A^H u = \sigma v \end{cases}$ 非负实数 σ 为 **奇异值** (singular value) ↗ 与矩阵的奇异程度有关
- 非零向量 u, v 为 **左/右奇异向量** (singular vector)
- $A^H = \bar{A}^T$, 即 A 的 **厄米特转置** (Matlab 中用 A' 计算)
- 若矩阵表示一个空间到另一个空间的变换, 奇异值很重要
- 奇异向量也无穷多, 但总标准化为 $\|u\|_2 = \|v\|_2 = 1$ (如超定/欠定方程组)

◦ 设 $m \geq n$, 若有 n 个 **正交** 的向量 $\{v_i\}$, 使 $\{Av_i\}$ 也 **两两正交** 即 u_i, v_i 为左/右奇异向量对

➡ $AV = U\Sigma$, Σ 为对角阵, U 的列两两正交 ➡ $A^T U = V\Sigma$

- eigshow 演示程序
- 2阶方阵的特征向量/奇异向量
- 找正交的两个向量 $\{x, y\}$, 使它们是奇异向量



↘ 对角元为奇异值

思考:

Ax, Ay (u_1, u_2) 总是沿椭圆的轴方向?


特征值与奇异值

(对一般复矩阵, 酉正交)

- ▶ 设 $m \geq n$, 能找到 n 个正交向量 $\{v_i\}$, 使 $\{Av_i\}$ 也两两正交 \Rightarrow
确实总能找到! (后面证明)

$$AV = U\Sigma$$
$$A^H U = V\Sigma$$

- ▶ 简化奇异值分解 $A = U\Sigma V^H$
- ▶ V 为酉阵 ($VV^H = I$); U 为 $m \times n$ 阵, 酉阵前 n 列
- ▶ 可将 U 扩充列为酉阵 (Σ 加零行), 得



$$A = U\Sigma V^H \quad (\text{SVD: singular value decomposition})$$

调整酉阵 U , V 列的顺序, 使: $\sigma_1 \geq \sigma_2 \geq \sigma_3 \geq \dots \geq 0$ (A 实矩阵: 正交阵)

- ▶ 例子与 Matlab (特征值)

$$A = \begin{pmatrix} -149 & -50 & -154 \\ 537 & 180 & 546 \\ -27 & -9 & -25 \end{pmatrix}$$

- D 为对角阵, V 为单位长度特征向量组成的矩阵 (可能奇异!)

```
>> A = gallery(3)
>> eig(A)
ans =
    1.0000
    2.0000
    3.0000
>> [V, D]=eig(A) % AV=VD
```

例子与Matlab

- ▶ 例子与Matlab (奇异值)
 - $s = \text{svd}(A)$; $[U, S, V] = \text{svd}(A)$
 - 注意奇异值与特征值的不同
 - 如果A为实对称呢?
- 简化SVD: $[U, S, V] = \text{svd}(A, 0)$
- 即去掉U的后 $m-n$ 列

```
>> A = gallery(3)
>> [U, S, V] = svd(A)
```

$$A = \begin{pmatrix} -149 & -50 & -154 \\ 537 & 180 & 546 \\ -27 & -9 & -25 \end{pmatrix}$$
$$S = \begin{pmatrix} 817.7597 & 0 & 0 \\ 0 & 2.4750 & 0 \\ 0 & 0 & 0.0030 \end{pmatrix}$$

特征值计算问题的敏感性

- » A为非亏损阵
- A为亏损阵
- 特征值敏感性的例子

特征值计算问题的敏感性

▶ A为非亏损矩阵

不存在特征值分解的矩阵为亏损阵，否则为非亏损阵

◦ 设 $X^{-1}AX = \Lambda$ ，矩阵A变化 δA ，则

$$\Lambda + \delta\Lambda = X^{-1}(A + \delta A)X \longrightarrow \delta\Lambda = X^{-1}\delta AX$$

◦ 取范数得: $\|\delta\Lambda\| \leq \|X^{-1}\| \|X\| \|\delta A\| = \kappa(X)\|\delta A\|$

◦ 注意，这里的 δA 往往不是对角阵

◦ 上述分析虽不严格，但结论有普遍性：**特征值的敏感性可通过特征向量构成矩阵的条件数估计**

◦ 若特征向量接近相关(对应矩阵很病态)，则特征值计算很敏感

```
>> A = gallery(3)
>> [X,lambda] = eig(A);
>> condest(X)
ans=
      1.2002e+003
```

此特征值计算问题比较病态

特征值计算问题的敏感性

▶ A为非亏损矩阵

注意: λ 的左特征向量是行向量, 且一定存在!

- 如何分析某个特征值 λ 的敏感程度?
- 左特征向量 y^H 满足 $y^H A = \lambda y^H$ (y 是 A^H 的对应 $\bar{\lambda}$ 的右特征向量)
- 将矩阵 A 看成随某个扰动因素变化的函数, \dot{A} 为对应的微分

$$Ax = \lambda x \xrightarrow{\text{两边微分}} \dot{A}x + A\dot{x} = \dot{\lambda}x + \lambda\dot{x}$$

$$\text{乘以左特征向量} \quad y^H \dot{A}x + \cancel{y^H A\dot{x}} = y^H \dot{\lambda}x + \cancel{y^H \lambda\dot{x}}$$

$$\text{得:} \quad \dot{\lambda} = \frac{y^H \dot{A}x}{y^H x} \quad \text{即} \quad |\dot{\lambda}| \leq \frac{\|y\| \|x\|}{|y^H x|} \|\dot{A}\|$$

>> `condeig(A)`

$$\text{定义特征值条件数} \quad \kappa(\lambda, A) = \frac{\|y\| \|x\|}{|y^H x|} \quad \text{则} \quad |\dot{\lambda}| \leq \kappa(\lambda, A) \|\dot{A}\|$$

$$\text{因为} \quad X^{-1}AX = \Lambda \xrightarrow{\text{}} X^{-1}A = \Lambda X^{-1} \xrightarrow{\text{}} y^H \text{为} X^{-1} \text{的行向量, 则}$$

$$\kappa(\lambda, A) = \frac{\|y\| \|x\|}{|y^H x|} = \|y\| \|x\| \leq \kappa(X)$$

$$y^H x = 1$$

特征值计算问题的敏感性

▶ A为非亏损矩阵

◦ 若A为实对称矩阵, 或复Hermite阵 $A = A^H$ (特征值全为实数)

◦ 左特征向量 y^H 满足 $y^H A = \lambda y^H \longrightarrow Ay = \lambda y \longrightarrow x, y$ 同方向

$|y^H x| = \|y\| \|x\| \longrightarrow \kappa(\lambda, A) = \frac{\|y\| \|x\|}{|y^H x|} = 1$ 实对称阵的特征值计算不敏感!

▶ A为亏损阵

◦ 设 λ_k 为重特征值, $p(\lambda) = \det(A - \lambda I) = (\lambda - \lambda_k)^m q(\lambda)$

◦ 矩阵某元素扰动 δ 后, 特征多项式变为 $p(\lambda) - O(\delta)$

◦ **重特征值对扰动很敏感!** $\longrightarrow \lambda = \lambda_k + O(\delta^{1/m})$

例:

$$A = \begin{pmatrix} 2 & 1 & & & \\ & 2 & 1 & & \\ & & \ddots & \ddots & \\ & & & 2 & 1 \\ \delta & & & & 2 \end{pmatrix}_{16 \times 16}$$

$\delta = 10^{-16}$, 则特征值的扰动为0.1

`A=diag(ones(16,1)*2)+diag(ones(15,1), 1);`
`A(16,1)= 1e-16;`
`eig(A)`

特征值计算问题的敏感性

▶ 另一个例子

```
A = gallery(5)
e = eig(A)
A^5
```

```
A =
    -9      11     -21      63     -252
     70     -69     141    -421     1684
    -575     575   -1149    3451   -13801
    3891   -3891    7782
    1024   -1024    2048

e =
    -0.0405
   -0.0118 + 0.0383i
   -0.0118 - 0.0383i
    0.0320 + 0.0228i
    0.0320 - 0.0228i
```


- 此矩阵的特征值应该全为0! (A^k 特征值与A的特征值的关系)

```
plot(real(e),imag(e),'r*',0,0,'ko');
axis(.1*[-1 1 -1 1]); axis square;
```

- 特征值计算的命令有错，还是误差？

```
e = eig(A + eps*randn(5,5).*A);
```

- 重复执行，看复平面上五个特征值
- 理论分析：0是特征多项式的五重根
- 若特征多项式扰动 δ ，则 $\lambda \approx O(\delta^{\frac{1}{5}})$



奇异值分解的存在性与性质

- » 分解存在性的证明
- 奇异值分解的性质
- 计算奇异值的敏感性

奇异值分解(SVD)

▶ 奇异值分解的存在性

◦ A为 $m \times n$ 矩阵, 奇异值分解为 $A = U \Sigma V^H$

◦ A^H 的分解: $A^H = V \Sigma^H U^H$ 实对称阵或 复Hermite阵

◦ 不妨仅讨论 $m \geq n$ 的情况 $A^H A = V \Sigma^H \Sigma V^H = V \begin{bmatrix} \sigma_1^2 & & \\ & \ddots & \\ & & \sigma_n^2 \end{bmatrix} V^H$

◦ 奇异值是 $A^H A$ 特征值的算术平方根

◦ 为了方便, 仅证明A为实数矩阵的情况

▶ 存在性的证明

◦ $A^T A$ 为对称半正定阵, 设其非零特征值为 $\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2$, 形成 Σ_r^2

特征值分解

$$A^T A = \underbrace{[V_1 \ V_2]}_{\text{(正交阵)}} \begin{bmatrix} \Sigma_r^2 & O \\ O & O \end{bmatrix} \begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} \longrightarrow \begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} A^T A \begin{bmatrix} V_1 & V_2 \end{bmatrix} = \begin{bmatrix} \Sigma_r^2 & O \\ O & O \end{bmatrix}$$

$$U_1^T U_1 = I_r \longleftarrow \Sigma_r^{-1} V_1^T A^T \underbrace{A V_1 \Sigma_r^{-1}}_{= I_r} \longleftarrow \begin{bmatrix} V_1^T A^T A V_1 & \dots \\ \dots & V_2^T A^T A V_2 \end{bmatrix}$$

$$A V_2 = O \longleftarrow$$

奇异值分解(SVD)

▶ 奇异值分解的存在性

◦ 存在性的证明

$$A = U\Sigma V^T$$

U_1 为正交阵 r 列

$$\begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} A^T A \begin{bmatrix} V_1 & V_2 \end{bmatrix} = \begin{bmatrix} \Sigma_r^2 & O \\ O & O \end{bmatrix} \longrightarrow \begin{matrix} AV_2 = O \\ \text{设 } U_1 = AV_1 \Sigma_r^{-1}, U_1^T U_1 = I_r \end{matrix}$$

根据 U_1 补齐正交单位向量得到正交阵 $U = [U_1 \ U_2]$

$$U^T AV = \begin{bmatrix} U_1^T \\ U_2^T \end{bmatrix} A \begin{bmatrix} V_1 & V_2 \end{bmatrix} = \begin{bmatrix} U_1^T AV_1 & U_1^T AV_2 \\ U_2^T AV_1 & U_2^T AV_2 \end{bmatrix} = \begin{bmatrix} U_1^T AV_1 & O \\ U_2^T AV_1 & O \end{bmatrix}$$

$$U_1 = AV_1 \Sigma_r^{-1} \longrightarrow \begin{matrix} U_1^T AV_1 = \Sigma_r^{-1} V_1^T A^T AV_1 = \Sigma_r \\ U_2^T AV_1 = U_2^T U_1 \Sigma_r = O \end{matrix}$$

$$\text{所以, } U^T AV = \begin{bmatrix} \Sigma_r & O \\ O & O \end{bmatrix} = \Sigma$$

SVD的存在性得证!

奇异值分解(SVD)

▶ 奇异向量的意义

- $A = U\Sigma V^T \Rightarrow AV = U\Sigma$ → 设有r个非零对角元
- U的前r列, u_1, \dots, u_r 是 $\text{span}(A)$ 的单位正交基 $\{Ax : \forall x \in \mathbb{R}^n\}$
- 而 $AV_2 = O$, 说明 v_{r+1}, \dots, v_n 是A的核空间 $\{x \in \mathbb{R}^n : Ax = 0\}$ 的单位正交基

▶ 与特征值分解比较(m=n) $A = X\Lambda X^{-1} \Rightarrow AX = X\Lambda$

- 对非亏损阵存在, 非零特征值对应的矩阵X的列向量为 $\text{span}(A)$ 的基, 但一般不正交
- 当A为实对称或复Hermite, 可正交对角化 $A = X\Lambda X^T$
- 非负特征值就是奇异值, 且 $u=v=x$ $A = X\Lambda X^H$
- 负特征值, 其相反数是奇异值, 且 $u=-v=x$

实对称半正定阵呢?

奇异值分解(SVD)

▶ 奇异值与矩阵的2-范数、条件数

◦ $A = U\Sigma V^T$, 其中 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$

$$\|A\|_2 = \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} = \max_{x \neq 0} \frac{\|U\Sigma V^T x\|_2}{\|x\|_2} = \max_{x \neq 0} \frac{\|\Sigma V^T x\|_2}{\|V^T x\|_2} = \max_{y \neq 0} \frac{\|\Sigma y\|_2}{\|y\|_2} = \sigma_1$$

最大奇异值

若 A 非奇异 ($m=n$), 其奇异值均 >0

$$\|A^{-1}\|_2 = \left(\min_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} \right)^{-1} = \left(\min_{y \neq 0} \frac{\|\Sigma y\|_2}{\|y\|_2} \right)^{-1} = 1/\sigma_n$$

→ $\text{cond}(A)_2 = \sigma_1/\sigma_n$

若列满秩(奇异值均大于0),

$$A^+ = (A^T A)^{-1} A^T = (V\Sigma^T \Sigma V^T)^{-1} V\Sigma^T U^T = V(\Sigma^T \Sigma)^{-1} \Sigma^T U^T$$

→ $\|A^+\|_2 = 1/\sigma_n$ → $\text{cond}(A)_2 = \sigma_1/\sigma_n$ SVD!

在其他情况下 $\text{cond}(A)_2 = \infty$

奇异值计算问题的敏感性

▶ 敏感性分析

- $\Sigma = U^H A V \longrightarrow \Sigma + \delta\Sigma = U^H (A + \delta A) V$ (不严格分析)
- U, V 为正交阵或酉阵, 则 $\|\delta\Sigma\|_2 = \|\delta A\|_2$
- 矩阵2-范数是其**最大奇异值**, 这说明最大奇异值不敏感
- 求小奇异值(可能是0)时, 仍可能很敏感
- **例子** (奇异阵, 特征值全0)

```
>> A = gallery(5)
>> format long e
>> svd(A)
```

```
    -9         11        -21         63        -252
     70        -69        141       -421        1684
   -575         575    -1149        3451   -13801
   3891    -3891        7782   -23345        93365
   1024    -1024        2048    -6144       24572
```

反复执行:

```
svd(A+eps*randn(5,5).*A)
```

结果: 1.010353607103610e+005
1.67945738406****e+000
1.46283872808****e+000
1.08016906998****e+000
*.*****-0**

计算特征值、奇异值的算法

- » 计算矩阵特征值的算法
QR算法及相关技术

特征值分解及其计算

▶ 特征值计算的方法

◦ 求解特征方程？

- 通过算矩阵行列式得到多项式系数，计算量大且很敏感
- 高阶多项式方程求根：工作量大，且得到的解不准确

• 例： $A = \begin{bmatrix} 1 & \epsilon \\ \epsilon & 1 \end{bmatrix}$, ϵ 比 $\sqrt{\epsilon_{\text{mach}}}$ 小一点，准确特征值为 $1 \pm \epsilon$ ，
但 $\det(A - \lambda I) = \lambda^2 - 2\lambda + 1$ ，算出两个根均为 1 (pp.232的例子)

- 相反，求矩阵特征值的方法可用于解多项式方程 `roots` 命令

$$p(\lambda) = c_0 + c_1\lambda + \cdots + c_{n-1}\lambda^{n-1} + \lambda^n$$

是伴随矩阵 C_n 的特征多项式。求出特征值即得多项式方程的所有根

$$C_n = \begin{bmatrix} 0 & 0 & \cdots & 0 & -c_0 \\ 1 & 0 & \cdots & 0 & -c_1 \\ 0 & 1 & \cdots & 0 & -c_2 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & -c_{n-1} \end{bmatrix}$$

◦ 幂法 (power iteration) $x_k = Ax_{k-1}$

- 求最大的特征值(主特征值)、及对应的特征向量
- 条件：主特征值是唯一的，对实矩阵它一定是实的

特征值、特征向量的计算

▶ 幂法与反幂法

- 幂法的应用：Google的PageRank算法
- 加速幂法的收敛(瑞利商、位移技术、二次外推...)
- 反幂法
 - 求最小的特征值，对 A^{-1} 应用幂法(解方程组)
 - 与位移技术结合(对 $A - \lambda I$ 用)，很适合求某特征值的特征向量

▶ 计算非单个特征值

- 若已知某个特征值及特征向量，可用收缩技术降维
- QR迭代算法
 - 将矩阵正交相似变换为易求的形式 $Q^T A Q$
- Krylov子空间迭代法：Lanczos算法，Arnoldi算法
 - 适合于大规模稀疏阵，求最大的若干个特征值

特征值、特征向量的计算

▶ 收缩技术 (已知A的一个特征值 λ_1 , 特征向量 x_1)

- 构造H矩阵对 x_1 实现消元: $Hx_1 = \sigma e_1$, 再对A做正交相似变换

$$HAH^T e_1 = HA \left(\frac{1}{\sigma} x_1 \right) = \frac{1}{\sigma} HAx_1 = \frac{1}{\sigma} H\lambda_1 x_1 = \frac{\lambda_1}{\sigma} (\sigma e_1) = \lambda_1 e_1$$

$$HAH^T = \begin{bmatrix} \lambda_1 & r_1^T \\ \mathbf{0} & A_1 \end{bmatrix}$$

- 例子:

$$A = \begin{bmatrix} 3 & -1 & 1 \\ 2 & 0 & 1 \\ 1 & -1 & 2 \end{bmatrix} \quad \lambda_1 = 2, \text{ 对应特征向量为 } x_1 = [1, 1, 0]^T, \text{ 求其他特征值}$$

Householder变换处理 x_1 , $v = x_1 + \sigma e_1 = \begin{bmatrix} 2.4142 \\ 1 \\ 0 \end{bmatrix}$

$$\Rightarrow H = \begin{bmatrix} -0.7072 & -0.7072 & 0 \\ -0.7072 & 0.7072 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad HAH^T = \begin{bmatrix} 2 & 3 & -1.4142 \\ 0 & 1 & 0 \\ 0 & -1.4142 & 2 \end{bmatrix}$$

易知A的其他两个特征值为1和2

A_1

计算所有特征值的方法

▶ QR算法

J. G.F. Francis和V. N. Kublanovskaya各自发明，见网络学堂“资源”文章

- “二十世纪十大算法”之一，计算中小规模矩阵所有特征值的稳定、有效的方法

- 实Schur分解: $A = QSQ^T \Rightarrow Q^T A Q = S$ (Q为正交阵)

- S为1阶或2阶对角块形成的分块上三角阵(实Schur型) 复Schur分解

- QR算法实现了Schur分解 $A = QUQ^H$

- $A_0 = A, Q_k R_k = A_k, A_{k+1} = R_k Q_k, k=0, 1, 2, \dots$


- $A_{k+1} = Q_k^T A_k Q_k$, 所以 A_k 的特征值总与A的相同 基本QR算法

- 可证明：序列 $\{A_k\}$ “基本收敛”到S (实Schur型)，其对角块为A的特征值 (2阶对角块 ~ 一对共轭复特征值)

- 条件：实矩阵A为非亏损阵，等模特征值只有实重特征值，或多重复的共轭特征值两种情况

怎么减少每步迭代的计算量？怎么保证收敛？

计算所有特征值的方法



实用的QR算法

- 把一般矩阵化为上Hessenberg阵再执行QR

(Householder变换)

$$A = \begin{bmatrix} a_{11} & \mathbf{r}_1^T \\ \mathbf{c}_1 & A_{22}^{(1)} \end{bmatrix} \xrightarrow{H_1 = \begin{bmatrix} 1 & \mathbf{0}^T \\ \mathbf{0} & H'_1 \end{bmatrix}} H_1 A = \begin{bmatrix} a_{11} & \mathbf{r}_1^T \\ \sigma_1 \mathbf{e}_1 & H'_1 A_{22}^{(1)} \end{bmatrix} \rightarrow H_1 A H_1 = \begin{bmatrix} a_{11} & \mathbf{r}_1^T H'_1 \\ \sigma_1 \mathbf{e}_1 & H'_1 A_{22}^{(1)} H'_1 \end{bmatrix}$$

$$A^{(2)} = H_1 A H_1 = \begin{bmatrix} A_{11}^{(2)} & A_{12}^{(2)} \\ A_{21}^{(2)} & A_{22}^{(2)} \end{bmatrix} \xrightarrow{H_2 = \begin{bmatrix} I_2 & \mathbf{0}^T \\ \mathbf{0} & H'_2 \end{bmatrix}} H_2 A^{(2)} H_2 = \begin{bmatrix} a_{11} & a_{12}^{(2)} & a_{13}^{(3)} & \cdots & \cdots & a_{1n}^{(3)} \\ \sigma_1 & a_{22}^{(2)} & a_{23}^{(3)} & \cdots & \cdots & a_{2n}^{(3)} \\ \hline 0 & \sigma_2 & a_{33}^{(3)} & \cdots & \cdots & a_{3n}^{(3)} \\ 0 & 0 & \vdots & \ddots & & \vdots \\ \vdots & \vdots & \vdots & & \ddots & \vdots \\ 0 & 0 & a_{n3}^{(3)} & \cdots & \cdots & a_{nn}^{(3)} \end{bmatrix}$$



- 最终 $H_{n-1} \cdots H_1 A H_1 \cdots H_{n-1}$ 为上Hessenberg阵 (与A相似)
- QR迭代第一步计算量变小, 后续迭代步呢?

计算所有特征值的方法

实用的QR算法

对 **上 Hessenberg 矩阵** A_k 执行 QR 迭代

采用 Givens 旋转，以 4 阶矩阵为例 $Q_k^T A_k = R_k$



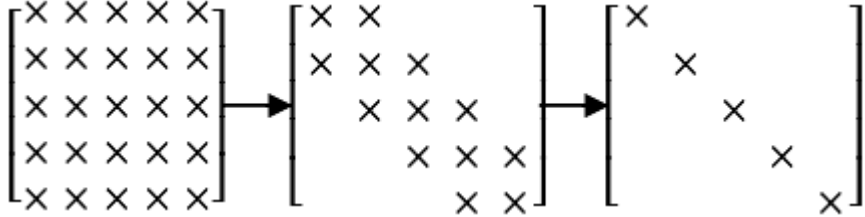
计算效率很高; A_{k+1} 仍是上 Hessenberg 阵!

计算所有特征值的方法

实用的QR算法

- 单位移技术可加速收敛

$$\begin{cases} \mathbf{Q}_k \mathbf{R}_k = \mathbf{A}_k - s_k \mathbf{I}, & (\text{作 QR 分解}) \\ \mathbf{A}_{k+1} = \mathbf{R}_k \mathbf{Q}_k + s_k \mathbf{I}, & k = 1, 2, \dots \end{cases} \longrightarrow \mathbf{A}_{k+1} = \mathbf{Q}_k^T (\mathbf{A}_k - s_k \mathbf{I}) \mathbf{Q}_k + s_k \mathbf{I} = \mathbf{Q}_k^T \mathbf{A}_k \mathbf{Q}_k$$

- $\{\mathbf{A}_k\}$ 序列仍正交相似, 求出原问题特征值
 - 一种单位移策略: $s_k = \mathbf{A}_k(n, n)$, 使 $\mathbf{A}_k(n, n)$ 最先收敛到特征值. 然后, 删除第 n 行, 第 n 列, 对低一阶矩阵做QR迭代
 - **Wilkinson位移**: 右下角2阶矩阵的特征值, 其中接近 $\mathbf{A}_k(n, n)$ 的
 - 对实对称阵, 上Hessenberg约化后为三对角阵
- 
- **结论**: 对实对称阵, 使用Wilkinson位移的QR算法一定收敛

计算所有特征值的方法

▶ 针对实对称阵的单位移实用QR算法

利用 Householder 变换将矩阵 A 化简为三对角阵;

$k := n;$ {对 A 的前 k 行、 k 列执行 QR 算法}

While $k > 1$ 并且 $a_{k,k-1} \neq 0$ **do**

$s := A(k-1:k, k-1:k)$ 的特征值中, 接近 a_{kk} 的那个;

For $j=1, 2, \dots, k$ {计算 $A(1:k, 1:k) - sI$ }

$a_{jj} := a_{jj} - s;$

End

 用 Givens 旋转将 $A(1:k, 1:k)$ 化为上三角阵, 得旋转阵 G_j ($j = 1, \dots, k-1$) 的参数 c_j, s_j ;

For $j=1, 2, \dots, k-1$ {计算 $RQ = RG_1^T \dots G_{n-1}^T$ }

$A(1:k, 1:k) := A(1:k, 1:k)G_j^T$; {执行列的 Givens 旋转}

End

For $j=1, 2, \dots, k$ {计算 $A(1:k, 1:k) + sI$ }

$a_{jj} := a_{jj} + s;$

End

If $a_{k,k-1} = 0$, **then**

$k := k-1;$

End

End

{ A 的对角元就是待求的特征值 $\lambda_1, \dots, \lambda_n$ }

约化为上 Hessenberg 阵

Wilkinson 位移

上 Hessenberg 阵的 QR 迭代

矩阵第 k 行已收敛!

计算所有特征值的方法

实用的QR算法


- 对非对称实矩阵, Wilkinson位移不适用(虚数特征值), 可采用一种双位移策略

- 计算过程:



- 正交约化为上Hessenberg阵, 以及位移技术, 显著扩大了QR算法收敛的适用范围
- 对实非对称阵, 可证明: 利用双位移技术的QR算法一定收敛*
(课本的说法值得商榷)
- 演示程序eigsvdgui

*L Elden, Matrix Methods in Data Mining and Pattern Recognition, SIAM, 2007, pp.198



Matlab中有关命令及其他

- ▶ **eig命令** - 主要对稠密矩阵
 - $d = \text{eig}(A)$; 返回所有特征值, 使用QR算法
 - $[V, D] = \text{eig}(A)$; 返回特征值和特征向量矩阵, QR算法
 - 可能还会对矩阵元素进行比例调整, 提高数值稳定性
 - 中小规模稠密阵, 较小规模的对称稀疏阵(只特征值)
- ▶ **eigs命令**
 - 针对一般稀疏矩阵, Lanczos算法, Arnoldi算法
 - $d = \text{eigs}(A, k)$; 返回最大的k个特征值(k缺省为6)
 - $[V, D] = \text{eigs}(A, k)$; 返回最大的k个特征值与相应特征向量
- ▶ **hess命令**: 对称正交变换生成上Hessenberg阵
- ▶ **schur命令**: 生成矩阵的Schur分解 $T = \text{schur}(A)$;
注意与eig的区别 $[U, T] = \text{schur}(A)$;

LAPACK程序包

如何计算矩阵奇异值?

■ 利用求特征值的QR算法

- 等效于求 $A^T A$ 矩阵的特征值 这样计算误差大!
- 注意: 对 A 施加左、右正交变换不改变它的奇异值
- 先将 A 化简(Householder变换)为双对角阵 B , 再对 $B^T B$ 执行(隐式)QR迭代算法

$$A = \begin{bmatrix} a_1 & \cdots & \cdots & a_n \end{bmatrix} \xrightarrow[\mathbf{H}_1 \mathbf{a}_1 = \alpha_1 \mathbf{e}_1^{(m)}]{\mathbf{H}_1 A} \begin{bmatrix} \alpha_1 & \mathbf{b}_1^T \\ \mathbf{0} & \text{shaded} \end{bmatrix} \xrightarrow[\mathbf{H}_2 \mathbf{b}_1 = \beta_1 \mathbf{e}_1^{(n-1)}]{\mathbf{H}_1 A \begin{bmatrix} 1 & 0 \\ 0 & \mathbf{H}_2 \end{bmatrix}} \begin{bmatrix} \alpha_1 & \beta_1 & \text{oval} \\ \mathbf{0} & \text{shaded} \end{bmatrix} \stackrel{=}{=} \mathbf{H}_1 A \mathbf{T}_1$$

$$\longrightarrow \begin{bmatrix} \alpha_1 & & & & \\ & \beta_1 & & & \\ & & \ddots & & \\ & & & \ddots & \\ & & & & \beta_{n-1} \\ & & & & & \alpha_n \end{bmatrix} = \mathbf{H}_n \cdots \mathbf{H}_1 A \mathbf{T}_1 \cdots \mathbf{T}_{n-1} = \mathbf{B}$$

QR迭代过程中:

$\mathbf{B}_k^T \mathbf{B}_k$ 为三对角矩阵, 迭代中保持其形状

演示程序: [eigsvdgui](#)

低秩近似与主分量分析

» 矩阵的低秩近似与PCA
一个图像处理问题

低秩近似与主分量分析 (PCA)

▶ 利用SVD做矩阵的低秩近似

$$A = \begin{bmatrix} u_1 & \cdots & u_m \end{bmatrix} \begin{bmatrix} \sigma_1 & & & \\ & \ddots & & \\ & & \sigma_n & \\ & & & \ddots \end{bmatrix} \begin{bmatrix} v_1^T \\ \vdots \\ v_n^T \end{bmatrix} = \begin{bmatrix} \sigma_1 u_1 & \cdots & \sigma_n u_n \end{bmatrix} \begin{bmatrix} v_1^T \\ \vdots \\ v_n^T \end{bmatrix} = \sum_{i=1}^n \sigma_i E_i$$

- $E_i = u_i v_i^T$, $i = 1, \dots, n$, 为秩1矩阵, 它有个奇异值为1, 其余0
- 存储 E_i 只要 $m+n$ 个单元, 计算 $E_i x$ 只需 $m+n$ 次乘法
- 忽略小奇异值有关项, 得到A的低秩近似 $A_r = \sum_{i=1}^r \sigma_i E_i$ $\|E_i\|_2 = 1$
- 可证明, 在所有秩为 r 的矩阵中 A_r 最接近A
(无论2范数还是F范数) $\|A - A_r\|_2 = \sigma_{r+1}$

▶ 主分量分析

- 统计分析、数据处理中的一个方法

- 用较少的独立数据(主分量)表示存在相关性的所有数据

$$A \approx \begin{bmatrix} \sigma_1 u_1 & \cdots & \sigma_r u_r \end{bmatrix} \begin{bmatrix} v_1^T \\ \vdots \\ v_r^T \end{bmatrix}$$

主分量分析 (PCA)

- ▶ 一组高度与重量的数据
 - 两列数据是高度相关联的

```
>> [U,S,V] = svd(A,0);  
>> sigma = diag(S)  
sigma =  
    156.4358  
     8.7658  
>> E1=sigma(1)*U(:,1)*V(:,1)'
```


有一个潜在的主要分量

A =

47	15	
93	35	
53	15	
sigma(1)*U(:,1)	45	10
49.3269	67	27
99.3163	42	10
55.0076		
45.8240		
72.1250		
42.9837		


V(:,1)'=[0.9468, 0.3219]

- 近似表示高度与重量



主分量分析 (PCA)

演示imagesvd.m



数字图像处理

- Albrecht Durer(丢勒)的版画Melancholia II
- 图像数据为359x371的矩阵, 进行低秩近似

```
>> load detail;  
>> image(X); colormap(gray(64))  
>> [U, S, V]= svd(X, 0);  
>> sigma= diag(S);  
>> semilogy(sigma, '.')
```


- 取若干主要奇异值重建矩阵

```
>> Xr= U(:,1:r)*S(1:r,1:r)*V(:,1:r)'
```

- 节省存储量; 目前主要用于特征识别

程序svd_appl.m

若A实对称, $A = Q\Lambda Q^T$ 左右奇异向量很接近, 低秩近似更简单



圆生成器

- » 用整数 $+$, $-$, $*$ 就能画圆?
其内在原因与特征值的关系

圆生成器

▶ 一个简单的画圆的程序

- 整数计算；没有乘法/平方根/三角函数
- 为什么能画圆？ [cirgen.m](#)

```
h = 1/32;  
x = 1; y = 0;  
h1=plot(x, y, '.', 'erasemode','none');  
axis([-1.1, 1.1, -1.1, 1.1]); axis square;  
while 1  
    x = x + h*y;  
    y = y - h*x;  
    set(h1, 'xdata', x, 'ydata', y); drawnow  
end
```

(在只有整数的计算机上)

```
x = 32768  
y = 0  
L: load y  
    shift right 5 bits  
    add x  
    store in x  
    change sign  
    shift right 5 bits  
    add y  
    store in y  
    plot x y  
    go to L
```

$$\mathbf{x}_{n+1} = \begin{pmatrix} 1 & h \\ -h & 1 - h^2 \end{pmatrix} \mathbf{x}_n$$

- 设第n个点为 \mathbf{x}_n ，则 $\mathbf{x}_0 = [1, 0]^T$ ， $\mathbf{x}_{n+1}(1) = \mathbf{x}_n(1) + h\mathbf{x}_n(2)$
 $\mathbf{x}_{n+1}(2) = \mathbf{x}_n(2) - h\mathbf{x}_{n+1}(1) = -h\mathbf{x}_n(1) + (1 - h^2)\mathbf{x}_n(2)$

圆生成器

▶ 一个简单的画圆的程序

- 生成一系列二维点 $\{x_n\}$, 满足 $x_{n+1} = \begin{pmatrix} 1 & h \\ -h & 1-h^2 \end{pmatrix} x_n$
- $x_n = A^n x_0$, 要求通式需求 A 特征值

$$\lambda = \frac{2-h^2 \pm \sqrt{h^2(h^2-4)}}{2} \xrightarrow{h \text{ 很小}} \lambda = \frac{2-h^2}{2} \pm i \frac{\sqrt{h^2(4-h^2)}}{2}$$

- 可证明: $|\lambda| = 1$. $AX = X\Lambda \longrightarrow A^n = X\Lambda^n X^{-1}$ 假设 $0 < h < 2$
- 设 $\lambda_1 = e^{i\theta}$, $\lambda_2 = e^{-i\theta}$, $\Lambda^n = \begin{bmatrix} e^{in\theta} & 0 \\ 0 & e^{-in\theta} \end{bmatrix}$

- 求解特征向量, 得 $X = \begin{bmatrix} \frac{h}{2} + i\sqrt{1-\frac{h^2}{4}} & 1 \\ -1 & -\frac{h}{2} - i\sqrt{1-\frac{h^2}{4}} \end{bmatrix}$ 再求 X^{-1} , 整理得

$$x_n = \frac{1}{\cos(\frac{\theta}{2})} \begin{bmatrix} \cos(n\theta - \frac{\theta}{2}) \\ \sin(n\theta) \end{bmatrix} \quad \text{是椭圆, 但 } h \rightarrow 0, \theta \rightarrow 0$$


$$\text{满足 } [x - y \sin(\frac{\theta}{2})]^2 + [y \cos(\frac{\theta}{2})]^2 = 1$$

圆生成器

▶ 画圆的程序

- $h=1/32$, 足够小, 画圆效果很好
- $h=0.20906$, 对应的 $\theta=\pi/15$, 生成30个离散点

$$\mathbf{x}_n = \frac{1}{\cos(\frac{\theta}{2})} \begin{bmatrix} \cos(n\theta - \frac{\theta}{2}) \\ \sin(n\theta) \end{bmatrix}$$



▶ 更多讨论

- 平面旋转矩阵 $\begin{pmatrix} \cos h & \sin h \\ -\sin h & \cos h \end{pmatrix}$
- 若它为 A , 则 $\mathbf{x}_{n+1} = A\mathbf{x}_n$, 一定生成圆
- 事实上 $\begin{pmatrix} \cos h & \sin h \\ -\sin h & \cos h \end{pmatrix} \approx \begin{pmatrix} 1 & h \\ -h & 1 - h^2 \end{pmatrix}$
- 常微分方程 $\dot{\mathbf{x}} = Q\mathbf{x}$, $Q = \begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix}$ 的准确解也得到圆

称为“圆”常微分方程 (与第7章和习题10.16有关)