



第三讲 特征分析与可对角化

李宇峰

liyf@nju.edu.cn

人工智能学院



特征值分解的意义

- 简化矩阵运算

- **矩阵幂运算**: 对于一般的 n 阶矩阵 A , 计算 A^n 通常需要进行大量的矩阵乘法运算。但如果 A 可相似对角化, 即存在可逆矩阵 P , 使得 $P^{-1}AP = \Lambda$, 其中 Λ 是对角矩阵, 那么 $A^n = (P\Lambda P^{-1})^n = P\Lambda^n P^{-1}$ 。而计算对角矩阵 Λ 的 n 次幂非常简单, 只需将对角线上的元素分别取 n 次幂即可, 大大减少了计算量。
- **矩阵函数计算**: 对于矩阵函数 $f(A)$, 如 e^A 、 $\sin A$ 等, 若 A 可相似对角化, 可先将 A 转化为对角矩阵 Λ , 计算 $f(\Lambda)$, 再通过相似变换得到 $f(A) = Pf(\Lambda)P^{-1}$, 使复杂的矩阵函数计算得以简化。

- 揭示矩阵本质特征

- **矩阵的秩**: 矩阵的秩与它的非零特征值的个数密切相关。对于 n 阶矩阵 A , 其秩 $r(A)$ 大于等于其非零特征值的个数。若 A 可对角化, 那么 $r(A)$ 就等于其非零特征值的个数, 这为通过特征值判断矩阵的秩提供了一种方法。
- **行列式与迹**: 矩阵 A 的行列式 $|A|$ 等于其所有特征值的乘积, 矩阵的迹 $tr(A)$ (即主对角线元素之和) 等于其所有特征值之和。这些关系为计算矩阵的行列式和迹提供了新的途径, 同时也能通过行列式和迹的性质来推断特征值的一些信息。

特征值分解的意义

- 构建矩阵理论体系

- **线性变换**：在向量空间中，线性变换可以用矩阵来表示。相似矩阵对应着同一个线性变换在不同基下的矩阵表示。通过相似化简，找到线性变换的最简矩阵表示形式，有助于研究线性变换的性质，如不变子空间、值域、核等。
- **二次型**：二次型 $f(x) = x^T Ax$ （其中 A 为对称矩阵）可以通过正交变换 $x = Py$ 化为标准形 $y^T \Lambda y$ ，其中 Λ 是由 A 的特征值构成的对角矩阵。这不仅实现了二次型的化简，还能根据特征值的正负性判断二次型的正定性、负定性等性质，为二次型的研究提供了有力工具。

实际应用方面

- 工程领域

- **控制系统稳定性分析**：在自动控制理论中，线性时不变系统 $\dot{x} = Ax$ （ x 为状态向量， A 为系统矩阵）的稳定性取决于矩阵 A 的特征值。若 A 的所有特征值都具有负实部，那么对于任意初始状态 $x(0)$ ，当时间 $t \rightarrow \infty$ 时，系统状态 $x(t) \rightarrow 0$ ，系统是渐近稳定的；若存在特征值具有正实部，则系统不稳定；若存在零实部的特征值且其他特征值实部非正，则系统处于临界稳定状态。通过计算 A 的特征值，工程师可以判断系统是否稳定，进而设计合适的控制器来保证系统的稳定性和性能。

特征分析 =》 可对角化

- 对称矩阵vs非对称矩阵的特征分析
 - 特征值性质、特征向量性质
 - 广义特征值分解
- 矩阵的相似变换
- 矩阵可对角化条件

3.1 特征值分解

定义3.1 对于给定的矩阵 L ，如果非零向量 u 作为矩阵 L 的输入时，所产生的输出向量与输入向量仅相差一个常数因子 λ ，也就是

$$Lu = \lambda u, \quad u \neq 0$$

则称向量 u 是矩阵 L 的特征向量，称标量 λ 为矩阵 L 的特征值

Eigenvalues and Eigenvectors

For an $n \times n$ matrix \mathbf{A} , scalars λ and vectors $\mathbf{x}_{n \times 1} \neq \mathbf{0}$ satisfying $\mathbf{A}\mathbf{x} = \lambda\mathbf{x}$ are called *eigenvalues* and *eigenvectors* of \mathbf{A} , respectively, and any such pair, (λ, \mathbf{x}) , is called an *eigenpair* for \mathbf{A} . The set of *distinct* eigenvalues, denoted by $\sigma(\mathbf{A})$, is called the *spectrum* of \mathbf{A} .

- $\lambda \in \sigma(\mathbf{A}) \iff \mathbf{A} - \lambda\mathbf{I}$ is singular $\iff \det(\mathbf{A} - \lambda\mathbf{I}) = 0$. (7.1.3)
- $\{\mathbf{x} \neq \mathbf{0} \mid \mathbf{x} \in N(\mathbf{A} - \lambda\mathbf{I})\}$ is the set of all eigenvectors associated with λ . From now on, $N(\mathbf{A} - \lambda\mathbf{I})$ is called an *eigenspace* for \mathbf{A} .
- Nonzero row vectors \mathbf{y}^* such that $\mathbf{y}^*(\mathbf{A} - \lambda\mathbf{I}) = \mathbf{0}$ are called *left-hand eigenvectors* for \mathbf{A} (see Exercise 7.1.18 on p. 503).

3.1 特征值分解

Let's now face the problem of finding the eigenvalues and eigenvectors of the matrix $\mathbf{A} = \begin{pmatrix} 7 & -4 \\ 5 & -2 \end{pmatrix}$ appearing in (7.1.1). As noted in (7.1.3), the eigenvalues are the scalars λ for which $\det(\mathbf{A} - \lambda\mathbf{I}) = 0$. Expansion of $\det(\mathbf{A} - \lambda\mathbf{I})$ produces the second-degree polynomial

$$p(\lambda) = \det(\mathbf{A} - \lambda\mathbf{I}) = \begin{vmatrix} 7 - \lambda & -4 \\ 5 & -2 - \lambda \end{vmatrix} = \lambda^2 - 5\lambda + 6 = (\lambda - 2)(\lambda - 3),$$

which is called the *characteristic polynomial* for \mathbf{A} . Consequently, the eigenvalues for \mathbf{A} are the solutions of the *characteristic equation* $p(\lambda) = 0$ (i.e., the roots of the characteristic polynomial), and they are $\lambda = 2$ and $\lambda = 3$.

The eigenvectors associated with $\lambda = 2$ and $\lambda = 3$ are simply the nonzero vectors in the eigenspaces $N(\mathbf{A} - 2\mathbf{I})$ and $N(\mathbf{A} - 3\mathbf{I})$, respectively. But determining these eigenspaces amounts to nothing more than solving the two homogeneous systems, $(\mathbf{A} - 2\mathbf{I})\mathbf{x} = \mathbf{0}$ and $(\mathbf{A} - 3\mathbf{I})\mathbf{x} = \mathbf{0}$.

3.1 特征值分解

For $\lambda = 2$,

$$\begin{aligned}\mathbf{A} - 2\mathbf{I} &= \begin{pmatrix} 5 & -4 \\ 5 & -4 \end{pmatrix} \longrightarrow \begin{pmatrix} 1 & -4/5 \\ 0 & 0 \end{pmatrix} \implies \begin{array}{l} x_1 = (4/5)x_2 \\ x_2 \text{ is free} \end{array} \\ \implies N(\mathbf{A} - 2\mathbf{I}) &= \left\{ \mathbf{x} \mid \mathbf{x} = \alpha \begin{pmatrix} 4/5 \\ 1 \end{pmatrix} \right\}.\end{aligned}$$

For $\lambda = 3$,

$$\begin{aligned}\mathbf{A} - 3\mathbf{I} &= \begin{pmatrix} 4 & -4 \\ 5 & -5 \end{pmatrix} \longrightarrow \begin{pmatrix} 1 & -1 \\ 0 & 0 \end{pmatrix} \implies \begin{array}{l} x_1 = x_2 \\ x_2 \text{ is free} \end{array} \\ \implies N(\mathbf{A} - 3\mathbf{I}) &= \left\{ \mathbf{x} \mid \mathbf{x} = \beta \begin{pmatrix} 1 \\ 1 \end{pmatrix} \right\}.\end{aligned}$$

3.1 特征值分解

$n \times n$ 矩阵 $A \in \mathbb{C}^{n \times n}$ 共有 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 和 n 个对应的特征向量 u_1, u_2, \dots, u_n 。若令 $U = [u_1, u_2, \dots, u_n]$ 代表特征向量为列组成的矩阵，则就由式(1)得到

$$A[u_1, u_2, \dots, u_n] = [\lambda_1 u_1, \lambda_2 u_2, \dots, \lambda_n u_n] \Leftrightarrow AU = U\Sigma \quad (1)$$

其中 $\Sigma = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 为 $n \times n$ 对角矩阵。

如果 U 是非奇异矩阵，则 $AU = U\Sigma$ 可以写成等价形式

$$U^{-1}AU = \Sigma \quad (2)$$

特别地，若 A 是 *Hermite* 矩阵，则 A 的特征值和特征向量有以下重要特征：

3.1 特征值分解

1) *Hermite*矩阵 A 的所有特征值都是实数, 即 $\lambda^* = \lambda$, 也就是说特征值矩阵 Σ 是一个实(值)对角矩阵;

2) *Hermite*矩阵 A 的特征向量 u_1, u_2, \dots, u_n 是相互正交的, 同时将其规范化, 即 $\|u_i\|_2 = 1, i = 1, 2, \dots, n$ 。故特征向量组成的矩阵 $U = [u_1, u_2, \dots, u_n]$ 是一个酉矩阵, 即 $UU^H = U^H U = I_n$, 推得 $U^H = U^{-1}$, 这样由分解式(2)就得到

$$U^H A U = \Sigma \quad (3)$$

3) 实对称矩阵 A 的特征值都是实数, 其对应的特征向量也可以组成一个正交矩阵。

3.1 特征值分解

*Hermite*矩阵和非*Hermite*矩阵的特征值分解之间的差别:

- 1) 对于定义给出的表达式(1)是对*Hermite*矩阵和非*Hermite*矩阵都成立的;
- 2) 对角分解式(2)对*Hermite*矩阵和可对角化的非*Hermite*矩阵是适用的, 而并不是对所有非*Hermite*矩阵成立;
- 3) 特征分解式(3)仅对*Hermite*矩阵成立。

由于特征值 λ_i 和特征向量 u_i 是成对出现的, 因此常将 (λ_i, u_i) 称为特征对 (*eigenpair*), 特征值可能为零, 但特征向量必须非零。

3.1 特征值分解

设 $A \in C^{n \times n}$ 是一个矩阵， λ 是它的一个特征值， $v \in C^n$ 是对应于 λ 的一个特征向量，则满足

$$(A - \lambda I)v = 0 \quad \text{或者} \quad Av = \lambda v \quad (4)$$

且 v 称为 A 的特征值 λ 对应的 **右特征向量**（简称特征向量）。

而满足

$$u^H(A - \lambda I)v = 0^T \quad \text{或者} \quad u^H A = \lambda u^H \quad (5)$$

则 u 称为 A 的特征值 λ 对应的 **左特征向量**。

若矩阵 A 为 *Hermite* 矩阵，则由于其所有特征值为实数，立即知道 $v = u$ ，即 *Hermite* 矩阵的左和右特征向量相同。

3.1 特征值分解

特征值的性质

我们知道即使矩阵 A 是实矩阵，其特征值也有可能是复数。

以*Givens*旋转矩阵

$$A = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix}$$

为例，其特征方程

$$\det(A - \lambda I) = \begin{vmatrix} \cos\theta - \lambda & -\sin\theta \\ \sin\theta & \cos\theta - \lambda \end{vmatrix} = (\cos\theta - \lambda)^2 + \sin^2\theta = 0$$

然而若 θ 不是 π 的整数倍，则 $\sin^2\theta > 0$ 。此时特征方程不可能有 λ 的实根，即*Givens*旋转矩阵的两个特征值均为复数。其对应的特征向量也是复向量。

3.1 特征值分解

下面是特征值的一些基本性质：

- (1) 矩阵 A 非奇异的充要条件是 A 没有零特征值；
- (2) 矩阵 A 和 A^T 有相同的特征值；
- (3) 若 λ 是 $n \times n$ 矩阵 A 的特征值，则 λ^k 是 A^k 的特征值；若 A 非奇异，则 $\frac{1}{\lambda}$ 是 A^{-1} 的特征值； $\lambda + \sigma^2$ 是矩阵 $A + \sigma^2 I$ 的特征值。

定义3.2 任意一个矩阵 A 的单个特征值 λ 的条件数定义为

$$\text{cond}(\lambda) = \frac{1}{\cos\theta(u, v)}$$

式中 $\theta(u, v)$ 表示与特征值 λ 对应的左特征向量 u 和右特征向量 v 之间的夹角(锐角)。

3.1 特征值分解

一个特征值的条件数越大，则计算这个特征值的稳定性越差，即当观测数据有扰动时，计算得到的特征值有可能变化很大。

例3.1 考虑矩阵

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

其特征值为 $\{1, 2, 3\}$ 。与特征值 $\lambda = 1$ 对应的特征向量分别是

$$u = (0.6810 \ 0.2253 \ 0.6967)^T, v = (0.3162 \ -0.9487 \ 0.0000)。$$

相应的条件数 $cond(\lambda_1) \approx 603.64$ ，这说明当矩阵元素有0.01数量级的扰动时，将有可能引起特征值 λ_1 最大6倍的变化。

3.1 特征值分解

关于矩阵(不一定是 $Hermite$ 矩阵)特征值还有一些性质:

(1) **矩阵特征值与行列式的关系**: 设 $\lambda_1, \lambda_2, \dots, \lambda_m$ 是 $m \times m$ 矩阵 A 的特征值, 则 A 的行列式的值为 $det(A) = \prod_{i=1}^m \lambda_i$;

(2) **矩阵特征值与矩阵迹的关系**:

$$tr(A) \triangleq a_{11} + a_{22} + \dots + a_{mm} = \lambda_1 + \lambda_2 + \dots + \lambda_m;$$

(3) **实矩阵特征值的特点**: $m \times m$ 实矩阵 A 如果有复特征值, 则一定是以共轭复数成对出现, 即若 $a + bi$ 是 A 的一个特征值, 则 $a - bi$ 也一定是 A 的一个特征值;

(4) **矩阵特征值与矩阵秩 ($rank$) 的关系**: 若 A 有 r 个非零特征值, 则 $rank(A) \geq r$;

3.1 特征值分解

(5) *Cayley-Hamilton*定理: 若 $\lambda_1, \lambda_2, \dots, \lambda_m$ 是 $m \times m$ 矩阵 A 的特征值, 则 $\prod_{i=1}^m (A - \lambda_i I) = 0$;

(6) 关于 $m \times n$ 矩阵 A 与 $n \times m$ 矩阵 B 乘积的特征值的关系:
 $m \times m$ 矩阵 AB 与 $n \times n$ 矩阵 BA 有相同的非零特征值, 所不同的是零特征值的重数不一样。

(15) 关于 $m \times n$ ($n \geq m$) 矩阵 A 与 $n \times m$ 矩阵 B 乘积的特征值:

① 若 λ 是矩阵乘积 AB 的特征值, 则 λ 也是 BA 的特征值。

② 若 $\lambda \neq 0$ 是矩阵乘积 BA 的特征值, 则 λ 也是 AB 的特征值。

③ 若 $\lambda_1, \lambda_2, \dots, \lambda_m$ 是矩阵乘积 AB 的特征值, 则矩阵乘积 BA 的 n 个特征值为 $\lambda_1, \lambda_2, \dots, \lambda_m, 0, \dots, 0$ 。

(16) 若矩阵 A 的特征值为 λ , 则多项式 $f(x) = c_0 x^m + c_1 x^{m-1} + \dots + c_{m-1} x + c_m$ 的矩阵多项式 $f(A) = c_0 A^m + c_1 A^{m-1} + \dots + c_{m-1} A + c_m I$ 的特征值为

$$f(\lambda) = c_0 \lambda^m + c_1 \lambda^{m-1} + \dots + c_{m-1} \lambda + c_m \quad (3.1.10)$$

(17) 若矩阵 A 的特征值为 λ , 则矩阵指数函数 e^A 的特征值为 e^λ 。

3.1 特征值分解

特征向量的性质：

- (1) 若 (λ, u) 是矩阵 A 的特征对，则 $(c\lambda, u)$ 和 (λ, cu) 分别是 cA 和 A 的特征对，其中 $c \neq 0$ 为常数；
- (2) 若 (λ, u) 是矩阵 A 的特征对，则 (λ^k, u) 是 A^k 的特征对；
- (3) 若 (λ_i, u_i) 和 (λ_j, u_j) 都是 A 的特征对，且 $\lambda_i \neq \lambda_j$ ，则特征向量 u_i 和 u_j 一定线性无关，也就是说，**相异特征值对应的特征向量一定线性无关**；
- (4) 若 $m \times m$ 矩阵 A 有 m 个相异的特征值，则一定有 m 个线性无关的特征向量；
- (5) **实对称矩阵和 *Hermite* 矩阵相异特征值对应的特征向量一定是正交的**；

3.1 特征值分解

特征值问题从本质上来说就是由 $n \times n$ 矩阵 A 对向量 u 所作的变换 Au 不改变向量 u 的方向。因此线性变换 Au 是一种“保持方向不变”的映射。为了确定向量 u ，不妨将(1)式写成

$$(\lambda I - A)u = 0$$

的形式。对上式关于 u 的齐次方程组，由于要求 $u \neq 0$ ，所以由线性方程组理论，就必须要求

$$\det(\lambda I - A) = |\lambda I - A| = 0 \quad \text{【特征方程】}$$

而展开行列式 $|\lambda I - A|$ ，它应该是一个关于 λ 的 n 次多项式。

这说明，求 A 的特征值问题就是求关于 λ 的 n 次多项式的根。

3.1 特征值分解

因此，求解矩阵 A 的特征值问题主要由下列步骤组成：

(1) **特征值计算** 求出特征方程 $\det(\lambda I - A) = 0$ 的 n 个根（解）

$\lambda_1, \lambda_2, \dots, \lambda_n$ 得到 A 的全部特征值；

(2) **特征向量计算** 对应于每一个特征值 λ_i 要解一个齐次线性方程组 $(A - \lambda_i I)u = 0$ 的非零解 $u \neq 0$ 。

矩阵特征值的**代数重数**和特征向量**几何重数**

若特征值 λ_i 是特征多项式的 c_i 重根，则就称特征值 λ_i 的代数重数是 c_i ；而对应于 c_i 重根的特征值存在 d_i 个线性无关的特征向量，则就称 d_i 是 λ_i 的几何重数。代数重数和几何重数的关系是**代数重数 \geq 几何重数**，也就是 $c_i \geq d_i$ 。

3.1 特征值分解

广义特征值分解

- **拓展特征值理论**：传统的特征值分解是广义特征值分解在 $B = I$ (I 为单位矩阵) 时的特殊情况。广义特征值分解将特征值问题从标准形式 $Ax = \lambda x$ 推广到 $Ax = \lambda Bx$ ，大大拓展了特征值理论的研究范围，使人们能更深入地理解矩阵的性质和线性变换的本质，为更复杂的数学问题提供了理论基础。
- **研究矩阵关系**：它有助于研究两个矩阵 A 和 B 之间的关系。通过广义特征值分解，可以揭示出矩阵 A 和 B 在某种线性变换下的共同特征结构，比如可以判断它们是否在某种意义上是“相似”的，或者是否具有某些相同的不变子空间等性质，这对于矩阵理论的完善和发展具有重要意义。
- **解决二次型问题**：在二次型理论中，广义特征值分解可用于处理形如 $x^T Ax$ 在约束 $x^T Bx = 1$ 下的极值问题。通过将其转化为广义特征值问题，能够方便地求出这些极值，进而深入研究二次型的性质，如正定性、负定性等，为许多数学分支中的相关问题提供了有效的解决方法。

3.1 特征值分解

广义特征值分解

$$\mathbf{A}\mathbf{u} = \lambda\mathbf{B}\mathbf{u} \quad (3.6.3)$$

广义特征系统的两个矩阵 $\mathbf{A}, \mathbf{B} \in \mathbb{C}^{m \times m}$ 组成一矩阵束 (matrix pencil) 或矩阵对 (matrix pair), 记作 (\mathbf{A}, \mathbf{B}) ; 常数 λ 和非零向量 \mathbf{u} 分别称为矩阵束的广义特征值 (generalized eigenvalue) 和广义特征向量 (generalized eigenvector)。

下面是关于广义特征值问题 $\mathbf{A}\mathbf{x} = \lambda\mathbf{B}\mathbf{x}$ 的一些性质 [57, pp.176~177]:

(1) 若矩阵 \mathbf{A} 和 \mathbf{B} 互换, 则广义特征值将变为其倒数, 但广义特征向量保持不变, 即有

$$\mathbf{A}\mathbf{x} = \lambda\mathbf{B}\mathbf{x} \Rightarrow \mathbf{B}\mathbf{x} = \frac{1}{\lambda}\mathbf{A}\mathbf{x}$$

(2) 若 \mathbf{B} 非奇异, 则广义特征值分解简化为标准的特征值分解

$$\mathbf{A}\mathbf{x} = \lambda\mathbf{B}\mathbf{x} \Rightarrow (\mathbf{B}^{-1}\mathbf{A})\mathbf{x} = \lambda\mathbf{x}$$

(3) 若 \mathbf{A} 和 \mathbf{B} 均为实对称的正定矩阵, 则广义特征值一定是正的。

(4) 如果 \mathbf{A} 奇异, 则 $\lambda = 0$ 必定是一个广义特征值。

(5) 若 \mathbf{A} 和 \mathbf{B} 均为正定的 Hermitian 矩阵, 则广义特征值必定是实的, 并且与不同广义特征值 (λ_i, λ_j) 对应的广义特征向量 $(\mathbf{x}_i, \mathbf{x}_j)$ 相对于正定矩阵 \mathbf{A} 和 \mathbf{B} 分别正交, 即有

$$\mathbf{x}_i^H \mathbf{A} \mathbf{x}_j = \mathbf{x}_i^H \mathbf{B} \mathbf{x}_j = 0, \quad i \neq j$$

3.2 矩阵对角化

- 简化矩阵运算

- **幂运算**：如前面提到，对于可对角化矩阵 A ，若 $A = P\Lambda P^{-1}$ ，那么 $A^n = P\Lambda^n P^{-1}$ ，计算对角矩阵 Λ 的幂次极为简便，只需对对角元素进行幂运算，这极大降低了矩阵高次幂的计算复杂度。
- **函数计算**：对于矩阵函数 $f(A)$ ，通过对角化可转化为计算 $f(\Lambda)$ ，进而得到 $f(A) = Pf(\Lambda)P^{-1}$ ，让复杂的矩阵函数计算更易处理。

- 揭示矩阵性质

- **秩**：矩阵对角化后，非零特征值的个数就是矩阵的秩，为确定矩阵的秩提供了直观方法。
- **行列式与迹**：矩阵的行列式等于其对角化后对角线上特征值的乘积，迹等于特征值之和，便于通过特征值计算这些矩阵属性，也能依据它们推断特征值的情况。

- 完善理论体系

- **线性变换**：矩阵对角化能找到线性变换在特定基下的最简矩阵表示，即对角矩阵，有助于深入研究线性变换的不变子空间、值域、核等性质。
- **二次型**：对于二次型 $f(x) = x^T Ax$ ，通过将对称矩阵 A 对角化，可利用正交变换化为标准形，方便判断二次型的正定性等性质。

3.2 矩阵对角化

有 $n \times n$ 矩阵 A ，若存在 $S \in C^{n \times n}$ 为非奇异矩阵，使得关系式

$$B = S^{-1}AS \quad (2.1)$$

成立，称矩阵 B 是 A 的相似矩阵，相应的变换就是相似变换，记作 $B \sim A$ 。

设 λ 是线性变换 B 的一个特征值，对应的特征向量是 y ，即

$$By = \lambda y \implies S^{-1}ASy = \lambda y \implies A(Sy) = \lambda(Sy)$$

若令 $x = Sy$ ，就有 $Ax = \lambda x$ 。

这说明相似矩阵有相同的特征值，且若 y 是 B 对应于 λ 的特征向量，那么 $x = Sy$ 就是 A 的对应于 λ 的特征向量。

3.2 矩阵对角化

相似矩阵具有以下基本性质:

- (1) 自反性 $A \sim A$, 即任一矩阵与它自己相似。
- (2) 对称性 若 A 相似于 B , 则 B 也相似于 A 。
- (3) 传递性 若 A 相似于 B , 并且 B 同时相似于 C , 则 A 相似于 C , 即 $A \sim C$ 。

相似矩阵具有以下重要性质:

- (1) 相似矩阵 $B \sim A$ 具有相同的行列式, 即 $|B| = |A|$ 。
- (2) 若矩阵 $S^{-1}AS = T$ (上三角矩阵), 则 T 的对角元素给出矩阵 A 的特征值 λ_i 。
- (3) 两个相似矩阵具有完全相同的特征值。

(4) 相似矩阵 $B = S^{-1}AS$ 意味着 $B^2 = S^{-1}ASS^{-1}AS = S^{-1}A^2S$, 从而有 $B^k = S^{-1}A^kS$ 。也就是说, 若 $B \sim A$, 则 $B^k \sim A^k$ 。这一性质称为相似矩阵的幂性质。

(5) 若矩阵 $B = S^{-1}AS$ 和 A 均可逆, 则 $B^{-1} = S^{-1}A^{-1}S$, 即当两个矩阵相似时, 它们的逆矩阵也相似。

3.2 矩阵对角化

- 所以如果矩阵 A 与 B 是相似矩阵，且 B 是一个对角矩阵，而求对角矩阵的特征值特别简单，其对角元素就是它的特征值。
- 这就是说，如果矩阵 A 与一个对角矩阵相似，这就极大的简化了矩阵 A 的特征值计算。
- 问题：哪些类型的矩阵是可对角化的？



3.2 矩阵对角化

在前面的讨论中，当矩阵 A 是实对称矩阵或*Hermite*矩阵时，它们的特征值都是实数；

并且它们都存在一组标准正交特征向量系组成正交矩阵 $U = [u_1, u_2, \dots, u_n]$ 使得

$$U^H A U = U^{-1} A U = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$$

这说明实对称矩阵或*Hermite*矩阵都是可对角化矩阵。

3.2 矩阵对角化

下面通过一个例子说明如何求出一个一般的 $m \times m$ 矩阵

A 的特征值、对应的特征向量和对角化。

例3.2 已知一个 3×3 的非对称实矩阵

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

3.2 矩阵对角化

解：直接计算得特征多项式

$$|\lambda I - A| = \begin{vmatrix} \lambda - 1 & -1 & -1 \\ 0 & \lambda - 3 & -3 \\ 2 & -1 & \lambda - 1 \end{vmatrix} = \lambda(\lambda - 2)(\lambda - 3)$$

求解特征方程 $|\lambda I - A| = 0$ 得到矩阵 A 的3个特征值 $\lambda=0, 2, 3$.

(1) 对于特征值 $\lambda = 0$, 就解齐次线性方程组 $(0 \cdot I - A)x = 0$,

$$\begin{cases} x_1 + x_2 + x_3 = 0 \\ 3x_2 + 3x_3 = 0 \\ 2x_1 - x_2 - x_3 = 0 \end{cases}$$

其解为 $x_1 = 0$ 和 $x_2 = -x_3$, 其中 x_3 任意。因此与特征值 $\lambda = 0$ 对应的特征向量是

3.2 矩阵对角化

$$x = \begin{bmatrix} 0 \\ -k \\ k \end{bmatrix} = k \begin{bmatrix} 0 \\ -1 \\ 1 \end{bmatrix}, \quad k \neq 0$$

取 $k = 1$, 得特征向量为 $x_1 = (0, -1, 1)^T$

(2) 对于特征值 $\lambda = 2$, 对应的齐次线性方程组 $(2 \cdot I - A)x = 0$,

$$\begin{cases} x_1 - x_2 - x_3 = 0 \\ x_2 + 3x_3 = 0 \\ 2x_1 - x_2 + x_3 = 0 \end{cases}$$

其解为 $x_1 = -2x_3$ 和 $x_2 = -3x_3$, 其中 x_3 任意。因此与特征值 $\lambda = 2$ 对应的特征向量是

3.2 矩阵对角化

$$x = \begin{bmatrix} -2k \\ -3k \\ k \end{bmatrix} = k \begin{bmatrix} -2 \\ -3 \\ 1 \end{bmatrix}, \quad k \neq 0$$

取 $k = 1$, 得特征向量为 $x_1 = (-2, -3, 1)^T$

(3) 类似的对于特征值 $\lambda = 3$ 对应的特征向量是 $(1, 2, 0)^T$ 。

三个特征向量组成矩阵

$$P = \begin{bmatrix} 0 & -2 & 1 \\ -1 & -3 & 2 \\ 1 & 1 & 0 \end{bmatrix} \quad P^{-1} = \begin{bmatrix} 1 & -0.5 & 0.5 \\ -1 & 0.5 & 0.5 \\ -1 & 1.0 & 1.0 \end{bmatrix}$$

3.2 矩阵对角化

于是矩阵 A 的对角化结果为

$$\begin{aligned} P^{-1}AP &= \begin{bmatrix} 1 & -0.5 & 0.5 \\ -1 & 0.5 & 0.5 \\ -1 & 1.0 & 1.0 \end{bmatrix} \begin{bmatrix} 1 & 1 & 1 \\ 0 & 3 & 3 \\ -2 & 1 & 1 \end{bmatrix} \begin{bmatrix} 0 & -2 & 1 \\ -1 & -3 & 2 \\ 1 & 1 & 0 \end{bmatrix} \\ &= \begin{bmatrix} 1 & -0.5 & 0.5 \\ -1 & 0.5 & 0.5 \\ -1 & 1.0 & 1.0 \end{bmatrix} \begin{bmatrix} 0 & -4 & 0 \\ 0 & -6 & 0 \\ 0 & 2 & 3 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 3 \end{bmatrix} \end{aligned}$$

这恰好就是由矩阵 A 的三个不同特征值0, 2, 3构成的对角矩阵。

3.2 矩阵对角化

定义3.3 一个 $n \times n$ 实矩阵 A 若与一个对角矩阵相似，则称矩阵 A 是可对角化矩阵(*diagonalizable*)。

我们已经知道，**当 A 为实对称矩阵或Hermite时一定是可对角化的。**

更一般化对于矩阵 $A \in \mathbb{C}^{n \times n}$ 可对角化的充要条件是：

一个 $n \times n$ 矩阵 A 是可对角化的充要条件是 A 具有 n 个线性无关的特征向量。

这样就可以得到结论，如果 $n \times n$ 矩阵 A 有 n 个相异特征值，则 A 一定是可对角化的。

3.2 矩阵对角化

但这并不意味着特征值有重根时就一定不能可对角化。事实上
一个 $n \times n$ 矩阵 A 如果它的几何重数之和

$$d_1 + d_2 + \cdots + d_r = n$$

则矩阵 A 一定是可对角化的。

以定理的形式可以表示为：

定理 3.2.2 ^[112,p.307] 若矩阵 $A \in \mathbb{C}^{m \times m}$ 的特征值 λ_k 具有代数多重度 $d_k, k = 1, 2, \dots, p$, 并且 $\sum_{k=1}^p d_k = m$, 则矩阵 A 具有 m 个线性无关的特征向量, 当且仅当 $\text{rank}(A - \lambda_k I) = m - d_k, k = 1, 2, \dots, p$ 。此时, $AU = U\Sigma$ 中的矩阵 U 是非奇异的, 而且 A 可对角化为 $U^{-1}AU = \Sigma$ 。

3.3 矩阵的相似化简

一个具有多重特征值、不可对角化的矩阵 $A \in \mathbb{C}^{m \times m}$ 可以相似化简为 Jordan 标准型 (Jordan canonical form)。

假定矩阵 A 具有 d 个互异的特征值，并且特征值 λ_i 的多重度为 m_i ，即有 $m_1 + m_2 + \cdots + m_d = m$ 。Jordan 标准型取形式

$$J = \begin{bmatrix} J_1 & & O \\ & \ddots & \\ O & & J_p \end{bmatrix} \quad (3.2.4)$$

式中， $J_i (i = 1, 2, \dots, p)$ 称为 Jordan 块，其中 Jordan 块的总个数 p 大于或等于互异特征值的个数 d ，因为一个多重度为 m_i 的特征值有可能对应多个 Jordan 块。

3.3 矩阵的相似化简

与多重度为 1 的特征值 λ_i 对应的 Jordan 块为 1 阶 Jordan 块，它是一个 1×1 Jordan 块 $\mathbf{J}_{1 \times 1} = \lambda_i$ 。一个 k 阶 Jordan 块定义为

$$\mathbf{J}_{k \times k} = \begin{bmatrix} \lambda & 1 & & 0 \\ & \lambda & \ddots & \\ & & \ddots & 1 \\ 0 & & & \lambda \end{bmatrix} \in \mathbb{C}^{k \times k} \quad (3.2.5)$$

主对角线的 k 个元素全部为特征值 λ ，主对角线右边的次对角线的 $k - 1$ 个元素全部为 1，其他元素均等于 0。例如，2 阶和 3 阶 Jordan 块分别为

$$\mathbf{J}_{2 \times 2} = \begin{bmatrix} \lambda & 1 \\ 0 & \lambda \end{bmatrix}, \quad \mathbf{J}_{3 \times 3} = \begin{bmatrix} \lambda & 1 & 0 \\ 0 & \lambda & 1 \\ 0 & 0 & \lambda \end{bmatrix}$$

3.3 矩阵的相似化简

如果一个 3×3 矩阵 A 具有一个多重度为 3 的特征值 λ_0 , 则矩阵 A 的 Jordan 标准型就有以下三种可能形式:

$$\begin{aligned} J &= \begin{bmatrix} J_{1 \times 1} & 0 & 0 \\ 0 & J_{1 \times 1} & 0 \\ 0 & 0 & J_{1 \times 1} \end{bmatrix} = \begin{bmatrix} \lambda_0 & 0 & 0 \\ 0 & \lambda_0 & 0 \\ 0 & 0 & \lambda_0 \end{bmatrix} & J = J_{3 \times 3} = \begin{bmatrix} \lambda_0 & 1 & 0 \\ 0 & \lambda_0 & 1 \\ 0 & 0 & \lambda_0 \end{bmatrix} \\ J &= \begin{bmatrix} J_{1 \times 1} & \mathbf{0} \\ \mathbf{0} & J_{2 \times 2} \end{bmatrix} = \begin{bmatrix} \lambda_0 & 0 & 0 \\ 0 & \lambda_0 & 1 \\ 0 & 0 & \lambda_0 \end{bmatrix} \end{aligned}$$

Jordan 块排列顺序不同的 Jordan 标准型被视为同一个 Jordan 标准型。例如上述第二种 Jordan 标准型也可以排列为

$$J = \begin{bmatrix} J_{2 \times 2} & \mathbf{0} \\ \mathbf{0} & J_{1 \times 1} \end{bmatrix} = \begin{bmatrix} \lambda_0 & 1 & 0 \\ 0 & \lambda_0 & 0 \\ 0 & 0 & \lambda_0 \end{bmatrix}$$

3.3 矩阵的相似化简

在实际应用中，一个不可对角化的 $m \times m$ 矩阵往往存在某些多重特征值。关键问题是，一个多重度为 n 的特征值究竟对应几个 Jordan 块，每个 Jordan 块的阶数又是如何分布的？

算法 3.2.1 (Jordan 块的个数及阶数确定)

- (1) Jordan 块阶次大于 1 (即 ≥ 2) 的个数 = $\text{rank}(\lambda_i \mathbf{I} - \mathbf{A}) - \text{rank}(\lambda_i \mathbf{I} - \mathbf{A})^2$ 。
- (2) Jordan 块阶次大于 2 (即 ≥ 3) 的个数 = $\text{rank}(\lambda_i \mathbf{I} - \mathbf{A})^2 - \text{rank}(\lambda_i \mathbf{I} - \mathbf{A})^3$ 。
- (3) Jordan 块阶次大于 3 (即 ≥ 4) 的个数 = $\text{rank}(\lambda_i \mathbf{I} - \mathbf{A})^3 - \text{rank}(\lambda_i \mathbf{I} - \mathbf{A})^4$ 。
- (4) 与特征值 λ_i 对应的 Jordan 块阶次之和等于 λ_i 的多重度。

3.3 矩阵的相似化简

例 3.2.2 求 3×3 矩阵

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 4 \\ 2 & -1 & 4 \\ -1 & 0 & -3 \end{bmatrix} \quad (3.2.6)$$

的 Jordan 标准型。

由特征行列式

$$|\lambda \mathbf{I} - \mathbf{A}| = \begin{vmatrix} \lambda - 1 & 0 & -4 \\ -2 & \lambda + 1 & -4 \\ 1 & 0 & \lambda + 3 \end{vmatrix} = (\lambda + 1)^3 = 0$$

得矩阵 \mathbf{A} 的特征值 $\lambda = -1$, 多重度为 3。

由于当 $\lambda = -1$ 时

$$\lambda \mathbf{I} - \mathbf{A} = \begin{bmatrix} -2 & 0 & -4 \\ -2 & 0 & -4 \\ 1 & 0 & 2 \end{bmatrix}, \quad (\lambda \mathbf{I} - \mathbf{A})^2 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

3.3 矩阵的相似化简

故 Jordan 块阶次 ≥ 2 的个数 $\text{rank}(\lambda\mathbf{I} - \mathbf{A}) - \text{rank}(\lambda\mathbf{I} - \mathbf{A})^2 = 1 - 0 = 1$, 即有一个 Jordan 块的阶次 ≥ 2 。又因为 $\text{rank}(\lambda\mathbf{I} - \mathbf{A})^2 - \text{rank}(\lambda\mathbf{I} - \mathbf{A})^3 = 0 - 0 = 0$, 故没有 Jordan 块的阶次会等于 3。于是, 三重特征值 -1 对应为 2 个 Jordan 块, 其中 1 个 Jordan 的阶次为 2, 另一个 Jordan 块阶次为 1。换言之, 已知矩阵 \mathbf{A} 的 Jordan 标准型为

$$\mathbf{J} = \begin{bmatrix} \mathbf{J}_{1 \times 1} & \mathbf{0} \\ \mathbf{0} & \mathbf{J}_{2 \times 2} \end{bmatrix} = \begin{bmatrix} -1 & 0 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \end{bmatrix}$$

3.3 矩阵的相似化简

矩阵 $A \in \mathbb{C}^{m \times m}$ 的 Jordan 标准型也可以利用矩阵的相似化简直接求出，其算法如下。

算法 3.2.2 矩阵的相似化简

步骤 1 通过求解特征行列式 $|\lambda I - A|$ 的根，得到 $m \times m$ 矩阵 A 的全部 m 个特征值 (包括多重的特征值)。令不同特征值 $\lambda_i (i = 1, 2, \dots, d)$ 的多重度 (包括多重度 1) 为 m_i ，即 $m_1 + m_2 + \dots + m_d = m$ ，并将多重度从小到大进行排列。

步骤 2 利用相似变换公式 $AP = PJ$ 求出与具有多重度 m_i 的多重特征值对应的 m_i 个相似变换向量。具体计算公式为

$$\left. \begin{aligned} Ap_{i1} &= \lambda_i p_{i1} \\ Ap_{i2} &= p_{i1} + \lambda_i p_{i2} \\ &\vdots \\ Ap_{im_i} &= p_{im_{i-1}} + \lambda_i p_{im_i} \end{aligned} \right\} \quad (3.2.7)$$

其中， $i = 1, 2, \dots, d$ 。

步骤 3 按照多重度的排列顺序，将 m 个相似变换向量依次排列，组成相似变换矩阵 P 。然后，计算相似变换矩阵的逆矩阵 P^{-1} 。

步骤 4 计算矩阵的相似化简的 Jordan 标准型

$$P^{-1}AP = J \quad (3.2.8)$$

3.3 矩阵的相似化简

例 3.2.3 使用相似化简求例 3.2.2 所给矩阵的 Jordan 标准型。

利用 $|\lambda I - A| = 0$ 求出特征值 $\lambda = -1$, 多重度为 3。

由式 (3.2.7) 的第 1 式求 3×3 相似变换矩阵 P 的第 1 列, 有

$$\begin{bmatrix} 1 & 0 & 4 \\ 2 & -1 & 4 \\ -1 & 0 & -3 \end{bmatrix} \begin{bmatrix} p_{11} \\ p_{21} \\ p_{31} \end{bmatrix} = - \begin{bmatrix} p_{11} \\ p_{21} \\ p_{31} \end{bmatrix}$$

由此得 $p_{11} = -p_{31}$ 以及 p_{21} 任意。取 $p_{11} = p_{31} = 0$ 和 $p_{21} = 1$ 。

又由式 (3.2.7) 的第 2 式即

$$\begin{bmatrix} 1 & 0 & 4 \\ 2 & -1 & 4 \\ -1 & 0 & -3 \end{bmatrix} \begin{bmatrix} p_{12} \\ p_{22} \\ p_{32} \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} - \begin{bmatrix} p_{12} \\ p_{22} \\ p_{32} \end{bmatrix}$$

有 $p_{12} = -2p_{32}$ 及 p_{22} 任意。取 $p_{12} = 2, p_{22} = 2, p_{32} = -1$ 。

类似地, 由

$$\begin{bmatrix} 1 & 0 & 4 \\ 2 & -1 & 4 \\ -1 & 0 & -3 \end{bmatrix} \begin{bmatrix} p_{13} \\ p_{23} \\ p_{33} \end{bmatrix} = \begin{bmatrix} 2 \\ 2 \\ -1 \end{bmatrix} - \begin{bmatrix} p_{13} \\ p_{23} \\ p_{33} \end{bmatrix}$$

3.3 矩阵的相似化简

得 $p_{13} + 2p_{33} = 1$ 及 p_{32} 任意。取 $p_{13} = 1, p_{23} = 0, p_{33} = 0$ 。由此得相似变换矩阵及其逆矩阵

$$\mathbf{P} = \begin{bmatrix} 0 & 2 & 1 \\ 1 & 2 & 0 \\ 0 & -1 & 0 \end{bmatrix}, \quad \mathbf{P}^{-1} = \begin{bmatrix} 0 & 1 & 2 \\ 0 & 0 & -1 \\ 1 & 0 & 2 \end{bmatrix} \quad (3.2.9)$$

矩阵 \mathbf{A} 的相似化简结果为 Jordan 标准型矩阵

$$\mathbf{J} = \mathbf{P}^{-1}\mathbf{A}\mathbf{P} = \begin{bmatrix} -1 & 0 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \end{bmatrix} \quad (3.2.10)$$

上述典型例子表明，当存在多重特征值时，不能随便臆断与之对应的 Jordan 标准型块矩阵就一定取式 (3.2.5) 的形式。

矩阵的相似化简与特征分析

- **对称矩阵**的特征值分解
 - 特征值和特征向量的性质
 - 广义特征值分解
- 矩阵的相似变换与对角化
 - 矩阵的可对角化条件