



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



# Chap. 9-10

## 第II部分 推断

### 张众



Data Mining Lab,  
Big Data Research Center, UESTC  
Email: [zhangzhong0512@163.com](mailto:zhangzhong0512@163.com)

➤ 我是目录，还没来得及写...



# 一点点回顾

## ➤ 局部独立性

- 给定父节点，每个节点 $X_i$ 独立于其非后代节点。

## ➤ 全局独立性

- 令 $\mathbf{X}$ ,  $\mathbf{Y}$ ,  $\mathbf{Z}$ 是图 $G$ 的三个节点集。给定 $\mathbf{Z}$ 的条件下，假如任意节点 $X \in \mathbf{X}$ 与 $Y \in \mathbf{Y}$ 之间不存在有效迹，那么 $\mathbf{X}$ 与 $\mathbf{Y}$ 在给定 $\mathbf{Z}$ 时时 $d$ -分离的，记作 $d\text{-sep}(\mathbf{X}; \mathbf{Y} | \mathbf{Z})$ 。
- 与 $d$ -分离相对应的独立性的集合用 $I(G)$ 表示：

$$I(G) = \{(X \perp Y | Z) : d\text{-sep}(X; Y | Z)\}$$


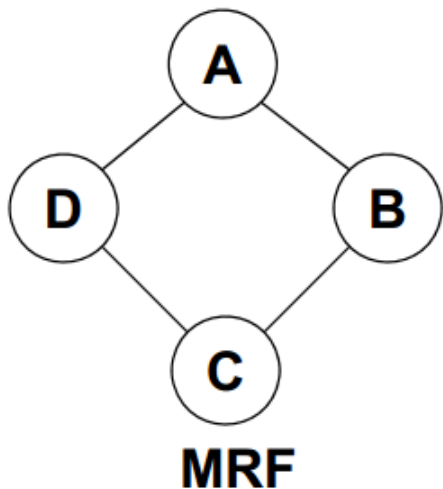
这个集合称为**全局马尔科夫独立性集**

## ➤ 可靠性与完备性

- 图中的独立性包含于分布中的独立性，但分布中蕴含的某些独立性不一定会在图中呈现

## ➤ 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

$$I_1(H): \{X_i \perp V - \{X_i\} - \mathbf{MarkovBlanket}(X_i)\}$$

## ➤ 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

## ➤ 贝叶斯网

- 令G为定义在变量 $X_1, \dots, X_n$ 上的一个贝叶斯网。可以将分布因子分解如下面的形式：

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

- 定义因子：

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

- 则分布可以写成下面形式：

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

## ➤ 马尔科夫随机场

- 令 $H$ 为定义在变量 $X_1, \dots, X_n$ 上的一个马尔科夫网。令 $C_1, \dots, C_k$ 为 $H$ 中的团，对每个团覆盖的辖域指定一系列因子 $\phi_1(C_1), \dots, \phi_l(C_l)$

$$P_{\Phi}(X_1, X_2, \dots, X_n) = \frac{1}{Z} \tilde{P}_{\Phi}(X_1, X_2, \dots, X_n)$$

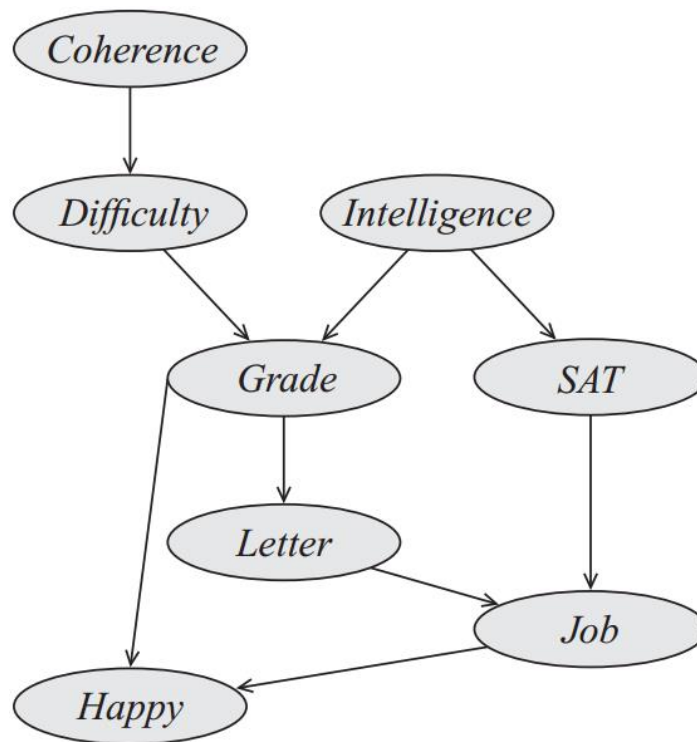
- 其中：

$$\tilde{P}_{\Phi}(X_1, X_2, \dots, X_n) = \prod_i \phi_i(C_i)$$

- 归一化因子：

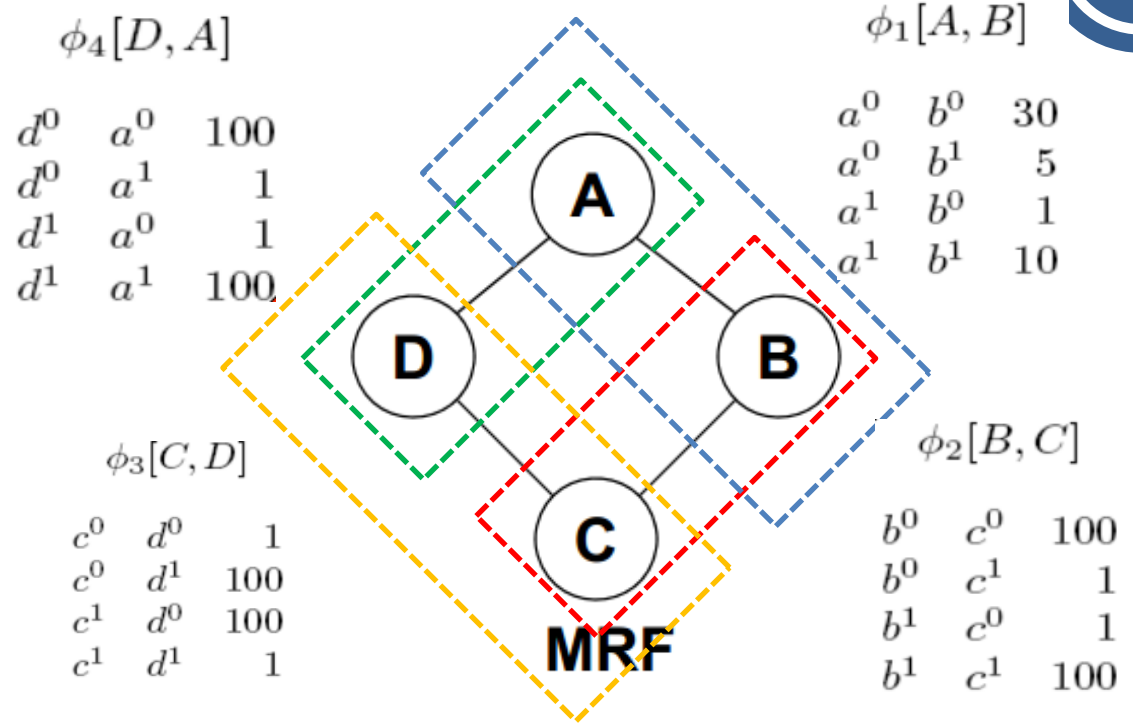
$$Z = \sum_{X_1, \dots, X_n} \tilde{P}_{\Phi}(X_1, X_2, \dots, X_n)$$





**BN**

$$\begin{aligned} P(C, D, I, G, S, L, J, H) &= P(C)P(D | C)P(I)P(G | I, D)P(S | I) \\ &\quad P(L | G)P(J | L, S)P(H | G, J) \\ &= \phi_C(C)\phi_D(D, C)\phi_I(I)\phi_G(G, I, D)\phi_S(S, I) \\ &\quad \phi_L(L, G)\phi_J(J, L, S)\phi_H(H, G, J). \end{aligned}$$



$$P(a, b, c, d) = \frac{1}{Z} \phi_1(a, b) \cdot \phi_2(b, c) \cdot \phi_3(c, d) \cdot \phi_4(d, a),$$

where

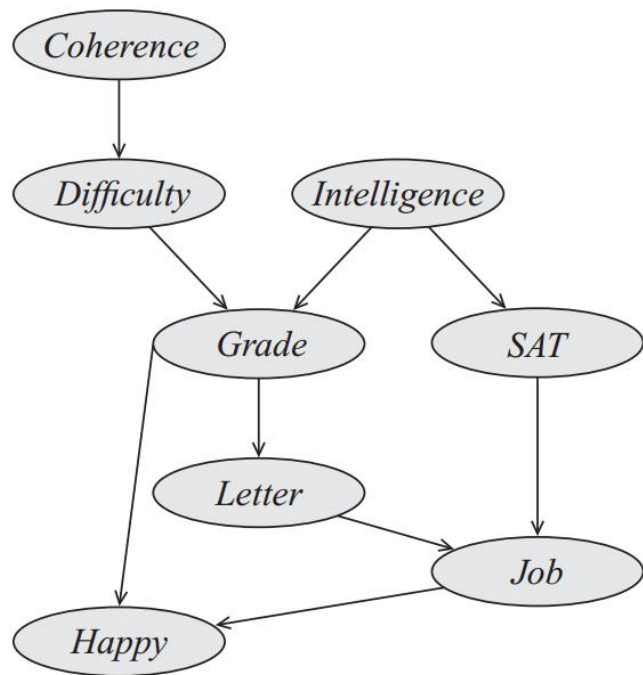
$$Z = \sum_{a,b,c,d} \phi_1(a, b) \cdot \phi_2(b, c) \cdot \phi_3(c, d) \cdot \phi_4(d, a)$$



# 推断的初步认识

➤ 有了联合概率分布后，我们希望从概率分布中查询特定变量的分布或概率，可以将查询任务概括为以下三种：

- Query 1：似然 Likelihood
- Query 2：后验概率 Conditional Probability
- Query 3：最大后验概率 Most Probable Assignment



**BN**

➤  $P(H, J) = \sum_C \dots \sum_L P(C, \dots, L, H, J)$

➤  $P(J|S = s^1) = \frac{P(J, S=s^1)}{P(S=s^1)} = \frac{P(J, S=s^1)}{\sum_j P(J=j, S=s^1)}$

➤  $\text{MAP}(L|J = j^1) = \text{argmax}_l P(L|J = j^1)$

## ➤ 带有证据的查询

- 令集合  $\mathbf{E} = \{X_{k+1}, \dots, X_n\}$
- $\mathbf{e}$  是  $\mathbf{E}$  中变量的特定取值，称为证据

## ➤ 最简单的查询：计算证据的概率

$$P(\mathbf{e}) = \sum_{x_1} \dots \sum_{x_k} P(x_1, \dots, x_k, \mathbf{e})$$

- 称  $P(\mathbf{e})$  为证据  $\mathbf{e}$  的似然概率

- 最常见的查询，在给定条件 $\mathbf{e}$ 的情况下，查询变量的条件分布


$$P(X|\mathbf{e}) = \frac{P(X, \mathbf{e})}{P(\mathbf{e})} = \frac{P(X, \mathbf{e})}{\sum_x P(X = x, \mathbf{e})}$$

- 以上称为给定证据 $\mathbf{e}$ 的情况下， $X$ 的**后验分布**
- 通常我们关心一个对变量子集的查询，令变量集合 $\mathbf{X} = \{\mathbf{Y}, \mathbf{Z}\}$ ，其中 $\mathbf{Y}$ 是关心的变量集， $\mathbf{Z}$ 是无关的变量集

$$P(\mathbf{Y}|\mathbf{e}) = \sum_z P(\mathbf{Y}, \mathbf{Z} = z | \mathbf{e})$$


- 求和消除无关变量 $\mathbf{Z}$ 的过程，称为**边缘化** ( marginalization )

- 预测：给定条件，推理结果



- 查询结点是给定证据的后代结点

- 诊断：给定结果，推理条件



- 查询结点是给定证据的祖先结点

- 通常我们希望找到对于某些变量的最可能的联合取值
- 给定证据 $\mathbf{e}$ ，无关变量集 $\mathbf{Z}$ ，关心变量集 $\mathbf{Y}$

$$MPA(\mathbf{Y}|\mathbf{e}) = \operatorname{argmax}_{\mathbf{y} \in \mathbf{y}} P(\mathbf{y}|\mathbf{e}) = \operatorname{argmax}_{\mathbf{y} \in \mathbf{y}} \sum_{\mathbf{z}} P(\mathbf{y}, \mathbf{z}, |\mathbf{e})$$

- 以上称为 $\mathbf{y}$ 的最大后验配置

## ➤ 例子

- $MPA(Y_1)$  ?       $y^* = 1$
- $MPA(Y_1, Y_2)$  ?       $y^* = 0, 0$

$y_1$	$y_2$	$P(y_1, y_2)$
0	0	0.35
0	1	0.05
1	0	0.3
1	1	0.3



## ➤ 精确推理

- The elimination algorithm
- Message-passing algorithm (sum-product, belief propagation)
- The junction tree algorithms

## ➤ 近似推理

- Stochastic simulation / sampling methods
- Markov chain Monte Carlo methods
- Variational algorithms

➤ 给定PGM  $P_{\Phi}$  , 变量 $X$  , 值 $x \in \text{Val}(X)$  , 证据 $e \in \text{Val}(E)$  , 以下问题是 NP-Hardness :

- 计算 $P_{\Phi}(X = x)$
- 判断 $P_{\Phi}(X = x) ? > 0$
- 计算 $P_{\Phi}(X = x | e)$
- 给定 $\varepsilon < 0.5$  , 找到一个 $\rho$ 使得 $|P_{\Phi}(X = x) - \rho| < \varepsilon$
- 给定 $\varepsilon < 0.5$  , 找到一个 $\rho$ 使得 $|P_{\Phi}(X = x | e) - \rho| < \varepsilon$



- 给定 $n$ 个变量，每个变量有 $k$ 个可能的取值，对于这样一个全联合分布，在描述该分布的表中，有多少个表项？
  - A、 $k^n$
  - B、 $nk^2$
  - C、 $kn^2$
  - D、 $n^k$
- 联合分布表项随着变量个数指数增长，直观的反映了推理任务本质上就很难有效地求解

能不能再给力一点

啊，老师？



当然可以！

NP-Hardness不代表不能解决推断，只是对于任意图模型，没有一般的有效推断方法。对于特定图模型，存在一些高效的方法。



假如E是我们感兴趣的变量，如何查询？


边缘化无关变量：

$$P(e) = \underbrace{\sum_d \sum_c \sum_b \sum_a}_{\text{指数爆炸}} P(a, b, c, d, e)$$

指数爆炸，需要遍历完整个分布表！

利用贝叶斯网络的链式规则：

$$P(e) = \sum_d \sum_c \sum_b \sum_a P(a)P(b|a)P(c|b)P(d|c)P(e|d)$$




利用贝叶斯网络的链式规则：

$$P(e) = \sum_d \sum_c \sum_b \sum_a P(a)P(b|a)P(c|b)P(d|c)P(e|d)$$

重新安排求和顺序：

$$\begin{aligned} &= \sum_d \sum_c \sum_b P(c|b)P(d|c)P(e|d) \underbrace{\sum_a P(a)P(b|a)}_{p(b)} \\ &= \sum_d \sum_c \sum_b P(c|b)P(d|c)P(e|d)p(b) \\ &= \sum_d \sum_c P(d|c)P(e|d) \underbrace{\sum_b P(c|b)p(b)}_{p(c)} \\ &= \sum_d \sum_c P(d|c)P(e|d)p(c) \end{aligned}$$



$$\begin{aligned} P(e) &= \sum_d \sum_c \sum_b \sum_a P(a)P(b|a)P(c|b)P(d|c)P(e|d) \\ &= \sum_d \sum_c \sum_b P(c|b)P(d|c)P(e|d) \underbrace{\sum_a P(a)P(b|a)} \\ &= \sum_d \sum_c \sum_b P(c|b)P(d|c)P(e|d)p(b) \\ &= \sum_d \sum_c P(d|c)P(e|d) \underbrace{\sum_b P(c|b)p(b)} \\ &= \sum_d \sum_c P(d|c)P(e|d)p(c) \\ &= \sum_d P(e|d) \underbrace{\sum_c P(d|c)p(c)} \\ &= \sum_d P(e|d)p(d) \end{aligned}$$

➤ 对于一般的链，分析复杂性：

- 假定n个变量的一条链 $X_1 \rightarrow \dots \rightarrow X_n$ ，每个变量有k个取值。

- 算法根据 $P(X_i)$ 计算 $P(X_{i+1})$ ：

$$P(X_{i+1}) = \sum_{x_i} P(X_{i+1}|x_i)P(x_i)$$

- 其中每一步计算的代价是 $O(k^2)$ ：

共有  $k^2$  个乘法运算， $k \times (k - 1)$  个加法运算。


$x_i$ 有k个取值，对于 $x_i$ 的每个取值，必须用CPD的表值 $P(x_{i+1}|x_i)$ 去乘 $P(x_i)$ （ $k^2$ 个乘法运算）；对于每个 $x_{i+1}$ ，有 $k \times (k - 1)$ 个加法运算。

- 对n个变量执行该过程，总的代价是 $O(nk^2)$ ，意味着在联合分布是指数规模的情况下（ $k^n$ ），我们却得到了一个线性时间内的推理！

## Why?

- 由于贝叶斯网的结构，联合分布中一些子表达式只依赖于少量的变量





根据贝叶斯网络的链式规则，联合分布可以分解为：

$$P(A, B, C, D) = P(A)P(B|A)P(C|B)P(D|C)$$

假设所有变量是二值变量。为了计算 $P(D)$ ，必须分别对 $D = d^1$ 以及 $D = d^2$ 的所有表值求和。计算过程如下：

	$P(a^1)$	$P(b^1   a^1)$	$P(c^1   b^1)$	$P(d^1   c^1)$
+	$P(a^2)$	$P(b^1   a^2)$	$P(c^1   b^1)$	$P(d^1   c^1)$
+	$P(a^1)$	$P(b^2   a^1)$	$P(c^1   b^2)$	$P(d^1   c^1)$
+	$P(a^2)$	$P(b^2   a^2)$	$P(c^1   b^2)$	$P(d^1   c^1)$
+	$P(a^1)$	$P(b^1   a^1)$	$P(c^2   b^1)$	$P(d^1   c^2)$
+	$P(a^2)$	$P(b^1   a^2)$	$P(c^2   b^1)$	$P(d^1   c^2)$
+	$P(a^1)$	$P(b^2   a^1)$	$P(c^2   b^2)$	$P(d^1   c^2)$
+	$P(a^2)$	$P(b^2   a^2)$	$P(c^2   b^2)$	$P(d^1   c^2)$

计算 $P(D = d^1)$

	$P(a^1)$	$P(b^1   a^1)$	$P(c^1   b^1)$	$P(d^2   c^1)$
+	$P(a^2)$	$P(b^1   a^2)$	$P(c^1   b^1)$	$P(d^2   c^1)$
+	$P(a^1)$	$P(b^2   a^1)$	$P(c^1   b^2)$	$P(d^2   c^1)$
+	$P(a^2)$	$P(b^2   a^2)$	$P(c^1   b^2)$	$P(d^2   c^1)$
+	$P(a^1)$	$P(b^1   a^1)$	$P(c^2   b^1)$	$P(d^2   c^2)$
+	$P(a^2)$	$P(b^1   a^2)$	$P(c^2   b^1)$	$P(d^2   c^2)$
+	$P(a^1)$	$P(b^2   a^1)$	$P(c^2   b^2)$	$P(d^2   c^2)$
+	$P(a^2)$	$P(b^2   a^2)$	$P(c^2   b^2)$	$P(d^2   c^2)$

计算 $P(D = d^2)$

$$\begin{array}{l}
P(a^1) P(b^1 | a^1) P(c^1 | b^1) P(d^1 | c^1) \\
+ P(a^2) P(b^1 | a^2) P(c^1 | b^1) P(d^1 | c^1) \\
+ P(a^1) P(b^2 | a^1) P(c^1 | b^2) P(d^1 | c^1) \\
+ P(a^2) P(b^2 | a^2) P(c^1 | b^2) P(d^1 | c^1) \\
+ P(a^1) P(b^1 | a^1) P(c^2 | b^1) P(d^1 | c^2) \\
+ P(a^2) P(b^1 | a^2) P(c^2 | b^1) P(d^1 | c^2) \\
+ P(a^1) P(b^2 | a^1) P(c^2 | b^2) P(d^1 | c^2) \\
+ P(a^2) P(b^2 | a^2) P(c^2 | b^2) P(d^1 | c^2)
\end{array}$$

$$\begin{array}{l}
P(a^1) P(b^1 | a^1) P(c^1 | b^1) P(d^2 | c^1) \\
+ P(a^2) P(b^1 | a^2) P(c^1 | b^1) P(d^2 | c^1) \\
+ P(a^1) P(b^2 | a^1) P(c^1 | b^2) P(d^2 | c^1) \\
+ P(a^2) P(b^2 | a^2) P(c^1 | b^2) P(d^2 | c^1) \\
+ P(a^1) P(b^1 | a^1) P(c^2 | b^1) P(d^2 | c^2) \\
+ P(a^2) P(b^1 | a^2) P(c^2 | b^1) P(d^2 | c^2) \\
+ P(a^1) P(b^2 | a^1) P(c^2 | b^2) P(d^2 | c^2) \\
+ P(a^2) P(b^2 | a^2) P(c^2 | b^2) P(d^2 | c^2)
\end{array}$$

提出关于A的公共项

$$\begin{array}{l}
(P(a^1)P(b^1 | a^1) + P(a^2)P(b^1 | a^2)) P(c^1 | b^1) P(d^1 | c^1) \\
+ (P(a^1)P(b^2 | a^1) + P(a^2)P(b^2 | a^2)) P(c^1 | b^2) P(d^1 | c^1) \\
+ (P(a^1)P(b^1 | a^1) + P(a^2)P(b^1 | a^2)) P(c^2 | b^1) P(d^1 | c^2) \\
+ (P(a^1)P(b^2 | a^1) + P(a^2)P(b^2 | a^2)) P(c^2 | b^2) P(d^1 | c^2)
\end{array}$$

$$\begin{array}{l}
(P(a^1)P(b^1 | a^1) + P(a^2)P(b^1 | a^2)) P(c^1 | b^1) P(d^2 | c^1) \\
+ (P(a^1)P(b^2 | a^1) + P(a^2)P(b^2 | a^2)) P(c^1 | b^2) P(d^2 | c^1) \\
+ (P(a^1)P(b^1 | a^1) + P(a^2)P(b^1 | a^2)) P(c^2 | b^1) P(d^2 | c^2) \\
+ (P(a^1)P(b^2 | a^1) + P(a^2)P(b^2 | a^2)) P(c^2 | b^2) P(d^2 | c^2)
\end{array}$$

令  $\tau_1(B) = \sum_A P(A)P(B|A)$

$$\begin{array}{l}
\tau_1(b^1) P(c^1 | b^1) P(d^1 | c^1) \\
+ \tau_1(b^2) P(c^1 | b^2) P(d^1 | c^1) \\
+ \tau_1(b^1) P(c^2 | b^1) P(d^1 | c^2) \\
+ \tau_1(b^2) P(c^2 | b^2) P(d^1 | c^2)
\end{array}$$

$$\begin{array}{l}
\tau_1(b^1) P(c^1 | b^1) P(d^2 | c^1) \\
+ \tau_1(b^2) P(c^1 | b^2) P(d^2 | c^1) \\
+ \tau_1(b^1) P(c^2 | b^1) P(d^2 | c^2) \\
+ \tau_1(b^2) P(c^2 | b^2) P(d^2 | c^2)
\end{array}$$

$$\begin{array}{l} \tau_1(b^1) P(c^1 | b^1) P(d^1 | c^1) \\ + \tau_1(b^2) P(c^1 | b^2) P(d^1 | c^1) \\ + \tau_1(b^1) P(c^2 | b^1) P(d^1 | c^2) \\ + \tau_1(b^2) P(c^2 | b^2) P(d^1 | c^2) \end{array}$$

$$\begin{array}{l} \tau_1(b^1) P(c^1 | b^1) P(d^2 | c^1) \\ + \tau_1(b^2) P(c^1 | b^2) P(d^2 | c^1) \\ + \tau_1(b^1) P(c^2 | b^1) P(d^2 | c^2) \\ + \tau_1(b^2) P(c^2 | b^2) P(d^2 | c^2) \end{array}$$

提出关于B的公共项

$$\begin{array}{l} (\tau_1(b^1)P(c^1 | b^1) + \tau_1(b^2)P(c^1 | b^2)) P(d^1 | c^1) \\ + (\tau_1(b^1)P(c^2 | b^1) + \tau_1(b^2)P(c^2 | b^2)) P(d^1 | c^2) \end{array}$$

$$\begin{array}{l} (\tau_1(b^1)P(c^1 | b^1) + \tau_1(b^2)P(c^1 | b^2)) P(d^2 | c^1) \\ + (\tau_1(b^1)P(c^2 | b^1) + \tau_1(b^2)P(c^2 | b^2)) P(d^2 | c^2) \end{array}$$

$$\text{令 } \tau_2(C) = \sum_B P(B)P(C|B)$$

$$\begin{array}{l} \tau_2(c^1) P(d^1 | c^1) \\ + \tau_2(c^2) P(d^1 | c^2) \end{array}$$

$$\begin{array}{l} \tau_2(c^1) P(d^2 | c^1) \\ + \tau_2(c^2) P(d^2 | c^2) \end{array}$$

注意到，通过改变计算顺序，得到和式中的公共项，这些公共项保存为变量 $\tau$ 后，可以重复使用，避免了指数量级的重复运算

- 帮助我们解决联合分布中指数爆炸问题的两个观点：
  - 根据贝叶斯网络的结构，联合分布中的一些子表达式只依赖于少量的变量
  - 通过计算这些表达式并存储起来，可以避免多次对其指数地生成



# 变量消除算法

- 辖域  $Scope[\phi] = X$  , 因子 ( factor )  $\phi: Val(\mathbf{X}) \rightarrow R$

在贝叶斯网中, 因子往往对应变量的分布 ( 概率 ) 或条件分布 ( 条件概率 ) , 而在马尔科夫网中, 不一定有这样的对应关系。

- $\phi_1(X, Y)$  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:

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

- $\mathbf{X}$  是变量的一个集合,  $Y$  是满足  $Y \notin \mathbf{X}$  的变量, 令  $\psi(\mathbf{X}, Y)$  是一个因子, 通过边缘化变量  $Y$  可以得到一个关于  $\mathbf{X}$  的因子:

$$\tau(\mathbf{X}) = \sum_Y \psi(\mathbf{X}, Y)$$

## Algorithm 9.1 Sum-product variable elimination algorithm

**Procedure** Sum-Product-VE (

$\Phi$ , // Set of factors

$Z$ , // Set of variables to be eliminated

$\prec$  // Ordering on  $Z$

)

1 Let  $Z_1, \dots, Z_k$  be an ordering of  $Z$  such that

2  $Z_i \prec Z_j$  if and only if  $i < j$

3 **for**  $i = 1, \dots, k$

4  $\Phi \leftarrow$  Sum-Product-Eliminate-Var( $\Phi, Z_i$ )

5  $\phi^* \leftarrow \prod_{\phi \in \Phi} \phi$

6 **return**  $\phi^*$

**Procedure** Sum-Product-Eliminate-Var (

$\Phi$ , // Set of factors

$Z$  // Variable to be eliminated

)

1  $\Phi' \leftarrow \{\phi \in \Phi : Z \in \text{Scope}[\phi]\}$

2  $\Phi'' \leftarrow \Phi - \Phi'$

3  $\psi \leftarrow \prod_{\phi \in \Phi'} \phi$

4  $\tau \leftarrow \sum_Z \psi$

5 **return**  $\Phi'' \cup \{\tau\}$

算法思想：每次对一个变量求和。

当对任意变量求和时，让所有与该变量有关的因子相乘，生成一个乘积因子，再对该乘积因子求和。进而生成一个新的关于其他待处理变量的因子。

一般来说，可以把任务看做计算以下表达式的值：

$$\sum_Z \prod_{\phi \in \mathcal{F}} \phi$$

$$\begin{aligned}
 P(C, D, I, G, S, L, J, H) &= P(C)P(D | C)P(I)P(G | I, D)P(S | I) \\
 &\quad P(L | G)P(J | L, S)P(H | G, J) \\
 &= \phi_C(C)\phi_D(D, C)\phi_I(I)\phi_G(G, I, D)\phi_S(S, I) \\
 &\quad \phi_L(L, G)\phi_J(J, L, S)\phi_H(H, G, J).
 \end{aligned}$$

下面利用变量消除算法计算 $P(J)$ 。消除顺序为 $C, D, I, H, G, S, L$

### 1. 消除 $C$ ：计算因子

$$\psi_1(C, D) = \phi_C(C)\phi_D(D, C)$$

$$\tau_1(D) = \sum_C \psi_1(C, D)$$

2. 消除 $D$ ：注意，已经消除了包含 $D$ 的边缘因子—— $\phi_D(D, C) = P(D|C)$ 。另一方面，引入了包含 $D$ 的因子  $\tau_1(D)$ 。因此，计算


$$\psi_2(G, I, D) = \phi_G(G, I, D)\tau_1(D)$$

$$\tau_2(G, I) = \sum_D \psi_2(G, I, D)$$

### 3. 消除 $I$ ：计算因子

$$\psi_3(G, I, S) = \phi_I(I)\phi_S(S, I)\tau_2(G, I)$$

$$\tau_3(G, S) = \sum_I \psi_3(G, I, S)$$





$$\begin{aligned} P(C, D, I, G, S, L, J, H) &= P(C)P(D | C)P(I)P(G | I, D)P(S | I) \\ &\quad P(L | G)P(J | L, S)P(H | G, J) \\ &= \phi_C(C)\phi_D(D, C)\phi_I(I)\phi_G(G, I, D)\phi_S(S, I) \\ &\quad \phi_L(L, G)\phi_J(J, L, S)\phi_H(H, G, J). \end{aligned}$$

下面利用变量消除算法计算P(J)。消除顺序为C, D, I, H, G, S, L

4. 消除H：计算因子

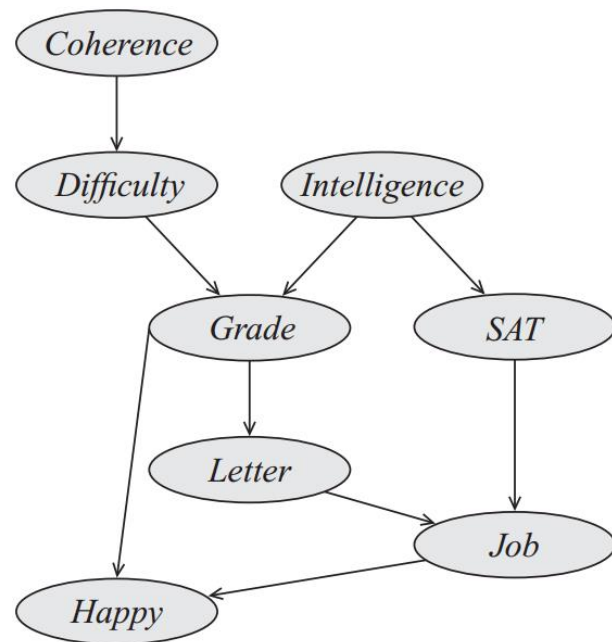
$$\begin{aligned} \psi_4(G, J, H) &= \phi_H(H, G, J) \\ \tau_4(G, J) &= \sum_H \psi_4(G, J, H) \equiv 1 \end{aligned}$$

5. 消除S：计算因子

$$\begin{aligned} \psi_6(J, L, S) &= \tau_5(J, L, S)\phi_J(J, L, S) \\ \tau_6(J, L) &= \sum_S \psi_6(J, L, S) \end{aligned}$$

3. 消除L：计算因子

$$\begin{aligned} \psi_7(J, L) &= \tau_6(J, L) \\ \tau_7(J) &= \sum_L \psi_7(J, L) \end{aligned}$$



$$P(A, B, C, D) = \frac{1}{Z} \phi_1(A, B) \phi_2(B, C) \phi_3(C, D) \phi_4(A, D).$$

$$Z = \sum_{X_1, \dots, X_n} \tilde{P}_{\Phi}(X_1, \dots, X_n)$$

查询目标P(D)。消除顺序为A, B, C

$$\tilde{P}(D) = \sum_{A, B, C} \phi_1(A, B) \phi_2(B, C) \phi_3(C, D) \phi_4(A, D)$$

1. 消除A：计算因子

$$\psi_1(A, B, D) = \phi_1(A, B) \phi_4(A, D)$$

$$\tau_1(B, D) = \sum_A \psi_1(A, B, D)$$

5. 消除B：计算因子


$$\psi_2(B, C, D) = \tau_1(B, D) \phi_2(B, C)$$

$$\tau_2(C, D) = \sum_B \psi_2(B, C, D)$$

3. 消除C：计算因子

$$\psi_3(C, D) = \tau_2(C, D) \phi_3(C, D)$$

$$\tau_3(D) = \sum_C \psi_3(C, D) = \tilde{P}(D)$$



➤ 存在观测变量集 $\mathbf{E}$ 的情况下，定义如下变量：

• 证据势能：

$$\delta(E_i, \bar{e}) = \begin{cases} 1 & \text{if } E_i == \bar{e} \\ 0 & \text{if } E_i \neq \bar{e} \end{cases}$$

• 所有证据势能：

$$\delta(\mathbf{E}, \bar{\mathbf{e}}) = \prod_{i \in I_E} \delta(E_i, \bar{e}_i)$$

• 引入证据——受限的因子：

$$\tau(\mathbf{Y}, \bar{\mathbf{e}}) = \sum_{z, e} \prod_{\phi \in \mathcal{F}} \phi \times \delta(\mathbf{E}, \bar{\mathbf{e}})$$

➤ 变量消除算法的两个基本操作：

$$\psi_k(\mathbf{X}_k) = \prod_i \phi_i$$
$$\tau_k(\mathbf{X}_k - \{Z\}) = \sum_Z \psi_k(\mathbf{X}_k)$$

令 $N_i$ 是因子 $\psi_i$ 中表值的个数， $N_{max} = \max_i N_i$

$m + n$ 个因子： $m$ 个初始因子 $\phi$ ， $n$ 个因子 $\tau_i$

乘法得到 $\psi_i$ 的代价最多是 $N_i$ ，即 $N_i$ 个乘法运算

乘法总代价是 $(n + m)N_i \leq (n + m)N_{max} = O(mN_{max})$

每次边缘化的代价是 $N_i$ ，加法的总代价是 $nN_{max}$

综上所述，总运算量是 $O(mN_{max})$

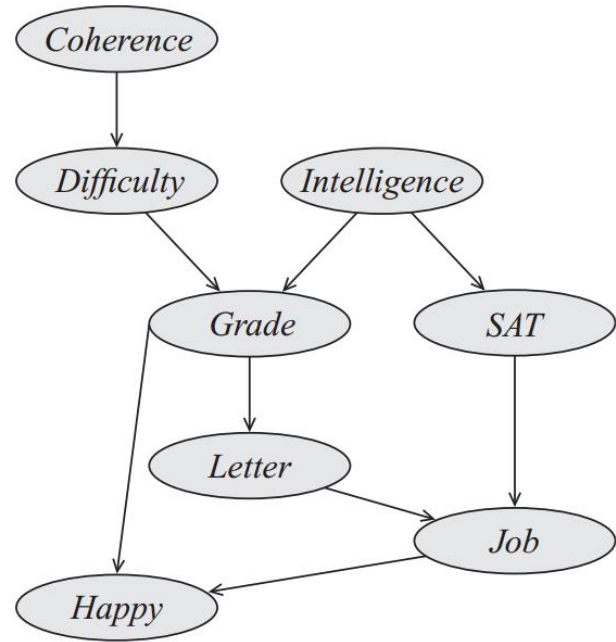
但是！指数爆炸不可避免，是因为因子 $\psi_i$ 的潜在规模。

如果每个变量值个数不超过 $v$ ，并且 $\psi_i$ 包含 $k_i$ 个变量的辖域，那么 $N_i \leq v^{k_i}$

# \*消除顺序

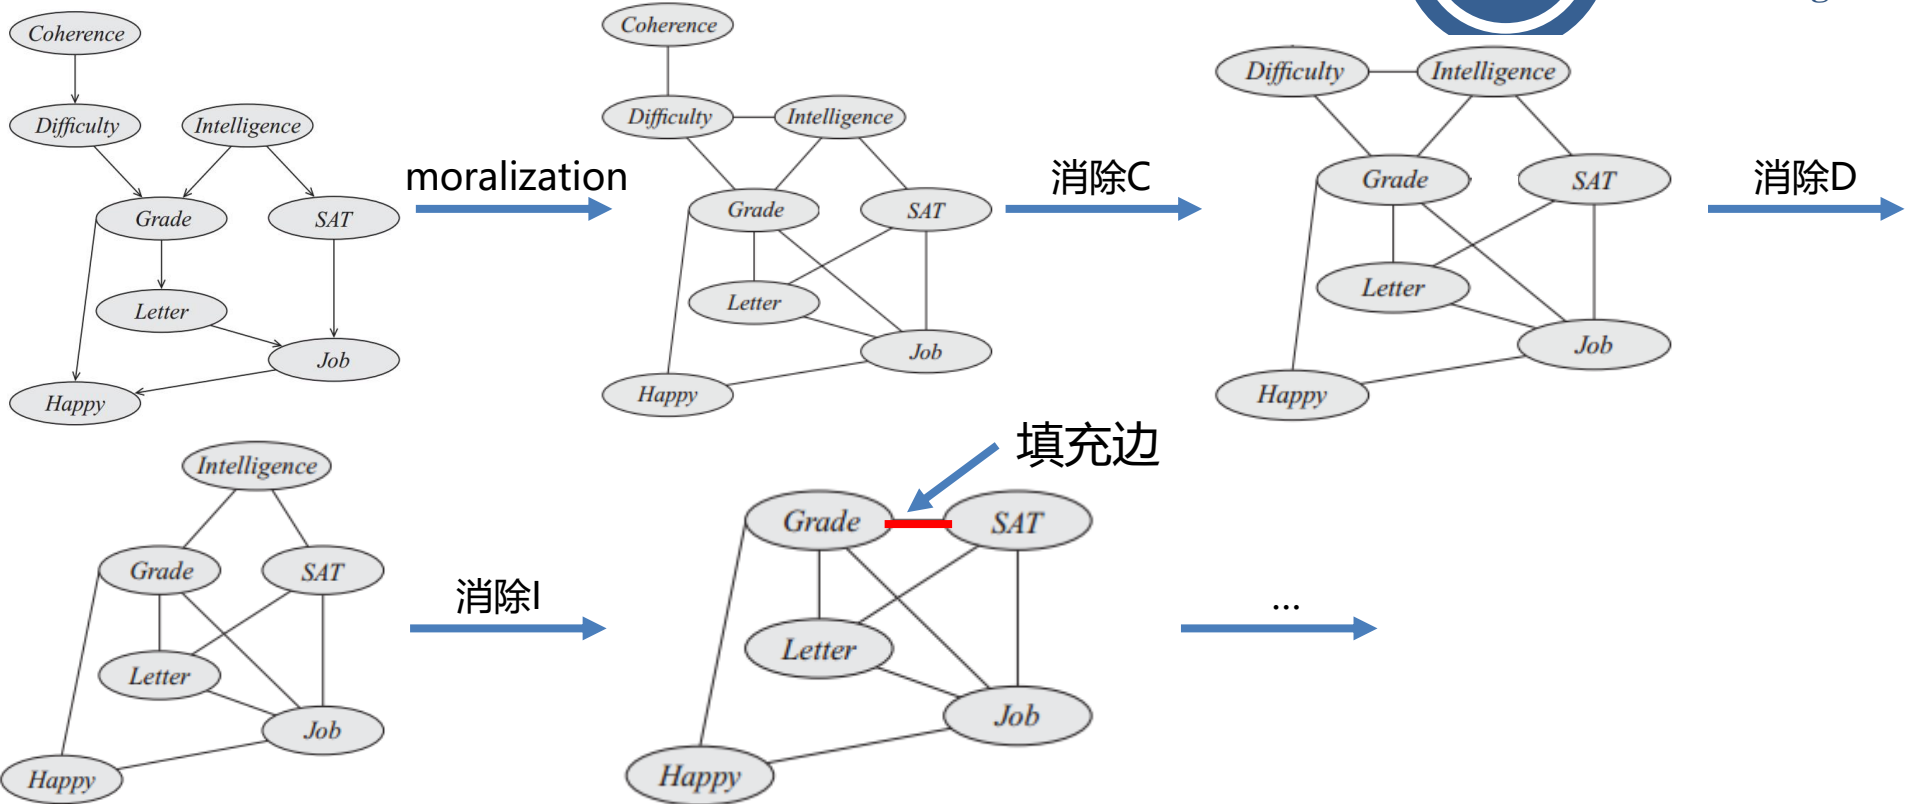


Step	Variable eliminated	Factors used	Variables involved	New factor
1	<i>C</i>	$\phi_C(C), \phi_D(D, C)$	<i>C, D</i>	$\tau_1(D)$
2	<i>D</i>	$\phi_G(G, I, D), \tau_1(D)$	<i>G, I, D</i>	$\tau_2(G, I)$
3	<i>I</i>	$\phi_I(I), \phi_S(S, I), \tau_2(G, I)$	<i>G, S, I</i>	$\tau_3(G, S)$
4	<i>H</i>	$\phi_H(H, G, J)$	<i>H, G, J</i>	$\tau_4(G, J)$
5	<i>G</i>	$\tau_4(G, J), \tau_3(G, S), \phi_L(L, G)$	<i>G, J, L, S</i>	$\tau_5(J, L, S)$
6	<i>S</i>	$\tau_5(J, L, S), \phi_J(J, L, S)$	<i>J, L, S</i>	$\tau_6(J, L)$
7	<i>L</i>	$\tau_6(J, L)$	<i>J, L</i>	$\tau_7(J)$



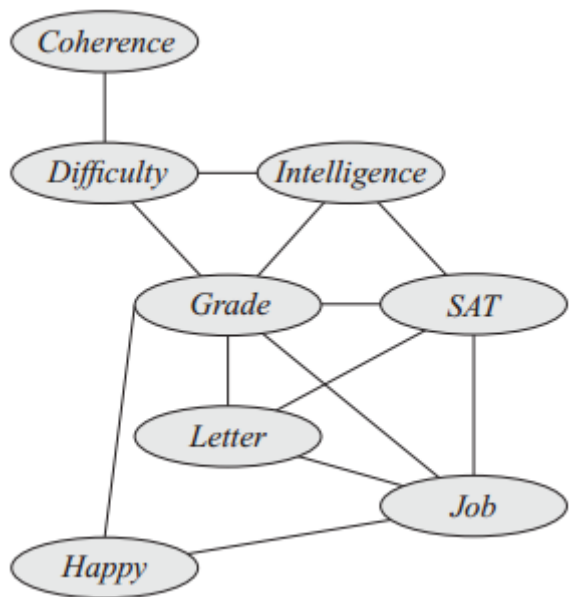
Step	Variable eliminated	Factors used	Variables involved	New factor
1	<i>G</i>	$\phi_G(G, I, D), \phi_L(L, G), \phi_H(H, G, J)$	<i>G, I, D, L, J, H</i>	$\tau_1(I, D, L, J, H)$
2	<i>I</i>	$\phi_I(I), \phi_S(S, I), \tau_1(I, D, L, S, J, H)$	<i>S, I, D, L, J, H</i>	$\tau_2(D, L, S, J, H)$
3	<i>S</i>	$\phi_J(J, L, S), \tau_2(D, L, S, J, H)$	<i>D, L, S, J, H</i>	$\tau_3(D, L, J, H)$
4	<i>L</i>	$\tau_3(D, L, J, H)$	<i>D, L, J, H</i>	$\tau_4(D, J, H)$
5	<i>H</i>	$\tau_4(D, J, H)$	<i>D, J, H</i>	$\tau_5(D, J)$
6	<i>C</i>	$\tau_5(D, J), \phi_C(C), \phi_D(D, C)$	<i>D, J, C</i>	$\tau_6(D, J)$
7	<i>D</i>	$\tau_6(D, J)$	<i>D, J</i>	$\tau_7(J)$

# 有趣现象



Step	Variable eliminated	Factors used	Variables involved	New factor
1	$C$	$\phi_C(C), \phi_D(D, C)$	$C, D$	$\tau_1(D)$
2	$D$	$\phi_G(G, I, D), \tau_1(D)$	$G, I, D$	$\tau_2(G, I)$
3	$I$	$\phi_I(I), \phi_S(S, I), \tau_2(G, I)$	$G, S, I$	$\tau_3(G, S)$
4	$H$	$\phi_H(H, G, J)$	$H, G, J$	$\tau_4(G, J)$
5	$G$	$\tau_4(G, J), \tau_3(G, S), \phi_L(L, G)$	$G, J, L, S$	$\tau_5(J, L, S)$
6	$S$	$\tau_5(J, L, S), \phi_J(J, L, S)$	$J, L, S$	$\tau_6(J, L)$
7	$L$	$\tau_6(J, L)$	$J, L$	$\tau_7(J)$

- 定义：令 $\Phi$ 是 $\mathcal{X} = \{X_1, \dots, X_n\}$ 上的一个因子集， $<$ 是某个子集 $X \in \mathcal{X}$ 的消除顺序。**导出图** $I_{\Phi, <}$ 是 $\mathcal{X}$ 上的一个无向图，其中，如果 $X_i$ 和 $X_j$ 同时出现在VE算法以 $<$ 为消除顺序产生的中间因子 $\psi$ 中，则它们由一条边链接。




Moralization + 填充边 -> 导出图


不同的消除顺序，导致不同的导出图（填充边）

消除顺序为C, D, I, H, G, S, L的一个导出图

- Star:

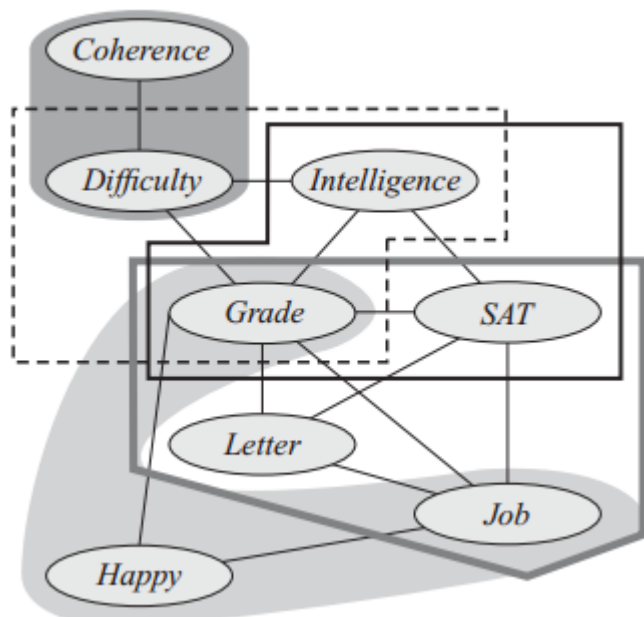


- Tree:





- 定理：令  $I_{\Phi, <}$  是因子集  $\Phi$  和某个消除顺序  $<$  的导出图，那么
  1. 变量消除过程中产生的每个因子的辖域是  $I_{\Phi, <}$  中的一个团
  2.  $I_{\Phi, <}$  中的每个最大团在计算中是某个中间因子的辖域



导出图中的团

Step	Variable eliminated	Factors used	Variables involved	New factor
1	$C$	$\phi_C(C), \phi_D(D, C)$	$C, D$	$\tau_1(D)$
2	$D$	$\phi_G(G, I, D), \tau_1(D)$	$G, I, D$	$\tau_2(G, I)$
3	$I$	$\phi_I(I), \phi_S(S, I), \tau_2(G, I)$	$G, S, I$	$\tau_3(G, S)$
4	$H$	$\phi_H(H, G, J)$	$H, G, J$	$\tau_4(G, J)$
5	$G$	$\tau_4(G, J), \tau_3(G, S), \phi_L(L, G)$	$G, J, L, S$	$\tau_5(J, L, S)$
6	$S$	$\tau_5(J, L, S), \phi_J(J, L, S)$	$J, L, S$	$\tau_6(J, L)$
7	$L$	$\tau_6(J, L)$	$J, L$	$\tau_7(J)$

计算中使用的每个因子  $\psi$ ，对应于图  $I_{\Phi, <}$  的一个完全子图

# BP算法，团树



你要不要吃  
饼干休息下


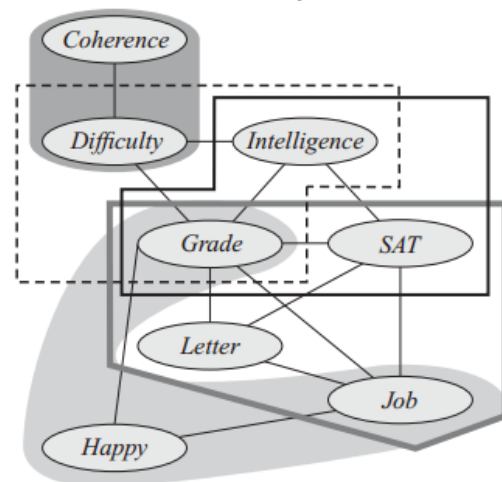
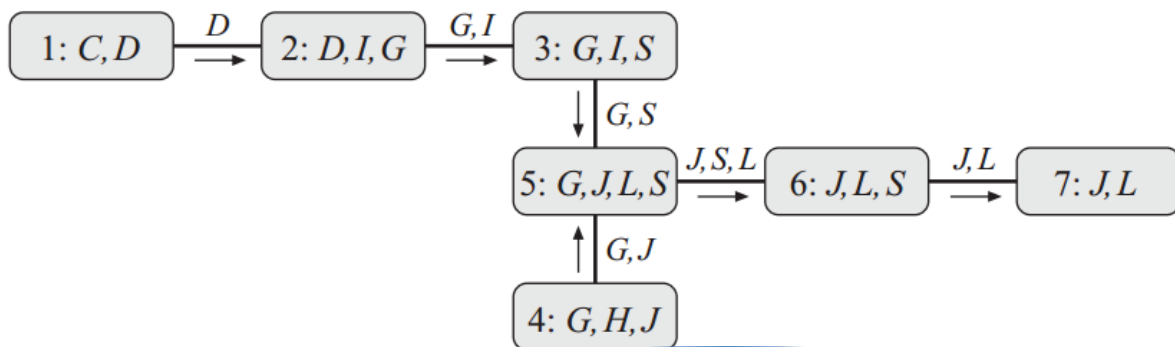


变量消除算法中，每一步通过已有的因子相乘来产生新的因子 $\psi_i$ ，然后在 $\psi_i$ 中消除一个变量，产生新因子 $\tau_i$ ，接着用 $\tau_i$ 产生下一个因子 $\psi_j$

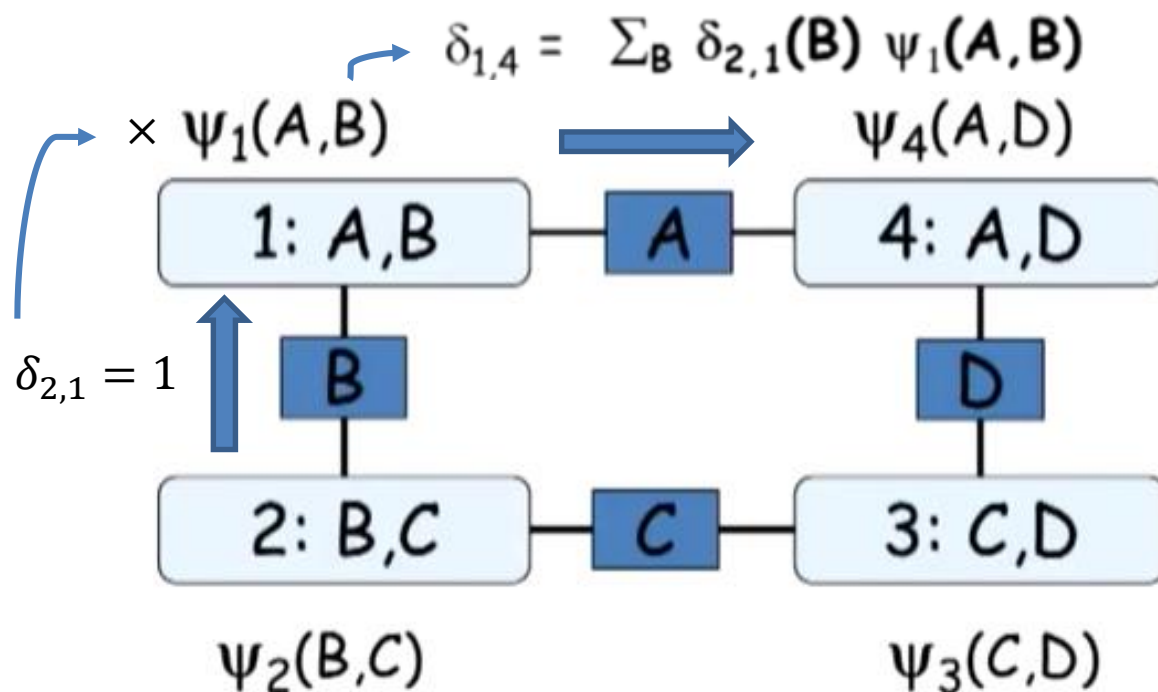
基于这种运算，接下来考虑另一种观点：

把因子 $\psi_i$ 作为一种计算的数据结构考虑，它携带者由其他因子 $\psi_j$ 产生的“消息” $\tau_j$ ，并且产生用于其他因子 $\psi_l$ 的消息 $\tau_i$

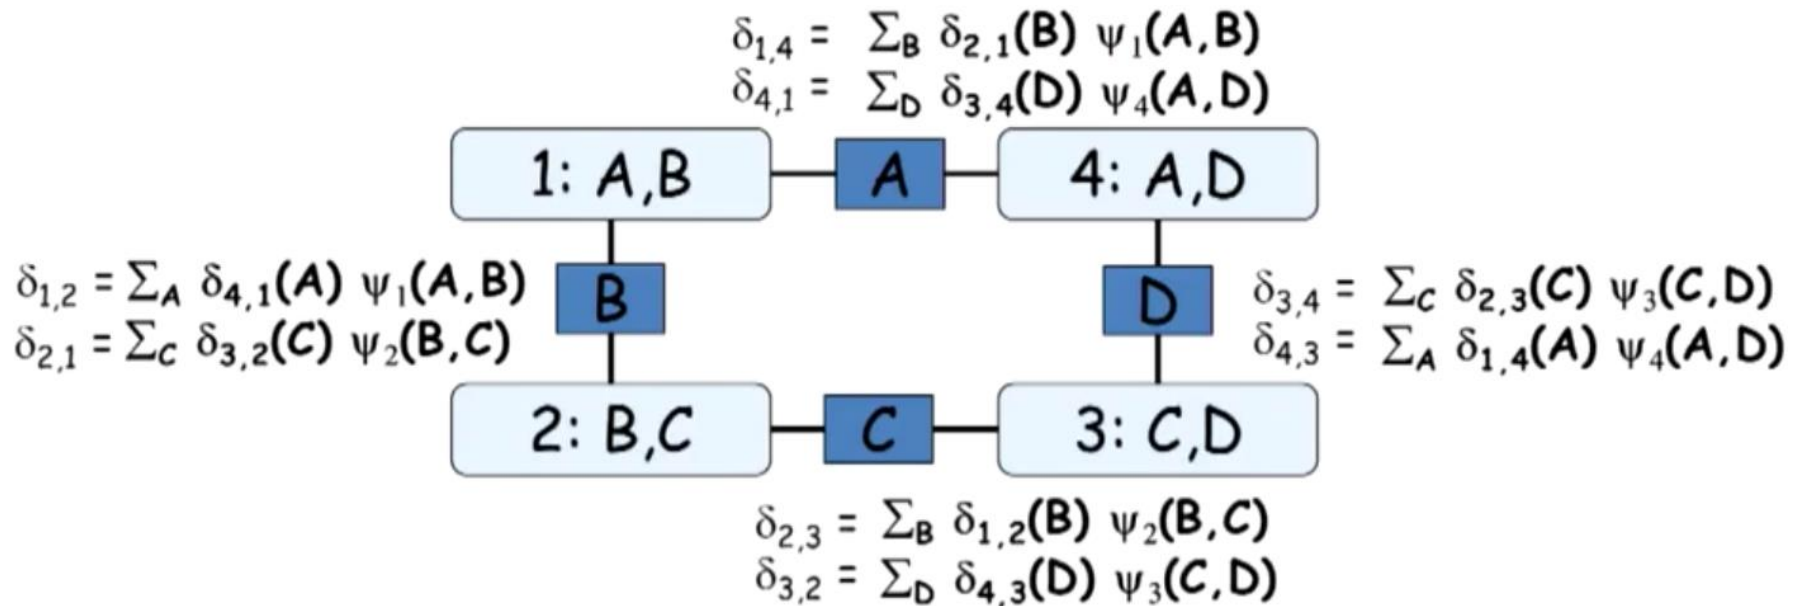
- 定义： $X$ 上的关于因子集 $\Phi$ 的**聚类图** $u$ 是一个无向图，它的每个节点 $i$ 与一个子集 $C_i \subseteq X$ 关联。聚类图必须是族保存的——每个因子 $\phi \subseteq \Phi$ 必须与一个聚类图 $C_i$ 关联，表示为 $\alpha(\phi)$ ，使得 $Scope[\phi] \subseteq C_i$ 。一对聚类 $C_i$ 和 $C_j$ 之间的每条边与一个割集 $S_{i,j} \subseteq C_i \cap C_j$ 关联。



- 初始化势能  $\psi_i(\mathbf{C}_i) = \prod_{k:\alpha(k)=i} \phi_k$ 。在此例中， $\psi_i = \phi_i$
- 初始化消息  $\delta_i = 1$
- 接收消息的团，接收其上游的消息，将消息与自己的势能相乘，并边缘化后形成新的消息，传给下游的团
- 传递消息直到收敛



- 初始化势能  $\psi_i(\mathbf{C}_i) = \prod_{k:\alpha(k)=i} \phi_k$ 。在此例中， $\psi_i = \phi_i$
- 初始化消息  $\delta_i = 1$
- 接收消息的团，接收其上游的消息，将消息与自己的势能相乘，并边缘化后形成新的消息，传给下游的团
- 传递消息直到收敛




- 将因子  $\phi_k \in \Phi$  指定给团  $\mathbf{C}_{\alpha(k)}$
- 初始化势能  $\psi_i(\mathbf{C}_i) = \prod_{k:\alpha(k)=i} \phi_k$
- 将所有消息  $\delta_i$  初始化为 1
- 重复：
  - 选择边  $(i,j)$  传播消息

$$\delta_{i \rightarrow j}(\mathbf{S}_{i,j}) = \sum_{\mathbf{C}_i - \mathbf{S}_{i,j}} \psi_i \times \prod_{k \in (\mathcal{N}_i - \{j\})} \delta_{k \rightarrow i}$$

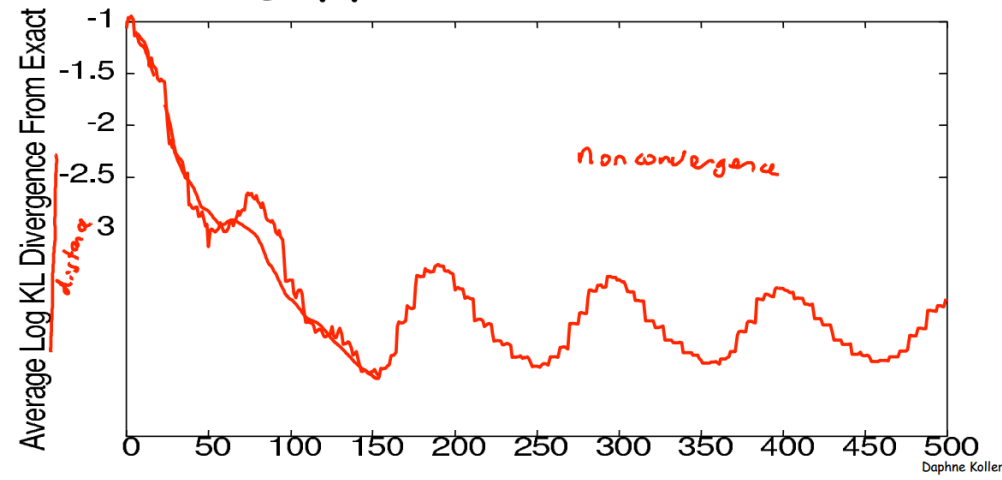
- 计算团置信

$$\beta_i \leftarrow \psi_i \cdot \prod_{k \in \text{Nb}_i} \delta_{k \rightarrow i}$$

## Belief Propagation Run



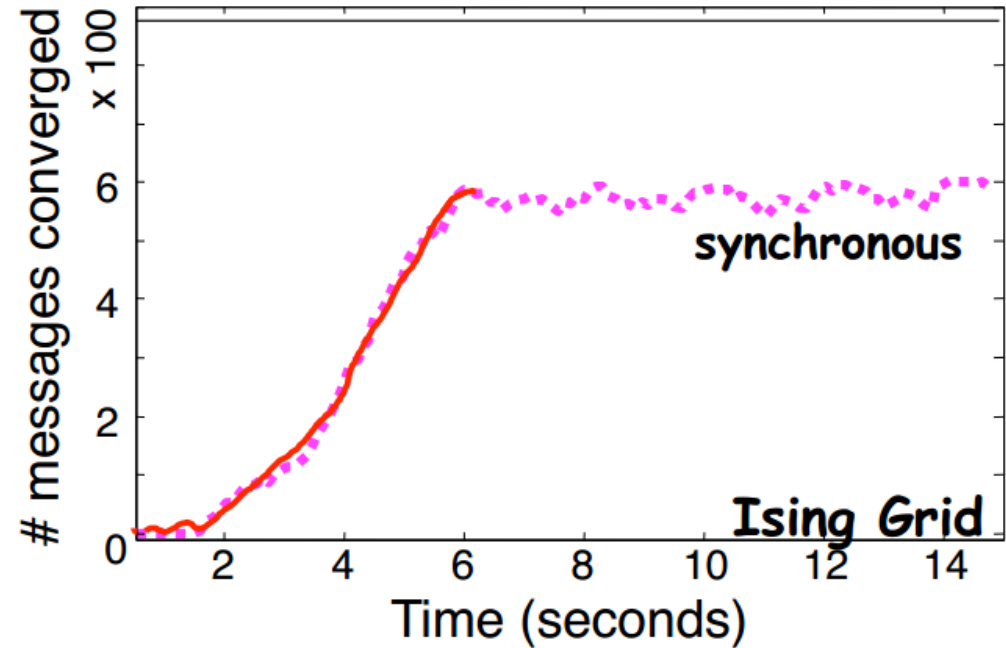

## Different BP Run



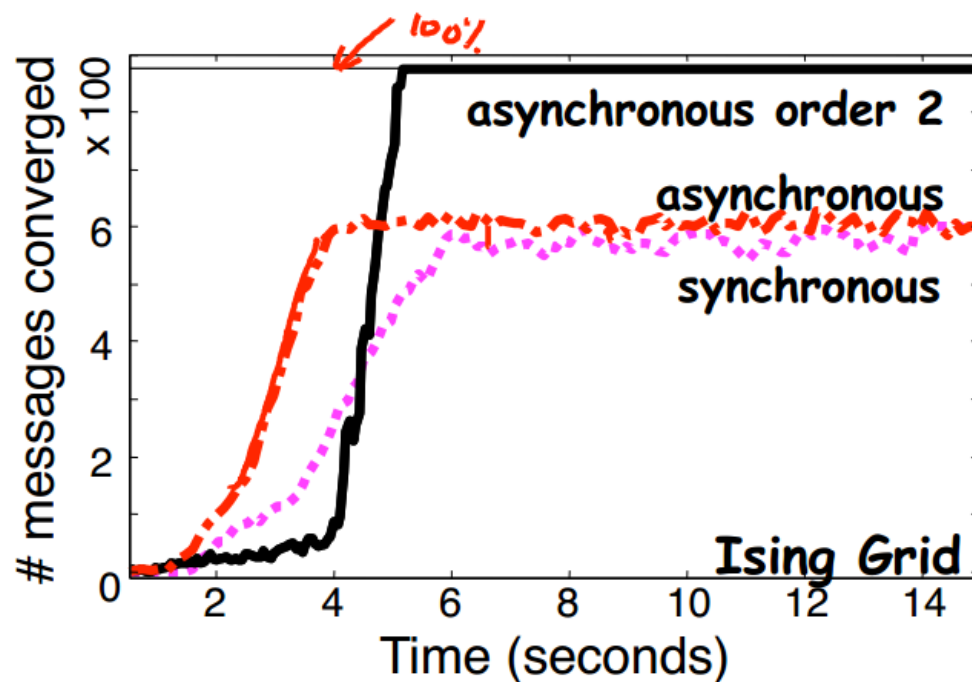



## Synchronous BP:


all messages are updated in parallel




Asynchronous BP:  
Messages are updated  
one at a time




- **族保存**：每个因子  $\phi \subseteq \Phi$  必须与一个聚类图  $C_i$  关联，表示为  $\alpha(\phi)$ ，使得  $Scope[\phi] \subseteq C_i$ 。一对聚类  $C_i$  和  $C_j$  之间的每条边与一个割集  $S_{i,j} \subseteq C_i \cap C_j$  关联。
- **执行相交性**：对于一对簇  $C_i$  与  $C_j$ ，以及变量  $X$  使得  $X \in C_i \cap C_j$ ，在  $C_i$  和  $C_j$  之间**存在**一条**唯一**的路径，使得变量  $X$  存在于该路径上的所有簇中。



合法的聚类图



不符合“存在”



不符合“唯一”

- 定义：如果

$$\sum_{C_i - S_{i,j}} \beta_i(C_i) = \sum_{C_j - S_{i,j}} \beta_j(C_j)$$

那么两个相邻的团 $C_i$ 和 $C_j$ 是**校准的**。

- 如果聚类图中，所有成对的相邻团都是校准的，那么该聚类图是**校准的**。

- 收敛  $\Rightarrow$  校准

收敛： $\delta_{i \rightarrow j}(S_{i,j}) = \delta'_{i \rightarrow j}(S_{i,j})$

$$\delta'_{i \rightarrow j}(S_{i,j}) = \sum_{C_i - S_{i,j}} \left( \psi_i \times \prod_{k \in (N_i - \{j\})} \delta_{k \rightarrow i} \right) = \sum_{C_i - S_{i,j}} \frac{\beta_i(C_i)}{\delta_{j \rightarrow i}(S_{i,j})}$$

$$\beta_i = \psi_i \cdot \prod_{k \in Nb_i} \delta_{k \rightarrow i}$$

$$\delta_{j \rightarrow i}(S_{i,j}) \delta_{i \rightarrow j}(S_{i,j}) = \sum_{C_i - S_{i,j}} \beta_i(C_i)$$

$$\delta_{j \rightarrow i}(S_{i,j}) \delta_{i \rightarrow j}(S_{i,j}) = \sum_{C_j - S_{i,j}} \beta_j(C_j)$$

$$\sum_{C_i - S_{i,j}} \beta_i(C_i) = \sum_{C_j - S_{i,j}} \beta_j(C_j)$$

割集置信  $\mu_{i,j}(S_{i,j}) = \delta_{j \rightarrow i} \delta_{i \rightarrow j} = \sum_{C_j - S_{i,j}} \beta_j(C_j)$

## ➤ 再参数化

在**校准**的聚类图的算法**收敛**处，下式成立

$$\tilde{P}_\Phi(\mathcal{X}) = \frac{\prod_{i \in \mathcal{V}_T} \beta_i(\mathbf{C}_i)}{\prod_{(i-j) \in \mathcal{E}_T} \mu_{i,j}(\mathbf{S}_{i,j})}$$

证明：

根据  $\beta_i = \psi_i \cdot \prod_{k \in \text{Nb}_i} \delta_{k \rightarrow i}$

原始分子可以写成

$$\prod_{i \in \mathcal{V}_T} \psi_i(\mathbf{C}_i) \prod_{k \in \text{Nb}_i} \delta_{k \rightarrow i}$$

根据

$$\mu_{i,j}(\mathbf{S}_{i,j}) = \delta_{j \rightarrow i} \delta_{i \rightarrow j}$$

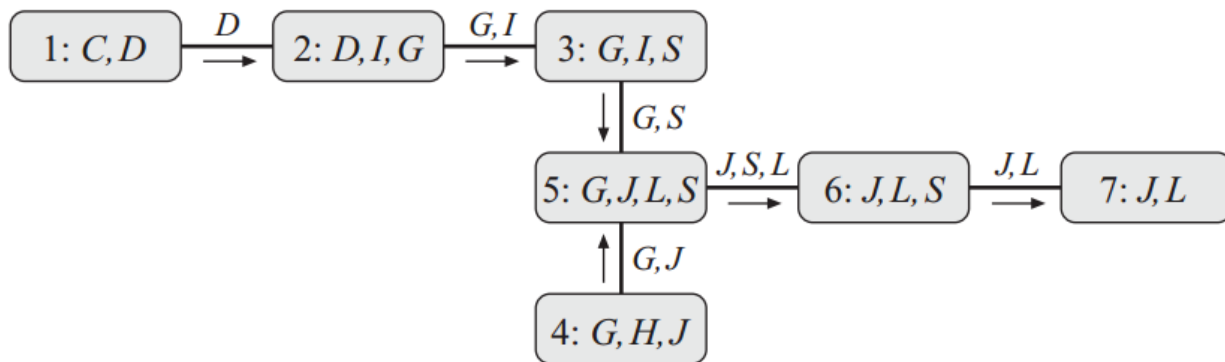
分母改写为

$$\prod_{(i-j) \in \mathcal{E}_T} \delta_{i \rightarrow j} \delta_{j \rightarrow i}$$



$$\prod_{i \in \mathcal{V}_T} \psi_i(\mathbf{C}_i) = \tilde{P}_\Phi$$

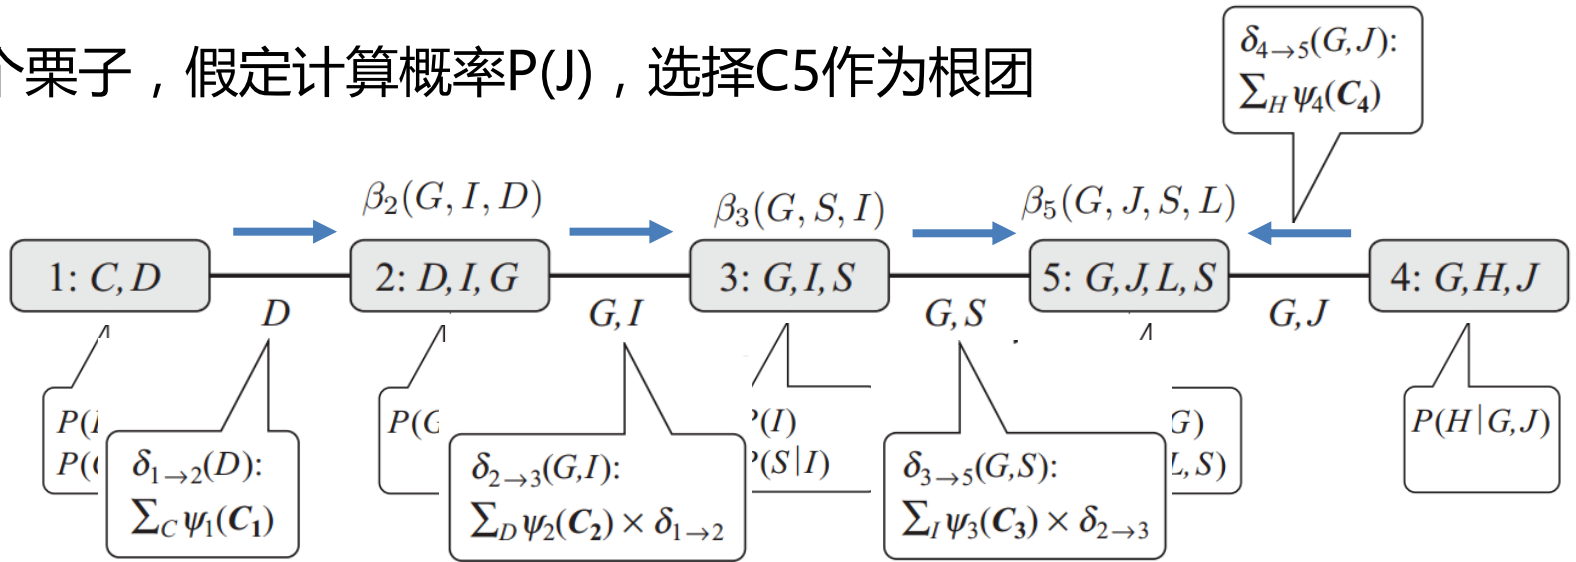
- 特殊地，变量消除算法的一个执行，得到的聚类图一定是一棵树。
- 定理：令 $\mathcal{T}$ 是由变量消除算法在某个因子集 $\Phi$ 上产生的聚类树，则 $\mathcal{T}$ 满足**执行相交性**。
- 命题：令 $\mathcal{T}$ 是变量消除算法在某个因子集 $\Phi$ 上产生的聚类树。令 $C_i$ 和 $C_j$ 是两个相邻的簇，并且 $C_i$ 向 $C_j$ 发送消息 $\tau_i$ ，则消息 $\tau_i$ 的辖域恰好是 $C_i \cap C_j$



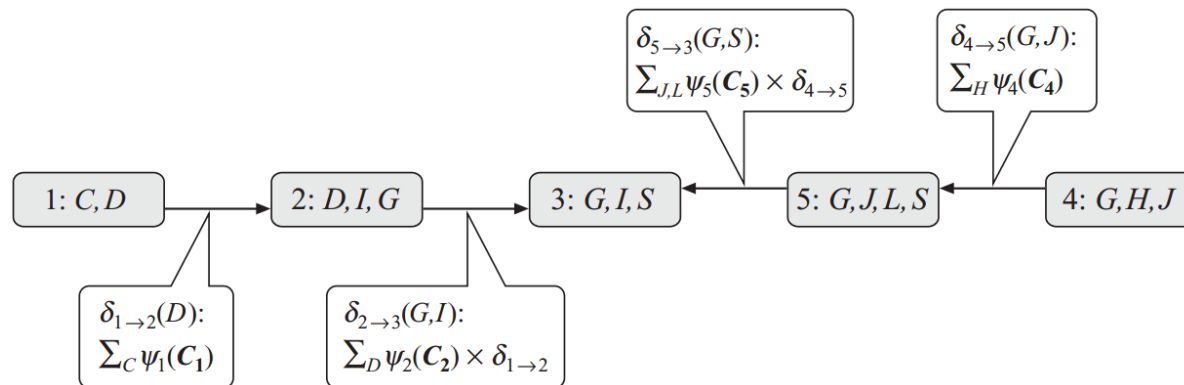
- 定义：设 $\Phi$ 是 $X$ 上的因子集， $\Phi$ 上满足**执行相交性**的聚类树，称为**团树**（clique tree）（也成为连接树或联合树），在团树的情况下，簇（cluster）也成为**团**（clique）

- 使用团树的好处：
  - 保证BP算法的**收敛性**（就绪—等待）
  - 保证BP算法的**正确性**（满足族保持性和执行相交性，自己下来证明）

- 举个栗子，假定计算概率 $P(J)$ ，选择 $C_5$ 作为根团



- 另一个顺序的执行。C3作为根团



- 注意到：

在C1，C2，C4中，计算和消息都不变。

在C5中，定义  $\beta_5(G, J, S, L) = \delta_{4 \rightarrow 5}(G, J) \cdot \psi_5(G, J, S, L)$ 。

并消除J和L后，将  $\delta_{5 \rightarrow 3}(G, S)$  作为消息发给C3


C3接收来自于其邻居发送的消息，与自己的初始势能相乘，计算出团置信



- 在团树消息传递过程中，不一定是同步的，消息可以异步的传播，只要满足约束：

团在给其上游近邻发出消息之前，必须收集所有来自其下游近邻传入的消息

- 如果一个团已经完成了所需消息的收集，那么该团是**就绪的**
- 叶子节点是就绪的



## Algorithm 10.1 Upward pass of variable elimination in clique tree

**Procedure** CTree-SP-Upward (

$\Phi$ , // Set of factors

$\mathcal{T}$ , // Clique tree over  $\Phi$

$\alpha$ , // Initial assignment of factors to cliques

$C_r$  // Some selected root clique

)

1 Initialize-Cliques

2 **while**  $C_r$  is not ready

3     Let  $C_i$  be a ready clique

4      $\delta_{i \rightarrow p_r(i)}(\mathcal{S}_{i,p_r(i)}) \leftarrow \text{SP-Message}(i, p_r(i))$

5      $\beta_r \leftarrow \psi_r \cdot \prod_{k \in \text{Nb}_{C_r}} \delta_{k \rightarrow r}$

6     **return**  $\beta_r$

**Procedure** Initialize-Cliques (

)

1 **for** each clique  $C_i$

2      $\psi_i(C_i) \leftarrow \prod_{\phi_j : \alpha(\phi_j) = i} \phi_j$

3

**Procedure** SP-Message (

$i$ , // sending clique

$j$  // receiving clique

)

1  $\psi(C_i) \leftarrow \psi_i \cdot \prod_{k \in (\text{Nb}_i - \{j\})} \delta_{k \rightarrow i}$

2  $\tau(\mathcal{S}_{i,j}) \leftarrow \sum_{C_i - \mathcal{S}_{i,j}} \psi(C_i)$

3 **return**  $\tau(\mathcal{S}_{i,j})$

- 有时我们不只关注一个团的查询，而是多个团。为方便日后分布的表示和查询，我们希望团树是校准的。即求得所有团的置信因子 $\beta$ 。算法如下：

**Algorithm 10.2 Calibration using sum-product message passing in a clique tree**

**Procedure** CTree-SP-Calibrate (

$\Phi$ , // Set of factors

$\mathcal{T}$  // Clique tree over  $\Phi$

)

1 Initialize-Cliques

2 **while** exist  $i, j$  such that  $i$  is ready to transmit to  $j$


3  $\delta_{i \rightarrow j}(\mathcal{S}_{i,j}) \leftarrow \text{SP-Message}(i, j)$

4 **for** each clique  $i$

5  $\beta_i \leftarrow \psi_i \cdot \prod_{k \in \text{Nb}_i} \delta_{k \rightarrow i}$

6 **return**  $\{\beta_i\}$

- 算法异步定义
- 过程由**向上传递**和**向下传递**组成



- 由于**校准**团树能保证收敛性和正确性，其**再参数化**性质成立：

$$\tilde{P}_{\Phi}(\mathcal{X}) = \frac{\prod_{i \in \mathcal{V}_{\mathcal{T}}} \beta_i(\mathbf{C}_i)}{\prod_{(i,j) \in \mathcal{E}_{\mathcal{T}}} \mu_{i,j}(\mathbf{S}_{i,j})}$$

- 由此，团树可以看作是联合分布的另一种表示形式
- 一个例子：

Assignment			max <sub>C</sub>
a <sup>0</sup>	b <sup>0</sup>	d <sup>0</sup>	600,000
a <sup>0</sup>	b <sup>0</sup>	d <sup>1</sup>	300,030
a <sup>0</sup>	b <sup>1</sup>	d <sup>0</sup>	5,000,500
a <sup>0</sup>	b <sup>1</sup>	d <sup>1</sup>	1,000
a <sup>1</sup>	b <sup>0</sup>	d <sup>0</sup>	200
a <sup>1</sup>	b <sup>0</sup>	d <sup>1</sup>	1,000,100
a <sup>1</sup>	b <sup>1</sup>	d <sup>0</sup>	100,010
a <sup>1</sup>	b <sup>1</sup>	d <sup>1</sup>	200,000


$\beta_1(A, B, D)$

Assignment		max <sub>A,C</sub>
b <sup>0</sup>	d <sup>0</sup>	600,200
b <sup>0</sup>	d <sup>1</sup>	1,300,130
b <sup>1</sup>	d <sup>0</sup>	5,100,510
b <sup>1</sup>	d <sup>1</sup>	201,000

$\mu_{1,2}(B, D)$

Assignment			max <sub>A</sub>
b <sup>0</sup>	c <sup>0</sup>	d <sup>0</sup>	300,100
b <sup>0</sup>	c <sup>0</sup>	d <sup>1</sup>	1,300,000
b <sup>0</sup>	c <sup>1</sup>	d <sup>0</sup>	300,100
b <sup>0</sup>	c <sup>1</sup>	d <sup>1</sup>	130
b <sup>1</sup>	c <sup>0</sup>	d <sup>0</sup>	510
b <sup>1</sup>	c <sup>0</sup>	d <sup>1</sup>	100,500
b <sup>1</sup>	c <sup>1</sup>	d <sup>0</sup>	5,100,000
b <sup>1</sup>	c <sup>1</sup>	d <sup>1</sup>	100,500

$\beta_2(B, C, D)$



$$\tilde{P}_{\Phi}(a^1, b^0, c^1, d^0) = \frac{\beta_1(a^1, b^0, d^0) \beta_2(b^0, c^1, d^0)}{\mu_{1,2}(b^0, d^0)} = \frac{200 \cdot 300,100}{600,200} = 100$$

- 见概率图模型10.3.1节

$$\delta_{i \rightarrow j} = \frac{\sum c_i - s_{i,j} \beta_i}{\delta_{j \rightarrow i}}.$$

- 查询的变量都在一个团中：

so easy ! 毕竟在校准团树中 ,  $\beta_i(\mathbf{C}_i) = \tilde{P}(\mathbf{C}_i)$  , do whatever you want !

- 增量更新

假设分布：
$$\tilde{P}_{\Phi}(\mathcal{X}) = \prod_{\phi \in \Phi} \phi$$

存在证据z，那么：
$$\tilde{P}_{\Phi}(\mathcal{X}, Z = z) = \mathbf{1}\{Z = z\} \prod_{\phi \in \Phi} \phi$$

令：
$$\tilde{P}'_{\Phi}(\mathcal{X}) = \tilde{P}_{\Phi}(\mathcal{X}, Z = z)$$

假设有一个用团树不变量表示该分部的团树（校准或非校准的）

$$\tilde{P}_{\Phi}(\mathcal{X}) = \frac{\prod_{i \in \mathcal{V}_{\mathcal{T}}} \beta_i(\mathbf{C}_i)}{\prod_{(i-j) \in \mathcal{E}_{\mathcal{T}}} \mu_{i,j}(\mathbf{S}_{i,j})}$$

$\tilde{P}'_{\Phi}(\mathcal{X})$ 可表示为：
$$\tilde{P}'_{\Phi}(\mathcal{X}) = \mathbf{1}\{Z = z\} \frac{\prod_{i \in \mathcal{V}_{\mathcal{T}}} \beta_i(\mathbf{C}_i)}{\prod_{(i-j) \in \mathcal{E}_{\mathcal{T}}} \mu_{i,j}(\mathbf{S}_{i,j})}$$

- 如果团树在引入证据前已经校准，那么 $\mathbf{C}_i$ 已经吸收了图中所有信息。为了获得 $\tilde{P}'_{\Phi}(\mathbf{C}_i)$ 不需要额外的消息传递。然而，其他团仍需要用新的消息来更新。

- 团外查询：考虑查询 $P(\mathbf{Y}|e)$ ，其中变量 $\mathbf{Y}$ 不会一起出现在一个团中  
naïve方法：强行构建一个团树，其中团包含 $\mathbf{Y}$ 的所有变量  
another way：在校准的团树上执行变量消除
- 如果一棵团树是校准的，那么该团树的任意子树也是校准的
- 例子：考虑如下简单团树，并假定该团树已经得到校准，所以可以再参数化表示该分布。现计算 $\tilde{P}_{\Phi}(B, D)$

$$\tilde{P}_{\Phi}(B, C, D) = \frac{\beta_2(B, C)\beta_3(C, D)}{\mu_{2,3}(C)}$$

$$\begin{aligned}\tilde{P}_{\Phi}(B, D) &= \sum_C \tilde{P}_{\Phi}(B, C, D) \\ &= \sum_C \frac{\beta_2(B, C)\beta_3(C, D)}{\mu_{2,3}(C)} \\ &= \sum_C \tilde{P}_{\Phi}(B | C)\tilde{P}_{\Phi}(C, D),\end{aligned}$$



- 源自变量消除的团树（见概率图模型10.4.1节）
- 源自弦图的团树（见概率图模型10.4.2节）

# Thanks

## Q & S

