


数字图像处理

第十七讲 目标识别



提纲



- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络

引言



- 识别图像中的各个区域
 - 物体识别 (object recognition)
 - 模式识别 (pattern recognition)
- 物体识别方法
 - 决策论方法
 - 定量描述符: 长度、面积、纹理
 - 结构方法
 - 定性描述符: 关系
- 从样本模式中学习

提纲



- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络



定义

- 模式 (pattern)
 - 描述符的排列 (arrangement)
 - 描述符也被称为特征 (feature)
- 模式类 (pattern class)
 - 具有某些共同属性的一组模式
 - $\omega_1, \omega_2, \dots, \omega_W$
- 基于机器的模式识别
 - 为模式分配对应类的技术
 - 自动完成、尽可能减少人工干预



定义

- 常见的模式排列

- 向量 (vector) , 用于定量描述

- $x = (x_1, x_2, \dots, x_n)^T$

- x_i 表示第*i*个描述符

- n 是描述符的数量

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

- 串 (string) , 用于结构描述

- 树 (tree) , 用于结构描述

向量举例



- 识别三种鸢尾花 (iris)

- 描述符

- 花瓣的长度、宽度

- 模式

- 2维向量

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

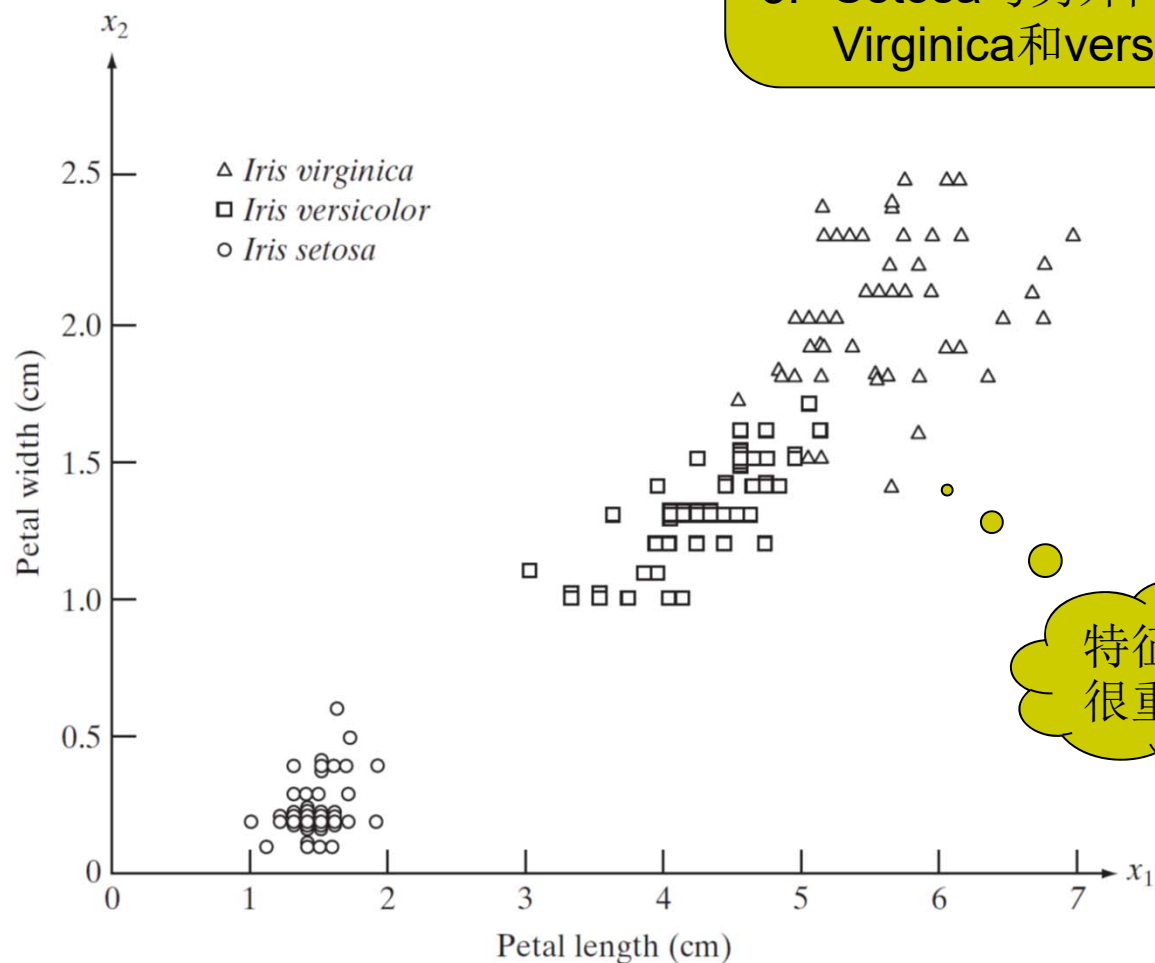
- 模式类

- Iris setosa、 Iris virginica、 Iris versicolor

向量举例

● 识别三种鸢尾花 (iris)

1. 花变成了二维空间内的点/向量
2. 不同类的模式向量不同、同一类内的模式向量也不同
3. *Setosa*与另外两类容易区分, *Virginica*和*versicolor*难以分开

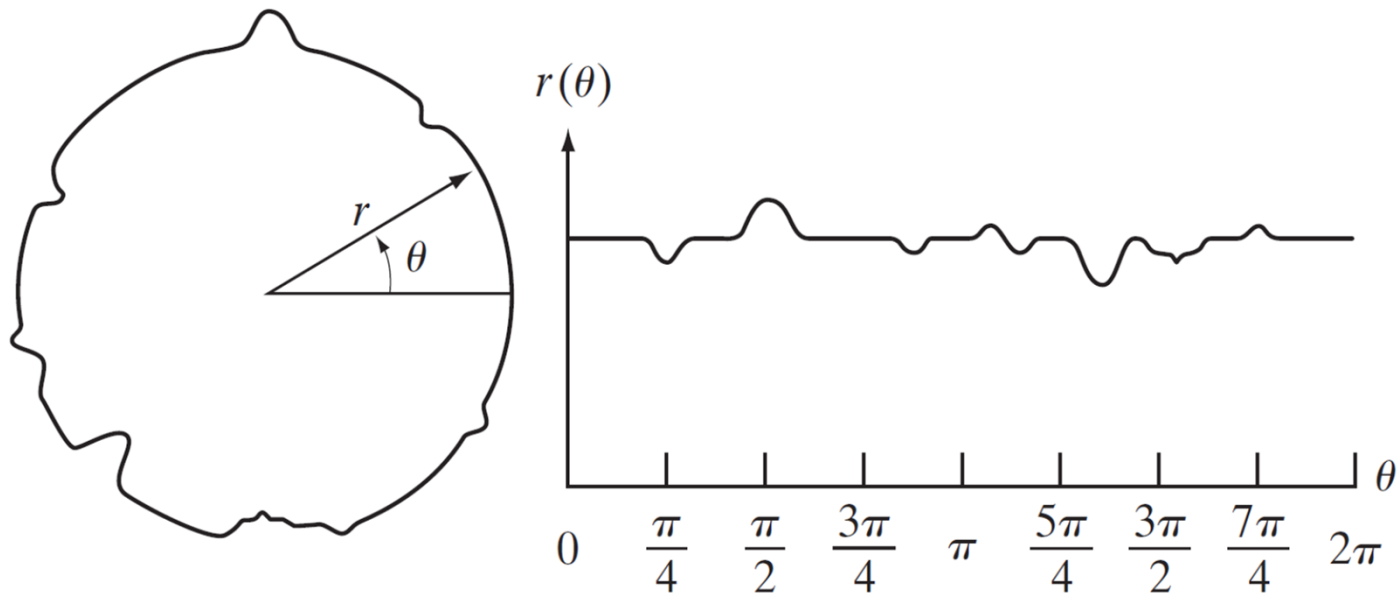


特征选择
很重要

向量举例




- 不同类型的噪声形状
 - 表示成签名 (signature)



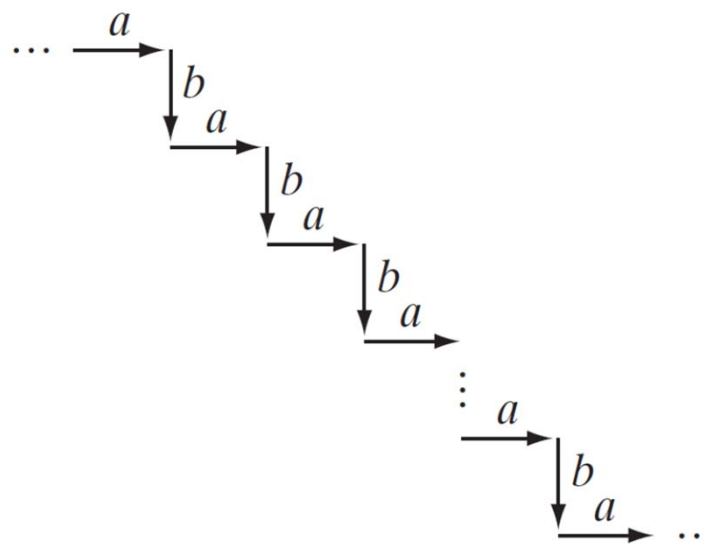

- $x_1 = r(\theta_1), x_2 = r(\theta_2), \dots, x_n = r(\theta_n)$

串举例



- 阶梯模式


- 定义元素 a, b
- $w = \dots abababab \dots$



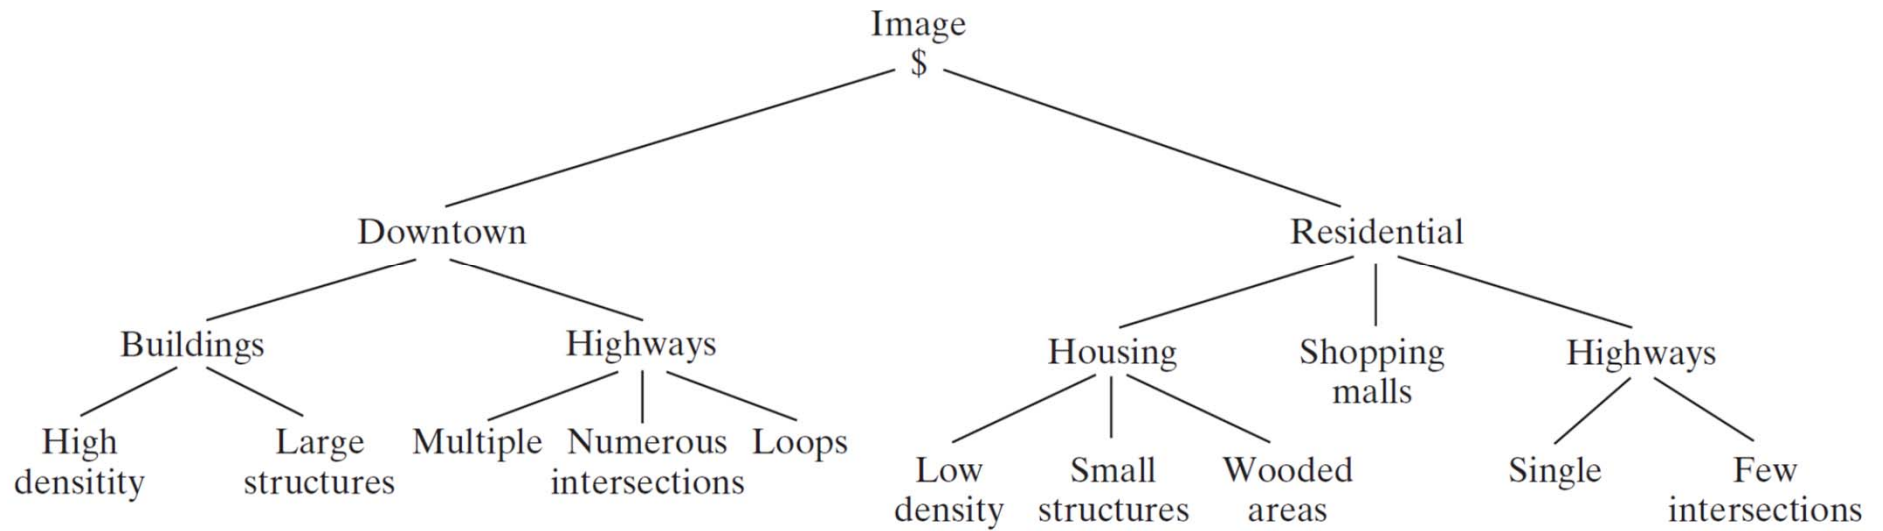
- 首尾相连、交替出现

树举例

- 卫星图片



树举例



提纲



- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络



决策论方法

- 决策论方法 (decision-theoretic methods)

- $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$ 表示 n 维的模式向量

- 存在 W 个模式类 $\omega_1, \omega_2, \dots, \omega_W$

- 构造决策函数 $d_1(\cdot), d_2(\cdot), \dots, d_W(\cdot)$

- 如果 $\mathbf{x} \in \omega_i$, 那么

$$d_i(\mathbf{x}) > d_j(\mathbf{x}) \quad j = 1, 2, \dots, W; j \neq i$$

- ω_i 和 ω_j 之间的决策边界

$$d_i(\mathbf{x}) = d_j(\mathbf{x}) \iff d_i(\mathbf{x}) - d_j(\mathbf{x}) = 0$$



决策论方法

- 决策论方法 (decision-theoretic methods)

- $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$ 表示 n 维的模式向量

- 存在 W 个模式类 $\omega_1, \omega_2, \dots, \omega_W$

- 构造决策函数 $d_1(\cdot), d_2(\cdot), \dots, d_W(\cdot)$

- 如果 $\mathbf{x} \in \omega_i$, 那么

$$d_i(\mathbf{x}) > d_j(\mathbf{x}) \quad j = 1, 2, \dots, W; j \neq i$$

- ω_i 和 ω_j 之间的决策边界

$$d_{ij}(\mathbf{x}) = d_i(\mathbf{x}) - d_j(\mathbf{x}) = 0$$

- $d_{ij}(x) > 0$ 则属于 ω_i ; 反之, 属于 ω_j



提纲

- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络

匹配（ Matching ）



1. 每一个类表示为一个原型模式向量
 2. 一个模式被分配给最近的类
 - 根据预先定义的度量判断远近
-
- 最小距离分类器
 1. 计算给定模式与原型模式向量之间的距离
 2. 选择距离最小的原型模式向量（类）
 - 基于相关的匹配



提纲

- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络



最小距离分类器

1. 把原型定义为每个类的平均向量

$$\mathbf{m}_j = \frac{1}{N_j} \sum_{\mathbf{x}_j \in \omega_j} \mathbf{x}_j, \quad j = 1, \dots, W$$

- N_j 是类别 ω_j 包含的模式数量

2. 利用欧氏距离判断远近

$$D_j(\mathbf{x}) = \|\mathbf{x} - \mathbf{m}_j\| \quad j = 1, 2, \dots, W$$

- $\|\mathbf{a}\| = (\mathbf{a}^T \mathbf{a})^{1/2}$
- 如果 $D_i(\mathbf{x})$ 是最短距离, 那么 $\mathbf{x} \in \omega_i$



最小距离分类器

1. 把原型定义为每个类的平均向量

$$\mathbf{m}_j = \frac{1}{N_j} \sum_{\mathbf{x}_j \in \omega_j} \mathbf{x}_j, \quad j = 1, \dots, W$$


- N_j 是类别 ω_j 包含的模式数量

2. 等价计算方式

$$d_j(\mathbf{x}) = \mathbf{x}^T \mathbf{m}_j - \frac{1}{2} \mathbf{m}_j^T \mathbf{m}_j \quad j = 1, 2, \dots, W$$

- 如果 $d_i(\mathbf{x})$ 是最大值, 那么 $\mathbf{x} \in \omega_i$

最小距离分类器



- ω_i 和 ω_j 之间的决策边界

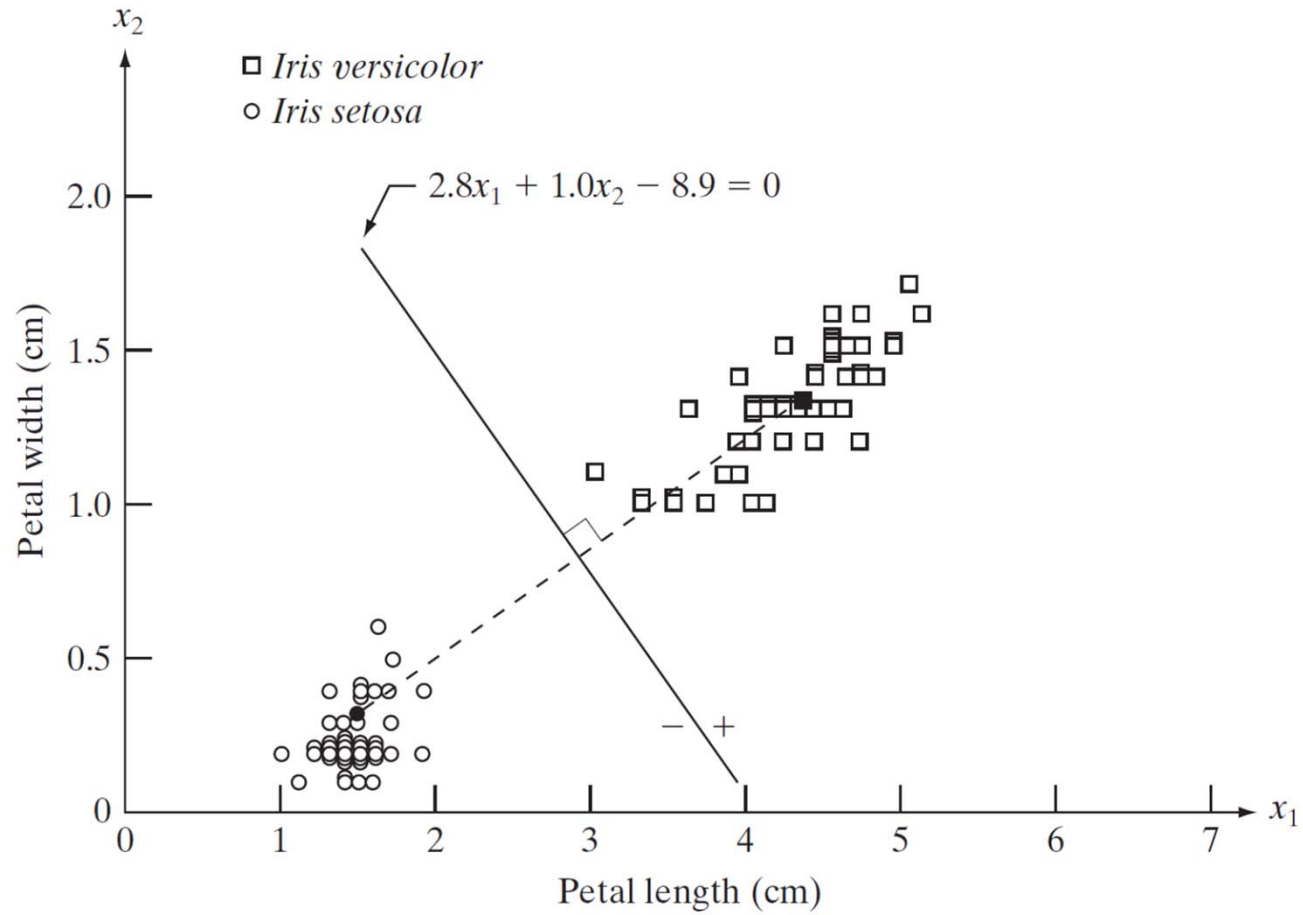
$$\begin{aligned}d_{ij}(\mathbf{x}) &= d_i(\mathbf{x}) - d_j(\mathbf{x}) \\ &= \mathbf{x}^T(\mathbf{m}_i - \mathbf{m}_j) - \frac{1}{2}(\mathbf{m}_i - \mathbf{m}_j)^T(\mathbf{m}_i + \mathbf{m}_j) = 0\end{aligned}$$

- 连接 m_i 和 m_j 线段的垂直平分线 (bisector)
- $n = 2$, 对应于直线
- $n = 3$, 对应于平面
- $n > 3$, 对应于超平面


举例



- 两种鸢尾花



举例



- 两种鸢尾花

- Versicolor和Setosa对应的平均向量

$$\mathbf{m}_1 = (4.3, 1.3)^T \quad \mathbf{m}_2 = (1.5, 0.3)^T$$

- 决策函数

$$\begin{aligned} d_1(\mathbf{x}) &= \mathbf{x}^T \mathbf{m}_1 - \frac{1}{2} \mathbf{m}_1^T \mathbf{m}_1 & d_2(\mathbf{x}) &= \mathbf{x}^T \mathbf{m}_2 - \frac{1}{2} \mathbf{m}_2^T \mathbf{m}_2 \\ &= 4.3x_1 + 1.3x_2 - 10.1 & &= 1.5x_1 + 0.3x_2 - 1.17 \end{aligned}$$

- 决策平面

$$\begin{aligned} d_{12}(\mathbf{x}) &= d_1(\mathbf{x}) - d_2(\mathbf{x}) \\ &= 2.8x_1 + 1.0x_2 - 8.9 = 0 \end{aligned}$$




讨论

- 最小距离分类器的适用场景
 - 类别均值之间的间距大
 - 类内之间的分散程度小
- 实际应用中
 - 未必满足上述条件
- 解决方案
 1. 对数据进行预处理
 - 特征选择、特征抽取
 2. 控制数据的产生过程

举例

- 美国银行字符
 - 磁性油墨打印
- 波形
 - 从右向左扫描
 - 差异很大
- 对波形采样
 - 最小距离分类器





提纲

- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络

基本概念



- 模板 $w(x, y)$ 和图像 $f(x, y)$ 的相关

$$c(x, y) = \sum_s \sum_t w(s, t) f(x + s, y + t)$$

- 求和的界限取 w 和 f 的共同区域
- 考虑所有的位移 (x, y) , 使得 w 的所有元素能访问 f 的每个位置
- 相关定理 (correlation theorem)

$$f(x, y) \star w(x, y) \Leftrightarrow F^*(u, v) W(u, v)$$

- 左边是二维循环相关
- 使用0填充避免缠绕错误

基本概念



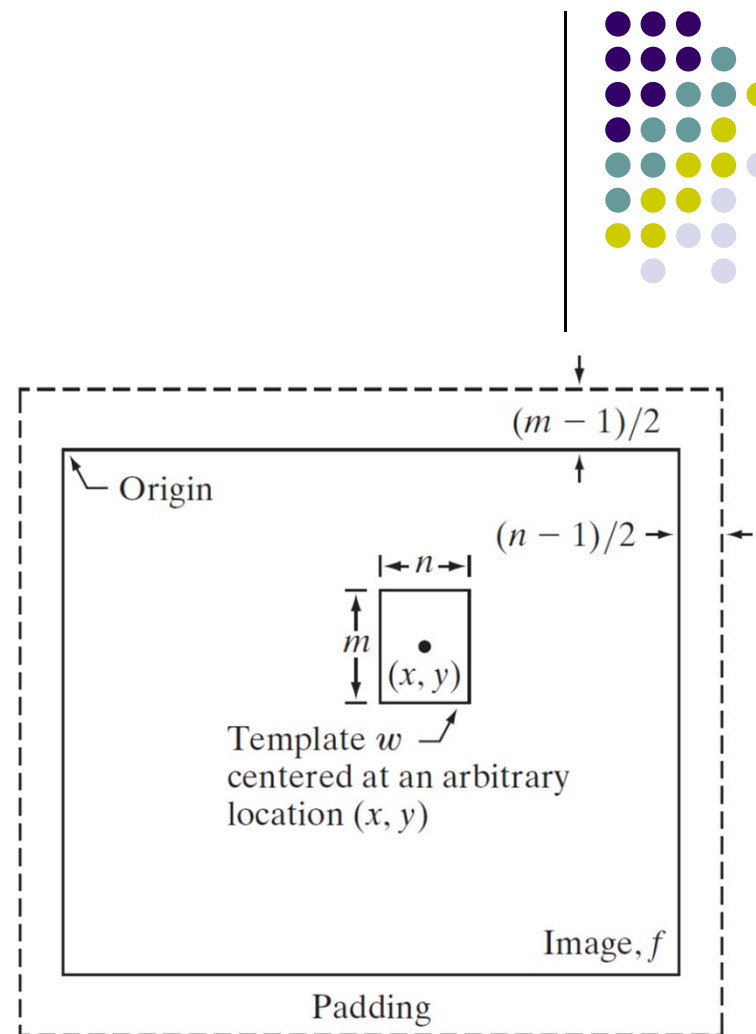
- 归一化相关系数

$$\gamma(x, y) = \frac{\sum_s \sum_t [w(s, t) - \bar{w}] [f(x + s, y + t) - \bar{f}_{xy}]}{\left\{ \sum_s \sum_t [w(s, t) - \bar{w}]^2 \sum_s \sum_t [f(x + s, y + t) - \bar{f}_{xy}]^2 \right\}^{\frac{1}{2}}}$$

- 求和的界限取 w 和 f 的共同区域
- \bar{w} 是模板 w 的均值
- \bar{f}_{xy} 是在 w 覆盖区域的均值
- $\gamma(x, y) \in [-1, 1]$, 其中1表示最大相关
- 相关定理不再成立


基于相关的匹配

1. 对图像四周补零
 - 使模板中心位于图像内
2. 移动模板中心
 - 使模板中心访问图像每一个位置 (x, y)
 - 在当前位置计算归一化相关系数 $\gamma(x, y)$
3. 寻找最大相关
 - 可能存在多个



举例

- 寻找飓风眼




飓风卫星图像




风眼（模板）

举例

- 寻找飓风眼



归一化相关系数



最大相关的位置

提纲



- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络



基础知识

- 把属于 ω_i 的模式预测为属于 ω_j
 - 遭受损失 L_{ij}
- 模式 \mathbf{x} 属于类别 ω_i 的概率记为 $p(\omega_i/\mathbf{x})$
- 预测模式 $\mathbf{x} \in \omega_j$ 的平均损失
 - 条件平均风险 $r_j(\mathbf{x}) = \sum_{k=1}^W L_{kj} p(\omega_k/\mathbf{x})$
 - 贝叶斯公式

$$r_j(\mathbf{x}) = \frac{1}{p(\mathbf{x})} \sum_{k=1}^W L_{kj} p(\mathbf{x}/\omega_k) P(\omega_k)$$

- $p(\mathbf{x}/\omega_k)$ 表示类别的概率密度



基础知识

- 预测模式 $\mathbf{x} \in \omega_j$ 的平均损失
 - 去掉与类别无关的 $1/p(\mathbf{x})$

$$r_j(\mathbf{x}) = \sum_{k=1}^W L_{kj} p(\mathbf{x}/\omega_k) P(\omega_k)$$

- 贝叶斯分类器
 - 最小化平均损失
 - 预测 $\mathbf{x} \in \omega_i$, 如果

$$\sum_{k=1}^W L_{ki} p(\mathbf{x}/\omega_k) P(\omega_k) < \sum_{q=1}^W L_{qj} p(\mathbf{x}/\omega_q) P(\omega_q), \quad \forall j \neq i$$



基础知识

- 0-1损失函数 $L_{ij} = 1 - \delta_{ij}$
 - 预测正确无损失，预测错误损失为1

- 预测模式 $\mathbf{x} \in \omega_j$ 的平均损失

$$\begin{aligned} r_j(\mathbf{x}) &= \sum_{k=1}^W (1 - \delta_{kj}) p(\mathbf{x}/\omega_k) P(\omega_k) \\ &= p(\mathbf{x}) - p(\mathbf{x}/\omega_j) P(\omega_j) \end{aligned}$$

- 贝叶斯分类器

- 预测 $\mathbf{x} \in \omega_i$ ，如果

$$p(\mathbf{x}) - p(\mathbf{x}/\omega_i)P(\omega_i) < p(\mathbf{x}) - p(\mathbf{x}/\omega_j)P(\omega_j), \quad \forall j \neq i$$



基础知识

- 0-1损失函数 $L_{ij} = 1 - \delta_{ij}$
 - 预测正确无损失，预测错误损失为1
- 预测模式 $\mathbf{x} \in \omega_j$ 的平均损失

$$\begin{aligned} r_j(\mathbf{x}) &= \sum_{k=1}^W (1 - \delta_{kj}) p(\mathbf{x}/\omega_k) P(\omega_k) \\ &= p(\mathbf{x}) - p(\mathbf{x}/\omega_j) P(\omega_j) \end{aligned}$$

- 贝叶斯分类器

- 预测 $\mathbf{x} \in \omega_i$ ，如果

决策函数 $d_j(\mathbf{x}) = p(\mathbf{x}/\omega_j) P(\omega_j)$

$$p(\mathbf{x}/\omega_i) P(\omega_i) > p(\mathbf{x}/\omega_j) P(\omega_j), \quad \forall j \neq i$$

讨论



- 贝叶斯分类器
 - 能够最小化平均损失
- 前提条件
 - 每个类 ω_j 出现的概率 $P(\omega_j)$ 已知
 - 从数据中估计，或者直接令 $P(\omega_j) = 1/W$
 - 每个类 ω_j 的概率密度 $p(\mathbf{x}/\omega_j)$ 已知
 - 从数据中估计高维密度函数非常困难
 - 通常假设密度函数为某种解析形式，然后从数据中估计函数参数

针对高斯模式类的贝叶斯分类器



- 假设概率密度 $p(\mathbf{x}/\omega_j)$ 为高斯函数
- 考虑1维空间内的2分类问题
 - $n = 1, W = 2$
 - 决策函数


$$\begin{aligned}d_j(x) &= p(x/\omega_j)P(\omega_j) \\ &= \frac{1}{\sqrt{2\pi}\sigma_j} e^{-\frac{(x-m_j)^2}{2\sigma_j^2}} P(\omega_j) \quad j = 1, 2\end{aligned}$$

- 参数为均值 m_1, m_2 , 标准差 σ_1, σ_2

针对高斯模式类的贝叶斯分类器



- 假设概率密度 $p(\mathbf{x}/\omega_j)$ 为高斯函数
- 考虑1维空间内的2分类问题
 - 假设 $P(\omega_1) = P(\omega_2) = 1/2$, 决策边界为 x_0



针对高斯模式类的贝叶斯分类器



- 考虑 n 维空间内的 W 分类问题
 - 类 ω_j 的概率密度函数

$$p(\mathbf{x}/\omega_j) = \frac{1}{(2\pi)^{n/2} |\mathbf{C}_j|^{1/2}} e^{-\frac{1}{2}(\mathbf{x} - \mathbf{m}_j)^T \mathbf{C}_j^{-1} (\mathbf{x} - \mathbf{m}_j)}$$

- $|\cdot|$ 表示矩阵行列式
- 参数：平均向量、协方差矩阵

$$\mathbf{m}_j = E_j\{\mathbf{x}\} \quad \mathbf{C}_j = E_j\{(\mathbf{x} - \mathbf{m}_j)(\mathbf{x} - \mathbf{m}_j)^T\}$$

- 从数据中估计参数

$$\mathbf{m}_j = \frac{1}{N_j} \sum_{\mathbf{x} \in \omega_j} \mathbf{x} \quad \mathbf{C}_j = \frac{1}{N_j} \sum_{\mathbf{x} \in \omega_j} \mathbf{x}\mathbf{x}^T - \mathbf{m}_j \mathbf{m}_j^T$$

针对高斯模式类的贝叶斯分类器



- 考虑 n 维空间内的 W 分类问题

- 决策函数

$$d_j(x) = p(x/\omega_j)P(\omega_j)$$

决策函数是
超二次曲线

- 决策函数 (等价形式)

$$\begin{aligned} d_j(\mathbf{x}) &= \ln[p(\mathbf{x}/\omega_j)P(\omega_j)] = \ln p(\mathbf{x}/\omega_j) + \ln P(\omega_j) \\ &= \ln P(\omega_j) - \frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |\mathbf{C}_j| - \frac{1}{2} [(\mathbf{x} - \mathbf{m}_j)^T \mathbf{C}_j^{-1} (\mathbf{x} - \mathbf{m}_j)] \end{aligned}$$

- 决策函数 (等价形式)

$$d_j(\mathbf{x}) = \ln P(\omega_j) - \frac{1}{2} \ln |\mathbf{C}_j| - \frac{1}{2} [(\mathbf{x} - \mathbf{m}_j)^T \mathbf{C}_j^{-1} (\mathbf{x} - \mathbf{m}_j)]$$

针对高斯模式类的贝叶斯分类器



- 考虑 n 维空间内的 W 分类问题

- 假设协方差矩阵相同

$$\mathbf{C}_j = \mathbf{C}, \text{ for } j = 1, 2, \dots, W$$

- 决策函数（等价形式）

$$d_j(\mathbf{x}) = \ln P(\omega_j) + \mathbf{x}^T \mathbf{C}^{-1} \mathbf{m}_j - \frac{1}{2} \mathbf{m}_j^T \mathbf{C}^{-1} \mathbf{m}_j$$

- 假设协方差为单位矩阵，不同类别等概率

$$\mathbf{C}_j = \mathbf{I}, P(\omega_j) = 1/W, \text{ for } j = 1, 2, \dots, W$$

- 决策函数（等价形式）


$$d_j(\mathbf{x}) = \mathbf{x}^T \mathbf{m}_j - \frac{1}{2} \mathbf{m}_j^T \mathbf{m}_j \quad j = 1, 2, \dots, W$$

最小距离分类器

举例



- 3维空间内的2分类问题



举例



- 3维空间内的2分类问题

- 估计平均向量

$$\mathbf{m}_1 = \frac{1}{4} \begin{bmatrix} 3 \\ 1 \\ 1 \end{bmatrix} \quad \text{and} \quad \mathbf{m}_2 = \frac{1}{4} \begin{bmatrix} 1 \\ 3 \\ 3 \end{bmatrix}$$

- 估计协方差

$$\mathbf{C}_1 = \mathbf{C}_2 = \frac{1}{16} \begin{bmatrix} 3 & 1 & 1 \\ 1 & 3 & -1 \\ 1 & -1 & 3 \end{bmatrix}$$

- 假设 $P(\omega_1) = P(\omega_2) = 1/2$

- 决策函数

$$d_j(\mathbf{x}) = \mathbf{x}^T \mathbf{C}^{-1} \mathbf{m}_j - \frac{1}{2} \mathbf{m}_j^T \mathbf{C}^{-1} \mathbf{m}_j$$



举例

- 3维空间内的2分类问题
 - 决策函数 (化简)

$$\mathbf{C}^{-1} = \begin{bmatrix} 8 & -4 & -4 \\ -4 & 8 & 4 \\ -4 & 4 & 8 \end{bmatrix}$$

$$d_1(\mathbf{x}) = 4x_1 - 1.5$$

$$d_2(\mathbf{x}) = -4x_1 + 8x_2 + 8x_3 - 5.5$$


- 决策边界

$$d_1(\mathbf{x}) - d_2(\mathbf{x}) = 8x_1 - 8x_2 - 8x_3 + 4 = 0$$

举例







- 多光谱遥感图像



举例

- 像素分三类
 1. 水
 2. 市区
 3. 植被



举例

- 标记数据
 1. 水
 2. 市区
 3. 植被
- 一半用于训练
 - 估计平均向量
 - 估计协方差
 - $P(w_i) = 1/3$
- 一半用于测试




Training Patterns					
Class	No. of Samples	Classified into Class			% Correct
		1	2	3	
1	484	482	2	0	99.6
2	933	0	885	48	94.9
3	483	0	19	464	96.1

Independent Patterns					
Class	No. of Samples	Classified into Class			% Correct
		1	2	3	
1	483	478	3	2	98.9
2	932	0	880	52	94.4
3	482	0	16	466	96.7

举例

黑色表示分错的点




- 标记数据
 1. 水
 2. 市区
 3. 植被
- 一半用于训练
 - 估计平均向量
 - 估计协方差
 - $P(w_i) = 1/3$
- 一半用于测试

Training Patterns					
Class	No. of Samples	Classified into Class			% Correct
		1	2	3	
1	484	482	2	0	99.6
2	933	0	885	48	94.9
3	483	0	19	464	96.1


Independent Patterns					
Class	No. of Samples	Classified into Class			% Correct
		1	2	3	
1	483	478	3	2	98.9
2	932	0	880	52	94.4
3	482	0	16	466	96.7

举例


- 对所有像素分类



白色表示水



白色表示市区



白色表示植被

小结



- 最小距离分类器
 - 由平均向量决定
- 针对高斯模式类的贝叶斯分类器
 - 由平均向量、协方差矩阵决定
- 训练集合 (training set)
 - 用于估计上述参数的模式集合
- 学习 (learning) 或训练 (training)
 - 从训练集合得到决策函数的过程
 - 前面两种方法只需要计算统计量, 相对简单



提纲

- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络

背景知识



- 实际问题的统计性质是未知的
 - 从数据中估计高维密度函数非常困难
 - 假设的密度函数未必符合实际
- 直接从训练数据产生决策函数
 - 避免额外的假设
 - 也被称为判别式方法
 - 神经网络
 - 支持向量机

背景知识



- 神经元 (neurons)
 - 基本的非线性计算单元
- 神经网络 (neural networks)
 - 由神经元组成的网络，模仿大脑神经元的连接
- 发展历史
 - 20世纪40年代初期，出现
 - 20世纪50年代中期至60年代初期，感知机
 - 20世纪80年代，反向传播
 - 21世纪10年代，深度学习



提纲

- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络



针对两类的感知机

- 感知机 (perceptron)

- 线性决策函数

$$d(\mathbf{x}) = \sum_{i=1}^n w_i x_i + w_{n+1}$$

- 权重 w_1, w_2, \dots, w_{n+1}
 - 权重类似于人类神经系统中的突触

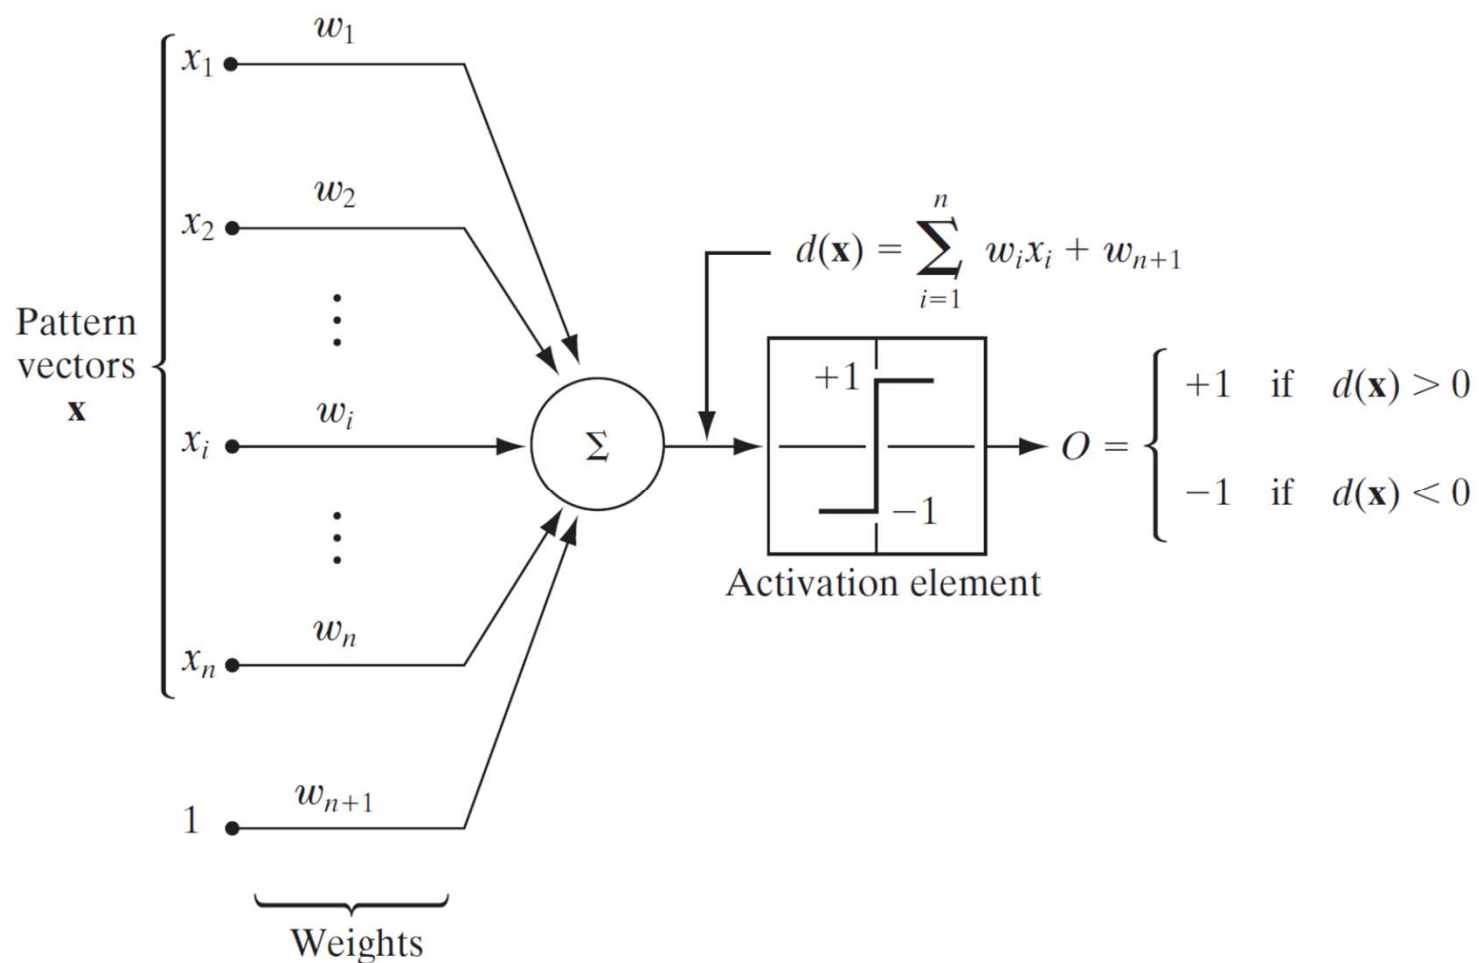
- 激活函数 (activation function)

$$O = \begin{cases} +1 & \text{if } d(\mathbf{x}) > 0 \\ -1 & \text{if } d(\mathbf{x}) < 0 \end{cases}$$

针对两类的感知机



- 感知机 (perceptron)



针对两类的感知机



- 感知机 (perceptron)

- 决策边界

$$d(\mathbf{x}) = \sum_{i=1}^n w_i x_i + w_{n+1} = 0$$

- n 维空间内的超平面

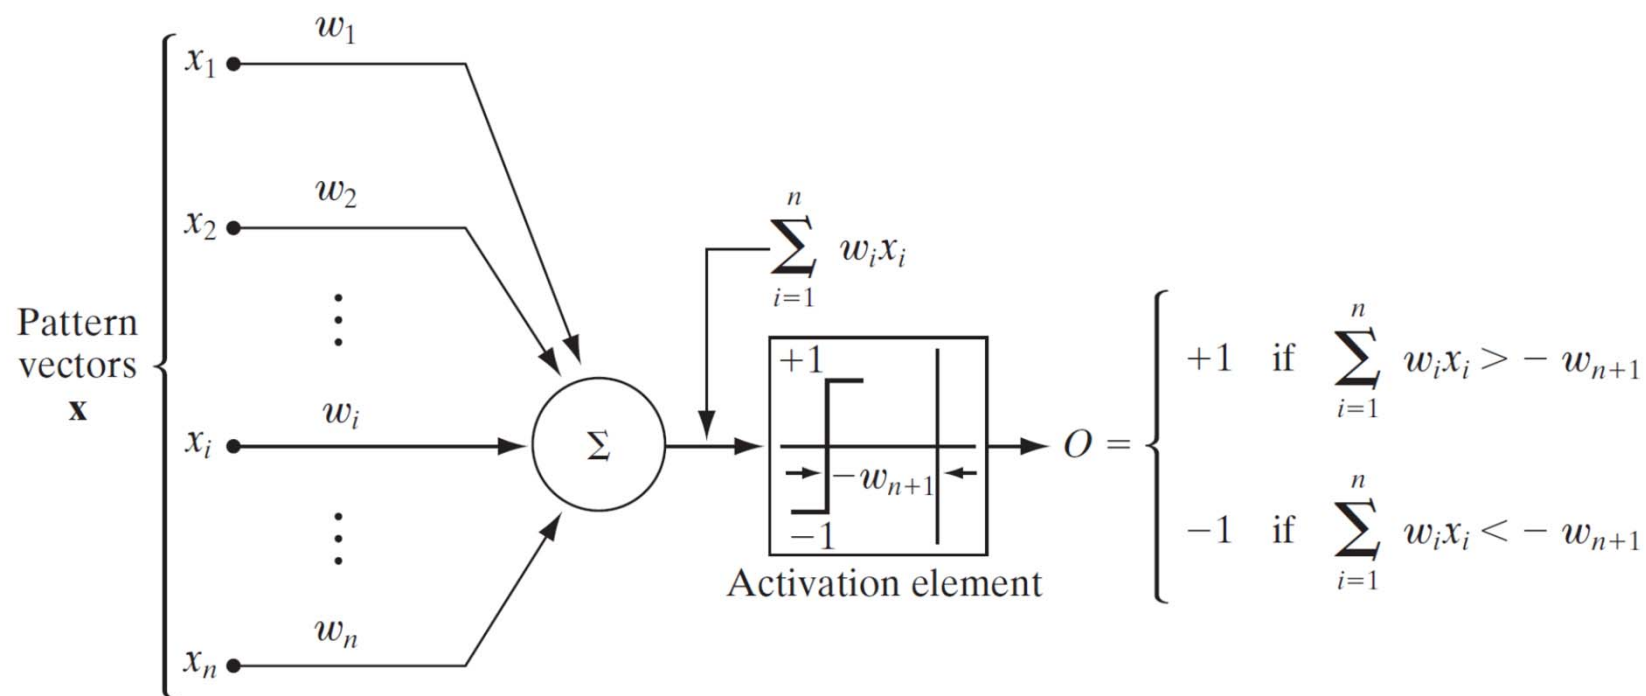
- 激活函数 (等价形式)

$$O = \begin{cases} +1 & \text{if } \sum_{i=1}^n w_i x_i > -w_{n+1} \\ -1 & \text{if } \sum_{i=1}^n w_i x_i < -w_{n+1} \end{cases}$$

针对两类的感知机



- 感知机 (perceptron)



- 不需要常数1输入、阈值函数偏移 $-w_{n+1}$

讨论



- 增广的模式向量

- $\mathbf{y} = [\mathbf{x}; 1] \in \mathbb{R}^{n+1}$

- 线性决策函数

$$\begin{aligned}d(\mathbf{y}) &= \sum_{i=1}^{n+1} w_i y_i \\ &= \mathbf{w}^T \mathbf{y}\end{aligned}$$

- 权重向量 $\mathbf{w} = [w_1, w_2, \dots, w_{n+1}]^T$

- 学习 (learning) 或训练 (training)

- 从训练集合得到权重向量 \mathbf{w}



训练算法

- 线性可分的两个模式类

- 模式向量属于两类 ω_1 、 ω_2
- 模式向量已经被增广
- 权重向量为 \mathbf{w}
- 决策函数

$$d(\mathbf{y}) = \sum_{i=1}^{n+1} w_i y_i = \mathbf{w}^T \mathbf{y}$$

- 预测函数 $\mathbf{y} \in \begin{cases} \omega_1, & \mathbf{w}^T \mathbf{y} \geq 0 \\ \omega_2, & \mathbf{w}^T \mathbf{y} < 0 \end{cases}$

训练算法

- 线性可分的两个模式类

- 令 $\mathbf{w}(1)$ 表示权重的初始值

- $k = 1, 2, \dots$

- 如果 $\mathbf{y}(k) \in \omega_1$ & $\mathbf{w}^T(k)\mathbf{y}(k) \leq 0$


$$\mathbf{w}(k + 1) = \mathbf{w}(k) + c\mathbf{y}(k)$$

- $c > 0$ 为修正增量


- 如果 $\mathbf{y}(k) \in \omega_2$ & $\mathbf{w}^T(k)\mathbf{y}(k) \geq 0$

$$\mathbf{w}(k + 1) = \mathbf{w}(k) - c\mathbf{y}(k)$$

- 其他情况 $\mathbf{w}(k + 1) = \mathbf{w}(k)$



当数据线性可分，
感知机算法在有限
步骤内收敛



分错时更
新权重

举例

- 线性可分的两个模式类


- 增广模式向量

$$\{(0, 0, 1)^T, (0, 1, 1)^T\}$$

$$\{(1, 0, 1)^T, (1, 1, 1)^T\}$$

- 初始权重 $\mathbf{w}(1) = \mathbf{0}$

- 参数 $c = 1$



举例



- 线性可分的两个模式类
 - 迭代过程

$$\mathbf{w}^T(1)\mathbf{y}(1) = [0, 0, 0] \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} = 0 \quad \mathbf{w}(2) = \mathbf{w}(1) + \mathbf{y}(1) = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$$

$$\mathbf{w}^T(2)\mathbf{y}(2) = [0, 0, 1] \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix} = 1 \quad \mathbf{w}(3) = \mathbf{w}(2) = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$$

举例



- 线性可分的两个模式类
 - 迭代过程

$$\mathbf{w}^T(3)\mathbf{y}(3) = [0, 0, 1] \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix} = 1 \quad \mathbf{w}(4) = \mathbf{w}(3) - \mathbf{y}(3) = \begin{bmatrix} -1 \\ 0 \\ 0 \end{bmatrix}$$

$$\mathbf{w}^T(4)\mathbf{y}(4) = [-1, 0, 0] \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} = -1 \quad \mathbf{w}(5) = \mathbf{w}(4) = \begin{bmatrix} -1 \\ 0 \\ 0 \end{bmatrix}$$

举例


- 线性可分的两个模式类

- 迭代过程

- 循环遍历数据

- $k = 14$ 时收敛

$$\mathbf{w}(14) = (-2, 0, 1)^T$$



● $\in \omega_1$

○ $\in \omega_2$





提纲

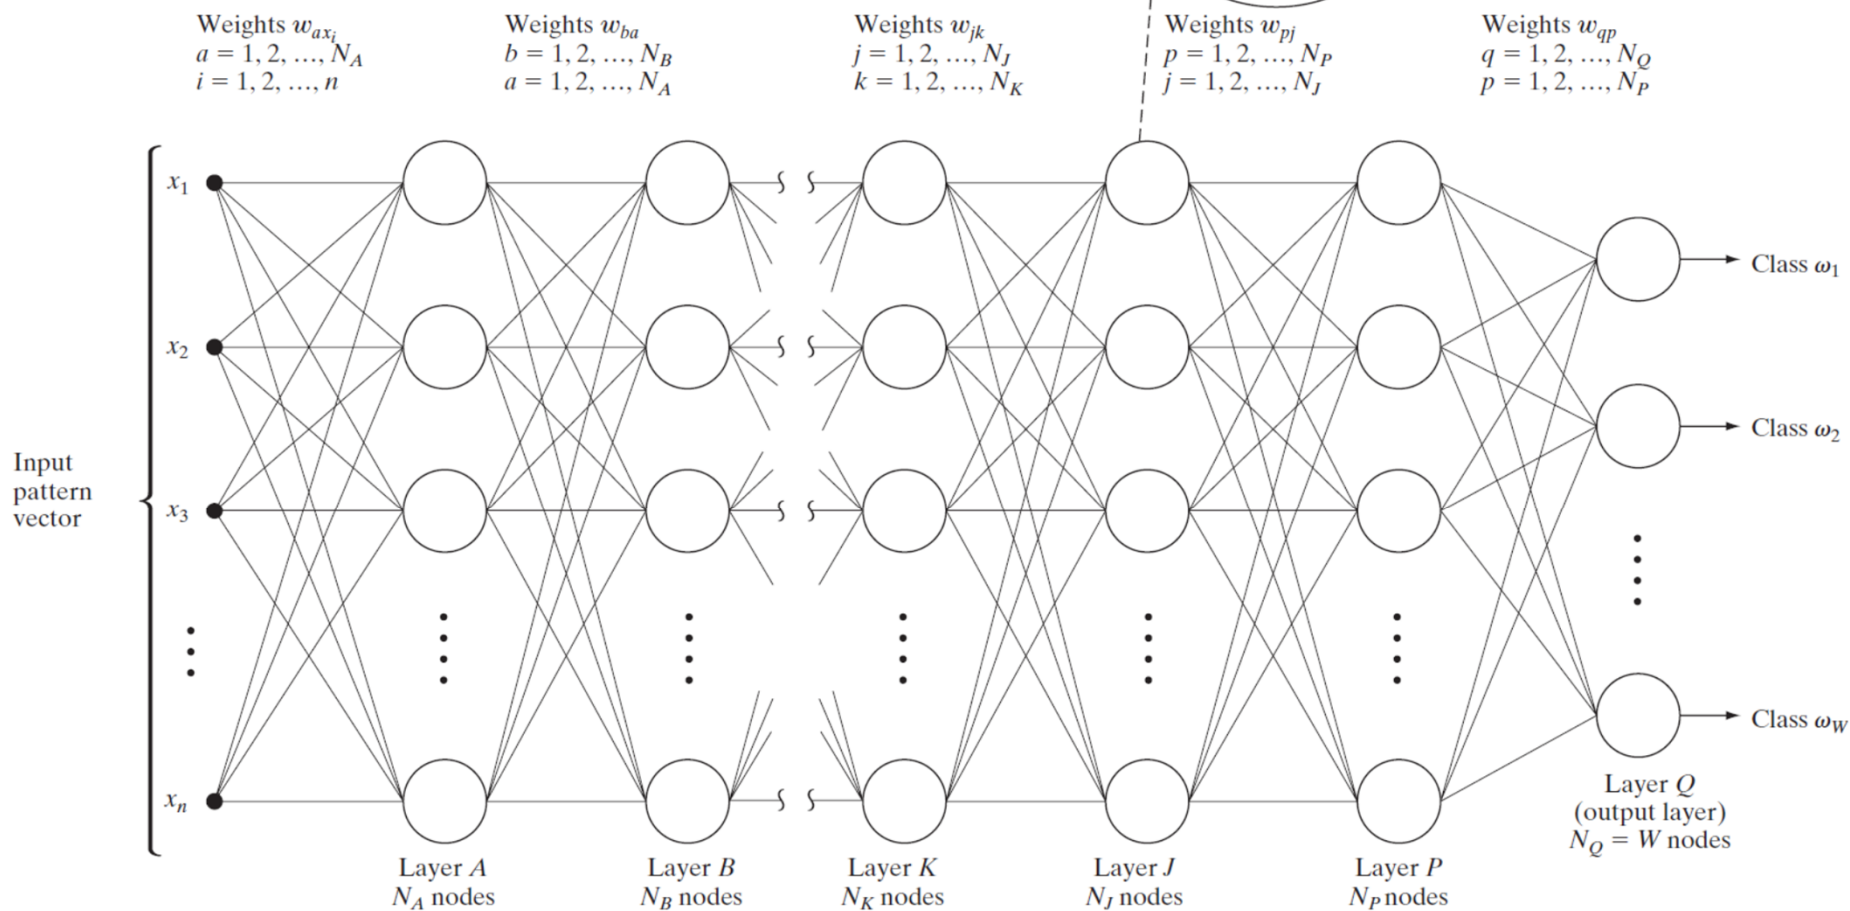

- 引言
- 模式和模式类
- 基于决策论方法的识别
 - 匹配
 - 最小距离分类器
 - 基于相关的匹配
 - 最佳统计分类器
 - 神经网络
 - 针对两类的感知机
 - 多层前馈神经网络

多层前馈神经网络



- 适用场景
 - 多分类问题
 - 线性可分或不可分
- 网络特点
 - 逐层结构，每一层由感知机的计算单元构成
 - 前一层的输出是后一层的输入
 - 输入为模式向量，个数为 n
 - 输出为类别，输出层的神经元个数为 W
 - 通过比较输出值大小决定类别

多层前馈神经网络




多层前馈神经网络



- S形激活函数 (sigmoid activation function)

$$h_j(I_j) = \frac{1}{1 + e^{-(I_j - \theta_j)/\theta_0}}$$

- I_j 是输入
- θ_j 为偏移, θ_0 控制函数的形状



多层前馈神经网络



- 每个节点的操作

- 假设第 K 层在第 J 层前面

1. 线性加权

$$I_j = \sum_{k=1}^{N_K} w_{jk} O_k$$

2. S形激活函数

$$O_k = h_k(I_k)$$

参数

- $N_J \times N_K$ 个权重系数
- N_J 个偏移系数

- 整体计算

$$h_j(I_j) = \frac{1}{1 + e^{-\left(\sum_{k=1}^{N_k} w_{jk} O_k - \theta_j\right) / \theta_o}}$$



通过反向传播训练

- 反向传播 (back propagation)

- 求导的链式法则 (chain rule)

- 梯度下降算法

- 对于优化问题 $\min f(x)$

- 更新策略: $x_{t+1} = x_t - \eta_t \nabla f(x_t)$

- $\eta_t > 0$ 为步长

- 输出层的损失

- r_q 是需要的输出

- Q_q 是网络的输出

$$E_Q = \frac{1}{2} \sum_{q=1}^{N_Q} (r_q - O_q)^2$$

举例



- 形状分类
 - 四种形状
 - 48维的模式向量
 - 计算归一化的签名



Shape 1



Shape 2



Shape 3




Shape 4

举例



- 形状分类
 - 三层神经网络
 - 48个节点
 - 26个节点
 - 4个节点




举例




- 形状分类

1. 随机初始化
2. 使用无噪声数据训练
 - 直到正确类别的输出大于0.95
3. 使用有噪声数据进行增量训练
 - 以概率 V 保持不变, 以 $R = 1 - V$ 选择临近点



举例

- 形状分类
 - 使用有噪声数据进行测试
 - 数据增多, 分错的概率下降
 - $R_t = 0.4$ 是异常情况
 - 噪声过大, 数据不足



举例

- 形状分类
 - 使用有噪声数据进行测试
 - 数据增多，分错的概率下降

