


现有 $X: n \times p$, n 是观测值的个数, p 是 features 个数. X 可以看成 p 维空间的一组点.

问题: 如何在尽可能保留信息的情况下, 把 X 的维度减少?

方案: 把 X 投影到 q 维空间上去, 使这 n 个点到投影点的距离最小.

从 p 维投影到过原点的一条直线上. (红线)



\vec{w} 是红线的 unit vector.

$$OB \text{ 的长度是 } \|\vec{x}_i\| \cdot \cos\theta = \|\vec{x}_i\| \frac{\vec{x}_i \cdot \vec{w}}{\|\vec{x}_i\| \|\vec{w}\|} = \vec{x}_i \cdot \vec{w}$$

OB 的坐标是 $(\vec{x}_i \cdot \vec{w}) \vec{w}$

目标: 希望投影过后仍然尽可能保持 \vec{x}_i 的信息. 信息就是长度.

$$\text{目标函数: } \min_{\vec{w}} \frac{1}{n} \sum_{i=1}^n \|\vec{x}_i - (\vec{x}_i \cdot \vec{w}) \vec{w}\|^2$$

$$\begin{aligned} \|\vec{x}_i - (\vec{x}_i \cdot \vec{w}) \vec{w}\|^2 &= \vec{x}_i \cdot \vec{x}_i - 2(\vec{x}_i \cdot \vec{w})^2 + (\vec{x}_i \cdot \vec{w})^2 \vec{w} \cdot \vec{w} \\ &= \vec{x}_i \cdot \vec{x}_i - (\vec{x}_i \cdot \vec{w})^2 \end{aligned}$$

$$\text{MSE}(\vec{w}) = \frac{1}{n} \sum_{i=1}^n \|\vec{x}_i\|^2 - \frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w})^2$$

最小化 MSE, 也即最大化 $\frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w})^2$

$$\frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w})^2 = \left(\frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w}) \right)^2 + \text{Var}(\vec{x}_i \cdot \vec{w})$$

\vec{x}_i 已作标准化, 所以第一项为 0. $\downarrow = \left(\frac{1}{n} \sum_{i=1}^n \vec{x}_i \right) \cdot \vec{w}$
 中心化, x 均值为 0. $\frac{1}{n} \sum_{i=1}^n \vec{x}_i = 0, \forall x^j \in \{x^1, x^2, \dots, x^p\}$

若投影到 q 维空间

$\sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j) \vec{w}_j$, w_j 是 q 维子空间的标准正交基.
 多维空间中 q 个方向上的和, 与 \vec{x} 的距离
 不希望太大

$$\|\vec{x}_i - \sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j) \vec{w}_j\|^2 = \vec{x}_i \cdot \vec{x}_i - 2 \sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j) \vec{x}_i \cdot \vec{w}_j + \left(\sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j) \vec{w}_j \right) \cdot \left(\sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j) \vec{w}_j \right)$$

$$\star = \left[(\vec{x}_i \cdot \vec{w}_1) \vec{w}_1 + \dots + (\vec{x}_i \cdot \vec{w}_q) \vec{w}_q \right] \cdot \left[(\vec{x}_i \cdot \vec{w}_1) \vec{w}_1 + \dots + (\vec{x}_i \cdot \vec{w}_q) \vec{w}_q \right]$$

$$= (\vec{x}_i \cdot \vec{w}_1)^2 \vec{w}_1 \cdot \vec{w}_1 + (\vec{x}_i \cdot \vec{w}_2)^2 \vec{w}_2 \cdot \vec{w}_2 + \dots + (\vec{x}_i \cdot \vec{w}_q)^2 \vec{w}_q \cdot \vec{w}_q$$

$$= \sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j)^2$$

$$\rightarrow = \vec{x}_i \cdot \vec{x}_i - \sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j)^2$$

最大化 $\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^q (\vec{x}_i \cdot \vec{w}_j)^2 = \sum_{j=1}^q \frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w}_j)^2$

$$= \frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w}_1)^2 + \frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w}_2)^2 + \dots + \frac{1}{n} \sum_{i=1}^n (\vec{x}_i \cdot \vec{w}_q)^2$$

$$= \frac{1}{n} (\sum \vec{w}_j)^T (\sum \vec{w}_j)$$

$$= \frac{1}{n} \vec{w}_j^T \sum \sum \vec{w}_j$$

$$= \vec{w}_j^T \frac{\sum \sum}{n} \vec{w}_j$$

$$= \vec{w}_j^T \text{Var}(\sum) \vec{w}_j$$

约束条件: $\vec{w}_j \cdot \vec{w}_j = 1$.

Lagrange: $\vec{w}_j^T \text{Var}(\sum) \vec{w}_j - \lambda (\vec{w}_j \cdot \vec{w}_j - 1)$

$$\frac{\partial L}{\partial \lambda} : w^T w - 1 = 0$$

$$\frac{\partial L}{\partial w} : 2v\vec{w} - 2\lambda\vec{w} = 0$$

$$\Rightarrow v\vec{w} = \lambda\vec{w}$$

因此 \vec{w} 是 v 的特征向量, λ 是特征值.