

机器学习

于元隆、朱丹红

福州大学计算机与大数据学院

Email: yu.yuanlong@fzu.edu.cn



- 第二讲 基于距离的分类器

基于距离的分类

- **基于距离的分类**：把测试样本到每个类之间的距离作为判断准则。该技术是最常见的模式识别技术，是其它高级识别技术的基础。


- **判别公式**：

$$\mathbf{x} \in C_i, \text{ if } d(\mathbf{x}, C_i) \leq d(\mathbf{x}, C_j), \forall j \neq i$$

\mathbf{x} : Test pattern (sample)

C_i, C_j : Classes

d : Distance



- 基于距离分类的两个关键因素：

- **类的表达（原型）**
- **距离的衡量**

类的原型


- **类的原型(prototype)**: 用来代表这个类的一个模式或者一组量, 方便计算该原型和测试样本之间的距离。

$$d(\mathbf{x}, C_i) = d(\mathbf{x}, \mathbf{z}_i)$$

where \mathbf{z}_i denotes the prototype of class i .

- **如何学习类的原型?**

- 统计值 (参数化)
- 概率密度估计 (无参数)



- 如果使用类的原型, 则基于距离的判别公式可以写为:

$$\mathbf{x} \in C_i, \text{ if } d(\mathbf{x}, \mathbf{z}_i) \leq d(\mathbf{x}, \mathbf{z}_j), \forall j \neq i$$

where \mathbf{z}_i and \mathbf{z}_j respectively denote the prototypes of class i and j .

类的原型：均值

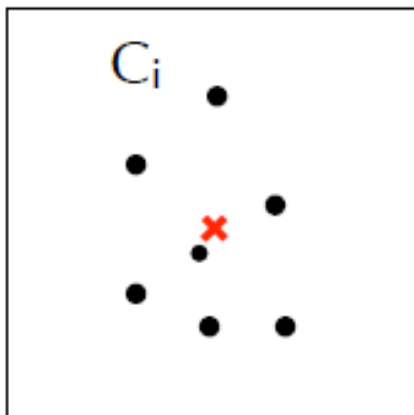
■ 原型的种类：

➤ **均值**：该类中所有训练样本的均值作为类的原型。

✓ 一阶统计

✓ 均值是对类中所有训练样本代表误差最小的一种表达方式

$$\mathbf{z}_i = \mathbf{m}_i = \frac{\sum_{\mathbf{x} \in C_i} \mathbf{x}}{N_i}$$



$$\begin{aligned} e_i &= \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \mathbf{z}_i\|_2^2 \\ &= \sum_{\mathbf{x} \in C_i} (\mathbf{x} - \mathbf{z}_i)^T (\mathbf{x} - \mathbf{z}_i) \end{aligned}$$

为了最小化误差，令其梯度为0，即：

$$\begin{aligned} \frac{\partial \text{err}_i}{\partial \mathbf{z}_i} &= \sum_{\mathbf{x} \in C_i} (\mathbf{x} - \mathbf{z}_i) \\ &= \sum_{\mathbf{x} \in C_i} \mathbf{x} - N_i \mathbf{z}_i = 0 \\ \Rightarrow \mathbf{z}_i &= \frac{\sum_{\mathbf{x} \in C_i} \mathbf{x}}{N_i} \end{aligned}$$

类的原型：概率密度估计

无参数概率密度估计的任务描述

- 在只给定 N 个训练样本，不知道概率分布形式的条件下，在特征空间内学习每个任意取值（模式） x 的概率密度；
- 也就是估计以 x 为中心、在极小的区域 $R = (x, x + \delta x)$ 内的概率密度函数 $p(x)$ 。

类的原型：概率密度估计

一个模式 x 落入区域 R 的概率

- 对于任意一个模式 x ，其落入区域 R 的概率 P 可以表达为：

$$P = \int_{x' \in R} p(x') dx'$$

- 如果区域 R 足够小， P 是 $p(x)$ 的平滑版本，可以用来估计 $p(x)$ 。


类的原型：概率密度估计

k 个样本落在区域 R

- 但是，由于 N 非常大，区域 R 内可能不止落入 x 一个模式！
- 因此， k 个样本落在区域 R 的概率密度可以用二项分布来表达：

$$p(k) = C_N^k P^k (1 - P)^{N - k}$$

注意：二项分布 $p(k)$ 是关于 k 为自变量的分布，描述的是 k 取各种值的可能性。




类的原型：概率密度估计

k 个样本落在区域 R 的概率密度

$$p(k) = C_N^k P^k (1 - P)^{N - k}$$

- 从二项分布的曲线可以看出，当 N 很大时， k 的分布非常尖锐且集中在均值 μ_k 附近。
- 二项分布的均值 μ_k ：

$$E[p(k)] = \mu_k = NP$$



类的原型：概率密度估计

$p(\mathbf{x})$ 的近似估计

- 因此，当 N 非常大时，我们可以用二项分布的均值来近似表达 k 的分布： $k \rightarrow \mu_k$
- 以此得到 P 的近似估计： $k \approx \mu_k = NP \Rightarrow P = \frac{k}{N}$
- 对照刚才对 P 的定义，并假设在极小的区域 R 内概率密度 $p(\mathbf{x})$ 相同。给定区域 R 的体积记作 V 。可以得到 $p(\mathbf{x})$ 的近似估计：

$$P = \int_{\mathbf{x}' \in R} p(\mathbf{x}') d\mathbf{x}' \approx p(\mathbf{x})V \Rightarrow p(\mathbf{x}) \approx \frac{k}{NV}$$


类的原型：概率密度估计

■ 如何确定 V ? $p(\mathbf{x}) \cong \frac{k/n}{V}$


➤ 思路：把 V 当做训练样本的函数。区域 R 以 x 为中心，并不断扩张到可以囊括 k 个训练样本，即 k 是训练样本个数 N 的函数。

- ✓ 如果概率密度在 x 附近很高，则会有较多的训练样本落在 x 附近，则 k 较小；
- ✓ 如果概率密度在 x 附近很低，则会有较少的训练样本落在 x 附近，则 k 较大。

8个训练样本， $k=3$ 、 $k=5$




$k=5$



KNN估计

- K近邻 (k-nearest neighbor, KNN) 估计：
 - ✓ 给定 N 个训练样本和 k 值。
 - ✓ 以任意模式 x 为中心，找到区域 R 使其包含 k 个训练样本。
 - ✓ 第 k 个样本与 x 的距离记作 $d_k(x)$ ，则体积 $V = 2d_k(x)$ 。
 - ✓ 概率密度估计表达为：


$$p(\mathbf{x}) \approx \frac{k}{2Nd_k(\mathbf{x})}$$



类的原型：最近相邻点



- **最近相邻点(nearest neighbor)**: 基于KNN估计, 设置 $k=1$.
 - 从一类的训练样本中, 选取与测试样本距离最近的一个训练样本, 作为该类的原型。类的原型取决于测试样本。
 - ✓ 表达类的误差较大。
 - ✓ 对噪声和异常样本比较敏感。
 - ✓ 实际识别过程:
 - ✓ (1) 选取与测试样本最相邻的训练样本;
 - ✓ (2) 该训练样本所属的类别, 就是测试样本所属的类别。

Choose $\mathbf{z}_i = \mathbf{x}$, if $d(\mathbf{x}, \mathbf{y})$ is minimized $\forall \mathbf{x} \in C_i$
if $\mathbf{x} \in C_i$, then classify \mathbf{y} as C_i



类的原型：K个最近相邻点

- **k个最近相邻点(k-nearest neighbor)**: 基于KNN估计, 设置 $k > 1$.
 - 从一类的模式中, 选取 k 个与测试模式距离最近的模式, 作为该类的原型。
 - 在这 k 个样本中, **投票选出**哪个类别的样本最多, 测试样本就属于这个类。
 - 特点: 部分去除噪声的影响, 但计算量较大。



距离测量

- 欧式距离:

$$d_w(\mathbf{x}, \mathbf{z}) = \sqrt{\sum_{j=1}^d (x_j - z_j)^2} = \sqrt{(\mathbf{x} - \mathbf{z})^T (\mathbf{x} - \mathbf{z})}$$

- Manhattan距离:

$$d(x, z_i) = |x - z_i| = \sum_m |x_m - z_{i,m}|$$

- 距离度量标准(Distance Metric):

- ✓ 1. 同一性: $d(x, z) = 0$, iff $x = z$
- ✓ 2. 非负性: $d(x, z) \geq 0$
- ✓ 3. 对称性: $d(x, z) = d(z, x)$
- ✓ 4. 三角不等式: $d(x, z) \leq d(x, y) + d(y, z)$

加权欧式距离

- **加权欧式距离：**对每个维度特征分别设置不同的权重 w_j

$$d_w(\mathbf{x}, \mathbf{z}) = \sqrt{\sum_{j=1}^d w_j (x_j - z_j)^2} = \sqrt{(\mathbf{x} - \mathbf{z})^T \mathbf{I}_w (\mathbf{x} - \mathbf{z})}$$

where \mathbf{I}_w is a diagonal matrix where each diagonal element is w_j .

MED分类器

■ MED分类器:

- 最小欧式距离分类器(Minimum Euclidean Distance Classifier)

- 给定两个类 C_1 和 C_2 , 以及两个类各自的原型 z_1 和 z_2 , 分类器判别规则如下:


$$\mathbf{x} \in C_1, \text{ if } d(\mathbf{x}, C_1) < d(\mathbf{x}, C_2)$$

$$(\mathbf{x} - \mathbf{z}_1)^T (\mathbf{x} - \mathbf{z}_1) < (\mathbf{x} - \mathbf{z}_2)^T (\mathbf{x} - \mathbf{z}_2)$$

- 类的原型: 通常使用均值, 也可以使用KNN。
- 距离衡量: 欧式距离
- MED分类器也可以用于多类分类。

MED分类器

- MED分类器例子：以均值为类的原型





$$d_E(\underline{y}, \underline{m}_1) < d_E(\underline{y}, \underline{m}_2)$$

classify pattern \underline{y} to class C_1

MED分类器

- 决策边界（分类边界）：通过训练，由分类器判别方程决定的边界。
- 对于2个类而言，MED分类器的**决策边界**是一个超平面，该平面垂直且二分连接两个类原型的线。

MED决策边界方程： $(\mathbf{x} - \mathbf{z}_1)^T (\mathbf{x} - \mathbf{z}_1) = (\mathbf{x} - \mathbf{z}_2)^T (\mathbf{x} - \mathbf{z}_2)$



MED分类器


- 对于2个类而言，MED分类器的决策边界方程为：

$$(\mathbf{x} - \boldsymbol{\mu}_1)^T (\mathbf{x} - \boldsymbol{\mu}_1) - (\mathbf{x} - \boldsymbol{\mu}_2)^T (\mathbf{x} - \boldsymbol{\mu}_2) = 0$$

即 $(\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)^T \left(\mathbf{x} - \frac{\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2}{2} \right) = 0$

关于 \mathbf{x} 的一次函数

MED分类器



- 在高维空间中，该决策边界是一个超平面。
- 且该平面垂直且二分连接两个类原型的线。


MED分类器

- 例题:

$$C_1 = \{(0, 0), (4, 1), (4, -1), (8, 0)\}$$

$$C_2 = \{(4, 2), (8, 3), (8, 1), (12, 2)\}$$

Classify point $(4,3)$ using means as prototypes and MED metric.



- 上页的例题说明，如果使用均值作为类的原型，MED分类器有时候并不能给出满意的分类性能。
- 如何解决这个问题？尝试一下不同的类原型：
 - **最近相邻点：** $(4,2)$ ，所以判断属于C2类
 - **K个最近相邻点：**
 - ✓ K=2: $(4,2)$ 和 $(4,1)$ ，分别属于C2和C1类，无法做出判断。
 - ✓ K=3: $(4,2)$ 、 $(4,1)$ 、 $(8,3)$ 或者 $(4,-1)$ ，第三个最近相邻点有两个，而且分属于不同的类，无法做出判断。
 - ✓ K=4: $(4,2)$ 、 $(4,1)$ 、 $(8,3)$ 或者 $(4,-1)$ ， $(8,1)$ ：无法判断。
 - ✓ K=5: $(4,2)$ 、 $(4,1)$ 、 $(8,3)$ 或者 $(4,-1)$ ， $(8,1)$ ， $(8,0)$ 或者 $(0,0)$ ：无法判断。
 - ✓ K=6: $(4,2)$ 、 $(4,1)$ 、 $(8,3)$ 或者 $(4,-1)$ ， $(8,1)$ ， $(8,0)$ 或者 $(0,0)$ ， $(12,2)$ ：判断属于C2类。

MED分类器

- 上页的例题，为什么使用基于**均值**的MED分类器不能给出正确的分类呢？
- 看一下两个类各自的特征**协方差矩阵**：

$$\text{cov}(C_1) = \begin{bmatrix} 6.1667 & -3.6667 \\ -3.6667 & 3.3333 \end{bmatrix}$$

$$\text{cov}(C_2) = \begin{bmatrix} 10.6667 & 0 \\ 0 & 0.6667 \end{bmatrix}$$

MED分类器

$$\text{cov}(C_1) = \begin{bmatrix} 6.1667 & -3.6667 \\ -3.6667 & 3.3333 \end{bmatrix} \quad \text{cov}(C_2) = \begin{bmatrix} 10.6667 & 0 \\ 0 & 0.6667 \end{bmatrix}$$

- ✓ 对角线元素不相等：每维特征的变化不同。
 - ✓ 非对角元素不为0：特征之间存在相关性。
-
- 解决方法：去除特征变化的不同及特征之间的相关性。

特征正交白化

目的

- 将原始特征映射到一个新的特征空间，使得在新空间中特征的协方差矩阵为单位矩阵，从而去除特征变化的不同及特征之间的相关性。


- 假设映射矩阵为：

$$W = [\mathbf{w}_1^T; \mathbf{w}_2^T; \dots; \mathbf{w}_p^T]$$

其中 \mathbf{w}_i^T 表示新的特征空间的第 i 个坐标轴。

- 转换后的特征 \mathbf{y} 为：


$$\mathbf{y} = W\mathbf{x} = [\mathbf{w}_1^T; \mathbf{w}_2^T; \dots; \mathbf{w}_p^T] \mathbf{x} = \begin{bmatrix} \mathbf{w}_1^T \mathbf{x} \\ \mathbf{w}_2^T \mathbf{x} \\ \vdots \\ \mathbf{w}_p^T \mathbf{x} \end{bmatrix}$$



- 转换后的特征协方差矩阵为:

$$\begin{aligned}\Sigma_y &= cov(\mathbf{y}) = E[(\mathbf{y} - \boldsymbol{\mu}_y)(\mathbf{y} - \boldsymbol{\mu}_y)^T] \\ &= E[W(\mathbf{x} - \boldsymbol{\mu}_x)(\mathbf{x} - \boldsymbol{\mu}_x)^T W^T] \\ &= W\Sigma_x W^T\end{aligned}$$

- 目标: $\Sigma_y = I$



- 将特征转换分为两步：先去除特征之间的相关性（解耦, Decoupling），然后再对特征进行尺度变换（白化, Whitening），使每维特征的方差相等。
- 令 $W = W_2 W_1$
 - ✓ 解耦：通过 W_1 实现协方差矩阵对角化，去除特征之间的**相关性**。
 - ✓ 白化：通过 W_2 对上一步变换后的特征再进行尺度变换，实现所有特征**具有相同方差**。

特征解耦任务

任务

求解转换矩阵 W_1 ，将原始特征构成的协方差矩阵 Σ_x 对角化。

即 $W_1 \Sigma_x W_1^T = \Lambda$ ， Λ 为对角矩阵。

协方差矩阵 Σ_x 的对角化

特征向量与特征值

- 如何得到转换矩阵 W_1 ?
 - ✓ 第一步：求解协方差矩阵 Σ_x 的特征值和特征向量。
 - ✓ 第二步：由特征向量构建转换矩阵 W_1 。
- A 是 $p \times p$ 的矩阵， ϕ 是 R^p 空间的非零向量：
 - ✓ 若 $A\phi = \lambda\phi$ ，则称 ϕ 是 A 的特征向量；
 - ✓ λ 是 ϕ 对应的特征值。

- 特征向量实例:

$$\underline{\phi} = \begin{bmatrix} 1 \\ 2 \end{bmatrix}$$

$$A = \begin{bmatrix} 3 & 0 \\ 8 & -1 \end{bmatrix}$$

$$A\underline{\phi} = \begin{bmatrix} 3 & 0 \\ 8 & -1 \end{bmatrix} \begin{bmatrix} 1 \\ 2 \end{bmatrix} = \begin{bmatrix} 3 \\ 6 \end{bmatrix} = 3\underline{\phi}$$

$\underline{\phi}$ 是 A 的特征向量, 其对应的特征值为 3。

$$A\phi = \lambda\phi \Rightarrow (A - \lambda I)\phi = 0$$

■ 关于特征向量的几点说明：

- ✓ 矩阵 A 是 $(p * p)$ 方阵。若不是方阵，则需做奇异值分解。
- ✓ 每个特征向量的维数： p 维。
- ✓ 如果 A 是实数对称矩阵，则有 p 个特征向量和对应的特征值。

$$A\phi_j = \lambda_j \phi_j \quad (j = 1, \dots, p)$$

特征解耦

- 原始特征协方差矩阵 Σ_x 的特征向量： $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p$
- 原始特征协方差矩阵 Σ_x 的特征值： $\lambda_1, \lambda_2, \dots, \lambda_p$
- **单位化**特征向量： $\phi_j = \frac{\mathbf{v}_j}{\|\mathbf{v}_j\|}$ ($j = 1, \dots, p$)
- 将所有单位化的特征向量组成矩阵 Φ ： $\Phi = [\phi_1, \phi_2, \dots, \phi_p]$

$$\Phi^T \Phi = \begin{bmatrix} \phi_1^T \\ \phi_2^T \\ \vdots \\ \phi_p^T \end{bmatrix} [\phi_1, \phi_2, \dots, \phi_p] \stackrel{?}{=} \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} \Rightarrow \Phi^T = \Phi^{-1}$$

- 由所有特征值组成一个对角矩阵:

$$\Lambda = \begin{bmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_p \end{bmatrix}$$

- 考虑所有特征向量矩阵和所有特征值矩阵相乘:

$$\Phi \Lambda = [\phi_1, \phi_2, \dots, \phi_p] \begin{bmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_p \end{bmatrix} = [\lambda_1 \phi_1 \quad \cdots \quad \lambda_p \phi_p]$$

- 考虑所有特征向量矩阵和协方差矩阵相乘:

$$\begin{aligned} \Sigma_x \Phi &= \Sigma_x [\phi_1, \phi_2, \dots, \phi_p] = [\Sigma_x \phi_1, \dots, \Sigma_x \phi_p] \\ &= [\lambda_1 \phi_1 \quad \cdots \quad \lambda_p \phi_p] \end{aligned}$$

- 因此得到: $\Phi \Lambda = \Sigma_x \Phi \Rightarrow \Phi^T \Sigma_x \Phi = \Lambda$

$$\Phi^T = \Phi^{-1}$$

协方差矩阵
对角化

- 问题：协方差矩阵的不同特征值对应的特征向量间一定**正交**吗？
- 对两个不同的特征向量进行如下点积运算：

$$\left. \begin{aligned} \phi_j^T \Sigma_x \phi_i &= \lambda_i \phi_j^T \phi_i \\ \phi_i^T \Sigma_x \phi_j &= \lambda_j \phi_i^T \phi_j \end{aligned} \right\} \begin{array}{l} \text{两式相减} \\ \longrightarrow \end{array} \phi_j^T \Sigma_x \phi_i - \phi_i^T \Sigma_x \phi_j = (\lambda_i - \lambda_j) \phi_j^T \phi_i$$

由于等式中每项都是一个标量：

$$\Rightarrow \phi_j^T \Sigma_x \phi_i = (\phi_j^T \Sigma_x \phi_i)^T = \phi_i^T \Sigma_x^T \phi_j$$

$$\Rightarrow \phi_i^T \Sigma_x^T \phi_j - \phi_i^T \Sigma_x \phi_j = (\lambda_i - \lambda_j) \phi_j^T \phi_i$$

- 协方差矩阵是**实对称的**，即 $\Sigma_x^T = \Sigma_x$ ：

$$\phi_i^T \Sigma_x^T \phi_j - \phi_i^T \Sigma_x \phi_j = (\lambda_i - \lambda_j) \phi_j^T \phi_i$$

- 上式左边等于0，且 $\lambda_i \neq \lambda_j \Rightarrow \phi_j^T \phi_i = 0$
- 因此不同特征值对应的特征向量**正交**。

- 协方差矩阵能够通过矩阵 Φ 转换为对角阵，即 Σ_x 矩阵被成功对角化了。
- W_1 ： Σ_x 的正交单位化的特征向量组成的矩阵。

$$W_1 = \Phi^T = \begin{bmatrix} \phi_1^T \\ \vdots \\ \phi_p^T \end{bmatrix} \Rightarrow W_1 \Sigma_x W_1^T = \begin{bmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_p \end{bmatrix}$$

转换矩阵 W_1 的特性

- 将原始特征投影到协方差矩阵对应的特征向量上，每一个特征向量构成一个坐标轴。
- 新特征的协方差是对角阵，对角线上的元素由原协方差矩阵的特征值构成。
- 转换前后欧氏距离保持一致，说明 W_1 只是起到**旋转**的作用。

- 证明：原始特征经 W_1 转换后欧式距离不变。


$$\text{令 } \mathbf{z} = W_1 \mathbf{x} = \Phi^T \mathbf{x}$$

$$\begin{aligned} d_E^2(\mathbf{z}_1, \mathbf{z}_2) &= (\mathbf{z}_1 - \mathbf{z}_2)^T (\mathbf{z}_1 - \mathbf{z}_2) \\ &= (\Phi^T (\mathbf{x}_1 - \mathbf{x}_2))^T \Phi^T (\mathbf{x}_1 - \mathbf{x}_2) \\ &= (\mathbf{x}_1 - \mathbf{x}_2)^T \Phi \Phi^T (\mathbf{x}_1 - \mathbf{x}_2) \\ &= (\mathbf{x}_1 - \mathbf{x}_2)^T (\mathbf{x}_1 - \mathbf{x}_2) \\ &= d_E^2(\mathbf{x}_1, \mathbf{x}_2) \end{aligned}$$

■ W_2 的求解:

$$\left. \begin{array}{l} W_1 \Sigma_x W_1^T = \Lambda \\ W_2 \Lambda W_2^T = I \end{array} \right\} \Rightarrow W_2 = \Lambda^{-1/2} \quad \Lambda = \begin{bmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_p \end{bmatrix}$$

■ W 的求解: $W = W_2 W_1 = \Lambda^{-1/2} \Phi^T$



- W 转换后的欧式距离:

$$\begin{aligned}d_E^2(\mathbf{y}_1, \mathbf{y}_2) &= (\mathbf{y}_1 - \mathbf{y}_2)^T (\mathbf{y}_1 - \mathbf{y}_2) \\&= (\Lambda^{-1/2} \Phi^T (\mathbf{x}_1 - \mathbf{x}_2))^T \Lambda^{-1/2} \Phi^T (\mathbf{x}_1 - \mathbf{x}_2) \\&= (\mathbf{x}_1 - \mathbf{x}_2)^T \Phi \Lambda^{-1/2} \Lambda^{-1/2} \Phi^T (\mathbf{x}_1 - \mathbf{x}_2) \\&= (\mathbf{x}_1 - \mathbf{x}_2)^T \Phi \Lambda^{-1} \Phi^T (\mathbf{x}_1 - \mathbf{x}_2) \\&= (\mathbf{x}_1 - \mathbf{x}_2)^T (\Phi \Lambda \Phi^T)^{-1} (\mathbf{x}_1 - \mathbf{x}_2) \\&= (\mathbf{x}_1 - \mathbf{x}_2)^T \Sigma_x^{-1} (\mathbf{x}_1 - \mathbf{x}_2)\end{aligned}$$

$$\begin{aligned}\Phi^T \Sigma_x \Phi &= \Lambda \\ \Rightarrow \Sigma_x &= \Phi \Lambda \Phi^T\end{aligned}$$

- $(\mathbf{x}_1 - \mathbf{x}_2)^T \Sigma_x^{-1} (\mathbf{x}_1 - \mathbf{x}_2)$ 称为**马氏距离**(Mahalanobis Distance)。

MICD距离度量

概念

- 最小类内距离分类器（Minimum Intra-class Distance Classifier），基于马氏距离的分类器。
 - ✓ 距离度量：**马氏距离**；类的原型：**均值**
- 该距离不仅考虑了类的均值对于距离测量的影响，还加入了**类的方差**对于距离测量的影响。

判别公式

$$\mathbf{x} \in C_1, \text{ if } d_M(\mathbf{x}, C_1) < d_M(\mathbf{x}, C_2)$$

$$\text{if } (\mathbf{x} - \boldsymbol{\mu}_1)^T \boldsymbol{\Sigma}_1^{-1} (\mathbf{x} - \boldsymbol{\mu}_1) < (\mathbf{x} - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}_2^{-1} (\mathbf{x} - \boldsymbol{\mu}_2)$$

马氏距离的属性


当 $\Sigma = I$ 时：等于欧式距离

$$\begin{aligned}d_M(\mathbf{x}, C_i) &= (\mathbf{x} - \boldsymbol{\mu}_i) \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \\ &= (\mathbf{x} - \boldsymbol{\mu}_i)^T (\mathbf{x} - \boldsymbol{\mu}_i)\end{aligned}$$

等距面方程：

$$(\mathbf{x} - \boldsymbol{\mu}_i)^T (\mathbf{x} - \boldsymbol{\mu}_i) = c^2$$

半径为 c 的球面。



等距图是一个球面


马氏距离的属性

当 Σ 为对角矩阵时:

$$\begin{aligned}d_M(\mathbf{x}, C_i) &= (\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \\ &= (\mathbf{x} - \boldsymbol{\mu}_i)^T \begin{bmatrix} \frac{1}{\sigma_1^2} & \dots & 0 \\ \vdots & \dots & \vdots \\ 0 & \dots & \frac{1}{\sigma_p^2} \end{bmatrix} (\mathbf{x} - \boldsymbol{\mu}_i) \\ &= \sum_{j=1}^p \left(\frac{x_i - \mu_{ij}}{\sigma_j} \right)^2\end{aligned}$$

等距面方程:


$$\sum_{j=1}^p \left(\frac{x_i - \mu_{ij}}{\sigma_j} \right)^2 = c^2$$



等距图是一个超椭圆面

马氏距离的属性

当 Σ 是任意值时：等距图是一个有方向的超椭圆面。



ϕ ：协方差矩阵 Σ 的特征向量
 λ ：协方差矩阵 Σ 的特征值

MICD分类器的决策边界

对于二类分类而言,

MICD分类器的决策边界位于到两个类的距离相等的面上, 即:

$$(\mathbf{x} - \boldsymbol{\mu}_1)^T \boldsymbol{\Sigma}_1^{-1} (\mathbf{x} - \boldsymbol{\mu}_1) - (\mathbf{x} - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}_2^{-1} (\mathbf{x} - \boldsymbol{\mu}_2) = 0$$

⋮

$$\mathbf{x}^T (\boldsymbol{\Sigma}_1^{-1} - \boldsymbol{\Sigma}_2^{-1}) \mathbf{x} + 2(\boldsymbol{\mu}_2^T \boldsymbol{\Sigma}_2^{-1} - \boldsymbol{\mu}_1^T \boldsymbol{\Sigma}_1^{-1}) \mathbf{x} + \boldsymbol{\mu}_1^T \boldsymbol{\Sigma}_1^{-1} \boldsymbol{\mu}_1 - \boldsymbol{\mu}_2^T \boldsymbol{\Sigma}_2^{-1} \boldsymbol{\mu}_2 = 0$$


当 $\boldsymbol{\Sigma}_1 \neq \boldsymbol{\Sigma}_2$ 时, 关于 \mathbf{x} 的二次函数

MICD分类器的决策边界

当 $\Sigma_1 = \Sigma_2$ 时，决策边界函数可化简为：

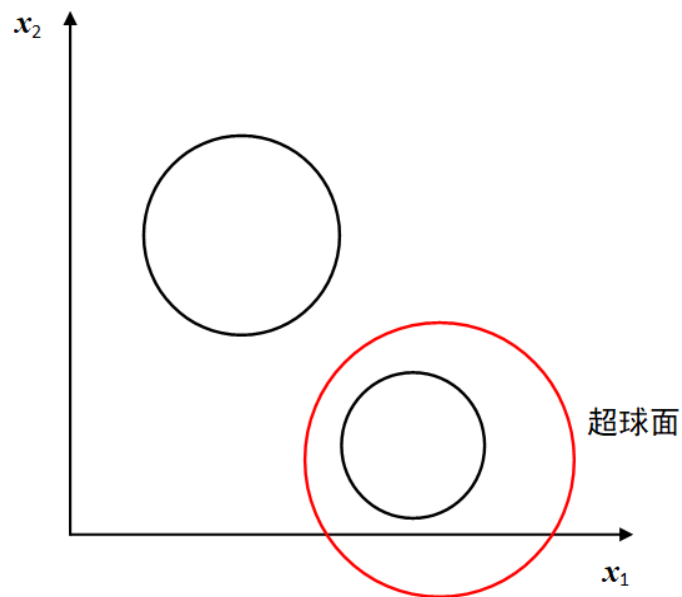
$$(\mu_2 - \mu_1)^T \Sigma^{-1} \left(\mathbf{x} - \frac{\mu_1 + \mu_2}{2} \right) = 0$$

此时决策边界为经过 $\frac{\mu_1 + \mu_2}{2}$ 的超平面。



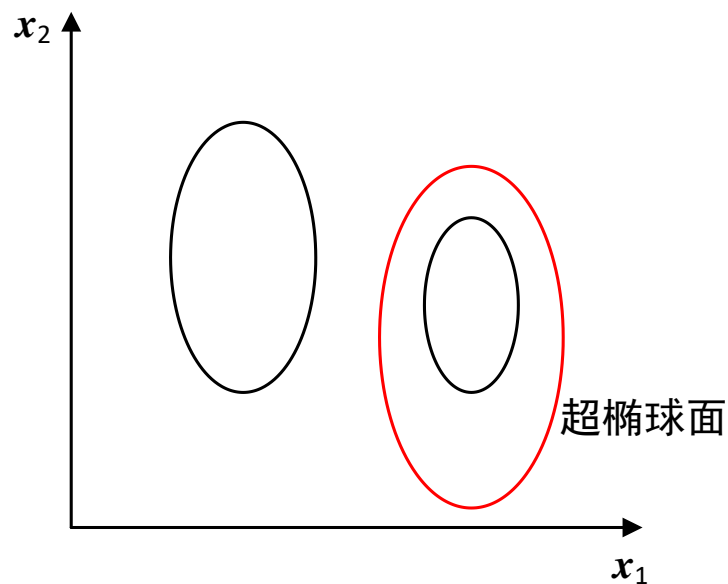
MICD分类器的决策边界

当 $\Sigma_1=c_1I$, $\Sigma_2=c_2I$ 时, 决策边界为超球面。




MICD分类器的决策边界

当 $\Sigma_1 = c\Sigma_2$ 时，决策边界为超椭球面。




MICD分类器的决策边界

当 Σ_1 、 Σ_2 是任意值，决策边界是一个超抛物面或者超双曲面。



超抛物面





超双曲面

MICD分类器的缺陷

- 如下情况，可以看出MICD分类器的一个缺陷。

$$\mu_1 = \mu_2, \Sigma_1 < \Sigma_2 \rightarrow d_M(\mathbf{y}, C_1) > d_M(\mathbf{y}, C_2)$$



$$\text{MICD: } d_M^2(\underline{x}, C_1) > d_M^2(\underline{x}, C_2) \forall \underline{x}$$

MICD分类器会选择方差较大的类