



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



# 贝叶斯网中的结构学习

## 于忠靖



Data Mining Lab, Big Data Research Center, UESTC  
Email: [junmshao@uestc.edu.cn](mailto:junmshao@uestc.edu.cn)  
<http://staff.uestc.edu.cn/shaojunming>

## 1. 简介

- 问题定义
- 方法概述

## 2. 基于约束的方法

## 3. 结构评分

- 似然评分
- 贝叶斯评分
- 单变量的边缘似然
- 贝叶斯网络的贝叶斯评分
- 先验

## 4. 结构搜索

## 问题定义

**目标:** 仅从给定的数据中学习网络模型（重构网络）。

**假设:** 数据根据未知分布采样，且满足独立同分布；数据能完全被观测到

**学习网络结构的原因:**

**知识发现:** 探索网络中依赖关系，获得领域中变量的依赖关系。

**密度估计:** 估计潜在分布的统计模型。将得到的网络结构能泛化到新样本上。

无事先指定结构的学习方法:

## ➤ 基于约束的结构学习

**思想:** 将贝叶斯网看作独立关系的表示, 尝试对数据中**条件依赖**和**条件独立关系**进行检验, 找到最好解释的某个网络。

**方法:** 给出一个满足**独立关系的分布**, 寻找该分布对于的**I-map**。

## ➤ 基于得分的结构学习

**思想:** 将贝叶斯网视为统计模型, 然后把学习作为**模型选择**问题来处理。

**方法:** 考虑可能的**网络结构集合**, 并定义测量模型对观测数据拟合程度的**得分函数**, 选**最高者**。

## 总体框架:

找到该领域最好最小I-map

主要技术问题:

如何回答数据中变量间的条件独立性查询。

方法: 假设检验 (单边假设检验)

如何设计好的决策规则 (判定是否拒绝输入)

偏差度量

定义偏离零假设的度量

构造网络

使用Build-PDAG算法

## 单边假设检验（如何评估决策规则）

- 零假设：数据从分布  $P^*(X, Y) = P^*(X)P^*(Y)$  中采样生成。一般令  $P^*(X, Y) = \hat{P}(X)\hat{P}(Y)$  来生成零假设 ( $\hat{P}(\square) \approx P^*(\square)$ )。



- 检验数据是否符合零假设 → 找到一个决策规则的过程。  
选择好决策规则后可计算错误拒绝概率：

$$P(\{D: R(D) = \text{Re}ject\} | H_0, M)$$

规则R有错误拒绝的概率  $p$ ， $1-p$ 代表拒绝某个假设的决策置信度。

## 偏差度量（如何设计决策规则）

标准框架：定义偏离零假设的度量。

例如：独立随机变量： $X$ 、 $Y$ ；

数据计数： $M[x, y]$  接近于  $M \square \hat{P}(x) \square \hat{P}(y)$  (计数的期望值)

**$\chi^2$  统计量：** 
$$d_{\chi^2}(D) = \sum_{x,y} \frac{(M[x, y] - M \square \hat{P}(x) \square \hat{P}(y))^2}{M \square \hat{P}(x) \square \hat{P}(y)}$$

$d_{\chi^2}(D) = 0$  完全拟合独立性假设的数据。

**互信息量：** 
$$d_I(D) = I_{\hat{P}_D}(X; Y) = \frac{1}{M} \sum_{x,y} M[x, y] \log \frac{M[x, y]}{M[x]M[y]}$$

度量



设计规则：

$$R_{d,t}(D) = \begin{cases} \text{接受,} & d(D) \leq t \\ \text{拒绝,} & d(D) > t \end{cases}$$

其中， $t$  决定决策规则的错误拒绝概率。


对  $\chi^2$  统计量进行扩展以检验条件独立性:

假设希望给定  $Z$  时检验  $X$  和  $Y$  是否独立。

零假设  $H_0$  是  $P^*(X, Y, Z) = \hat{P}(Z)\hat{P}(X | Z)\hat{P}(Y | Z)$

$\chi^2$  统计量是:

$$d_{\chi^2}(D) = \sum_{x,y,z} \frac{(M[x, y, z] - M \hat{P}(z)\hat{P}(x | z)\hat{P}(y | z))^2}{M \hat{P}(x | z)\hat{P}(y | z)}$$





以上介绍了如何检测变量之间的独立性检测问题。得到变量间关系之后就可以**构建网络**了。

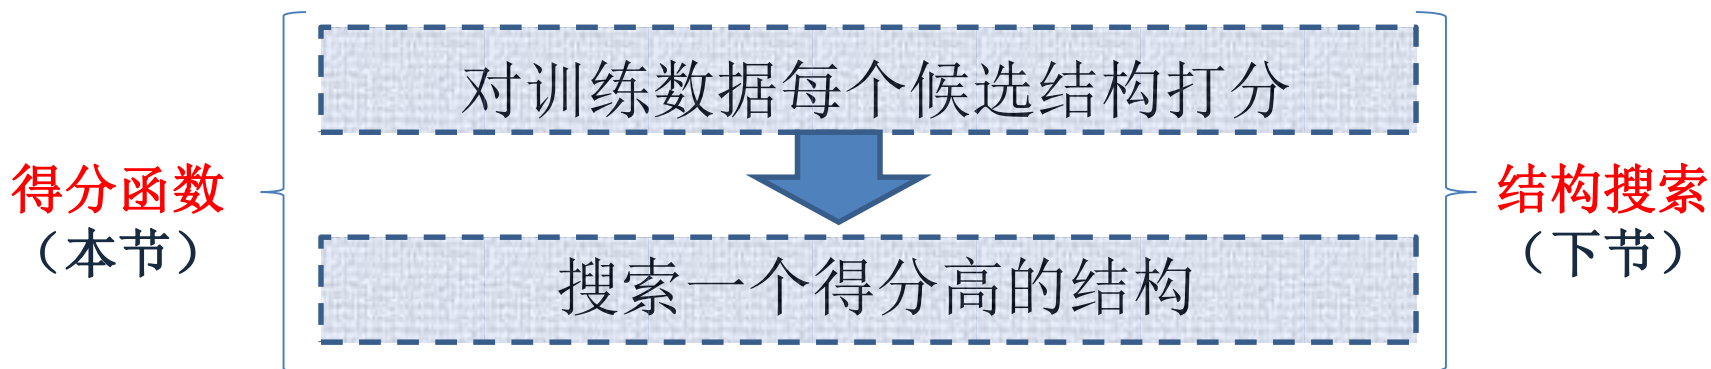
利用Build-PDAG算法构建网络：

详细见第3章算法3.5

- 存在**错误决策风险**，特别多重假设检验时，错误结论数量增加。
- Build-PDAG对以上错误很**敏感**，从而误导PDAG的生成。

该类方法将结构学习看做一个**优化问题**来解决。

## 框架:



## 得分函数:

- 似然得分
- 贝叶斯得分

# 结构得分(似然得分)

直观上，使数据尽可能代表的模型。

**目标：**找到最大化似然图  $G$  和参数  $\theta_G$  (模型为  $\langle G, \theta_G \rangle$  组成)。

给定图结构  $G$  最大化似然参数：

$$\begin{aligned} \max_{G, \theta_G} L(\langle G, \theta_G \rangle : D) &= \max_G [\max_{\theta_G} L(\langle G, \theta_G \rangle : D)] \\ &= \max_G [L(\langle G, \hat{\theta}_G \rangle : D)] \end{aligned}$$

反之

使用  $G$  的 MLE 参数时，寻找达到最大似然的图结构  $G$

$$\text{定义： } score_L(G : D) = l(\hat{\theta}_G : D)$$

$l(\hat{\theta}_G : D)$  是似然对数， $\hat{\theta}_G$  是  $G$  的最大似然参数。

# 结构得分(似然得分)




## 信息论解释:

➤  $G_0$ : X与Y独立

$$\text{score}_L(G_0 : \mathcal{D}) = \sum_m \log \hat{\theta}_{x[m]} + \log \hat{\theta}_{y[m]}$$

➤  $G_1$ : 存在边  $X \rightarrow Y$

$$\text{score}_L(G_1 : \mathcal{D}) = \sum_m \log \hat{\theta}_{x[m]} + \log \hat{\theta}_{y[m]|x[m]}$$



➤ 得分差异:

$$\text{score}_L(G_1 : \mathcal{D}) - \text{score}_L(G_0 : \mathcal{D}) = \sum_m \log \hat{\theta}_{y[m]|x[m]} - \log \hat{\theta}_{y[m]}$$

**注:**  $x[m]$ 表示变量X为m状态。 $\hat{\theta}_{x|y}$ 表示  $P(x)$  的最大似然估计,  $\hat{\theta}_{x|y}$  是  $P(y|x)$  的最大似然估计。

# 结构得分(似然得分)



$$\text{score}_L(\mathcal{G}_1 : \mathcal{D}) - \text{score}_L(\mathcal{G}_0 : \mathcal{D}) = \sum_m \log \hat{\theta}_{y[m]|x[m]} - \log \hat{\theta}_{y[m]}$$

写出每个数据  $x, y$

$$\text{score}_L(\mathcal{G}_1 : \mathcal{D}) - \text{score}_L(\mathcal{G}_0 : \mathcal{D}) = \sum_{x,y} M[x,y] \log \hat{\theta}_{y|x} - \sum_y M[y] \log \hat{\theta}_y$$

$$M[x,y] = M \cdot \hat{P}(x,y)$$

$$M[y] = M \cdot \hat{P}(y)$$

$$\hat{\theta}_{y|x} = \hat{P}(y|x)$$

$$\hat{\theta}_y = \hat{P}(y)$$

$$\text{score}_L(\mathcal{G}_1 : \mathcal{D}) - \text{score}_L(\mathcal{G}_0 : \mathcal{D}) = M \sum_{x,y} \hat{P}(x,y) \log \frac{\hat{P}(y|x)}{\hat{P}(y)} = M \cdot I_{\hat{P}}(X;Y)$$

似然取决于变量间的互信息量。互信息量越大，依赖性越强

其中  $I_{\hat{P}}(X,Y)$  是分布  $\hat{P}$  中  $X$  与  $Y$  的互信息。

# 结构得分(似然得分)

推广到一般网络结构:

似然得分可以分解如下:

$$\text{score}_L(\mathcal{G} : \mathcal{D}) = M \sum_{i=1}^n I_{\hat{p}}(X_i; \text{Pa}_{X_i}^{\mathcal{G}}) - M \sum_{i=1}^n H_{\hat{p}}(X_i)$$

证明: 定义:  $\text{score}_L(\mathcal{G} : \mathcal{D}) = l(\hat{\theta}_{\mathcal{G}} : \mathcal{D})$

$$l(\hat{\theta}_{\mathcal{G}} : \mathcal{D}) = \sum_{i=1}^n \left[ \sum_{u_i \in \text{Val}(\text{Pa}_{X_i}^{\mathcal{G}})} \sum_{x_i} M[x_i, u_i] \log \hat{\theta}_{x_i|u_i} \right] \xrightarrow{U_i = \text{Pa}_{X_i}}$$

$$\frac{1}{M} \sum_{u_i} \sum_{x_i} M[x_i, u_i] \log \hat{\theta}_{x_i|u_i} \rightarrow \text{Jerry} \rightarrow \text{Tom} \rightarrow \text{Jerry and Tom}$$

$$\rightarrow \underbrace{I_{\hat{p}}(X_i; U_i) - H_{\hat{p}}(X_i)}_{\text{网络中变量的熵, 不依赖网络结构}}$$

网络似然度量了变量与其父节点的依赖强度, 即倾向于每个变量的父节点对变量有信息量的网络




# 结构得分(似然得分)



## 最大似然得分局限

### 偏好更复杂的网络



$$\text{score}_L(\mathcal{G}_{X \rightarrow Y} : \mathcal{D}) - \text{score}_L(\mathcal{G}_\phi : \mathcal{D}) = M \cdot I_p(X; Y)$$

$$\forall \mathcal{D} \quad \text{score}_L(\mathcal{G}_{X \rightarrow Y} : \mathcal{D}) \geq \text{score}_L(\mathcal{G}_\phi : \mathcal{D}) \quad \text{互信息量非负}$$

$\mathcal{G}_{X \rightarrow Y}$  为  $X$  是  $Y$  的父节点网络。

当条件独立在经验分布中恰好确切成立，最大似然网络将不表现出条件独立性。统计噪声使得这种情况几乎不存在。因此，似然过拟合了训练数据，泛化能力降低。

有没有更好的得分函数，使得更好的描述结构得分？



# 结构得分(贝叶斯得分)

**贝叶斯原则：**对任何事物的不确定，都应为其确定一个分布。

结构



参数

定义：结构先验 $P(G)$ ，参数先验 $P(\theta_G | G)$

$$P(G | \mathcal{D}) = \frac{P(\mathcal{D} | G)P(G)}{P(\mathcal{D})}$$

**贝叶斯得分定义：**

$$\text{score}_B(G : \mathcal{D}) = \log P(\mathcal{D} | G) + \log P(G)$$



对比似然得分，贝叶斯得分有更好的泛化能力，防止过拟合？



# 结构得分(贝叶斯得分)

窥探一下

$$\text{score}_B(\mathcal{G} : \mathcal{D}) = \log P(\mathcal{D} | \mathcal{G}) + \log P(\mathcal{G})$$

考虑参数的不确定性

$$\text{边缘似然: } P(\mathcal{D} | \mathcal{G}) = \int_{\theta_{\mathcal{G}}} P(\mathcal{D} | \theta_{\mathcal{G}}, \mathcal{G}) P(\theta_{\mathcal{G}} | \mathcal{G}) d\theta_{\mathcal{G}}$$

给定网络时数据的似然

网络参数值的先验分布



边缘似然与最大似然差异:

- 最大似然: 返回这个函数的**最大值**
- 边缘似然: 是这个函数的**平均值**, 基于先验度量  $P(\theta_{\mathcal{G}} | \mathcal{G})$  做的平均。

最大似然: 给定数据集D时最可能选择的参数  $\hat{\theta}$ 。

贝叶斯: 提供多种选择及每种选择的可能性的度量。

# 结构得分(贝叶斯得分)

边缘似然很N，如何在简单情况下计算呢？

-----单个变量的边缘似然

例子：在实验室是否出现Jarry:

$X = \{\text{出现}, \text{不出现}\}$ ，其先验  $Dirichlet(\alpha_1, \alpha_0)$

出现次数:  $M[1]$ ，不出现次数:  $M[0]$ 。

给定数据  $D = \{\text{出现}, \text{不出现}, \text{不出现}, \text{出现}, \dots, \text{出现}\}$ 。



$$\text{最大似然: } P(D | \hat{\theta}) = \left(\frac{M[1]}{M}\right)^{M[1]} \cdot \left(\frac{M[0]}{M}\right)^{M[0]}$$


$$\text{边缘似然: } P(x[m+1] = H | x[1], \dots, x[m]) = \frac{M^m[1] + \alpha_1}{m + \alpha}$$

(计数过程)

若  $D = \{\text{出现}, \text{不出现}, \text{不出现}, \text{出现}, \text{出现}\}$ ;

最大似然: 0.035; 边缘似然: 0.017.

太naïve !



# 结构得分(贝叶斯得分)




对于先验分布为 *Dirichlet*

通过之前讲的 *Dirichlet* 分布


是可以得到

$$P(x[1], \dots, x[M]) = \frac{\Gamma(\alpha)}{\Gamma(\alpha + M)} \cdot \prod_{i=1}^k \frac{\Gamma(\alpha_i + M[x^i])}{\Gamma(\alpha_i)}$$


$$= P(\mathcal{D} | \mathcal{G})$$



$\{\alpha_k\} = 0.1$



$\{\alpha_k\} = 1$



$\{\alpha_k\} = 10$

# 结构得分(贝叶斯得分)


推广：

$$\mathcal{G}_\emptyset \quad P(\mathcal{D} | \mathcal{G}_\emptyset) = \int_{\Theta_X \times \Theta_Y} P(\theta_X, \theta_Y | \mathcal{G}_\emptyset) P(\mathcal{D} | \theta_X, \theta_Y, \mathcal{G}_\emptyset) d[\theta_X, \theta_Y]$$

$$\begin{aligned} P(\mathcal{D} | \mathcal{G}_\emptyset) &= \left( \int_{\Theta_X} P(\theta_X | \mathcal{G}_\emptyset) \prod_m P(x[m] | \theta_X, \mathcal{G}_\emptyset) d\theta_X \right) \\ &= \left( \int_{\Theta_Y} P(\theta_Y | \mathcal{G}_\emptyset) \prod_m P(y[m] | \theta_Y, \mathcal{G}_\emptyset) d\theta_Y \right) \end{aligned}$$

相同

$$\begin{aligned} \mathcal{G}_{X \rightarrow Y} \quad P(\mathcal{D} | \mathcal{G}_{X \rightarrow Y}) &= \left( \int_{\Theta_X} P(\theta_X | \mathcal{G}_{X \rightarrow Y}) \prod_m P(x[m] | \theta_X, \mathcal{G}_{X \rightarrow Y}) d\theta_X \right) \\ &\quad \left( \int_{\Theta_{Y|X^0}} P(\theta_{Y|X^0} | \mathcal{G}_{X \rightarrow Y}) \prod_{m: x[m]=x^0} P(y[m] | \theta_{Y|X^0}, \mathcal{G}_{X \rightarrow Y}) d\theta_{Y|X^0} \right) \\ &\quad \left( \int_{\Theta_{Y|X^1}} P(\theta_{Y|X^1} | \mathcal{G}_{X \rightarrow Y}) \prod_{m: x[m]=x^1} P(y[m] | \theta_{Y|X^1}, \mathcal{G}_{X \rightarrow Y}) d\theta_{Y|X^1} \right) \end{aligned}$$



其中 $\mathbf{x}$ 与 $\mathbf{y}$ 都为二值变量。

# 结构得分(贝叶斯得分)



比较差异项:

$$\left( \int_{\Theta_Y} P(\theta_Y | \mathcal{G}_\emptyset) \prod_m P(y[m] | \theta_Y, \mathcal{G}_\emptyset) d\theta_Y \right)$$

$$\left( \int_{\Theta_{Y|x^0}} P(\theta_{Y|x^0} | \mathcal{G}_{X \rightarrow Y}) \prod_{m: x[m]=x^0} P(y[m] | \theta_{Y|x^0}, \mathcal{G}_{X \rightarrow Y}) d\theta_{Y|x^0} \right)$$

$$\left( \int_{\Theta_{Y|x^1}} P(\theta_{Y|x^1} | \mathcal{G}_{X \rightarrow Y}) \prod_{m: x[m]=x^1} P(y[m] | \theta_{Y|x^1}, \mathcal{G}_{X \rightarrow Y}) d\theta_{Y|x^1} \right)$$

若 $Y$ 在 $X$ 取值下为不同的分布, 则  $\mathcal{G}_{X \rightarrow Y}$  更好的刻画边缘似然。

给个实验:  $P(x^1) = 0.5$   $P(y^1 | x^1) = 0.5 + p$   $P(y^1 | x^0) = 0.5 - p$


$p$  是 $X$ 与 $Y$ 之间的依赖程度。

说明:

实线为  $\mathcal{G}_\emptyset$ , 即  $p = 0$ 。

$O \rightarrow A$ : 选择实线 (简单模型)

$A \rightarrow B$ : 选择虚线 (拟合数据)



# 结构得分(贝叶斯得分)

## 如何理解贝叶斯得分

定义: **BIC得分** (贝叶斯近似)


$$\text{score}_{BIC}(\mathcal{G} : \mathcal{D}) = \ell(\hat{\theta}_{\mathcal{G}} : \mathcal{D}) - \frac{\log M}{2} \text{Dim}[\mathcal{G}]$$

$\text{Dim}[\mathcal{G}]$  为模型的维数, 或模型独立参数的数量。

$$\text{score}_{BIC}(\mathcal{G} : \mathcal{D}) = M \sum_{i=1}^n I_{\hat{p}}(X_i; \text{Pa}_{X_i}) - M \sum_{i=1}^n H_{\hat{p}}(X_i) - \frac{\log M}{2} \text{Dim}[\mathcal{G}]$$

### 结论:

- 熵不依赖于图, 对结构没影响。
- 变量对父节点依赖越强, 得分越高。
- 网络越复杂, 得分越低。
- $M$  越大, 数据拟合重要性越大。



A: 原始结构(含509个参数); B: 简化结构(359个参数); C: 树结构(含214个参数)

# 结构得分(贝叶斯得分)

$$P(G | D) \propto P(D | G)P(G)$$

对先验没有要求?



- 结构先验
- 参数先验

结构先验：经常对结构使用均匀先验（然并卵）。

参数先验：

什么样的先验是我们想要的呢？





# 结构得分(先验性)

推广的似然得分:  $\text{score}_L(\mathcal{G} : \mathcal{D}) = M \sum_{i=1}^n I_{\hat{p}}(X_i; \text{Pa}_{X_i}^{\mathcal{G}}) - M \sum_{i=1}^n H_{\hat{p}}(X_i)$

↓ 分解

$$\sum \text{FamScore}(X_i | \text{Pa}_i^{\mathcal{G}}; \mathcal{D})$$

$$\text{FamScore}_L(X | U; \mathcal{D}) = M \cdot [I_{\hat{p}}(X; U) - H_{\hat{p}}(X)]$$

可分解 → 局部变化不影响其他部分 → 采用局部搜索算法

我们希望

**参数模块性**: 令  $\{P(\theta_G | G) : G \in \mathcal{G}\}$  是满足全局参数独立性的参数先验集合。如果对满足  $\text{Pa}_{X_i}^G = \text{Pa}_{X_i}^{G'} = U$  的每对  $G$  和  $G'$ , 均有  $P(\theta_{X_i|U} | G) = P(\theta_{X_i|U} | G')$  成立, 则称先验满足参数模块性。

→  $X_i$  的CPD上的先验**仅依赖与网络的局部结构** (即  $X_i$  的父节点集), 而不依赖于网络的其他部分。则意味着得分可分解。

→ 若  $P(\theta_G | G)$  是满足全局参数独立性和参数模块性的一个**参数先验**, 则网络结构上的贝叶斯得分可分解。

我们发现

# 结构得分(先验性)

先验的表示:

这里用一种单纯的形式: Dirichlet分布

$Dirichlet(\alpha, \alpha, \alpha, \dots, \alpha)$  其中  $\alpha = 1$

## 明确优化问题:

### 输入:

- 训练集 $\mathcal{D}$
- 得分函数（如需要，包括先验）
- 可能的网络结构的集合 $\mathcal{G}$ （融入任意先验知识）；

### 输出:



- 最大化的得分网络结构（可能来自结构的集合）

## 网络结构 $\mathcal{G}$ 的得分:

$$\text{score}(\mathcal{G} : \mathcal{D}) = \sum_i \text{FamScore}(X_i | \text{Pa}_i^{\mathcal{G}} : \mathcal{D})$$

# 结构搜索(树结构)

定义：如果每个变量 $X$ 在 $G$ 中至多有一个父节点，即  $|\text{Pa}_X^G| \leq 1$   
则网络结构 $G$ 称为树结构。



关键性质：

- 可分解性
- 父节点的限制

网络得分:

$$\Delta(\mathcal{G}) = \text{score}(\mathcal{G} : \mathcal{D}) - \text{score}(\mathcal{G}_\phi : \mathcal{D})$$



$$\Delta(\mathcal{G}) = \sum_{i, \text{Pa}_i^{\mathcal{G}} \neq \emptyset} (\text{FamScore}(X_i | \text{Pa}_i^{\mathcal{G}} : \mathcal{D}) - \text{FamScore}(X_i : \mathcal{D}))$$



$$w_{j \rightarrow i} = \text{FamScore}(X_i | X_j : \mathcal{D}) - \text{FamScore}(X_i : \mathcal{D})$$



$$\Delta(\mathcal{G}) = \sum_{X_j \rightarrow X_i \in \mathcal{G}} w_{j \rightarrow i}$$

有向图加权图中寻找一个最大权值生成森林(困难)

满足

$$w_{i \rightarrow j} = w_{j \rightarrow i}$$

有向图



无向图

# 结构搜索(给定顺序)


给定变量顺序:  $\{x_1, x_2, x_3, x_4, x_5\}$

$x_1$   
●

$$\arg\{w_{1 \rightarrow i} \mid i = 2, 3, \dots, 5\}$$

# 结构搜索(给定顺序)

给定变量顺序:  $\{x_1, x_2, x_3, x_4, x_5\}$




$$\arg\{w_{1 \rightarrow i} \mid i = 2, 3, \dots, 5\}$$



# 结构搜索(给定顺序)


给定变量顺序:  $\{x_1, x_2, x_3, x_4, x_5\}$



$$\arg\{w_{1 \rightarrow i} \mid i = 2, 3, \dots, 5\}$$

# 结构搜索(给定顺序)


给定变量顺序:  $\{x_1, x_2, x_3, x_4, x_5\}$



$$\arg\{w_{1 \rightarrow i} \mid i = 2, 3, \dots, 5\}$$

# 结构搜索(给定顺序)

给定变量顺序:  $\{x_1, x_2, x_3, x_4, x_5\}$



$$\arg \min_i \{w_{1 \rightarrow i} \mid i = 2, 3, \dots, 5\}$$

节点数目较多时, 比较的次数很多, 学习更多的父节点, 代价太高



咋办??

限制度:

$$G_d = \{G : \forall i, |Pa_{X_i}^G| \leq d\}$$

如何搜索图:

定义操作:

- 添加边
- 删除边
- 反转边

## 局部搜索算法:

**idea:** 从当前“状态”出发，寻找与当前状态“相近”的状态，及邻近状态，其中邻近状态是通过搜索算子（边的操作）得到的。从邻近状态中选取最优的。

算法 A.5 带有搜索算子的贪婪局部搜索算法

**Procedure** Greedy-Local-Search (

$\sigma_0$ , // 初始候选解

score, // 得分函数



$\mathcal{O}$ , // 搜索算子集

)

```
1   $\sigma_{\text{best}} \leftarrow \sigma_0$ 
2  执行
3   $\sigma \leftarrow \sigma_{\text{best}}$ 
4   $progress \leftarrow false$ 
5  对每个算子  $o \in \mathcal{O}$ 
6   $\sigma_o \leftarrow o(\sigma)$  // 在  $\sigma$  上应用  $o$  的结果
7  如果  $\sigma_o$  为合法的解, 那么
8  如果  $score(\sigma_o) > score(\sigma_{\text{best}})$  那么
9   $\sigma_{\text{best}} \leftarrow \sigma_o$ 
10  $progress \leftarrow true$ 
11 当  $progress$ 
12
13 返回  $\sigma_{\text{best}}$ 
```


# 结构搜索(一般图)

局部爬山（贪婪爬山）正如刚才所讲；  
问题来了：局部极大解；一个平台期；



# 结构搜索(一般图)

改进：强制新方向



1. 基于约束的方法
2. 结构评分
  - 似然评分
  - 贝叶斯评分
  - 单变量的边缘似然
  - 贝叶斯网络的贝叶斯评分
  - 先验
3. 结构搜索





---

# Thank You