



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

1

# 数据科学导论

## Introduction to Data Science

### 第二章 数据分析基础

黄振亚, 陈恩红

Email: [huangzhy@ustc.edu.cn](mailto:huangzhy@ustc.edu.cn), [cheneh@ustc.edu.cn](mailto:cheneh@ustc.edu.cn)

课程主页:

<http://staff.ustc.edu.cn/~huangzhy/Course/DS2024.html>



# 回顾：数据分析基础

2

- 数据采集 Data Collection
- 数据存储 Data Storage
- 数据预处理 Data Preprocessing
- 特征工程 Feature Engineering





# 数据预处理

3

- 大数据环境下的数据特征
- 为什么需要进行预处理
- **预处理的基本方法**
  - 数据清理
  - 数据集成
  - **数据变换**
  - 数据规约



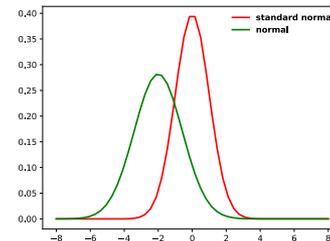
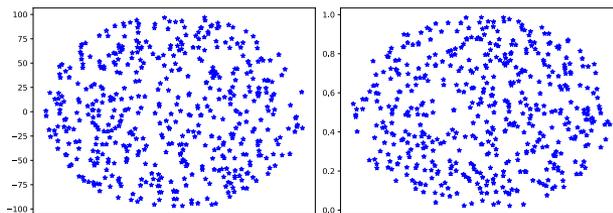
# 数据预处理：数据变换

## 数据变换的目的是将数据转换成适合分析建模的形式

前提条件：尽量不改变原始数据的规律

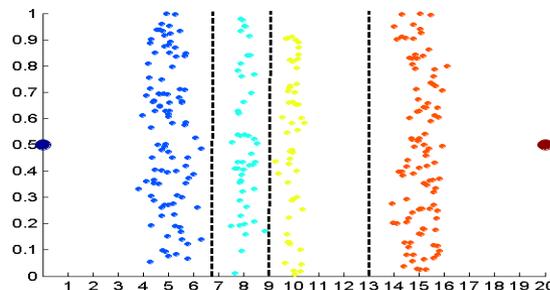
### 数据规范化

- 最小-最大规范化
- z-score规范化
- 小数定标规范化



### 数据离散化

- 非监督离散化
- 监督离散化



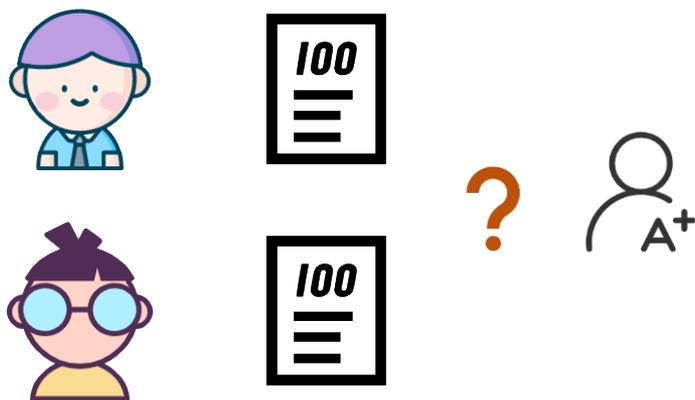


# 数据预处理：数据变换

5

## □ 数据规范化

- 目的：将不同数据（属性）按一定规则进行缩放，使它们具有可比性
- 例如，我们需要考察学生A和学生B的某门课程成绩。A的考试满分是100分（及格60分），B的考试满分是150分（及格90分）。显然，A和B的100分代表着完全不同的含义。



如何用一个同等的标准来比较A与B的成绩数据呢？



# 数据变换-规范化

6

## □ 最小-最大规范化

- 对原始数据进行线性变换。把数据A的观察值 $v$ 从原始的区间 $[\min_A, \max_A]$ 映射到新区间 $[\text{new\_min}_A, \text{new\_max}_A]$ 
  - 0-1规范化又称为归一化

$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{new\_max}_A - \text{new\_min}_A) + \text{new\_min}_A$$

- 数理依据:

$$\frac{v' - \text{new\_min}_A}{\text{new\_max}_A - \text{new\_min}_A} = \frac{v - \min_A}{\max_A - \min_A}$$



# 数据变换-规范化

7

## □ 最小-最大规范化

$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{new\_max}_A - \text{new\_min}_A) + \text{new\_min}_A$$

- 例：假设某属性规范化前的取值区间为 $[-100, 100]$ ，规范化后的取值区间为 $[0, 1]$ ，采用最小-最大规范化 66，得

$$v' = \frac{66 - (-100)}{100 - (-100)} (1 - 0) + 0 = 0.83$$

**快速练习：采用最小-最大规范化 -80 ？**



# 数据变换-规范化

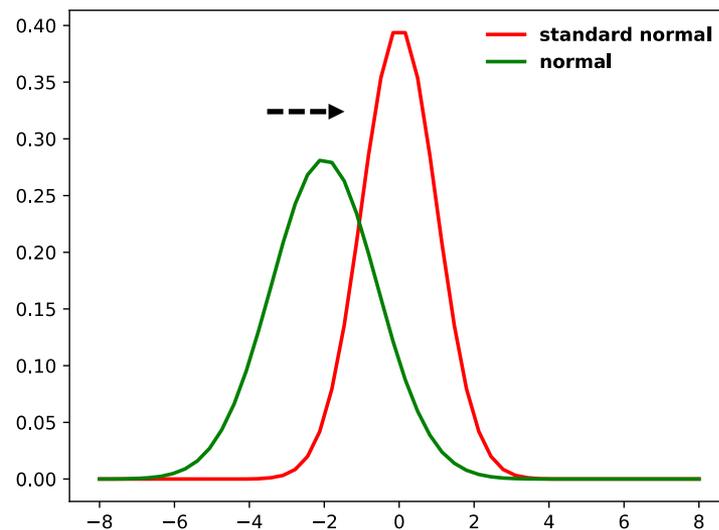
## □ z-score规范化

- 最大最小值未知，或者离群点影响较大时，假设数据服从正态分布
  - 某一原始数据 ( $v$ ) 与原始均值的差再除以标准差，可以衡量某数据在分布中的相对位置

$$v' = \frac{v - \bar{A}}{\sigma_A}$$

- 例：假设某属性的平均值、标准差分别为80、25，用z-score规范化 66

$$v' = \frac{66 - 80}{25} = -0.56$$





# 数据变换-规范化

11

## □ 小数定标规范化

- 通过移动小数点的位置来进行规范化。小数点移动多少位取决于属性A的取值中的最大绝对值。

$$v' = \frac{v}{10^j} \quad \text{其中, } j \text{ 是使 } \text{Max}(|v'|) < 1 \text{ 的最小整数}$$

- 比如属性A的取值范围是-999到88，那么最大绝对值为999，小数点就会移动3位，即新数值=原数值/1000。那么A的取值范围就被规范为-0.999到0.088。



# 数据变换-规范化

12

## □ 小结

	优点	缺点	适用场景
<b>最小-最大规范化</b>	保留了原始数据中存在的关系，是消除量纲和数据取值范围影响的最简单方法	对最大最小值敏感，新数据加入时，可能改变最大最小值，需重新计算	适用于原始数据不存在很大/很小的一部分数据的时候
<b>z-score 规范化</b>	算法简单方便，结果方便比较，应用于数值型的数据，且不受数据量级的影响	总体平均值和方差不一定可知，在一定程度上要求数据分布，结果没有具体意义，只用于比较	适用于最大最小值未知，或者离群点影响较大的时候
<b>小数定标规范化</b>	算法实现简单	不适用于不同含义数据的比较，无实际意义	使用含义相同的数据，且最大最小相差较大



# 数据预处理：数据变换

13

## □ 数据离散化

- 连续数据过于细致，数据之间的关系难以分析
- 划分为离散化的区间，发现数据之间的关联，便于算法处理
  - 同学们成绩：100分制分数使用五分制离散化表示
    - A（大于等于85分），B，C，D，F（小于60分）
  - 人的年龄：离散化为不同的年龄段（引源自世卫组织）
    - 未成年人：0至17岁；
    - 青年人：18岁至45岁；
    - 中年人：46岁至69岁；
    - 老年人：大于70岁。
  - 一年365天：离散化表示为12个月份或四个季节

A+	A	A-
B+	B	B-
C+	C	C-
D+	D	D-
	F	





# 数据变换-离散化

14

## □ 数据离散化

- 连续数据过于细致，数据之间的关系难以分析，将其分段为离散化的区间，发现数据之间的关联，便于算法处理
- 非监督离散化（无类别信息）
- 有监督离散化（有类别信息）



# 数据变换-离散化

15

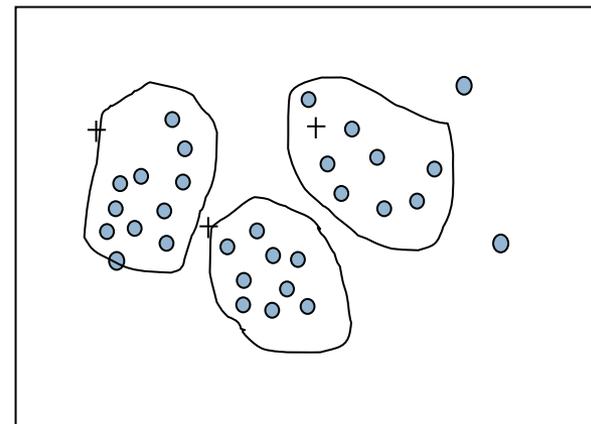
## □ 非监督离散化 (参考上一节内容: **数据清理-噪声数据**)

### □ 分箱

- 1. 排序数据, 并将他们分到等深的箱中
- 2. 按箱平均值平滑、按箱中值平滑、按箱边界平滑等

### □ 聚类: 监测并且去除噪声数据

- 将类似的数据聚成簇
- 每个簇计算一个值用以将该簇的数据离散化





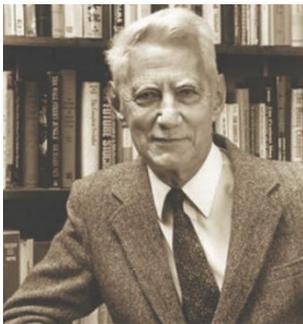
# 数据变换-离散化

16

## □ 有监督离散化—基于熵的离散化

### ■ 熵用来度量系统的**不确定程度**

- 熵是由 克劳德·艾尔伍德·香农 将热力学的熵，引入到信息论，因此它又被称为香农熵



香农提出了信息熵的概念，为**信息论**和**数字通信**奠定了基础，被誉为“**信息论之父**”



# 数据变换-离散化

17

## □ 信息熵：度量系统的不确定程度

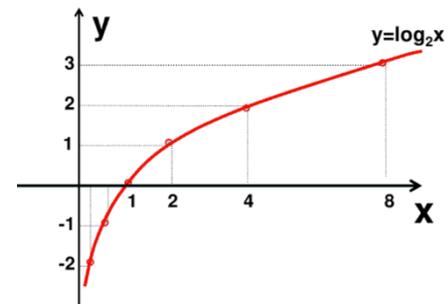
### □ 信息量

- 定义一个事件 $x$ 的概率分布为 $P(x)$
- 则事件 $x$ 的自信息量是 $-\log P(x)$ , 取值范围:  $[0, +\infty]$

### □ 信息熵

- 平均而言, 发生一个事件得到的自信息量大小
- 即: 熵可以表示为自信息量的期望

$$H = - \sum P(x) \log P(x)$$



$x$	0	1
$P(x)$	0.4	0.6

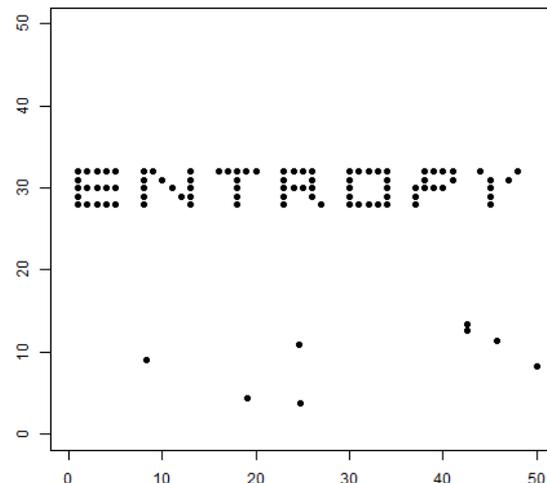
$$\begin{aligned} H(P) &= -P(X=0)\log_2 P(X=0) - P(X=1)\log_2 P(X=1) \\ &= -0.4 * \log_2(0.4) - 0.6 * \log_2(0.6) \\ &\approx 0.97 \end{aligned}$$



# 数据变换-离散化

## 熵与数据离散化有什么关系？——**不确定程度**

- 数据点单词 (ENTROPY) **完整**的时候，容易理解表达的意思，**确定程度较高**，对应的**信息熵也较小**。
- 数据点被完全打乱的时候，难以理解其意思，造成**不确定性**也就多了，对应的**信息熵也变大了**。
- 目标：对数据进行离散化后，每个区间的数据的确定性（也称“纯度”）更高因此用熵来对数据进行离散化。

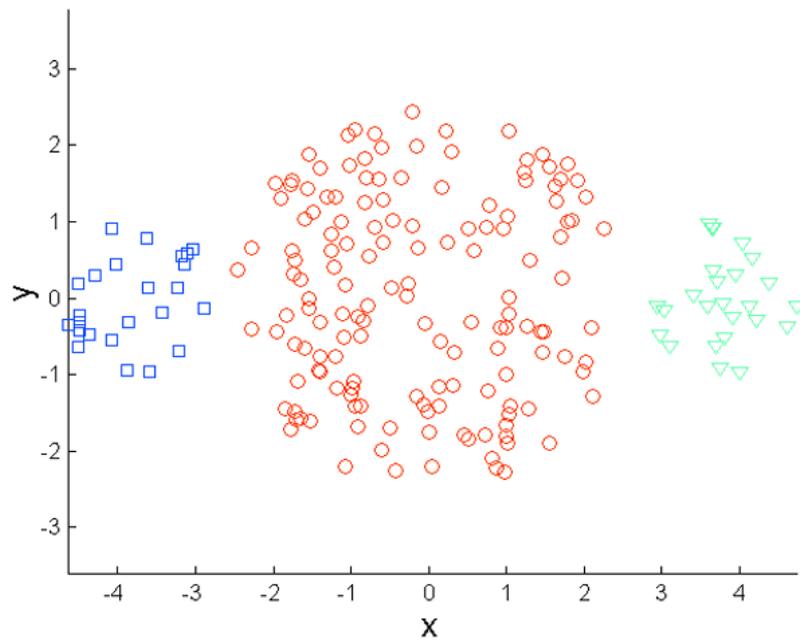




# 数据变换-离散化

19

- 基于熵的离散化
  - 在x轴上对数据划分



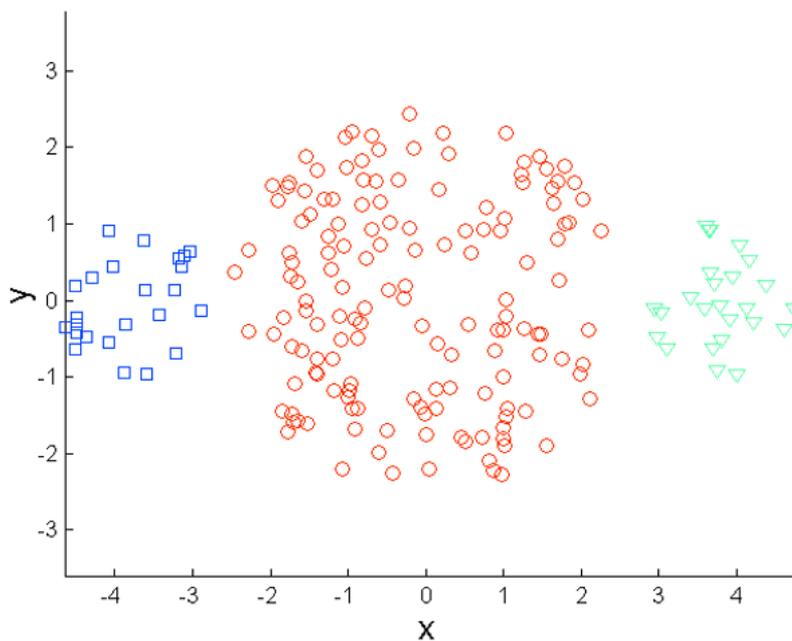
原始数据



# 数据变换-离散化

20

- 基于熵的离散化
  - 在x轴上对数据划分



原始数据



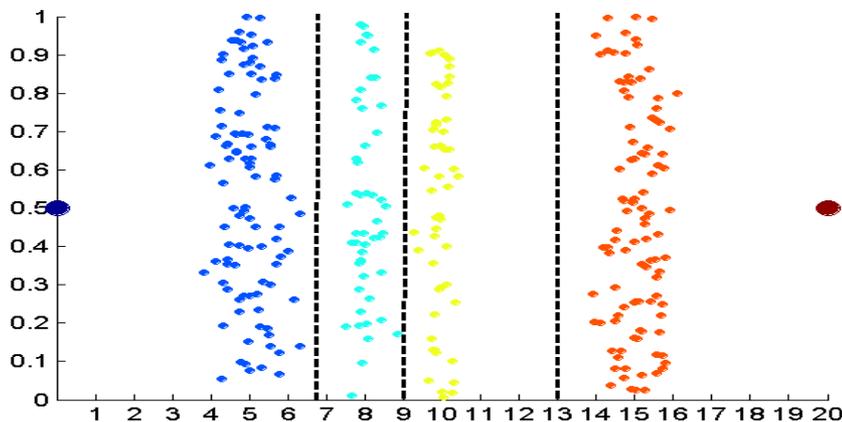
# 数据变换-离散化

21

- 熵—计算不确定性以及不纯性
  - 假设数据已经离散，计算离散后的某个区间  $t$  中的熵:

$$Entropy(t) = -\sum_j p(j|t) \log p(j|t)$$

- 其中， $p(j|t)$  表示第  $j$  类在区间  $t$  中的概率；一般对数  $\log$  以 2 为底





# 数据变换-离散化

## 计算 单个区间 的 Entropy

$$Entropy(t) = -\sum_j p(j | t) \log_2 p(j | t)$$

C1	0
C2	6

$$P(C1) = 0/6 = 0 \quad P(C2) = 6/6 = 1$$

$$Entropy = -0 \log_2 0 - 1 \log_2 1 = -0 - 0 = 0$$

C1	1
C2	5

$$P(C1) = 1/6 \quad P(C2) = 5/6$$

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

C1	2
C2	4

$$P(C1) = 2/6 \quad P(C2) = 4/6$$

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

- 练习:**
- (1) 假设区里t里面C1和C2的样本数各为3, Entropy是多少? 1
  - (2) 假设区间t里面有4个类, 且样本数一样, Entropy是多少? 2
  - (3) 假设区间t里面有C个类, 且样本数一样, Entropy是多少? logC



# 数据变换-离散化

23

- 熵—计算不确定性以及不纯性
  - 假设数据已经离散，计算离散后的某个区间  $t$  中的熵：

$$Entropy(t) = -\sum_j p(j|t) \log p(j|t)$$

- 其中， $p(j|t)$  表示第  $j$  类在区间  $t$  中的概率；一般对数  $\log$  以 2 为底
- 区间里面不同类别的样本均匀分布时，熵值最大（最不确定、最不纯），熵值为： $\log C$
- 区间里面只有一类样本时，熵值最小（最确定、最纯）
- 熵的取值范围： $[0, \log C]$

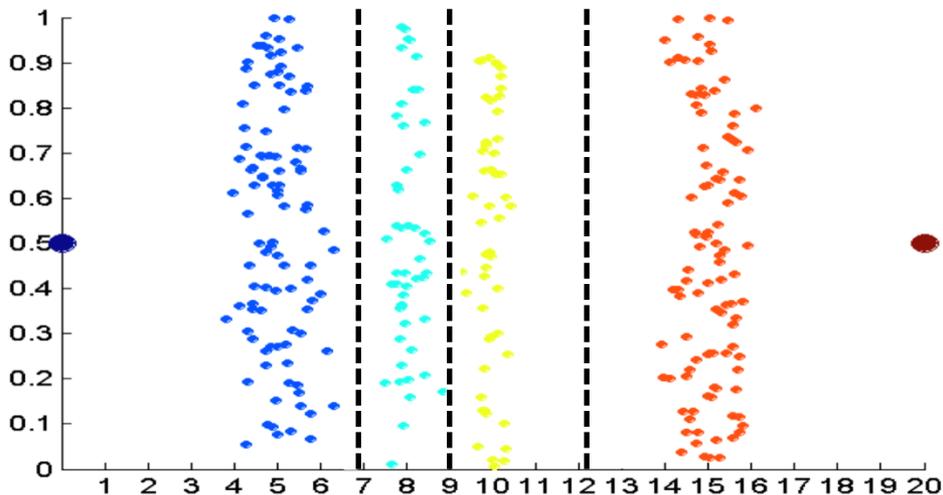
结  
论



# 数据变换-离散化

24

- 根据Entropy进行二分离散化
  - 先找到一个分隔点（属性值），把所有数据分到两个区间
  - 分别对两个子区间的数据进行二分
  - 重复以上步骤





# 数据变换-离散化

□ 如何确定分隔点？ -- 计算分隔后的信息增益

□ 信息增益 (Information Gain)

■ 表示在某个条件下，信息不确定性减少的程度

$Ent(p)$

属性	$x_1$	$x_2$	$x_3$	.....	$x_{n-2}$	$x_{n-1}$	$x_n$
类别	C0	C0	C1	.....	C1	C1	C0

$x_1$	$x_2$
C0	C0

$x_3$	.....	$x_{n-2}$	$x_{n-1}$	$x_n$
C1	.....	C1	C1	C0

$Ent(m_{11})$

$Ent(m_{12})$

$$Ent(m_1) = \frac{n_1}{n} Ent(m_{11}) + \frac{n_2}{n} Ent(m_{12})$$

$$Gain1 = Ent(p) - Ent(m_1) > 0$$

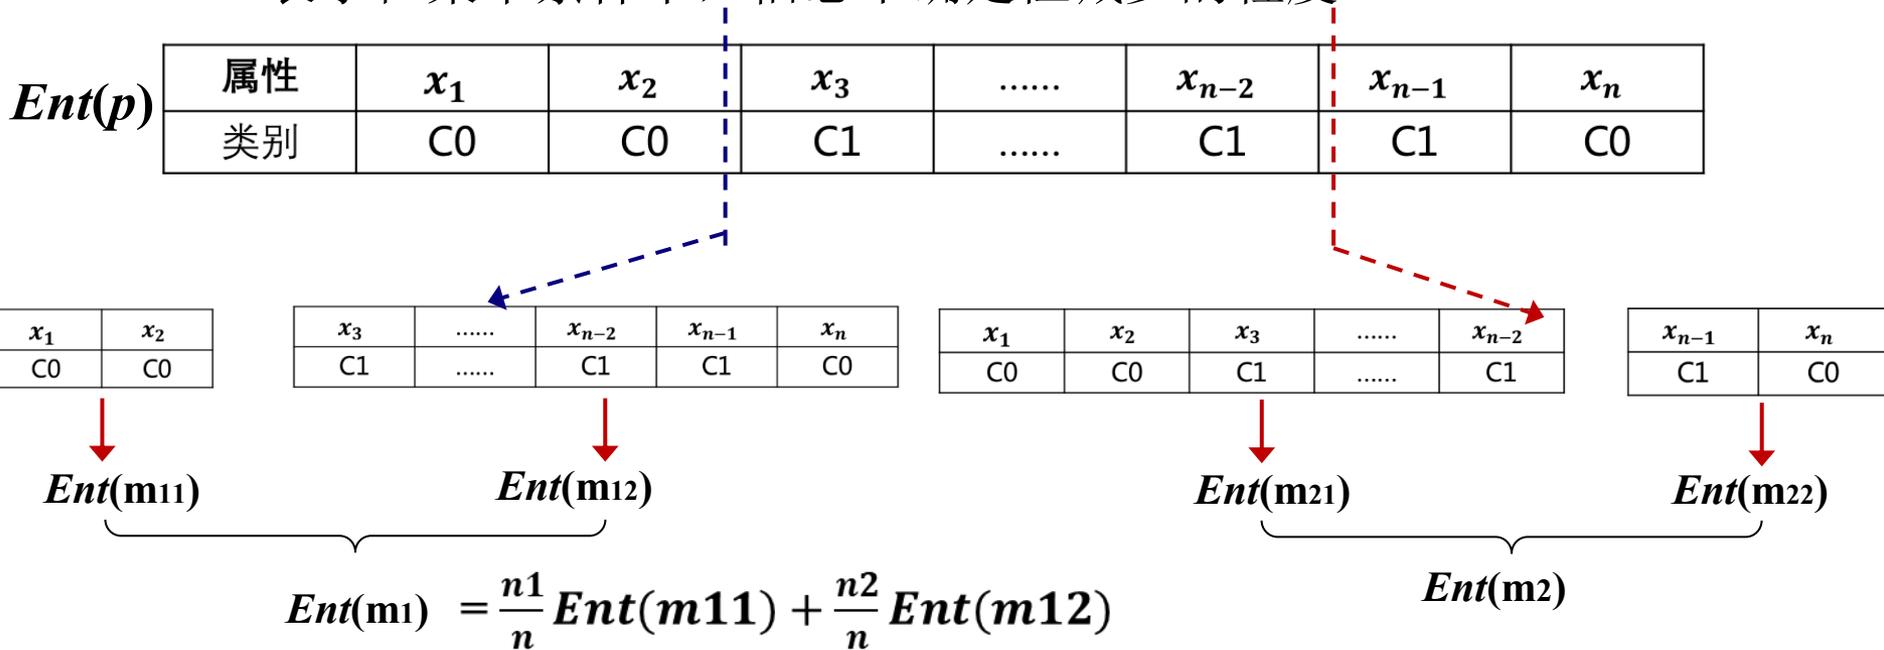


# 数据变换-离散化

□ 如何确定分隔点？——计算分隔后的信息增益

□ 信息增益 (Information Gain)

■ 表示在某个条件下，信息不确定性减少的程度







# 数据变换-离散化

28

## □ 如何确定分隔点？ -- 计算分隔后的信息增益

□ 信息增益 (Information Gain) :

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

- 信息增益：表示在某个条件下，信息不确定性减少的程度。
- 父节点 P 被分隔为 K 个区间
- n 表示总记录数，n<sub>i</sub>表示区间 i 中的记录数

□ 确定分隔点 j :

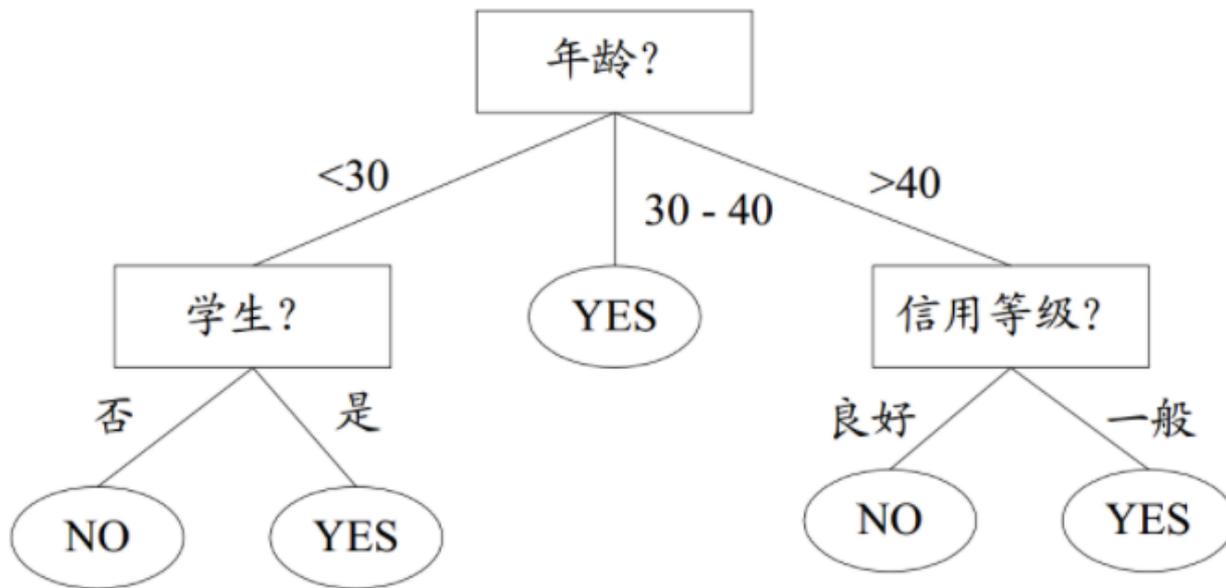
- 选择信息增益最大的分隔点，即

$$j = \max(GAIN_{\text{split}})$$



# 数据变换-离散化

- 十大经典机器学习算法
  - 决策树 (第四章：数据挖掘)





# 数据变换-离散化

## 熵 (Entropy) 的应用举例

- 使用熵进行旅游季节 (Travel Season) 的划分
- 假设不同的景点适合不同的季节进行旅游



1月

2月

3月

4月

5月

6月

7月

8月

9月

10月

11月

12月

- 根据景点的类别分布, 计算区间 (季节) 中的熵:

$$WAE(i; S^P) = \frac{|S_1^P(i)|}{|S^P|} Ent(S_1^P(i)) + \frac{|S_2^P(i)|}{|S^P|} Ent(S_2^P(i))$$



# 课后学习

31

## □ 前沿文献调研：“熵在数据科学中的应用”

### □ 推荐1：基于技术分布的熵值预测公司发展前景

- 技术的发展一般处于5个阶段(萌芽期、过热期、低谷期、复苏期和成熟期)，如果公司的技术发展在以上阶段分布越均衡，可能它的发展前景就越好

- Bo Jin, Yong Ge, Hengshu Zhu, Li Guo, Hui Xiong and Chao Zhang. Technology Prospecting for High Tech Companies through Patent Mining ICDM'2014

### □ 推荐2：基于交叉熵的机器学习目标函数设计

- 信息熵、交叉熵和相对熵：<https://charlesliuyx.github.io/2017/09/11/>



# 参考资料

- Qi Liu, Yong Ge, Zhongmou Li, Enhong Chen, and Hui Xiong. Personalized Travel Package Recommendation. ICDM'2011
- Bo Jin, Yong Ge, Hengshu Zhu, Li Guo, Hui Xiong and Chao Zhang. Technology Prospecting for High Tech Companies through Patent Mining ICDM'2014
- 数据规范化的几种方法: <https://www.jianshu.com/p/55aee18b3fbc>
- Z-score (Z值) 的意义: [http://blog.sina.com.cn/s/blog\\_72208a6a0101cdt1.html](http://blog.sina.com.cn/s/blog_72208a6a0101cdt1.html)
- 信息熵是什么: <https://www.zhihu.com/question/22178202>
- 交叉熵损失函数的优点: [https://blog.csdn.net/qq\\_41853758/article/details/82826820](https://blog.csdn.net/qq_41853758/article/details/82826820)
- 信息熵、交叉熵和相对熵: <https://charlesliuyx.github.io/2017/09/11/>
- 常见的三种数据规范化方法及其python实现: <https://joshuaqyh.github.io/2019/02/24/>
- 一种基于信息熵的离散化方法 (MDLP) python实现: <https://zhuanlan.zhihu.com/p/74839156>

