

# 高等数值算法与应用 (四)

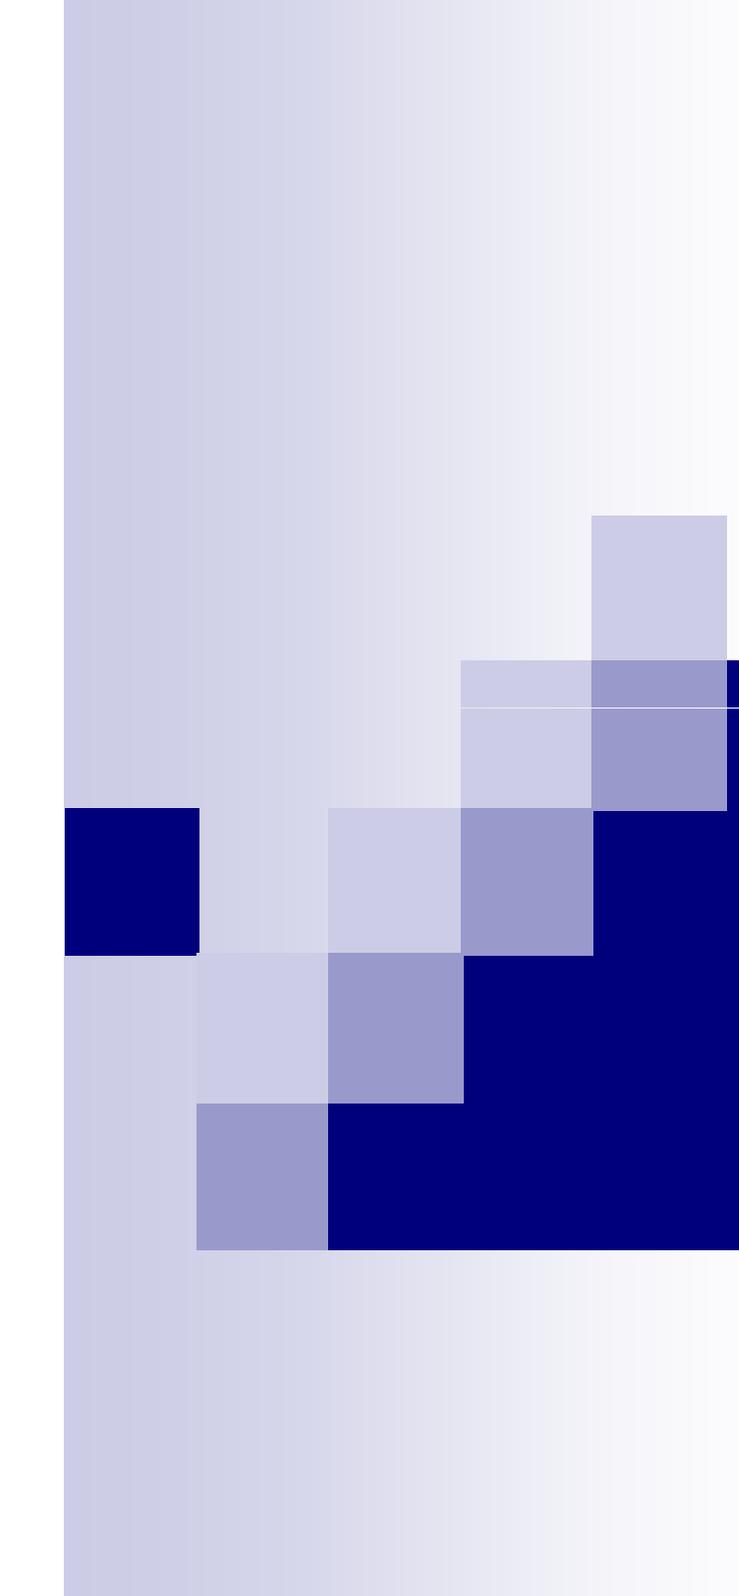
## Advanced Numerical Algorithms & Applications

计算机科学与技术系 喻文健

# 内容概要

## ■ 矩阵分解及其应用

- 六大分解简介
- 矩阵与线性方程组求解基本理论
- **LU**分解, **Cholesky**分解及其应用
- **QR**分解与线性最小二乘问题
- 特征值分解、奇异值分解(**SVD**)及其应用
- 稀疏矩阵的直接解法



# Spectrum Decomposition and Algorithms

## ■ 本节主要内容

- 矩阵的特征值与特征向量
- 有关的计算问题
- 特征值计算方法
  - 幂法、反幂法 (应用: **PageRank**)
  - 收缩技术
  - **QR**算法

演示程序 **eigshow**

# $n \times n$ 矩阵 $A$ 的特征值分解

## ■ 基本概念与重要性质

$$Ax = \lambda x \Leftrightarrow \det(\lambda I - A) = \lambda^n - \left( \sum_{j=1}^n a_{jj} \right) \lambda^{n-1} + \dots = 0$$

- 特征值  $\lambda$ , 特征向量  $x$ , 特征方程, 谱  $\lambda(A)$ , 特征子空间
- 实矩阵: 特征值可能是虚数, 它一定与其共轭成对出现
- 实特征值对应实特征向量, 虚特征值对应非实特征向量
- 实对称矩阵  $A$ : 特征值均为实数, 可正交对角化

$$A = Q\Lambda Q^T \Leftrightarrow AQ = Q\Lambda$$

- $\lambda(A) = \lambda(A^T)$ , 同一特征值还有左特征向量  $y^T A = \lambda y^T$
- 若为对角阵、上(下)三角阵, 特征值为其对角线元素
- 若为分块对角阵、分块上(下)三角阵,

特征值为对角块矩阵特征值的合并

$$\lambda(A) = \bigcup_{j=1}^m \lambda(A_{jj}), \quad A = \begin{bmatrix} A_{11} & A_{12} & \cdots & A_{1m} \\ & A_{22} & \cdots & A_{2m} \\ & & \ddots & \vdots \\ & & & A_{mm} \end{bmatrix}$$

# 特征值分解

## ■ 基本概念与重要性质 (续)

- “倍数”  $cA$  的特征值, “平移”  $A+pI$  的特征值
- “幂”  $A^k$  的特征值,  $k$  为正整数
- “多项式”  $P(A)$  的特征值, 为特征值的多项式函数值
- 若  $A$  非奇异,  $A^{-1}$  的特征值
- 相似变换不改变特征值
- $B = X^{-1}AX, \lambda(A) = \lambda(B)$
- 设有  $m$  个不同的特征值  $\tilde{\lambda}_1, \dots, \tilde{\lambda}_m$ , 若  $\tilde{\lambda}_j$  是特征方程的  $n_j$  重根, 称  $n_j$  为其代数重数, 其几何重数  $d_j$  为特征子空间维数
- $\forall j, n_j \geq d_j$ ; 若两者总相等, 则有  $n$  个线性无关特征向量, 这种矩阵称为非亏损矩阵, 否则为亏损矩阵
- 非亏损矩阵  $\Leftrightarrow A$  可对角化,  $X^{-1}AX = \Lambda$

# 特征值分解

## ■ 计算有关的问题

- 矩阵**A**是实的，还是复的？规模大小？
- 既要特征值，又要特征向量？
- 要所有特征值，还是一部分（最大、最小）？
- 特征值(向量)计算问题的敏感性
  - 同一个矩阵的不同特征值(向量)的敏感性可能不同
  - 对非亏损矩阵，设  $X^{-1}AX = \Lambda$ ，矩阵**A**变化 $\Delta A$ ， $\mu$ 为扰动后矩阵的特征值， $\lambda_k$ 为与它最接近的**A**的特征值，则
$$|\mu - \lambda_k(A)| \leq \text{cond}(X)_2 \|\Delta A\|_2$$
  - 若特征向量接近线性相关，则特征值计算非常敏感
  - 对于**正规阵A** ( $A^T A = A A^T$ , 特例是实对称阵)，有正交特征向量组， $\text{cond}(X)_2 = 1$ ，不敏感
  - 亏损矩阵一般分析：
$$|\Delta \lambda| \lesssim \frac{\|y\|_2 \|x\|_2}{\|y^T x\|_2} \|\Delta A\|_2 = \frac{1}{\cos \theta} \|\Delta A\|_2$$

$y$ 为左特征向量

# 特征值分解及其计算

## ■ 特征值计算的方法

### □ 求解特征方程？

- 计算特征多项式系数工作量很大，且对矩阵扰动敏感
- 高阶多项式方程求根的工作量很大，两种误差累计使解不准
- 例：  $A = \begin{bmatrix} 1 & \epsilon \\ \epsilon & 1 \end{bmatrix}$ ， $\epsilon$  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  $1$
- 因此，反而是求矩阵特征值的方法被用于求解多项式方程

$p(\lambda) = c_0 + c_1\lambda + \dots + c_{n-1}\lambda^{n-1} + \lambda^n$  是  $C_n$  的特征多项式。因此，通过求  $C_n$  的特征值即求解了多项式方程。

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

### □ 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)
- 反幂法
  - 求最小的特征值, 对 $A^{-1}$ 应用幂法
  - 与位移技术结合, 即对  $A - \lambda I$  使用, 精确求某一特征值

## ■ 计算所有特征值的主要方法

- 1. 若已知某个特征值、及特征向量, 可采用收缩技术
- 2. **QR算法**
- 3. 分治算法
- 4. Krylov子空间迭代法: **Lanczos算法**, **Arnoldi算法**

# 计算所有特征值的方法

## ■ 收缩技术

假设已经求出了一个特征值 $\lambda_1$ 及相应的特征向量 $\mathbf{x}_1$ , 则

$$\mathbf{A}\mathbf{x}_1 = \lambda_1\mathbf{x}_1.$$

首先构造一个 Householder 变换矩阵 $\mathbf{H}$ 使

$$\mathbf{H}\mathbf{x}_1 = \sigma\mathbf{e}_1,$$

$$\Rightarrow \mathbf{H}\mathbf{A}\mathbf{H}^T\mathbf{e}_1 = \mathbf{H}\mathbf{A}\left(\frac{1}{\sigma}\mathbf{x}_1\right) = \frac{1}{\sigma}\mathbf{H}\mathbf{A}\mathbf{x}_1 = \frac{1}{\sigma}\mathbf{H}\lambda_1\mathbf{x}_1 = \frac{\lambda_1}{\sigma}(\sigma\mathbf{e}_1) = \lambda_1\mathbf{e}_1.$$

由于 $\mathbf{e}_1 = [1, 0, \dots, 0]^T$ , 上式中 $\mathbf{H}\mathbf{A}\mathbf{H}^T\mathbf{e}_1$ 即为矩阵 $\mathbf{H}\mathbf{A}\mathbf{H}^T$ 的第一列。因此有

$$\mathbf{H}\mathbf{A}\mathbf{H}^T = \begin{bmatrix} \lambda_1 & \mathbf{r}_1^T \\ \mathbf{0} & \mathbf{A}_1 \end{bmatrix},$$

其中 $\mathbf{A}_1 \in \mathbb{R}^{(n-1) \times (n-1)}$ ,  $\mathbf{r}_1 \in \mathbb{R}^{(n-1)}$ 。因为正交相似变换不改变矩阵特征值, 所以求矩阵 $\mathbf{A}$ 的其余特征值变为求 $n-1$ 阶矩阵 $\mathbf{A}_1$ 的特征值。若 $\lambda_2$ 是 $\mathbf{A}_1$ 的一个特征值 (假设 $\lambda_2 \neq \lambda_1$ ), 且对应的特征向量为 $\mathbf{y}_2$ , 则可证明 ?

$$\mathbf{x}_2 = \mathbf{H} \begin{bmatrix} \alpha \\ \mathbf{y}_2 \end{bmatrix}, \quad \text{其中 } \alpha = \frac{\mathbf{r}_1^T \mathbf{y}_2}{\lambda_2 - \lambda_1}$$

是 $\mathbf{A}$ 的与 $\lambda_2$ 对应的特征向量。



# 计算所有特征值的方法

■ 例(收缩技术): 已知矩阵

$$\mathbf{A} = \begin{bmatrix} 3 & -1 & 1 \\ 2 & 0 & 1 \\ 1 & -1 & 2 \end{bmatrix}$$

的一个特征值和特征向量分别是 $\lambda_1 = 2$ ,  $\mathbf{x}_1 = [1, 1, 0]^T$ , 求它的其他特征值。

使用 Householder 变换对 $\mathbf{x}_1$ 进行消元, 相应的 $\sigma = -\sqrt{2} = -1.4142$ , 所以构造 Householder 矩阵 $\mathbf{H}$ 所需的向量 $\mathbf{v}$ 为:

$$\mathbf{v} = \mathbf{x}_1 - \sigma \mathbf{e}_1 = \begin{bmatrix} 2.4142 \\ 1 \\ 0 \end{bmatrix} \Rightarrow \mathbf{w} = \mathbf{v} / \|\mathbf{v}\|_2 = \begin{bmatrix} 0.9239 \\ 0.3827 \\ 0 \end{bmatrix}$$

$$\Rightarrow \mathbf{H} = \begin{bmatrix} -0.7072 & -0.7072 & 0 \\ -0.7072 & 0.7072 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

$$\Rightarrow \mathbf{H}\mathbf{A}\mathbf{H}^T = \begin{bmatrix} 2 & 3 & -1.4142 \\ 0 & 1 & 0 \\ 0 & -1.4142 & 2 \end{bmatrix}.$$

矩阵 $\mathbf{A}$ 的其他特征值通过矩阵 $\mathbf{A}_1 = \begin{bmatrix} 1 & 0 \\ -1.4142 & 2 \end{bmatrix}$ 求得, 即 $\lambda_2 = 1$ ,  $\lambda_3 = 2$ .

# 计算所有特征值的方法

## ■ QR算法

□ “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:  $A = QSQ^T \Rightarrow Q^T A Q = S$

□  $S$  为分块上三角阵，对角块为1阶或2阶方阵

□ QR算法就是不断做正交相似变换，得到Schur分解

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

■  $A_{k+1} = Q_k^T A_k Q_k$ , 所以 $A_k$ 的特征值与 $A$ 的相同

基本QR算法

■ 可证明，序列 $\{A_k\}$ “基本收敛”到拟上三角阵 $S$ ，对角元按绝对值从大到小排列

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

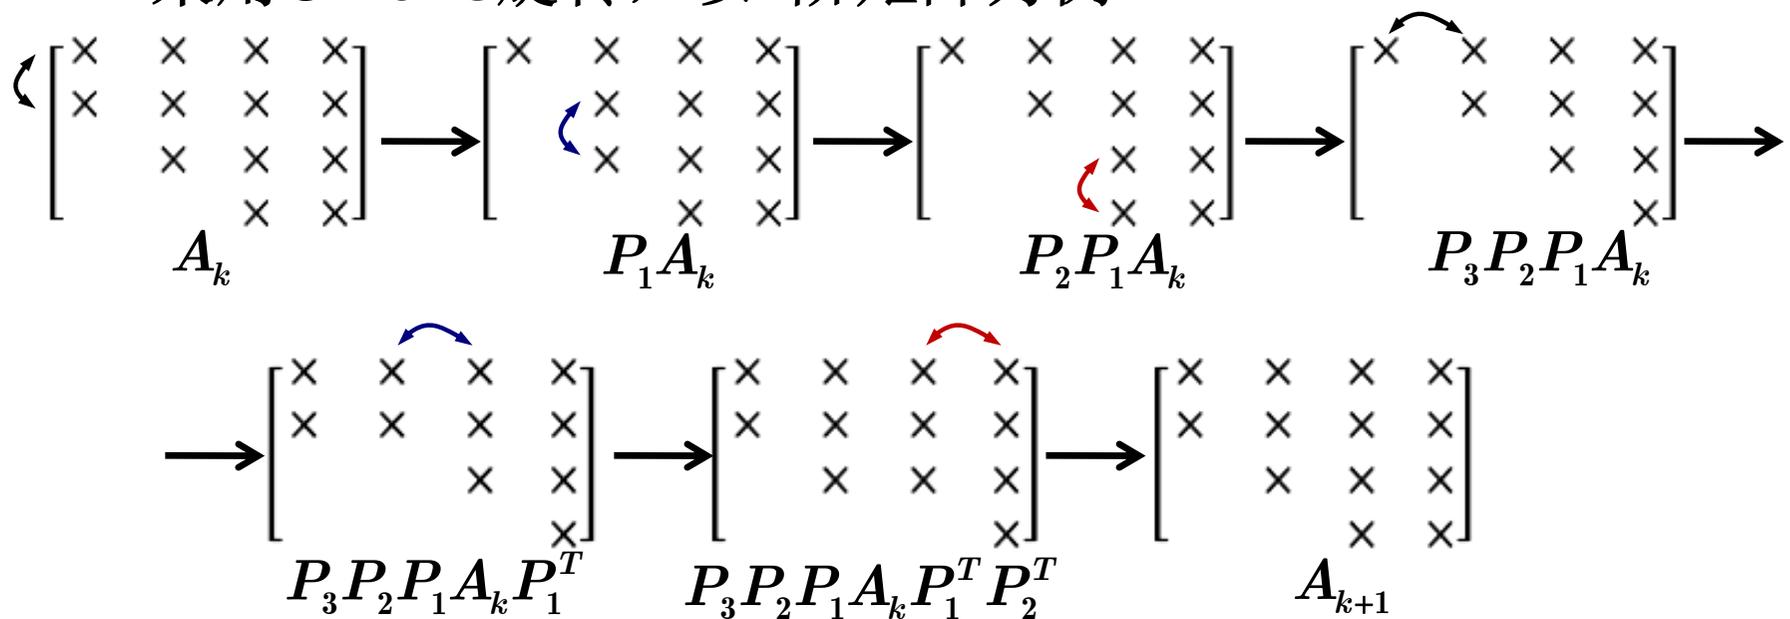
□ 实际应用，先化简为上Hessenberg阵，再使用位移技术

# 计算所有特征值的方法

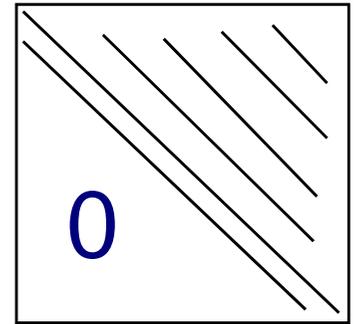
## ■ 实用的QR算法

□ 对上Hessenberg矩阵 $A_k$ 执行QR迭代

- 对 $A_k$ 进行QR分解:  $P_{n-1} \cdots P_2 P_1 A_k = R_k \Rightarrow Q_k = (P_{n-1} \cdots P_2 P_1)^T$
- 算 $A_{k+1}$ :  $A_{k+1} = R_k Q_k = P_{n-1} \cdots P_1 A_k (P_{n-1} \cdots P_1)^T = P_{n-1} \cdots P_1 A_k P_1^T \cdots P_{n-1}^T$
- 采用Givens旋转, 以4阶矩阵为例



□  $A_{k+1}$  仍是上Hessenberg阵. 随  $k \rightarrow \infty$ , 下三角元素  $\rightarrow 0$



# 计算所有特征值的方法

## ■ 实用的QR算法

- 一般矩阵化为上Hessenberg阵, 使用Householder变换

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

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

... ..

- 最终  $H_{n-1} \cdots H_1 A H_1 \cdots H_{n-1}$  为上Hessenberg阵

- 好处: 减小后续QR迭代每步计算量  
加速收敛过程

演示程序 `eigsvdgui`



矩阵元素颜色什么意思?

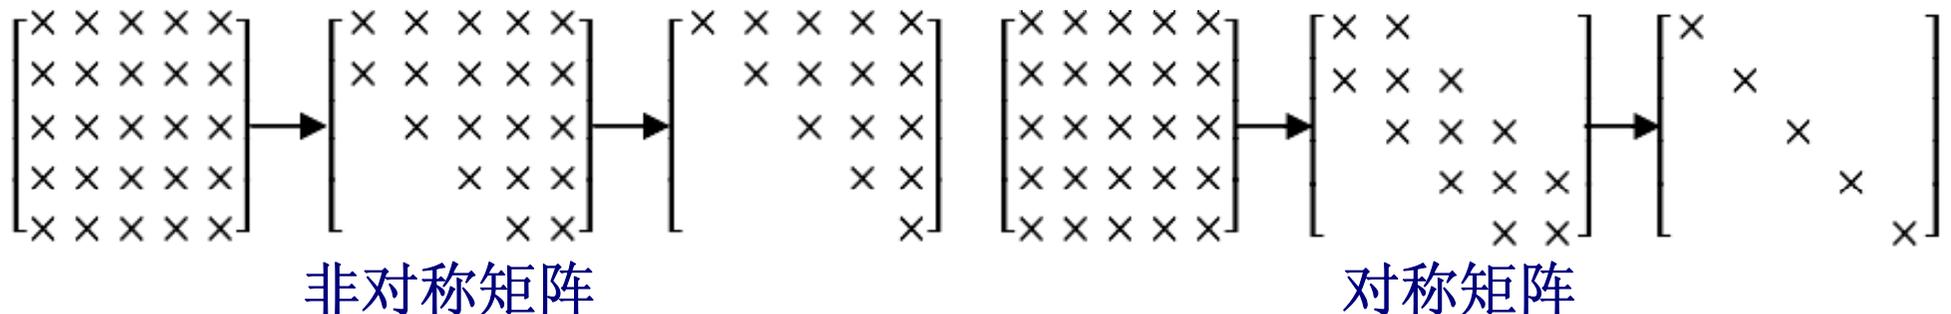
# 计算所有特征值的方法

## ■ 实用的QR算法

### □ 带位移的QR迭代

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

- 迭代矩阵序列仍正交相似，加快收敛速度，使迭代过程对更多的矩阵能收敛
- 简单策略取  $s_k$  为  $\mathbf{A}_k(n, n)$ ，还有更复杂的策略和双位移技术
- 实对称矩阵，Wilkinson证明了单位移的QR迭代过程收敛；实非对称矩阵，还没有这样的证明，理论上可能不收敛





# 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
- $[V, D] = \text{eig}(A)$ ; 返回特征值和完备特征向量组, qr算法
- 若A稀疏且对称, 也可返回所有特征值, 对其他稀疏矩阵, 或要算特征向量, 则需使用eigs命令
- 可能还会对矩阵元素进行比例调整, 保证数值稳定性

## ■ eigs命令

- 针对稀疏矩阵, Lanczos算法, Arnoldi算法
- $d = \text{eigs}(A, k)$ ; 返回最大的k个特征值, k缺省值为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, schur命令

# 期末Project安排

## □ 要求

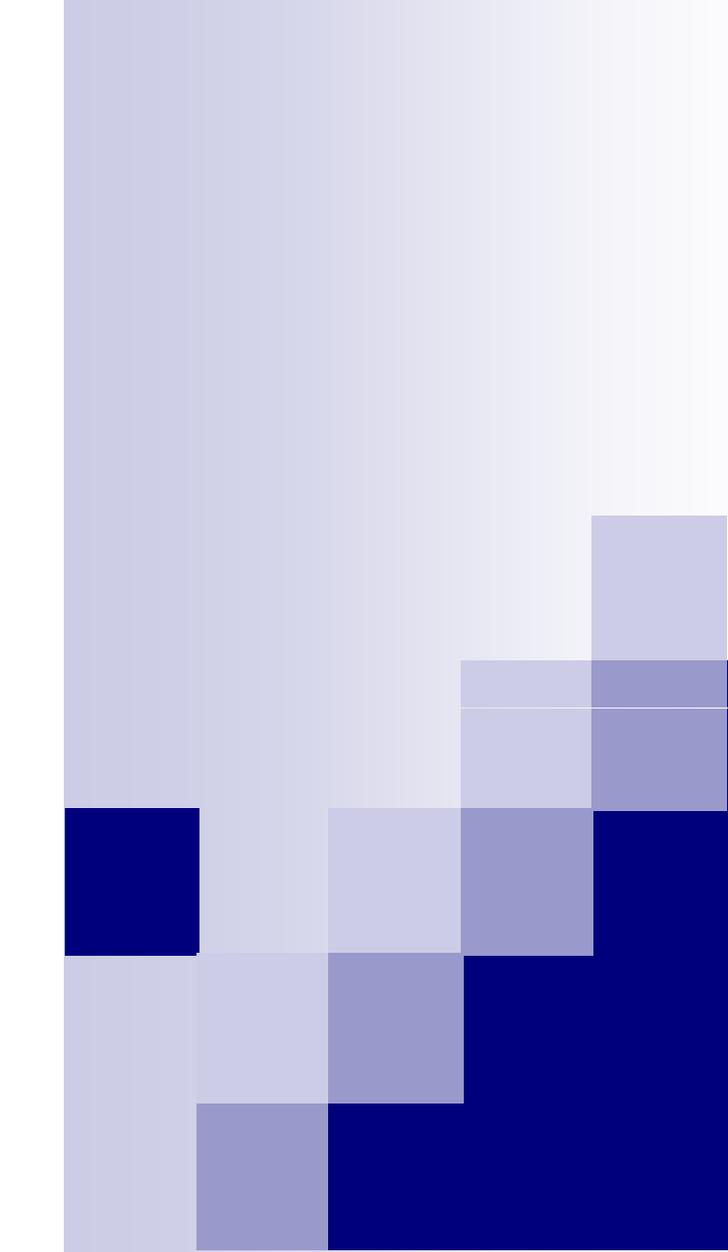
- 根据所学内容编写一个**Matlab**演示软件
- 形象地表现概念、算法、或应用，利于使用者学习巩固知识，中文界面且交互性、效率较好
- 选题可根据**Heath**网站改编，或根据教学内容自编
- 由单独的**.m**程序文件实现，设计使用者的思考编程题
- 特别欢迎有独特的创意 (若改编**NCM**需明确说明修改计划)

<http://www.cse.illinois.edu/iem/>

例: `floatshow.m`, `qformula.m`, `revste.m`, `matrix_cond.m`

## □ 时间安排

- 选题：第**12**周之前(**12月3日deadline**)，在“课程讨论”提交选题内容，获得同意，各人之间不要重复
- 完成/演示阶段：第**16**周，做课堂演示，交实验报告
- 占成绩比重：**40%**



# Singular Value Decomposition (SVD)

# Singular Value Decomposition (SVD)

## ■ 矩阵的奇异值分解

- $A$ 为 $m \times n$ 矩阵, 则  $A = U \Sigma V^T$
- $U, V$ 均为正交阵,  $\Sigma = (\sigma_{ij})$ 为 $m \times n$ 的对角阵, 且对角元素 $\geq 0$ , 称为奇异值
- 记 $\Sigma$ 的第 $i$ 个对角元为 $\sigma_i$ , 通常调整 $U, V$ 列的顺序使得奇异值按降序排列:  $\sigma_1 \geq \sigma_2 \geq \sigma_3 \geq \dots$

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \\ 10 & 11 & 12 \end{bmatrix} = U \Sigma V^T = \begin{bmatrix} .141 & .825 & -.420 & -.351 \\ .344 & .426 & .298 & .782 \\ .547 & .0278 & .664 & -.509 \\ .750 & -.371 & -.542 & .0790 \end{bmatrix}$$

只讨论 $m \geq n$ 的情况

Why?

$$\begin{bmatrix} 25.5 & 0 & 0 \\ 0 & 1.29 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} .504 & .574 & .644 \\ -.761 & -.057 & .646 \\ .408 & -.816 & .408 \end{bmatrix}$$

# Singular Value Decomposition (SVD)

## ■ 奇异值分解有关性质

□  $A^T$ 的分解:  $A = U\Sigma V^T \Rightarrow A^T = V\Sigma^T U^T$

□  $U, V$ 列向量为  $u_i, v_i$ , 称为左、右奇异向量

□  $Av_i = \sigma_i u_i$ , 即  $Av_1 = \sigma_1 u_1, Av_2 = \sigma_2 u_2, \dots$  演示程序 `eigshow`

□ 假设  $m \geq n$ , 有  $n$  个奇异值

$$A = U\Sigma V^T \Rightarrow A^T A = V \underbrace{\Sigma^T \Sigma}_{n \times n} V^T = V \begin{bmatrix} \sigma_1^2 & & & \\ & \ddots & & \\ & & \sigma_n^2 & \\ & & & \end{bmatrix} V^T$$

□ 所以奇异值是  $A^T A$  特征值的算术平方根, 是唯一的

□ 存在性的证明: 设  $A^T A$  非零特征值为  $\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2$  形成  $\Sigma_r^2$

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

令  $U_1 = AV_1 \Sigma_r^{-1}$ , 则  $U_1^T U_1 = I_r$ , 则可将  $U_1$  看作正交阵的  $r$  列

# Singular Value Decomposition (SVD)

## ■ 奇异值分解

□ 存在性的证明

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

$$A^T A = [V_1 \ V_2] \begin{bmatrix} \Sigma_r^2 & O \\ O & O \end{bmatrix} \begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} \longrightarrow \begin{matrix} AV_2 = O \\ U_1 = AV_1 \Sigma_r^{-1} \text{ 为正交阵 } r \text{ 列} \end{matrix}$$

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

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

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

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

**SVD的存在性得证!**

# Singular Value Decomposition (SVD)

## ■ 奇异向量的意义

□  $A = U\Sigma V^T \Rightarrow AV = U\Sigma$

□ 对应于非零奇异值的矩阵**U**的列,  $u_1, \dots, u_r$ 是**span(A)**的单位正交基, **U**的剩下的列是**span(A)**补空间的单位正交基

□ **0**奇异值对应的矩阵**V**的列,  $v_{r+1}, \dots, v_n$ 是**A**的核空间  $\{x \in \mathbb{R}^n : Ax = O\}$  的单位正交基

## ■ 与特征值分解的比较(m=n) $A = X\Lambda X^{-1} \Rightarrow AX = X\Lambda$

□ 特征值分解仅对非亏损阵存在, 非零特征值对应的矩阵**X**的列向量为**span(A)**的基, 但一般不正交

□ 当**A**为对称半正定时, 其特征值分解存在, 特征值 $\geq 0$

$A = Q\Lambda Q^T$  也是**SVD**, 若正定,  $\text{cond}(A)_2 = \frac{\lambda_{\max}}{\lambda_{\min}} = \frac{\sigma_{\max}}{\sigma_{\min}}$

□ 其他实对称矩阵,  $A = Q\Lambda Q^T$ 适当修改即得**SVD**分解

# Singular Value Decomposition (SVD)

## ■ 奇异值与矩阵的2-范数、条件数

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

最大  
奇异值

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

若  $A$  非奇异 ( $m=n$ ), 其奇异值均  $>0$

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

  $\text{cond}(A)_2 = \sigma_1 / \sigma_n$ 
  $\begin{bmatrix} \sigma_1^{-1} & & \\ & \ddots & \\ & & \sigma_n^{-1} \end{bmatrix}$

若  $m > n$ , 仍有  $\|A\|_2 = \sigma_1$ . 若列满秩 (奇异值  $>0$ ),

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

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

其他情况, 规定  $\text{cond}(A)_2 = \infty$

# 如何计算奇异值分解

## ■ 利用求特征值的QR算法

- 等效于求 $A^T A$ 矩阵的特征值
- 实际上不直接计算 $A^T A$ , 因为对 $A$ 施加左、右正交变换不改变它的奇异值
- 所以, 先将 $A$ 化简(Householder变换)为简单的 $B$ , 再对 $B^T B$ 执行QR迭代算法

$$\begin{aligned}
 A = \begin{bmatrix} a_1 & \cdots & \cdots & a_n \end{bmatrix} &\xrightarrow[\substack{H_1 A \\ H_1 a_1 = \alpha_1 e_1^{(m)}}]{H_1} \begin{bmatrix} \alpha_1 & \cdots & b_1^T \\ 0 & \cdots & \cdots \end{bmatrix} \xrightarrow[\substack{H_2 b_1 = \beta_1 e_1^{(n-1)}}]{H_1 A \begin{bmatrix} 1 & 0 \\ 0 & H_2 \end{bmatrix} = H_1 A T_1} \begin{bmatrix} \alpha_1 & \beta_1 & \cdots \\ 0 & \cdots & \cdots \end{bmatrix} \\
 \cdots &\longrightarrow \begin{bmatrix} \alpha_1 & \beta_1 & & \\ & \ddots & \ddots & \\ & & \beta_{n-1} & \\ & & & \alpha_n \end{bmatrix} = H_n \cdots H_1 A T_1 \cdots T_{n-1} = B \quad \text{QR迭代过程:} \\
 &\quad B_k^T B_k \text{ 为三对角矩阵, 迭代中保持其形状}
 \end{aligned}$$

演示程序: [eigsvdgui](#)

# SVD的应用

- 任意矩阵的**2-范数, 2-条件数**

$$\|A\|_2 = \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} = \sigma_{\max}, \quad \text{cond}(A)_2 = \frac{\sigma_{\max}}{\sigma_{\min}}$$

- 确定矩阵的秩: 不为零的奇异值的数目

$$AV = U\Sigma$$

span(A)  
的维数

- 解线性最小二乘问题  $Ax \cong b$

- **A列满秩, 奇异值均>0**

$$U\Sigma V^T x \cong b \longrightarrow \Sigma V^T x \cong U^T b \longrightarrow \Sigma_1 V^T x = U_1^T b \longrightarrow x = V\Sigma_1^{-1}U_1^T b$$

- **A列不满秩, 存在0奇异值**

$$\min \|U^T b - \Sigma V^T x\|_2 \xrightarrow{\text{令 } y = V^T x} \min \|U^T b - \Sigma y\|_2$$

取最小值要求  $\sigma_i y_i = u_i^T b, i = 1, \dots, r$

若y的其他分量=0, 是**2-范数**最小的解. 由于  $\|y\|_2 = \|x\|_2$ ,

得到原问题**最小范数解**:  $x = Vy = \sum_{i=1}^r v_i y_i = \sum_{i=1}^r \frac{u_i^T b}{\sigma_i} v_i$

# SVD的应用

## ■ 更一般的矩阵伪逆 (推广到列不满秩矩阵)

➤ 标量 $\sigma$ 的“伪逆”： $1/\sigma$ , 或 $0$

➤ 对角阵的伪逆  $\Sigma^+$ : 矩阵转置, 然后每个对角元求“伪逆”

➤ 一般的矩阵 $\mathbf{A}$ :

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^T, \text{ 则 } \mathbf{A}^+ = \mathbf{V}\Sigma^+\mathbf{U}^T$$

➤ 易证明, 它与 $\mathbf{A}$ 列满秩时伪逆定义兼容  $\mathbf{A}^+ = (\mathbf{A}^T\mathbf{A})^{-1}\mathbf{A}^T$ ,

➤ 任意情况下,  $\mathbf{A}\mathbf{x} \approx \mathbf{b}$ 的最小 $2$ -范数解为  $\mathbf{x} = \mathbf{A}^+\mathbf{b}$

➤ 其他伪逆的性质:

$$(\mathbf{A}^+)^+ = \mathbf{A}$$

$$(\mathbf{A}^T)^+ = (\mathbf{A}^+)^T$$

$$\|\mathbf{A}^+\|_2 = 1/\sigma_r$$

# SVD的应用

## ■ 低秩矩阵近似 (Low rank matrix approximation)

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

其中  $E_i = u_i v_i^T$ ,  $i = 1, \dots, n$ , 它秩为**1**, 奇异值  $\sigma_1 = 1$ , 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

忽略小奇异值对应求和项, 称  $\tilde{A} = \sum_{i=1}^k \sigma_i E_i$

$$\|E_i\|_2 = 1$$

为**A**的秩**k**近似, 可证明, 以**Frobenius**范数度量, 在所有秩为**k**的矩阵中, 它最接近**A**

演示程序 [svd\\_appl.m](#)

在图像处理、数据压缩、信息抽取等方面都有应用

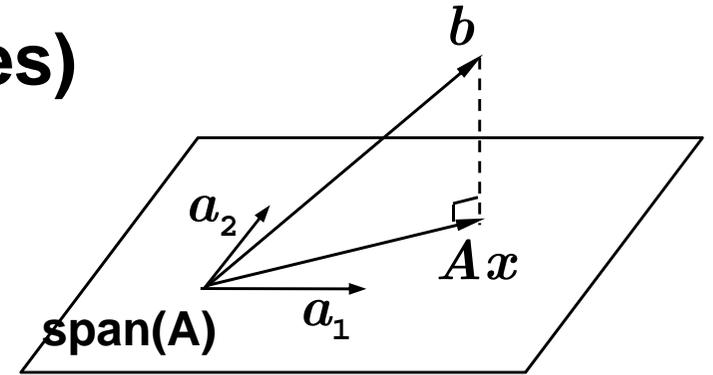
若**A**实对称, 从合同标准型导出类似公式, 其中  $E_i$  更简单

PCA, PFA

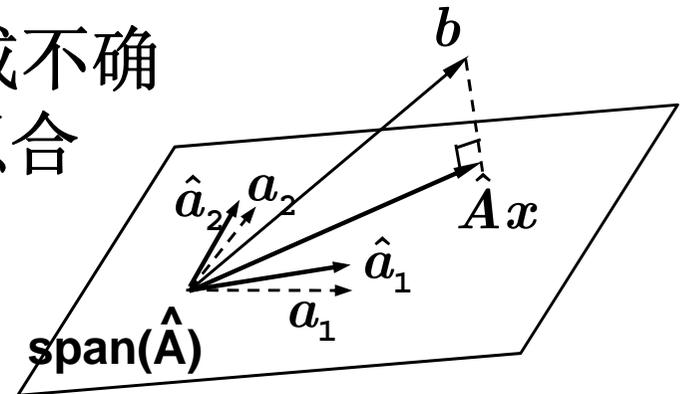
# SVD的应用

## 完全最小二乘问题 (Total least squares)

普通线性最小二乘问题: 
$$\begin{bmatrix} a_1 & \cdots & a_n \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} = Ax \approx b$$



假设  $b$  的数据有误差, 而模型数据, 即  $A$  准确, 数据点到曲线垂直距离最小  
 完全最小二乘问题: 所有数据都有误差或不确定性, 包括  $A$  中的数据, 要求  $b$  和  $A$  到拟合“平面”总的2-范数距离最小



设  $y = \hat{A}x$ ,  $x$  为待求的参数, 则

$$\begin{bmatrix} \hat{A} & y \end{bmatrix} \approx \begin{bmatrix} A & b \end{bmatrix}$$

解法: 用SVD求  $\begin{bmatrix} A & b \end{bmatrix}$  的秩  $n$  近似

列秩:  $n$   $(n+1)$   
 若  $\begin{bmatrix} A & b \end{bmatrix} = U \Sigma V^T$ , 则  $\begin{bmatrix} \hat{A} & y \end{bmatrix} = U \hat{\Sigma} V^T$ ,  
 $\hat{\Sigma}$  由将  $\Sigma$  中  $\sigma_{n+1}$  变为  $0$  得到

$$\begin{bmatrix} \hat{A} & y \end{bmatrix} \begin{bmatrix} x \\ -1 \end{bmatrix} = 0$$

$\begin{bmatrix} x \\ -1 \end{bmatrix}$  与  $v_{n+1}$  成比例

# SVD的应用

## ■ 完全最小二乘问题的例子

用模型函数  $f(t) = xt$

拟合数据:

t	-2	-1	3
y	-1	3	-2

常规最小二乘问题拟合结果:  $x = -0.5$

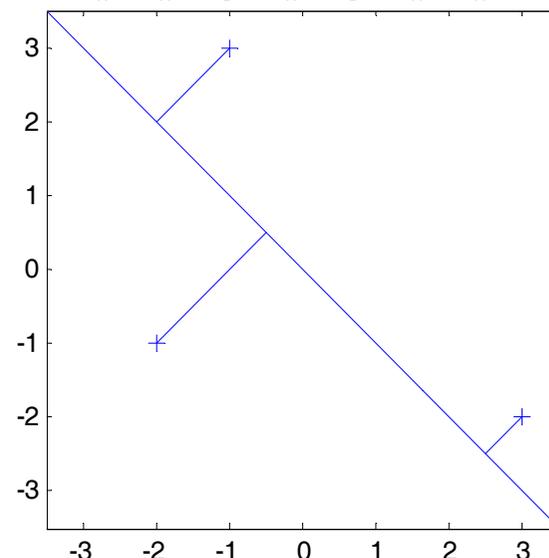
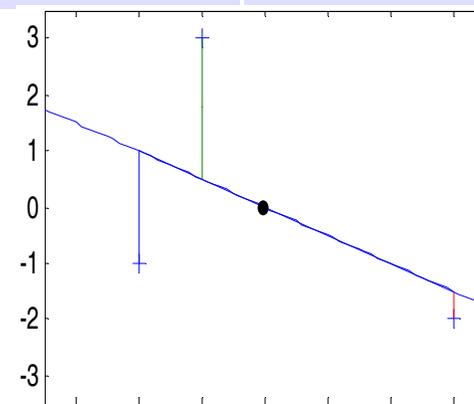
完全最小二乘拟合:

$$[A \quad b] = \begin{bmatrix} -2 & -1 \\ -1 & 3 \\ 3 & -2 \end{bmatrix} = \begin{bmatrix} -0.154 & 0.802 & 0.577 \\ -0.617 & -0.533 & 0.577 \\ 0.772 & -0.267 & 0.577 \end{bmatrix}$$

$$\begin{bmatrix} 4.583 & 0 \\ 0 & 2.646 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 0.707 & -0.707 \\ -0.707 & -0.707 \end{bmatrix} \rightarrow x = \frac{v_{n+1}(1:n)}{-v_{n+1}(n+1)} = -1$$

$$\begin{bmatrix} \hat{A} & \hat{y} \\ \downarrow & \downarrow \\ \hat{t} & \hat{y} \end{bmatrix} \approx \begin{bmatrix} A & b \\ \downarrow & \downarrow \\ t & y \end{bmatrix}$$

所有过原点直线中，数据点到该线垂线距离平方和最小!



# Matlab命令与方法比较

## ■ Matlab中svd命令

- $s = \text{svd}(X)$ ;  $[U, S, V] = \text{svd}(X)$ ; 返回奇异值, 或完整分解
- $[U, S, V] = \text{svd}(X, 0)$ ;  $[U, S, V] = \text{svd}(X, 'econ')$ ; 分解的简化形式,  $S$ 为方阵,  $U$ 或 $V$ 为正交阵的一部分

## ■ 方法间比较

- 解线性最小二乘问题, 正交变换法最稳定、准确, 但计算量可能比法方程方法大(**Householder**变换,  $m \gg n$ )
- 对(近似)秩亏损问题, 只能用列主元正交变换法, 或基于**SVD**的方法, 后者更可靠, 计算量则更大
- 奇异值、特征值分解联系紧密, 前者似乎更易用一些

## Some useful Matlab commands (2)

- **Constants:** realmin, realmax, eps, Inf, -Inf, NaN
- **Logical:** isinf, isfinite, isnan
- **Floating point arithmetic:** single, double, **vpa**
- **Operators:** \ (back slash)
- **Matrices:** zeros, ones, eye, diag, rand, cond, condest, **rank**, det, inv, eig, tril, triu, sparse, issparse, speye, spones, spdiags, sprand, nnz, full, eigs
- **Graphs:** spy
- **Algorithms:** lu, chol, qr, eig, svd, hess, schur, polyfit

## ■ 本节内容小结

- 矩阵的奇异值分解的概念
- 分解的存在性, 唯一性
- 奇异向量的意义
- 奇异值与**2-范数, 2-条件数**
- 计算奇异值的算法
- 奇异值分解的应用
  - **2-范数、条件数, 矩阵的秩**
  - **解秩亏损的线性最小二乘问题, 最小2-范数解**
  - **一般的伪逆定义**
  - **低秩矩阵近似**
  - **完全最小二乘问题的求解**

# Assignment

- 阅读课本第三章, 第四章有关内容
- 阅读文献: (“教学资源”--“top 10 algorithm”)
- B. N. Parlett, “The QR Algorithm,” Computing in Science and Engineering, Vol. 2, No. 1, pp. 38-44, 2000
- 作业题见网络学堂