

## Part I

# PCA

### 1 线性降维基本原理

**Proposition 1.1.** 给定一个低维的线性空间 $U$ ，一般 $\mathbb{R}^2$ 用于可视化，线性降维本质上都是寻找一个从特征空间 $V$ 到 $U$ 的线性映射 $\varphi: V \rightarrow U$ 。在这个线性映射的作用下，高维空间中的向量可以用坐标表示，从而在平面上展开，并且保留数据的某些特征。

**Theorem 1.1** (PCA主定理). 对于 $n \times 1$ 的 $k$ 个列向量并成的 $n \times k$ 矩阵 $Y$ ，每个坐标轴上的方差和坐标轴之间的协方差用协方差矩阵 $D$ 表示。若列向量矩阵 $Y$ 是中心化的，即每一个坐标轴上的分量总和为0，将 $n \times k$ 矩阵 $Y$ 写成行向量形式：

$$Y = \begin{pmatrix} \vec{\alpha}_1 & \vec{\alpha}_2 & \cdots & \vec{\alpha}_k \end{pmatrix}_{n \times k} = \begin{pmatrix} \vec{\gamma}_1 \\ \vec{\gamma}_2 \\ \vdots \\ \vec{\gamma}_n \end{pmatrix}_{n \times k}$$

其中每一个 $\vec{\gamma}_i$ 的所有分量之和为0（中心化条件），两个行向量之间的协方差满足

$$\text{cov}(\gamma_i, \gamma_j) = \begin{cases} \text{var}(\gamma_i) = \frac{1}{k} \sum_{t=1}^k (a_{it} - 0)^2 = \frac{1}{k} \gamma_i \gamma_i^t, & i = j \\ \text{cov}(\gamma_i, \gamma_j) = \frac{1}{k} \sum_{t=1}^k (a_{it} - 0)(a_{jt} - 0) = \frac{1}{k} \gamma_i \gamma_j^t, & i \neq j \end{cases}$$

协方差矩阵 $D$ 可用矩阵乘法表示：

$$\begin{aligned} D &= \frac{1}{k} Y Y^t = \frac{1}{k} \begin{pmatrix} \vec{\gamma}_1 \\ \vec{\gamma}_2 \\ \vdots \\ \vec{\gamma}_n \end{pmatrix} \begin{pmatrix} \vec{\gamma}_1^t & \vec{\gamma}_2^t & \cdots & \vec{\gamma}_n^t \end{pmatrix} \\ &= \begin{pmatrix} \text{cov}(\gamma_1, \gamma_1) & \text{cov}(\gamma_1, \gamma_2) & \cdots & \text{cov}(\gamma_1, \gamma_n) \\ \text{cov}(\gamma_2, \gamma_1) & \text{cov}(\gamma_2, \gamma_2) & \cdots & \text{cov}(\gamma_2, \gamma_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(\gamma_n, \gamma_1) & \text{cov}(\gamma_n, \gamma_2) & \cdots & \text{cov}(\gamma_n, \gamma_n) \end{pmatrix} \end{aligned}$$

综上，当降维后的协方差矩阵为对角矩阵，且对角线元素从大到小排列的时候，就实现了我们的目标：在每个坐标轴上，样本尽可能分散，在并且不同的坐标轴之间是线性无关的（正交的），即：

$$\text{cov}(\gamma_i, \gamma_j) = \begin{cases} \text{var}(\gamma_i) & \text{max, } i = j \\ \text{cov}(\gamma_i, \gamma_j) = 0, & i \neq j \end{cases}$$

根据我们的线性降维手段， $Y = AX$ ，带入上述方程：

$$D = \frac{1}{k}YY^t = \frac{1}{k}(AX)(AX)^t = \frac{1}{k}AXX^tA^t = ACA^t$$

其中 $C = \frac{1}{k}XX^t$ 是 $X$ 的协方差矩阵， $D$ 是对角阵。由于实对角阵总可以相似合同对角化，所以这里的 $A$ 取正交矩阵，满足 $A^t = A^{-1}$  若 $C$ 有相似对角化：

$$\begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix} = A_{n \times n}CA^t$$

这里 $ACD$ 都为同形方阵，取前 $m$ 个最大的特征值 $\{\lambda_1 \dots \lambda_m\}$ 构成的对角阵 $D$ ，从而得到取前 $m$ 个坐标的截短的特征向量矩阵 $A_{m \times n}$ ，使得：

$$D = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_m \end{pmatrix} = A_{m \times n}C_{n \times n}A^t$$

从而，对于有 $k$ 个样本点的原始数据矩阵 $X$ ，我们找到了一个 $A$ ，使得结果 $Y = AX$ 满足 $\frac{1}{k}YY^t$ 是对角线元素递减的对角阵。 ■