

第七章-特征值和特征向量

(2): QR 分解和 QR 算法

目录

1. 背景
2. QR 分解和 Householder 方法
3. QR 算法
4. 总结

幂法及其变式可以求解特定的特征值和特征向量。

目标：同时求解**所有**的特征值和特征向量。

目录

1. 背景
2. QR 分解和 Householder 方法
3. QR 算法
4. 总结

QR 分解

定理 (QR 分解)

- ▶ 对于任何的非奇异 n 阶矩阵 \mathbf{A} , 则 \mathbf{A} 可分解为 $\mathbf{A} = \mathbf{QR}$; 其中 \mathbf{Q} 为正交矩阵 (即 $\mathbf{Q}^T = \mathbf{Q}^{-1} \leftrightarrow \mathbf{QQ}^T = \mathbf{I}, \mathbf{Q}^T\mathbf{Q} = \mathbf{I}$), \mathbf{R} 为上三角矩阵。
- ▶ 当 \mathbf{R} 的对角元素都为正数时, 该 QR 分解唯一。

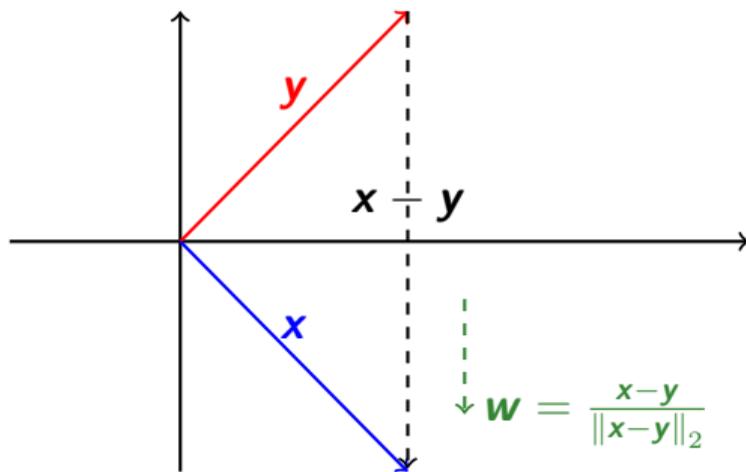
接下来, 我们会学习如何找到这样的 QR 分解。

探究关系 $Q^T \mathbf{A} = \mathbf{R}$ 的第一列，我们至少需要找到某个 Q 使得

$$Q^T \mathbf{a}_1 = \begin{bmatrix} r_1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \text{ 其中 } \mathbf{a}_1 \text{ 是矩阵 } \mathbf{A} \text{ 的第一列。}$$

问题： $|r_1|$ 和 $\|\mathbf{a}_1\|_2$ 需要有什么关系吗？

我们探究一般的情况，如何通过一个正交矩阵实现变换 $Q\mathbf{x} = \mathbf{y}$ ，其中 \mathbf{x} 和 \mathbf{y} 是给定的向量，且 $\|\mathbf{x}\|_2 = \|\mathbf{y}\|_2$



我们观察到：

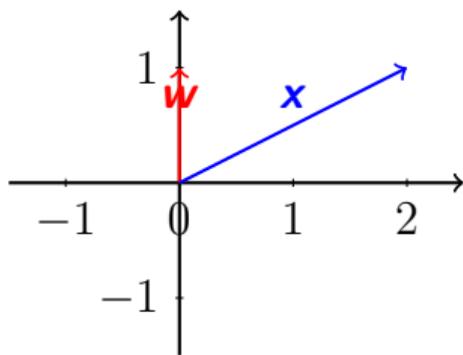
$$\mathbf{y} = \mathbf{x} - (\mathbf{x} - \mathbf{y}) = \mathbf{x} - \|\mathbf{x} - \mathbf{y}\| \mathbf{w} = \mathbf{x} - 2\langle \mathbf{w}, \mathbf{x} \rangle \mathbf{w} = (\mathbf{I} - 2\mathbf{w}\mathbf{w}^T) \mathbf{x}.$$

练习：请验证 $\mathbf{I} - 2\mathbf{w}\mathbf{w}^T$ 是对称的正交矩阵。

定义 (初等反射阵)

假设向量 $\|\mathbf{w}\|_2 = 1$, 矩阵 $\mathbf{H} = \mathbf{I} - 2\mathbf{w}\mathbf{w}^T$ 称为初等反射阵, 又记为 $\mathbf{H}(\mathbf{w})$ 。

练习: 请在图中大致画出 $\mathbf{H}(\mathbf{w})\mathbf{x}$



定理

初等反射阵 \mathbf{H} 为对称阵 ($\mathbf{H}^T = \mathbf{H}$), 正交阵 ($\mathbf{H}^T \mathbf{H} = \mathbf{I}$) 和对合阵 ($\mathbf{H}^2 = \mathbf{I}$)。

总结

定理

设 $\mathbf{x} \neq \mathbf{y} \in \mathbb{R}^n$ ，且 $\|\mathbf{x}\|_2 = \|\mathbf{y}\|_2$ ，则存在一个初等反射阵 \mathbf{H} ，使得 $\mathbf{H}\mathbf{x} = \mathbf{y}$ 。

证明：取 $\mathbf{w} = \frac{\mathbf{x}-\mathbf{y}}{\|\mathbf{x}-\mathbf{y}\|_2}$

定理 (推论)

设 $\mathbf{x} \in \mathbb{R}^n$ ，令 $\sigma = \pm\|\mathbf{x}\|_2$ ，且 $\mathbf{x} \neq -\sigma\mathbf{e}_1$ ，则存在一个初等反射阵 $\mathbf{H} = \mathbf{I} - 2\frac{\mathbf{u}\mathbf{u}^T}{\|\mathbf{u}\|_2^2}$ ，使得 $\mathbf{H}\mathbf{x} = -\sigma\mathbf{e}_1$ ，其中 $\mathbf{u} = \mathbf{x} + \sigma\mathbf{e}_1$ 。

证明：在最上面的定理中，取 $\mathbf{y} = -\sigma\mathbf{e}_1$ 。

提示：为避免有效数字的缺失，我们会取 $\sigma = \text{sign}(x_1)\|\mathbf{x}\|_2$ ；但实际情况中，除非 \mathbf{x} 平行于 \mathbf{e}_1 ，否则 $\sigma = \pm\|\mathbf{x}\|_2$ 都是可以的。

考虑矩阵 \mathbf{A} 的列 $\mathbf{A} = (\mathbf{A}_1 \ \mathbf{A}_2 \ \dots \ \mathbf{A}_n)$ 则

$$\begin{aligned} \mathbf{HA} &= (\mathbf{HA}_1 \ \mathbf{HA}_2 \ \dots \ \mathbf{HA}_n) \\ &= \begin{pmatrix} -\sigma_1 & & & \\ 0 & \mathbf{HA}_2 & \dots & \mathbf{HA}_n \\ \vdots & & & \\ 0 & & & \end{pmatrix} = \left(\begin{array}{c|ccc} -\sigma_1 & \star & \dots & \star \\ \hline 0 & & & \\ \vdots & & \mathbf{A}^{(2)} & \\ 0 & & & \end{array} \right) \end{aligned}$$

若我们希望系数为 σ_1 ，则可以通过

$$(-\mathbf{H})\mathbf{A} = \begin{pmatrix} \sigma_1 & & & \\ 0 & -\mathbf{HA}_2 & \dots & -\mathbf{HA}_n \\ \vdots & & & \\ 0 & & & \end{pmatrix} = \left(\begin{array}{c|ccc} \sigma_1 & \star & \dots & \star \\ \hline 0 & & & \\ \vdots & & \mathbf{A}^{(2)} & \\ 0 & & & \end{array} \right)$$

对于 $\mathbf{A}^{(2)}$ ，我们可以重复过程找到某个对称且正交矩阵 $\mathbf{H}^{(2)}$ ，使得

$$\mathbf{H}^{(2)} \mathbf{A}^{(2)} = \left(\begin{array}{c|ccc} -\sigma_2 & \star & \cdots & \star \\ \hline 0 & & & \\ \vdots & & & \\ 0 & & & \end{array} \mathbf{A}^{(3)} \right)$$

因此，

$$\underbrace{\begin{pmatrix} 1 & 0 & 0 & \cdots & 0 \\ 0 & & & & \\ 0 & & & & \\ \vdots & & & & \\ 0 & & & & \end{pmatrix}}_{\tilde{\mathbf{H}}^{(2)}} \begin{pmatrix} -\sigma_1 & \star & \cdots & \cdots & \star \\ \hline 0 & & & & \\ \vdots & & & & \\ \vdots & & & & \\ 0 & & & & \end{pmatrix} \mathbf{A}^{(2)} = \begin{pmatrix} -\sigma_1 & \star & \cdots & \cdots & \star \\ 0 & -\sigma_2 & \star & \cdots & \star \\ 0 & 0 & & & \\ 0 & \vdots & & & \\ 0 & 0 & & & \end{pmatrix} \mathbf{A}^{(3)}$$

通过不断继续, 可得 $\tilde{H}^{(n)} \tilde{H}^{(n-1)} \dots \tilde{H}^{(2)} \tilde{H}^{(1)} \mathbf{A} = \mathbf{R}$ 一个上三角矩阵, 其中 $\tilde{H}^{(k)}$ 为第 k 层基于 Householder 构造的对称正交阵。在这个过程中, 我们可以保证 $R_{ii} \geq 0$ 。

最后, 令 $\mathbf{Q}^{-1} = \tilde{H}^{(n)} \tilde{H}^{(n-1)} \dots \tilde{H}^{(2)} \tilde{H}^{(1)}$, 则 $\mathbf{A} = \mathbf{QR}$ 。

练习: 请验证这样定义出来的矩阵 \mathbf{Q} 为正交矩阵, 且

$$\mathbf{Q} = \tilde{H}^{(1)} \tilde{H}^{(2)} \dots \tilde{H}^{(n-1)} \tilde{H}^{(n)}$$

练习：请计算矩阵 \mathbf{A} 的 QR 分解，其中 $\mathbf{A} = \begin{bmatrix} 1 & -2 & 1 \\ 2 & 2 & 1 \\ -2 & 1 & 0 \end{bmatrix}$

答案： $\mathbf{Q} = \begin{bmatrix} 1/3 & -2/3 & 2/3 \\ 2/3 & 2/3 & 1/3 \\ -2/3 & 1/3 & 2/3 \end{bmatrix}$, $\mathbf{R} = \begin{bmatrix} 3 & 0 & 1 \\ 0 & 3 & 0 \\ 0 & 0 & 1 \end{bmatrix}$

计算复杂度

矩阵 Q 可由如下算法实现:

$$Q = I_n$$
$$Q = Q\tilde{H}^{(k)}, \quad k = 1, 2, \dots, n$$

这个过程中, 计算量为 $\mathcal{O}(n^2 + n(n-1) + \dots + n) = \mathcal{O}(n^3)$

计算上三角矩阵 R 的复杂度为 $\mathcal{O}(n^2 + (n-1)^2 + \dots + 1) = \mathcal{O}(n^3)$

总体而言, 基于 Householder 的 QR 算法的复杂度为 $\mathcal{O}(n^3)$ 。

目录

1. 背景
2. QR 分解和 Householder 方法
3. QR 算法
4. 总结

QR 算法

给定 $\mathbf{A} \stackrel{\text{分解}}{=} \mathbf{QR}$, 我们取 $\mathbf{B} \stackrel{\text{定义}}{=} \mathbf{RQ} = \mathbf{Q}^T \mathbf{A} \mathbf{Q}$

我们可以观察到 \mathbf{A} 和 \mathbf{B} 具有相同的特征值。

$$\mathbf{A} \equiv \mathbf{A}_1 \stackrel{\text{分解}}{=} \mathbf{Q}_1 \mathbf{R}_1$$

$$\mathbf{A}_2 \stackrel{\text{定义}}{=} \mathbf{R}_1 \mathbf{Q}_1 = \mathbf{Q}_1^T \mathbf{A}_1 \mathbf{Q}_1 \quad \mathbf{A}_2 \stackrel{\text{分解}}{=} \mathbf{Q}_2 \mathbf{R}_2$$

$$\mathbf{A}_3 \stackrel{\text{定义}}{=} \mathbf{R}_2 \mathbf{Q}_2 \quad \mathbf{A}_3 \stackrel{\text{分解}}{=} \mathbf{Q}_3 \mathbf{R}_3$$

⋮

$$\mathbf{A}_k \stackrel{\text{分解}}{=} \mathbf{Q}_k \mathbf{R}_k$$

$$\mathbf{A}_{k+1} \stackrel{\text{定义}}{=} \mathbf{R}_k \mathbf{Q}_k$$

...

定理 (基本性质)

令 $\tilde{Q}_k = Q_1 Q_2 \cdots Q_k$, $\tilde{R}_k = R_k R_{k-1} \cdots R_1$, 则

- ▶ A_{k+1} 相似于 A_k , 即 $A_{k+1} = Q_k^T A_k Q_k$
- ▶ $A_{k+1} = \tilde{Q}_k^T A_1 \tilde{Q}_k$
- ▶ A^k 的 QR 分解为 $A^k = \tilde{Q}_k \tilde{R}_k$

证明该结论将作为练习。

QR 算法的收敛性

定理 (定理 9.18 QR 算法的收敛性)

设 $\mathbf{A} = (a_{ij}) \in \mathbb{R}^{n \times n}$,

1° 如果 \mathbf{A} 的特征值满足: $|\lambda_1| > |\lambda_2| > \cdots > |\lambda_n| > 0$;

2° \mathbf{A} 满足一些其他条件: **【 \mathbf{A} 有标准形 $\mathbf{A} = \mathbf{XDX}^{-1}$ 其中 $\mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \cdots, \lambda_n)$, 且设 \mathbf{X}^{-1} 有 LU 分解】**

则由 QR 算法产生的 $\{\mathbf{A}_k\}_{k=1}^{\infty}$ 收敛于上三角

$$\mathbf{A}_k \xrightarrow{\text{当 } k \rightarrow \infty} \begin{pmatrix} \lambda_1 & \times & \cdots & \times \\ & \lambda_2 & \ddots & \vdots \\ & & \ddots & \times \\ & & & \lambda_n \end{pmatrix}.$$

对于对称矩阵的 QR 算法

定理 (定理 9.19)

若对称阵 \mathbf{A} 满足定理 9.18 的条件, 则由 QR 算法产生的 $\{\mathbf{A}_k\}$ 收敛于对角阵。

目录

1. 背景
2. QR 分解和 Householder 方法
3. QR 算法
4. 总结

总结

- ▶ 知道 QR 分解是什么
- ▶ 能通过 Householder 方法计算 QR 分解，并了解其运算复杂度为 $\mathcal{O}(n^3)$
- ▶ 知道 QR 算法是什么，以及定理 9.18 和 9.19 的结论