

矩阵分解之奇异值分解 (Singular Value Decomposition, SVD)

Jingbo Xia

Huazhong Agricultural University

xiajingbo.math@gmail.com

20260113——人工智能2301/02

开宗明义 I

- 对矩阵的操作必要性在于数据本身的矩阵存储形式。

开宗明义 II

- 对矩阵的操作必要性在于数据本身的矩阵存储形式。
- 矩阵分解的目的之一是把放置在矩阵中的数据进行低秩逼近——可用以进行数据压缩；可用以消除数据稀疏性。

开宗明义 III

- 对矩阵的操作必要性在于数据本身的矩阵存储形式。
- 矩阵分解的目的之一是把放置在矩阵中的数据进行低秩逼近——可用以进行数据压缩；可用以消除数据稀疏性。
- SVD是一个知名的矩阵分解算法，该算法的自然应用是衍生到推荐系统，也可以是NLP领域的潜在语义分析。

开宗明义 IV

- 对矩阵的操作必要性在于数据本身的矩阵存储形式。
- 矩阵分解的目的之一是把放置在矩阵中的数据进行低秩逼近——可用以进行数据压缩；可用以消除数据稀疏性。
- SVD是一个知名的矩阵分解算法，该算法的自然应用是衍生到推荐系统，也可以是NLP领域的潜在语义分析。
- PCA同样是对存储在数据中的矩阵进行操作。我们介绍该算法的两个应用——第一是数据的降维，第二是数据的重构。

开宗明义 V

- 对矩阵的操作必要性在于数据本身的矩阵存储形式。
- 矩阵分解的目的之一是把放置在矩阵中的数据进行低秩逼近——可用以进行数据压缩；可用以消除数据稀疏性。
- SVD是一个知名的矩阵分解算法，该算法的自然应用是衍生到推荐系统，也可以是NLP领域的潜在语义分析。
- PCA同样是对存储在数据中的矩阵进行操作。我们介绍该算法的两个应用——第一是数据的降维，第二是数据的重构。
- 这个教学材料中包括一个图片处理的示例，它能帮助同学们较为生动地理解PCA算法中的“维”。

- 对矩阵的操作必要性在于数据本身的矩阵存储形式。
- 矩阵分解的目的之一是把放置在矩阵中的数据进行低秩逼近——可用以进行数据压缩；可用以消除数据稀疏性。
- SVD是一个知名的矩阵分解算法，该算法的自然应用是衍生到推荐系统，也可以是NLP领域的潜在语义分析。
- PCA同样是对存储在数据中的矩阵进行操作。我们介绍该算法的两个应用——第一是数据的降维，第二是数据的重构。
- 这个教学材料中包括一个图片处理的示例，它能帮助同学们较为生动地理解PCA算法中的“维”。
- 最后，为什么要把SVD和PCA放在一起讲授呢？难道仅仅因为它们都同时是在对矩阵类型的数据进行算法处理吗？

Table of contents I

1	奇异值分解/Singular Value Decomposition	9
●	SVD定理	10
●	SVD定理的证明	15
●	习题演算	32
2	SVD算法应用	45
●	矩阵补全和推荐系统	47
●	潜在语义分析	50
●	图像压缩	51
●	低秩逼近	63

Outline

1	奇异值分解/Singular Value Decomposition	9
•	SVD定理	10
•	SVD定理的证明	15
•	习题演算	32
2	SVD算法应用	45
•	矩阵补全和推荐系统	47
•	潜在语义分析	50
•	图像压缩	51
•	低秩逼近	63

1	奇异值分解/Singular Value Decomposition	9
•	SVD定理	10
•	SVD定理的证明	15
•	习题演算	32
2	SVD算法应用	45

奇异值分解/Singular Value Decomposition I

SVD定理

SVD 是一个知名的矩阵算法，广泛地（并不限于）应用于以下场景

- Image compression (图像压缩) ,
- Matrix completion (矩阵补全) ,
- Recommendation system (推荐系统) ,
- Latent semantic index (有时候被称作Latent semantic analysis, 潜在语义分析),
- ...

奇异值分解/Singular Value Decomposition II

SVD定理

定理 (奇异值分解)

对于一个秩为 r 的 $m \times n$ 矩阵 A , 存在如下分解:

$$A = U\Sigma V^T,$$

其中

- U 和 V 是正交矩阵; U 称为左奇异向量, 其列向量是 AA^T 的特征向量, V 称为右奇异向量, 其列向量是 A^TA 的特征向量。
- $\Sigma = \begin{pmatrix} \Delta & 0 \\ 0 & 0 \end{pmatrix}$, 被称为奇异值矩阵;
- $\Delta = \text{diag}(\sigma_1, \dots, \sigma_r)$,
- $\sigma_i = \sqrt{\lambda_i}$ (被称为矩阵 A 的奇异值, 按降序排列, 它们衡量了矩阵在对应方向上的“伸缩”程度。), $i = 1, 2, \dots, r$, $r = \text{Rank}(A)$,
- λ_i 是 AA^T 的特征值。

奇异值分解/Singular Value Decomposition III

SVD定理

为了更好地理解, 这里以一个 5×3 的矩阵 A 为例:

$$\underbrace{\begin{bmatrix} * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \end{bmatrix}}_A = \underbrace{\begin{bmatrix} * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \end{bmatrix}}_U \underbrace{\begin{bmatrix} * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \end{bmatrix}}_{\Sigma} \underbrace{\begin{bmatrix} * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \\ * & * & * \end{bmatrix}}_{V^T}$$
$$\underbrace{\begin{bmatrix} * & * & * & * & * \\ * & * & * & * & * \\ * & * & * & * & * \\ * & * & * & * & * \\ * & * & * & * & * \end{bmatrix}}_A = \underbrace{\begin{bmatrix} * & * & * \\ * & * & * \\ * & * & * \end{bmatrix}}_U \underbrace{\begin{bmatrix} * & * & * \\ * & * & * \\ * & * & * \end{bmatrix}}_{\Sigma} \underbrace{\begin{bmatrix} * & * & * & * & * \\ * & * & * & * & * \\ * & * & * & * & * \\ * & * & * & * & * \\ * & * & * & * & * \end{bmatrix}}_{V^T}$$

我们将上述公式改写为:

$$A = (A_1, A_2, A_3) = (U_1, \dots, U_5) \begin{pmatrix} \sigma_1 & 0 & 0 \\ 0 & \sigma_2 & 0 \\ 0 & 0 & \sigma_3 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} V_1^T \\ V_2^T \\ V_3^T \end{pmatrix},$$

奇异值分解/Singular Value Decomposition IV

SVD定理

其中 A_i 是矩阵 A 的第 i 列, U_k 是矩阵 U 的第 k 列, 而 V_j 是矩阵 V 的第 j 列。

通过直接计算可以得出:

$$A = \sigma_1 U_1 V_1^T + \sigma_2 U_2 V_2^T + \sigma_3 U_3 V_3^T.$$

因此, $\sigma_1 U_1 V_1^T + \sigma_2 U_2 V_2^T$ 被称为矩阵 A 的低秩逼近 (low-rank approximation)。

一般而言, $\sum_{i=1}^R \sigma_i U_i V_i^T$ 是任意矩阵 A 的一个秩为 R 的逼近。

奇异值分解/Singular Value Decomposition V

SVD定理

总结：

列向量表示：

公式 $A = \sum \sigma_i U_i V_i^T$ 展示了 SVD 的另一种视角——将矩阵分解为若干个秩为 1 的矩阵（外积）之和。

数据压缩：

在实际应用中（如图像压缩），如果奇异值 σ_i 衰减很快，我们只需保留前 R 个较大的奇异值及其对应的向量，就能以极小的数据量还原出矩阵的主要特征。

①	奇异值分解/Singular Value Decomposition	9
●	SVD定理	10
●	SVD定理的证明	15
●	习题演算	32
②	SVD算法应用	45

奇异值分解/Singular Value Decomposition I

SVD定理的证明-引理准备

引理 1.

假设 $A \in \mathbb{R}^{m \times n}$, 则 $A^T A$ 和 AA^T 的特征值均为非负的。

奇异值分解/Singular Value Decomposition II

SVD定理的证明-引理准备

引理 1.

假设 $A \in \mathbb{R}^{m \times n}$, 则 $A^T A$ 和 AA^T 的特征值均为非负的。

证明: 假设 λ 是 $A^T A$ 的特征值, x 是其对应的特征向量, 则我们有

$$A^T A x = \lambda x.$$

由于 $A^T A$ 是对称的, 因此 λ 是一个实数, 且我们有

$$0 \leq (Ax, Ax) = (Ax)^T (Ax) = x^T A^T A x = x^T (\lambda x) = \lambda x^T x.$$

因为 $x^T x > 0$, 所以我们得出 $\lambda \geq 0$ 。

同理, 可知 AA^T 的特征值也是非负的。 \square

奇异值分解/Singular Value Decomposition III

SVD定理的证明–引理准备

引理 2.

假设 $A \in \mathbb{R}^{m \times n}$, 则有 $r(A) = r(A^T A) = r(AA^T)$ 。

奇异值分解/Singular Value Decomposition IV

SVD定理的证明–引理准备

引理 2.

假设 $A \in \mathbb{R}^{m \times n}$, 则有 $r(A) = r(A^T A) = r(AA^T)$ 。

证明:

我们通过证明齐次线性方程组 $Ax = 0$ 与 $A^T Ax = 0$ 具有完全相同的解集来推导此结论。

(i) 证明 “若 $Ax = 0$, 则 $A^T Ax = 0$ ”。

若 x 满足 $Ax = 0$, 我们在等式两边同时左乘 A^T :

$$A^T(Ax) = A^T(0) \implies A^T Ax = 0$$

这说明 $Ax = 0$ 的每一个解都是 $A^T Ax = 0$ 的解。

(ii) 证明 “若 $A^T Ax = 0$, 则 $Ax = 0$ ”。

奇异值分解/Singular Value Decomposition V

SVD定理的证明–引理准备

若 x 满足 $A^T Ax = 0$, 我们在等式两边同时左乘 x^T :

$$x^T (A^T Ax) = x^T (0) \implies (Ax)^T (Ax) = 0$$

根据向量内积的性质, $(Ax)^T (Ax) = \|Ax\|_2^2$ 。若向量长度的平方为 0, 则该向量本身必须为零向量:

$$\|Ax\|_2^2 = 0 \implies Ax = 0$$

这说明 $A^T Ax = 0$ 的每一个解也都是 $Ax = 0$ 的解。

(iii) 既然 $Ax = 0$ 与 $A^T Ax = 0$ 的解空间完全相同, 它们的维数必定相等:

$$n - r(A) = n - r(A^T A),$$

奇异值分解/Singular Value Decomposition VI

SVD定理的证明–引理准备

因此, $r(A) = r(A^T A)$ 。

(iv) 同理可证 $r(A) = r(AA^T)$ 。

对 A^T 应用上述结论, 有 $r(A^T) = r((A^T)^T A^T) = r(AA^T)$ 。由于矩阵与其转置的秩相等 ($r(A) = r(A^T)$), 故:

$$r(A) = r(A^T A) = r(AA^T) \quad \square$$

奇异值分解/Singular Value Decomposition VII

SVD定理的证明-引理准备

引理 3:

假设 $A \in \mathbb{R}^{m \times n}$, 则 AA^T 和 A^TA 具有相同的特征值 (非零特征值)。

奇异值分解/Singular Value Decomposition VIII

SVD定理的证明-引理准备

引理 3:

假设 $A \in \mathbb{R}^{m \times n}$, 则 AA^T 和 A^TA 具有相同的特征值 (非零特征值)。

证明:

假设 λ 是 A^TA 的一个特征值, 则有 $A^TAx = \lambda x$ (其中 $x \neq 0$)。

在等式两边同时左乘矩阵 A , 等式变为:

$$A(A^TAx) = A(\lambda x) \implies (AA^T)(Ax) = \lambda(Ax)$$

由此可知, 若 $Ax \neq 0$, 则 λ 也是 AA^T 的一个特征值, 其对应的特征向量为 Ax 。

同理可知, AA^T 的特征值也是 A^TA 的特征值。

以上两点陈述足以证明本引理 (对于非零特征值的情况)。 \square

奇异值分解/Singular Value Decomposition IX

SVD定理的证明–引理准备

引理 4:

如果两个矩阵彼此正交等价 (Orthogonally equivalent), 则它们具有相同的奇异值。

奇异值分解/Singular Value Decomposition X

SVD定理的证明–引理准备

引理 4:

如果两个矩阵彼此正交等价 (Orthogonally equivalent), 则它们具有相同的奇异值。

证明: 假 $A, B \in \mathbb{R}^{m \times n}$ 正交等价, 则存在正交矩阵 $U \in \mathbb{R}^{m \times m}$ 和 $V \in \mathbb{R}^{n \times n}$, 使得 $A = UBV$ 。

直接计算知,

$$A^T A = (UBV)^T (UBV) = V^T B^T U^T UBV = V^T B^T BV.$$

由于 V 是正交矩阵, 则有 $V^T = V^{-1}$, 故

$$A^T A = V^{-1} B^T BV.$$

所以 $A^T A$ 与 $B^T B$ 相似, 因此它们具有相同的特征值, 以及相同的奇异值。

□

奇异值分解/Singular Value Decomposition I

SVD定理的证明–主定理的证明

[Singular Value Decomposition]

对于一个秩为 r 的 $m \times n$ 矩阵 A , 存在如下分解:

$$A = U\Sigma V^T,$$

其中

- U 和 V 是正交矩阵; U 称为左奇异向量, 其列向量是 AA^T 的特征向量, V 称为右奇异向量, 其列向量是 A^TA 的特征向量。
- $\Sigma = \begin{pmatrix} \Delta & 0 \\ 0 & 0 \end{pmatrix}$, 被称为奇异值矩阵;
- $\Delta = \text{diag}(\sigma_1, \dots, \sigma_r)$,
- $\sigma_i = \sqrt{\lambda_i}$ (被称为矩阵 A 的奇异值, 按降序排列, 它们衡量了矩阵在对应方向上的“伸缩”程度。), $i = 1, 2, \dots, r$, $r = \text{Rank}(A)$,
- λ_i 是 AA^T 的特征值。

奇异值分解/Singular Value Decomposition II

SVD定理的证明–主定理的证明

证明: 由于 A^TA 实对称, 所以存在一个正交矩阵 V (其秩为 r), 使得

$$V^T(A^TA)V = \begin{pmatrix} \Delta^2 & 0 \\ 0 & 0 \end{pmatrix},$$

此处 $\Delta = \text{diag}(\sigma_1, \dots, \sigma_r)$, 且 $\sigma_i^2 = \lambda_i$ (λ_i 为 A^TA 的特征值)。

注: 请回忆如何使用施密特正交化, 将一个方阵正交对角化。另外一个重要结论: 实对称矩阵永可对角化。

奇异值分解/Singular Value Decomposition III

SVD定理的证明–主定理的证明

证明：由于 $A^T A$ 实对称，所以存在一个正交矩阵 V （其秩为 r ），使得

$$V^T (A^T A) V = \begin{pmatrix} \Delta^2 & 0 \\ 0 & 0 \end{pmatrix},$$

此处 $\Delta = \text{diag}(\sigma_1, \dots, \sigma_r)$ ，且 $\sigma_i^2 = \lambda_i$ (λ_i 为 $A^T A$ 的特征值)。

对 V 进行分块，我们有：

$$V = (V_1, V_2),$$

其中 V_1 由 V 的前 r 列组成。

注：此处 V 的矩阵分块方式是一个技巧。

奇异值分解/Singular Value Decomposition IV

SVD定理的证明–主定理的证明

证明：由于 $A^T A$ 实对称，所以存在一个正交矩阵 V （其秩为 r ），使得

$$V^T (A^T A) V = \begin{pmatrix} \Delta^2 & 0 \\ 0 & 0 \end{pmatrix},$$

此处 $\Delta = \text{diag}(\sigma_1, \dots, \sigma_r)$ ，且 $\sigma_i^2 = \lambda_i$ (λ_i 为 $A^T A$ 的特征值)。

对 V 进行分块，我们有：

$$V = (V_1, V_2),$$

其中 V_1 由 V 的前 r 列组成。把结果代回上式，有

$$\begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} (A^T A) (V_1, V_2) = \begin{pmatrix} V_1^T A^T A V_1 & * \\ * & V_2^T A^T A V_2 \end{pmatrix} \cdot = \begin{pmatrix} \Delta^2 & 0 \\ 0 & 0 \end{pmatrix}$$

奇异值分解/Singular Value Decomposition V

SVD定理的证明–主定理的证明

$$\begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} (A^T A)(V_1, V_2) = \begin{pmatrix} V_1^T A^T A V_1 & * \\ * & V_2^T A^T A V_2 \end{pmatrix} \cdot = \begin{pmatrix} \Delta^2 & 0 \\ 0 & 0 \end{pmatrix}$$

通过比较左右两端，我们得出：

$$V_2^T A^T A V_2 = (A V_2)^T (A V_2) = 0.$$

由此可得 $A V_2 = 0$ 。

此外，我们还可知：

$$V_1^T A^T A V_1 = (A V_1)^T (A V_1) = \Delta^2.$$

奇异值分解/Singular Value Decomposition VI

SVD定理的证明–主定理的证明

为了记号的简洁，我们令 $U_1 = A V_1 \Delta^{-1}$ 。直接验证，知

$$U_1^T U_1 = (\Delta^{-1} V_1^T A^T)(A V_1 \Delta^{-1}) = \Delta^{-1} (V_1^T A^T A V_1) \Delta^{-1} = \Delta^{-1} \Delta^2 \Delta^{-1} = E_r.$$

这说明 U 的前 r 列（即构成的 U_1 ）是正交单位向量。

因此，我们可以通过 $U_2 \in \mathbb{R}^{m \times (m-r)}$ 对 U_1 进行扩充，从而构造出一个正交矩阵 $U = (U_1, U_2)$ 。

注：我们永可这样做——首先扩充 r 个线性无关的向量到一个包含 m 个向量的无关组，其次用施密特正交变换和单位化后，这 m 个正交单位向量则组合成一个正交矩阵。

由此，我们已得到 V 、 Σ （即中间的对角阵）和 U 。

奇异值分解/Singular Value Decomposition VII

SVD定理的证明–主定理的证明

由此，我们已得到 V 、 Σ （即中间的对角阵）和 U 。下面将其代入SVD的矩阵分解结果，予以验证：

$$\begin{aligned} U^T A V &= \begin{pmatrix} U_1^T \\ U_2^T \end{pmatrix} A(V_1, V_2) = \begin{pmatrix} U_1^T A V_1 & U_1^T A V_2 \\ U_2^T A V_1 & U_2^T A V_2 \end{pmatrix} \\ &= \begin{pmatrix} U_1^T U_1 \Delta & U_1^T (A V_2) \\ U_2^T U_1 \Delta & U_2^T (A V_2) \end{pmatrix} = \begin{pmatrix} \Delta & 0 \\ 0 & 0 \end{pmatrix}, \end{aligned}$$

因为 $U_2^T U_1 = 0$ （由于 U 的正交性）且 $A V_2 = 0$ 。

综上所述，定理得证。 \square

①	奇异值分解/Singular Value Decomposition	9
●	SVD定理	10
●	SVD定理的证明	15
●	习题演算	32
②	SVD算法应用	45

Singular Vector Decomposition I

习题演算

例题

请计算矩阵 A 的SVD分解。其中 $A = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix}$.

Singular Vector Decomposition II

习题演算

例题

请计算矩阵 A 的SVD分解。其中 $A = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix}$.

【答案】

$$A = \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & \sqrt{3} & 0 \end{pmatrix} \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} \\ -\frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \end{pmatrix}.$$

Singular Vector Decomposition III

习题演算

历史作业

专业班级:生信1701 学号:2017317220120 姓名:高玲秀 批阅教师:

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

解: $A^T A = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix} \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$

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

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

当 $\lambda=3$ 时, $A^T A - 3E = \begin{pmatrix} -2 & 0 & 1 \\ 0 & -2 & 1 \\ 1 & 1 & -1 \end{pmatrix}$

得基础解系 $\begin{pmatrix} 1 \\ 1 \\ 2 \end{pmatrix}$, 单位化 $\begin{pmatrix} \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{6}} \end{pmatrix}$

$\therefore A^T A$ 的特征值为 $\lambda_1=1, \lambda_2=3$

当 $\lambda=1$ 时, $A^T A - E = \begin{pmatrix} 0 & 0 & 1 \\ 0 & 0 & 1 \\ 1 & 1 & 1 \end{pmatrix}$

得基础解系 $\begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$, 单位化 $\begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix}$

$\therefore V = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ -1 & 1 & -1 \end{pmatrix}$ 且 $\theta_1=1, \theta_2=\sqrt{3}$

$\therefore \Delta = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \sqrt{3} & 0 \\ 0 & 0 & 1 \end{pmatrix}$

$\therefore A = \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ 0 & \sqrt{3} & 0 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & \frac{1}{\sqrt{6}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix} \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ -1 & 1 & -1 \end{pmatrix}$

Singular Vector Decomposition IV

习题演算

专业班级:生信1702 学号:2017317220108 姓名:高玲秀 批阅教师:

$A = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$ 则 $A^T = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$, $A^T A = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$

$(A^T A)x = \lambda x$

$\begin{vmatrix} 1-\lambda & 0 & 1 \\ 0 & 1-\lambda & 1 \\ 1 & 1 & 2-\lambda \end{vmatrix} \xrightarrow{R_1-R_2} \begin{vmatrix} 1-\lambda & -(1-\lambda) & 0 \\ 0 & 1-\lambda & 1 \\ 1 & 1 & 2-\lambda \end{vmatrix} = 1-\lambda \begin{vmatrix} 1 & -1 & 0 \\ 0 & 1-\lambda & 1 \\ 1 & 1 & 2-\lambda \end{vmatrix} = (1-\lambda)\lambda(\lambda-3)$

$\lambda=0$ 时, $\xi_1 = \begin{pmatrix} 1 \\ 1 \\ -1 \end{pmatrix}$, $\lambda=1$ 时, $\xi_2 = \begin{pmatrix} 1 \\ -1 \\ 0 \end{pmatrix}$, $\lambda=3$ 时, $\xi_3 = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$

$\beta_1 = \xi_1$, $\beta_2 = \xi_2 - \frac{[\xi_2, \beta_1]}{[\beta_1, \beta_1]} \beta_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$, $\beta_3 = \xi_3 - \frac{[\xi_3, \beta_1]}{[\beta_1, \beta_1]} \beta_1 - \frac{[\xi_3, \beta_2]}{[\beta_2, \beta_2]} \beta_2 = \begin{pmatrix} 1 \\ 1 \\ 2 \end{pmatrix}$

单位化为 $V_1 = \begin{pmatrix} \frac{1}{\sqrt{3}} \\ \frac{1}{\sqrt{3}} \\ \frac{1}{\sqrt{3}} \end{pmatrix}$, $V_2 = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \\ 0 \end{pmatrix}$, $V_3 = \begin{pmatrix} \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{6}} \end{pmatrix} \Rightarrow V = (V_1, V_2, V_3)$

$\Delta = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix}$, $V^{-1} = \frac{1}{\sqrt{3}} \begin{pmatrix} \sqrt{3} & 0 & 0 \\ 0 & \sqrt{2} & 0 \\ 0 & 0 & \sqrt{6} \end{pmatrix}$

$U_1 = AV, \Delta^{-1} = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{2}} & 0 \\ 0 & \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{3}} & 0 & 0 \\ 0 & \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix} = \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix}$

$\therefore A = \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{6}} \end{pmatrix} \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ -1 & 1 & -1 \end{pmatrix}$

Singular Vector Decomposition V

习题演算

解：

(i). 计算 $A^T A$ 并求解 V 和奇异值.

首先计算对称矩阵 $A^T A \in \mathbb{R}^{3 \times 3}$:

$$A^T A = \begin{pmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix} = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$$

由 $|A^T A - \lambda I| = 0$ 求特征值 λ :

$$\begin{vmatrix} 1 - \lambda & 0 & 1 \\ 0 & 1 - \lambda & 1 \\ 1 & 1 & 2 - \lambda \end{vmatrix} = (1 - \lambda)[(1 - \lambda)(2 - \lambda) - 1] + 1[0 - (1 - \lambda)] = 0$$

化简得: $(1 - \lambda)(\lambda^2 - 3\lambda) = 0$ 。

解得特征值为: $\lambda_1 = 3, \lambda_2 = 1, \lambda_3 = 0$ 。

Singular Vector Decomposition VI

习题演算

因为奇异值 $\sigma_i = \sqrt{\lambda_i}$, 所以有

$$\Sigma = \begin{pmatrix} \sqrt{3} & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix}$$

下求右奇异向量 V (即 $A^T A$ 的特征向量):

对于 $\lambda = 1$: 解 $(A^T A - I)\vec{v}_1 = 0 \Rightarrow \vec{v}_1 = (-1/\sqrt{2}, 1/\sqrt{2}, 0)^T$

对于 $\lambda = 3$: 解 $(A^T A - 3I)\vec{v}_2 = 0 \Rightarrow \vec{v}_2 = (1/\sqrt{6}, 1/\sqrt{6}, 2/\sqrt{6})^T$

对于 $\lambda = 0$: 解 $A^T A \vec{v}_3 = 0 \Rightarrow \vec{v}_3 = (-1/\sqrt{3}, -1/\sqrt{3}, 1/\sqrt{3})^T$

由此构造 $V = (\vec{v}_1, \vec{v}_2, \vec{v}_3)$ 。

Singular Vector Decomposition VII

习题演算

(ii). 利用映射关系 $U_1 = AV_1\Delta^{-1}$ 构造 U .

$$\begin{aligned} U &= AV_1\Delta^{-1} = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix} \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{6}} \\ 0 & \frac{2}{\sqrt{6}} \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & \frac{1}{\sqrt{3}} \end{pmatrix} \\ &= \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{3}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & \frac{3}{\sqrt{6}} \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & \frac{1}{\sqrt{3}} \end{pmatrix} \\ &= \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{3}{\sqrt{18}} \\ \frac{1}{\sqrt{2}} & \frac{3}{\sqrt{18}} \end{pmatrix} = \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{pmatrix} \end{aligned}$$

因为 A 的秩 $r = 2$, 且 $U \in \mathbb{R}^{2 \times 2}$, 此时 $U_1 = (\vec{u}_1, \vec{u}_2)$ 已经构成了完整的正交矩阵 U , 无需额外扩充 U_2 。

Singular Vector Decomposition VIII

习题演算

最终分解形式:

$$A = U\Sigma V^T$$

$$A = \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & \sqrt{3} & 0 \end{pmatrix} \begin{pmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} \\ -\frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \end{pmatrix}$$

Singular Vector Decomposition IX

习题演算

再例

$A \in \mathbb{R}^{2 \times 2}$, 求SVD分解 $A = U\Sigma V^T$ 。

$$A = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}.$$

Singular Vector Decomposition X

习题演算

再例

$A \in \mathbb{R}^{2 \times 2}$, 求SVD分解 $A = U\Sigma V^T$ 。

$$A = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}.$$

【答案】

(i). 计算 $A^T A$ 并求解 V 和奇异值.

$$A^T A = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} = \begin{pmatrix} 2 & 2 \\ 2 & 2 \end{pmatrix}$$

通过特征方程 $|A^T A - \lambda I| = 0$ 求解:

$$\begin{vmatrix} 2 - \lambda & 2 \\ 2 & 2 - \lambda \end{vmatrix} = (2 - \lambda)^2 - 4 = 0$$

Singular Vector Decomposition XI

习题演算

解得特征值为: $\lambda_1 = 4, \lambda_2 = 0$ 。3. 构造奇异值矩阵 Σ 与相关对角阵 Δ 奇异值为 $\sigma_1 = \sqrt{4} = 2, \sigma_2 = 0$ 。构造 2×2 的对角矩阵 Σ :

$$\Sigma = \begin{pmatrix} 2 & 0 \\ 0 & 0 \end{pmatrix}$$

定义非零奇异值对角阵 Δ 及其逆:

$$\Delta = (2), \quad \Delta^{-1} = (1/2)$$

下求解右奇异向量矩阵 V 对应特征值 $\lambda_1 = 4, \lambda_2 = 0$ 的单位特征向量为:

$$\vec{v}_1 = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix}, \quad \vec{v}_2 = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{pmatrix}$$

取非零部分 $V_1 = \vec{v}_1$, 完整矩阵 $V = \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{pmatrix}$ 。

Singular Vector Decomposition XII

习题演算

(ii). 利用映射关系 $U_1 = AV_1\Delta^{-1}$ 构造 U .

由于 A 的秩 $r = 1$, U 的第一列 U_1 为:

$$\begin{aligned} U_1 &= AV_1\Delta^{-1} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix} (1/2) \\ &= \begin{pmatrix} \frac{2}{\sqrt{2}} \\ \frac{2}{\sqrt{2}} \end{pmatrix} (1/2) = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix} \end{aligned}$$

为了构造正交矩阵 U , 我们需要通过施密特正交化或其他方式补全第二列 U_2 (需与 U_1 正交且单位化):

$$U = \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{pmatrix}$$