


# 贝叶斯网络(BAYES NETS)



# 接下来的内容

---

- 独立性(Independence)
- 条件独立性(Conditional independence)
- 贝叶斯网络(Bayes nets)
  - 语法和语义

# 概率基础总结，继续

---

■ 求和消除:  $P(X=x) = \sum_y P(X=x, Y=y)$

■ 条件概率分布:  $P(X|Y) = P(X, Y) / P(Y)$

通过列举法概率推理:  $P(Q|e_1, \dots, e_k) =$

$$\alpha \sum_{h_1, \dots, h_m} P(Q, e_1, \dots, e_k, h_1, \dots, h_m)$$

■ 这里  $\alpha$  (即是  $1/Z$ ) 是一个正规化因子, 使得  $P(Q|\dots)$

之和为 1


■ 乘法规则:  $P(X|Y)P(Y) = P(X, Y) = P(Y|X)P(X)$

■ 推广到连锁法则:  $P(X_1, \dots, X_n) = \prod_i P(X_i | X_1, \dots, X_{i-1})$

■ 贝叶斯规则:  $P(X|Y) = P(Y|X)P(X) / P(Y)$


# 概率模型(Probabilistic Models)

- 模型描述的是世界（或某一部分）是如何工作的
- **模型总是一种简化**
  - 可能忽略了某些变量和它们之间的交互关系
  - “所有模型都是错的;但某些是有用的。”  
– George E. P. Box
- 概率模型能用来做什么?
  - 我们(或我们的人工智能体)需要对未知变量进行推理，当给定一些证据后
  - 例如: 解释 (诊断推理)
  - 例如: 预测 (因果推理)
  - 例如: 基于期望利益值的决策
- 如何建立模型，并避免  $d^n$  的复杂性?



# 独立性

---




# 随机变量的独立性


- 两个随机变量是相互独立的 if:
  - 他们的联合概率分布 分解为 两个相对简单的分布的乘积
  - 另一种表达形式:  $\forall x, y : P(x, y) = P(x)P(y)$

$$\forall x, y : P(x|y) = P(x)$$

- 记为:  $X \perp\!\!\!\perp Y$
- 独立性是构建模型时常用的假设, 可以使模型相对简单
  - Empirical* joint distributions: at best “近似于” 独立的 (关联性很小可以忽略)
  - 我们可以对这4个变量构成的模型有什么样的假设: {Weather, Traffic, Cavity, Toothache}?



# 独立性



- 两个变量  $X$  和  $Y$  是 **独立的** 如果

$$\forall x, y \quad P(x, y) = P(x)P(y)$$

- 这说明他们的联合分布 **因式分解** 两个简单的分布之乘积

- 结合乘法规则:  $P(x, y) = P(x|y)P(y)$  我们可以获得另一种形式:

$$\forall x, y \quad P(x|y) = P(x) \quad \text{or} \quad \forall x, y \quad P(y|x) = P(y)$$

- 举例: 两个骰子  $Roll_1$  和  $Roll_2$

- $P(Roll_1=5, Roll_2=5) = P(Roll_1=5)P(Roll_2=5) = 1/6 \times 1/6 = 1/36$

- $P(Roll_2=5 | Roll_1=5) = P(Roll_2=5)$

# 天气和温度（的独立性）？

计算边缘分布

$P_1(T, W)$

T	W	P
hot	sun	0.4
hot	rain	0.1
cold	sun	0.2
cold	rain	0.3

$P(T)$

T	P
hot	0.5
cold	0.5

$P(W)$

W	P
sun	0.6
rain	0.4

验证独立性，与  
P1对比

$P_2(T, W)$

T	W	P
hot	sun	0.3
hot	rain	0.2
cold	sun	0.3
cold	rain	0.2



# 举例：独立性

n 个公平，独立的硬币翻转：

$P(X_1)$

H	0.5
T	0.5


$P(X_2)$

H	0.5
T	0.5

...


$P(X_n)$

H	0.5
T	0.5



$P(X_1, X_2, \dots, X_n)$

$2^n$



# 条件独立性

- 无条件的 (绝对的) 独立性 是非常少的 (why?)
- 条件独立性 是关于不确定环境的最基本和相对可靠的建模假设.
- $X$  条件独立于  $Y$  当给定  $Z$   $X \perp\!\!\!\perp Y | Z$

当且仅当:

$$\forall x, y, z : P(x, y | z) = P(x | z)P(y | z)$$

等价地, 当且仅当

$$\forall x, y, z : P(x | z, y) = P(x | z)$$

# 举例：幽灵探测器

- 变量和值域:

- $G$  (幽灵位置) 在  $\{(1,1), \dots, (3,3)\}$

- $C_{x,y}$  (在方格  $x,y$  探测到的颜色；颜色越深离幽灵越近)：{红red, 橙orange, 黄yellow, 绿green}

0.11	0.11	0.11
0.11	0.11	0.11
0.11	0.11	0.11

- 假设我们有两个概率分布:

- **先验概率 (Prior distribution)** 幽灵的位置:  $P(G)$

- 假设是均匀(uniform)分布

- **传感器模型 (Sensor model)**:  $P(C_{x,y} | G)$  (只依赖于到  $G$  的距离)

- 例如  $P(C_{1,1} = \text{yellow} | G = (1,1)) = 0.1$

# 幽灵搜寻者 计算: 第一步

当检测到  $C_{1,1} = \text{yellow}$  时, 幽灵可能在哪儿?

给定证据, 概率分布在  $P(G | C_{1,1} = \text{yellow})$  上?

正规化  
Normalize

可能性 Likelihood

先验  
Prior

Bayes' rule:

$$P(G | C_{1,1} = \text{yellow}) \propto P(C_{1,1} = \text{yellow} | G) P(G) / P(C_{1,1} = \text{yellow})$$

(贝叶斯 **Bayesian** 更新)

0.11	0.11	0.11	0.17	0.10	0.10
0.11	0.11	0.11	0.09	0.17	0.10
0.11	0.11	0.11	0.01	0.09	0.17

# 幽灵搜寻者 计算: 第二步

- 当看到  $C_{1,1} = \text{yellow}, C_{3,1} = \text{green}$  , 幽灵在哪?
- 换句话说,  $P(G | C_{1,1} = \text{yellow}, C_{3,1} = \text{green})$  概率是什么?
- 我们的模型给出了  $P(C_{x,y} | G)$  需要应用贝叶斯规则:

$$\begin{aligned} & \blacksquare P(G | C_{1,1}=y, C_{3,1}=g) \\ & = \alpha P(C_{1,1}=y, C_{3,1}=g | G) P(G) \\ & = \alpha P(C_{3,1}=g | C_{1,1}=y, G) P(C_{1,1}=y | G) P(G) \end{aligned}$$

- 条件后多了一项

应用乘法规则 | G

0.11	0.11	0.11	0.17	0.10	0.10	?	?	?
0.11	0.11	0.11	0.09	0.17	0.10	?	?	?
0.11	0.11	0.11	0.01	0.09	0.17	?	?	?

# 幽灵搜寻者 计算: 第二步

---

- 如何计算  $P(C_{3,1}=g \mid C_{1,1}=y, G)$ ?
- **给定幽灵的位置**, 在位置 1,1 观察到的黄色是否影响到在 3,1 为绿色的概率?
  - 不影响!
  - (只依赖于到幽灵的距离)
- 当给定幽灵的位置后, 在位置 3,1 的颜色是 **条件独立 (无关的)** (**conditionally independent**) 对于在位置 1,1 的颜色
- $P(C_{3,1}=g \mid C_{1,1}=y, G) = P(C_{3,1}=g \mid G)$

# 幽灵搜寻者 计算: 第二步

■ 观察到  $C_{1,1} = \text{yellow}$ ,  $C_{3,1} = \text{green}$  后, 幽灵的位置在哪?

■  $P(G \mid C_{1,1} = \text{yellow}, C_{3,1} = \text{green})$  ?

■ 我们的模型给出  $P(C_{x,y} \mid G)$  只需应用 Bayes' rule:

■  $P(G \mid C_{1,1} = y, C_{3,1} = g)$

$$= \alpha P(G) P(C_{1,1} = y, C_{3,1} = g \mid G)$$

$$= \alpha P(G) P(C_{1,1} = y \mid G) P(C_{3,1} = g \mid C_{1,1} = y, G)$$

$$= \alpha P(G) P(C_{1,1} = y \mid G) P(C_{3,1} = g \mid G)$$

依据  $C_{3,1}$  和  $C_{1,1}$  条件独立  
(无关性), 当给定  $G$  后

距离	$P(\text{green} \mid \text{距离})$
0	0.01
1	0.1
2	0.2
3	0.3
4	0.4

0.11	0.11	0.11	0.17	0.10	0.10	0.34	0.15	0.10
0.11	0.11	0.11	0.09	0.17	0.10	0.13	0.17	0.05
0.11	0.11	0.11	0.01	0.09	0.17	0.01	0.04	0.01

# 条件独立性（举例）


---

■ 关于以下环境的独立性是怎样的：

■ 交通流量

■ 雨伞

■ 下雨







# 条件独立性

■ 关于以下环境的独立性是怎样的：

- 燃火
- 冒烟
- 报警器



# 条件独立性与连锁法则( Chain Rule)

## ■ 连锁法则

$$P(x_1, x_2, \dots, x_n) = \prod_j P(x_j \mid x_1, \dots, x_{j-1})$$


## ■ 简单的分解:

$$P(\text{Rain}, \text{Traffic}, \text{Umbrella}) = P(\text{Rain}) P(\text{Traffic} \mid \text{Rain}) P(\text{Umbrella} \mid \text{Rain}, \text{Traffic})$$

## ■ 利用了条件独立性的假设后:

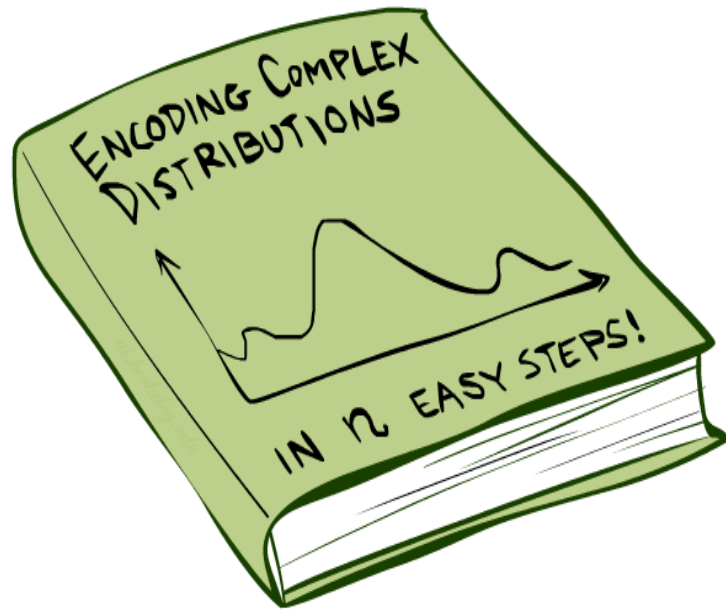
$$P(\text{Rain}, \text{Traffic}, \text{Umbrella}) = P(\text{Rain}) P(\text{Traffic} \mid \text{Rain}) P(\text{Umbrella} \mid \text{Rain})$$

## ■ 贝叶斯网络 / 图形模型 帮助表达条件独立性的假设



# 贝叶斯网络(Bayes Nets)

---



# 贝叶斯网络: 宏观


## 直接学习 完整联合概率分布表 (作为概率模型) 的问题:

- Unless there are only a few variables, the joint is WAY too big to represent explicitly
- Hard to learn (estimate) anything empirically about more than a few variables at a time (sample complexity)

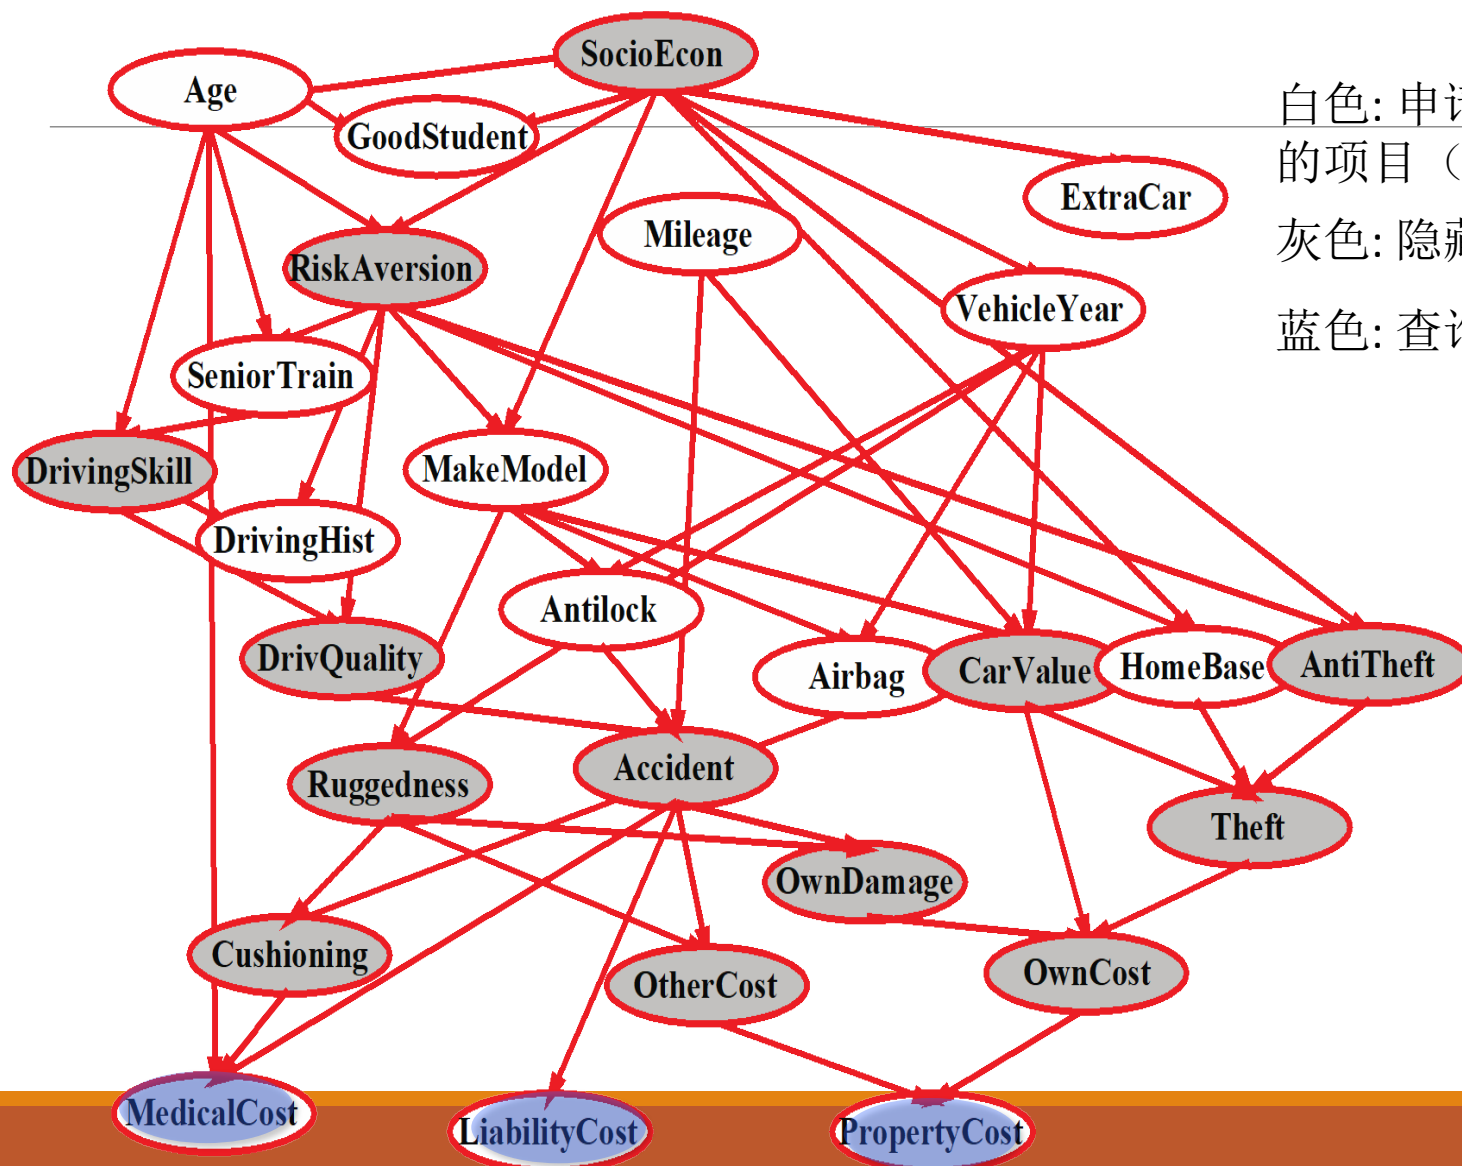


## 贝叶斯网络: a technique for describing complex joint distributions (models) using simple, local distributions (conditional probabilities)

- More properly called **概率图形模型**
- We describe how variables locally interact
- Local interactions chain together to give global, indirect interactions
- For about 10 min, we'll be vague about how these interactions are specified



# 贝叶斯网络举例：汽车保险

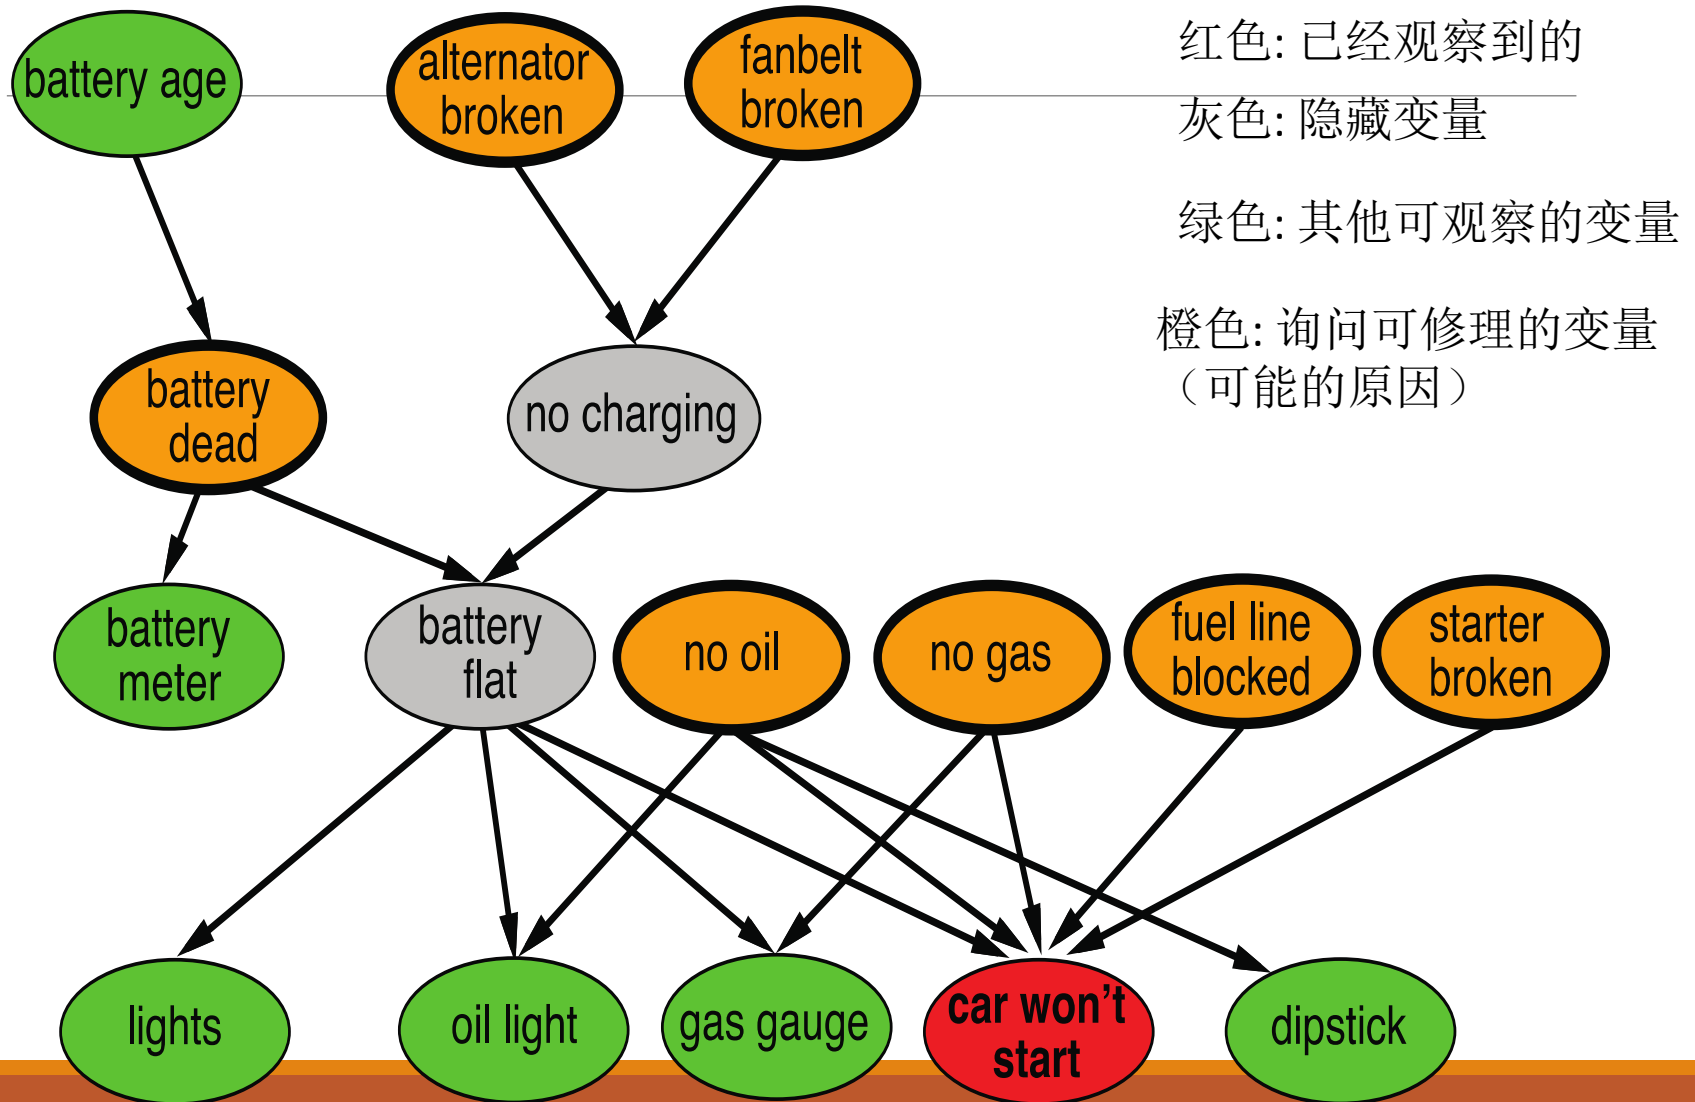


白色: 申请表里出现的项目 (观察到的)

灰色: 隐藏变量

蓝色: 查询变量

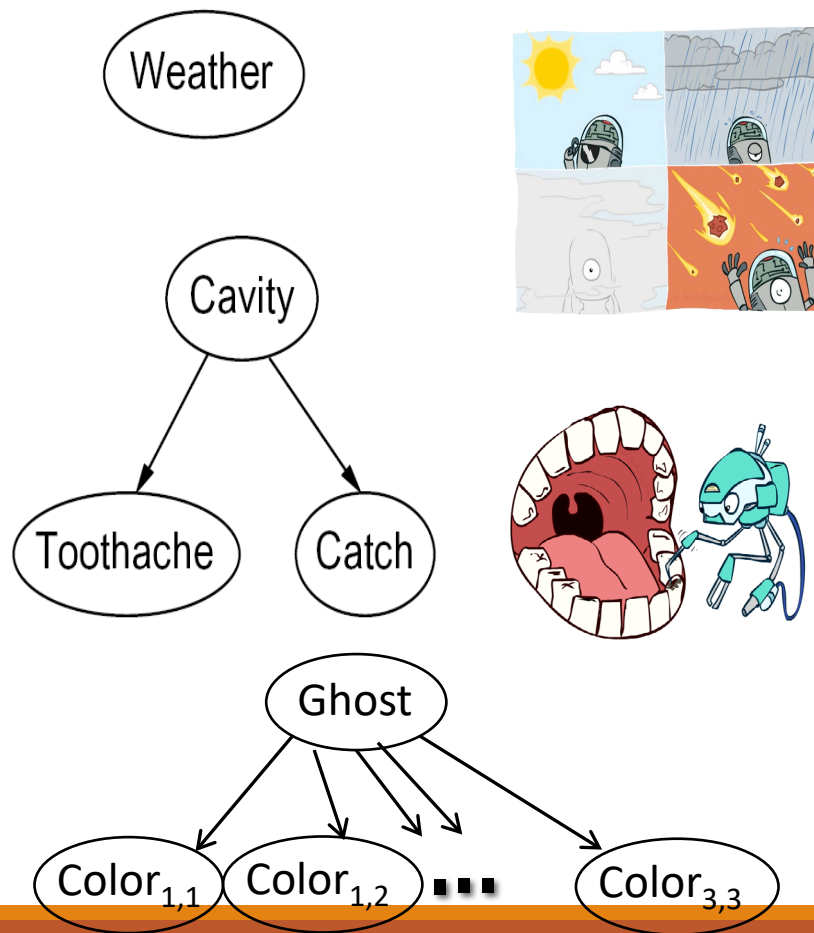
# 贝叶斯网络举例：简单汽车维修



# 图形模型的表达

- 节点: 变量 (每个变量有个值域)
- 弧/边: 相互作用
  - 指示 变量间的“直接的影响”
  - 正式的意思: 代表条件独立性
- 现在可以简单地: 箭头意味着直接的因果关系 (通常情况下, 它们并不一定是这样!)



Catch, 这里指的是牙医机器人的探测器是否捕获到你的牙洞。



# 举例：硬币上抛翻转

---

- N 次硬币上抛（也可以理解为N个硬币抛一次）



- 变量间没有相互作用：**绝对独立**（没有边连接）





# 举例: 交通流量预测

■ 变量:


■ R: 下雨

■ T: 交通状况


■ 模型 1: 独立的



■ 模型 2: 下雨导致交通状况变化




■ 为什么用模型 2 更好?



# 举例: 防盗报警系统

## 变量

- B: 入室盗窃
- A: 报警器响
- M: 马丽打电话
- J: 约翰打电话
- E: 地震!



# 贝叶斯网络语法和语义

---



# 贝叶斯网络语法

- 一个节点对应一个变量  $X_i$
- 一个有向, 无环图
- 对每个节点 给定图中它的 **父节点**


有一个条件概率分布,

- **CPT**: 条件概率分布表:

在给定父节点的一个配置以后,  
每一行是子节点取值的一个分布

- 一个近似的“因果”过程的描述

$$P(X|a_1 \dots a_n)$$



$$P(X|A_1 \dots A_n)$$


**贝叶斯网络 = 拓扑结构(图形) + 局部条件概率**

# 贝叶斯网络里的概率

- 贝叶斯网络 **隐式地** 蕴含了联合概率分布
  - 局部条件概率分布的乘积
  - To see what probability a BN gives to a full assignment, multiply all the relevant conditionals together:

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

- Example:



$$P(+cavity, +catch, -toothache)$$

# 贝叶斯网络里的概率

- 以下表达式成立，为什么？

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

- 乘法法则：

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | x_1 \dots x_{i-1})$$

- 假设条件独立性存在：


$$P(x_i | x_1, \dots, x_{i-1}) = P(x_i | \text{parents}(X_i))$$

→ 结果：

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

- 不是每一个BN 可以表达与变量相关的任何的联合概率分布
  - 图结构表达了某种特定的条件独立性

# 举例: Traffic


$$P(R)$$

+r	1/4
-r	3/4

$$P(T|R)$$

+r	+t	3/4
+r	-t	1/4


-r	+t	1/2
-r	-t	1/2

$$P(+r, -t) =$$




# 举例: 报警器模型

B	P(B)
+b	0.001
-b	0.999



E	P(E)
+e	0.002
-e	0.998




A	J	P(J A)
+a	+j	0.9
+a	-j	0.1
-a	+j	0.05
-a	-j	0.95

A	M	P(M A)
+a	+m	0.7
+a	-m	0.3
-a	+m	0.01
-a	-m	0.99

B	E	A	P(A B,E)
+b	+e	+a	0.95
+b	+e	-a	0.05
+b	-e	+a	0.94
+b	-e	-a	0.06
-b	+e	+a	0.29
-b	+e	-a	0.71
-b	-e	+a	0.001
-b	-e	-a	0.999




# 举例: 报警器网络



**1**

P(B)	
true	false
0.001	0.999




**1**

P(E)	
true	false
0.002	0.998

B	E	P(A B,E)	
		true	false
true	true	0.95	0.05
true	false	0.94	0.06
false	true	0.29	0.71
false	false	0.001	0.999

**2**

A	P(J A)	
	true	false
true	0.9	0.1
false	0.05	0.95



**2**

A	P(M A)	
	true	false
true	0.7	0.3
false	0.01	0.99

条件概率分布表CPT的自由参数的个数总共有:


父变量的值域大小:  
 $d_1, \dots, d_k$

子变量的值域为  $d$   
表中每一行概率值之和为 1

$$(d - 1) \prod_i d_i$$

# 举例: Traffic

- 因果关系方向


$$P(R)$$

+r	1/4
-r	3/4

$$P(T|R)$$

+r	+t	3/4
	-t	1/4
-r	+t	1/2
	-t	1/2


$$P(T, R)$$

+r	+t	3/16
+r	-t	1/16
-r	+t	6/16
-r	-t	6/16



# 举例: Reverse Traffic

- 因果关系反向会怎么样?


$$P(T)$$

+t	9/16
-t	7/16

$$P(R|T)$$


+t	+r	1/3
	-r	2/3
-t	+r	1/7
	-r	6/7

$$P(T, R)$$

+r	+t	3/16
+r	-t	1/16
-r	+t	6/16
-r	-t	6/16



# 因果关系(Causality)?



- 当贝叶斯网络反映了真实的因果关系模式时，通常以下成立：
  - 更简单的网络 (较少的父节点, 较少的参数)
  - 更容易评估概率
  - 鲁棒性更强， 比如修改盗窃的频率后应该不影响模型里的其他部分!
- BNs 不需要实际上表达因果关系
  - 有时没有因果网络存在于一个领域 (尤其是在一些变量丢失的情况下)
  - 其结果是箭头关联反映的是 *相关性*(correlation), 而不是因果关系
- 箭头实际表示的是什么？
  - 拓扑结构可能碰巧表达的是因果关系
  - 拓扑结构真正表达 (编码) 的是条件独立性:
    - $P(X_i | X_1, \dots, X_{i-1}) = P(X_i | \text{Parents}(X_i))$