本课件仅用于教学使用。未经许可，任何单位、组织和个人不得将课件用于该课程教学之外的用途(包括但不限于盈利等)，也不得上传至可公开访问的网络环境

新媒体大数据分析

New Media Big Data Analysis

数据建模：概论

黄振亚，朱孟潇，张凯，唐秀秀

课程主页：
http://staff.ustc.edu.cn/~mxzhu/Course/NNM2026.html

助教：谭施越 朱嘉骏
bigdata_20262026@163.com

本课件仅用于教学使用。未经许可，任何单位、组织和个人不得将课件用于该课程教学之外的用途(包括但不限于盈利等)，也不得上传至可公开访问的网络环境

新媒体大数据分析

New Media Big Data Analysis

数据建模：分类

黄振亚，朱孟潇，张凯，唐秀秀

课程主页：
http://staff.ustc.edu.cn/~mxzhu/Course/NNM2026.html

助教：谭施越 朱嘉骏
bigdata_20262026@163.com

分类与预测

- 数据挖掘任务 — 分类与预测









该图片有关联

该图片是科大

这张照片是哪里?



如果数据有标签，即已知图片是科大，则可以预测新图片的类

分类与预测

- 案例一：垃圾邮件分类 — 中科大安全演练
  - 判断：下面这封邮件是垃圾邮件吗？

结论：一封垃圾邮件

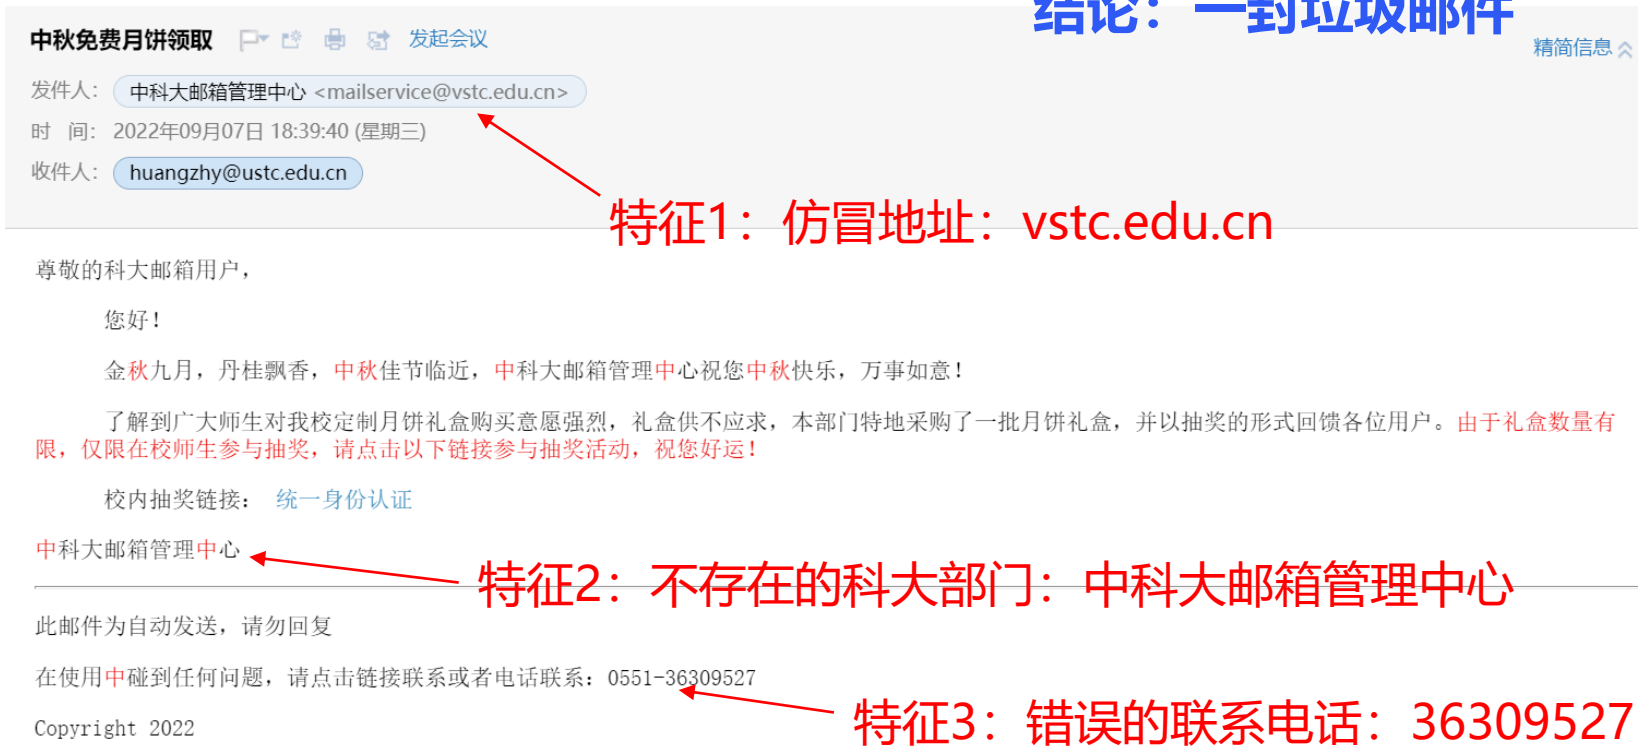

基于一些特征与规则，我们可以将垃圾邮件的判别视作一个分类问题

分类与预测

- 案例二：电影评分预测
  - 预测：用户对电影《功夫》的评分是多少？

已知：他对4部电影的评分分别为：5.0，4.8，4.9，4.5

特征1：喜欢周星驰

特征2：喜欢喜剧









结论：预测评分5分



基于一些特征与规则，我们可以将电影评分(连续值)估计视作一个预测问题

分类与预测

- 生活中的案例：直观理解买芒果

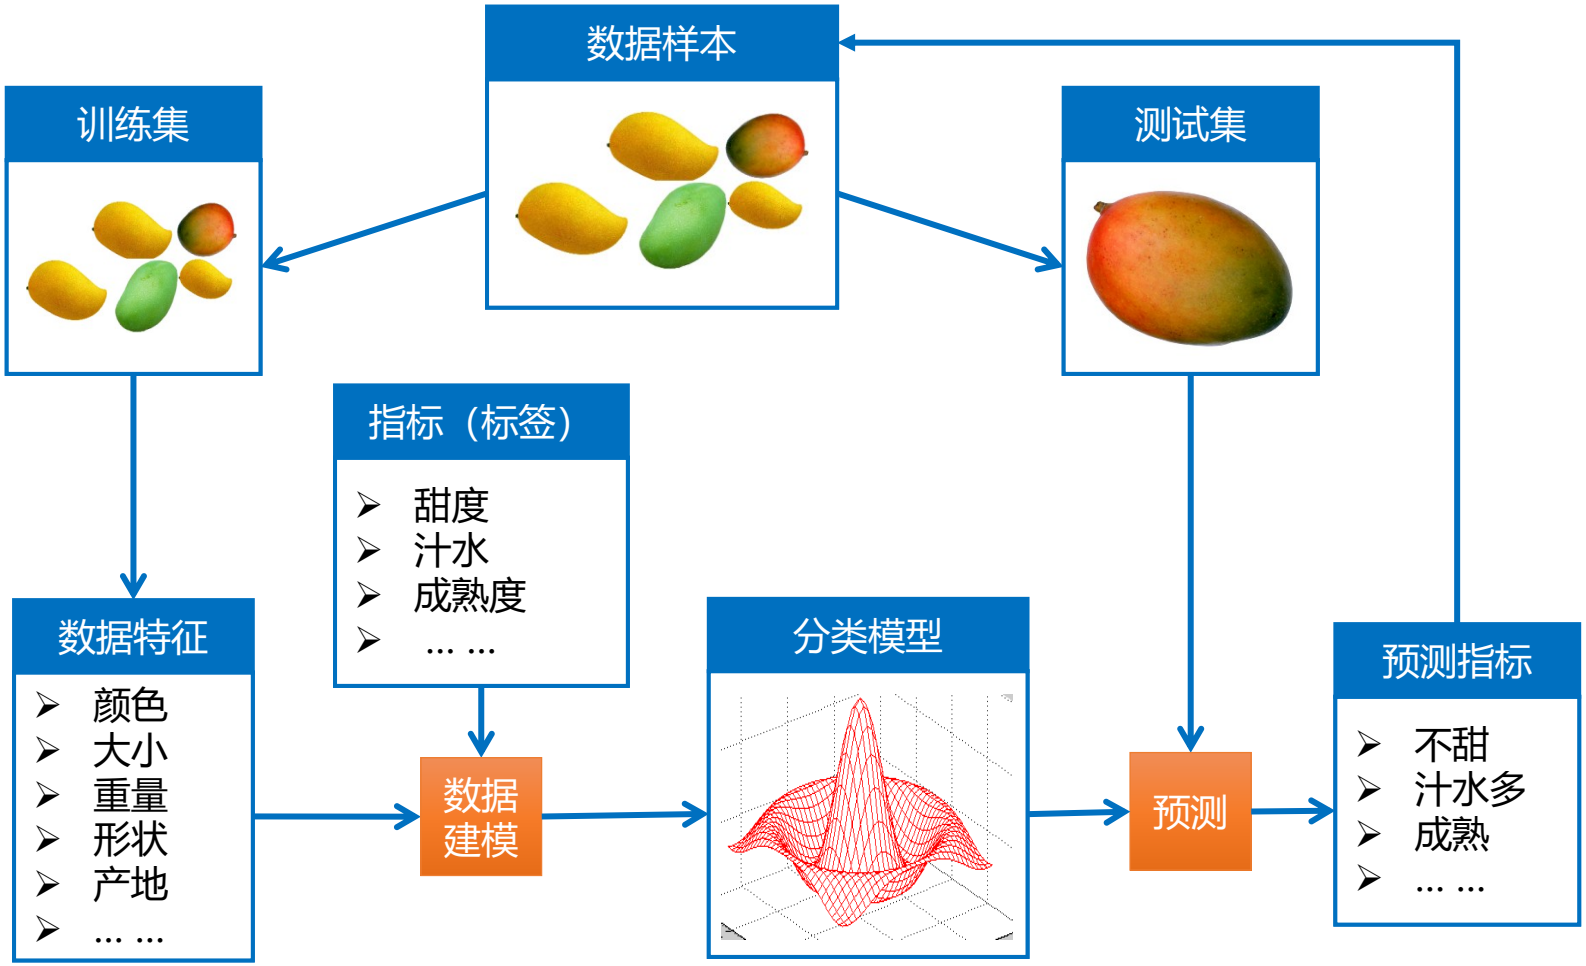

分类与预测

- 分类与预测 — 有监督学习
  - 已知：一组数据（训练集） (X, Y)
  - 如右图，每一条记录表示为 (x, y)
    - x：数据特征/属性（如收入）
    - y：类别标记（是否有借款）
  - 任务:
    - 学习一个模型，利用每一条记录的特征x去预测它对应的类别y

即：输入未标记的数据（含特征x），预测数据的类别y

分类 / 数值预测 取决于 类别标签是离散型 / 数值型

3个特征：

- 是否有住房
- 婚姻状态
- 年收入

类别：

是否拖欠贷款

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

分类与预测

- 分类与预测 — 回顾前例

任务	特征x	类别y
垃圾邮件分类	收件人、邮箱名、邮件内容等	是否时垃圾邮件 **离散型**
电影评分预测	用户在其他电影的评分 电影的演员，类型等	实值评分[0,5] **数值型**
芒果好坏预测	芒果的颜色、大小、重量、形状、产地等	芒果的甜度、水分、成熟与否 **离散型 或 数值型**

分类与预测

- 如何建立分类与预测模型？
  - 一般流程：有监督学习
  - 通常包括两个阶段：模型训练、模型预测
    - 模型训练：目标是利用训练数据，学习一个分类或预测模型

Tid	Attrib1	Attrib2	Attrib3	Class
1	Yes	Large	125K	No
2	No	Medium	100K	No
3	No	Small	70K	No
4	Yes	Medium	120K	No
5	No	Large	95K	Yes
6	No	Medium	60K	No
7	Yes	Large	220K	No
8	No	Small	85K	Yes
9	No	Medium	75K	No
10	No	Small	90K	Yes

Training Set

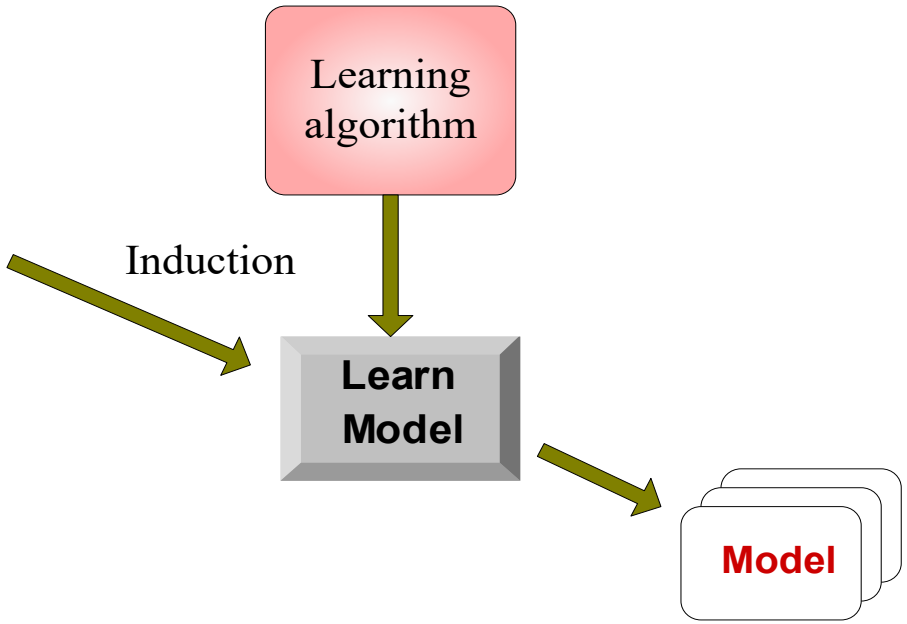

训练集有类别标签

分类与预测

- 如何建立分类与预测模型？
  - 一般流程：有监督学习
  - 通常包括两个阶段：模型训练、模型预测
    - 模型预测：目标是利用学习的模型，预测测试数据的标签

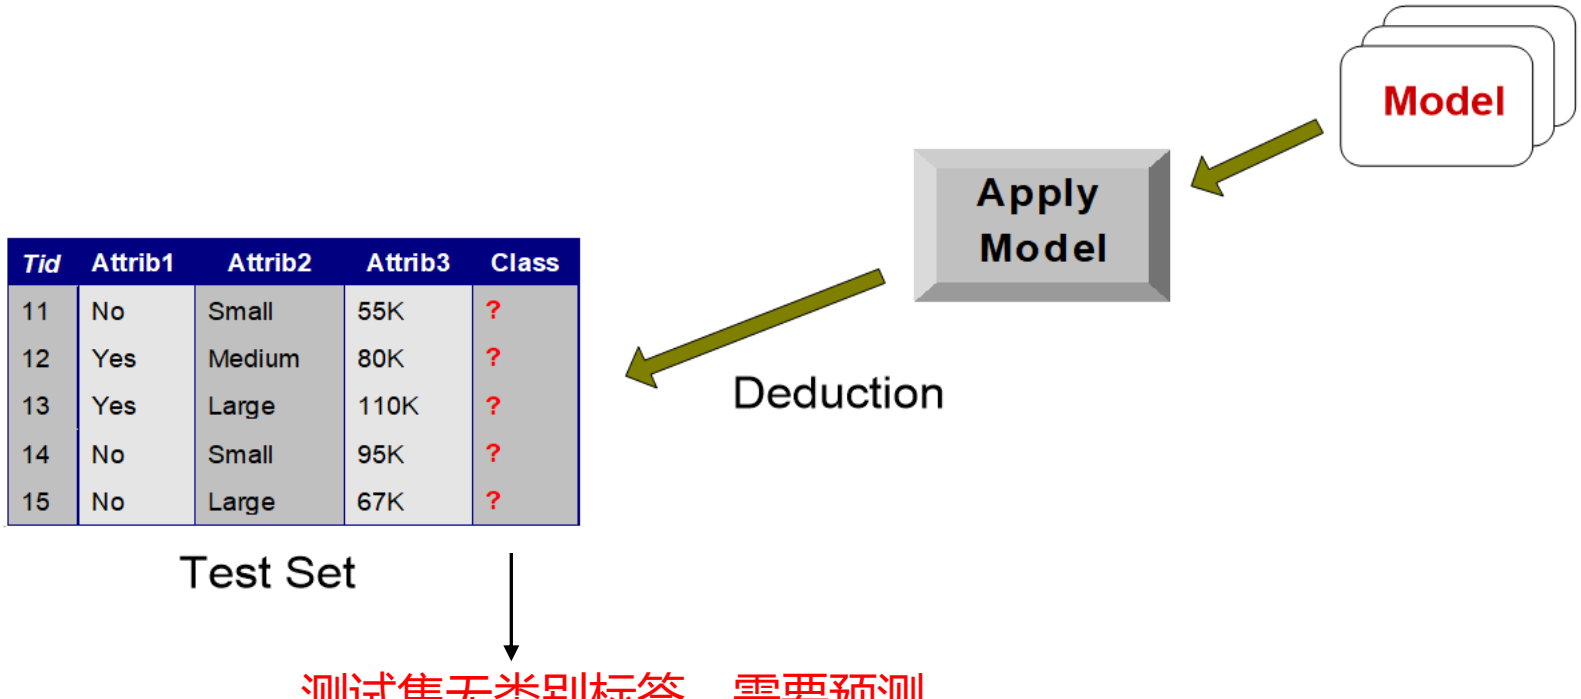



分类与预测

- 有监督学习：分类与预测
- 常用方法
  - 规则方法
  - 决策树
  - 贝叶斯方法
  - 最近邻方法
  - 支持向量机（SVM）
  - 神经网络
  - 集成方法
- 分类的评价指标

分类：规则方法

- **规则方法**
  - 基于规则的分类器（Rule-based Classifier）就是使用一组 if-then 的模式来进行分类
  - 基本形式：Condition → y（标签）
    - 其中，Condition是一组属性的组合，也被称作规则的前提
  - 例如：
    - (胎生= 否) ∧ (飞行动物= 是) → 鸟类
    - (胎生= 是) ∧ (体温= 恒温) → 哺乳类
  - 最基础的获得规则的方法：人工制定规则进行分类

↓

不足：人工定义规则、效率低，难以处理复杂问题

↓

自动生成规则？决策树

分类：规则方法

- 回顾垃圾邮件分类的例子
  - 判断：下面这封邮件是垃圾邮件吗？

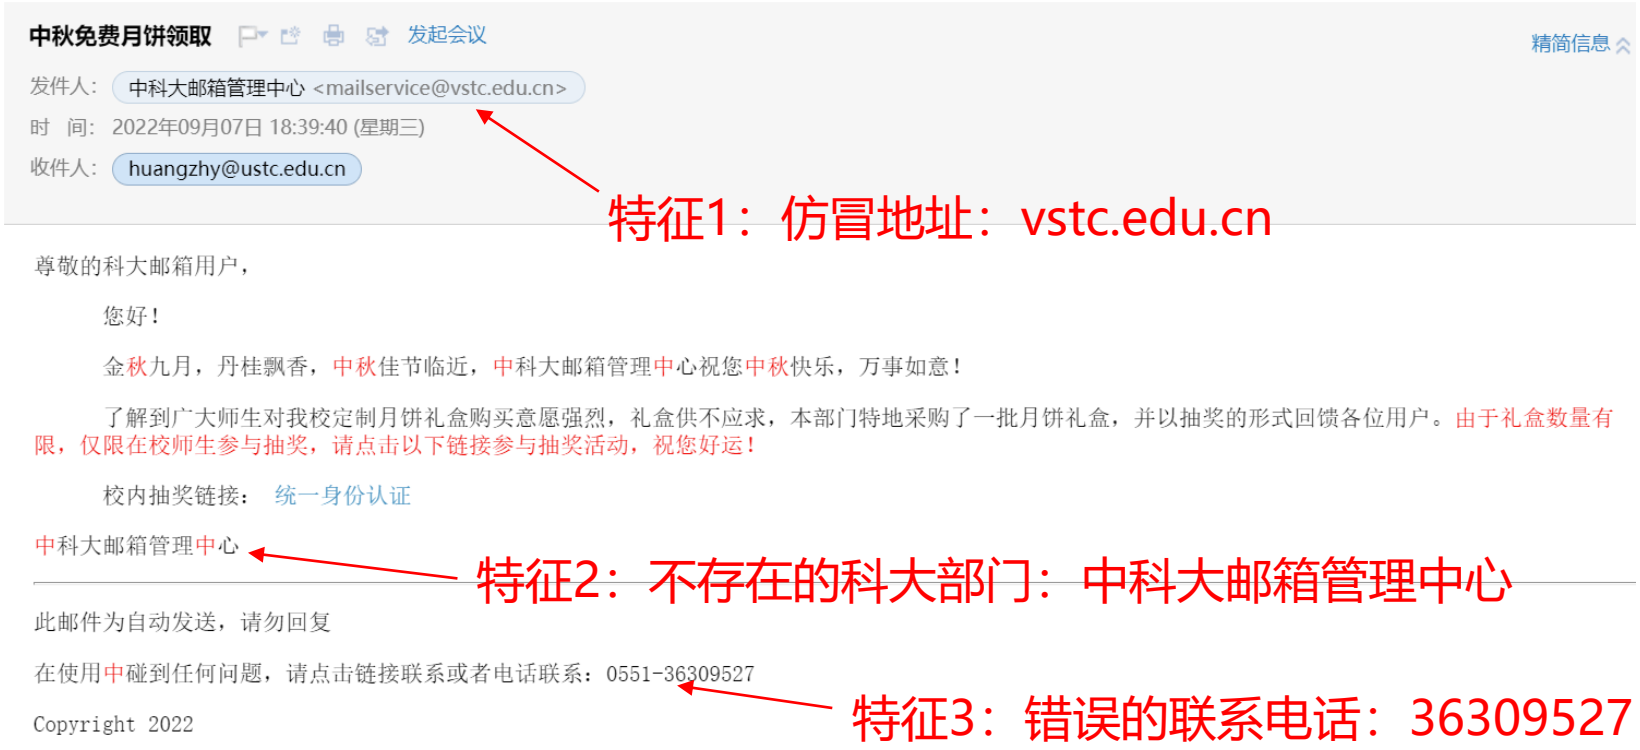

(地址= vstc.edu.cn) ∧ (部门= 中科大邮箱管理中心) ∧ (电话= 36309527) → 垃圾邮件

分类：决策树

- 回顾第一章的例子

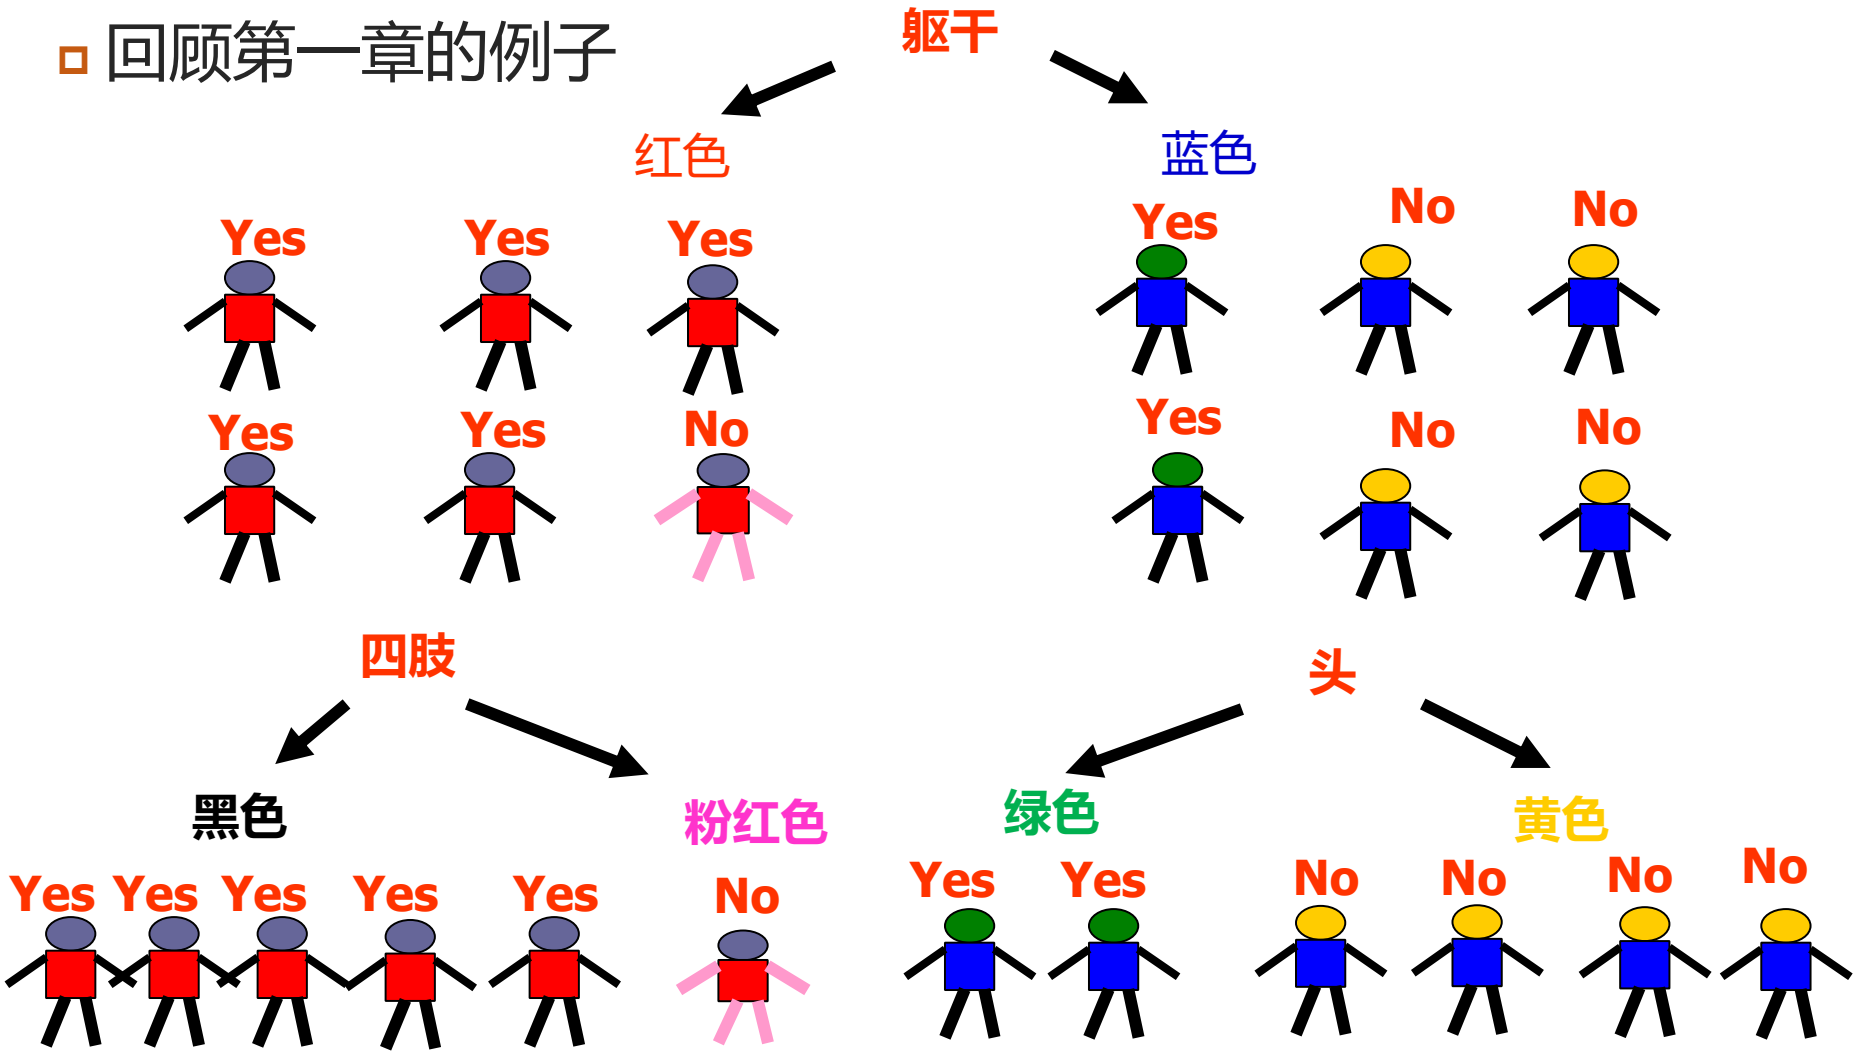

分类：决策树

- 什么是决策树
  - 对数据进行处理，利用归纳算法生成可读的规则
  - 模型以树状形式呈现出来

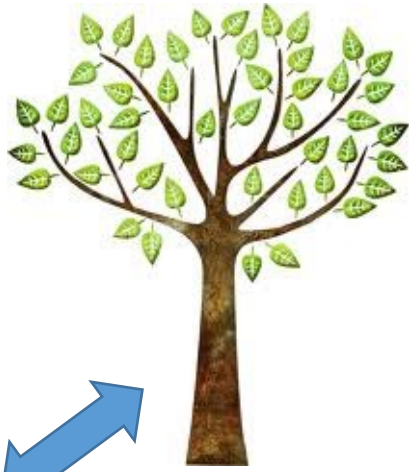

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

训练数据

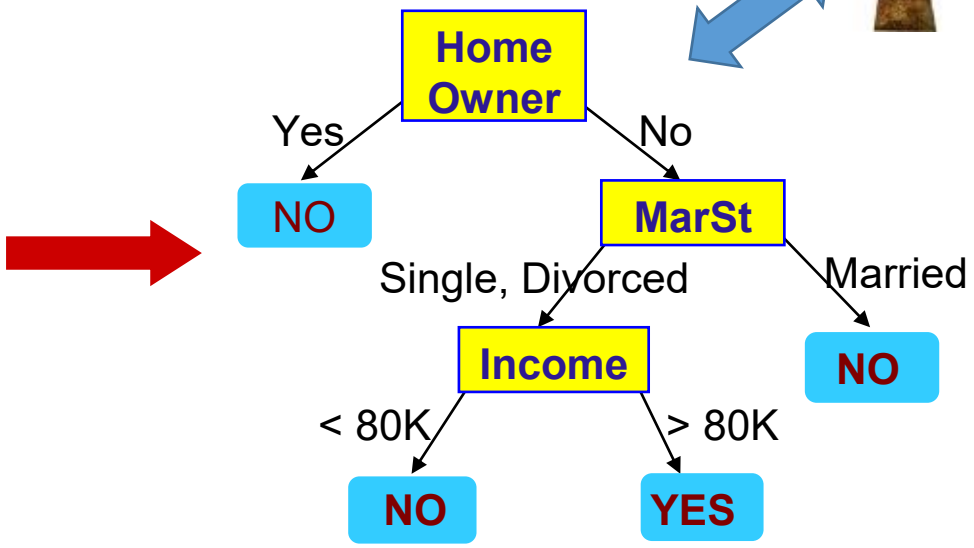

模型：决策树

分类：决策树

- 什么是决策树 —— 基本概念
  - 非叶节点：一个属性上的测试，每个分枝代表该测试的输出
  - 叶节点：存放一个类标记
  - 规则：从根节点到叶节点的一条属性取值路径
    - (HomOwn= No) ∧ (MarSt= Married) → Borrorwer=No

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

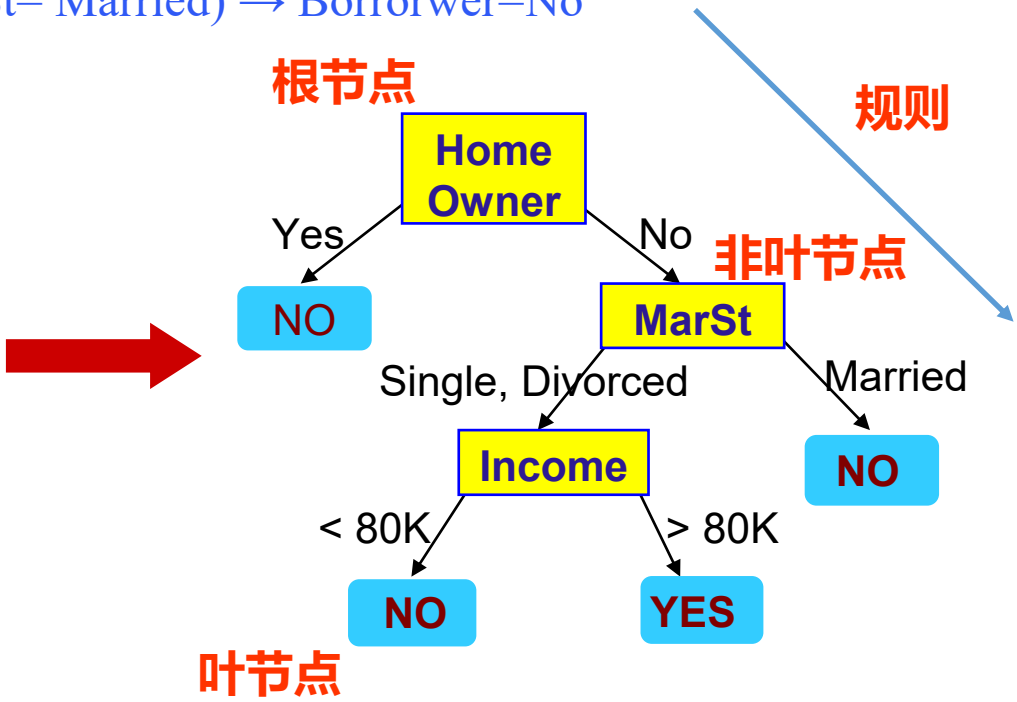

分类：决策树

- 建立决策树分类模型的流程
  - 模型训练：从已有数据中生成一棵决策树
    - 分裂数据的特征，寻找决策类别的路径

Tid	Attrib1	Attrib2	Attrib3	Class
1	Yes	Large	125K	No
2	No	Medium	100K	No
3	No	Small	70K	No
4	Yes	Medium	120K	No
5	No	Large	95K	Yes
6	No	Medium	60K	No
7	Yes	Large	220K	No
8	No	Small	85K	Yes
9	No	Medium	75K	No
10	No	Small	90K	Yes

Training Set

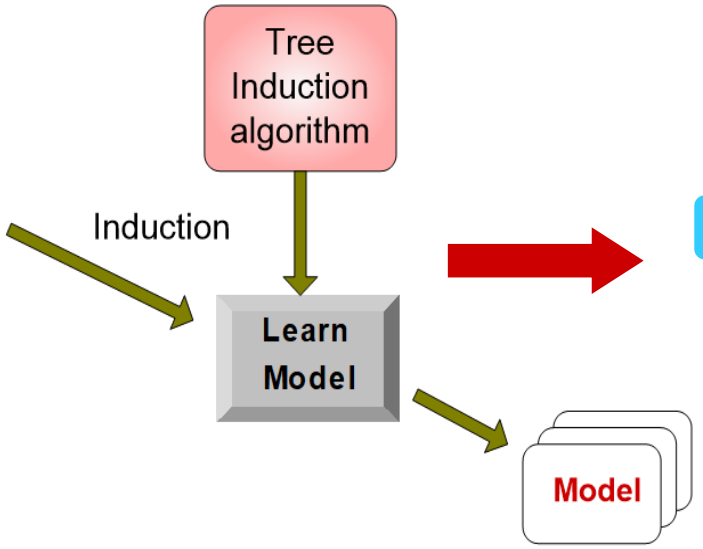

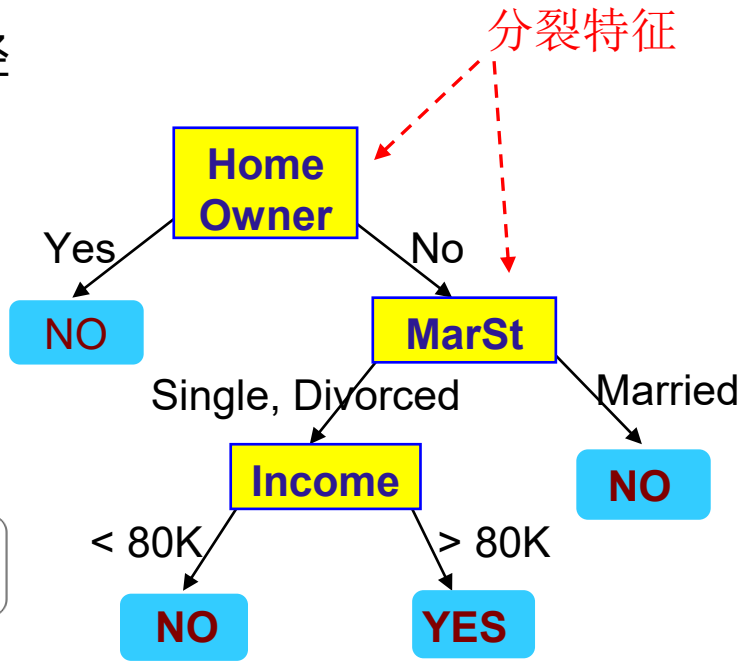

分裂特征:Home Owner, MarSt, Income

生成模型：决策树

分类：决策树

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

- 是否有其他决策树?

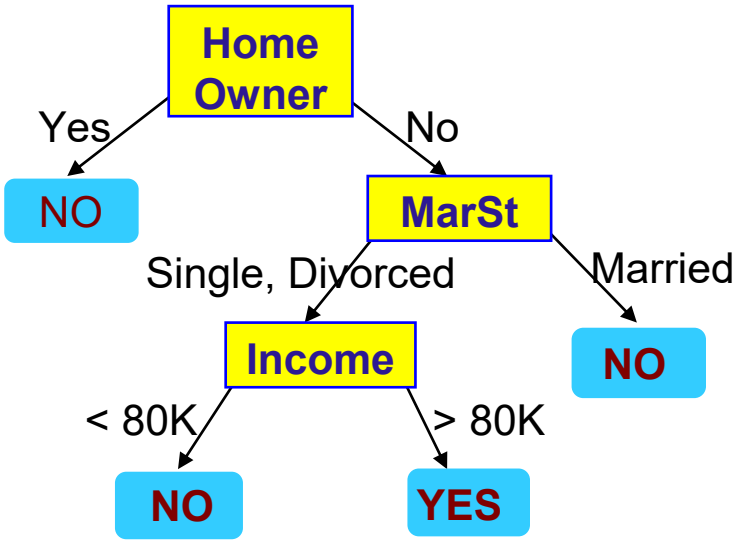

特征顺序: Home Owner, MarSt, Income

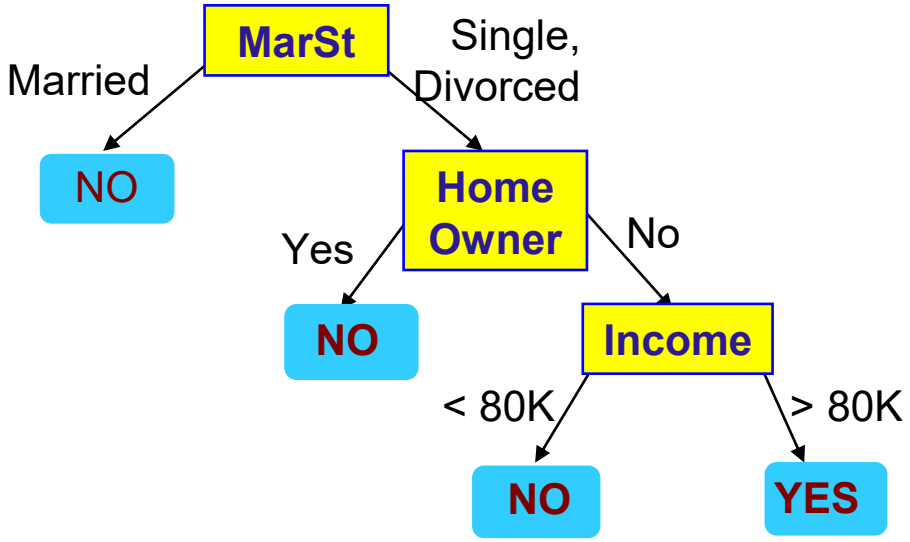

特征顺序: MarSt, Home Owner, Income

相同的数据，根据不同的特征顺序，可以建立多种决策树

分类：决策树

- 决策树分类模型的测试过程
  - 模型测试：根据规则将样本分类到某个叶子节点

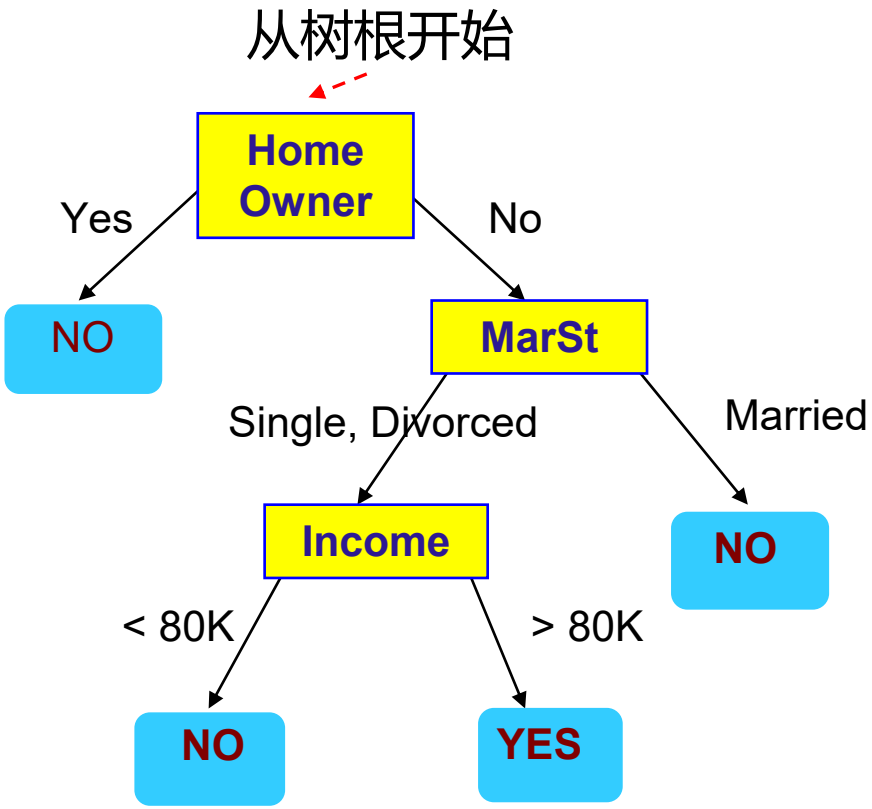

测试数据（预测标签）

Home Owner	Marital Status	Annual Income	Defaulted Borrower
No	Married	80K	?

分类：决策树

- 决策树分类模型的测试过程

测试数据（预测标签）

Home Owner	Marital Status	Annual Income	Defaulted Borrower
No	Married	80K	?

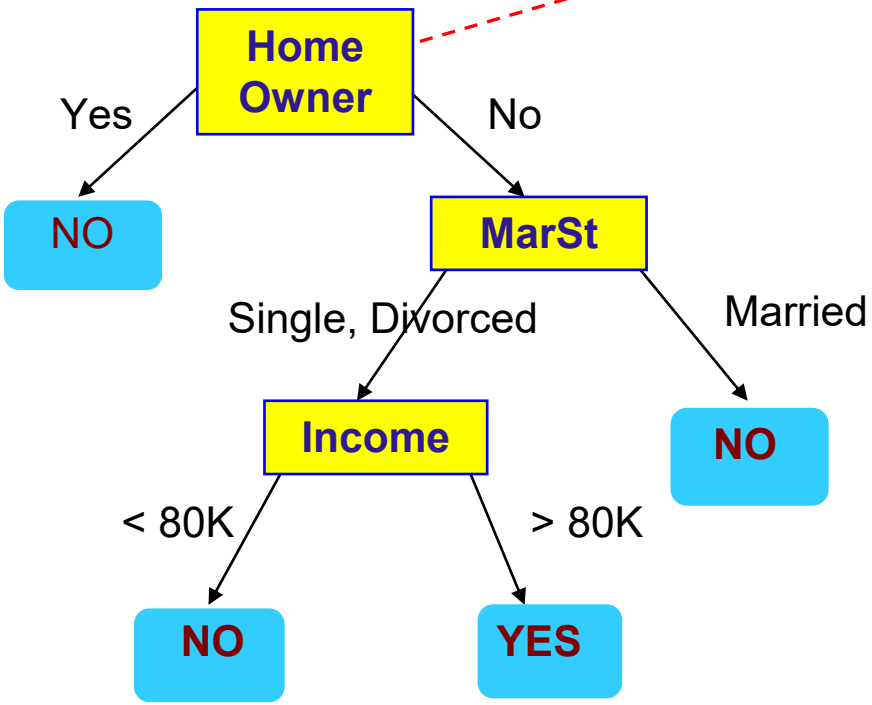

分类：决策树

- 决策树分类模型的测试过程

测试数据（预测标签）

Home Owner	Marital Status	Annual Income	Defaulted Borrower
No	Married	80K	?

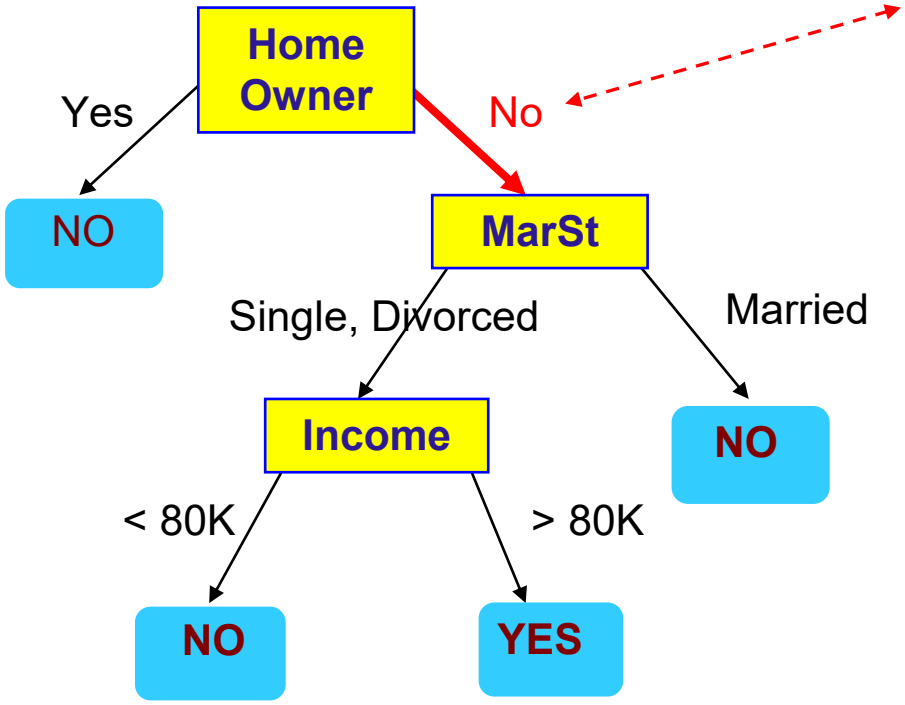

分类：决策树

- 决策树分类模型的测试过程

测试数据（预测标签）

Home Owner	Marital Status	Annual Income	Defaulted Borrower
No	Married	80K	?

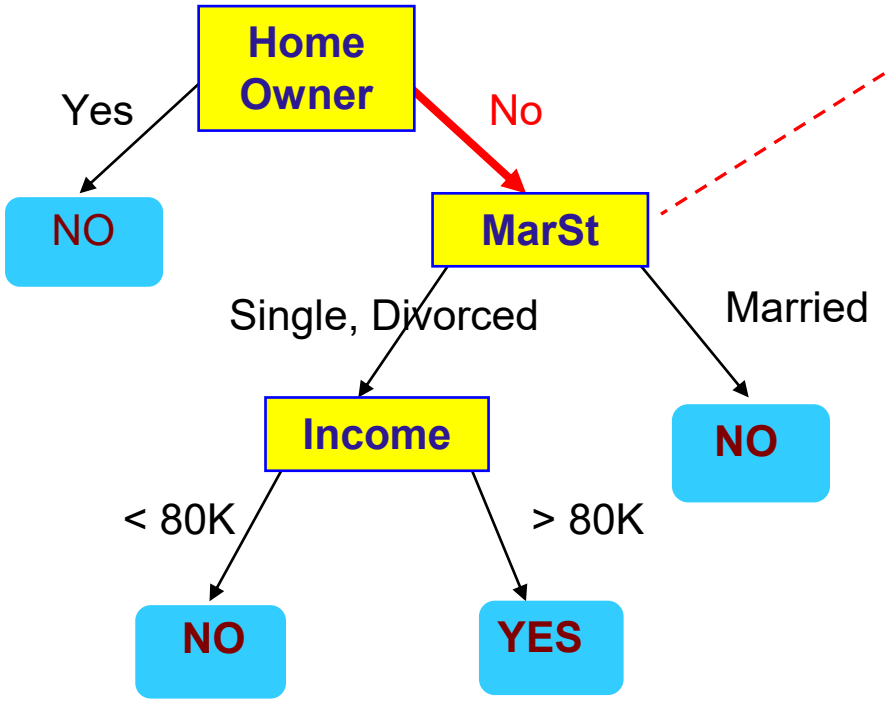

分类：决策树

- 决策树分类模型的测试过程

测试数据（预测标签）

Home Owner	Marital Status	Annual Income	Defaulted Borrower
No	Married	80K	?

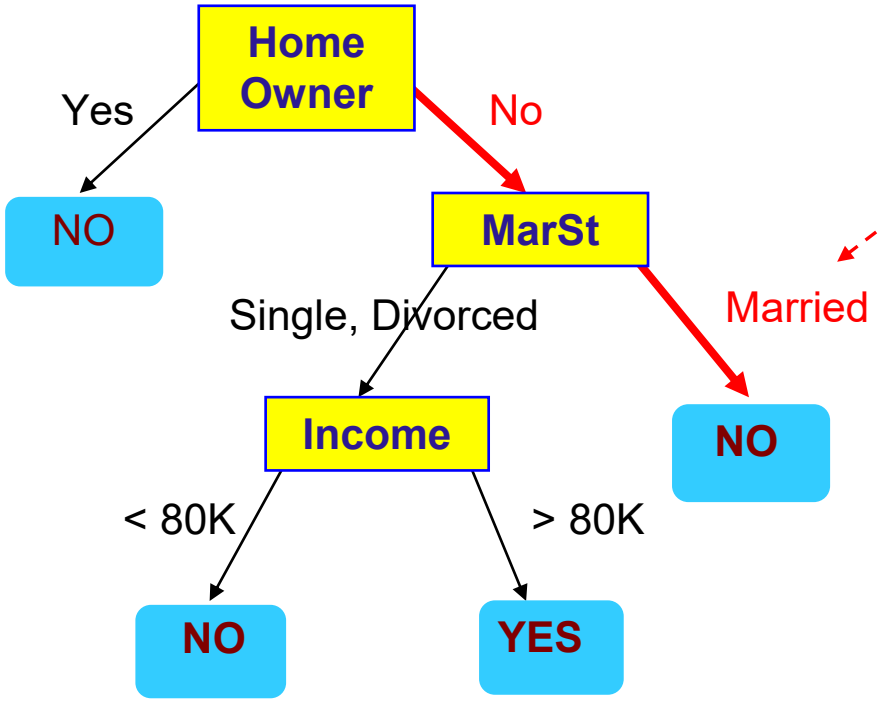

分类：决策树

- 决策树分类模型的测试过程

测试数据（预测标签）

Home Owner	Marital Status	Annual Income	Defaulted Borrower
No	Married	80K	?

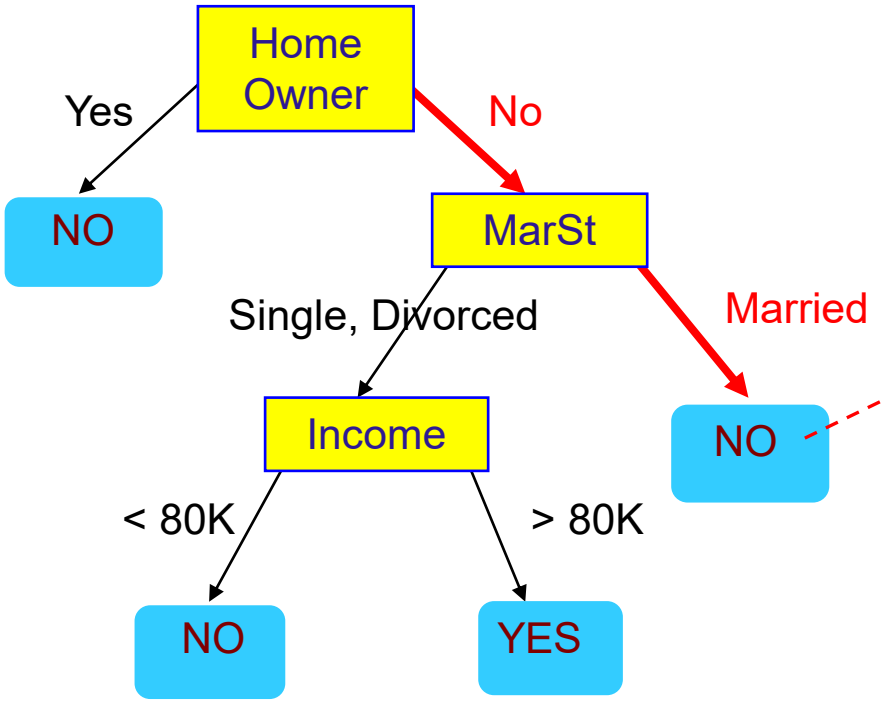

类别Defaulted Borrower 为 “No”

决策过程：未使用所有的特征/属性

分类：决策树

- 如何建立决策树?
  - 基本的决策树学习过程，可以归纳为以下三个步骤：
  - **1. 特征选择：** 选取对于训练数据有着较强区分能力的特征
  - **2. 生成决策树：** 基于选定的特征，逐步生成完整的决策树
  - **3. 决策树剪枝：** 简化部分枝干，避免过拟合因素影响

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

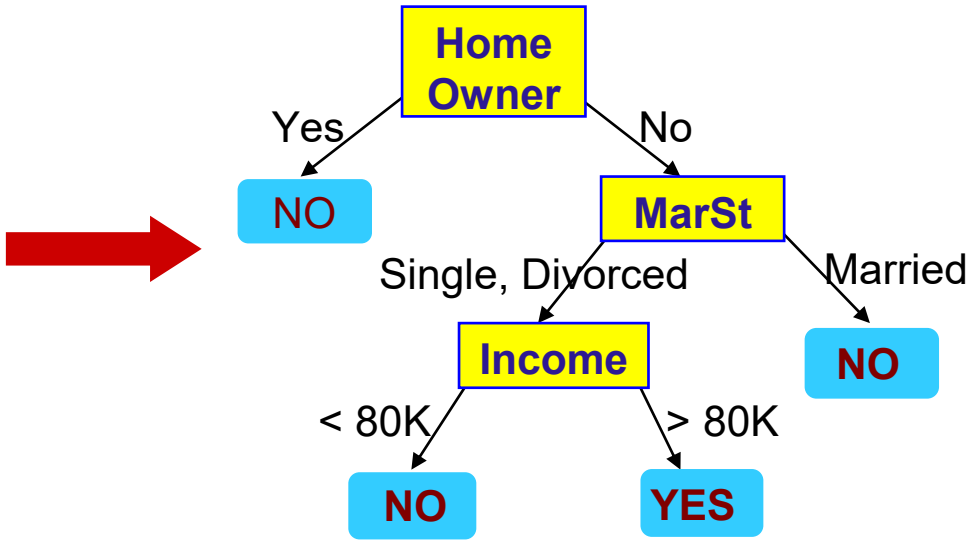

分类：决策树

- 1. 特征选择
  - 决策树的基本思想：特征分裂
  - 初始节点包含所有的数据样本，我们希望这些样本能划分到同个类里，如defaulted=No
  - 但往往不成立，因此通过选择特征和取值，将样本集合不断划分

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

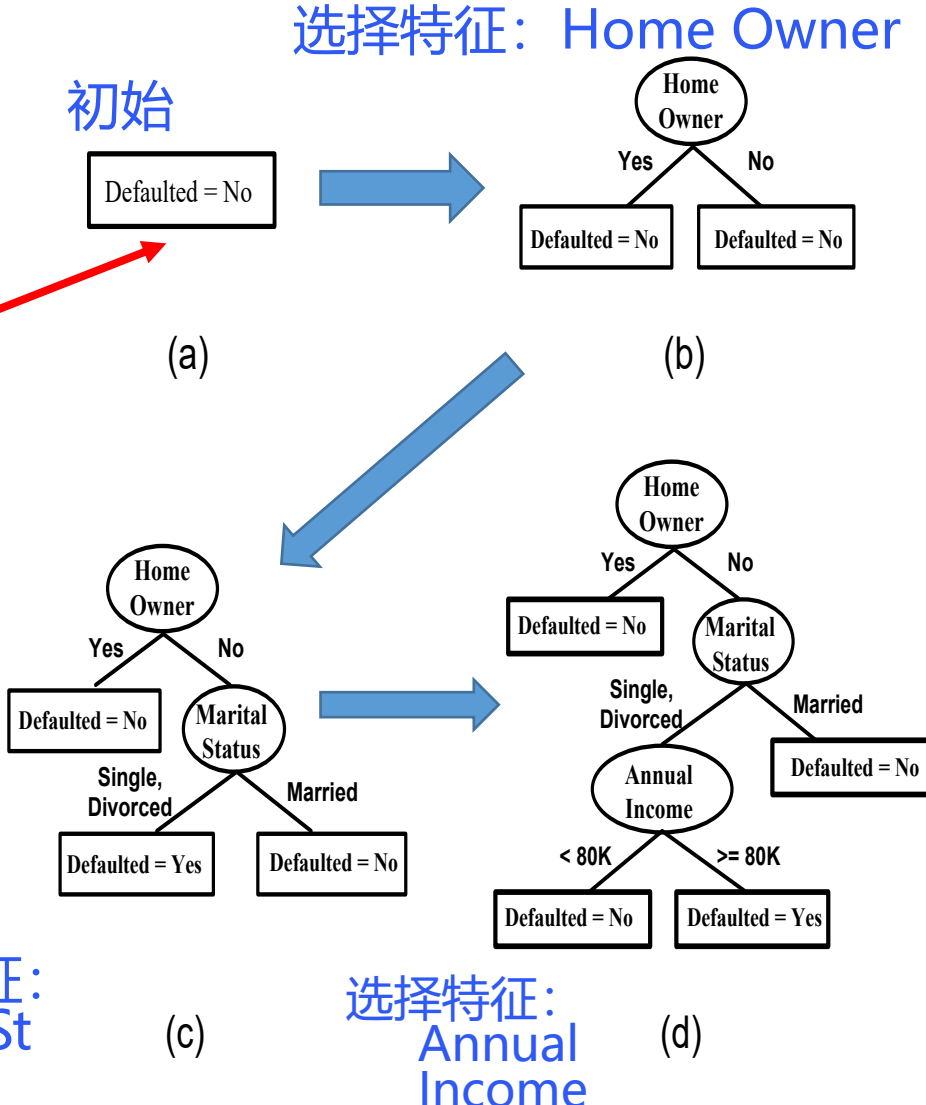

分类：决策树

ID	Home Owner	Marital Status	Annual Income	Defaulted Borrower
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

- **1. 特征选择：** 分裂思想的形式化
- Hunt贪心算法
  - D_t：为树中结点t的所有训练样本
  - 若D_t 中的样本属于同一类别y_t, 则t 作为叶子节点，标签为y_t
  - 若D_t 中的样本不属于同一类别, 则根据某特征将D_t 分为更小的样本集
  - 重复上述过程

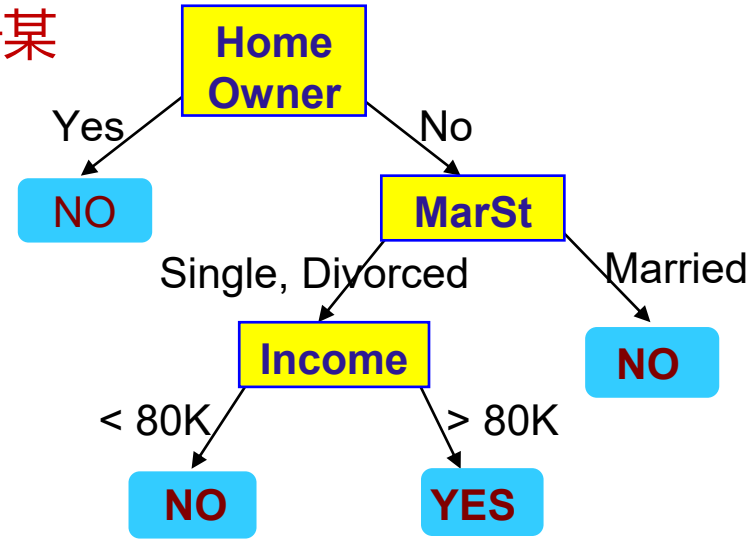

分类：决策树

- **1. 特征选择：** 分裂过程的形式
  - 多路分裂(Multi-way split)
    - 不同取值均作为一个子集
  - 二分裂(Binary split)
    - 只划分两个子集
    - 需找到最优划分方法

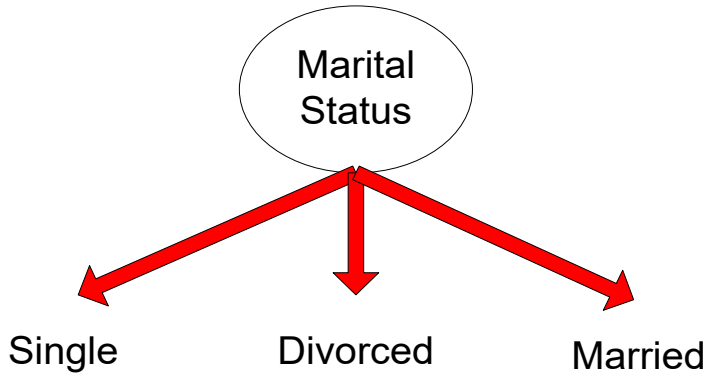

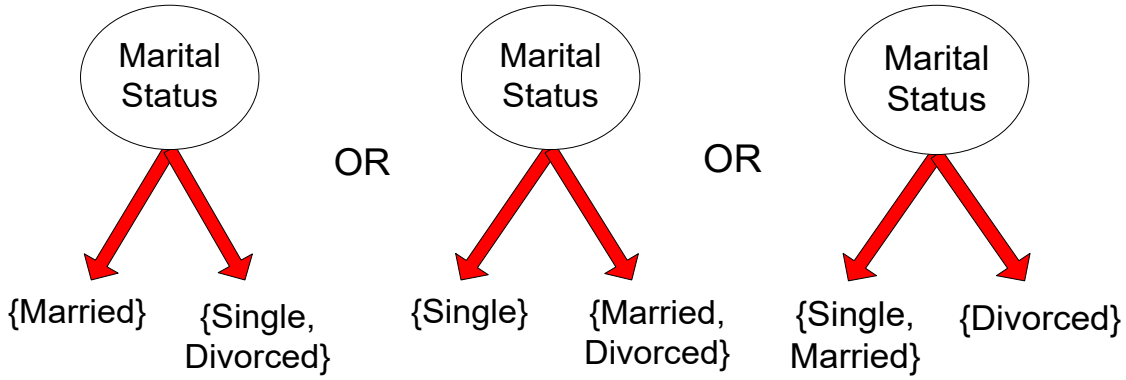



分类：决策树

- **1. 特征选择：**分裂过程的两个问题
  - 训练样本如何分裂?
    - 选择分裂特征
    - 评价测试条件
  - 分裂过程何时停止?
    - 理想终止
      - 如果所有记录属于同一类
      - 所有数据有相同的属性值
    - 提前终止

决策树特征选择

- 问题1：如何选择分裂特征？
  - 例子：右图的数据
    - 10个记录类别为0
    - 10个记录类别为1

Customer Id	Gender	Car Type	Shirt Size	Class
1	M	Family	Small	C0
2	M	Sports	Medium	C0
3	M	Sports	Medium	C0
4	M	Sports	Large	C0
5	M	Sports	Extra Large	C0
6	M	Sports	Extra Large	C0
7	F	Sports	Small	C0
8	F	Sports	Small	C0
9	F	Sports	Medium	C0
10	F	Luxury	Large	C0
11	M	Family	Large	C1
12	M	Family	Extra Large	C1
13	M	Family	Medium	C1
14	M	Luxury	Extra Large	C1
15	F	Luxury	Small	C1
16	F	Luxury	Small	C1
17	F	Luxury	Medium	C1
18	F	Luxury	Medium	C1
19	F	Luxury	Medium	C1
20	F	Luxury	Large	C1

对不同特征属性进行分裂

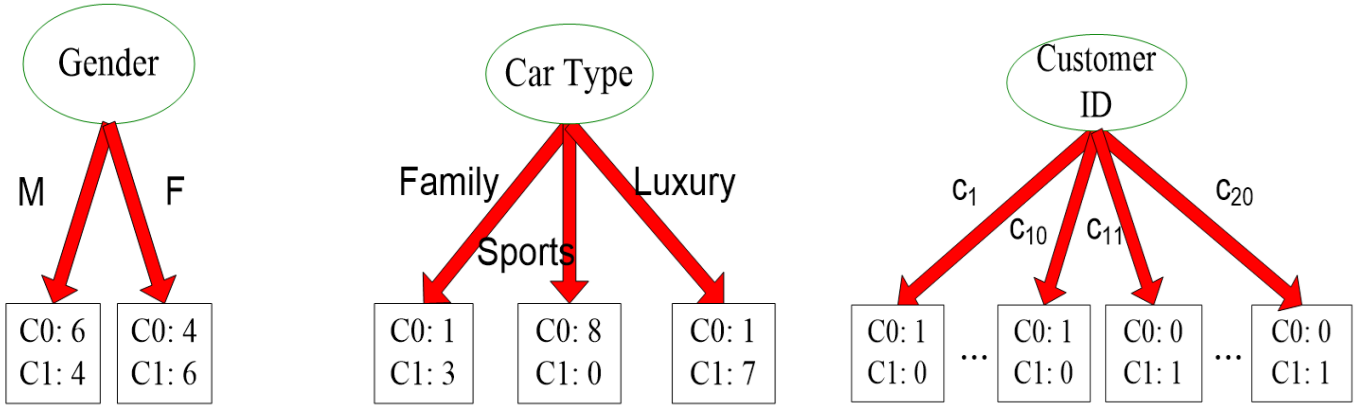

哪一种分裂方式最优？

决策树特征选择

- 问题1：如何选择分裂特征？
  - 目标：选取对于训练数据有着**较强区分能力**的特征
    - 如果某特征分类的结果与随机结果没有很大的差别，则称这个特征是没有分类能力的，扔掉这样的特征对学习的精度影响不大
  - 常用特征选择准则
    - 信息增益 → 回顾第二章：数据离散化
    - 信息增益率
    - 基尼指数



决策树特征选择

- 信息增益：信息熵（回顾第二章）
  - 信息熵：计算数据的不确定性

$$Entropy(t) = -\sum_{j} p(j|t) \log p\,(j|t)$$

  - 此时：表示某个节点t （即某个特征）的信息不确定性
    - $p(j \mid t)$ 是节点特征t的属于类别j的样本的比例

- 特点：对于该节点特征t
  - 当样本均匀地分布在各个类别时，熵达到最大值 $\log(n_c)$, 此时包含的信息最少
  - 当样本只属于一个类别时，熵达到最小值 0, 此时包含的信息最多

决策树特征选择

- 计算 某个节点 特征的信息熵（回顾第二章）

$$Entropy(t) = -\sum_{j} p(j|t) \log_2 p(j|t)$$

C1	**0**
C2	**6**

P(C1) = 0/6 = 0　　P(C2) = 6/6 = 1

Entropy = – 0 log 0 – 1 log 1 = – 0 – 0 = 0

C1	**1**
C2	**5**

P(C1) = 1/6　　P(C2) = 5/6

Entropy = – (1/6) $\log_2$ (1/6) – (5/6) $\log_2$ (1/6) = 0.65

C1	**2**
C2	**4**

P(C1) = 2/6　　P(C2) = 4/6

Entropy = – (2/6) $\log_2$ (2/6) – (4/6) $\log_2$ (4/6) = 0.92

决策树特征选择：信息增益

- 特征选择准则一：信息增益
  - 信息增益: 按某个特征划分之后，数据不确定性降低的程度

$$GAIN(m) = Entropy(p) - \left(\sum_{i=1}^{k} \frac{n_i}{n} Entropy(i) \right)$$

  - 第一项表示数据未划分时的信息熵
  - 第二项表示按特征m划分后，数据的信息熵
    - 按特征m划分后，父节点分裂成k个子节点
    - n表示父节点的样本个数
    - n_i 表示子节点i的样本个数

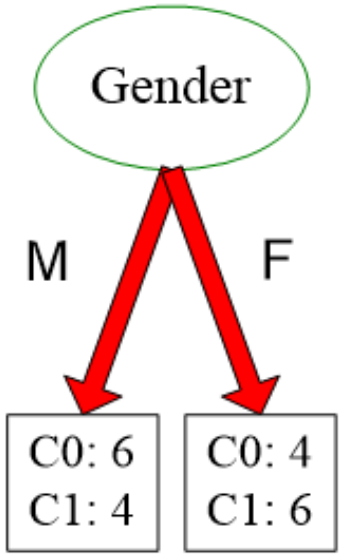

- 选择准则：选择最大的$GAIN$ 对应的特征m

信息增益在ID3和C4.5决策树算法中被应用

决策树特征选择：信息增益

- 特征选择准则—: 信息增益
  - 选择A或B两个特征构造节点，哪种方式好?

特征A	Yes	Yes	No	…	No	No
特征B	No	Yes	Yes	…	Yes	No
类别	C0	C0	C1		C1	C1

$Entropy(p)$

以特征A划分

特征A	Yes	Yes
特征B	No	Yes
类别	C0	C0

特征A	No	…	No	No
特征B	Yes	…	Yes	No
类别	C1		C1	C1

$Entropy(A_{Yes})$ $Entropy(A_{No})$

$$M = \frac{|A_{Yes}|}{n} Entropy(A_{Yes}) + \frac{|A_{No}|}{n} Entropy(A_{No})$$

$$Gain(A) = Entropy(p) - M$$

决策树特征选择：信息增益

- 特征选择准则—: 信息增益
  - 选择A或B两个特征构造节点，哪种方式好?

特征A	Yes	Yes	No	…	No	No
特征B	No	Yes	Yes	…	Yes	No
类别	C0	C0	C1		C1	C1

$Entropy(p)$

以特征B划分

特征A	Yes	No	…	No
特征B	Yes	Yes	…	Yes
类别	C0	C1		C1

特征A	Yes	No
特征B	No	No
类别	C0	C1

$Entropy(B_{Yes})$ $Entropy(B_{No})$

$$M = \frac{|B_{Yes}|}{n} Entropy(B_{Yes}) + \frac{|B_{No}|}{n} Entropy(B_{No})$$

$$Gain(B) = Entropy(p) - M \quad < \quad Gain(A)$$

决策树特征选择：信息增益

- 特征选择准则一：信息增益
- **结论：**信息增益能够较好地体现某个特征在降低信息不确定性方面的贡献
  - 信息增益越大，说明信息纯度提升越快，最后结果的不确定性越低
- **不足：**信息增益的局限性，尤其体现在更偏好可取值较多的特征
  - 取值较多，不确定性相对更低，因此得到的熵偏低

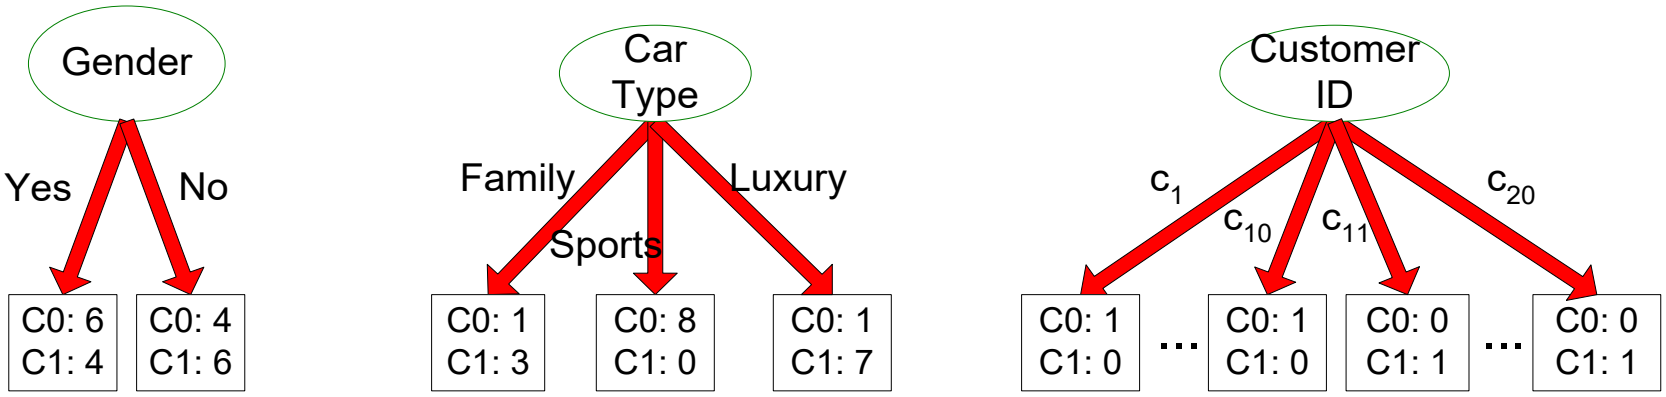

特征Customer ID有最大的信息增益，因为每个子节点的熵均为0

决策树特征选择：信息增益率

- 特征选择准则二：信息增益率
  - 信息增益率(Gain ratio): 综合考虑划分结果信息增益和划分数量的信息

$$GAIN_{ratio(m)} = \frac{GAIN(m)}{IV}, \qquad IV = -\left(\sum_{i=1}^{k} \frac{n_i}{n} log_2 \frac{n_i}{n}\right)$$

  - 相比于信息增益，增加了一个惩罚项IV, 考虑产生划分的数量带来的划分信息
  - 即，若某个特征产生的划分数量很大，则划分信息很大，降低增益率

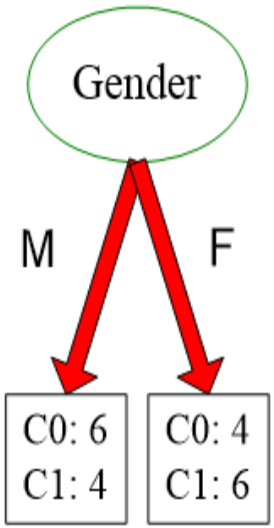

- 选择准则：选择最大的 信息增益率 对应的特征m

信息增益率在C4.5决策树算法中被应用

决策树特征选择：信息增益率

- 特征选择准则二：信息增益率
  - 结论：信息增益率有矫枉过正的危险
    - 采用信息增益率的情况下，往往倾向于选择取值较少的特征
    - 当特征的取值较少时，IV较小，因此惩罚项相对较小
  - 实际应用中，通常采用折中的方法
    - 先从候选特征中，找到信息增益高于平均水平的集合
    - 再从这一集合中，找到信息增益率最大的特征

决策树特征选择：基尼指数

- 特征选择准则三：基尼指数
  - 基尼指数的目的，在于表示样本集合中一个随机样本被分错的概率
  - 基尼指数越低，表明被分错的概率越低，相应的信息纯度也就越高
  - 计算特征节点t的基尼指数：

$$GINI(t) = 1 - \sum_{j} [p(j|t)]^2$$

    - $p(j \mid t)$ 是特征节点t上属于类别j的样本的比例

- 特点：对于该节点特征t
  - 当样本均匀地分布在各个类别时，基尼指数达到最大值 $1 - \frac{1}{n_c}$, 此时包含的信息最少
  - 当样本只属于一个类别时，基尼指数达到最小值 0, 此时包含的信息最多

决策树特征选择：基尼指数

- 计算 某个节点 特征的 基尼指数

$$GINI(t) = 1 - \sum_j [p(j \mid t)]^2$$

C1	**0**
C2	**6**

P(C1) = 0/6 = 0　　P(C2) = 6/6 = 1

Gini = 1 – P(C1)^2 – P(C2)^2 = 1 – 0 – 1 = 0

C1	**1**
C2	**5**

P(C1) = 1/6　　P(C2) = 5/6

Gini = 1 – (1/6)^2 – (5/6)^2 = 0.278

C1	**2**
C2	**4**

P(C1) = 2/6　　P(C2) = 4/6

Gini = 1 – (2/6)^2 – (4/6)^2 = 0.444

决策树特征选择：基尼指数

- 特征选择准则三：基尼指数
  - 当一个特征节点p 分裂成 k 个子节点（如两个子节点）

$$GINI_{split} = \sum_{i=1}^{k} \frac{n_i}{n} GINI(i)$$

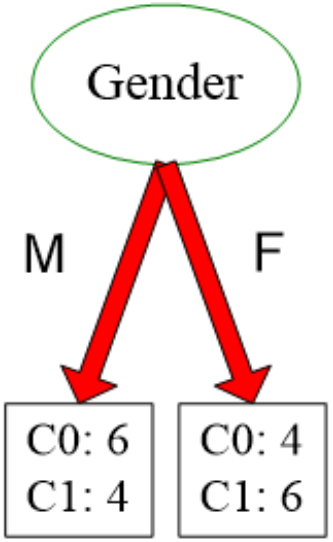

    - n表示父节点的样本个数
    - n_i 表示子节点i的样本个数
  - 选择准则：选择最大的GINI 对应的特征m

基尼指数在CART, SLIQ, SPRINT等决策树算法中被应用

决策树特征选择：基尼指数

- 基尼指数计算示例

分裂前：

	Parent
C1	6
C2	6
Gini = 0.500	

$$GINI(t) = 1 - \sum_j [p(j \mid t)]^2$$

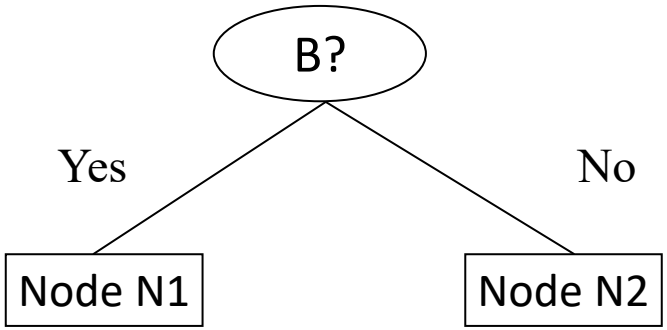

$$GINI_{split} = \sum_{i=1}^{k} \frac{n_i}{n} GINI(i)$$

	N1	N2
C1	5	2
C2	1	4
Gini=0.361		

Gini(N1)
= 1 – $(5/6)^2$ – $(1/6)^2$
= 0.278

Gini(N2)
= 1 – $(2/6)^2$ – $(4/6)^2$
= 0.444

分裂后：

Gini(Children)
= 6/12 * 0.278 +
6/12 * 0.444
= 0.361

决策树特征选择

- 决策树特征选择：连续属性的分裂
  - 将连续属性进行离散化
    - 最简单：人为划分一次，如设定收入的阈值
    - 通过等间隔分段、等频率分段(百分位数)或聚类找到划分位置
    - 利用算法二分离散化考虑所有情况，找出最好的划分

回顾第二章知识：基于熵的数据离散化

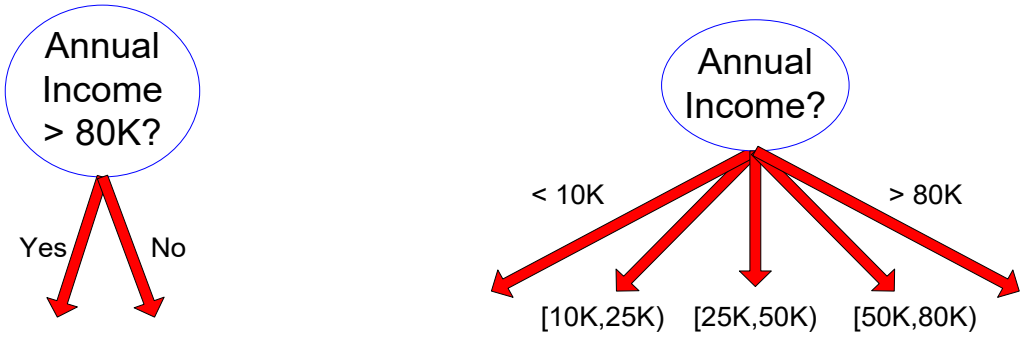

(i) Binary split　　(ii) Multi-way split