



电子科技大学  
University of Electronic Science and Technology of China



# Chap. 3-4

## 图模型的两种表示方法

### 黄峰 & 黄晨



Data Mining Lab,  
Big Data Research Center, UESTC  
Email: [huangchen.uestc@gmail.com](mailto:huangchen.uestc@gmail.com)

## ➤ 第一部分：贝叶斯网络

- ✓ 表示
- ✓ 推断的例子
- ✓ . . .

## ➤ 第二部分：马尔科夫随机场

- ✓ MRF的初步认识
- ✓ 越来越熟悉的MRF
- ✓ 熟悉到陌生的BN和MRF

**友情提示：为了和峰峰的风格保持一致，我继续用中文做ppt，并且同样加入新的风格，避免枯燥的理论讲解，迈出人类坚实的又一小步。**



## 第二部分

# 马尔科夫随机场


从入门到放弃

# 马尔科夫随机场的初步认识



你也可以叫我  
**Markov  
Random  
Field**

- 四个学生ABCD，被安排两两一起讨论做毕设
- 但AC有矛盾，BD也有矛盾
- 四个人对毕设的要求可能存在偏差（0存在，1不存在）
- 假设一开始，AB意见一致的可能性比不一致的可能性更大




- 怎么刻画这个关系？ → 因子  
→ 因子是什么

# \*图论中的因子




- **因子**：G的一个至少含有一条边的生成子图(点不变，边子集)
- **N-因子**：N度正则因子（每个节点度数都为N的因子）
- **因子分解**：G划分成为边不相交（无公共边）的因子的并
- **N-因子分解**：G划分成为边不相交（无公共边）的N-因子的并



映射？N-因子分解？因子分解？

- **因子** $\phi$ ：定义为变量集 $X$ 到实数域 $R$ 上的一个映射
- 这个变量集叫做 $\phi$ 的**辖域**，记为 $\text{Scope}[\phi]$
- 刻画变量之间的局部交互影响

 $\phi_1(A, B)$ 

$a^0$	$b^0$	30
$a^0$	$b^1$	5
$a^1$	$b^0$	1
$a^1$	$b^1$	10

(a)

 $\phi_2(B, C)$ 

$b^0$	$c^0$	100
$b^0$	$c^1$	1
$b^1$	$c^0$	1
$b^1$	$c^1$	100

(b)

 $\phi_3(C, D)$ 

$c^0$	$d^0$	1
$c^0$	$d^1$	100
$c^1$	$d^0$	100
$c^1$	$d^1$	1

(c)


 $\phi_4(D, A)$ 

$d^0$	$a^0$	100
$d^0$	$a^1$	1
$d^1$	$a^0$	1
$d^1$	$a^1$	100

(d)

➤ 为了定义一个全局的模型，仿照DAG中概率乘积的方式，对局部交互项做组合

Assignment				Unnormalized	Normalized
$a^0$	$b^0$	$c^0$	$d^0$	300,000	0.04
$a^0$	$b^0$	$c^0$	$d^1$	300,000	0.04
$a^0$	$b^0$	$c^1$	$d^0$	300,000	0.04
$a^0$	$b^0$	$c^1$	$d^1$	30	$4.1 \cdot 10^{-6}$
$a^0$	$b^1$	$c^0$	$d^0$	500	$6.9 \cdot 10^{-5}$
$a^0$	$b^1$	$c^0$	$d^1$	500	$6.9 \cdot 10^{-5}$
$a^0$	$b^1$	$c^1$	$d^0$	5,000,000	0.69
$a^0$	$b^1$	$c^1$	$d^1$	500	$6.9 \cdot 10^{-5}$
$a^1$	$b^0$	$c^0$	$d^0$	100	$1.4 \cdot 10^{-5}$
$a^1$	$b^0$	$c^0$	$d^1$	1,000,000	0.14
$a^1$	$b^0$	$c^1$	$d^0$	100	$1.4 \cdot 10^{-5}$
$a^1$	$b^0$	$c^1$	$d^1$	100	$1.4 \cdot 10^{-5}$
$a^1$	$b^1$	$c^0$	$d^0$	10	$1.4 \cdot 10^{-6}$
$a^1$	$b^1$	$c^0$	$d^1$	100,000	0.014
$a^1$	$b^1$	$c^1$	$d^0$	100,000	0.014
$a^1$	$b^1$	$c^1$	$d^1$	100,000	0.014



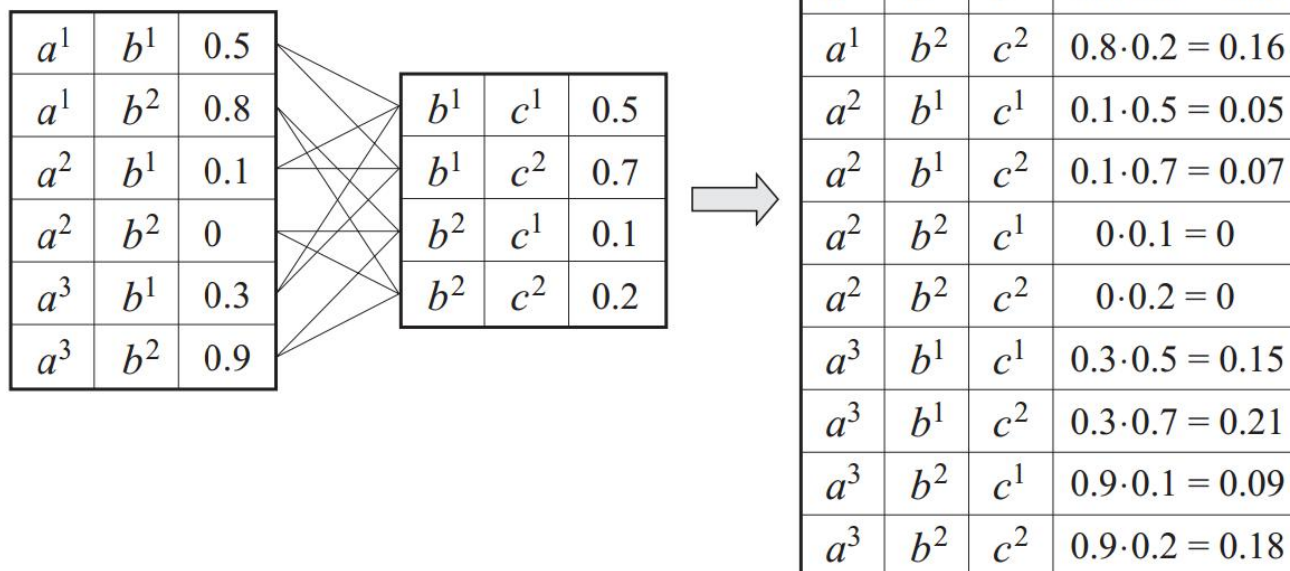
$$P(a, b, c, d) = \frac{\phi_1(a, b)\phi_2(b, c)\phi_3(c, d)\phi_4(d, a)}{\sum_{a,b,c,d} \phi_1(a, b)\phi_2(b, c)\phi_3(c, d)\phi_4(d, a)}$$



- 令XYZ是三个不相交的变量集
- $\phi_1(X, Y)$ 和 $\phi_2(Y, Z)$ 是两个因子，那么两者的乘积可以定义为一个新的因子：

$$\phi(X, Y, Z) = \phi_1(X, Y)\phi_2(Y, Z)$$

- 在更大的辖域上进行刻画



> 当计算 $P(X, Y)$ 时，总是可以写成概率乘积的形式 $P(X)P(Y|X)$ 或者 $P(Y)P(X|Y)$ ，更一般来说：

> 现在令


> 则有

> 所以，BN把因子定义为变量的条件概率。

$$P(X_1, X_2, \dots, X_n) = \prod_i P(X_i | Parents(X_i))$$

$$\phi_{X_i}(X_i, Parents(X_i)) = P(X_i | Parents(X_i))$$

$$P(X_1, X_2, \dots, X_n) = \prod_i \phi_{X_i}(X_i, Parents(X_i))$$



因子乘积之前

$\phi_1(A, B)$

$a^0$	$b^0$	30
$a^0$	$b^1$	5
$a^1$	$b^0$	1
$a^1$	$b^1$	10



因子乘积之后

$a^0$	$b^0$	0.13
$a^0$	$b^1$	0.69
$a^1$	$b^0$	0.14
$a^1$	$b^1$	0.04



确实引入了变量之间的相互影响

# \*因子表示的好处



> 若  $P_{\phi}(X_1, \dots, X_n)$  满足以下

- 型称  $P_{\phi}(X_1, \dots, X_n)$  为在因子集  $D = \{D_1, D_2, \dots, D_m\}$  上的 Gibbs 分布，其中  $\phi$  称为 Partition Function

$$P_{\phi}(X_1, \dots, X_n) = \frac{1}{Z} \phi_1(D_1) \phi_2(D_2) \dots \phi_m(D_m)$$

$$Z = \sum_{D_1, \dots, D_m} \phi_1(D_1) \phi_2(D_2) \dots \phi_m(D_m)$$

很生硬的引入：

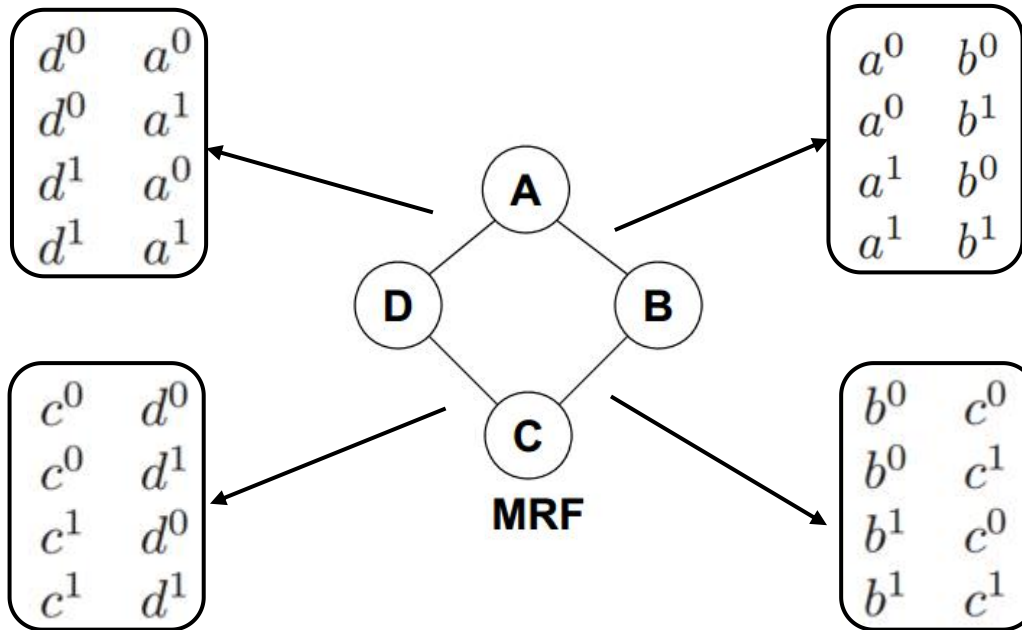
无向图模型上通过因子分解的方式正好对应了一个 Gibbs 分布

# 因子表示的好处



- > 回想BN，因子分解提供了联合概率的紧凑表示
- > 那么，下图联合概率需要 $2^4 - 1$ 个参数，因子分解表示之后呢？

> 现在考虑n个节点，全连通MRF的情况：



$$2^n - 1 \rightarrow 3C_n^2$$

不管你承不承认，反正现在我已经给你介绍了无向图模型的大致轮廓了。

**那到目前为止，你认识到了什么？**



- MRF通过定义**因子**来刻画变量之间的相互关系，这种因子的表示为变量联合概率提供了紧凑表示，简化计算
- MRF与**Gibbs**有联系

## 人生若只如初见，何事秋风悲画扇

事物的结果并不像人们最初想象的那样美好，在发展的过程中往往会变化的超出人们最初的理解。



## 越来越熟悉的MRF



你要不要吃  
饼干休息下



➤ 根据你的了解，请在空白处填上适当的语句。


- MRF通过在 \_\_\_\_\_ 上，定义因子函数 \_\_\_\_\_ 来刻画变量之间的相互关系，这种因子的表示方变量联合概率提供了紧凑表示，简化计算。
- MRF与**Gibbs**的联系是 \_\_\_\_\_

➤ 听完这一部分之后，你需要知道：

- 因子的辖域如何选择？为什么这么选择？
- 因子定义成什么？为什么这么定义？
- MRF的具体定义是？
- MRF与Gibbs分布的关系是？

## ➤ 团 ( Clique ) !

- 全连通子图
- 最大团 ( Max Clique )



最大团 = ABC, BCD





为什么要定义在团上?

- ➔ 由图结构导出的独立性不会被破坏
- ➔ MRF中的独立性是什么?

## ➤ 马尔科夫毯 ( Markov Blanket )

- $MB_{MRF}(X) = \{ X \text{ 的所有邻居} \}$
- $MB_{DAG}(X) = \{ X \text{ 的父节点, } X \text{ 的子节点, } X \text{ 的子节点的父节点} \}$




$$MB(D) = \{A, C\}_{UGM} = \{A, C, B\}_{DAG}$$

## ➤ 局部马尔科夫独立性

$$I_L(H): \{X_i \perp V - \{X_i\} - \text{MarkovBlanket}(X_i)\}$$

## ➤ 全局马尔科夫独立性

- 对于点集 $A, B, C$ ， $B$  分离(separate)  $A$  and  $C$ , 如果每一条从 $A$ 到 $C$ 的路都经过 $B$





$Sep(A; C|B)$

- \*可靠性+完备性

图上因子分解的Gibbs分布满足与图相关的独立性  
图中的非独立性，在部分分布上可能也非独立

## ➤ 图中的独立性有什么用？

- 直观的，BN根据独立性进行因子分解
- MRF中的因子分解是根据团，那MRF的独立性就没用了?(生硬)
- **独立集和团**：Independent Set  $\leq_p$  Clique



明天考试了，  
研一的小伙伴  
谁来证明下！



# \*因子为什么定义在团上




- MRF根据独立性因子分解，但表现形式是团
- 图中，在给定点集B的情况下，点集A条件独立于点集C



图中任意的团在 $A \cup B$ ， $B \cup C$ 中




$$P(X_1, \dots, X_n) \propto \prod_{i \in X_A \cup X_B} \phi_i(D_i) \prod_{i \in X_C \cup X_B} \phi_i(D_i)$$




## ➤ 因子定义在团上

- 应该如何选团的大小呢？
- 团的大小对MRF有什么影响？




- 给定一个无向图 $G$ ，可以将它表示两种节点组合而成的新图：**变量节点**和**因子节点**。
- 在因子图上，可以直观的看出团的辖域






## ➤ 用最大团



$$P'(x_1, x_2, x_3, x_4) = \frac{1}{Z} \psi_c(\mathbf{x}_{124}) \times \psi_c(\mathbf{x}_{234})$$

$$Z = \sum_{x_1, x_2, x_3, x_4} \psi_c(\mathbf{x}_{124}) \times \psi_c(\mathbf{x}_{234})$$

## ➤ 用比较小的团




$$\frac{1}{Z} \psi_{12}(\mathbf{x}_{12}) \psi_{14}(\mathbf{x}_{14}) \psi_{23}(\mathbf{x}_{23}) \psi_{24}(\mathbf{x}_{24}) \psi_{34}(\mathbf{x}_{34})$$

## ➤ 都试试

$$\frac{1}{Z} \psi_c(\mathbf{x}_{124}) \times \psi_c(\mathbf{x}_{234})$$

$$\times \psi_{12}(\mathbf{x}_{12}) \psi_{14}(\mathbf{x}_{14}) \psi_{23}(\mathbf{x}_{23}) \psi_{24}(\mathbf{x}_{24}) \psi_{34}(\mathbf{x}_{34})$$

$$\times \psi_1(x_1) \psi_2(x_2) \psi_3(x_3) \psi_4(x_4)$$



## ➤ 最大团

- 忽略了更多的局部结构信息
- 表征空间的值更大（二维表能表示的信息，三维表一定能表示）
- 用更少的项来分解

## ➤ 用比较小的团

- Partition function更容易计算
- 便于做 Variable Elimination

## ➤ 用所有团

- ...

这三种方式刻画分布等价吗？


## ➤ 势函数

- 正值函数  $\varphi_c$
- 用来刻画团中各个节点之间的演化关系
- 一般采用指数形式

$$P(X) = \frac{1}{Z} \exp\left(-\sum \phi_c(X_c)\right) = \frac{1}{Z} \exp(-H(X))$$

- 其中  $\phi_c$  叫做能量函数(Energy Function), 能量越高, 出现的可能性越低。  $H(X)$  叫自由能量(Free Energy)

$$\varphi_c = \exp(-\phi'(c))$$



$a^0$	$b^0$	30
$a^0$	$b^1$	5
$a^1$	$b^0$	1
$a^1$	$b^1$	10

➤ 保证正分布

➤ \*把 $\varphi_c = \exp(-f(c))$ 视为指数簇函数：

$$P(X|\eta) = H(X) \exp(T(X)^T \eta - A(\eta))$$

- $\eta$ 叫natural parameter
- $A(\eta)$ 叫log-normalizer，是唯一一个不含有X的项，如果对原式子做积分等于1的话，可以反解出A就等于其他项在x上的积分，所以A也可以看做是一个partition function。
- $T(X)$ 叫Sufficient Statistics（充分统计量），它的意思是给定了T，我们不能再从X的概率分布中获得更多关于 $\eta$ 的更多信息。

- 保证正分布
- \*把 $\varphi_c = \exp(-f(c))$ 视为指数簇函数，享受便利（MRF的求解一般比BN更难，为什么？）

$$P(X|\eta) = H(X)\exp(T(X)^T\eta - A(\eta))$$

## \*指数簇的便利性

- 矩生成
- MLE
- 共轭
- 变分推断

$$A'(\eta) = \frac{1}{n} \sum_{i=1}^n T(X_i) \quad \frac{\partial^d A(\eta)}{\partial \eta^d} = E_{P(X|\eta)}[T(X)^d]$$

$$\lambda = E_{Q(Z|\phi)}[\eta(Z, X)]$$

➤ 根据你的了解，请在空白处填上适当的语句。

- MRF通过在 团c 上，定义 势函数 $\psi_c$  来刻画变量之间的相互关系，这种因子的表示方变量联合概率提供了紧凑表示，简化计算。形如：

- 这个形式在统计上，称为 对数线性模型 (log-linear model)

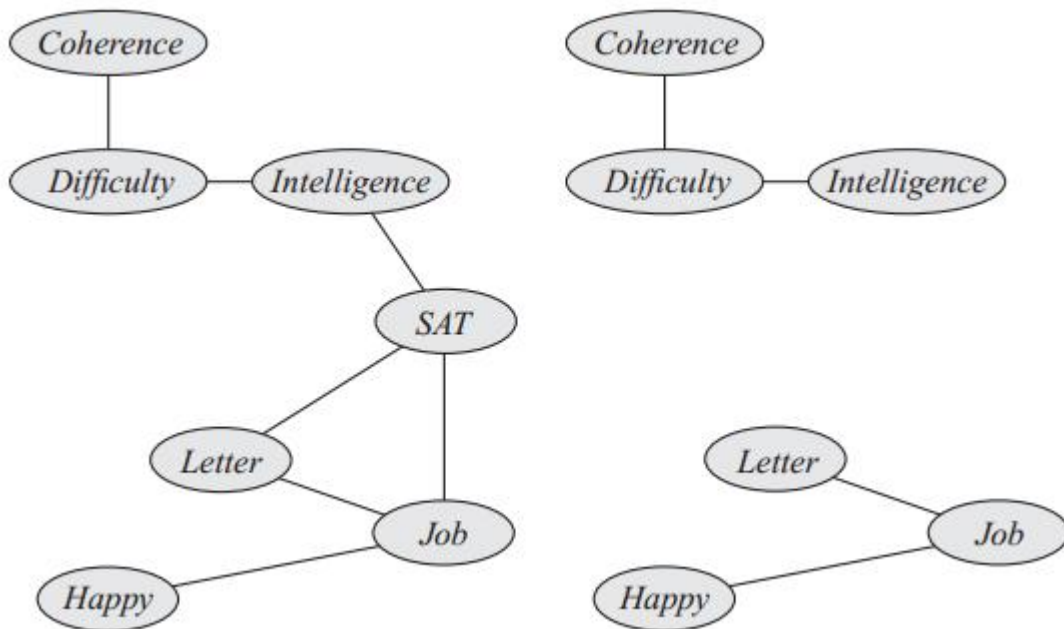
$$P(X_1, \dots, X_n) = \frac{1}{Z} \prod \psi_c(X_c)$$

$$Z = \sum \prod \psi_c(X_c)$$


# \*约简的MRF



- 令 $H$ 是节点集 $X$ 上的MRF，若子集 $U \subseteq X$ 已经被观察到，则 $H[U]$ 是节点集 $W = X - U$ 上的一个约简的MRF



➤ 给定下图中三个变量



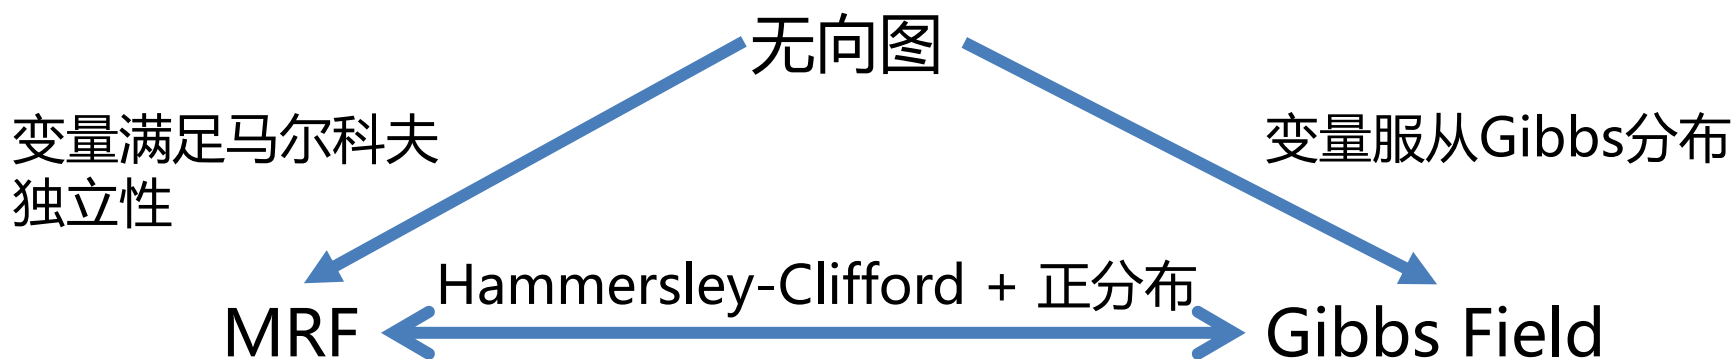
$$\begin{aligned} P(X, Y, Z) &= P(Y)P(X|Y)P(Z|Y) \\ &= P(X, Y)P(Z|Y) \\ &= P(X|Y)P(Z, Y) \\ &\propto \psi(x, y)\psi(y, z) \end{aligned}$$

概率展开

势函数乘积


在某些团上，势函数不能全部表示为边缘分布，或条件分布



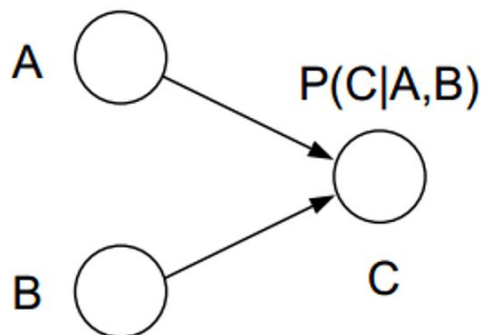


## 熟悉到陌生的BN与MRF


BN和MRF的联合分布  
都是乘积的形式，那么  
它们能不能**相互转换**？




- 条件概率  $\rightarrow$  因子势函数
- 考虑如图中A,B,C三个变量的条件概率



- 把上图的条件概率转化为因子势  $\rightarrow$  不能，为什么？
- A,B,C都不在同一个团中！




肿么办




- Moral图：在一个团中的所有条件概率上定义因子势函数
- Moralization: “父母联姻”，去除方向

$$\begin{aligned}
 &P(A, B, C, D, E, F) \\
 &= \underbrace{P(A)P(B)P(C|A, B)}_{\phi(A, B, C)} \underbrace{P(D|C)P(E|C)}_{\phi(C, D, E)} \underbrace{P(F|D, E)}_{\phi(D, E, F)}
 \end{aligned}$$



## ➤ 转化损失


- 转化成MRF之后，AB不在边缘独立




\***有向正则图**可以在假定不丢失独立性的情况下转化为一个MRF，实际上，独立性的丢失都在于V-structure上。

## ➤ 正则图 ( V-Structure )

正则





非正则



## ➤ 对于两个BN，如果满足







- 相同骨架 + 相同V-structure集  $\rightarrow$  I-等价
- 相同骨架 + 相同非正则V-structure集  $\leftrightarrow$  I-等价

- 直观上就知道，这个很难
- 作为某个MRF的最小I-map的BN可能比原MRF复杂很多



- 需要添加很多边，构成三角形的，对应的MRF一定是弦图


# \*MRF $\rightarrow$ BN





## ➤ BN和MRF的区别？

- 有向图与无向图
- 因果关系与对等联系(Affinity: 亲密性)
- 势函数不能直接表征概率
- 刻画独立性能力



- MRF更难求解 → 因为partition function
- 给定观察变量后，BN可能会引入新的依赖关系（V-Structure），而MRF只是对应约简的MRF
- 马尔科夫毯
- .....

# Take-Home Message



- MRF的全局和局部独立性
- MRF通过因子乘积来传递变量间的相互影响
- MRF根据独立性因子分解，但表现形式是团
- 团不会破坏图结构导出的独立性
- 指数形式的势函数
- MRF与Gibbs
- MRF与BN的区别和相互转换
- Moralization和弦图

# Thanks

By HC

