

9.3.2 最小化重建误差

从低维投影重建（即“编码-解码”）的角度，PCA 的第二种解释是最小化重建的高维数据与原始数据之间的误差。

具体地，记 \mathbb{R}^p 中的一组标准正交基为 $U = \{\mu_1, \mu_2, \dots, \mu_p\}$ ，其满足性质 $\mu_i^\top \mu_j = \mathbb{I}(i=j)$ 。由于这组正交基是完备的，该内积空间中的任意一点 x_n 都可以用它们的线性组合表示 $x_n = \sum_{i=1}^p \alpha_{ni} \mu_i$ ，两边同时左乘 μ_i^\top ，可以得到 $\alpha_{ni} = x_n^\top \mu_i$ ，因此每个数据 x_n 有如下的正交展开：

$$x_n = \sum_{i=1}^p (x_n^\top \mu_i) \mu_i. \quad (9.18)$$

上述表示是准确并没有误差的。降维的目标是将数据投影到 d 维子空间中。这里选取前 d 个正交基向量作为投影方向，构建一个子空间。因为 $d < p$ ，所以这种投影是存在信息丢失的。对于误差项，我们也用一个线性空间表示，即使用剩余的 $p-d$ 维正交基的线性组合表示，同时假设误差项与具体数据无关——这一点与第 3 章介绍的线性回归模型类似。基于此，我们构建了一个误差模型：

$$\tilde{x}_n = \sum_{i=1}^d z_{ni} \mu_i + \sum_{i=d+1}^p b_i \mu_i, \quad (9.19)$$

其中 b_i 为全部数据共享的系数，即误差项。与数据无关的项一般称为“全局项”，相应地，与数据有关的项称为局部项。为了尽量多地保留信息，我们最小化重建数据与原始数据之间的误差，即

$$\min_{U, z, b} J := \frac{1}{N} \sum_{n=1}^N \|x_n - \tilde{x}_n\|^2. \quad (9.20)$$

假设在正交基 U 给定的情况下，通过最优优化损失函数，可得到参数 z 、 b 的解析形式： $z_{ni} = x_n^\top \mu_i$ ($i = 1, 2, \dots, d$)、 $b_i = \bar{x}^\top \mu_i$ ($i = d+1, d+2, \dots, p$)，其中 \bar{x} 为数据的均值。从而重建数据与原始数据的误差可化简为 $x_n - \tilde{x}_n = \sum_{i=d+1}^p \{(x_n - \bar{x})^\top \mu_i\} \mu_i$ ，

可见误差就是数据关于均值的偏移量在被约减的维度上的投影。

代入目标函数，可得 $J = \sum_{n=1}^N \sum_{i=d+1}^p (x_n^\top \mu_i - \bar{x}^\top \mu_i)^2 = \sum_{i=d+1}^p \mu_i^\top S \mu_i$ 。因此，求解

U 简化为最优化问题：

$$\begin{aligned} \min_U J &= \sum_{i=d+1}^p \mu_i^\top S \mu_i \\ \text{s.t. } &\mu_i^\top \mu_j = \mathbb{I}(i=j). \end{aligned} \quad (9.21)$$

该形式我们在 9.3.1 节中已经见过，唯一不同的是这次我们要找误差的最小值，因此要选择特征值较小的 $p-d$ 个特征向量作为被约减的维度。于是，用作投影映射的前