

奇异值分解

奇异值分解与矩阵近似

总体主成分分析

样本主成分分析

## 第十一讲 奇异值分解与主成分分析简介

2025年5月

奇异值分解

奇异值分解与矩阵近似

总体主成分分析

样本主成分分析

# PART I 奇异值分解

# 概要

1

## 奇异值分解

- 从谱分解到奇异值分解
- 奇异值与奇异向量

对非零矩阵  $A \in \mathbf{R}^{m \times n}$ , 其秩  $\text{rank}(A) = r$

- $r \leq \min\{m, n\}$ .
- $A$  的四个基本子空间
  - $A$  的值域:

$$R(A) = \{z \in \mathbf{R}^m | \exists x \in \mathbf{R}^n, z = Ax\} = A \text{ 的列空间.}$$

- $A$  的零空间:

$$N(A) = \{x \in \mathbf{R}^n | Ax = 0\}.$$

- $A^T$  的值域:

$$R(A^T) = \{y \in \mathbf{R}^n | \exists x \in \mathbf{R}^m, y = A^T x\} = A \text{ 的行空间.}$$

- $A^T$  的零空间:

$$N(A^T) = \{x \in \mathbf{R}^m | A^T x = 0\}.$$

对非零矩阵  $A \in \mathbf{R}^{m \times n}$ ,  $\text{rank}(A) = r$ .

$A$  的四个基本子空间:

- $R(A), N(A^T) \subseteq \mathbf{R}^m.$ 
  - $R(A)^\perp = N(A^T).$
  - $\dim(R(A)) = \text{rank}(A) = r.$
  - $\dim(N(A^T)) = m - r.$
- $R(A^T), N(A) \subseteq \mathbf{R}^n.$ 
  - $R(A^T)^\perp = N(A).$
  - $\dim(R(A^T)) = \text{rank}(A) = r.$
  - $\dim(N(A)) = n - r.$

对非零矩阵  $A \in \mathbb{R}^{m \times n}$ , 其秩  $\text{rank}(A) = r$  且不妨设  $m \geq n$ , 考虑实对称矩阵  $A^T A_{n \times n}$ :

- 不妨设  $A^T A$  的特征值按降序排列为  $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n$ , 则  $\lambda_n \geq 0$ .
- $\text{rank}(A^T A) = \text{rank}(A) = r$ .
- $A^T A$  可对角化: 即

$$V^T A^T A V = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n),$$

这里  $V = [v_1, v_2, \dots, v_n]$  为正交矩阵.

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

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

能否构造  $A$  的类似因子乘积的表示形式?

- $\text{rank}(\Lambda) = \text{rank}(A^T A) = r$ , 则
  - $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_r > 0$ ,
  - $\lambda_{r+1} = \cdots = \lambda_n = 0$ .
- 我们将  $V$  分成两部分  $V = [V_1, V_2]$ , 其中  $V_1 = [v_1, \dots, v_r]$ ,  $V_2 = [v_{r+1}, \dots, v_n]$ .
  - $v_{r+1}, \dots, v_n$  正好构成  $A^T A$  的零空间  $N(A^T A)$  (也是  $N(A)$ ) 的一组标准正交基.
  - $A V_2 = 0$ .
  - $I = V V^T = V_1 V_1^T + V_2 V_2^T$ .
  - $A = A I = A(V_1 V_1^T + V_2 V_2^T) = A V_1 V_1^T$ .

- 从  $V_1 = [v_1, v_2, \dots, v_r]$  出发, 构造  $U_1 = [u_1, \dots, u_r]$  如下:

$$u_i = \frac{1}{\sqrt{\lambda_i}} A v_i, \quad i = 1, \dots, r.$$

则

$$u_i^T u_j = \frac{1}{\sqrt{\lambda_i \lambda_j}} v_i^T A^T A v_j = \frac{1}{\sqrt{\lambda_i \lambda_j}} v_i^T \lambda_j v_j = \delta_{ij}.$$

这说明

$$u_1, \dots, u_r$$

是  $A$  的值域空间  $R(A)$  的一组标准正交基.

- $R(A)$ 的正交补空间为  $N(A^T)$ .
- 设  $u_{r+1}, \dots, u_m$  为  $N(A^T)$  的一组标准正交集.
- 令  $U_2 = [u_{r+1}, \dots, u_m]$ , 构造正交矩阵

$$U = [U_1, U_2].$$

- 令  $\sigma_i = \sqrt{\lambda_i}$ ,  $i = 1, 2, \dots, r$ . 构造对角线元素降序排列的对角矩阵

$$\Sigma_1 = \text{diag}(\sigma_1, \dots, \sigma_r).$$

由前面  $U_1$  构造可知  $U_1 \Sigma_1 = A V_1$ .

- 进一步构造  $m \times n$  矩形对角矩阵

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

## 定理1

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

证明：我们先计算等式右边

$$\begin{aligned} U\Sigma V^T &= [U_1, U_2] \begin{bmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} \\ &= U_1 \Sigma_1 V_1^T \\ &= A V_1 V_1^T \\ &= A. \end{aligned}$$

□

## 奇异值分解

矩阵的奇异值分解运算就是将一个非零的  $m \times n$  实矩阵  $A \in \mathbb{R}^{m \times n}$ , 表示为满足如下特性的三个实矩阵乘积形式的因子分解运算:

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

其中

- $U$  是  $m$  阶正交矩阵,  $U^T U = I$ ;
- $V$  是  $n$  阶正交矩阵,  $V^T V = I$ ;
- $\Sigma$  是由降序排列的非负的对角线元素组成的  $m \times n$  矩形对角矩阵:

$$\Sigma = \text{diag}(\sigma_1, \dots, \sigma_p),$$

这里  $\sigma_1 \geq \dots \geq \sigma_p \geq 0$ , 且  $p = \min(m, n)$ .

$U\Sigma V^T$  称为  $A$  的奇异值分解,  $\sigma_i$  称为  $A$  的奇异值,  $U$  和  $V$  的列向量分别称为  $A$  的左、右奇异向量.



- 由定理1可知，对任一非零的 $m \times n$ 实矩阵  $A \in \mathbb{R}^{m \times n}$ ，其奇异值分解存在。
- 由  $A = U\Sigma V^T$  可推出
  - $A^T A = V(\Sigma^T \Sigma)V^T$ .
  - 右奇异向量为  $A^T A$  的特征向量.
  - $AA^T = U(\Sigma \Sigma^T)U^T$ .
  - 左奇异向量为  $AA^T$  的特征向量.
  - $AV = U\Sigma$ .
  - $A^T U = V\Sigma^T$ .
- $A$  的奇异值  $\sigma_1, \dots, \sigma_n$  是唯一的，但  $U$  和  $V$  不唯一。
- 矩阵的奇异值分解可以看作将其对应的线性变换分解为旋转变换( $V^T$ )、缩放变换( $\Sigma$ )及旋转变换( $U$ )的组合。

## 紧奇异值分解与截断奇异值分解

一个非零的秩为  $r$  的  $m \times n$  实矩阵  $A \in \mathbf{R}^{m \times n}$  奇异值分解为  $U\Sigma V^T$ , 其中

- $U = [u_1, u_2, \dots, u_m]$ ;
- $V = [v_1, v_2, \dots, v_n]$ ;
- $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_p)$ ,  $p = \min(m, n)$ .

则  $A = U_r \Sigma_r V_r^T$  称为  $A$  的紧奇异值分解, 其中

- $U_r = [u_1, u_2, \dots, u_r]$ ;
- $V_r = [v_1, v_2, \dots, v_r]$ ;
- $\Sigma_r = \text{diag}(\sigma_1, \dots, \sigma_r)$ .

## 紧奇异值分解与截断奇异值分解

对  $0 < k < r$ ,  $U_k \Sigma_k V_k^T$  称为  $A$  的截断奇异值分解, 其中

- $U_k = [u_1, u_2, \dots, u_k]$ ;
- $V_k = [v_1, v_2, \dots, v_k]$ ;
- $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k)$ .

问题:  $A \approx U_k \Sigma_k V_k^T$  的程度如何度量?

# 概要

1

## 奇异值分解

- 从谱分解到奇异值分解
- 奇异值与奇异向量

2

## 奇异值分解与矩阵近似

- 费罗贝尼乌斯范数
- 矩阵的最优近似
- 矩阵的外积展开

## 费罗贝尼乌斯范数

设  $A \in \mathbb{R}^{m \times n}$  且  $A = [a_{ij}]_{m \times n}$ ,  $A$  的费罗贝尼乌斯范数 (Frobenius norm)  $\|A\|_F$  定义如下:

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

- 若  $Q$  是  $m$  阶正交矩阵, 则  $\|QA\|_F = \|A\|_F$ .
- 若  $P$  是  $n$  阶正交矩阵, 则  $\|AP\|_F = \|A\|_F$ .
- 若  $Q$  是  $m$  阶正交矩阵,  $P$  是  $n$  阶正交矩阵, 则

$$\|QAP\|_F = \|A\|_F.$$

- 若  $Q$  是  $m$  阶正交矩阵, 则  $\| QA \|_F = \| A \|_F$ .

证明: 不妨设  $A = [a_1, \dots, a_n]$ , 则  $QA = [Qa_1, \dots, Qa_n]$ . 故

$$\| QA \|_F^2 = \| [Qa_1, \dots, Qa_n] \|_F^2$$

$$= \sum_{i=1}^n \| Qa_i \|_2^2$$

$$= \sum_{i=1}^n (Qa_i)^T Qa_i = \sum_{i=1}^n a_i^T Q^T Q a_i$$

$$= \sum_{i=1}^n \| a_i \|_2^2 = \| A \|_F^2. \quad \square$$

## 引理1

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

$$\|A\|_F = \sqrt{\sum_{i=1}^n \sigma_i^2}$$

证明:  $\|A\|_F = \|U\Sigma V^T\|_F = \|\Sigma\|_F = \sqrt{\sum_{i=1}^n \sigma_i^2}$ .  $\square$

## 引理2

设  $A \in \mathbf{R}^{m \times n}$  且  $\text{rank}(A) = r$ , 并设  $\mathcal{M}$  为  $\mathbf{R}^{m \times n}$  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  $X$ , 使得

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

称矩阵  $X$  为矩阵  $A$  在费罗贝尼乌斯范数意义下的最优近似.

## 定理2

设  $A \in \mathbf{R}^{m \times n}$  且  $\text{rank}(A) = r$ , 其奇异值分解为  $U\Sigma V^T$ , 并设  $\mathcal{M}$  为  $\mathbf{R}^{m \times n}$  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  $\|A - X\|_F = \min_{S \in \mathcal{M}} \|A - S\|_F$ ,

$$\text{则 } \|A - X\|_F = \sqrt{\sum_{l=k+1}^n \sigma_l^2}.$$

- 特别地, 若  $A' = U\Sigma' V^T$ , 其中  $\Sigma'_{m \times n} = \begin{bmatrix} \Sigma_k & 0 \\ 0 & 0 \end{bmatrix}$ , 这里  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k)$ , 则

$$\|A - A'\|_F = \sqrt{\sum_{l=k+1}^n \sigma_l^2} = \min_{S \in \mathcal{M}} \|A - S\|_F.$$

证明：设  $X$  为  $A$  的最优近似，则

$$\|A - X\|_F \leq \|A - A'\|_F = \sqrt{\sum_{l=k+1}^n \sigma_l^2}.$$

下面证明

$$\|A - X\|_F \geq \sqrt{\sum_{l=k+1}^n \sigma_l^2}.$$

设  $X$  的奇异值分解为  $Q\Omega P^T$ ，其中

$$\Omega = \begin{bmatrix} \Omega_1 & 0 \\ 0 & 0 \end{bmatrix},$$

这里  $\Omega_1 = \text{diag}(\omega_1, \dots, \omega_k)$ .

令  $B = Q^T AP$ , 则  $A = QBP^T$ . 按照  $\Omega$  的分块方法对  $B$  进行分块

$$B = \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix},$$

则

$$\begin{aligned} \|A - X\|_F^2 &= \|Q(B - \Omega)P^T\|_F^2 = \|B - \Omega\|_F^2 \\ &= \|B_{11} - \Omega_1\|_F^2 + \|B_{12}\|_F^2 + \|B_{21}\|_F^2 + \|B_{22}\|_F^2. \end{aligned}$$

下面我们证明  $B_{12} = 0$ 、 $B_{21} = 0$ 、 $B_{11} = \Omega_k$ .

- 若  $B_{12} \neq 0$ , 则构造  $Y = Q \begin{bmatrix} B_{11} & B_{12} \\ 0 & 0 \end{bmatrix} P^T$ , 则  $Y \in \mathcal{M}$ , 且

$$\|A - Y\|_F^2 = \|B_{21}\|_F^2 + \|B_{22}\|_F^2 < \|A - X\|_F^2.$$

这与  $X$  是最优近似相矛盾.

- 同理可证  $B_{21} = 0$ .

- 若  $B_{11} \neq \Omega_1$ , 则构造  $Z = Q \begin{bmatrix} B_{11} & 0 \\ 0 & 0 \end{bmatrix} P^T$ , 则  $Z \in \mathcal{M}$ , 且

$$\| A - Z \|_F^2 = \| B_{22} \|_F^2 < \| B_{11} - \Omega_1 \|_F^2 + \| B_{22} \|_F^2 = \| A - X \|_F^2.$$

这与  $X$  是最优近似相矛盾, 故  $B_{11} = \Omega_k$ .

基于上面已经证明的结论, 则

$$\| A - X \|_F = \| B_{22} \|_F.$$

设  $B_{22}$  的奇异值分解为  $U_1 \Lambda V_1^T$ , 则

$$\| A - X \|_F = \| B_{22} \|_F = \| \Lambda \|_F.$$

令  $U_2 = \begin{bmatrix} I_k & 0 \\ 0 & U_1 \end{bmatrix}$ ,  $V_2 = \begin{bmatrix} I_k & 0 \\ 0 & V_1 \end{bmatrix}$ , 则

$$U_2^T Q^T A P V_2 = \begin{bmatrix} \Omega_1 & 0 \\ 0 & \Lambda \end{bmatrix},$$

即

$$A = Q U_2 \begin{bmatrix} \Omega_1 & 0 \\ 0 & \Lambda \end{bmatrix} (P V_2)^T.$$

这意味着 $\Lambda$ 的对角线元素为 $A$ 的奇异值，故有

$$\| A - X \|_F = \| \Lambda \|_F \geq \sqrt{\sum_{l=k+1}^n \sigma_l^2}.$$

因此  $\| A - X \|_F = \sqrt{\sum_{l=k+1}^n \sigma_l^2} = \| A - A' \|_F . \quad \square$

- 定理2说明在秩不超过 $k$ 的 $m \times n$ 矩阵集合中，存在矩阵 $A$ 的最优近似矩阵 $X$ ;  $A' = U\Sigma'V^T$ 就是这样的最优近似矩阵.
- $A$ 的紧奇异值分解是在费罗贝尼乌斯范数意义下 $A$ 的无损压缩.
- $A$ 的秩为 $k$ 的截断奇异值分解是 $A$ 的有损压缩，通常 $k$ 远小于 $r$ ，因此是由低秩矩阵实现了对 $A$ 的压缩。

- 设  $A \in \mathbb{R}^{m \times n}$  且其奇异值分解为  $U\Sigma V^T$ , 则

$$\begin{aligned} A &= U\Sigma V^T \\ &= [\sigma_1 u_1, \dots, \sigma_n u_n] \begin{bmatrix} v_1^T \\ \vdots \\ v_n^T \end{bmatrix} \\ &= \sigma_1 u_1 v_1^T + \dots + \sigma_n u_n v_n^T. \end{aligned}$$

- 称  $A = \sigma_1 u_1 v_1^T + \dots + \sigma_n u_n v_n^T$  为  $A$  的外积展开式.
- $A$  的外积展开式也可以看作矩阵的有序加权和  $\sum_{k=1}^n \sigma_k u_k v_k^T$ .

- 若  $A$  的秩为  $n$ , 则

$$A = \sigma_1 u_1 v_1^T + \cdots + \sigma_n u_n v_n^T.$$

- 令

$$A_k = \sum_{i=1}^k \sigma_i u_i v_i^T,$$

则  $A_k$  的秩为  $k$ , 是  $A$  的截断奇异值分解.

- $A_k$  是秩为  $k$  的矩阵中在费罗贝尼乌斯范数意义下  $A$  的最优近似矩阵.
- 由于通常奇异值  $\sigma_i$  递减很快, 所以  $k$  很小时,  $A_k$  对  $A$  也可有很好的近似.

# 奇异值分解小结

- 矩阵的基本子空间
- 矩阵的奇异值分解
- 紧奇异值分解与截断奇异值分解
- 矩阵的费罗贝尼乌斯范数
- 截断奇异值分解与最优近似矩阵
- 矩阵的外积表示
- 奇异值分解与谱分解

奇异值分解

奇异值分解与矩阵近似

总体主成分分析

样本主成分分析

费罗贝尼乌斯范数

矩阵的最优近似

矩阵的外积展开

## PART II 主成分分析

# 概要

3

## 总体主成分分析

- 标准化随机变量
- 方差贡献率
- 因子负荷量

# 主成分分析

- 如果数据的一些特征之间存在相关性，处理起来不太方便；
- 如果数据维数过高，影响算法性能.

我们希望能构造一组新的相互不相关的特征来表示数据：

- 通常用原来特征的线性组合来构造新特征.
- 希望特征变换的过程中损失的信息尽可能少.
- 构造出的新特征个数比原来的特征数少很多，达到降维的目的.

## 标准线性组合

设  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  是  $m$  维随机向量,  $\alpha \in \mathbb{R}^m$  且  $\alpha^T \alpha = 1$ , 则称

$$y = \alpha^T \mathbf{x}$$

为标准线性组合.

本讲主要考虑标准线性组合.

设  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  是  $m$  维随机向量, 其均值为  $\mu$ , 协方差矩阵

$$\Sigma = E[(\mathbf{x} - \mu)(\mathbf{x} - \mu)^T] = [\sigma_{ij}]_{m \times m},$$

则

- $E[(\mathbf{x} - \mu)] = \mathbf{0}$ .
- $\text{trace}(\Sigma) = \sum_{i=1}^m \text{Var}(x_i) = \sum_{i=1}^m \sigma_{ii}$ .
- $\Sigma$  是半正定的.
- 不妨设  $\Sigma$  的特征值按照降序排列为

$$\lambda_1 \geq \lambda_2 \cdots \geq \lambda_m \geq 0$$

- $\Sigma$  可对角化: 即

$$A^T \Sigma A = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m),$$

这里  $A = [\alpha_1, \alpha_2, \dots, \alpha_m]$  为正交矩阵,  
 $\alpha_i = (\alpha_{1i}, \alpha_{2i}, \dots, \alpha_{mi})^T$  且  $\alpha_i$  是  $\Sigma$  的属于  $\lambda_i$  的特征向量.

- $\alpha_1, \alpha_2, \dots, \alpha_m$  正好构成了  $\mathbf{R}^m$  的一组标准正交基, 即

对  $\forall \alpha \in \mathbf{R}^m$ ,  $\exists c_1, c_2, \dots, c_m \in \mathbf{R}$  s.t.  $\alpha = \sum_{i=1}^m c_i \alpha_i$ .

## 主成分变换

设  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  是均值为  $\mu$ , 协方差矩阵为  $\Sigma$  的  $m$  维随机向量, 则如下线性变换被称为主成分变换:

$$\mathbf{y} = \mathbf{A}^T(\mathbf{x} - \mu).$$

并称  $\mathbf{y}$  的第  $i$  个分量

$$y_i = \alpha_i^T(\mathbf{x} - \mu)$$

为  $\mathbf{x}$  的第  $i$  主成分, 这里  $\alpha_i$  为  $\mathbf{A}$  的第  $i$  个列向量.

考虑  $\mathbf{x} = (x_1, x_2)^T$ , 其中

- $E[x_1] = E[x_2] = 0$ ,
- $\text{Var}(x_1) = \text{Var}(x_2) = 1$ ,
- $\text{Cov}(x_1, x_2) = \rho > 0$ ,

协方差矩阵为

$$\Sigma = \begin{bmatrix} 1 & \rho \\ \rho & 1 \end{bmatrix}$$

其特征值为

$$\lambda_1 = 1 + \rho, \quad \lambda_2 = 1 - \rho$$

相应的特征向量为

$$\alpha_1 = \left( \frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right)^T, \quad \alpha_2 = \left( \frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}} \right)^T$$

由此得到 $\mathbf{x}$ 的第一、第二主成分分别为

$$y_1 = \frac{1}{\sqrt{2}}(x_1 + x_2);$$

$$y_2 = \frac{1}{\sqrt{2}}(x_1 - x_2)$$

相应的方差为

$$\text{Var}(y_1) = 1 + \rho = \lambda_1;$$

$$\text{Var}(y_2) = 1 - \rho = \lambda_2.$$

$$\text{Var}(y_1) + \text{Var}(y_2) = \text{Var}(x_1) + \text{Var}(x_2) = 2.$$

# 主成分的性质

**TH1.** 设  $\mathbf{x} \sim (\mu, \Sigma)$ , 则  $\mathbf{y} = \mathbf{A}^T(\mathbf{x} - \mu)$  满足

- (1)  $E[\mathbf{y}] = \mathbf{0}$ .
- (2)  $\text{Var}(y_i) = \lambda_i, i = 1, 2, \dots, m$ .
- (3)  $\text{Cov}(y_i, y_j) = 0, i \neq j, i, j = 1, 2, \dots, m$ .
- (4)  $\text{Var}(y_1) \geq \text{Var}(y_2) \geq \dots \geq \text{Var}(y_m) \geq 0$ .
- (5)  $\sum_{i=1}^m \text{Var}(y_i) = \text{trace}(\Sigma) = \sum_{i=1}^m \text{Var}(x_i)$ .
- (6)  $\prod_{i=1}^m \text{Var}(y_i) = |\Sigma|$ .

(1) 的证明:  $E[\mathbf{y}] = E[A^T(\mathbf{x} - \mu)] = A^T E[(\mathbf{x} - \mu)] = \mathbf{0}$ .

(2) 的证明:

$$\begin{aligned}\text{Var}(y_i) &= \text{Var}(\alpha_i^T(\mathbf{x} - \mu)) = \alpha_i^T E[(\mathbf{x} - \mu)(\mathbf{x} - \mu)^T] \alpha_i \\ &= \alpha_i^T \Sigma \alpha_i = \lambda_i \alpha_i^T \alpha_i = \lambda_i\end{aligned}$$

(3) 的证明: 如果  $i \neq j$ ,

$$\begin{aligned}\text{Cov}(y_i, y_j) &= \text{Cov}(\alpha_i^T(\mathbf{x} - \mu), \alpha_j^T(\mathbf{x} - \mu)) \\ &= \alpha_i^T E[(\mathbf{x} - \mu)(\mathbf{x} - \mu)^T] \alpha_j \\ &= \alpha_i^T \Sigma \alpha_j = \lambda_j \alpha_i^T \alpha_j = 0.\end{aligned}$$

由(2)可知, (4), (5), (6)都成立.  $\square$

**TH2.** 不存在方差比 $\lambda_1$ 更大的标准线性组合 $y = \alpha^T \mathbf{x}$ .

证明：考虑标准线性组合 $y = \alpha^T \mathbf{x}$ , 其中 $\alpha \in \mathbf{R}^m$  且 $\alpha^T \alpha = 1$ . 由于 $\alpha_1, \alpha_2, \dots, \alpha_m$ 正好构成了 $\mathbf{R}^m$ 的一组标准正交基, 则

$$\exists c_1, c_2, \dots, c_m \in \mathbf{R} \text{ s.t. } \alpha = \sum_{i=1}^m c_i \alpha_i.$$

对此线性组合来说,

$$\begin{aligned}\text{Var}(y) &= \alpha^T \Sigma \alpha = \left[ \sum_{i=1}^m c_i \alpha_i^T \right] \Sigma \left[ \sum_{i=1}^m c_i \alpha_i \right] \\ &= \sum_{i=1}^m c_i^2 \lambda_i \alpha_i^T \alpha_i = \sum_{i=1}^m c_i^2 \lambda_i.\end{aligned}$$

另一方面  $\alpha^T \alpha = 1$  意味着  $\sum_{i=1}^m c_i^2 = 1$ .

考虑如下最优化问题：

$$\max_{c_1, \dots, c_m} \sum_{i=1}^m c_i^2 \lambda_i$$

$$s.t. \quad \sum_{i=1}^m c_i^2 = 1.$$

则此问题的最优解为

$$c_1 = 1, c_2 = \dots = c_m = 0$$

此时

$$\lambda_1 = \max_{c_1, \dots, c_m} \sum_{i=1}^m c_i^2 \lambda_i$$

对应的标准线性组合

$$y_1 = \alpha_1^T \mathbf{x}$$

正好是的第一主成分.  $\square$

**TH3.** 如果标准线性组合  $y = \alpha^T \mathbf{x}$  与  $\mathbf{x}$  的前  $k$  个主成分都不相关，则  $y$  的方差当  $y$  是第  $k+1$  主成分时达到最大。

证明：设  $y = \alpha^T \mathbf{x}$ , 其中  $\alpha^T \alpha = 1$  且  $\alpha = \sum_{i=1}^m c_i \alpha_i$ . 对此线性组合来说，

$$\text{Var}(y) = \sum_{i=1}^m c_i^2 \lambda_i.$$

对  $1 \leq j < k$  来说，

$$\begin{aligned}\text{Cov}(y, y_j) &= \text{Cov}(\alpha^T \mathbf{x}, \alpha_j^T \mathbf{x}) = \left[ \sum_{i=1}^m c_i \alpha_i^T \right] \Sigma \alpha_j \\ &= c_j \lambda_j \alpha_j^T \alpha_j = c_j \lambda_j = 0.\end{aligned}$$

这意味着对  $1 \leq j < k$  来说,  $c_j^2 \lambda_j = 0$ . 故

$$\text{Var}(y) = \sum_{i=k+1}^m c_i^2 \lambda_i.$$

和前面证明类似, 我们可得

$$\max_{c_1, \dots, c_m} \text{Var}(y) = \lambda_{k+1}.$$

对应的标准线性组合

$$y = \alpha_{k+1}^T \mathbf{x}$$

正好是的第  $k+1$  主成分.  $\square$

设  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  是均值为  $\mu$ , 协方差矩阵为  $\Sigma$  的  $m$  维随机向量, 对每个  $x_i$  定义

$$x'_i = \frac{x_i - \mu_i}{\sqrt{\sigma_{ii}}},$$

则

$$E[x'_i] = 0, \quad \text{Var}(x'_i) = 1.$$

对  $\mathbf{x}' = (x'_1, x'_2, \dots, x'_m)^T$  来说,

$$\begin{aligned} \text{Cov}(x'_i, x'_j) &= E \left[ \left( \frac{x_i - \mu_i}{\sqrt{\sigma_{ii}}} \right) \left( \frac{x_j - \mu_j}{\sqrt{\sigma_{jj}}} \right) \right] \\ &= \frac{E[(x_i - \mu_i)(x_j - \mu_j)]}{\sqrt{\sigma_{ii}\sigma_{jj}}} = \rho_{ij} \end{aligned}$$

即  $\mathbf{x}'$  的协方差矩阵  $\Sigma'$  为  $\mathbf{x}$  的相关矩阵:  $\Sigma' = [\rho_{ij}]_{m \times m}$ . 此时  $\text{trace}(\Sigma') = m$ .

$\mathbf{x}$ 的第  $k$  主成分  $y_k$  的方差贡献率  $\eta_k$  定义为  $\eta_k = \frac{\lambda_k}{\sum_{i=0}^m \lambda_i}$ .

$\mathbf{x}$  的前  $k$  个主成分  $y_1, \dots, y_k$  的累计方差贡献率  $\eta_{1 \rightarrow k}$  定义为

$$\eta_{1 \rightarrow k} = \sum_{i=1}^k \eta_i = \frac{\sum_{i=1}^k \lambda_i}{\sum_{j=0}^m \lambda_j}.$$

累计方差贡献率  $\eta_{1 \rightarrow k}$  反映了  $\mathbf{x}$  的前  $k$  个主成分保留原有变量方差信息的比例, 可以作为  $k$  的选择标准, 比如选择  $k$  使得  $\eta_{1 \rightarrow k}$  达到规定的百分比(如 80%)以上.

- 主成分变换  $\mathbf{y} = A^T \mathbf{x}$  的逆变换为  $\mathbf{x} = A\mathbf{y}$ .
- $x_i = \sum_{j=1}^m \alpha_{ij} y_j, i = 1, 2, \dots, m.$
- 因子负荷量: 第  $k$  主成分与变量  $x_i$  的相关系数, 即  $y_k$  对  $x_i$  的贡献程度:

$$\rho(y_k, x_i) = \frac{\text{Cov}\left(\sum_{j=1}^m \alpha_{jj} y_j, y_k\right)}{\sqrt{\lambda_k \sigma_{ii}}} = \frac{\alpha_{ik} \text{Var}(y_k)}{\sqrt{\lambda_k \sigma_{ii}}} = \frac{\sqrt{\lambda_k} \alpha_{ik}}{\sqrt{\sigma_{ii}}}$$

- 因子负荷量满足如下性质:
  - $\sum_{i=1}^m \sigma_{ii} \rho^2(y_k, x_i) = \lambda_k \left( \sum_{i=1}^m \alpha_{ik}^2 \right) = \lambda_k.$
  - $\sum_{k=1}^m \rho^2(y_k, x_i) = 1.$

$\mathbf{x}$ 的前 $k$ 个主成分  $y_1, \dots, y_k$  的对原有变量  $x_i$  的贡献率  $\nu_{1 \rightarrow k}(i)$  定义为

$$\nu_{1 \rightarrow k}(i) = \sum_{j=1}^k \rho^2(y_j, x_i) = \sum_{j=1}^k \frac{\lambda_j \alpha_{ij}^2}{\sigma_{ii}}$$

# 概要

## 3 总体主成分分析

- 标准化随机变量
- 方差贡献率
- 因子负荷量

## 4 样本主成分分析

- 设  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$  是对  $m$  维随机向量  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  进行  $n$  次独立观测的样本, 其中  $\mathbf{x}_j = (x_{1j}, x_{2j}, \dots, x_{mj})^T$  表示第  $j$  个观测样本, 则观测数据矩阵

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{m1} & \cdots & x_{mn} \end{bmatrix}$$

- 样本均值向量为  $\bar{\mathbf{x}} = \frac{1}{n} \sum_{j=1}^n \mathbf{x}_j = (\bar{x}_1, \dots, \bar{x}_m)^T$ .
- 样本协方差矩阵为  $\mathbf{S} = [s_{ij}]_{m \times m}$ , 其中  $s_{ij} = \frac{1}{n-1} \sum_{k=1}^n (x_{ik} - \bar{x}_i)(x_{jk} - \bar{x}_j)$ ,  $i, j = 1, 2, \dots, m$ .
- 样本相关矩阵为  $\mathbf{R} = [r_{ij}]_{m \times m}$ , 其中  $r_{ij} = \frac{s_{ij}}{\sqrt{s_{ii}s_{jj}}}$ .

- 定义  $m$  维随机向量  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  到  $\mathbf{y} = (y_1, y_2, \dots, y_m)^T$  的线性变换

$$\mathbf{y} = A^T \mathbf{x},$$

其中  $A = [\alpha_1, \alpha_2, \dots, \alpha_m] = \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1m} \\ \vdots & \ddots & \vdots \\ \alpha_{m1} & \cdots & \alpha_{mm} \end{bmatrix}$ .

- 对每个分量来说,  $y_i = \alpha_i^T \mathbf{x}$ .
- 对每个观测数据  $\mathbf{x}_j$  来说,  $\mathbf{y}_j = A^T \mathbf{x}_j$ .
- $y_i$  对应于  $\mathbf{X}$  的样本均值  $\bar{y}_i = \frac{1}{n} \sum_{j=1}^n \alpha_i^T \mathbf{x}_j = \alpha_i^T \bar{\mathbf{x}}$ .

- $y_i$  对应于  $\mathbf{X}$  的样本方差  $\text{Var}(y_i) = \alpha_i^T \mathbf{S} \alpha_i$ .
- $y_i, y_j$  对应于  $\mathbf{X}$  的样本协方差  $\text{Cov}(y_i, y_j) = \alpha_i^T \mathbf{S} \alpha_j$ .

- 我们首先对数据进行规范化:

$$x'_{ik} = \frac{x_{ik} - \bar{x}_i}{\sqrt{s_{ii}}}, \quad i = 1, 2, \dots, m; k = 1, 2, \dots, n.$$

- 我们仍以  $x_{ik}$  表示规范化的  $x'_{ik}$ , 并将规范的样本矩阵仍然记为  $\mathbf{X}$ , 此时样本协方差矩阵

$$\mathbf{S} = \mathbf{R} = \frac{1}{n-1} \mathbf{X} \mathbf{X}^T$$

- 我们设  $\mathbf{R}$  的特征值为  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ ,  $\alpha_i$  为  $\mathbf{R}$  的属于  $\lambda_i$  的单位特征向量, 则样本主成分变换为

$$\mathbf{y} = \mathbf{A}^T \mathbf{x},$$

这里  $\mathbf{A} = [\alpha_1, \alpha_2, \dots, \alpha_m]$ .

- $n$ 个样本  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$  的第  $j$  主成分的行向量为

$$(y_{j1}, \dots, y_{jn}) = \alpha_j^T \mathbf{X}$$

- 样本前  $k$  主成分矩阵为

$$\mathbf{Y}_{k \times n} = [\alpha_1, \dots, \alpha_k]^T \mathbf{X}$$

基于以上的分析，我们可以

- 求出  $R$  的特征值为  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ ;
- 确定使得累计方差贡献率达到预定值的主成分个数  $k$ ;
- 求出前  $k$  个特征值  $\lambda_i$  对应的单位特征向量  $\alpha_i$ ;
- 求  $k$  个样本主成分

$$y_i = \alpha_i^T x$$

- 计算  $\rho(y_j, x_i)$  以及  $\nu_{1 \rightarrow k}(i)$ ;
- 计算样本前  $k$  主成分矩阵.

# 奇异值分解与主成分分析

- 定义一个新的数据矩阵

$$\mathbf{X}' = \frac{1}{\sqrt{n-1}} \mathbf{X}^T$$

则

$$(\mathbf{X}')^T \mathbf{X}' = \frac{1}{n-1} \mathbf{X} \mathbf{X}^T = R = S$$

- $\mathbf{X}'$  的右奇异向量就是  $S = (\mathbf{X}')^T \mathbf{X}'$  的单位特征向量.

# 主成分分析算法

输入：规范化的样本矩阵  $\mathbf{X}_{m \times n}$

输出：样本主成分矩阵  $\mathbf{Y}_{k \times n}$

参数：主成分个数  $k$

(1) 构造

$$\mathbf{X}' = \frac{1}{\sqrt{n-1}} \mathbf{X}^T$$

(2) 求  $\mathbf{X}'$  的  $k$  秩截断奇异值分解

$$U\Sigma V^T$$

(3) 样本前  $k$  主成分矩阵为

$$\mathbf{Y}_{k \times n} = V^T \mathbf{X}$$

# 主成分分析小结

- 标准线性组合
- 总体主成分变换
- 总体主成分性质
- 方差贡献率
- 因子负荷量
- 规范化数据
- 样本主成分分析