

子空间算法

① 主成分分析 (PCA)

设 x_1, x_2, \dots, x_p 为训练样本, 每个 x_i 为 N 维。

寻找一个 $M \times N$ 维矩阵 A , 使 X 变为 AX ; 即将 X 的维度由 N 降到 M 。

PCA 的要求:

$$\textcircled{1} A = \begin{bmatrix} \text{---} a_1 \text{---} \\ \text{---} a_2 \text{---} \\ \vdots \\ \text{---} a_m \text{---} \end{bmatrix} \quad \text{其中 } a_i \text{ 为 } 1 \times N \text{ 维。}$$

$$\textcircled{2} a_i a_j^T = \begin{cases} 1 & i=j \text{ 时} \\ 0 & i \neq j \text{ 时} \end{cases} \quad (\text{正交性})$$

③ 方差最大。

即: ② 寻找 a_1 , 使

$$\sum_{i=1}^p \|a_1 (x_i - \bar{x})\|^2 \text{ 最大。}$$

$$\text{maximize } \sum_{i=1}^p a_1 (x_i - \bar{x}) (x_i - \bar{x})^T a_1^T = a_1 \Sigma a_1^T$$

$$\text{Subject to: } a_1 a_1^T = 1$$

其中 $\Sigma = \sum_{i=1}^p (x_i - \bar{x}) (x_i - \bar{x})^T$ 为协方差矩阵

拉格朗日乘子法:

$$E(a_1) = a_1 \Sigma a_1^T - \lambda (a_1 a_1^T - 1)$$

$$\frac{\partial E}{\partial a_1} = \Sigma a_1^T - \lambda a_1^T = 0 \Rightarrow \Sigma a_1^T = \lambda a_1^T$$

$$\text{而 } a_1 \Sigma a_1^T = a_1 (\lambda a_1^T) = \lambda$$

因此， λ 为 Σ 的最大特征值， a_1^T 为最大特征值对应的特征向量。

② 求 a_2 ， a_2 满足条件为：

$$\text{Maximize } \sum_{i=1}^p \|a_2(x_i - \bar{x})\|^2$$

$$\text{s.t. } \begin{aligned} a_2 a_2^T &= 1 \\ a_2 a_1^T &= 0 \end{aligned}$$

拉格朗日乘子法：

$$E(a_2) = a_2 \Sigma a_2^T - \lambda (a_2 a_2^T - 1) - \beta a_1 a_2^T$$

$$\frac{\partial E(a_2)}{\partial a_2} = \Sigma a_2^T - \lambda a_2^T - \beta a_1^T = 0$$

① 先证明 $\beta = 0$ ，这是因为：

$$(\Sigma a_2^T - \lambda a_2^T - \beta a_1^T)^T = 0$$

$$a_2 \Sigma^T - \lambda a_2 - \beta a_1 = 0$$

又由于 $\Sigma^T = \Sigma$ ，即

$$a_2 \Sigma - \lambda a_2 - \beta a_1 = 0$$

两边乘以 a_1^T ，得：

$$a_2 \underbrace{(\Sigma a_1^T)}_{\lambda_1 a_1^T} - \lambda \underbrace{a_2 a_1^T}_0 - \beta \underbrace{a_1 a_1^T}_1 = 0$$

$$\text{所以 } \lambda_1 a_2 a_1^T - \lambda a_2 a_1^T - \beta = 0$$

因此 $\beta = 0$

$$\frac{\partial E(a_2)}{\partial a_2} = \Sigma a_2^T - \lambda a_2^T = 0$$

因此 λ 为 Σ 的第二大特征值， a_2^T 为 Σ 第二大特征值对应的特征向量。

③ a_3 为 Σ 第三大特征值对应的特征向量，依次类推。

Singular Value Decomposition

$$M = U S V^T$$

$n \times p$ $n \times n$ $n \times p$ $p \times p$

$$\begin{cases} U^T U = I_{n \times n} \\ V^T V = I_{p \times p} \\ S: \text{对角阵} \end{cases}$$

证明: U^T 为 MM^T 的特征向量, V^T 为 $(M^T M)$ 的特征向量。

证明: $MM^T = (USV^T)(USV^T)^T$

$$= US \underline{V^T V} S^T U^T$$
$$= U S^2 U^T \quad (S^2 \text{ 为 } S \text{ 对角线上非零元素平方})$$

则有: $(MM^T)U^T = S^2 U^T$

同理: $M^T M = V S^2 V^T$

则有: $(M^T M)V^T = S^2 V^T$

$$M = \left[\begin{array}{c|c|c|c|c} | & | & | & \cdots & | \\ x_{1-M} & x_{2-M} & x_{3-M} & \cdots & x_{p-M} \\ | & | & | & & | \end{array} \right] \left. \vphantom{\begin{array}{c|c|c|c|c} | & | & | & \cdots & | \end{array}} \right\} n \text{ 维}$$

$$\Sigma = MM^T$$


$n \times n$ $n \times p$ $p \times n$

svd分解: $M = U S V^T$

U^T 为特征向量, S^2 对角线元素为特征值。

Linear Discriminant Analysis

① 举例



② 两类问题:

找一个矩阵 W , 使

$$\tilde{X} = WX,$$

$$\tilde{\mu}_1 = \frac{1}{N_1} \sum_{x \in C_1} \tilde{X} \quad \tilde{\mu}_2 = \frac{1}{N_2} \sum_{x \in C_2} \tilde{X}$$

$$\tilde{S}_1 = \sum_{x \in C_1} (\tilde{x} - \tilde{\mu}_1)^T (\tilde{x} - \tilde{\mu}_1)$$

$$\tilde{S}_2 = \sum_{x \in C_2} (\tilde{x} - \tilde{\mu}_2)^T (\tilde{x} - \tilde{\mu}_2)$$

要使 $\frac{\|\tilde{\mu}_1 - \tilde{\mu}_2\|^2}{\tilde{S}_1^2 + \tilde{S}_2^2}$ 最大。

$$\|\tilde{\mu}_1 - \tilde{\mu}_2\|^2 = W[(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T]W^T$$

$$\text{其中 } \mu_1 = \frac{1}{N_1} \sum_{x \in C_1} X \quad \mu_2 = \frac{1}{N_2} \sum_{x \in C_2} X$$

$$\tilde{S}_1^2 = W \left[\sum_{x \in C_1} (x - \mu_1)(x - \mu_1)^T \right] W^T$$

$$\tilde{S}_2^2 = W \left[\sum_{x \in C_2} (x - \mu_2)(x - \mu_2)^T \right] W^T$$

$$\frac{\tilde{S}_1^2 + \tilde{S}_2^2}{\tilde{S}_1^2 + \tilde{S}_2^2} = 1$$

$$\text{设 } S_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T$$

$$S_W = \sum_{x \in C_1} (x - \mu_1)(x - \mu_1)^T + \sum_{x \in C_2} (x - \mu_2)(x - \mu_2)^T$$

则有:

$$\text{最大化: } E(W) = \frac{WS_B W^T}{WS_W W^T}$$

$$\frac{\partial E(W)}{\partial W} = 0 \Rightarrow$$

$$WS_W W^T \cdot S_B W^T - WS_B W^T \cdot S_W W^T = 0$$
$$S_B W^T - \left(\frac{WS_B W^T}{WS_W W^T} \right) S_W W^T = 0$$

$$S_B W^T - C S_W W^T = 0$$

$$S_B W^T = C S_W W^T$$

$$(S_W^{-1} S_B) W^T = C W^T$$

$$W^* \propto S_W^{-1} (\mu_1 - \mu_2)$$

③ 多类问题

如果有 C 类, 则我们要找 $C-1$ 个方向。

$$S_i = \sum_{x \in c_i} (x - \mu_i)(x - \mu_i)^T$$

$$S_W = \sum_{i=1}^C S_i$$

$$S_B = \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (\text{秩 } C-1)$$

$$\text{最大化 } \frac{|W^T S_B W|}{|W^T S_W W|} \quad (Y = W^T X)$$

$$(S_W^{-1} S_B) w_i^* = \lambda_i w_i^*$$

最多只有 $C-1$ 个非零特征值。