

第15章 奇异值分解

1 奇异值分解的定义与性质

矩阵特征值与特征向量

矩阵代表线性变换。特征向量为变化的属性之一

线性动力学系统： $x_{k+1} = Ax_k (k = 0, 1, 2, \dots)$ ，则 $x_k = A^k x_0$

矩阵特征值与特征向量

➤ 特征值与特征向量 A 为 $n \times n$ 矩阵，如果数 λ 和 n 维非零向量 x 使

$$Ax = \lambda x$$

➤ 则称 λ 是特征值， x 是对应于 λ 的特征向量

➤ 1) 矩阵与向量相乘 Ax 是一种线性变换，把一个向量，变换成另一个向量

➤ 2) 矩阵 A 的特征向量经过线性变换 A 后方向与原方向保持一致

➤ 【重要应用：线性动力学系统】

➤ 线性动力学系统中 $x_{k+1} = Ax_k (k = 0, 1, 2, \dots)$ ，则 $x_k = A^k x_0$ ，计算 A^n

对角矩阵

➤ 对角矩阵(diagonal matrix), 主对角线之外的元素皆为0

➤ 记作 $\mathbf{M} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n) = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix}$

➤ 【用途】

➤ \mathbf{M}^k 比较容易计算

➤ \mathbf{M} 代表线性变换有明确的几何意义【缩放】

对角化矩阵

- A 为 $n \times n$ 矩阵，如果 A 有 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ ，对应特征向量 V_1, V_2, \dots, V_n ，以特征向量为列构造矩阵 P : $P = [V_1 \ V_2 \ \dots \ V_n]$ ，则变换

$$AP = A[V_1 \ V_2 \ \dots \ V_n] = [\lambda_1 V_1 \ \lambda_2 V_2 \ \dots \ \lambda_n V_n]$$

$$P^{-1}AP = \begin{bmatrix} V_1^{-1} \\ \vdots \\ V_n^{-1} \end{bmatrix} [\lambda_1 V_1 \ \dots \ \lambda_n V_n] = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix}$$

$$D = P^{-1}AP = P^{-1}A[V_1 \ V_2 \ \dots \ V_n] = \mathit{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$$

- A 的对角阵分解: $A = P^{-1}DP$


- 【相似变换】

- 把 A 变成 $P^{-1}AP$ 的变换

- 若矩阵 A 和 B 相似，它们有相同的特征多项式和相同的特征值(和相同的重数)

相似变换的几何意义

➤ 相似变换： $A = PCP^{-1}$



➤ 【几何意义】相似矩阵为线性变换在不同坐标系下的不同的矩阵表达形式

➤ A 可对角化

➤ 如果方阵 A 相似于对角矩阵，即存在可逆矩阵 P 和对角矩阵 D ，使得 $A = PDP^{-1}$

➤ 从分解式 $A = PDP^{-1}$ (其中 D 是对角矩阵)，能够了解到有关矩阵 A 的特征值和特征向量的信息。

➤ 【注】

➤ 此处的变换 P 不一定是正交变换（旋转和镜像）

对角化矩阵

➤ 【定理】（列行展开）若A是 $m \times n$ 矩阵，B是 $n \times p$ 矩阵，则

$$\begin{aligned} \mathbf{AB} &= [\mathit{col}_1(\mathbf{A}) \quad \mathit{col}_2(\mathbf{A}) \quad \cdots \quad \mathit{col}_n(\mathbf{A})] \begin{bmatrix} \mathit{row}_1(\mathbf{B}) \\ \mathit{row}_2(\mathbf{B}) \\ \vdots \\ \mathit{row}_n(\mathbf{B}) \end{bmatrix} \\ &= \mathit{col}_1(\mathbf{A})\mathit{row}_1(\mathbf{B}) + \cdots + \mathit{col}_n(\mathbf{A})\mathit{row}_n(\mathbf{B}) \\ \mathbf{A} &= \mathbf{P}^{-1}\mathbf{M}\mathbf{P} \end{aligned}$$

➤ 【外积展开形式】两组向量做外积。信息叠加， λ_i 为权重，可用于代表信息

➤ $\mathbf{A} = \lambda_1 \mathbf{u}_1 \mathbf{v}_1^T + \lambda_2 \mathbf{u}_2 \mathbf{v}_2^T + \cdots + \lambda_n \mathbf{u}_n \mathbf{v}_n^T$

➤ $\mathbf{u}_i, \mathbf{v}_i$ 分别为 \mathbf{P}^{-1} 和 \mathbf{P}^T 的列向量

➤ 当 λ_i 很小时可被忽略，则可用作数据压缩

实对称矩阵的对角化

➤ 若 $A^T = A$ ，则称 A 为对称矩阵

➤ 【Theorem】所有实对称矩阵都可分解为

$$A = Q\Lambda Q^{-1} = Q\Lambda Q^T, Q^{-1} = Q^T$$

其中 Q 由 A 的正交特征向量组成， A 的特征值均为实数。

➤ 【注】

➤ 正交矩阵可以看作是一种旋转或镜像变换，它将向量旋转或镜像到一个新的坐标系中。


➤ 正交矩阵在计算机图形学中用于进行坐标变换，或在物理学中用于表示刚体的旋转和运动。

奇异值分解

奇异值分解

- **【定义15.1 (奇异值分解)】** 指将非零的 $m \times n$ 实矩阵 $A \in \mathbf{R}^{m \times n}$ 进行矩阵的因子分解： $A = U\Sigma V^T$ ，其中 U 是 m 阶正交矩阵， V 是 n 阶正交矩阵， Σ 是由降序排列的非负的对角线元素组成的 $m \times n$ 对角矩阵

$$\begin{aligned}
 UU^T &= I \\
 VV^T &= I \\
 \Sigma &= \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_p) \\
 \sigma_1 &\geq \sigma_2 \geq \dots \geq \sigma_p \geq 0 \\
 p &= \min(m, n)
 \end{aligned}$$




- 则
- $U\Sigma V^T$ 称为矩阵 A 的奇异值分解 (singular value decomposition, SVD)
 - σ_i 称为矩阵 A 的奇异值， U 的列向量称为左奇异向量， V 的列向量称为右奇异向量。
- 奇异值分解不要求矩阵 A 是方阵，可以看成方阵的对角化推广
- **【注】** 连续的变换等价于做一个复合变换（变换矩阵连乘代表的变换）。变换从右往左

奇异值分解的一种几何解释


将一组正交向量变换成另一组正交向量
奇异值分解为该变换的变形形式

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



奇异值分解的一种几何解释

- ▶ 对于任意的 2×2 矩阵，通过SVD可以将一个相互垂直的网格(orthogonal grid)变换到另外一个相互垂直的网格。【目的，要找到变换前后都正交的向量】
 - ▶ 即，选择两个相互正交的单位向量 v_1 和 v_2 ，使得向量 Av_1 和 Av_2 正交。
- ▶ u_1 和 u_2 分别表示 Av_1 和 Av_2 的单位向量， $\sigma_1 * u_1 = Av_1$ 和 $\sigma_2 * u_2 = Av_2$ ， σ_1 和 σ_2 表示向量 Av_1 和 Av_2 的模，称作为矩阵 A 的奇异值



奇异值分解的一种几何解释

$Av_1 = \sigma_1 u_1$, $Av_2 = \sigma_2 u_2$, A 线性变换, v_1 和 v_2 是正交的单位向量, 向量 x 投影展开

$$x = (v_1 \cdot x)v_1 + (v_2 \cdot x)v_2$$

两边同乘以 A

$$Ax = (v_1 \cdot x)Av_1 + (v_2 \cdot x)Av_2$$

$$Ax = (v_1 \cdot x)\sigma_1 u_1 + (v_2 \cdot x)\sigma_2 u_2$$

$(v_1 \cdot x) = v_1^T x$, 上式变为

$$Ax = u_1 \sigma_1 v_1^T x + u_2 \sigma_2 v_2^T x$$

$$A = u_1 \sigma_1 v_1^T + u_2 \sigma_2 v_2^T$$

上式实际上为矩阵 $U\Sigma V^T$ 的外积展开形式, 于是

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

其中, U 的列向量分别是 u_1, u_2 , $\Sigma = \text{diag}(\sigma_1, \sigma_2)$ 对角矩阵, V 的列向量分别是 v_1, v_2

奇异值分解的另一种解释：外积展开形式

$$A = U\Sigma V^T = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_n u_n v_n^T$$

变换视角，把 A 看作一系列变换组合而成

数据视角，把 A 看作一系列（投影）分量组合而成

奇异值分解的另一种解释：外积展开形式

矩阵乘法的外积展开形式

$$U\Sigma = [\sigma_1 u_1 \quad \sigma_2 u_2 \quad \cdots \quad \sigma_n u_n]$$

$$V^T = \begin{bmatrix} v_1^T \\ v_2^T \\ \vdots \\ v_n^T \end{bmatrix}$$

则

$$A = U\Sigma V^T = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_n u_n v_n^T$$

➤ 【注】

- 变换视角，把 A 看作一系列变换组合而成
- 数据视角，把 A 看作一系列分量组合而成

例15.1

给定一个5x4矩阵A

$$A = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 4 \\ 0 & 3 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0 \end{bmatrix}$$

$$U = \begin{bmatrix} 0 & 0 & \sqrt{0.2} & 0 & \sqrt{0.8} \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & \sqrt{0.8} & 0 & -\sqrt{0.2} \end{bmatrix}, \quad \Sigma = \begin{bmatrix} 4 & 0 & 0 & 0 \\ 0 & 3 & 0 & 0 \\ 0 & 0 & \sqrt{5} & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}, \quad V^T = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

矩阵的奇异值分解不唯一

如果选择U为

$$U = \begin{bmatrix} 0 & 0 & \sqrt{0.2} & \sqrt{0.4} & -\sqrt{0.4} \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sqrt{0.5} & \sqrt{0.5} \\ 0 & 0 & \sqrt{0.8} & -\sqrt{0.1} & \sqrt{0.1} \end{bmatrix}$$

而 Σ 和 V 不变，那么 $U\Sigma V^T$ 也是 A 的一个奇异值分解


奇异值分解基本定理

【定理15.1(奇异值分解基本定理)】 若 A 为 $m \times n$ 实矩阵, $A \in \mathbb{R}^{m \times n}$ 则 A 的奇异值分解存在

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

其中 U 是 m 阶正交矩阵, V 是 n 阶正交矩阵, Σ 为 $m \times n$ 矩形对角矩阵, 其对角线元素非负, 且按降序排列。

【证明】对给定的矩阵 A , 构造出其奇异值分解的各个矩阵。设 $m \geq n$ ($m < n$ 证明类似)



奇异值分解基本定理 - 构造性证明

【关键： $A^T A$ 是对角矩阵】

(1) 确定 V 和 Σ

首先，构造 n 阶正交实矩阵 V 和 $m \times n$ 矩形对角实矩阵 Σ

矩阵 A 是 $m \times n$ 实矩阵，则矩阵 $A^T A$ 是 n 阶实对称矩阵。因而 $A^T A$ 的特征值都是实数，并且存在一个 n 阶正交实矩阵 V 实现 $A^T A$ 的对角化，使得

$$A^T A = V^T \Lambda V$$

因此 $V^T (A^T A) V = \Lambda$ ，其中 Λ 是 n 阶对角矩阵，其对角线元素由 $A^T A$ 的特征值组成。而且， $A^T A$ 的特征值都是非负的【令 λ 是 $A^T A$ 的一个特征值， x 是对应的特征向量， $A^T A x = \lambda x$ ，

$$|Ax|^2 = (Ax)^T (Ax) = x^T A^T A x = x^T (\lambda x) = x^T \lambda x = \lambda |x|^2, \text{ 于是 } \lambda = \frac{|Ax|^2}{|x|^2} \geq 0 \text{】}$$

假设正交矩阵 V 的列，其排列使得对应的特征值形成降序排列

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$$

特征值的平方根(即为矩阵 A 的奇异值) $\sigma_j = \sqrt{\lambda_j}, j = 1, 2, \dots, n$

确定 V 和 Σ

设矩阵 A 的秩是 r , $\text{rank}(A) = r$, 则矩阵 $A^T A$ 的秩也是 r 。 $A^T A$ 对称, 秩等于正特征值个数, 所以

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > 0, \quad \lambda_{r+1} = \lambda_{r+2} = \dots = \lambda_n = 0$$

对应地有 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$, $\sigma_{r+1} = \sigma_{r+2} = \dots = \sigma_n = 0$

令 $V_1 = [v_1 \ v_2 \ \dots \ v_r]$, $V_2 = [v_{r+1} \ v_{r+2} \ \dots \ v_n]$, 其中

$v_1 \dots v_r$ 为 $A^T A$ 的正特征值对应的特征向量, $v_{r+1} \dots v_n$ 为 0 特征值对应的特征向量

则 $V = [V_1 V_2]$ 为矩阵 A 的奇异值分解中的 n 阶正交矩阵 V

$$\Sigma_1 = \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_r \end{bmatrix}$$

则 r 阶对角矩阵 $\Sigma_1 = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$, $m \times n$ 矩形对角矩阵 Σ 为

$$\Sigma = \begin{bmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{bmatrix}$$

关于 V_2 的性质

V_2 的列向量是 $A^T A$ 对应于特征值为0的特征向量，因此

$$A^T A v_j = 0, j = r + 1, \dots, n$$

于是， V_2 的列向量构成了 $A^T A$ 的零空间 $N(A^T A)$ ，而 $N(A^T A) = N(A)$

【所以】： V_2 的列向量构成 A 的零空间的一组标准正交基

$$A V_2 = 0$$

由于 V 是正交矩阵，由 $V = [V_1 V_2]$ 可得

$$\begin{aligned} I &= V V^T = V_1 V_1^T + V_2 V_2^T \\ A &= A I = A V_1 V_1^T + A V_2 V_2^T = A V_1 V_1^T \end{aligned}$$

确定U

(2) 确定U

接着构造m阶正交实矩阵,令

$$u_j = \frac{1}{\sigma_j} A v_j, \quad j = 1, 2, \dots, r$$


$$U_1 = [u_1 \ u_2 \ \dots \ u_r]$$

则有 $AV_1 = U_1 \Sigma_1$

【形式上 $A = U \Sigma V^T \Rightarrow U = AV \Sigma^{-1}$, 变换: 右下-左下-左上=右下-右上】

U_1 的列向量构成了一组标准正交集, 维数为r【以下为证明】

$$\begin{aligned} u_i^T u_j &= \left(\frac{1}{\sigma_i} v_i^T A^T \right) \left(\frac{1}{\sigma_j} A v_j \right) \\ &= \frac{1}{\sigma_i \sigma_j} v_i^T (A^T A v_j) \\ &= \frac{\sigma_j}{\sigma_i} v_i^T v_j \\ &= \delta_{ij}, i = 1, 2, \dots, r; j = 1, 2, \dots, r \end{aligned}$$



确定 U_2 和 U

将 A 看成是从 \mathbf{R}^n 到 \mathbf{R}^m 的线性变换，则 A 的列空间和 A 的值域 $R(A)$ 是相同的。因此 u_1, u_2, \dots, u_r 也是 $R(A)$ 的一组标准正交基。

$R(A)^\perp$ 表示 $R(A)$ 的正交补，则有 $R(A)$ 的维数为 r ， $R(A)^\perp$ 的维数为 $m - r$ 、
有 $R(A)^\perp = N(A^T)$ ，

设 $u_{r+1} u_{r+2} \dots u_m$ 为 $N(A^T)$ 的一组标准正交基【即 U_2 为 $A^T U_2 = 0$ 的解】，令

$$U_2 = [u_{r+1} \ u_{r+2} \ \dots \ u_m]$$
$$U = [U_1 \ U_2]$$

则 $u_1 u_2 \dots u_m$ 构成了 \mathbf{R}^m 的一组标准正交基

因此， U 是 m 阶正交矩阵。为矩阵 A 的奇异值分解中的 m 阶正交矩阵。

紧/截断奇异值分解

紧奇异值分解与截断奇异值分解

- $A = U\Sigma V^T$ 又称为矩阵的完全奇异值分解(full singular value decomposition)
- 常用方式
 - 紧奇异值分解，与原始矩阵等秩的奇异值分解
 - 截断奇异值分解，比原始矩阵低秩的奇异值分解

紧奇异值分解

定义15.2 $m \times n$ 实矩阵 A ，其秩为 $\text{rank}(A) = r, r \leq \min(m, n)$ ，则称 $U_r \Sigma_r V_r^T$ 为 A 的紧奇异值分解 (compact singular value decomposition)，即

$$A = U_r \Sigma_r V_r^T$$

U_r : $m \times r$ 矩阵， U 的前 r 列

V_r : $n \times r$ 矩阵， V 的前 r 列

Σ_r : r 阶对角矩阵， Σ 的前 r 个对角线元素，且秩相等

【注意】

紧的意思是，对焦矩阵信息表达效率最高，没有全为0的行/列

例15.2

矩阵A的秩 $r = 3$

$$A = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 4 \\ 0 & 3 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0 \end{bmatrix}$$

$$U_r = \begin{bmatrix} 0 & 0 & \sqrt{0.2} \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \sqrt{0.8} \end{bmatrix}$$

$$\Sigma_r = \begin{bmatrix} 4 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & \sqrt{5} \end{bmatrix},$$

$$V_r^T = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{bmatrix}$$

$$A = U_r \Sigma_r V_r^T$$

截断奇异值分解

- ▶ 在矩阵的奇异值分解中，取最大的 k 个奇异值($k < r$, r 为矩阵的秩)对应的部分，得到矩阵的截断奇异值分解
- ▶ 实际应用中，提到矩阵的奇异值分解，通常指截断奇异值分解

截断奇异值分解

(定义15.3) 设 A 为 $m \times n$ 实矩阵, 其秩 $\text{rank}(A) = r$, 且 $0 < k < r$, 则称 $U_k \Sigma_k V_k^T$ 为矩阵 A 的截断奇异值分解 (truncated singular value decomposition)

$$A \approx U_k \Sigma_k V_k^T$$

其中 U_k 是 $m \times k$ 矩阵, V_k 是 $n \times k$ 矩阵, Σ_k 是 k 阶对角矩阵; 矩阵 U_k 由完全奇异值分解中 U 的前 k 列、矩阵 V_k 由 V 的前 k 列、矩阵 Σ_k 由 Σ 的前 k 个对角线元素得到。对角矩阵 Σ_k 的秩比原始矩阵 A 的秩低。

例

例 15.3 矩阵 $A = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 4 \\ 0 & 3 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0 \end{bmatrix}$

的秩为 3, 若取 $k = 2$ 则其截断奇异值分解是 $A \approx A_2 = U_2 \Sigma_2 V_2^T$

$$U_2 = \begin{bmatrix} 0 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, \Sigma_2 = \begin{bmatrix} 4 & 0 \\ 0 & 3 \end{bmatrix}, V_2^T = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

其中

$$A_2 = U_2 \Sigma_2 V_2^T = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 4 \\ 0 & 3 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$


U_2, V_2 是例 15.1 的 U 和 V 的前 2 列, Σ_2 是 Σ 的前 2 行前 2 列。 A_2 与 A 比较, A 的元素 1 和 2 在 A_2 中均变成 0

理解奇异值分解：几何角度

线性变换分解为连续的基础变换

从线性变换的角度理解奇异值分解

- $m \times n$ 矩阵 A 表示 R^n 到 R^m 的一个线性变换
 - $T: x \rightarrow Ax, x \in R^n, Ax \in R^m$
- 线性变换 T 分解为三个简单的变换
 - 坐标系的旋转或反射变换 V^T
 - V 的列向量 v_1, \dots, v_n 构成 R^n 的一组标准正交基, 表示旋转或反射变换
 - 坐标轴的缩放变换 Σ
 - Σ 的对角元素 $\sigma_1, \dots, \sigma_n$ 非负实数, R^m 中原始正交坐标系的缩放变换
 - 坐标系的旋转或反射变换 U
 - U 的列向量 u_1, \dots, u_m 构成 R^m 一组标准正交基, 表示旋转或反射变换
- 奇异值定理保证这种分解一定存在



几何解释

- ▶ 任意一个向量 $x \in R^n$ ，经过基于 $A = U\Sigma V^T$ 的线性变换，等价于
 - ▶ 经过坐标系的旋转或反射变换 V^T
 - ▶ 坐标轴的缩放变换 Σ
 - ▶ 以及坐标系的旋转或反射变换 U
 - ▶ 得到向量 $Ax \in R^m$

主要性质

1) 设矩阵 A 的奇异值分解为 $A = U\Sigma V^T$ ，则一下关系成立：

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

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

矩阵 $A^T A$ 和 $A A^T$ 的特征分解存在，且可以由矩阵 A 的奇异值分解的矩阵表示

V 的列向量是 $A^T A$ 的特征向量

U 的列向量是 $A A^T$ 的特征向量

Σ 的奇异值是 $A^T A$ 和 $A A^T$ 的特征值的平方根。

主要性质

2) 在矩阵 A 的奇异值分解中, 奇异值、左奇异向量和右奇异向量之间存在对应关系

由 $A = U\Sigma V^T$ 易知 $AV = U\Sigma$, 比较这一等式两端的第 j 列, 得到

$$Av_j = \sigma_j u_j, j = 1, 2, \dots, n$$

矩阵 A 的右奇异向量和奇异值、左奇异向量的关系

类似地, 由 $A^T U = V\Sigma^T$

得到

$$A^T u_j = \sigma_j v_j, j = 1, 2, \dots, n$$

$$A^T u_j = 0, j = n + 1, n + 2, \dots, m$$

矩阵 A 的左奇异向量和奇异值、右奇异向量的关系。

主要性质

3) 矩阵 A 的奇异值分解中, 奇异值 $\sigma_1, \sigma_2, \dots, \sigma_n$ 唯一, 而矩阵 U 和 V 不唯一。

零空间的基不唯一

4) 矩阵 A 和 Σ 的秩相等, 等于正奇异值 σ_i 的个数 r (包含重复的奇异值)

5) 矩阵 A 的 r 个右奇异向量 v_1, v_2, \dots, v_r 构成 A^T 的值域 $R(A^T)$ 的一组标准正交基

因为矩阵 A^T 是从 \mathbf{R}^m 映射到 \mathbf{R}^n 的线性变换, 则 A^T 的值域 $R(A^T)$ 和 A 的列空间是相同的, v_1, v_2, \dots, v_r 是 A^T 的一组标准正交基, 因而也是 $R(A^T)$ 的一组标准正交基。

矩阵 A 的 $n - r$ 个右奇异向量 $v_{r+1}, v_{r+2}, \dots, v_n$ 构成 A 的零空间 $N(A)$ 的一组标准正交基。

矩阵 A 的 r 个左奇异向量 u_1, u_2, \dots, u_r 构成值域 $R(A)$ 的一组标准正交基。

矩阵 A 的 $m - r$ 个左奇异向量 $u_{r+1}, u_{r+2}, \dots, u_m$ 构成 A^T 的零空间 $N(A^T)$ 的一组标准正交基

2 奇异值分解的计算

奇异值分解的计算

- 矩阵 A 的奇异值分解可以通过求对称矩阵 $A^T A$ 的特征值和特征向量得到。
- $A^T A$ 的特征向量构成正交矩阵 V 的列
- $A^T A$ 的特征值 λ_j 的平方根为奇异值 σ_i ，即 $\sigma_j = \sqrt{\lambda_j}, j = 1, 2, \dots, n$
- 对其由大到小排列作为对角线元素，构成对角矩阵 Σ
- 求正奇异值对应的左奇异向量，再求扩充的 A^T 的标准正交基，构成正交矩阵 U 的列
- 从而得到 A 的奇异值分解 $A = U\Sigma V^T$

奇异值分解的计算

1) 求 $A^T A$ 的特征值和特征向量, $A^T A$ 的特征向量构成正交矩阵 V 的列

计算对称矩阵 $W = A^T A$, 求解特征方程 $(W - \lambda I)x = 0$

得到特征值 λ_i , 并将特征值由大到小排列: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$

将特征值 λ_i 代入特征方程求得对应的特征向量

2) 求 n 阶正交矩阵 V

将特征向量单位化, 得到单位特征向量 v_1, v_2, \dots, v_n , 构成 n 阶正交矩阵 V : $V = [v_1 \ v_2 \ \dots \ v_n]$

3) 求 $m \times n$ 对角矩阵 Σ

计算 A 的奇异值 $\sigma_j = \sqrt{\lambda_j}, j = 1, 2, \dots, n$, 构造 $m \times n$ 矩形对角矩阵 Σ : $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$

4) 求 m 阶正交矩阵 U

对 A 的前 r 个正奇异值, 令 $u_j = \frac{1}{\sigma_j} A v_j, j = 1, 2, \dots, r$, 得到 $U_1 = [u_1 \ u_2 \ \dots \ u_r]$

求 A^T 的零空间【 $A^T X = 0$ 的解】的一组标准正交基 $\{u_{r+1}, \dots, u_m\}$, 令 $U_2 = [u_{r+1} \ \dots \ u_m]$, 令 $U = [U_1 \ U_2]$

5) 得到奇异值分解 $A = U \Sigma V^T$

3 奇异值分解与矩阵近似

矩阵的最优近

矩阵代表信息量，矩阵在给定度量下的近似表达

弗罗贝尼乌斯范数

奇异值分解也是一种矩阵近似的方法（在弗罗贝尼乌斯范数(Frobenius norm)意义下的近似）

【即，矩阵 A 经过奇异值分解-截断近似-变换回原空间得矩阵 X ， A 和 X 的弗罗贝尼乌斯范数接近】

【此时的矩阵不再只是看作是变换，也可以代表数据本身】

矩阵的弗罗贝尼乌斯范数是向量的 L_2 范数的直接推广，对应着机器学习中的平方损失函数

定义15.4 (弗罗贝尼乌斯范数) 矩阵 $A \in \mathbf{R}^{m \times n}$, $A = [a_{ij}]_{m \times n}$, 定义矩阵 A 的弗罗贝尼乌斯范数为

$$\|A\|_F = \left(\sum_{i=1}^m \sum_{j=1}^n (a_{ij})^2 \right)^{\frac{1}{2}}$$

引理15.1 设矩阵 $A \in \mathbf{R}^{m \times n}$, A 的奇异值分解为 $U\Sigma V^T$, 其中 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$, 则

$$\|A\|_F = (\sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2)^{\frac{1}{2}}$$

弗罗贝尼乌斯范数

设矩阵 $A \in R^{m \times n}$, A 的奇异值分解为 $U\Sigma V^T$, 其中 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$, 则

$$|A|_F = (\sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2)^{\frac{1}{2}}$$

【定理15.2】 设矩阵 $A \in R^{m \times n}$, 矩阵的秩 $\text{rank}(A) = r$, 并设 \mathcal{M} 为 $R^{m \times n}$ 中所有秩不超过 k 的矩阵集合, $0 < k < r$, 则存在一个秩为 k 的矩阵 $X \in \mathcal{M}$, 使得

$$|A - X|_F = \min_{S \in \mathcal{M}} |A - S|_F$$

称矩阵 X 为矩阵 A 在弗罗贝尼乌斯范数意义下的最优近似。

定理15.3

【定理15.3】设矩阵 $A \in R^{m \times n}$, 矩阵的秩 $\text{rank}(A) = r$, A 的奇异值分解为 $U\Sigma V^T$, 并设 \mathcal{M} 为 $R^{m \times n}$ 中所有秩不超过 k 的矩阵集合, $0 < k < r$, 若秩为 k 的矩阵 $X \in \mathcal{M}$ 满足 $|A - X|_F = \min_{S \in \mathcal{M}} |A - S|_F$, 则

$$|A - X|_F = (\sigma_{k+1}^2 + \sigma_{k+2}^2 + \cdots + \sigma_n^2)^{\frac{1}{2}}$$

特别地, 若 $A' = U\Sigma'V^T$, 其中

$$\Sigma' = \begin{bmatrix} \sigma_1 & & & \\ & \sigma_k & & \\ & & \ddots & \\ & & & 0 \end{bmatrix} = \begin{bmatrix} \Sigma_k & 0 \\ 0 & 0 \end{bmatrix}$$

则

$$|A - A'|_F = (\sigma_{k+1}^2 + \sigma_{k+2}^2 + \cdots + \sigma_n^2)^{\frac{1}{2}} = \min_{S \in \mathcal{M}} |A - S|_F$$

矩阵的最优近似

- ▶ 在秩不超过 k 的 $m \times n$ 矩阵的集合中，存在矩阵 A 的弗罗贝尼乌斯范数意义下的最优近似矩阵 X ， $A' = U\Sigma'V^T$ 是达到最优值的一个矩阵
- ▶ 紧奇异值分解是在弗罗贝尼乌斯范数意义下的无损压缩
- ▶ 截断奇异值分解是有损压缩
- ▶ 截断奇异值分解得到的矩阵的秩为 k ，通常远小于原始矩阵的秩 r ，所以是由低秩矩阵实现了对原始矩阵的压缩

矩阵的外积展开式

矩阵看成变换，矩阵由一系列外积形式的变化组合而成

矩阵的外积展开式

矩阵A的奇异值分解 $A = U\Sigma V^T$ 也可以由外积形式表示

若将A的奇异值分解看成矩阵 $U\Sigma$ 和 V^T 的乘积，将 $U\Sigma$ 按列向量分块，将 V^T 按行向量分块，即得

$$U\Sigma = [\sigma_1 u_1 \quad \sigma_2 u_2 \quad \cdots \quad \sigma_n u_n], \quad V^T = \begin{bmatrix} v_1^T \\ v_2^T \\ \vdots \\ v_n^T \end{bmatrix}$$

则【直观上，每一个 $A_{i,j}$ 都是 $U\Sigma$ 第 i 行和 V^T 第 j 列内积而来，即为下式的 i,j 的值】

$$A = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_n u_n v_n^T$$

其中 $u_i v_j^T$ 是矩阵， $u_i v_j^T = \begin{bmatrix} u_{1i} \\ u_{2i} \\ \vdots \\ u_{mi} \end{bmatrix} [u_{1j} \quad v_{2j} \quad \cdots \quad v_{nj}] = \begin{bmatrix} u_{1i} v_{1j} & u_{1i} v_{2j} & \cdots & u_{1i} v_{nj} \\ u_{2i} v_{1j} & u_{2i} v_{2j} & \cdots & u_{2i} v_{nj} \\ \vdots & \vdots & & \vdots \\ u_{mi} v_{1j} & u_{mi} v_{2j} & \cdots & u_{mi} v_{nj} \end{bmatrix}$

A的外积展开式也可写为 $A = \sum_{k=1}^n A_k = \sum_{k=1}^n \sigma_k u_k v_k^T$ ，为矩阵的有序加权

矩阵的外积展开式

由矩阵 A 的外积展开式知，若 A 的秩为 n ，则

$$A = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_n u_n v_n^T$$

设矩阵

$$A_k = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_k u_k v_k^T$$

则 A_k 的秩为 k ，并且 A_k 是秩为 k 矩阵在弗罗贝尼乌斯范数意义 A 的最优近似矩阵，矩阵 A_k 就是 A 的截断奇异值分解

由于通常奇异值 σ_i 递减很快，所以 k 取很小值时， A_k 也可以对 A 有很好的近似。