



厦门大学信息学院 本科选修课

2021-2022 第二学期

模式识别

Pattern Recognition

主讲：王程




3 判别函数

3.6 可训练的确定性分类器的迭代算法

3.7 Fisher线性判别

3.5 感知器算法

已知一个班a级所有同学的身高和体重数据，学号为{0,2,3,4,7}的同学为男生，学号为{1,5,6,8,9}的同学为女生，如何分开两类数据




| 学号 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|---------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 身高 (cm) | 174 | 155 | 175 | 180 | 185 | 153 | 158 | 176 | 160 | 159 |
| 体重 (kg) | 68 | 48 | 69 | 86 | 90 | 42 | 48 | 80 | 46 | 45 |

3.6 可训练的确定性分类器迭代算法

对于每一样本引入类别标签 $t_n = \{+1, -1\}$, $N = 1, 2, \dots, N$

如果 $x_n \in \omega_1$, 则 $t_n = +1$;

如果 $x_n \in \omega_2$, 则 $t_n = -1$



| 学号 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|---------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 身高 (cm) | 174 | 155 | 175 | 180 | 185 | 153 | 158 | 176 | 160 | 159 |
| 体重 (kg) | 68 | 48 | 69 | 86 | 90 | 42 | 48 | 80 | 46 | 45 |
| 标签 | +1 | -1 | +1 | +1 | +1 | -1 | -1 | +1 | -1 | -1 |

3.6 可训练的确定性分类器迭代算法

感知器算法和梯度法的关系：

$t_n \mathbf{w}^T \mathbf{x}_n > 0$ 样本分类正确

$t_n \mathbf{w}^T \mathbf{x}_n \leq 0$ 样本分类错误

$$\mathbf{w} = (0.0875 \ 1.0345 \ , \ -74.9995 \)^T$$

$$g(\mathbf{x}_n) = \mathbf{w}^T \mathbf{x}_n \begin{matrix} > 0 \\ < 0 \end{matrix} \quad \mathbf{x}_n \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

| 学号 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|------------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 身高 (cm) | 174 | 155 | 175 | 180 | 185 | 153 | 158 | 176 | 160 | 159 |
| 体重 (kg) | 68 | 48 | 69 | 86 | 90 | 42 | 48 | 80 | 46 | 45 |
| 标签 | +1 | -1 | +1 | +1 | +1 | -1 | -1 | +1 | -1 | -1 |

3.6 可训练的确定性分类器迭代算法

感知器算法是梯度法的特殊情况，设准则函数为：

$$J(\mathbf{w}) = \sum_{n=1}^N J_n(\mathbf{w}) = \sum_{n=1}^N \frac{|t_n \mathbf{w}^T \mathbf{x}_n| - t_n \mathbf{w}^T \mathbf{x}_n}{2}$$

如何求解目标函数 $J(\mathbf{w})$ 取得极小值时候的权向量 \mathbf{w} ?

$t_n \mathbf{w}^T \mathbf{x}_n > 0$ 样本分类正确

$t_n \mathbf{w}^T \mathbf{x}_n \leq 0$ 样本分类错误


3.6 可训练的确定性分类器迭代算法

梯度法：

$$\nabla J(\mathbf{w}) = \begin{bmatrix} \frac{\partial J}{\partial w_1} \\ \vdots \\ \frac{\partial J}{\partial w_n} \end{bmatrix}$$

$\nabla J(\mathbf{w})$ 定义为准则函数 $J(\mathbf{w})$ 的梯度方向，它是一个向量。

梯度方向是函数在其自变量增加时最增长率的方向，反之，负梯度方向是函数 J 的最陡下降方向。





3.6 可训练的确定性分类器迭代算法

构造关于权向量的准则函数 $J(w)$, 我们通常需要寻找使得 $J(w)$ 取得极值时对应的权向量最优解 w^* 。

每一步迭代中, 计算:

$$w^{(k+1)} = w^{(k)} - C \nabla J(w) |_{w=w^{(k)}}$$

其中, C 是一个正的比例因子, 作为步长。



3.6 可训练的确定性分类器迭代算法

由 $J_n(\mathbf{w}) = \frac{|t_n \mathbf{w}^T \mathbf{x}_n| - t_n \mathbf{w}^T \mathbf{x}_n}{2}$ 可得:

$$J_n(\mathbf{w}) = \begin{cases} 0 & t_n \mathbf{w}^T \mathbf{x}_n \geq 0 \\ -t_n \mathbf{w}^T \mathbf{x}_n & t_n \mathbf{w}^T \mathbf{x}_n \leq 0 \end{cases}$$

对 $J_n(\mathbf{w})$ 关于 \mathbf{w} 求偏导数可以得到:

$$\nabla J_n(\mathbf{w}) = \frac{\partial J_n(\mathbf{w})}{\partial \mathbf{w}} = \begin{cases} 0 & t_n \mathbf{w}^T \mathbf{x}_n \geq 0 \\ -t_n \mathbf{x}_n & t_n \mathbf{w}^T \mathbf{x}_n \leq 0 \end{cases}$$

3.6 可训练的确定性分类器迭代算法

$$\mathbf{w}^T \mathbf{x}_n = w_1 x_{n1} + w_1 x_{n2} + \cdots + w_1 x_{nD}$$

其中 $\mathbf{w} = (w_1, w_1, \dots, w_1)^T$, $\mathbf{x}_n = (x_{n1}, x_{n2}, \dots, x_{nD})^T$

求 $\mathbf{w}^T \mathbf{x}_n$ 关于 \mathbf{w} 的偏导数

$$\frac{\partial \mathbf{w}^T \mathbf{x}_n}{\partial \mathbf{w}} = \begin{pmatrix} \frac{\partial \mathbf{w}^T \mathbf{x}_n}{\partial w_1} \\ \vdots \\ \frac{\partial \mathbf{w}^T \mathbf{x}_n}{\partial w_D} \end{pmatrix} = \begin{pmatrix} x_{n1} \\ \vdots \\ x_{nD} \end{pmatrix} = \mathbf{x}_n$$

3.6 可训练的确定性分类器迭代算法

根据随机梯度法的迭代规则：

$$\begin{aligned} \mathbf{w}^{(k+1)} &= \mathbf{w}^{(k)} - C \frac{\partial J_n(\mathbf{w})}{\partial \mathbf{w}} \Big|_{\mathbf{w}=\mathbf{w}^{(k)}} \\ &= \begin{cases} \mathbf{w}^{(k)} & t_n \mathbf{w}^{(k)T} \mathbf{x}_n \geq 0 \\ \mathbf{w}^{(k)} + Ct_n \mathbf{x}_n & t_n \mathbf{w}^{(k)T} \mathbf{x}_n \leq 0 \end{cases} \end{aligned}$$

式中， \mathbf{x}_n 为训练的模式样本， k 为第 k 次迭代。

感知器算法是梯度法的特例！

$$\frac{\partial J_n(\mathbf{w})}{\partial \mathbf{w}} = \begin{cases} 0 & t_n \mathbf{w}^T \mathbf{x}_n \geq 0 \\ -t_n \mathbf{x}_n & t_n \mathbf{w}^T \mathbf{x}_n \leq 0 \end{cases}$$

3.6 可训练的确定性分类器迭代算法

感知器方法的**优点**:

简单容易实现。

缺点:

要求全部样本线性可分，当样本不是线性可分时，如果仍然使用感知器算法，则不会收敛。

3.6 可训练的确定性分类器迭代算法

最小平方误差 (LMSE) :

对于两类分类问题相当于求一组线性不等式的解:

$$w^T x_n > 0, \forall x_n \in \omega_1$$

$$w^T x_n < 0, \forall x_n \in \omega_2$$

若引入样本类别标签 $t_n = \{+1, -1\}$, $N = 1, 2, \dots, N$ 可得
对于全部模式都需要满足不等式 $t_n w^T x_n > 0$,


以上用不等式表示为:

$$Xw > 0$$

其中 $X = \begin{bmatrix} t_1 x_1^T \\ \vdots \\ t_N x_N^T \end{bmatrix}$

3.5 感知器算法

已知一个班a级所有同学的身高和体重数据，学号为{0,2,3,4,7}的同学为男生，学号为{1,5,6,8,9}的同学为女生，如何分开两类数据



| 学号 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|---------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 身高 (cm) | 174 | 155 | 175 | 180 | 185 | 153 | 158 | 176 | 160 | 159 |
| 体重 (kg) | 68 | 48 | 69 | 86 | 90 | 42 | 48 | 80 | 46 | 45 |

3.6 可训练的确定性分类器迭代算法

$t_n \mathbf{w}^\top \mathbf{x}_n > 0$ 样本分类正确

$t_n \mathbf{w}^\top \mathbf{x}_n \leq 0$ 样本分类错误

$$\mathbf{w} = (0.0875, 1.0345, -74.9995)^\top$$

$$g(\mathbf{x}_n) = \mathbf{w}^\top \mathbf{x}_n \begin{matrix} > 0 \\ < 0 \end{matrix} \quad \mathbf{x}_n \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

| 学号 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|------------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 身高 (cm) | 174 | 155 | 175 | 180 | 185 | 153 | 158 | 176 | 160 | 159 |
| 体重 (kg) | 68 | 48 | 69 | 86 | 90 | 42 | 48 | 80 | 46 | 45 |
| 标签 | +1 | -1 | +1 | +1 | +1 | -1 | -1 | +1 | -1 | -1 |

$$\mathbf{X} = \begin{bmatrix} t_0 \mathbf{x}_0^\top \\ \vdots \\ t_9 \mathbf{x}_9^\top \end{bmatrix} = \begin{bmatrix} 174, 68 \\ \vdots \\ -159, -45 \end{bmatrix}$$

3.6 可训练的确定性分类器迭代算法

根据以上分析，如令分 $b = (b_1, \dots, b_N)^T$ ，且 b 的所有量均为正值，则 $Xw > 0$ 可写为：

$$Xw = b$$

这里需要同时求解 W 和 b 。一般情况下， $Xw = b$ 属于**超定方程**，只能求得最小二乘解。

3.6 可训练的确定性分类器迭代算法

Hoshen–Kopelman algorithm

如上分析，H-K算法定义准则函数

$$\begin{aligned} J(\mathbf{w}, \mathbf{b}) &= \frac{1}{2} \|\mathbf{X}\mathbf{w} - \mathbf{b}\|^2 \\ &= \frac{1}{2} (\mathbf{X}\mathbf{w} - \mathbf{b})^\top (\mathbf{X}\mathbf{w} - \mathbf{b}) \\ &= \frac{1}{2} \sum_{n=1}^N (\mathbf{w}^\top \mathbf{x}_n - b)^2 \end{aligned}$$

上式为两个数量的方差之和，故名为**最小均方误差 算法**。

Hoshen, J.; Kopelman, R. (15 October 1976). "Percolation and cluster distribution. I. Cluster multiple labeling technique and critical concentration algorithm". *Phys. Rev. B*. **14** (8): 3438–3445. doi:10.1103/PhysRevB.14.3438

3.6 可训练的确定性分类器迭代算法

$$\begin{aligned} J(\mathbf{w}, \mathbf{b}) &= \frac{1}{2} (\mathbf{X}\mathbf{w} - \mathbf{b})^\top (\mathbf{X}\mathbf{w} - \mathbf{b}) \\ &= \frac{1}{2} (\mathbf{w}^\top \mathbf{X}^\top \mathbf{X}\mathbf{w} - \mathbf{w}^\top \mathbf{X}^\top \mathbf{b} - \mathbf{b}^\top \mathbf{X}\mathbf{w} + \mathbf{b}^\top \mathbf{b}) \\ &= \frac{1}{2} (\mathbf{w}^\top \mathbf{X}^\top \mathbf{X}\mathbf{w} - 2\mathbf{w}^\top \mathbf{X}^\top \mathbf{b} + \mathbf{b}^\top \mathbf{b}) \end{aligned}$$

$$\frac{\partial J}{\partial \mathbf{w}} = \mathbf{X}^\top \mathbf{X}\mathbf{w} - \mathbf{X}^\top \mathbf{b}$$

3.6 可训练的确定性分类器迭代算法

$$\mathbf{w}^T \mathbf{A} \mathbf{w} = \sum_{i=1}^D \sum_{j=1}^D a_{ij} w_i w_j$$

其中 $\mathbf{w} = (w_1, w_2, \dots, w_D)^T$, $\mathbf{A} = \begin{pmatrix} a_{11} & \cdots & a_{1D} \\ \vdots & \ddots & \vdots \\ a_{D1} & \cdots & a_{DD} \end{pmatrix}$

求 $\mathbf{w}^T \mathbf{A} \mathbf{w}$ 关于 \mathbf{w} 的偏导数

$$\frac{\partial \mathbf{w}^T \mathbf{A} \mathbf{w}}{\partial \mathbf{w}} = \begin{pmatrix} \frac{\partial \mathbf{w}^T \mathbf{A} \mathbf{w}}{\partial w_1} \\ \vdots \\ \frac{\partial \mathbf{w}^T \mathbf{A} \mathbf{w}}{\partial w_D} \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^D (a_{1j} + a_{j1}) w_j \\ \vdots \\ \sum_{j=1}^D (a_{Dj} + a_{jD}) w_j \end{pmatrix} = (\mathbf{A} + \mathbf{A}^T) \mathbf{w}$$

3.6 可训练的确定性分类器迭代算法

使函数 J 同时对 w 和 b 求最小, 对于 w 的梯度为:

$$\frac{\partial J}{\partial w} = X^T(Xw - b)$$

$$\text{令 } \frac{\partial J}{\partial w} = 0, \text{ 得 } X^T(Xw - b) = 0$$

$$w = (X^T X)^{-1} X^T b = X^\# b$$

式中 $X^\# = (X^T X)^{-1} X^T$ 称为 X 的**伪逆**。

3.6 可训练的确定性分类器迭代算法

利用梯度法求解**b**的迭代式为：

$$\mathbf{b}^{(k+1)} = \mathbf{b}^{(k)} - C \frac{\partial J}{\partial \mathbf{b}} \Big|_{\mathbf{b}=\mathbf{b}^{(k)}}$$

为了保证每次迭代中的为 **$\mathbf{b}^{(k)}$** 正值，应使 $\frac{\partial J}{\partial \mathbf{b}} \Big|_{\mathbf{b}=\mathbf{b}^{(k)}}$ 为负值。

因为：

$$\frac{\partial J}{\partial \mathbf{b}} = -(\mathbf{X}\mathbf{w} - \mathbf{b})$$

为保证为 **$\mathbf{b}^{(k+1)}$** 正数，故令：

$$\frac{\partial J}{\partial \mathbf{b}} = -\frac{1}{2} [(\mathbf{X}\mathbf{w} - \mathbf{b}) + |\mathbf{X}\mathbf{w} - \mathbf{b}|]$$

3.6 可训练的确定性分类器迭代算法

H-K算法流程:

已知 $b^{(0)}$

$$w^{(0)} = (X^T X)^{-1} X^T b^{(0)} = X^\# b^{(0)};$$

...

$$b^{(k)} = b^{(k-1)} - C \left. \frac{\partial J}{\partial b} \right|_{b=b^{(k-1)}}$$

$$w^{(k)} = (X^T X)^{-1} X^T b^{(k)} = X^\# b^{(k)};$$

当 $Xw^{(k)} - b^{(k)} = 0$ **,停止迭代, 有解**

当 $Xw^{(k)} - b^{(k)} > 0$ **,继续迭代, 有解**

当 $Xw^{(k)} - b^{(k)}$ **全部分量停止变为正值, 表明该模式类别线性不可分。**

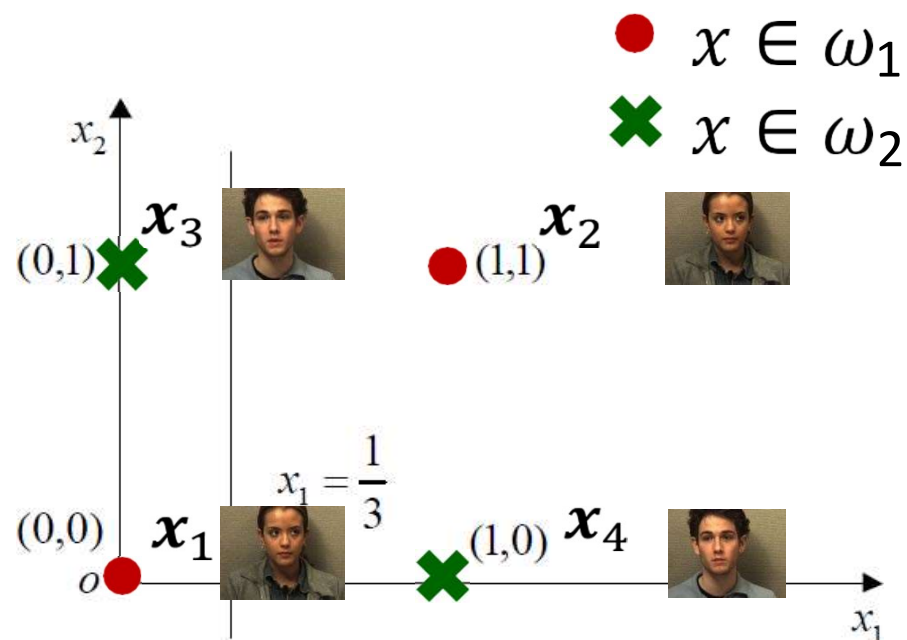
3.6 可训练的确定性分类器迭代算法

例：已知模式样本集：

$$\omega_1: \{(0, 0)^\top, (1, 1)^\top\}$$

$$\omega_2: \{(0, 1)^\top, (1, 0)^\top\}$$

它是线性不可分的。



3.6 可训练的确定性分类器迭代算法

取 $C = 1$ 和 $b^{(0)} = (1, 1, 1, 1)^\top$, 则

$$X = \begin{pmatrix} 0 & 0 & 1 \\ 1 & 1 & 1 \\ 0 & -1 & -1 \\ -1 & 0 & -1 \end{pmatrix}$$

伪逆矩阵为:

$$X^\# = (X^\top X)^{-1} X^\top = \begin{pmatrix} -1 & 1 & 1 & -1 \\ -1 & 1 & -1 & 1 \\ 3 & 1 & 1 & 1 \\ \frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \end{pmatrix}$$

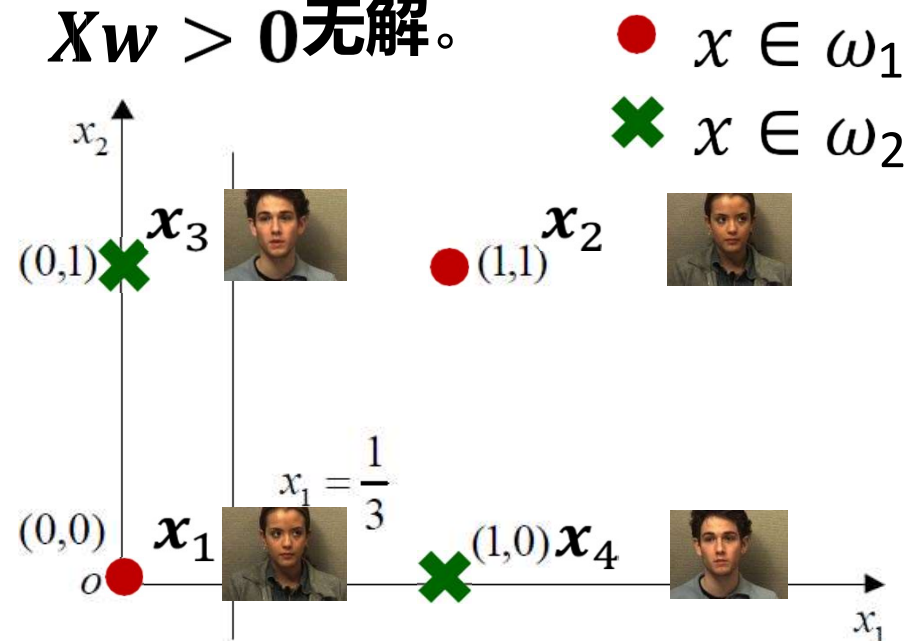
3.6 可训练的确定性分类器迭代算法

$$\mathbf{w}^{(0)} = \mathbf{X}^\# \mathbf{b}^{(0)} = (\mathbf{0}, \mathbf{0}, \mathbf{0})^T$$

$$\mathbf{X}\mathbf{w}^{(0)} - \mathbf{b}^{(0)} = (-1, -1, -1, -1)^T$$

向量 $\mathbf{X}\mathbf{w}^{(0)} - \mathbf{b}^{(0)}$ 的全部分量都为负，

这表示不等式组 $\mathbf{X}\mathbf{w} > \mathbf{0}$ 无解。



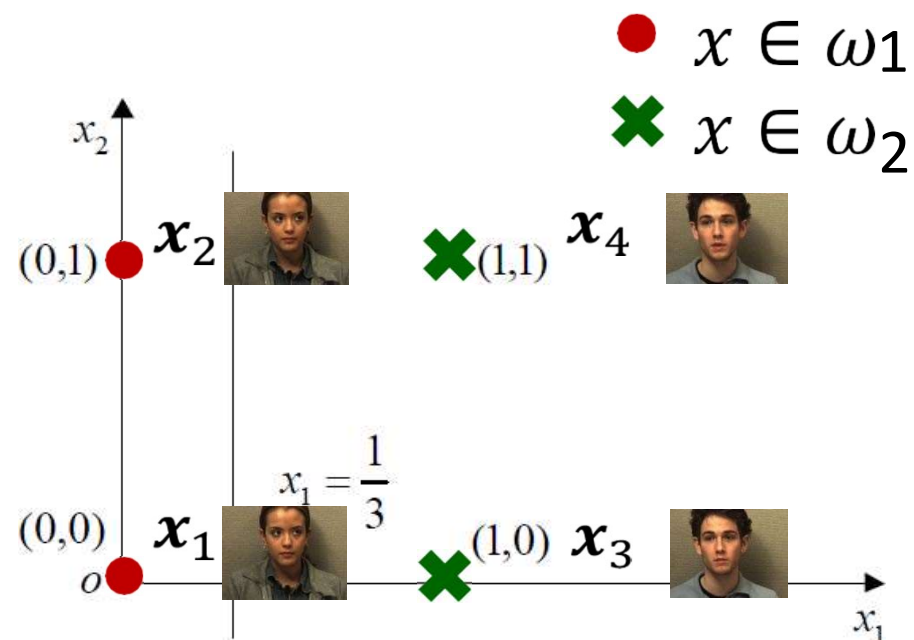
3.6 可训练的确定性分类器迭代算法

例：已知两类样本：

$$\omega_1: \{(0,0)^\top, (0,1)^\top\};$$

$$\omega_2: \{(1,0)^\top, (1,1)^\top\};$$

试计算能区分两类样本的判别界面方程。



3.6 可训练的确定性分类器迭代算法

写出模式的增广矩阵为：

$$X = \begin{pmatrix} 0 & 0 & 1 \\ 1 & 1 & 1 \\ -1 & 0 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

则伪逆为：

$$X^\# = (X^T X)^{-1} X^T = \frac{1}{2} \begin{pmatrix} -1 & -1 & -1 & -1 \\ -1 & 1 & 1 & -1 \\ 3 & 1 & 1 & 1 \\ \frac{3}{2} & \frac{1}{2} & -\frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

3.6 可训练的确定性分类器迭代算法

取 $\mathbf{C}=\mathbf{1}$ 和 $\mathbf{b}^{(0)} = (1, 1, 1, 1)^T$, 则

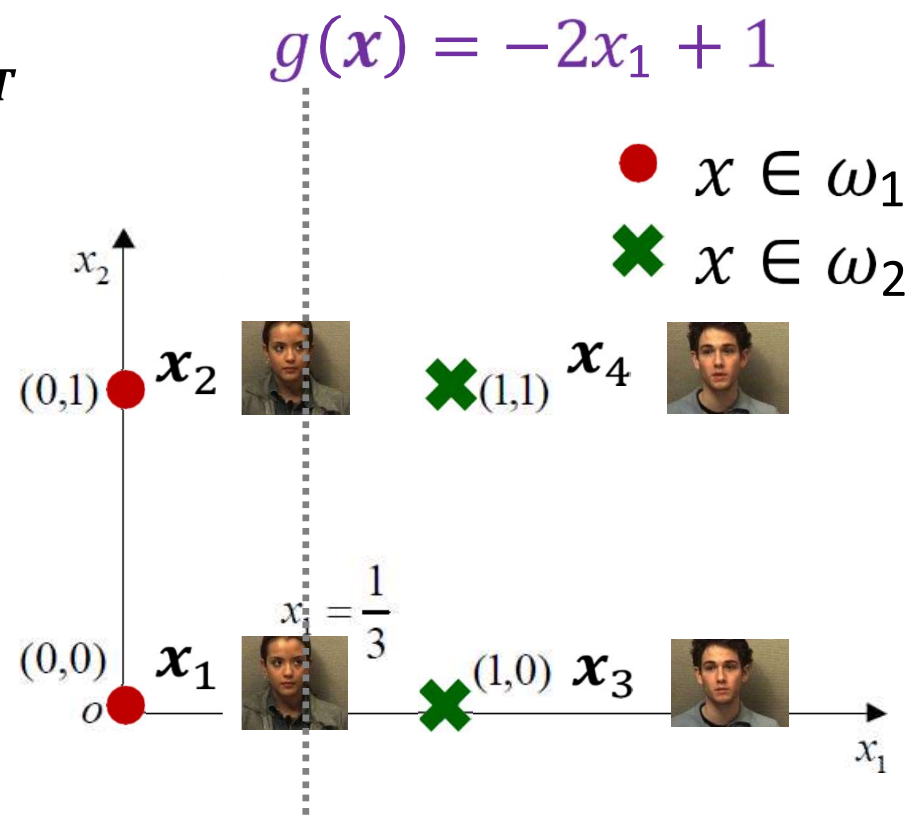
$$\mathbf{w}^{(0)} = \mathbf{X}^\# \mathbf{b}^{(0)} = (-2, 0, 1)^T$$

因 $\mathbf{X}\mathbf{w}^{(0)} = (1, 1, 1, 1)^T$

$$\mathbf{X}\mathbf{w}^{(0)} - \mathbf{b}^{(0)} = (0, 0, 0, 0)^T$$

故

$$\mathbf{w} = \mathbf{w}^{(0)} = (-2, 0, 1)^T$$





3 判别函数

3.6 可训练的确定性分类器的迭代算法

3.7 Fisher线性判别

3.7 Fisher线性判别


Fisher判别法是1936年提出来的，该方法的主要思想是通过将多维数据投影到某个方向上，投影的原则是将总体与总体之间尽可能的分开，然后再选择合适的判别规则，将新的样本进行分类判别。



3.7 Fisher线性判别

假设有样本集 $\{x_1, x_2, \dots, x_N\}$ 以及它们所属类别 ω_1 和 ω_2 ，我们希望寻找一个投影方向 w ，期望对于属于 ω_1 的样本 x_n ，其投影后的值 $w^T x_n > w_0$ ，对于属于 ω_2 的样本 x_n ，其投影后的值 $w^T x_n < w_0$ 。

Fisher线性判别准则同时期望两个类别样本在投影后的类别间隙最大，类内样本尽量集中。



3.7 Fisher线性判别

类别中心:

$$\mu_1 = \frac{1}{N} \sum_{x_n \in \omega_1} x_n$$
$$\mu_2 = \frac{1}{N} \sum_{x_n \in \omega_2} x_n$$

变换后各个模式在投影方向 w 上的均值可以表示为:

$$\mu'_1 = \frac{1}{N_1} \sum_{x_n \in \omega_1} w^T x_n = w^T \mu_1$$
$$\mu'_2 = \frac{1}{N_2} \sum_{x_n \in \omega_2} w^T x_n = w^T \mu_2$$

3.7 Fisher线性判别

类内散度:

$$S'_W = \sum_{x_n \in \omega_1} (w^T x_n - \mu_1)^2 + \sum_{x_n \in \omega_2} (w^T x_n - w^T \mu_2)^2 = w^T S_W w$$

表示同类样本的集中程度。类

内散度矩阵:

$$S_W = \sum_{x_n \in \omega_1} (x_n - \mu_1)(x_n - \mu_1)^T + \sum_{x_n \in \omega_2} (x_n - \mu_2)(x_n - \mu_2)^T$$

3.7 Fisher线性判别

类间散度：

$$\begin{aligned} s'_B &= (\mu'_2 - \mu'_1)^2 \\ &= (\mathbf{w}^T \boldsymbol{\mu}_2 - \mathbf{w}^T \boldsymbol{\mu}_1)^2 = \mathbf{w}^T \mathbf{S}_B \mathbf{w} \end{aligned}$$

表示不同类样本之间的分离程度。

类间散度矩阵：

$$\mathbf{S}_B = (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)(\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)^T$$

根据Fisher 准则的定义，期望类内散度 s_W 越小，类间散度 s_B 越大越好，根据以上准则定义目标函数：

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}}$$

3.7 Fisher线性判别

求解 $J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}}$ 的最大值转化为优化问题：

$$\begin{aligned} \max_{\mathbf{w}} \quad & \mathbf{w}^T \mathbf{S}_B \mathbf{w} \\ \text{s.t.} \quad & \mathbf{w}^T \mathbf{S}_W \mathbf{w} = c \neq 0 \end{aligned}$$

s.t. 表示优化问题中需要满足约束的条件 (subject to的缩写)

聂曼 - 皮尔逊判别准则

拉格朗日乘子法:

假设需要求极值的目标函数(objective function)为, $f(x, y)$, 限制条件为 $\varphi(x, y) = M$

设 $g(x, y) = M - \varphi(x, y)$

定义一个新函数

$$F(x, y, \lambda) = f(x, y) + \lambda g(x, y)$$

则用偏导数方法列出方程:

$$\partial F / \partial x = 0$$

$$\partial F / \partial y = 0$$

$$\partial F / \partial \lambda = 0$$

求出 x, y, λ 的值, 代入即可得到目标函数的极值

聂曼 - 皮尔逊判别准则

扩展为多个变量的式子为：

$$F(x_1, x_2, \dots, \lambda) = f(x_1, x_2, \dots) + \lambda g(x_1, x_2, \dots)$$

则求极值点的方程为

$$\partial F / \partial x_i = 0$$

$$\partial F / \partial \lambda = 0$$

3.7 Fisher线性判别

通过引入拉格朗日乘子转化为以下拉格朗日无约束极值问题:

$$L(\mathbf{w}, \lambda) = \mathbf{w}^T \mathbf{S}_B \mathbf{w} - \lambda(\mathbf{w}^T \mathbf{S}_W \mathbf{w} - c)$$

令导数

可得:
$$\frac{\partial L(\mathbf{w}, \lambda)}{\partial \mathbf{w}} = \mathbf{0}$$

$$\mathbf{S}_B \mathbf{w} - \lambda \mathbf{S}_W \mathbf{w} = \mathbf{0}$$

3.7 Fisher线性判别

可得：

$$S_B \mathbf{w} = \lambda S_W \mathbf{w}$$

假定 S_W 为非奇异，则：



$$S_W^{-1} S_B \mathbf{w} = \lambda \mathbf{w}$$

即最佳投影方向为 $S_W^{-1} S_B$ 的最大特征值对应的特征量。

3.7 Fisher线性判别

取 $w_0 = \frac{1}{2}(w^T \mu_2 + w^T \mu_1)$, 对于任意模式向量 x_n , 计算它在 w 上的投影, 即可判断类别。

$$w^T x_n \begin{cases} > w_0 \\ < w_0 \end{cases}, x_n \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$





3.7 Fisher线性判别

判别规则为:

$$\mathbf{w}^T \mathbf{x}_n \begin{cases} > w_0 \\ < w_0 \end{cases}, \mathbf{x}_n \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

等价于:

$$g(\mathbf{x}_n) = \mathbf{w}^T \mathbf{x}_n - w_0 \begin{cases} > 0 \\ < 0 \end{cases}, \mathbf{x}_n \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$



3.7 Fisher线性判别

有两类样本：

ω_1 : $\{(1, 0)^\top, (-1, 0)^\top, (0, 2)^\top, (0, -2)^\top\}$ 和

ω_2 : $\{(5, 8)^\top, (3, 8)^\top, (4, 10)^\top, (4, 6)^\top\}$,

用Fisher准则进行分类，得到判别规则。

解：计算两个类别的中心 μ_1 和 μ_2 ,

$$\mu_1 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \quad \mu_2 = \begin{pmatrix} 4 \\ 8 \end{pmatrix}$$

3.7 Fisher线性判别

由类内散度矩阵的计算公式

$$S_W = \sum_{x_n \in \omega_1} (x_n - \mu_1)(x_n - \mu_1)^T + \sum_{x_n \in \omega_2} (x_n - \mu_2)(x_n - \mu_2)^T$$

得到

$$S_W = \begin{pmatrix} 4 & 0 \\ 0 & 16 \end{pmatrix}$$

3.7 Fisher线性判别

由类间散度矩阵的计算公式

$$S_B = (\mu_2 - \mu_1)(\mu_2 - \mu_1)^T$$

得到

$$S_B = \begin{pmatrix} 16 & 32 \\ 32 & 64 \end{pmatrix}$$

3.7 Fisher线性判别

根据Fisher准则, 最佳投影方向 w 应该为 $S_W^{-1} S_B$ 的最大值对应的特征向量,

$$S_W^{-1} S_B = \begin{pmatrix} 1/4 & 0 \\ 0 & 1/16 \end{pmatrix} \begin{pmatrix} 16 & 32 \\ 32 & 64 \end{pmatrix} = \begin{pmatrix} 4 & 8 \\ 2 & 4 \end{pmatrix}$$

$S_W^{-1} S_B$ 对应的特征值为

$$\lambda_1 = 8, \lambda_2 = 0,$$

其中较大特征值 λ_1 对应的特征向量为 $\left(\frac{2}{\sqrt{5}}, \frac{1}{\sqrt{5}}\right)^T$, 因此最佳投影方向 $w = \left(\frac{2}{\sqrt{5}}, \frac{1}{\sqrt{5}}\right)^T$

3.7 Fisher线性判别

对于任意样本 x_n , 判别规则为:

$$\mathbf{w}^T x_n \begin{cases} > \\ < \end{cases} w_0, \quad x_n \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

$$w_0 = \frac{1}{2}(\mathbf{w}^T \boldsymbol{\mu}_2 + \mathbf{w}^T \boldsymbol{\mu}_1) = \frac{1}{2} \left(\frac{2}{\sqrt{5}}, \frac{1}{\sqrt{5}} \right)^T \begin{pmatrix} 4 \\ 8 \end{pmatrix} = \frac{8}{\sqrt{5}} \circ$$

3.7 Fisher线性判别



3.7 Fisher线性判别



3.7 Fisher线性判别

1. 计算类内散度矩阵:

$$\begin{aligned} S_W &= \sum_{x_n \in \omega_1} (x_n - \mu_1)(x_n - \mu_1)^T \\ &+ \sum_{x_n \in \omega_2} (x_n - \mu_2)(x_n - \mu_2)^T \end{aligned}$$

2. 计算类间散度矩阵:

$$S_B = (\mu_2 - \mu_1)(\mu_2 - \mu_1)^T$$

3.7 Fisher线性判别



平均脸



平均脸

3.7 Fisher线性判别

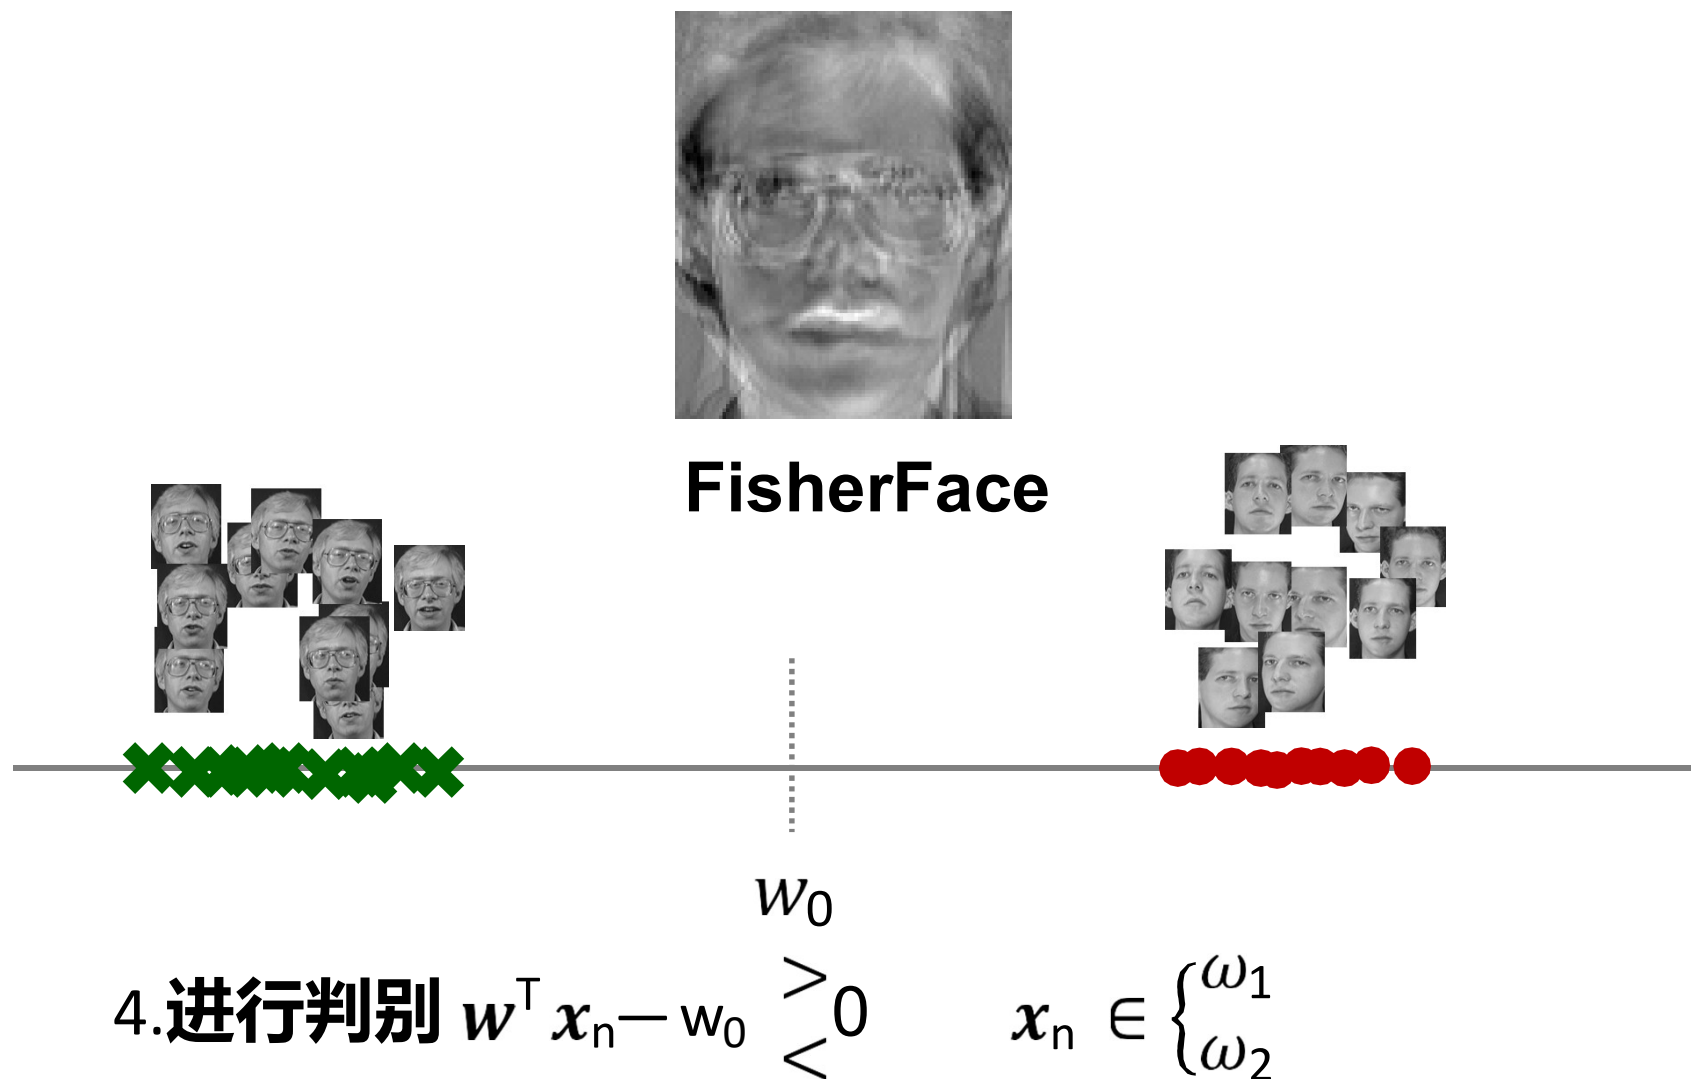
3.求解特征值:

$$S_W^{-1} S_B w = \lambda w$$



FisherFace w

3.7 Fisher线性判别



Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 19, NO. 7, JULY 1997



原始脸



FisherFace



End

