

《数学实验》第9讲

主要内容:

矩阵运算函数

线性方程组求解的应用

应用实验：矩阵的幂

补充1：图像与矩阵关系

补充2：主成分分析（PCA）及人脸压缩与恢复应用

快速了解相关函数：

矩阵 A 的对角阵	<code>diag(diag(A))</code>
获取上三角阵(upper)	<code>triu(A)</code>
获取下三角阵(lower)	<code>tril(A)</code>
解线性方程组 $Ax=b$	<code>A\b</code> 或者 <code>inv(A)*b</code>
矩阵的特征值、特征向量	<code>[V,D]=eig(A)</code>

请自行生成一个5阶随机矩阵，并快速练习上述命令（脚本文件编写）

解线性方程组 $Ax=b$

MATLAB命令: $A \backslash b$

示例

```
>>A=rand(3,3);  
x_true=rand(3,1)  
b=A*x_true;  
x_comp=A\b
```

思考: A/B ?

结果

```
x_true =  
    0.9649  
    0.1576  
    0.9706  
  
x_comp =  
    0.9649  
    0.1576  
    0.9706
```

矩阵特征值

定义 设 A 是 n 阶方阵，若非零向量 α 和数 λ 满足

$$A\alpha = \lambda\alpha$$

称 λ 为 A 的一个特征值，称 α 为 A 对应于 λ 的一个特征向量。

• **$\text{lambda}=\text{eig}(A)$** —— 计算 A 的特征值，这里 lambda 是 A 的全部特征值构成的列向量。

• **$[P, D]=\text{eig}(A)$** —— 计算出 A 的全部特征值和对应的特征向量。其中， D 是对角矩阵，保存 A 的全部特征值； P 是满阵， P 的列向量构成对应于 D 的特征向量组。

例1. 计算矩阵 $A = \begin{pmatrix} -1 & 1 & 0 \\ -4 & 3 & 0 \\ 1 & 0 & 2 \end{pmatrix}$ 的特征值和特征向量。

```
>> A = [-1 1 0;  
        -4 3 0;  
        1 0 2];
```

```
>> lambda =  
        eig(A)
```

```
lambda =  
     2  
     1  
     1
```

```
>> [P, D] = eig(A)
```

```
P =
```

```
     0     0.4082     0.4082  
     0     0.8165     0.8165  
     1.0000    -0.4082    -0.4082
```

```
D =
```

```
     2     0     0  
     0     1     0  
     0     0     1
```

线性方程组求解的应用

解线性方程组之所以重要:是因为很多复杂的实际问题最后往往可以简化为或归结为比较容易处理的线性方程组的问题。

线性方程组的理论应用已经渗透到数学发展的许多分支。

线性方程组在物理学、经济学、信息科学、工程技术和国民经济的许多领域都有着广泛的应用。

应用问题: 在减肥食谱中的应用

下表列出了某食谱中的3种食物以及每100克每种食物中含有的营养素的数量:

营养	每100克食物所含营养(g)			减肥所要求的每日营养量
	脱脂牛奶	大豆面粉	乳清	
蛋白质	36	51	13	33
碳水化合物	52	34	74	45
脂肪	0	7	1.1	3

线性方程组求解的应用

如果用这三种食物作为每天的主要食物，那么它们的用量应各取多少才能全面准确地达到这个营养要求？

以100克为一个单位。为了保证减肥所要求的营养量，设每日需食用脱脂牛奶 x_1 个单位，大豆面粉 x_2 个单位，乳清 x_3 个单位，则由所给条件得

$$\begin{cases} 36x_1 + 51x_2 + 13x_3 = 33 \\ 52x_1 + 34x_2 + 74x_3 = 45 \\ 7x_2 + 1.1x_3 = 3 \end{cases}$$

求解该线性方程组

在MATLAB命令窗口中输入：

```
>> A = [36 51 13;  
        52 34 74;  
        0 7 1.1];  
>> b = [33; 45; 3];  
>> x = A\b
```

```
x =  
  
    0.2772  
    0.3919  
    0.2332
```

解方程组得：

$$x_1 = 0.2772$$

$$x_2 = 0.3919$$

$$x_3 = 0.2332$$

即为保证减肥所要求的每日营养量，每日需：
脱脂牛奶27.72克，
大豆面粉39.19克，
乳清23.32克。

一、相关知识点

相似对角化，特征值，特征向量，正交矩阵

在许多工程计算中，经常遇到计算矩阵的幂的问题，请问有没有快速的计算方法？

定义： 设 A, B 都是 n 阶方阵，若存在可逆矩阵 P ，使

$$P^{-1}AP=B$$

对 A 进行 $P^{-1}AP$ 则称 B 是 A 的相似矩阵，并称**矩阵 A 与 B 相似**。

运算称为对 A 进行相似变换，称**可逆矩阵 P 为相似变换矩阵**。

应用实验：矩阵的幂

易证矩阵的相似关系满足：

- ①**自反性**：对于任意 n 阶方阵 A ，有 A 与 A 相似；
- ②**对称性**：若 A 与 B 相似，则 B 与 A 相似；
- ③**传递性**：若 A 与 B 相似， B 与 C 相似，则 A 与 C 相似。

定理 若 n 阶矩阵 A 与 B 相似，则 A 与 B 有相同的特征多项式，从而 A 与 B 有相同的特征值。

相似矩阵的一个重要性质：

若 n 阶矩阵 A 与对角阵

$$\Lambda = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix}$$

相似，

则 $\lambda_1, \lambda_2, \dots, \lambda_n$ 即为 A 的 n 个特征值。

定义 若 n 阶矩阵 A 与对角阵 Λ 相似，则称 A 可以相似对角化，简称 A 可对角化。

如果矩阵 A 可以相似对角化，则存在可逆矩阵 P ，满足

$$P^{-1}AP = \Lambda,$$

其中

$$P = (p_1, p_2, \dots, p_n), \quad \Lambda = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix}$$

易得 $AP = P\Lambda$.

$$\begin{aligned} \text{由 } AP=P\Lambda \text{ 得, } A(p_1 \ p_2 \ \cdots \ p_n) \\ = (p_1 \ p_2 \ \cdots \ p_n) \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix} \\ = (\lambda_1 p_1 \ \lambda_2 p_2 \ \cdots \ \lambda_n p_n) \end{aligned}$$

即： $A p_i = \lambda_i p_i, i = 1, 2, \dots, n.$

可知， λ_i 为矩阵 A 的特征值，其中 p_i 为对应于特征值 λ_i 的特征向量。

若 A 可对角化，则 $A=P\Lambda P^{-1}$ ，因此

$$A^k = P\Lambda P^{-1}P\Lambda P^{-1}\cdots P\Lambda P^{-1} = P\Lambda^k P^{-1}$$

特别地，如果 P 是正交矩阵(正交矩阵 $PP^T=I$)，则 $A=P\Lambda P^T$ 。

此时，矩阵的幂有：

$$A^k = P\Lambda^k P^T$$

这样就大大简化了计算矩阵的幂 A^k 的复杂度。

注：需要计算矩阵 A 的特征值和特征向量。

示例： 设对称矩阵 A 如下，求 A^5 。

$$A = \begin{pmatrix} 2.30 & 0.89 & 0.53 & 1.07 \\ 0.89 & 2.88 & 0.87 & 1.35 \\ 0.53 & 0.87 & 3.62 & 1.11 \\ 1.07 & 1.35 & 1.11 & 3.60 \end{pmatrix}$$

利用 $[V, D] = \text{eig}(A)$ 得：

$V =$

0.8658	0.1968	0.2961	0.3521
-0.4463	0.7064	0.2603	0.4837
0.0822	0.0201	-0.8573	0.5078
-0.2108	-0.6796	0.3311	0.6198

D =

1.6310	0	0	0
0	1.8540	0	0
0	0	2.7441	0
0	0	0	6.1709

在命令行输入 $v*v'$ 得：

ans =

1.0000	-0.0000	0.0000	0.0000
-0.0000	1.0000	0.0000	0.0000
0.0000	0.0000	1.0000	0
0.0000	0.0000	0	1.0000

可知 `eig` 所计算得到特征向量矩阵 V 已经是正交矩阵，则计算 A 的5次幂可用如下命令完成：

$$V * D.^5 * V'$$

输入 $A^5 - V * D.^5 * V'$ 得：

`ans =`

`1.0e-11 *`

-0.0227	-0.0227	-0.0909	-0.0455
-0.0227	-0.0455	-0.1364	-0.0455
-0.0909	-0.1364	-0.1819	-0.1819
-0.0227	-0.0455	-0.1364	0

说明二者相差很小。

补充1：图像与矩阵关系

```
clear; close all
I = imread('color_img.png'); % 可换为任意你想要的输入的图片
I = double(I)/255;
figure,
subplot(2,2,1), imshow(I); title('show color fig.')
subplot(2,2,2), imshow(I(:,:,1)); title('show color fig.')
subplot(2,2,3), imshow(I(:,:,2)); title('show color fig.')
subplot(2,2,4), imshow(I(:,:,3)); title('show color fig.')

G = rgb2gray(I);
W = G;
figure, imshow(G); title('gray Img.')

G(50:100, :) = 0; % 让图像某行为0（黑色）
figure, imshow(G); title('Img.1')
G(:, 50:100) = 1; % 让图像某列为0（黑色）
figure, imshow(G); title('Img.2')
G(50:100, :) = []; % 删除图像某行
figure, imshow(G); title('Img.3')
G(:, 50:100) = []; % 删除图像某列
figure, imshow(G); title('Img.4')

W = W + rand(size(W));
figure, imshow(W); title('Img.5')
```

补充2：主成分分析（PCA）及人脸压缩与恢复应用

- **PCA**是一种经典的数据降维方法（为什么要降维？）
- 能将数据如 $\mathbf{x} \in \mathbf{R}^{1 \times N}$ 降到 $\mathbf{z} \in \mathbf{R}^{1 \times n}$, 其中 $n < N$

举例1：如何将 m 个 $\mathbf{x}_i \in \mathbf{R}^{1 \times N}$ ($\mathbf{X} \in \mathbf{R}^{m \times N}$) **降维(压缩)**至 $\mathbf{z}_i \in \mathbf{R}^{1 \times n}$ ($\mathbf{Z} \in \mathbf{R}^{m \times n}$) ?

Step 1: 数据预处理（**mean normalization**, 为什么？）

$$a) \mu_i = \text{mean}(x_i), s_i = \text{std}(x_i)$$

$$b) x_i = \frac{x_i - \mu_i}{s_i}$$

Step 2: 计算协方差矩阵

$$\Sigma = \frac{1}{m} \mathbf{X}^T \mathbf{X}, \quad \text{where } \mathbf{X} \in \mathbf{R}^{m \times N}$$

Step 3: 计算协方差矩阵的奇异值分解（**SVD**）

$$\Sigma = \mathbf{U} \mathbf{S} \mathbf{V}^T$$

(**Matlab命令**: `[U, S, V] = svd(Σ);`)

Step 4: 提取 \mathbf{U} 的前 n 列向量构造降维矩阵（ n 为你想降到的维数）

$$\mathbf{U}_{\text{reduce}} = \mathbf{U}(:, 1:n)$$

Step 5: 最终得到降维(压缩)数据 \mathbf{Z}

$$\mathbf{Z} = \mathbf{X} * \mathbf{U}_{\text{reduce}};$$

举例2：如何将 m 个**降维(压缩)**数据 $\mathbf{z}_i \in \mathbf{R}^{1 \times n}$ ($\mathbf{Z} \in \mathbf{R}^{m \times n}$) **恢复(解压)**出原来数据 $\mathbf{x}_i \in \mathbf{R}^{1 \times N}$ ($\mathbf{X} \in \mathbf{R}^{m \times N}$) ?

Step 1: $\mathbf{U}_{\text{reduce}} = \mathbf{U}(:, 1:n)$ 进行转置, 并进行如下操作即可：

$$\mathbf{X}_{\text{recover}} = \mathbf{Z} * \mathbf{U}_{\text{reduce}}^T;$$

详见**PCA_face**文件下人脸压缩与恢复代码样例：
PCA_face/demo_pca.m

为什么用协方差矩阵: <https://blog.csdn.net/a10767891/article/details/80288463>

学到了什么？



矩阵运算函数

线性方程组求解的应用

应用实验：矩阵的幂

补充1：图像与矩阵关系

补充2：主成分分析（PCA）及人脸压缩与恢复应用