

# 高等数值算法与应用(2)

– 线性方程组求解 (chap2) –

喻文健

# Outline

- ▶ 高斯消去法与LU分解
- ▶ 误差分析
- ▶ 稀疏矩阵与条带状矩阵
- ▶ Google的PageRank
- ▶ 对称正定矩阵的Cholesky分解



# 高斯消去法与LU分解

- 解线性方程组的基本概念与方法
- 排列阵、上/下三角阵的求解
- 基于部分主元LU分解的方法
- 相关Matlab程序

# 求解线性方程组

▶ 方程 
$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \cdots \\ a_{m1}x_1 + a_{m2}x_2 + \cdots + a_{mn}x_n = b_m \end{cases}$$

- 若  $m > n$ , 超定方程组, 一般无解 (但有最小二乘解)
- 若  $m < n$ , 一般有无穷多解, 需加其他条件 (约束优化, 等)
- $m = n$ , 线性方程组求解问题, 矩阵形式为

$$Ax = b, \quad A \in \mathbb{R}^{n \times n}, b \in \mathbb{R}^n$$

- **复习:** 奇异/非奇异矩阵, 解的存在性与唯一性, ...
- $x = A^{-1}b$ , 但实际上, 计算  $A^{-1}$  不但没必要也很不明智
- **例:**  $7x = 21$ ,  $x = 7^{-1} * 21 = 0.142857 * 21 = 2.99997$

而且计算量大

# 求解线性方程组

## ▶ Matlab反斜线算符

- $\backslash$  : backward slash
- 线性方程组  $AX=B$ , 求解命令为  $X=A\backslash B$
- 由于A在左边,  $\backslash$  也称为“左除”算符
- 求解方程组  $YA=B$  的命令:  $Y=B/A$ . 称  $/$  为“右除”
- 左除运算与右除运算有何关系?

## ▶ 求解线性方程组的一个例子

$$\begin{pmatrix} 10 & -7 & 0 \\ -3 & 2 & 6 \\ 5 & -1 & 5 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 4 \\ 6 \end{pmatrix} \longleftrightarrow \begin{cases} 10x_1 - 7x_2 & = 7 \\ -3x_1 + 2x_2 + 6x_3 & = 4 \\ 5x_1 - x_2 + 5x_3 & = 6 \end{cases}$$

- 用第1个方程消其他方程中的  $x_1$

# 求解线性方程组

- ▶ 求解线性方程组的一个例子 (第1个方程乘0.3, -0.5)
  - 第1个方程 $x_1$ 的系数称为主元(pivot), 即**矩阵对角元**
  - 当前列其他系数除以主元, 得到“**乘子**”: -0.3, 0.5

$$\begin{pmatrix} 10 & -7 & 0 \\ -3 & 2 & 6 \\ 5 & -1 & 5 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 4 \\ 6 \end{pmatrix} \Rightarrow \begin{pmatrix} 10 & -7 & 0 \\ 0 & -0.1 & 6 \\ 0 & 2.5 & 5 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 6.1 \\ 2.5 \end{pmatrix}$$

- 用第2、第3个方程可消去其中一个的 $x_2$ . 考虑到-0.1较小, 不适合当主元, 交换第2、3个方程 (**选主元**)

消元时, **乘子**为-0.04

$$\begin{pmatrix} 10 & -7 & 0 \\ 0 & 2.5 & 5 \\ 0 & -0.1 & 6 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 2.5 \\ 6.1 \end{pmatrix} \Rightarrow \begin{pmatrix} 10 & -7 & 0 \\ 0 & 2.5 & 5 \\ 0 & 0 & 6.2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 2.5 \\ 6.2 \end{pmatrix}$$

最后一个方程  $6.2x_3 = 6.2 \Rightarrow x_3 = 1$

# 求解线性方程组

## 求解线性方程组的一个例子

- 将  $x_3 = 1$  代回前面方程，依次解出  $x_2, x_1$



$$x = \begin{pmatrix} 0 \\ -1 \\ 1 \end{pmatrix}$$

$$\begin{pmatrix} 10 & -7 & 0 \\ 0 & 2.5 & 5 \\ 0 & 0 & 6.2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 2.5 \\ 6.2 \end{pmatrix}$$

$$\begin{pmatrix} 10 & -7 & 0 \\ -3 & 2 & 6 \\ 5 & -1 & 5 \end{pmatrix} \begin{pmatrix} 0 \\ -1 \\ 1 \end{pmatrix} = \begin{pmatrix} 7 \\ 4 \\ 6 \end{pmatrix}$$

- 用原始方程验证解的正确性

- 消去过程的描述(仅看A):  $M_2 P_2 M_1 A = U$

- 行交换矩阵  $P_2$  为

$$\Rightarrow P_2 M_1 A = M_2^{-1} U \Rightarrow P_2 M_1 P_2 P_2 A = M_2^{-1} U$$

$$\Rightarrow P_2 A = \underbrace{(P_2 M_1 P_2)^{-1}}_{L} M_2^{-1} U$$

$$P_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$

由乘子填充  
执行行交换

$$L = \begin{pmatrix} 1 & 0 & 0 \\ 0.5 & 1 & 0 \\ -0.3 & -0.04 & 1 \end{pmatrix}$$

- 矩阵A与L, U的关系:  $PA=LU$   
称为部分主元LU分解 (P排列阵)

# 排列阵与上(下)三角阵

- ▶ **排列阵**(permutation matrix): 单位阵经一系列行、列交换而得. 每行(列)上有且仅有一个1, 其余为0

- 例: 
$$P = \begin{pmatrix} 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix}$$

- $PA \sim$  对A作**行重列**
- $AP \sim$  对A作**列重列**

- 用**向量**p表示单位阵各行的新顺序, 易得排列阵
- $I(p, :)$  就是排列阵P
- 注意“:”的用法
- $A(p, :)$ 实现矩阵A的行重排
- 求解系数为排列阵的方程

1:n的一个重排序

```
>> p = [4 1 3 2];  
>> I = eye(4, 4); P = I(p, :)
```

```
>> P*A  
>> A(p, :) %计算速度快, 省内存
```

$$Px = b \Rightarrow x = P^T b \quad P \text{ 为正交阵 ? !}$$



# 排列阵与上(下)三角阵

## ▶ 系数矩阵为上(下)三角阵的方程

- 矩阵的LU分解得: 上三角阵U, **单位**下三角阵L

$$U = \begin{pmatrix} 10 & -7 & 0 \\ 0 & 2.5 & 5 \\ 0 & 0 & 6.2 \end{pmatrix} \quad L = \begin{pmatrix} 1 & 0 & 0 \\ 0.5 & 1 & 0 \\ -0.3 & -0.04 & 1 \end{pmatrix}$$

- 解 $Ux=b$ 的两种“回代”(backsubs)

```
x = zeros(n, 1);  
for k = n: -1: 1  
    j = k+1:n;  
    x(k)=(b(k)-U(k, j)*x(j))/ U(k,k)  
end
```

用U的行和解出的部分x作内积

```
x = zeros(n, 1); b;  
for k= n: -1: 1  
    x(k) = b(k)/ U(k, k);  
    i = 1: k-1;  
    b(i) = b(i) - x(k) *U(i, k)  
end
```

从b中依次减去U某列的倍数

先LU分解, 再解x:  $PA=LU \implies x=U^{-1}(L^{-1}Pb)$

# 部分主元LU分解程序

- ▶ 为什么必须选主元？
  - 保证算法不中断；防止小主元导致的误差传播

乘子  $m_{ik} = a_{ik}^{(k)} / a_{kk}^{(k)}$  主元

## ▶ lutx程序

- “原地存储”方式 (KIJ version)

$$\begin{bmatrix}
 a_{11} & a_{12} & a_{13} & \cdots & a_{1n} \\
 a_{21} & a_{22} & a_{23} & \cdots & a_{2n} \\
 a_{31} & a_{32} & a_{33} & \cdots & a_{3n} \\
 \vdots & \vdots & \vdots & \ddots & \vdots \\
 a_{n1} & a_{n2} & a_{n3} & \cdots & a_{nn}
 \end{bmatrix}$$

最大值,位置索引

交换两行

算乘子

更新未消去部分

```

function [L,U,p] = lutx(A)
[n,n] = size(A);
p = (1:n)';
for k = 1:n-1
    [r,m] = max(abs(A(k:n,k)));
    m = m+k-1;
    if (A(m,k) ~= 0)
        if (m ~= k)
            A([k m],:) = A([m k],:);
            p([k m]) = p([m k]);
        end
        i = k+1:n;
        A(i,k) = A(i,k)/A(k,k);
        j = k+1:n;
        A(i,j) = A(i,j) - A(i,k)*A(k,j);
    end
end
end
    
```

# 部分主元LU分解程序

## ▶ Matlab中的程序

- 前一页程序加两行算L, U:
- 使用向量/矩阵运算提高效率
- **lu**: 部分主元LU分解; lutx为其简化版
- **\**: 解单个/多个右端项的线性方程组
- bslashtx.m是“\”的简化版, 它检测三种特殊情况做处理
- 调用forward, backsubs求解下三角、上三角线性方程组
- 请自己看bslashtx程序的源码!
- lugui是NCM中一个演示程序, 试验4种选主元策略: **手工, 对角线, 部分主元, 全主元**

```
L = tril(A, -1) + eye(n, n);  
U = triu(A);
```

UMFPACK/CHOLMOD

稀疏阵

(Basic Linear Algebra Subpro

稠密阵 → Lapack + BLAS

```
>> lugui
```

看演示网站第2.4个演示, *操作与思考*

# 误差分析

- » 残差小、误差大的情况  
敏感性分析-矩阵条件数  
舍入误差对结果的影响

# 残差小、误差大的情况

- ▶  $x_*$  为解方程  $Ax = b$  得到的数值解,  $\neq$  准确解  $x$ 
  - 误差:  $e = x_* - x = -(x - x_*)$
  - 残差向量(residual, 剩余):  $r = b - Ax_* = A(x - x_*)$
  - 常常用残差评估计算准确度. 但可能残差小、误差大
  - 例: 在3位有效数字(10进制)的机器上求解

$$\begin{pmatrix} 0.780 & 0.563 \\ 0.913 & 0.659 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0.217 \\ 0.254 \end{pmatrix} \quad \text{解出: } x_2 = \frac{0.001}{0.001} = 1.00$$

交换行, 消元

$$\begin{pmatrix} 0.913 & 0.659 \\ 0 & 0.001 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0.254 \\ 0.001 \end{pmatrix} \quad \begin{array}{l} \text{准确解为:} \\ x = \begin{pmatrix} 1 \\ -1 \end{pmatrix} \end{array} \quad x_1 = \frac{0.254 - 0.659x_2}{0.913} = -0.443 \text{ (保留3位)}$$

若不知道准确解, 计算残差

$$r = \begin{pmatrix} 0.217 - ((0.780)(-0.443) + (0.563)(1.00)) \\ 0.254 - ((0.913)(-0.443) + (0.659)(1.00)) \end{pmatrix} = \begin{pmatrix} -0.000460 \\ -0.000541 \end{pmatrix}$$

# 误差分析

## ▶ 数值求解方程 $Ax = b$

- 上例：舍入误差造成解误差大，但残差很小（相对量）
- 改用6位有效数字重算(减小舍入误差)，可得很准确的解
- 另一个不可忽视的原因：系数矩阵接近奇异
- 一个重要事实：采用部分选主元的高斯消去法，可以保证解对应的残差  $b - Ax_*$  相对较小

## ▶ 线性方程组求解的误差分析

- 1.系数矩阵与右端项上有数值扰动 (敏感性)
- 2.线性方程组是精确的，考虑计算中的舍入误差
- 对情况1，与  $A$  矩阵的近奇异性有关(病态矩阵 vs. 单位阵)  
严格讨论，需使用矩阵条件数的概念

# 范数与矩阵条件数

## 常用的向量范数

- 1-范数:  $\|x\|_1 = \sum_{i=1}^n |x_i|$
- 2-范数:  $\|x\|_2 = (\sum_{i=1}^n |x_i|^2)^{1/2}$
- $\infty$ -范数:  $\|x\|_\infty = \max_{1 \leq i \leq n} |x_i|$
- 例子: 在二维坐标系中按不同范数绘出的“单位圆”
- `norm`命令(默认2范数)


```
>> x = (1:4) / 5  
>> norm1 = norm(x, 1)  
>> norm2 = norm(x)  
>> norminf = norm(x, inf)
```

$$\|x\|_p = (\sum_{i=1}^n |x_i|^p)^{1/p}, p \geq 1$$

(曼哈顿范数)

(欧氏距离)

(“最大”范数)



# 范数与矩阵条件数

## ▶ 矩阵条件数

- 不同的 $x$ ,  $Ax$ 的范数可能差别很大
- 有两个极端情况:
- 其比值反映 $A$ 的性质, 称为“矩阵条件数”

$$\kappa(A) = \frac{\max \frac{\|Ax\|}{\|x\|}}{\min \frac{\|Ax\|}{\|x\|}}$$

对于奇异阵,  $m=0$ ,  
条件数为无穷大

$\|A\|$  与向量范数相容:  
 $\|Ax\| \leq \|A\| \cdot \|x\|$

$$M = \max \frac{\|Ax\|}{\|x\|}, \quad m = \min \frac{\|Ax\|}{\|x\|}$$

## ▶ 敏感性分析

- 改变右端项,  $A(x + \delta x) = b + \delta b$
- 矩阵条件数是数据传递误差的上限情况
- 对于系数矩阵上的扰动, 有类似结果

$$\frac{\|\delta x\|}{\|x\|} \leq \kappa(A) \frac{\|\delta b\|}{\|b\|}$$

(可达到, 见pp.58)

敏感性分析不  
考虑具体解法



# 范数与矩阵条件数

## ▶ 矩阵条件数的性质

$$\kappa(A) = \frac{\max \frac{\|Ax\|}{\|x\|}}{\min \frac{\|Ax\|}{\|x\|}}$$

- $\kappa(A) \geq 1$

- $\kappa(P) = 1$

(排列阵)  $\kappa(A)$ 描述奇异程度,而行列式不能

- $\kappa(cA) = \kappa(A)$

- $\kappa(D) = \frac{\max |d_{ii}|}{\min |d_{ii}|}$

$$\det \begin{bmatrix} 0.1 & & \\ & \ddots & \\ & & 0.1 \end{bmatrix}_{100} = 10^{-100}$$

- Matlab中计算/估算条件数: `cond(A)`, `cond(A, 1)`, `condest(A)`

## ▶ 矩阵范数

- $\|A\| = \max \frac{\|Ax\|}{\|x\|}$


注意,  $\min \frac{\|Ax\|}{\|x\|} = \frac{1}{\|A^{-1}\|}$

$$\kappa(A) = \|A\| \|A^{-1}\|$$

- $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$ ,  $\|A\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$

- $\|A\|_2$ 的计算涉及奇异值分解SVD


```
>> norm2 = norm(A)
```



# 舍入误差对结果的影响

J. H. Wilkinson

矩阵计算的舍入误差分析



## 高斯消去法的舍入误差分析

设数值解  $x_*$  精确满足  $(A + E)x_* = b$  (绝对值)

from Golub's 进行LU分解的解法:  $|E| \leq n\epsilon_{\text{mach}}(3|A| + 5|\hat{L}||\hat{U}|)$

$\frac{\|E\|}{\|A\|} \lesssim n\rho\epsilon_{\text{mach}}$ , 其中  $\rho = \frac{\max_{i,j} |\hat{u}_{ij}|}{\max_{i,j} |a_{ij}|}$  (增长因子)

不选主元,  $\rho$  可任意大, 部分选主元,  $\rho$  一般  $\leq 10$

两个重要结论

高斯消去, 残差:  $b - Ax_* = Ex_*$

$$\|b - Ax_*\| \leq \|E\| \|x_*\| \implies \frac{\|b - Ax_*\|}{\|A\| \|x_*\|} \leq \frac{\|E\|}{\|A\|} \lesssim n\rho\epsilon_{\text{mach}}$$

相对残差

理论上限  $2^{n-1}$



高斯消去, 解误差:  $x - x_* = A^{-1}(b - Ax_*)$

$$\|x - x_*\| \leq \|A^{-1}\| \|E\| \|x_*\| \implies \frac{\|x - x_*\|}{\|x_*\|} \lesssim n\rho \frac{\|A\| \|A^{-1}\|}{\text{条件数}\kappa(A)} \epsilon_{\text{mach}}$$

# 舍入误差对结果的影响

## ▶ 高斯消去法的舍入误差分析

增长因子  $\rho$  很小

- 一般情况下, **部分主元**高斯消去(LU分解)的**相对残差**很小
- 若问题不病态(矩阵条件数不很大), 且使用**部分主元**高斯消去法, 则将得到很**准确的解**
- 若不选主元, 则**相对残差**、**解的误差**都可能很大
- 更一般的两个结论:

$$\frac{\|b - Ax_*\|}{\|A\|\|x_*\|} \leq \frac{\|E\|}{\|A\|}$$

相对残差大, 说明  
方程求解算法**不稳定**

$$\frac{\|x - x_*\|}{\|x_*\|} \leq \frac{\|E\|}{\|A\|} \|A\|\|A^{-1}\|$$

解的误差受**算法稳定性**  
与**问题敏感性**共同影响



# 稀疏矩阵与条带状矩阵

- » 基本概念
- 存储格式与生成矩阵
- 带状矩阵方程的求解

# 基本概念

## ► 稀疏矩阵 (sparse matrix)

- 存在大量零元素的矩阵 非零元数目为 $O(n)$
- Wilkinson's definition: "*matrices that allow special techniques to take advantage of the large number of zero elements.*"
- 强调采用特殊技术提高计算与处理效率 (不处理零元素)
- 用二维数组存储的矩阵, 即使有些零元素, 也不算稀疏矩阵
- 非零元的数目、稀疏度
- 带状矩阵(band matrix):



带宽: 非零元到主  
对角线的最大距离

(有些书也称之为“半带宽”)

```
>>density= nnz(A)/prod(size(A))  
>>sparsity= 1- density
```

```
>>[i, j]= find(A)  
>>bandwidth= max(abs(i-j))
```

# 存储格式

$$A = \begin{bmatrix} 1 & 0 & 2 & 0 & 0 \\ 3 & 4 & 0 & 5 & 0 \\ 6 & 0 & 7 & 0 & 8 \\ 0 & 9 & 0 & 10 & 0 \\ 0 & 0 & 0 & 0 & 11 \end{bmatrix}$$

## ▶ 存储稀疏矩阵的数据结构

### ◦ 三元组 (COO格式)

aa	1	2	5	3	4	6	7	8	9	10	11
row	1	1	2	2	2	3	3	3	4	4	5
col	1	3	4	1	2	1	3	5	2	4	5

- 非零元的排列顺序可任意; 冗余: 连续的相同行编号

### ◦ 压缩稀疏行 (CSR格式)

关键是方便操作某行

aa	1	2	5	3	4	6	7	8	9	10	11
col	1	3	4	1	2	1	3	5	2	4	5
proW	1	3	6	9	11	12					

- 按第1行, 第2行, ... 顺序存非零元; proW为各行第一个元素位置

### 压缩稀疏列 (CSC格式)

aa	1	3	6	4	9	2	7	5	10	8	11
row	1	2	3	2	4	1	3	2	4	3	5
pcol	1	4	6	8	10	12					

# 存储格式

## ▶ Matlab中的稀疏矩阵

- 采用压缩稀疏列(CSC)方式存储
- 相反的矩阵格式转换
- 若阶数很大, 稠密格式A无法存  
可直接用**sparse**命令生成
- (相当于用COO格式输入数据)
- **spdiags**生成带状稀疏矩阵
- **spy**看矩阵的非零元分布

```
>>S = sparse(A)
```

```
>>A = full(S)
```

```
>>S = sparse(i, j, x, m, n)
```

生成的S满足  $\begin{cases} [i, j, x] = \text{find}(S) \\ [m, n] = \text{size}(S) \end{cases}$

```
>>S = spdiags([a b c], [-1, 0, 1], n, n)
```

whos看变量类型

```
>>whos
```

Name	Size	Bytes	Class	Attributes
A	20x20	3200	double	
S	20x20	528	double	<code>{sparse}</code>

# 方程求解

## ▶ Matlab中对稀疏矩阵处理

- 大多数矩阵运算和函数可直接用于稀疏矩阵
- 例如：“\”会判断稀疏矩阵，并用高效的特殊算法求解
- 非零元数目`nnz(S)`是影响运算时间与存储量的主要因素

## ▶ 三对角系数矩阵的方程求解

$$\begin{pmatrix} b_1 & c_1 & & & \\ a_1 & b_2 & c_2 & & \\ & a_2 & b_3 & c_3 & \\ & & \ddots & \ddots & \ddots \\ & & & a_{n-2} & b_{n-1} & c_{n-1} \\ & & & & a_{n-1} & b_n \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_{n-1} \\ x_n \end{pmatrix} = \begin{pmatrix} d_1 \\ d_2 \\ d_3 \\ \vdots \\ d_{n-1} \\ d_n \end{pmatrix}$$

- 若需选主元，用`spdiags`生成A  
再用“\”算符

```
function x = tridisolve(a,b,c,d)
x = d; n = length(x);
for j = 1:n-1
    mu = a(j)/b(j);
    b(j+1) = b(j+1) - mu*c(j);
    x(j+1) = x(j+1) - mu*x(j);
end
x(n) = x(n)/b(n);
for j = n-1:-1:1
    x(j) = (x(j)-c(j)*x(j+1))/b(j);
end
```



# Matlab中处理稀疏矩阵小结

- ▶ 生成或转换成稀疏矩阵
  - `sparse(X)` or `sparse(i, j, s, m, n)`; `sparse(m, n)`
- ▶ 显示矩阵非零元分布: `spy(X)`
- ▶ 构造特殊的稀疏矩阵
  - `speye(n, m)`; `spones(pattern)`; `spdiags(B, d, m, n)`
- ▶ 随机稀疏矩阵生成器
  - `sprand(S)` or `sprand(m, n, density)`
- ▶ 统计非零元数目, 获取非零元信息
  - `nnz(X)`; `nonzeros(A)`, `find(X)` (索引, 三元组); `nzmax` (存储空间)
- ▶ 其他: `\`, `lu`, `qr`, `svd`等各种运算都支持稀疏矩阵

# Google的PageRank

- » PageRank及其数学问题
- 迭代计算的收敛性
- 三种计算方法
- 实用的幂法程序

# PageRank™的计算


## ▶ Google网络搜索

- PageRank技术是其创立之初的**关键创新**之一
- 搜索分两步：**找到匹配关键词的网页**，对它们**排序显示**
- L. Page和S. Brin于1998年提出PageRank算法
- 给出网页信息可靠/重要性的指标(**PageRank**)，带来突破
- 怎样的网页PageRank高? 被推荐，被**链接到**

## ▶ 数学模型

- $n$ : 网页的总数,  $G = (g_{ij})_{n \times n}$ : 网页链接矩阵

- 若网页 **$j$** 链接到网页 **$i$** , 则 **$g_{ij} = 1$** ,  
否则 **$g_{ij} = 0$**   
$$G = \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 1 & 1 & 0 \end{bmatrix}$$



大规模、非对称、稀疏阵

# PageRank™的计算

## ▶ 数学模型(续)

- $G$ 的列元素之和 $c_j = \sum_i g_{ij}$ , 等于网页j的“出度”
- 访问网页的Markov过程, 到达网页的极限概率定义为它的PageRank (按概率 $p$ 沿链接跳, 按概率 $1-p$ 随便跳)

- 设当前在网页j、下一步到网页i的条件概率为 $a_{ij}$ :

$$\begin{array}{l}
 \text{i在j的链接上: } p \cdot 1/c_j + (1-p) \cdot 1/n \xrightarrow{\text{乘 } g_{ij}} \\
 \text{i不在j的链接上: } (1-p) \cdot 1/n \xrightarrow{\text{乘 } (1-g_{ij})}
 \end{array}
 \Rightarrow a_{ij} = \frac{p g_{ij}}{c_j} + \frac{1-p}{n}$$

$\delta$

- 若 $c_j = 0$ 呢?  $a_{ij} = 1/n$
- $a_{ij}$ 组成转移概率矩阵 $A$ : 
$$A = pGD + \delta \mathbf{e} \mathbf{e}^T, D = \text{diag}(1/c_j)$$
- $$A = pGD + \mathbf{e} \mathbf{f}^T, f_j = \begin{cases} \delta, & c_j \neq 0 \\ 1/n, & c_j = 0 \end{cases}$$

- 设 $\mathbf{x}^{(k)}$ 为第k次跳转后在各个网页的概率, 则

$$\mathbf{x}^{(k+1)} = A \mathbf{x}^{(k)}$$

为再跳一次后, 在各网页的概率

# PageRank™的计算

## ▶ 数学模型(续)

- PageRank: 随机“冲浪”过程访问网页的**极限**概率

$$\mathbf{x}^{(k+1)} = A\mathbf{x}^{(k)}$$

$$\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = ?$$

它存在吗?

## ▶ 迭代过程收敛性分析

- 数学本质: **求1对应的特征向量** $\mathbf{x}$

$$\begin{cases} A\mathbf{x} = \mathbf{x} \\ \sum_{i=1}^n x_i = 1 \end{cases}$$

- 矩阵 $A$ 的特点:  $a_{ij} > 0$ , 第 $j$ 列元素之和为1

- $|\lambda(A)| \leq \|A\| = 1$ ;  $A^T \mathbf{e} = \mathbf{e} \implies 1$  是主特征值


- 幂法的迭代过程一定收敛!

- ▶ 计算中不需对 $\mathbf{x}^{(k)}$ 规格化;  
实际用时**不形成**矩阵 $A$

“圆盘定理”

$A^T$ 的第 $j$ 个圆盘

**唯一主特征值!**



可证明是单的,  
因此极限概率唯一

# PageRank™的计算

- ▶ 一个小型的例子(设G无全零列)

```
>> i= [2 3 4 4 5 6 1 6 1];
>> j= [1 2 2 3 3 3 4 5 6];
>> n=6; G= sparse(i, j, 1, n, n);
```

甚至不生成G

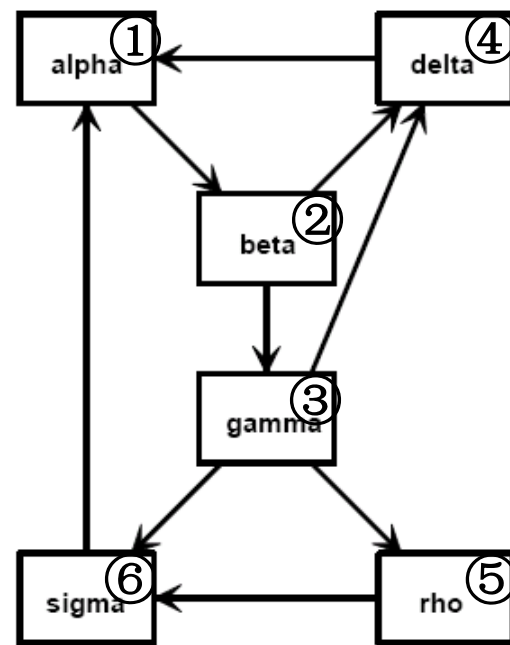
- **幂法:**  $A = pGD + \delta ee^T \Rightarrow x^{(k+1)} = pGDx^{(k)} + \delta e$  ( $e^T x = 1$ )

```
>> c= sum(G);
>> D= spdiags(1./c, 0, n, n);
>> x= p*G*D*x+ (1-p)/n;
```

- 变为**方程求解**的解法

```
>> I= speye(n,n); e= ones(n,1);
>> x= (I- p*G*D) \ ((1-p)/n*e);
```


- **迭代法(奇异方程):**  $x = (I - A) \setminus e$   
(部分主元高斯消去解 近奇异矩阵)  
 $x = x / \text{sum}(x)$



$$Ax = x \Rightarrow x = pGDx + \delta e$$

$$\Rightarrow (I - pGD)x = \delta e \quad \text{保留了稀疏性, 适合中小规模}$$

- 解:



# 一个实用的幂法程序

```
function [x,cnt] = pagerankpow(G)
[n,n] = size(G);
for j = 1:n
    L{j} = find(G(:,j)); %某列非零元
    c(j) = length(L{j}); %网页的出度
end
p = .85; delta = (1-p)/n;
x = ones(n,1)/n;
z = zeros(n,1); cnt = 0;
while max(abs(x-z)) > .0001
    z = x; x = zeros(n,1);
    for j = 1:n
        if c(j) == 0, x = x + z(j)/n;
        else
            x(L{j}) = x(L{j}) + z(j)/c(j);
        end
    end
end
x = p*x + delta; cnt = cnt+1;
end
```

→(单元数组cell)

- 习题2.27
- 迭代中不使用矩阵A,  $G$
- $z, x$ 分别为前一步和当前的迭代解

$$x = Az \quad \text{网页}j\text{出度}$$

$$a_{ij} = \begin{cases} p g_{ij}/c_j + \delta, & c_j \neq 0 \\ 1/n = p/n + \delta, & c_j = 0 \end{cases}$$

$$A = p\tilde{G} + \delta ee^T \Rightarrow x = p\tilde{G}z + \delta e$$

$$\tilde{G}z = [\tilde{g}_1 \dots \tilde{g}_n] \begin{bmatrix} z_1 \\ \vdots \\ z_n \end{bmatrix} = \sum_{j=1}^n z_j \tilde{g}_j$$

- 更多关于pagerank, 看“教学资源”-《Matrix Methods in Data Mining》第12章

# Cholesky分解

- » 分解定理
- 分解算法



# Cholesky分解定理

1.如果实对称阵**A**各阶**顺序主子式**≠0，则它可唯一分解为：

$$A = LDL^T,$$

其中**L**为单位下三角阵，**D**为对角阵

2.若矩阵**A**同时正定，则存在**非奇异下三角阵L**，

$$A = LL^T$$

若限定**L**的**对角元**>0，则此分解唯一

In 2x2 case, for example,

$$\begin{bmatrix} a_{11} & a_{21} \\ a_{21} & a_{22} \end{bmatrix} = \begin{bmatrix} l_{11} & 0 \\ l_{21} & l_{22} \end{bmatrix} \begin{bmatrix} l_{11} & l_{21} \\ 0 & l_{22} \end{bmatrix}$$

which implies

$$l_{11} = \sqrt{a_{11}}, \quad l_{21} = a_{21} / l_{11}, \quad l_{22} = \sqrt{a_{22} - l_{21}^2}$$

实对称阵正定  $\Leftrightarrow$

- $\forall x \neq 0$ , 二次型  $x^T A x > 0$
- **A**的各阶顺序主子式都大于0
- **A**的所有特征值都大于0

# Cholesky分解算法

可根据LU分解算法的kij版本进行修改，考虑对称性；  
**原地存储**: 仅使用A的下三角部分，L的结果将其覆盖

$$\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n1} & \cdots & a_{nn} \end{bmatrix} \rightarrow \begin{bmatrix} \underbrace{l_{11}} & 0 & \cdots & 0 \\ \underbrace{l_{21}} & \underbrace{l_{22}} & \ddots & \vdots \\ \vdots & \vdots & \ddots & 0 \\ \underbrace{l_{n1}} & \underbrace{l_{n2}} & \cdots & \underbrace{l_{nn}} \end{bmatrix} = \begin{bmatrix} \underbrace{l_{11}} & 0 & \cdots & 0 \\ \underbrace{l_{21}} & \underbrace{l_{22}} & \ddots & \vdots \\ \vdots & \vdots & \ddots & 0 \\ \underbrace{l_{n1}} & \underbrace{l_{n2}} & \cdots & \underbrace{l_{nn}} \end{bmatrix} \begin{bmatrix} l_{11} & l_{21} & \cdots & l_{n1} \\ 0 & l_{22} & \cdots & l_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & l_{nn} \end{bmatrix} = A$$

## 第2种算法

1. For  $k=1$  to  $n$
- 1'.  $a_{kk} = \sqrt{a_{kk}}$  注意: L不是单位下三角
2. For  $i= k+1$  to  $n$  (没有选主元)
3.  $a_{ik} = a_{ik} / a_{kk}$
4. For  $j= k+1$  to  $i$
5.  $a_{ij} = a_{ij} - a_{ik} \cdot a_{jk}$
6. End
7. End
8. End

For  $k = 1$  to  $n$

$$a_{kk} = \sqrt{a_{kk} - \sum_{j=1}^{k-1} a_{kj}^2}$$

每步计算都求得L中的某个元素!

For  $i = k+1$  to  $n$

$$a_{ik} = (a_{ik} - \sum_{j=1}^{k-1} a_{ij} \cdot a_{kj}) / a_{kk}$$

End

End



# 对称正定矩阵的Cholesky分解算法

- 算法复杂度：仅需要 $n^3/6$ 次乘法运算和差不多的加法运算，是LU分解的一半计算量
- 对于对称正定矩阵，可证明：
- 所有 $n$ 个平方根运算的操作数都为正数，算法可行
- Cholesky算法是稳定的(对舍入误差不敏感)，不需要选主元
- Matlab命令为chol, 缺省得到上三角矩阵( $R^*R=A$ ), 可用于检测矩阵正定性
- 仅使用矩阵A上(下)三角部分的元素，因此下(上)三角部分元素没有用

```
>>R = chol(S)  
>>L = chol(S, 'lower')
```