



西北农林科技大学 信息工程学院



# 决策支持系统及其开发

主讲教师：唐晶磊

E-mail: [tangjingle.cn](mailto:tangjingle.cn)

Tel:87091337(O)



## 5.5 知识发现与数据挖掘

## 5.6 数据挖掘的决策支持及应用

## 5.5 知识发现与数据挖掘

### DW的兴起

- (1) 80年在美国召开了**第一届国际机器学习研讨会**；
- (2) 89年8月, 美国底特律市召开的**第一届KDD国际学术会议**；
- (3) 95年, 加拿大召开了**第一届KDD和DM国际学术会议**；
- (4) 我国于87年召开了**第一届全国机器学习研讨会**。

## 5.5.1 知识发现与数据挖掘概念

**知识发现 (Knowledge discovery in database) :** 从数据中发现有用知识的整个过程(KDD)。

**KDD过程**定义:从数据集中识别出有效的、新颖的、潜在有用的,以及最终可理解的**模式**的高级处理过程。

**“模式”**即是**“知识”**的雏形,需经过验证、完善(模式评价)后形成知识。

**KDD过程**概括: **数据准备(data preparation)**、**数据挖掘(data mining)**及**结果的解释和评估(interpretation&evaluation)**。

## 5.5.1 知识发现与数据挖掘概念

**问题：**所有企业都面临企业数据量巨大，而其中真正有价值的信息却很少。

**解决方法：**对大量的数据进行深层分析，获得有利于商业运作、提高竞争力的信息。

**数据挖掘（DM）：**KDD过程中的一个特定步骤，它用专门算法从数据中抽取模式（patterns）。

数据挖掘是一门交叉学科，涉及数据库技术、人工智能技术、数理统计、可视化技术、并行计算等方面。

## 5.5.1 知识发现与数据挖掘概念

**(1) DM (技术角度)**：从大量的、不完全的、有噪声的、模糊的、随机的实际应用数据中，提取隐含在其中的、事先不知道的、但又是潜在**有用的信息和知识**的过程。即从**数据源**发现用户感兴趣的知识，**知识**要可接受、可以理解和运用；

## 5.5.1 知识发现与数据挖掘概念

**(2) (DM) 商业角度：**是一种新的、商业信息处理技术。


对商业数据库中的大量业务数据进行抽取、转换、分析和其他模型化处理，从中提取辅助商业决策的关键性数据。

数据挖掘是一种**深层次的数据分析方法**。

## 5.5.1 知识发现与数据挖掘概念

**(3) (DM)企业角度：**按企业既定业务目标，对大量的企业数据进行探索和分析，揭示隐藏的、未知的或验证已知的规律性，并进一步将其模型化的先进有效方法。

# KDD过程



# 数据准备

- ❖ 数据准备：**数据选择**(data selection)、**数据预处理**(data preprocessing)和**数据转换**(data transformation)。
- ❖ **数据选择**：确定操作对象，即目标数据(target data)，是根据用户的需要，从原始DB中选取的一组数据。
- ❖ **数据预处理**：消除噪声、处理缺值数据、消除重复记录等。
- ❖ **数据转换**：完成数据**类型转换**，进行**属性约简**（从初始属性中找出真正有用的属性，删除无用属性，以减少数据挖掘时要考虑的属性个数）。

# 数据挖掘

## ❖ 数据挖掘

- (1) 首先确定挖掘的任务或目的；
- (2) 确定使用何种挖掘算法。

## ❖ 选择挖掘算法需考虑2个因素：

- 不同数据具有不同特点，需要用与之相关的算法来挖掘；
- 考虑用户或实际运行系统的要求。如用户可能希望**获取描述性的、容易理解的知识**，或者希望获取预测准确度更可能高**预测型知识**。

# 结果的解释和评估

## ❖ 结果的解释和评估（模式评价）

- (1) 经过评估，剔除冗余或无关的模式；
- (2) 不满足用户要求的模式，需回退到**KDD**过程的前面阶段。
- (3) **KDD**是面向用户的，一般需对发现的模式进行可视化处理，或把结果转换为用户易懂的表示形式。

## ❖ **DM**质量好坏的2个影响因素：

- (1) 所采用的**DM**技术的有效性；
- (2) 用于挖掘的数据的质量和数量（数据量的大小）。

# 数据挖掘任务

❖ DM任务有六项：

## (1) 关联分析

若两个或多个数据项的取值重复出现，且概率很高时，它就存在某种关联，**则可建立起这些数据项的关联规则。**

## (2) 时序模式

通过时间序列，搜索出**重复发生概率较高的模式。**

## (3) 聚类（通过聚类建立宏观概念）

有统计分析方法、机器学习方法、神经网络方法等。

# 数据挖掘任务

(4) 分类：以聚类为基础，对已确定的类找出该类别的概念描述。它代表此类数据的整体信息（内涵描述）。

- **内涵描述**分为**特征描述**和**辨别性描述**。
- 判别分类方法的**3个标准**：**预测准确度**、**计算复杂度**、**模式的简洁度**。

(5) 偏差检测：寻找观察结果与**DB**中参照数据之间的差别。

(6) 预测：利用历史数据找出变化规律，建立模型，并用此模型来预测未来数据的种类、特征等。

# 属性约简

## ❖ 属性约简常用于分类问题

- **原则：**保持数据库中分类关系不变。
- 一般采用**粗糙集(rough set)**方法，也可采用**信息论**方法。

❖ 在DB的分类问题中，属性分为条件属性(C)和决策属性(D)。  
条件属性分为**可省略属性**和不可省略属性。

❖ 属性约简是在**条件属性**中，删除不影响**对决策属性进行分类**的多余的条件属性。

❖ 不可省略属性，实质上是对决策属性进行分类的核心属性。

## 补充：数据挖掘与传统分析方法的区别

- ❖ 传统的数据分析方法：查询、报表和联机分析等。
- ❖ 采用完全不同的工具，基于的技术差别也很大。
  - (1) 查询和报表，告诉决策者数据库中都有什么。
  - (2) **OLAP**会进一步告诉决策者，下一步会怎么样，**(假设)**如果我采用这样的措施，又会怎么样。**OLAP**通过建立一系列的假设，来证实或推翻这些假设，以得到合理的结论。因此，**OLAP**本质上是**演绎推理过程**。

## 补充：数据挖掘与联机分析处理的区别

- ❖ **DM**在没有明确假设的前提下挖掘信息、发现知识。
- ❖ **DM**所得到的信息是**先前未知**、有效的和可实用的。
- ❖ 数据挖掘不用于验证某个假定的模式，而是在数据库中自己寻找模型。本质是一个归纳的过程。
- ❖ **DM**和**OLAP**具有一定的互补性。
- ❖ 在利用**DM**出来的结论采取行动之前，利用**OLAP**验证一下，如果采取这样的行动，将会给公司带来什么样的影响。

## 5.5.2 数据挖掘方法和技术

- ❖ **DM**方法由人工智能、机器学习的方法发展而来。结合传统的统计分析方法、模糊数学方法以及计算机科学可视化技术，以数据库为研究对象，形成了数据挖掘方法和技术。
- ❖ 数据挖掘方法和技术可以分为六大类。

## 5.5.2 数据挖掘方法和技术

### (一) 归纳学习方法

按采用的技术可分为信息论方法（决策树方法）和集合论方法

。

#### 1、信息论方法（决策树方法）

利用信息论的原理建立决策树或者决策规则树。

较有特色的方法有：

(1) ID3等方法（决策树方法）

(2) IBLE（决策规则树）方法。



## 2、集合论方法

### (1) 粗糙集 (Rough Set) 方法

对数据库中的**条件属性集**与**决策属性集**建立上下近似关系，对**下近似集合**建立**确定性规则**，对**上近似集合**建立**不确定性规则**（含可信度）。

### (2) 关联规则挖掘

在交易事务数据库中，**挖掘出不同商品集的关联关系**，即发现哪些商品频繁地被顾客同时购买。

### (3) 覆盖正例排斥反例方法

它是利用**覆盖所有正例**，**排斥所有反例**的思想来寻找规则。较典型的有AQ11方法、AQ15方法及AE5方法。



## (二) 仿生物技术

典型的仿生物技术方法是神经网络方法和遗传算法。

**1、神经网络方法：**包括：前馈式网络、反馈式网络、自组织网络等多个神经网络方法。

**2、遗传算法：**模拟生物进化过程的算法。它由三个基本算子组成：**繁殖（选择）、交叉（重组）、变异（突变）**

遗传算法起到产生优良后代的作用，经过若干代的遗传，将得到满足要求的后代（问题的解）。



### (三) 公式发现

在工程和科学数据库中对若干数据项（变量）进行一定的数学运算，求得相应的数学公式。

#### 1. 物理定律发现系统BACON

BACON发现系统完成了物理学中大量定律的重新发现。

#### 2. 经验公式发现系统FDD

寻找由数据项的初等函数或复合函数组合成的经验公式。



## （四）统计分析方法

利用统计学原理对总体中的样本数据进行分析，得出描述和推断该总体信息和知识的方法。

## （五）模糊数学方法

利用模糊集合理论进行数据挖掘，如模糊聚类、模糊分类等。

## （六）可视化技术

利用可视化技术分析数据库，找到潜在的有用信息。

## 5.5.3 数据挖掘的知识表示（一）

DM获取知识表示形式主要有六种：

规则、决策树、浓缩数据、网络权值、公式和案例。

### 1、规则

规则知识由**前提条件**和**结论**两部分组成

**前提**由变量（或取值与）

和析取（或 $\vee$ ）组合而成。

**结论**为决策字段项（属性）的取值或者类别组成。

## 5.5.3 数据挖掘的知识表示（一）

	身高	头发	眼睛
第一类人	矮	金色	兰色
	高	红色	兰色
	高	金色	兰色
	矮	金色	灰色
第二类人	高	金色	黑色
	矮	黑色	兰色
	高	黑色	兰色
	高	黑色	灰色
	矮	金色	黑色

IF (发色=金色 $\vee$ 红色) $\wedge$ (眼睛=兰色 $\vee$ 灰色)

THEN 第一类人

IF (发色=黑色) $\vee$ (眼睛=黑色)


THEN 第二类人

即：凡是具有金色或红色的头发，并且同时具有兰色或灰色眼睛的人属于第一类人；凡是具有黑色头发或黑色眼睛的人属于第二类人。

# 数据挖掘的知识表示（二）

## 2、决策树

例如：上例的人群数据库，按ID3方法得到的决策树如下：



# 数据挖掘的知识表示（三）

## 3、知识基（浓缩数据）

例如上例的人群数据库，通过计算可得出**身高**是不重要的字段，删除它后，再**合并相同数据元组**，得到浓缩数据如下表：

	头发	眼睛
1 类人	金色	兰色
1 类人	红色	兰色
1 类人	金色	灰色
2 类人	金色	黑色
2 类人	黑色	兰色
2 类人	黑色	灰色

# 数据挖掘的知识表示（四）

## 4、网络权值


神经网络方法经过对**训练样本**的学习后，**所得到的知识是网络连接权值和结点的阈值。**

$$\begin{pmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}$$

$$\begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} = \begin{pmatrix} 0.5 \\ 1.5 \end{pmatrix}$$

$$\phi = 0.5$$

$$(T_1, T_2) = (-1, 1)$$



# 数据挖掘的知识表示（五）

## 5、公式

例如，太阳系行星运动数据中包含行星运动周期（旋转一周所需时间，天），以及它与太阳的距离（围绕太阳旋转的椭圆轨道的长半轴，百万公里），数据如下表：

	水星	金星	地球	火星	木星	土星
周期 P	88	225	365	687	4343.5	10767.5
距离 d	58	108	149	228	778	1430

**通过物理定律发现系统BACON和经验公式发现系统FDD，  
都可得到开普勒第三定律： $d^3/p^2=25$**

## 5.6 数据挖掘的决策支持及应用

### 5.6.1 决策树及其应用

#### 1、决策树概念：

用样本的**属性**作为结点，用属性的**取值**作为分支的树结构。利用**信息论原理**对大量样本的属性进行分析和归纳。

决策树的**根结点**是所有样本中信息量最大的**属性**。

**中间结点**是以该结点为根的子树，所包含的**样本子集**中信息量最大的**属性**。

**叶结点**是样本的**类别值**。

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/178062002103007002>