

# 第8章 分类算法

## 《人工智能算法》

清华大学出版社

2022年7月

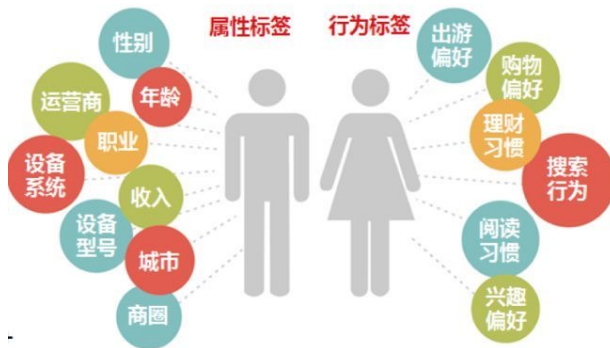
# 提纲

- ◆ 分类算法概述
- ◆ 决策树
- ◆ 支持向量机
- ◆ 贝叶斯分类
- ◆ 总结

# 分类算法概述 (1)

## ◆ 电商平台面临的实际问题

- 如何快速精准地实现用户分群？（预测流失或VIP客户）
- 如何预测新产品的销量及喜爱该产品的客户？
- 如何对客户的某些特征进行分类（圈选具有共同特征的用户，提供个性化的购物体验）



# 分类算法概述 (2)


## ◆ 数据分类 (Classification)

目的：根据新数据样本的属性为其分配一个正确的类别

应用：图片识别、信誉证实、医疗诊断、异常检测、情感分析...

## ◆ 经典的单一分类算法

- 决策树 (Decision Tree)
- k-近邻 (k-Nearest Neighbor)
- 支持向量机 (Support Vector Machine, SVM)
- 贝叶斯 (Bayesian) 分类
- 人工神经网络 (Neural Network)
- 关联分类 (Association Classification)



监督学习  
(Supervised  
Learning)

# 提纲

- ◆ 分类算法概述
- ◆ 决策树
- ◆ 支持向量机
- ◆ 贝叶斯分类
- ◆ 总结

# 决策树 (1)

## ◆ 基本概念

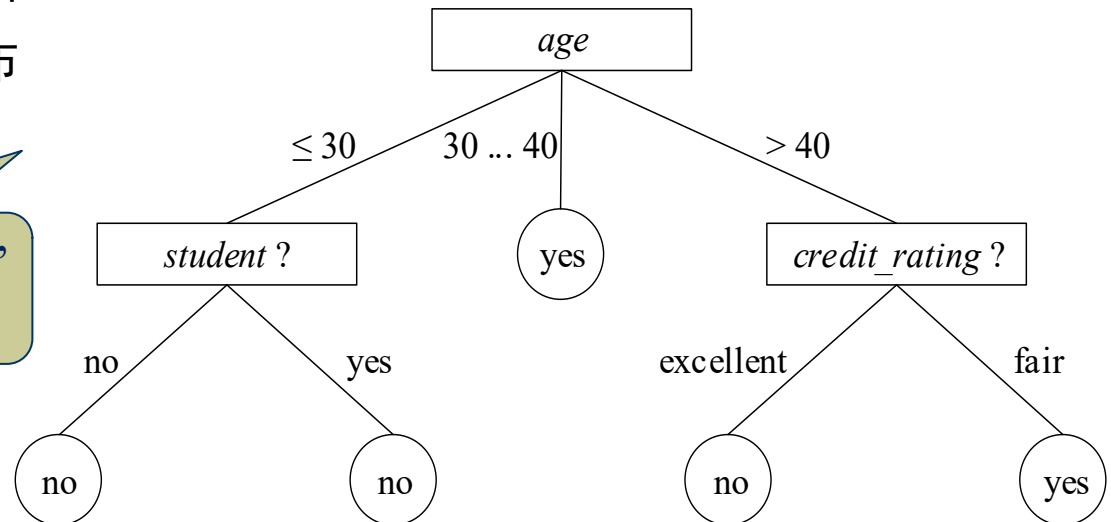
- 从实例中构造表示分类规则的决策树（描述属性与类别的关系）
- 类似于流程图的树结构

内部节点：一个属性变量上的测试

分枝：一个测试输出

叶子节点：类或分布

描述 “buys\_computer”  
的决策树



# 决策树 (2)

## ◆ 决策树构造算法

基本思想：基于贪心法递归地分裂输入变量空间的各个单元

关键步骤（以ID3为例）：

(1) 选择测试变量

- ① 如果样本都在同一个类，则该节点成为叶子节点
- ② 否则，选择信息增益最高的变量作为该节点的测试变量

(2) 递归分裂

(3) 递归分裂步骤停止，仅当下列条件之一成立

- ① 给定节点的所有样本属于同一类
- ② 没有剩余属性变量可用来进一步分裂样本
- ③ 一个分枝没有样本

# 决策树 (3)

## ◆ 决策树构造算法

选择测试变量：

设 $S$ 是 $s$ 个带类标记的数据样本的集合， $F$ 是 $n$ 个属性变量的集合，有 $m$ 个类 $\{c_1, \dots, c_m\}$ ， $s_i$ 是类 $c_i$ 中的样本数，对每个样本分类的期望信息为：

$$I(s_1, \dots, s_m) = - \sum_{i=1}^m (p_i \cdot \log p_i)$$

设属性变量 $A = \{a_1, \dots, a_v\}$  ( $A \in F$ )，可用 $A$ 将 $S$ 划分为 $v$ 个子集 $\{S_1, \dots, S_v\}$ 的熵或期望信息为：

$$E(A) = \sum_{j=1}^v \frac{s_{1j} + \dots + s_{mj}}{s} I(s_{1j} + \dots + s_{mj})$$

以 $A$ 作为测试变量（即在 $A$ 上分裂）所获得的信息增益为：

$$Gain(A) = I(s_1, \dots, s_m) - E(A)$$



# 决策树 (4)

## ◆ 决策树构造算法

输入:  $S$ , 带有类标记的训练数据集;  
 $F$ : 属性变量集;  $\varepsilon$ : 信息增益阈值  
输出:  $T$ , 决策树 (类标记)

### 步骤:

1. **If**  $S$ 所有样本属于同个类 $c_k$  **Then**
2.  $T$ 为单节点树,  $c_k$ 为该节点的类标记
3. **Return**  $T$
4. **End if**
5. **If**  $F=\emptyset$  **Then**
6.  $T$ 为单节点树, 将 $S$ 中实例最多的类 $c_k$ 作为该节点的类标记
7. **Return**  $T$
8. **End If**

9.  $A_g \leftarrow \arg \max \{Gain(A), A \in F\}$
10. **If**  $Gain(A_g) < \varepsilon$  **Then**
11.  $T$ 为单节点树, 通过多数表决将 $S$ 中实例最多的类 $c_k$ 作为该节点的类标记
12. **Return**  $T$
13. **Else**
14. **For**  $j=0$  **To**  $v$  **Do** //考察 $A_g$ 的每一个可能取值
15. 得到 $S$ 中在 $A_g$ 上具有 $a_j$ 值得样本集 $S_j$
16.  $createDecisionTree(S_j, F \setminus \{A_0\}, \varepsilon)$
17. **End For**

复杂度  $O(sn|T|)$

# 决策树 (5)

## ◆ 决策树构造算法示例

由表中的训练数据集构造概念 “buys\_computer”的决策树

<i>age</i>	<i>income</i>	<i>student</i>	<i>credit_rating</i>	<b>Class: buys_computer</b>
≤30	high	no	fair	no
≤30	high	no	excellent	no
31…40	high	no	fair	yes
>40	Medium	no	fair	yes
>40	low	yes	fair	yes
⋮	⋮	⋮	⋮	⋮
31…40	high	yes	fair	yes
>40	medium	no	excellent	no

“buys\_computer”有2个类： $c_1$ 代表 “yes”， $c_2$ 代表 “no”； $c_1$ 有9个样本， $c_2$ 有5个样本。

# 决策树 (6)

## ◆ 决策树构造算法示例

(1) 根据公式 $I(s_1, \dots, s_m)$ 计算对给定的样本进行分类所需要的期望值

$$I(s_1, s_2) = I(9, 5) = -\left(\frac{9}{14}\right) \times \log\left(\frac{9}{14}\right) - \left(\frac{5}{14}\right) \times \log\left(\frac{5}{14}\right)$$

(2) 根据公式 $E(A)$ 和 $Gain(A)$ 计算“age”变量的信息增益

- 对于“30”： $s_{11} = 2$ ,  $s_{21} = 3$ , 则 $I(s_{11}, s_{21}) = 0.971$
- 对于“31...40”： $s_{12} = 4$ ,  $s_{22} = 0$ , 则 $I(s_{12}, s_{22}) = 0$
- 对于“>40”： $s_{13} = 3$ ,  $s_{23} = 2$ , 则 $I(s_{13}, s_{23}) = 0.971$

所以,  $E(age) = \left(\frac{5}{14}\right) \times I(s_{11}, s_{21}) + \left(\frac{4}{14}\right) \times I(s_{12}, s_{22}) + \left(\frac{5}{14}\right) \times I(s_{13}, s_{23}) = 0.694$ 。

相应地,  $Gain(age) = I(s_1, s_2) - E(age) = 0.246$ 。

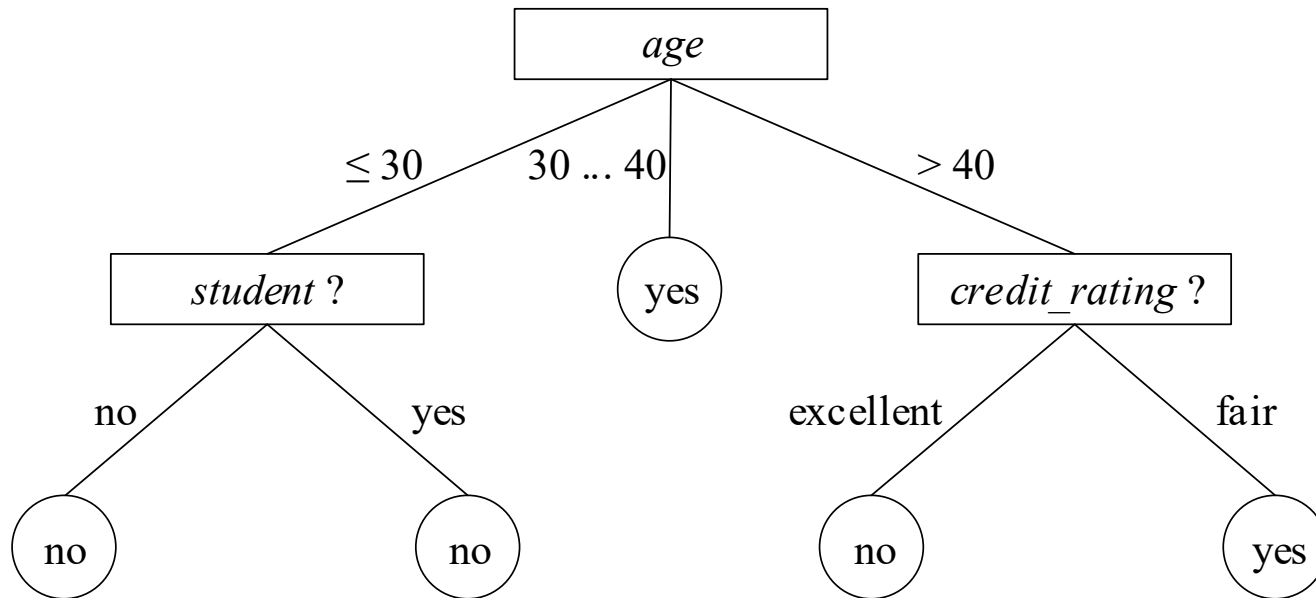
类似地, 可以计算出:

$$Gain(income) = 0.029, \quad Gain(student) = 0.151, \quad Gain(credit\_rating) = 0.048$$

# 决策树 (7)

## ◆ 决策树构造算法示例

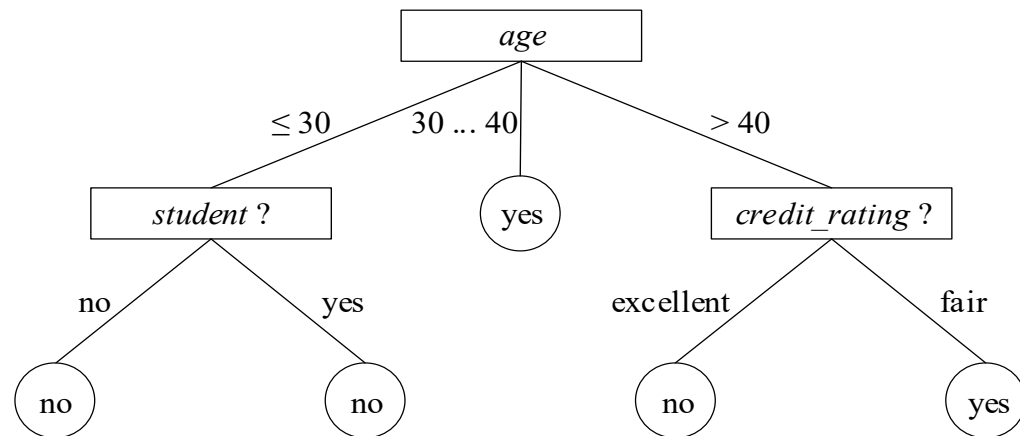
(3) 由于 “*age*” 具有最高的信息增益，则选择它为测试变量，创建 “*age*” 节点，进行第一次分裂，最终可构造出决策树



# 决策树 (8)

## ◆ 分类规则提取

可从已经构造好的决策树中提取形如If-Then的分类规则，每条从根节点到叶子节点的路径对应一个规则



沿着从根节点到叶子节点的路径，可提取出如下的分类规则：

**If**  $age = \leq 30$  and  $student = \text{no}$  **Then**  $buys\_computers = \text{no}$

**If**  $age = \leq 30$  and  $student = \text{yes}$  **Then**  $buys\_computers = \text{yes}$

**If**  $age = 31 \dots 40$  **Then**  $buys\_computers = \text{yes}$


# 提纲

- ◆ 分类算法概述
- ◆ 决策树
- ◆ 支持向量机
- ◆ 贝叶斯分类
- ◆ 总结

# 支持向量机 (1)

## ◆ 基本概念

- ✓ **二分类模型**：在样本空间中找出一个超平面来对数据进行分类，并使分类误差尽可能小。
- ✓ **分离超平面**：比所在数据空间小一维的空间，在二维数据空间中是一条直线，在三维数据空间中就是一个平面。



分离超平面将两类训练样本分开

训练集有两个特征和两类标签：

- 特征一用 $x_1$ 表示，特征二用 $x_2$ 表示
- 用“+”表示正例，用“-”表示负例

# 支持向量机 (2)

## ◆ 训练算法

### (1) 训练数据

一个特征空间上线性可分的数据集  $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$ ，其中  $x_i \in \mathbb{R}^n$ ， $y_i = \{+1, -1\}$ ， $i=1, 2, \dots, n$ 。  $x_i$  为第  $i$  个训练样本的特征向量， $y_i$  为  $x_i$  的类标记， $(x_i, y_i)$  称为样本点。当  $y_i = +1$  时，称  $x_i$  为正例；当  $y_i = -1$  时，称  $x_i$  为负例。

### (2) 寻找最大间隔超平面

通过线性方程  $\mathbf{w}^T x + b = 0$  来描述分离超平面，其中  $\mathbf{w} = (w_1; \dots; w_d)$  为决定超平面方向的**法向量**， $b$  为决定超平面与原点之间距离的**位移项**。

分类策略函数为：

$$f(x) = \text{sign}(\mathbf{w}^T x + b), \text{ sign}(\cdot) \text{ 为符号函数。}$$



# 支持向量机 (3)

## ◆ 训练算法

给定数据集 $D$ 和超平面 $(\mathbf{w}, b)$ ，超平面关于样本点 $(x_i, y_i)$ 的几何间隔为：

$$\gamma_i = \frac{y_i(\mathbf{w}^T x_i + b)}{\|\mathbf{w}\|}, i = 1, \dots, n$$

若超平面 $(\mathbf{w}, b)$ 能将所有样本点正确分类，则 $y_i(\mathbf{w}^T x_i + b) > 0$

若 $y_i=+1$ ，则正例 $x_i$ 满足约束条件 $\mathbf{w}^T x_i + b > 0$ ；

若 $y_i=-1$ ，则负例 $x_i$ 满足约束条件 $\mathbf{w}^T x_i + b < 0$ 。

令 $y_i(\mathbf{w}^T x_i + b) \geq 1$ ，则约束条件表示为：

$$\begin{cases} \mathbf{w}^T x_i + b \geq +1, y_i = +1 \\ \mathbf{w}^T x_i + b \leq -1, y_i = -1 \end{cases}$$

# 支持向量机 (4)

## ◆ 训练算法

**支持向量**：与超平面几何间隔最小且满足约束条件的样本点  $\min_{i=1, \dots, n} \gamma_i$

样本点到超平面的最小几何间隔为  $\frac{1}{\|\mathbf{w}\|}$

两个异类支持向量到超平面距离之和为  $\frac{2}{\|\mathbf{w}\|}$ ，称为**间隔**

**求解最大间隔分离超平面**，可表示为以下最优化问题：

$$\max_{\mathbf{w}, b} \frac{2}{\|\mathbf{w}\|} \quad \text{s.t.} \quad y_i(\mathbf{w}^T x_i + b) \geq 1, \quad i = 1, \dots, n$$

由于  $\max_{\mathbf{w}, b} \frac{2}{\|\mathbf{w}\|}$  和  $\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2$  等价，训练SVM的最优化问题如下：

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{s.t.} \quad (\mathbf{w}^T x_i + b) \geq 1, \quad i = 1, \dots, n$$

# 支持向量机 (5)

## ◆ 训练算法

### (3) 软间隔最大化

**硬间隔：** 分离超平面能正确划分所有样本

**软间隔：**

允许某些点不满足约束，可对每个样本点 $(x_i, y_i)$ 引入松弛变量 $\xi_i \geq 0$ ，则约束条件变为： $y_i(\mathbf{w}^T x_i + b) \geq 1 - \xi_i$

$$\xi_i = l_{0/1}(y_i(\mathbf{w}^T x_i + b) - 1) \quad 0/1 \text{ 损失函数 } l_{0/1}(z) = \begin{cases} 1, & z < 0 \\ 0, & z \geq 0 \end{cases}$$

目标函数变为： $\min_{\mathbf{w}, b, \xi_i} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i$ ，正常数 $C$ 称为惩罚系数

**优化目标：** 使 $\frac{1}{2} \|\mathbf{w}\|^2$ 尽量小（间隔尽量大），同时使误差分类点的个数尽量少

实际情况下  
几乎不存在

# 支持向量机 (6)

## ◆ 训练算法

0/1损失函数：**非凸和非连续**，是单位跃迁函数，目标函数求解难。

常用**凸连续函数**替代损失函数来取代“0/1损失函数”。

常用的替代损失函数：

1. hinge损失： $l_{\text{hinge}}(z) = \max(0, 1 - z)$
2. 指数损失： $l_{\text{exp}}(z) = \exp(-z)$
3. 对率损失： $l_{\text{log}}(z) = \exp(1 + \exp(-z))$

# 支持向量机 (7)

## ◆ 训练算法

输入:  $D$ , 训练数据集;  $C$ , 惩罚系数

输出:  $f(x)$ , 分类决策函数

### 步骤:

1. 构造线性支持向量机原始最优化问题:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2$$

s. t.  $y_i(\mathbf{w}^T x_i + b) \geq 1, i = 1, \dots, n$

2. 使用拉格朗日乘子求解对偶问题:

$$\max_{\alpha} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i * x_j) - \sum_{i=1}^N \alpha_i$$

s. t.  $\sum_{i=1}^N \alpha_i \alpha_j = 0, 0 \leq \alpha_i \leq C, i = 1, \dots, n$

3. 计算法向量  $\mathbf{w}^*$  和位移项  $b^*$ :

$$\mathbf{w}^* = \sum_{i=1}^N \alpha_i^* y_i x_i$$
$$b^* = y_i - \sum_{i=1}^N y_i \alpha_i^* (x_i * x_j)$$

4. 计算最大间隔分离超平面以及分类决策函数:

$$\mathbf{w}^* x + b^* = 0$$
$$f(x) = \text{sign}(\mathbf{w}^* x + b^*)$$

Return  $f(x)$

时间复杂度  $O(n^3)$   
空间复杂度  $O(n^2)$

# 支持向量机 (8)

## ◆ 核函数

- 原始样本空间可能**不存在能正确划分两类样本的超平面**
- **经过空间转换**，在高维空间解决线性问题等价于在低维空间中解决非线性问题

名称	表达式	参数
线性核	$k(x_i, x_j) = x_i^T x_j$	/
多项式核	$k(x_i, x_j) = (x_i^T x_j)^d$	$d \geq 1$ 为多项式的次数
高斯核	$k(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ ^2}{2\sigma^2})$	$\sigma > 0$ 为高斯核的带宽
拉普拉斯核	$k(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ }{\sigma})$	$\sigma > 0$
Sigmoid	$k(x_i, x_j) = \tanh(\beta x_i^T x_j + \theta)$	$\beta > 0, \theta < 0$

# 提纲

- ◆ 分类算法概述
- ◆ 决策树
- ◆ 支持向量机
- ◆ 贝叶斯分类
- ◆ 总结

# 贝叶斯分类 (1)

## ◆ 基本概念

- 一类以贝叶斯定理为基础、用概率论和统计学知识进行分类的算法
- 包括朴素贝叶斯分类、链增强朴素贝叶斯分类、树增强朴素贝叶斯分类等

## ◆ 朴素贝叶斯分类

- 贝叶斯分类器中最简单、应用最为广泛的算法之一
- 由于假设特征之间相互独立，所以称为“朴素贝叶斯”
- 分类时对每个类别计算 $P(c_k)P(x_i|c_k)$ ，以 $P(c_k)P(x_i|c_k)$ 的最大项作为待预测样本 $X$ 所属的类别



# 贝叶斯分类 (2)

## ◆ 贝叶斯分类的基本思想


- 设数据集  $D = \{x_1, \dots, x_i, \dots, x_{n(D)}\}$ ，样本  $x_i$  的属性集合  $X_i = \{x_{i1}, \dots, x_{in}\}$ ，类别集合  $C = \{c_1, c_2, \dots, c_m\}$ ，即样本可分为  $m$  个类别

- 网络结构含有属性集合  $X = \{x_1, \dots, x_i, \dots, x_n\}$  和类别集合  $C = \{c_1, \dots, c_k, \dots, c_m\}$ 。对于属性集合为  $\{x_1, x_2, \dots, x_n\}$  的待预测数据样本  $X$ ，使  $P(c_k | x_1, \dots, x_n)$  最大的分类任务称为贝叶斯分类：

$$C(X) = \arg \max_{c_k \in C} \{P(c_k | x_1, \dots, x_n)\}$$

$c_k$  的后验概率为：

$$P(c_k | x_1, \dots, x_n) = \frac{P(c_k, x_1, \dots, x_n)}{P(x_1, \dots, x_n)} = \frac{P(x_1, \dots, x_n | c_k) P(c_k)}{P(x_1, \dots, x_n)}$$




没有变量独立假设  
时计算需指数时间

# 贝叶斯分类 (3)

## ◆ 朴素贝叶斯分类的基本思想

- 设在给定类别变量下属性变量之间条件独立，朴素贝叶斯分类使 $P(c_k|x_1, \dots, x_n)$ 最大
- 在条件独立性假设下，朴素贝叶斯分类具有简单的星形结构网络结构
- 每个属性只有唯一的类 $c_k$ 作为其父节点，这意味着给定类 $c_k$ 时， $x_1, x_2, \dots, x_n$ 条件独立，即



$$P(x_1, \dots, x_n|c_k) = \prod_{i=1}^n P(x_i|c_k)$$

# 贝叶斯分类 (4)

## ◆ 朴素贝叶斯分类的基本思想

- 为了降低 $P(c_k | x_1, \dots, x_n)$ 的计算复杂度，根据条件独立性将联合概率分解为：

$$P(c_k, x_1, \dots, x_n) = P(c_k)P(x_1, \dots, x_n | c_k) = P(c_k) \prod_{i=1}^n P(x_i | c_k)$$

- 根据联合概率的分解形式，对于给定的待预测样本 $X$ ，朴素贝叶斯分类形式表示为：

$$C(X) = \arg \max_{c_k \in C} \left\{ P(c_k) \prod_{i=1}^n P(x_i | c_k) \right\}$$

# 贝叶斯分类 (5)

## ◆ 朴素贝叶斯分类的训练算法

- 关键步骤:

- ① 确定特征属性、获取样本数据集
- ② 训练分类器，分别计算每个类别的概率 $P(c_k)$ 和每个属性在该类别下的条件概率 $P(x_i|c_k)$
- ③ 对每个类别计算 $P(c_k) \prod_{i=1}^n P(x_i|c_k)$ ，以 $P(c_k) \prod_{i=1}^n P(x_i|c_k)$ 的最大项作为 $X$ 所属的类别

步骤②中的参数估计，包括**类别概率估计** $\hat{P}(c_k)$ 和**条件概率估计** $\hat{P}(c_k|x_i)$

# 贝叶斯分类 (6)

## ◆ 朴素贝叶斯分类的训练算法

- 属性值为**离散型**:

**类别概率估计:**  $\hat{P}(c_k) = n(c_k)/n(D)$ ; 其中,  $n(c_k)$ 为第 $c_k$ 类中样本的数量,  $n(D)$ 为样本总数

**条件概率估计:**  $\hat{P}(x_i|c_k) = n(x_i|c_k)/n(c_k)$ ; 其中,  $n(x_i|c_k)$ 为第 $c_k$ 类中属性为 $x_i$ 的样本数量

- 属性值为**连续型**:

**类别概率估计:**  $\hat{P}(c_k) = n(c_k)/n(D)$ ; 其中,  $n(c_k)$ 为第 $c_k$ 类中样本的数量,  $n(D)$ 为样本总数

**条件概率估计:**  $\hat{P}(x_i|c_k) = \frac{1}{\sqrt{2\pi}\sigma_{c_k}} \exp\left\{-\frac{(x_i - \mu_{c_k})^2}{2\sigma_{c_k}^2}\right\}$ ; 其中,

$\hat{P}(x_i|c_k) \sim N(\mu_{c_k}, \sigma_{c_k}^2)$ ,  $\mu_{c_k}$ 和 $\sigma_{c_k}^2$ 分别为 $c_k$ 类中 $x_i$ 的均值和方差

# 贝叶斯分类 (7)

## ◆ 朴素贝叶斯分类的训练算法

输入:  $D$ , 数据样本集;  $X$ , 待预测数据的属性集合;  $C$ , 类别集合

输出:  $C(X)$  //以 $P(x|y_i)P(y_i)$ 最大项作为 $X$ 所属类别

### 步骤:

1. 统计 $D$ 中样本的总数 $n(D)$
2. 统计 $D$ 中每类样本的数量 $n(c_k)$
3. 统计 $D$ 中第 $c_k$ 类中属性为 $x_i$ 的样本数量 $n(x_i|c_k)$
4. 统计 $X$ 中属性的总数 $n$
5.  $\hat{P}(x_i|c_k) \leftarrow 1$
6.  $P(c_k|X) \leftarrow \emptyset$

7. **For**  $k=0$  **To**  $n(c_k)$  **Do**

8.  $\hat{P}(c_k) \leftarrow n(c_k)/n(D)$  //类别概率估计

9. **For**  $j=i$  **To**  $n$  **Do**

10.  $\hat{P}(x_j|c_k) \leftarrow (n(x_j|c_k)/n(c_k)) \times \hat{P}(x_j|c_k)$

11.  $\hat{P}(c_k|X) \leftarrow \hat{P}(c_k) \times \hat{P}(x_j|c_k)$

12.  $P(c_k|X) \leftarrow P(c_k|X) \cup \hat{P}(c_k|X)$

13. **End For**

14. **End For**

15.  $C(X) = \arg \max\{P(c_k|X)\}$

时间复杂度  
 $O(n(c_k) \times n)$

# 贝叶斯分类 (8)

## ◆ 朴素贝叶斯分类示例

**任务：**已知某人身高“高”、体重“中”和鞋码“中”，预测其性别。

设“男”和“女”为2个类别，用 $c_1$ 和 $c_2$ 表示；属性集合为“身高”、“体重”和“鞋码”，用 $x_1$ 、 $x_2$ 和 $x_3$ 表示。分类步骤如下：

编号	身高	体重	鞋码	性别
1	高	重	大	男
2	高	重	大	男
3	中	中	大	男
4	中	中	中	男
5	矮	轻	小	女
6	矮	轻	小	女
7	矮	中	中	女
8	中	中	中	女

### ① 类别概率估计：

类别为“男”的概率为 $\hat{P}(c_1)=1/2$ ，类别为“女”的概率为 $\hat{P}(c_2)=1/2$ 。

### ② 条件概率估计：

性别为“男”、身高“高”、体重“中”、鞋码“中”的概率为

$$\begin{aligned}\hat{P}(x_1, x_2, x_3|c_1) &= \hat{P}(x_1|c_1)\hat{P}(x_2|c_1)\hat{P}(x_3|c_1) \\ &= (1/2) \times (1/2) \times (1/4) = 1/16\end{aligned}$$

性别为“女”、身高“高”、体重“中”、鞋码“中”的概率为

$$\hat{P}(x_1, x_2, x_3|c_2) = \hat{P}(x_1|c_2) \times \hat{P}(x_2|c_2) \times \hat{P}(x_3|c_2) = 0$$

### ③ 类别预测：

由于 $\hat{P}(c_1) \times \hat{P}(x_1, x_2, x_3|c_1) > \hat{P}(c_2) \times \hat{P}(x_1, x_2, x_3|c_2)$ ，此人性别为“男”。

# 提纲

- ◆ 分类算法概述
- ◆ 决策树
- ◆ 支持向量机
- ◆ 贝叶斯分类
- ◆ 总结



# 总结

## ◆ 决策树

**优点：**易于理解和解释，可处理混合类型的变量，对缺失值不敏感且灵活性好。

**缺点：**贪心法的解可能不是最优值，会出现过拟合。

## ◆ 支持向量机

**优点：**全局最优值，泛化能力强，算法简单且鲁棒。

**缺点：**样本数量大时，存储和计算的开销较大。

## ◆ 朴素贝叶斯

**优点：**时空开销小，能处理多分类任务，对缺失数据不太敏感，结果可解释、容易理解。

**缺点：**决策存在错误率，对输入数据的表达形式很敏感。



结语

谢谢！