

# 矩阵分解简介

统计 91 董晟渤

2021 年 8 月 29 日

## 目录

<b>1</b>	<b>前言</b>	<b>2</b>
<b>2</b>	<b>矩阵的初步分解</b>	<b>5</b>
2.1	满秩分解 . . . . .	5
2.2	UR 分解 . . . . .	6
2.3	LU 分解 . . . . .	7
<b>3</b>	<b>矩阵的奇异值分解</b>	<b>8</b>
3.1	奇异值的定义 . . . . .	8
3.2	奇异值分解定理 . . . . .	10
3.3	奇异值分解的编程实现 . . . . .	12
3.4	奇异值分解的应用 . . . . .	13
<b>4</b>	<b>矩阵的谱分解</b>	<b>15</b>
4.1	Jordan 标准形理论回顾 . . . . .	15
4.2	谱分解定理 . . . . .	15

## 1 前言

所谓的**矩阵分解**,指的是将给定的矩阵写为一系列矩阵的乘积.

在进行矩阵的分解的时候,首先需要清楚**分解的对象**是什么.例如,QR分解的对象是非奇异的实矩阵,而UR分解的对象是非奇异的复矩阵.除此之外,我们也可以尝试分解一些较为一般的矩阵.

除此之外,我们还需要明白**分解后的形式**是什么.通常,我们需要将矩阵分解得足够简洁,或者性质足够好,才能够简化问题.那么哪些矩阵是符合要求的呢?在此,给出几种相对简洁,或者性质较好的矩阵的定义.

最为简单的矩阵就是对角矩阵,其的定义如下.

**定义 1.1** (对角矩阵). 形如

$$\begin{pmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{pmatrix}_{n \times n}$$

的矩阵称为**对角矩阵**,记作  $\text{diag}\{\lambda_1, \lambda_2, \cdots, \lambda_n\}$ .

当然,在前面的课程中,我们知道,并不是所有的矩阵都可以被化成对角阵.但是, Jordan 型矩阵的理论指出,所有的矩阵都可以被化作 Jordan 型矩阵.

**定义 1.2** (Jordan 块和 Jordan 形矩阵). 形如

$$\mathbf{J}_i = \begin{pmatrix} \lambda_i & 1 & 0 & \cdots & 0 \\ 0 & \lambda_i & 1 & \cdots & 0 \\ 0 & 0 & \lambda_i & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & \lambda_i \end{pmatrix}_{n_i \times n_i}$$

的矩阵称为**Jordan 块**,而由若干个 Jordan 块形成的准对角矩阵

$$\mathbf{J} = \text{diag}\{\mathbf{J}_1, \mathbf{J}_2, \cdots, \mathbf{J}_n\}$$

称为**Jordan 形矩阵**.

再退一步, 上面的这两种矩阵, 它们的元素其实都集中在右上角. 从而, 我们可以定义更一般的, 像三角形一样的矩阵.

**定义 1.3** (上三角矩阵与下三角矩阵). 形如

$$\begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ 0 & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & x_{nn} \end{pmatrix}_{n \times n}$$

的矩阵称为上三角矩阵; 对应地, 形如

$$\begin{pmatrix} x_{11} & 0 & \cdots & 0 \\ x_{21} & x_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nn} \end{pmatrix}_{n \times n}$$

的矩阵称为下三角矩阵. 若上 (下) 三角矩阵对角线上的元素  $a_{ii} > 0 (1 \leq i \leq n)$ , 则称其为正线上 (下) 三角矩阵. 若上 (下) 三角矩阵对角线上的元素  $a_{ii} = 1 (1 \leq i \leq n)$ , 则称其为单位上 (下) 三角矩阵.

上三角矩阵和下三角矩阵是比较容易研究的, 并且可以通过转置来相互转化. 接下来, 对于  $\mathbb{R}^n$  中的实矩阵, 我们有正交矩阵的定义. 同时, 对于  $\mathbb{C}^n$  中的矩阵, 我们推广了正交矩阵的概念, 定义了所谓的酉矩阵.

**定义 1.4** (酉矩阵与正交矩阵). 设  $U \in \mathbb{C}^{n \times n}$ , 且满足

$$U^H U = U U^H = I,$$

则称其为酉矩阵. 对应地, 设  $Q \in \mathbb{R}^{n \times n}$ , 且满足

$$Q^T Q = Q Q^T = I,$$

则称其为正交矩阵.

更一般地, 我们可以给出如下的定义, 相当于是酉矩阵的一般情况.

**定义 1.5** (正规矩阵). 设  $\mathbf{A} \in \mathbb{C}^{n \times n}$ , 且满足

$$\mathbf{A}\mathbf{A}^H = \mathbf{A}^H\mathbf{A},$$

则称其为正规矩阵.

如果我们可以把矩阵分解为对角矩阵, 三角矩阵或者酉矩阵, 那么就能够方便地研究矩阵. 除此之外, 矩阵的分解也有许多实际中的应用.

以下, 我们用  $\mathbb{C}_r^{m \times n}$  来表示复数域  $\mathbb{C}$  上的  $m$  行  $n$  列且秩为  $r$  的矩阵. 对应地,  $\mathbb{R}_r^{m \times n}$  表示实数域  $\mathbb{R}$  上的  $m$  行  $n$  列且秩为  $r$  的矩阵.

## 2 矩阵的初步分解

之所以将这些分解方式叫作初步分解, 是因为这些方法几乎只需要用到高代中的基本方法. 所谓的基本方法, 包括初等行变换和正交化.

### 2.1 满秩分解

我们首先利用初等行变换, 寻求一般矩阵的分解方式. 并且在这里, 我们希望将矩阵分解为满秩的矩阵, 从而方便研究问题.

**定理 2.1** (满秩分解). 设  $A \in \mathbb{C}_r^{m \times n}$ , 则存在  $B \in \mathbb{C}_r^{m \times r}$  及  $C \in \mathbb{C}_r^{r \times n}$ , 使得

$$A = BC.$$

证明. 用初等行变换, 可以将矩阵  $A$  化成阶梯矩阵, 也即存在  $P \in \mathbb{C}_m^{m \times m}$ , 使得

$$PA = \begin{pmatrix} C \\ O \end{pmatrix},$$

其中  $C \in \mathbb{C}_r^{r \times n}$ . 再记

$$P^{-1} = \begin{pmatrix} B & D \end{pmatrix},$$

其中  $B = \mathbb{C}_r^{m \times r}$ , 则有

$$A = P^{-1} \begin{pmatrix} C \\ O \end{pmatrix} = \begin{pmatrix} B & D \end{pmatrix} \begin{pmatrix} C \\ O \end{pmatrix} = BC.$$

□

需要注意的是, 上面的证明过程, 同样给出了求矩阵的满秩分解的方式. 其中,  $B$  为列满秩矩阵,  $C$  为行满秩矩阵. 上面的分解只用到了初等行变换, 并不复杂. 为了求出  $P^{-1}$ , 可以考虑对分块矩阵  $\begin{pmatrix} A & I \end{pmatrix}$  作初等行变换, 使得  $A$  被化为阶梯矩阵.

## 2.2 UR 分解

接下来, 我们可以对一个  $n$  阶的非奇异复矩阵进行分解, 将其写成一个酉矩阵和上三角矩阵的乘积. 这个分解只需要应用 Gram-Schmidt 正交化方法.

**定理 2.2** (UR 分解). 设  $A \in \mathbb{C}_n^{n \times n}$ , 则存在酉矩阵  $U$  及正线上三角矩阵  $R$ , 使得

$$A = UR.$$

证明. 记

$$A = (\alpha_1, \alpha_2, \dots, \alpha_n).$$

应用 Gram-Schmidt 正交化方法, 我们可以将  $A$  的列向量化为标准正交向量组  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$ , 且有

$$\begin{cases} \alpha_1 = r_{11}\mathbf{u}_1, \\ \alpha_2 = r_{12}\mathbf{u}_1 + r_{22}\mathbf{u}_2, \\ \dots, \\ \alpha_n = r_{1n}\mathbf{u}_1 + r_{2n}\mathbf{u}_2 + \dots + r_{nn}\mathbf{u}_n. \end{cases}$$

其中  $r_{ii} > 0$ . 记

$$U = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n), \mathbf{R} = \begin{pmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ 0 & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & r_{nn} \end{pmatrix},$$

则有  $A = UR$ , 其中  $U$  为酉矩阵,  $R$  为正线上三角矩阵. □

将范围限制在实数上, 立即得到如下推论.

**推论 2.3** (QR 分解). 设  $A \in \mathbb{R}_n^{n \times n}$ , 则存在正交矩阵  $Q$  及正线上三角矩阵  $R$ , 使得

$$A = QR.$$

上面的证明过程, 其实也给出了求矩阵的 UR 分解的方式.

### 2.3 LU 分解

再考虑更加特殊的  $n$  阶的实矩阵. 我们不但要求它是非奇异的, 还要求它的所有顺序主子式都非零.

**定理 2.4.** 设  $\mathbf{A} \in \mathbb{R}^{n \times n}$ , 且所有顺序主子式都非零, 则存在单位下三角矩阵  $\mathbf{L}$  和非奇异上三角矩阵  $\mathbf{U}$ , 使得

$$\mathbf{A} = \mathbf{L}\mathbf{U}.$$

证明. 当  $n = 1$  时, 结论一定成立.

假设所有的  $n - 1$  阶的所有顺序主子式都非零的矩阵都存在 LU 分解, 考虑满足条件的  $n$  阶的矩阵  $\mathbf{A}$ , 将其写成分块形式

$$\mathbf{A} = \begin{pmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{A}_{22} \end{pmatrix},$$

其中  $\mathbf{A}_{11} \in \mathbb{R}^{n \times n}$ , 并且其顺序主子式都非零, 从而存在单位下三角矩阵  $\mathbf{L}_{11}$  和非奇异上三角矩阵  $\mathbf{U}_{11}$ , 使得

$$\mathbf{A}_{11} = \mathbf{L}_{11}\mathbf{U}_{11}.$$

令  $\mathbf{L}_{21} = \mathbf{A}_{21}\mathbf{U}_{11}^{-1}$ ,  $\mathbf{U}_{12} = \mathbf{L}_{11}^{-1}\mathbf{A}_{12}$ ,  $\mathbf{U}_{22} = \mathbf{A}_{22} - \mathbf{L}_{21}\mathbf{U}_{12}$ , 则

$$\mathbf{A} = \begin{pmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{A}_{22} \end{pmatrix} = \begin{pmatrix} \mathbf{L}_{11} & \mathbf{O} \\ \mathbf{L}_{21} & \mathbf{1} \end{pmatrix} \begin{pmatrix} \mathbf{U}_{11} & \mathbf{U}_{12} \\ \mathbf{O} & \mathbf{U}_{22} \end{pmatrix}.$$

记  $\mathbf{L} = \begin{pmatrix} \mathbf{L}_{11} & \mathbf{O} \\ \mathbf{L}_{21} & \mathbf{1} \end{pmatrix}$ ,  $\mathbf{U} = \begin{pmatrix} \mathbf{U}_{11} & \mathbf{U}_{12} \\ \mathbf{O} & \mathbf{U}_{22} \end{pmatrix}$ , 则  $\mathbf{A} = \mathbf{L}\mathbf{U}$ , 其中  $\mathbf{L}$  为单位下三角矩阵,  $\mathbf{U}$  为非奇异上三角矩阵. □

要实现矩阵的 LU 分解, 有许多的算法, 最基本的是 **Gauss 消去法**. 限于篇幅有限, 在此没有展开介绍.

### 3 矩阵的奇异值分解

#### 3.1 奇异值的定义

为了给出奇异值的定义, 我们需要先证明一些结论.

**引理 3.1.** 设  $A \in \mathbb{C}_r^{m \times n}$ , 则

$$\text{rank}(A^H A) = \text{rank}(A A^H) = r.$$

**证明.** 一方面, 设  $x \in \mathbb{C}^n$  是齐次线性方程组  $Ax = 0$  的解, 则有

$$A^H Ax = A^H 0 = 0,$$

从而  $A^H Ax = 0$ ; 另外一方面, 设  $x \in \mathbb{C}^n$  是方程组  $A^H Ax = 0$  的解, 则有

$$(Ax)^H Ax = x^H A^H Ax = x^H 0 = 0,$$

从而  $Ax = 0$ . 由上知  $\text{rank}(A^H A) = \text{rank}(A) = r$ . 同理  $\text{rank}(A A^H) = r$ . □

**引理 3.2.** 设  $A \in \mathbb{C}_r^{m \times n}$ , 则  $A^H A$  与  $A A^H$  的特征值都是非负实数.

**证明.** 设  $\lambda$  是  $A^H A$  的任一特征值, 其对应的特征向量为  $\alpha$ , 则

$$A^H A \alpha = \lambda \alpha.$$

从而

$$\alpha^H A^H A \alpha = (A \alpha)^H A \alpha = \lambda \alpha^H \alpha,$$

解得  $\lambda = \frac{(A \alpha)^H A \alpha}{\alpha^H \alpha} \geq 0$ . 同理  $A A^H$  的特征值都是非负实数. □

**引理 3.3.** 设  $A \in \mathbb{C}_r^{m \times n}$ , 则  $A^H A$  与  $A A^H$  非零特征值相同, 且个数都为  $r$ .

**证明.** 设  $\lambda$  是  $A^H A$  的任一特征值, 其对应的特征向量为  $\alpha$ , 则

$$A^H A \alpha = \lambda \alpha.$$



从而

$$\mathbf{A}\mathbf{A}^H\mathbf{A}\boldsymbol{\alpha} = \lambda\mathbf{A}\boldsymbol{\alpha},$$

也即  $\lambda$  是  $\mathbf{A}\mathbf{A}^H$  的特征值, 其对应的特征向量为  $\mathbf{A}\boldsymbol{\alpha}$ . 另外, 根据  $\text{rank}(\mathbf{A}^H\mathbf{A}) = \text{rank}(\mathbf{A}\mathbf{A}^H) = r$  知特征值的个数为  $r$ .  $\square$

在上面的基础下, 我们可以开始考虑矩阵  $\mathbf{A}^H\mathbf{A}$  和  $\mathbf{A}\mathbf{A}^H$  的特征值了. 我们知道, 它们的特征值都是相同的, 且必定是非负的. 因此以下定义是合理的.

**定义 3.4** (奇异值). 设  $\mathbf{A} \in \mathbb{C}_r^{m \times n}$ , 记  $\mathbf{A}^H\mathbf{A}$  的特征值为  $\lambda_1, \lambda_2, \dots, \lambda_r$ , 则

$$\delta_i = \sqrt{\lambda_i}, 1 \leq i \leq r$$

称为矩阵  $\mathbf{A}$  的奇异值.

事实上, 上面的定义还有另外一种等价的写法.

**定义 3.5** (奇异值). 设  $\mathbf{A} \in \mathbb{C}_r^{m \times n}$ , 若存在非负实数  $\delta$  及向量  $\mathbf{u} \in \mathbb{C}^n, \mathbf{v} \in \mathbb{C}^m$ , 使得

$$\mathbf{A}\mathbf{u} = \delta\mathbf{v}, \mathbf{A}^H\mathbf{v} = \delta\mathbf{u},$$

则称  $\delta$  为  $\mathbf{A}$  的奇异值,  $\mathbf{u}$  和  $\mathbf{v}$  为  $\mathbf{A}$  对应于奇异值  $\delta$  的右奇异向量 和左奇异向量.

一方面, 设  $\lambda$  是  $\mathbf{A}^H\mathbf{A}$  的特征值, 对应的特征向量为  $\boldsymbol{\alpha}$ , 则

$$\mathbf{A}^H\mathbf{A}\boldsymbol{\alpha} = \lambda\boldsymbol{\alpha}.$$

由上知  $\boldsymbol{\beta} = \frac{1}{\delta}\mathbf{A}\boldsymbol{\alpha}$  是  $\mathbf{A}\mathbf{A}^H$  的特征向量, 计算得

$$\mathbf{A}^H\boldsymbol{\beta} = \frac{1}{\delta} \cdot \lambda\boldsymbol{\alpha} = \delta\boldsymbol{\alpha}.$$

从而  $\boldsymbol{\alpha}$  和  $\boldsymbol{\beta}$  分别是  $\mathbf{A}$  的右奇异向量和左奇异向量.

另一方面, 设存在非负实数  $\delta$  及非零向量  $\mathbf{u} \in \mathbb{C}^n, \mathbf{v} \in \mathbb{C}^m$ , 使得

$$\mathbf{A}\mathbf{u} = \delta\mathbf{v}, \mathbf{A}^H\mathbf{v} = \delta\mathbf{u},$$

计算得

$$\mathbf{A}^H \mathbf{A} \mathbf{u} = \delta \mathbf{A}^H \mathbf{v} = \delta^2 \mathbf{u}.$$

从而  $\delta^2$  是  $\mathbf{A}^H \mathbf{A}$  的特征值. 这便说明了上述两种定义的等价性.

### 3.2 奇异值分解定理

接下来, 对于一般的矩阵, 我们给出如下的分解方式.

**定理 3.6** (奇异值分解). 设  $\mathbf{A} \in \mathbb{C}^{m \times n}$ , 则存在酉矩阵  $\mathbf{V} \in \mathbb{C}^{m \times m}$  和  $\mathbf{U} \in \mathbb{C}^{n \times n}$ , 使得

$$\mathbf{V}^H \mathbf{A} \mathbf{U} = \begin{pmatrix} \mathbf{S} & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{pmatrix},$$

其中  $\mathbf{S} = \text{diag}\{\delta_1, \delta_2, \dots, \delta_r\}$ ,  $\delta_1 \geq \delta_2 \geq \dots \geq \delta_r \geq 0$  为  $\mathbf{A}$  的奇异值.

证明. 设  $\mathbf{A}^H \mathbf{A}$  的特征值为  $\delta_1^2, \delta_2^2, \dots, \delta_r^2$ , 注意到此时  $\mathbf{A}^H \mathbf{A}$  为 Hermite 矩阵, 从而存在酉矩阵  $\mathbf{U} \in \mathbb{C}^{n \times n}$ , 使得

$$\mathbf{U}^H \mathbf{A}^H \mathbf{A} \mathbf{U} = \text{diag}\{\delta_1^2, \delta_2^2, \dots, \delta_r^2, 0, \dots, 0\} = \begin{pmatrix} \mathbf{S}^2 & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{pmatrix}.$$

记  $\mathbf{U} = (\mathbf{U}_1 \ \mathbf{U}_2)$ , 其中  $\mathbf{U}_1 \in \mathbb{C}^{n \times r}$ , 则

$$\begin{cases} \mathbf{A}^H \mathbf{A} \mathbf{U}_1 = \mathbf{U}_1 \mathbf{S}^2, \\ \mathbf{A}^H \mathbf{A} \mathbf{U}_2 = \mathbf{O}. \end{cases}$$

进而可得  $\mathbf{A} \mathbf{U}_2 = \mathbf{O}$ . 令  $\mathbf{V}_1 = \mathbf{A} \mathbf{U}_1 \in \mathbb{C}^{m \times r} \mathbf{S}^{-1}$ , 可以验证  $\mathbf{V}_1^H \mathbf{V}_1 = \mathbf{I}$ . 将  $\mathbf{V}_1$  扩充为  $\mathbf{V} = (\mathbf{V}_1 \ \mathbf{V}_2) \in \mathbb{C}^{m \times m}$ , 使得  $\mathbf{V}$  为酉矩阵, 此时  $\mathbf{V}_2^H \mathbf{A} \mathbf{U}_1 = \mathbf{V}_2^H \mathbf{V}_1 \mathbf{S} = \mathbf{O}$ , 则有

$$\begin{cases} \mathbf{V}_1^H \mathbf{A} \mathbf{U}_1 = \mathbf{S}, \\ \mathbf{V}_2^H \mathbf{A} \mathbf{U}_1 = \mathbf{O}. \end{cases}$$

代入计算得

$$\mathbf{V}^H \mathbf{A} \mathbf{U} = \begin{pmatrix} \mathbf{V}_1^H \\ \mathbf{V}_2^H \end{pmatrix} \mathbf{A} \begin{pmatrix} \mathbf{U}_1 & \mathbf{U}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{V}_1^H \mathbf{A} \mathbf{U}_1 & \mathbf{V}_1^H \mathbf{A} \mathbf{U}_2 \\ \mathbf{V}_2^H \mathbf{A} \mathbf{U}_1 & \mathbf{V}_2^H \mathbf{A} \mathbf{U}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{S} & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{pmatrix}.$$

□

事实上, 上面的证明过程也给出了求矩阵的奇异值分解的方式. 对于矩阵  $\mathbf{A}$ ,

- 首先, 我们需要求出矩阵  $\mathbf{A}^H \mathbf{A}$  的特征值与特征向量, 开根号后即可得到奇异值;
- 其次, 根据特征向量, 进行单位正交化后可以得到矩阵  $\mathbf{U} = (\mathbf{U}_1 \ \mathbf{U}_2)$ ;
- 接下来, 利用等式  $\mathbf{V}_1 = \mathbf{A} \mathbf{U}_1 \mathbf{S}^{-1}$ , 再单位正交扩充得到  $\mathbf{V} = (\mathbf{V}_1 \ \mathbf{V}_2)$ ;
- 最后, 得到了矩阵  $\mathbf{A}$  的奇异值分解  $\mathbf{V}^H \mathbf{A} \mathbf{U} = \begin{pmatrix} \mathbf{S} & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{pmatrix}$ .

另外一方面, 如果  $\mathbf{A} \mathbf{A}^H$  的特征向量更容易求出的话, 也可以从  $\mathbf{V}$  出发, 再算出  $\mathbf{U}$ .

在这里, 奇异值分解还有另外一种写法. 记

$$\mathbf{U} = (\mathbf{u}_1, \dots, \mathbf{u}_r, \mathbf{u}_{r+1}, \dots, \mathbf{u}_n), \mathbf{V} = (\mathbf{v}_1, \dots, \mathbf{v}_r, \mathbf{v}_{r+1}, \dots, \mathbf{v}_m).$$

代入计算得此时

$$\begin{aligned} \mathbf{A} &= \mathbf{V} \begin{pmatrix} \mathbf{S} & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{pmatrix} \mathbf{U}^H = (\mathbf{v}_1, \dots, \mathbf{v}_m) \begin{pmatrix} \mathbf{S} & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{pmatrix} \begin{pmatrix} \mathbf{u}_1 \\ \mathbf{u}_2 \\ \vdots \\ \mathbf{u}_n \end{pmatrix} \\ &= \sum_{i=1}^r \delta_i \mathbf{v}_i \mathbf{u}_i^H. \end{aligned}$$

据最后一式, 我们成功地将矩阵  $\mathbf{A}$  写成了一系列矩阵的线性组合. 其中,  $\mathbf{v}_i \mathbf{u}_i^H$  都是酉矩阵, 其前面的系数是从大到小排列的. 这在奇异值分解的后续应用中非常重要.

### 3.3 奇异值分解的编程实现

在 MATLAB 中, 函数 `svd` 可以用来求矩阵的奇异值分解, 例如对矩阵  $\mathbf{A}$ , 用法如下.

```
1 [V S U] = svd(A);
```

根据该命令, 可以将矩阵  $\mathbf{A}$  分解为

$$\mathbf{A} = \mathbf{V}\mathbf{S}\mathbf{U},$$

其中  $\mathbf{V}$  和  $\mathbf{U}$  都是酉矩阵,  $\mathbf{S}$  的对角线上的元素都是  $\mathbf{A}$  的奇异值.

例 3.7. 利用 *MATLAB* 求矩阵

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

的奇异值分解.

解答 在 *MATLAB* 中输入如下代码.

```
1 A = [0 1; -1 0; 0 2; 1 0];
2 [V S U] = svd(A);
```

最终计算得到的结果是

$$\mathbf{V} = \begin{pmatrix} -0.447 & 0 & -0.784 & -0.430 \\ 0 & 0.707 & -0.340 & 0.620 \\ -0.894 & 0 & 0.392 & 0.215 \\ 0 & -0.707 & -0.340 & 0.620 \end{pmatrix}, \mathbf{S} = \begin{pmatrix} 2.236 & 0 \\ 0 & 1.414 \\ 0 & 0 \\ 0 & 0 \end{pmatrix}, \mathbf{U} = \begin{pmatrix} 0 & -1 \\ -1 & 0 \end{pmatrix}.$$

从而我们得到了矩阵  $\mathbf{A}$  的奇异值分解  $\mathbf{A} = \mathbf{V}\mathbf{S}\mathbf{U}$ .

### 3.4 奇异值分解的应用

在这里, 个人尝试自己编写了程序, 成功实现了图片压缩. 设此时目录中有一个彩色图片pic.png, 我们首先将其转化为黑白图片. 黑白图片上的每一点都有所谓的灰度, 从

而其对应着一个矩阵  $C$ . 我们尝试对这个矩阵  $C$  进行奇异值分解

$$C = \sum_{i=1}^r \delta_i \mathbf{v}_i \mathbf{u}_i^H,$$

其中  $\delta_1 \geq \delta_2 \geq \dots \geq \delta_r$ , 再对  $n < r$ , 取上式的前  $n$  项  $\sum_{i=1}^n \delta_i \mathbf{v}_i \mathbf{u}_i^H$ , 其可以作为矩阵  $A$  的近似替代. 这便是利用奇异值分解完成图像压缩的基本原理, 对应的代码如下.

```

1   % 输入图像
2   A = imread('.\pic.png');
3
4   % 将图像转化为黑白
5   B = rgb2gray(A);
6   imwrite(B, '.\pic-pre.png','png');
7   figure();
8   imshow(B);
9
10  % 计算SVD分解, 并取前n项
11  C = im2double(B);
12  [U, S, V] = svd(C);
13  n = 50;
14  D = S(1, 1) * U(:, 1) * V(:, 1)';
15  for k = 2 : n
16      D = D + S(k, k) * U(:, k) * V(:, k)';
17  end
18
19  % 输出压缩结果
20  P = im2uint8(D);
21  imwrite(P, '.\pic-print.png','png');
22  figure();
23  imshow(P);

```

在上面, 取  $n = 50$ , 可以得到较为理想的分解式. 在实际应用中, 改变  $n$  的值, 可以得到不同的结果. 为了体现这一点, 在此取  $n = 1, 5, 10, 30, 50$ , 并与原图作比较.

从而, 我们利用矩阵的奇异值分解, 成功实现了简易的图像压缩. 但事实上, 上面的

方法效率较低. 通过查阅资料得知, 通常图像压缩需要结合图片本身的特征, 例如图像中往往有一部分是连续的, 同时有一些棱角. 从而, 使用小波分解的方法, 效率会更高.

## 4 矩阵的谱分解

### 4.1 Jordan 标准形理论回顾

接下来, 我们处理的对象是方阵. 在前序课程中, 我们已经引入了将矩阵对角化, 或者化为 Jordan 标准形的理论和方式. 在这里不加证明地给出相关的定理, 并且指出, 这也是一种矩阵分解的方式.

**定理 4.1** (Jordan 标准形). 设  $A \in \mathbb{C}_r^{n \times n}$ , 则存在  $P \in \mathbb{C}_n^{n \times n}$  及  $n$  阶 Jordan 形矩阵  $J$ , 使得

$$P^{-1}AP = J.$$

其中  $J$  称为矩阵  $A$  的 Jordan 标准形.

根据这个定理, 我们可以将矩阵  $A$  分解为

$$A = PJP^{-1}.$$

同时, 如果矩阵  $A$  所对应的 Jordan 标准形是由一系列一阶的 Jordan 块组成的, 则此时  $J$  为对角矩阵, 称此时矩阵  $A$  可对角化.

### 4.2 谱分解定理

谱分解的对象是 可对角化的矩阵, 这种分解方式也被叫作特征分解.

首先, 我们需要明白分解后的结果应该是什么样的. 在谱分解中, 可以将一个可对角化的矩阵, 分解成一系列的幂等矩阵的线性组合. 而所谓的幂等矩阵, 与投影矩阵是等价的. 在此, 不再介绍较为复杂的幂等矩阵和投影矩阵的理论, 直接给出幂等矩阵的定义.

**定义 4.2** (幂等矩阵). 设  $A \in \mathbb{C}^{n \times n}$ , 且满足

$$A^2 = A,$$

则称其为 幂等矩阵.

**定理 4.3** (谱分解). 设  $\mathbf{A} \in \mathbb{C}^{n \times n}$ , 且可对角化, 则存在一系列正交的幂等矩阵  $P_1, P_2, \dots, P_k$ , 使得

$$\mathbf{A} = \sum_{i=1}^n \lambda_i \mathbf{P}_i,$$

其中  $\lambda_i$  为  $\mathbf{P}$  的特征值, 且

$$\sum_{i=1}^n \mathbf{P}_i = \mathbf{I}.$$

证明. 首先, 设  $\mathbf{A}$  的特征值为  $\lambda_1, \lambda_2, \dots, \lambda_n$ , 线性无关的特征向量为  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ , 记  $\mathbf{P} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ , 则有

$$\mathbf{A} = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^{-1} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) \begin{pmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{pmatrix} \begin{pmatrix} \mathbf{y}_1^H \\ \mathbf{y}_2^H \\ \vdots \\ \mathbf{y}_n^H \end{pmatrix} = \sum_{i=1}^n \lambda_i \mathbf{x}_i \mathbf{y}_i^H,$$

其中  $\mathbf{y}_i^H$  是矩阵  $\mathbf{P}^{-1}$  的行向量. 记  $\mathbf{x}_i \mathbf{y}_i^H = \mathbf{P}_i$ , 则有  $\mathbf{A} = \sum_{i=1}^n \lambda_i \mathbf{P}_i$ .

其次, 我们证明  $P_1, P_2, \dots, P_k$  是正交的幂等矩阵, 根据

$$\mathbf{I} = \mathbf{P}^{-1} \mathbf{P} = \begin{pmatrix} \mathbf{y}_1^H \\ \mathbf{y}_2^H \\ \vdots \\ \mathbf{y}_n^H \end{pmatrix} (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) = \begin{pmatrix} \mathbf{y}_1^H \mathbf{x}_1 & \mathbf{y}_1^H \mathbf{x}_2 & \cdots & \mathbf{y}_1^H \mathbf{x}_n \\ \mathbf{y}_2^H \mathbf{x}_1 & \mathbf{y}_2^H \mathbf{x}_2 & \cdots & \mathbf{y}_2^H \mathbf{x}_n \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{y}_n^H \mathbf{x}_1 & \mathbf{y}_n^H \mathbf{x}_2 & \cdots & \mathbf{y}_n^H \mathbf{x}_n \end{pmatrix},$$

可以得知  $\mathbf{y}_i^H \mathbf{x}_j = \begin{cases} 1, & i = j, \\ 0, & i \neq j \end{cases}$ , 从而

$$\mathbf{P}_i \mathbf{P}_j = (\mathbf{x}_i \mathbf{y}_i^H = \mathbf{P}_i)(\mathbf{x}_j \mathbf{y}_j^H = \mathbf{P}_j) = \mathbf{x}_i (\mathbf{y}_i^H \mathbf{x}_j) \mathbf{y}_j^H = \begin{cases} \mathbf{P}_i, & i = j, \\ \mathbf{O}, & i \neq j. \end{cases}$$



接下来, 我们证明  $\sum_{i=1}^n \mathbf{P}_i = \mathbf{I}$ , 这是因为

$$\mathbf{I} = \mathbf{P}\mathbf{P}^{-1} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) \begin{pmatrix} \mathbf{y}_1^H \\ \mathbf{y}_2^H \\ \vdots \\ \mathbf{y}_n^H \end{pmatrix} = \sum_{i=1}^n \mathbf{x}_i \mathbf{y}_i^H = \sum_{i=1}^n \mathbf{P}_i.$$

□

事实上, 谱分解本质上还是矩阵的对角化, 只是将其换了一种写法. 我们还可以深入地证明, 每个矩阵  $\mathbf{P}_i$  都可以由特征值直接算出, 在此就不再阐述.

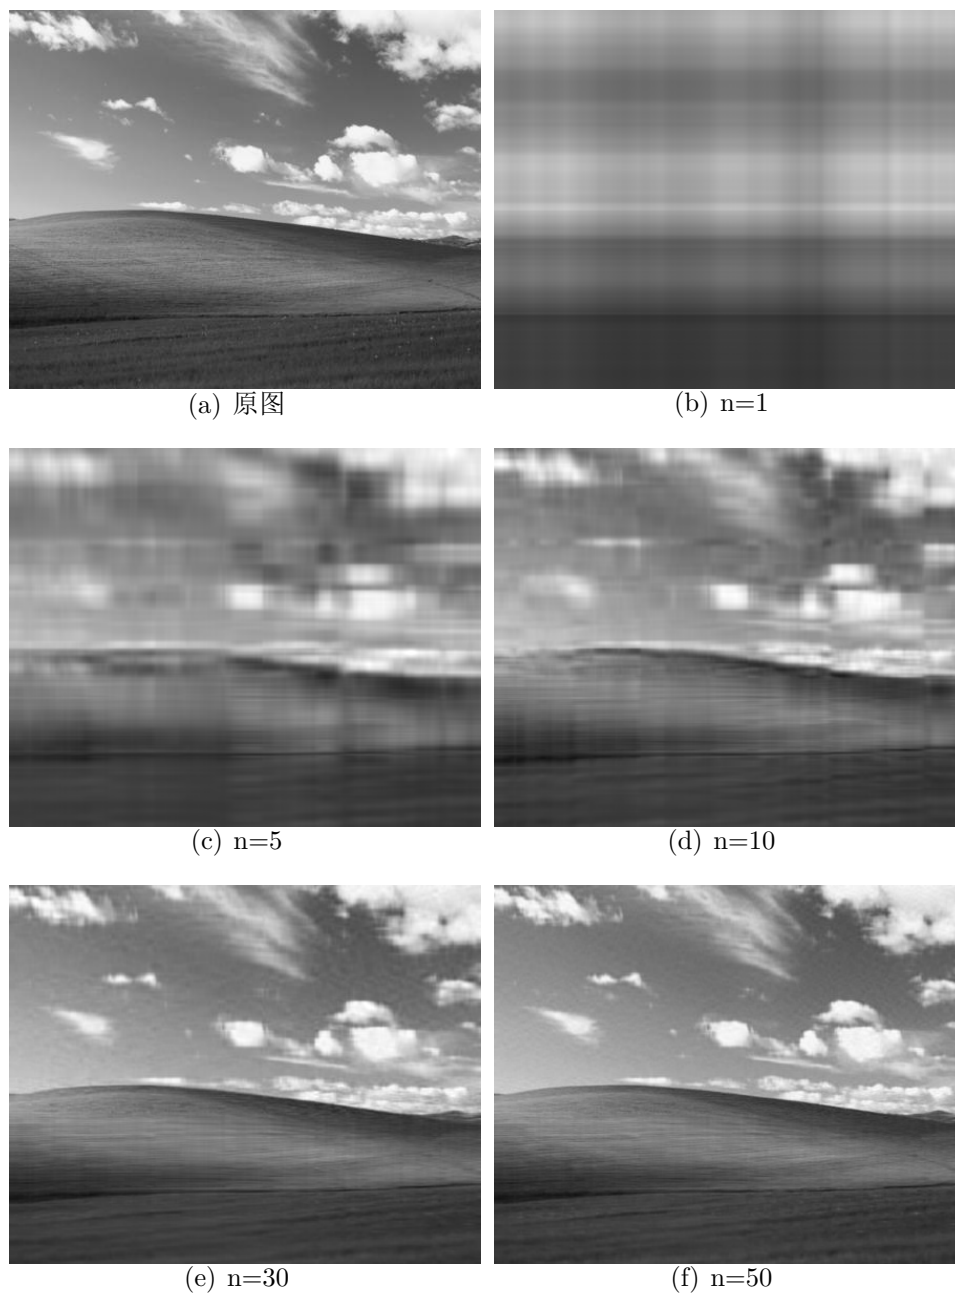


图 1: 图像压缩示例