

Chapter 14a

Bayesian Networks

王子磊 (Zilei Wang)

Email: zlwang@ustc.edu.cn

<http://vim.ustc.edu.cn>

提纲

❖ 贝叶斯网络 (Bayesian networks)

- 语法
- 语义

❖ 参数化分布 (parameterized distributions) *

贝叶斯网络 (Bayesian networks)


- ❖ 条件独立断言的一种简单图 (graphical) 表示，用于完全联合概率分布的紧致表达
- ❖ 语法：
 - 一个节点集合，每个节点对应一个随机变量
 - 一个有向无环图 DAG (link \approx "directly influences")
 - 每个节点上一个条件概率（相对于父节点的）

$$P(X_i | Parents(X_i))$$

- ❖ 最简单情况下，条件概率可以表示为条件概率表 (conditional probability table, CPT)，它给出了 X_i 相对于父节点值组合的概率分布

示例

- ❖ 网络拓扑 编码了 条件独立断言：




- ❖ *Weather* 与其他变量是独立的
- ❖ 给定 *Cavity* 条件下, *Toothache* 和 *Catch* 是条件独立的

示例


- ❖ I'm at work, neighbor John calls to say my alarm is ringing, but neighbor Mary doesn't call. Sometimes it's set off by minor earthquakes. Is there a burglar?
- ❖ 变量: *Burglary, Earthquake, Alarm, JohnCalls, MaryCalls*
- ❖ 网络拓扑反应了 **因果关系 (causal)** 知识
 - A burglar can set the alarm off
 - An earthquake can set the alarm off
 - The alarm can cause Mary to call
 - The alarm can cause John to call

示例



紧致性 (Compactness)

- ❖ 一个 Boolean 变量 X_i 相对于 k 个 Boolean 父节点的 CPT 有 2^k 行
 - 每行需要一个数值 p 表示 $X_i = true$ 的条件概率
($X_i = false$ 的条件概率为 $1-p$)



- ❖ 如果每个变量的父节点数不超过 k 个，完整的网络需要 $O(n \cdot 2^k)$ 个数值
 - i.e., 随 n 线性增长, vs. 完全联合概率分布的 $O(2^n)$
 - 对 burglary 网络, 有 $1 + 1 + 4 + 2 + 2 = 10$ 个数字 (vs. $2^5 - 1 = 31$)


全局语义 (Global Semantics)

完全联合概率分布由局部条件概率分布的乘积进行定义 (链式法则)

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


e.g., $P(j \wedge m \wedge a \wedge \neg b \wedge \neg e)$

$$= P(j|a)P(m|a)P(a|\neg b, \neg e)P(\neg b)P(\neg e)$$
$$= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998$$
$$\approx 0.00063$$



局部语义 (Local Semantics)

局部语义：给定父节点，一个节点条件独立于它的其他祖先节点



定理: Local semantics \Leftrightarrow global semantics

局部语义 (Local Semantics)

局部语义：给定父节点，一个节点条件独立于它的其他祖先节点

给定 x_i 的任一其他祖先节点 x_j

$$P(x_i, x_j | \text{Parent}(x_i)) = P(x_i | x_j, \text{Parent}(x_i)) P(x_j | \text{Parent}(x_i)) \quad (\text{联合概率定义})$$


$$= P(x_i | \text{Parent}(x_i)) P(x_j | \text{Parent}(x_i)) \quad (\text{贝叶斯网络})$$

→ 条件独立性

马尔科夫覆盖 (Markov blanket)

给定它的 **Markov blanket**, 该节点条件独立于网络中的所有其他节点

Markov blanket = parents + children + children's parents



- <http://maider.blog.sohu.com/307235658.html>

马尔科夫覆盖 (Markov blanket)

给定它的 **Markov blanket**, 该节点条件独立于网络中的所有其他节点

给定 x_i 的Markov 覆盖 $MB(x_i) = (Parent(x_i), Son(x_i), Parant(Son(x_i)))$,
以及其他所有节点 \mathbf{z}

$$P(x_i, MB(x_i), \mathbf{z}) = P(x_i | Parent(x_i)) \prod P(MB_j(x_i) | Parent(MB_j(x_i))) \prod P(z_k | Parent(z_k))$$

$$P(x_i | MB(x_i), \mathbf{z}) = P(x_i, MB(x_i), \mathbf{z}) / \int P(x_i, MB(x_i), \mathbf{z}) dx_i \quad (\text{条件概率定义})$$


$$= \frac{P(x_i | Parent(x_i)) \prod P(MB_j(x_i) | Parent(MB_j(x_i)))}{P(x_i | Parent(x_i)) \prod P(MB_j(x_i) | Parent(MB_j(x_i)))}$$

$$= P(x_i | MB(x_i)) \quad (\text{代入消除})$$

→ 条件独立性

马尔科夫覆盖 (Markov blanket) *

d 分离 (d-separation): DAG 的三种基本结构




分连结构:

a 和 b 关于 c 条件独立



父节点




顺连结构:

a 和 b 关于 c 条件独立



子节点



汇连结构:

a 和 b 边缘独立, 若已知结果 c 反而不独立



子节点的父节点

构建贝叶斯网络

1. 选择一组排好序的随机变量 X_1, \dots, X_n
2. For $i = 1$ to n
 - 将 X_i 添加到网络中
 - 从 X_1, \dots, X_{i-1} 中选择它的父节点, 使得

$$P(X_i / Parents(X_i)) = P(X_i / X_1, \dots, X_{i-1})$$

这种父节点选择方法保证了贝叶斯网络的全局语义:

$$\begin{aligned} P(X_1, \dots, X_n) &= \prod_{i=1}^n P(X_i / X_1, \dots, X_{i-1}) && \text{(chain rule)} \\ &= \prod_{i=1}^n P(X_i / Parents(X_i)) && \text{(by construction)} \end{aligned}$$

构建示例

❖ 假设我们选定了 M, J, A, B, E 的次序


MaryCalls

JohnCalls

$$P(J / M) = P(J) ?$$

构建示例

❖ 假设我们选定了 M, J, A, B, E 的次序




$P(J / M) = P(J)$? **No**

$P(A / J, M) = P(A / J)$? $P(A / J, M) = P(A)$?

构建示例

❖ 假设我们选定了 M, J, A, B, E 的次序



$P(J / M) = P(J)$? **No**


$P(A / J, M) = P(A / J)$? $P(A / J, M) = P(A)$? **No**

$P(B / A, J, M) = P(B / A)$?

$P(B / A, J, M) = P(B)$?

构建示例

❖ 假设我们选定了 M, J, A, B, E 的次序



$P(J / M) = P(J)$? **No**

$P(A / J, M) = P(A / J)$? $P(A / J, M) = P(A)$? **No**

$P(B / A, J, M) = P(B / A)$? **Yes**


$P(B / A, J, M) = P(B)$? **No**

$P(E / B, A, J, M) = P(E / A)$?

$P(E / B, A, J, M) = P(E / A, B)$?

构建示例

❖ 假设我们选定了 M, J, A, B, E 的次序



$P(J / M) = P(J)$? **No**

$P(A / J, M) = P(A / J)$? $P(A / J, M) = P(A)$? **No**

$P(B / A, J, M) = P(B / A)$? **Yes**


$P(B / A, J, M) = P(B)$? **No**

$P(E / B, A, J, M) = P(E / A)$? **No**

$P(E / B, A, J, M) = P(E / A, B)$? **Yes**

构建示例

- ❖ 在非因果 (noncausal) 方向上判断条件独立性是困难的
- ❖ 对人类而言，因果模型和条件独立性看起来是根深蒂固的 (hardwired)!
- ❖ 这个网络是相对不紧致的：需要 $1 + 2 + 4 + 2 + 4 = 13$ 个数值



紧致的条件分布

- ❖ CPT 随着父节点数呈指数级增长
- ❖ 对连续变量父节点或子节点，CPT 将变成无穷大

- ❖ 解决方案：规范分布 (canonical distribution)

- 确定性节点是最简单的情况：

$$X = f(\text{Parents}(X)) \text{ for some function } f$$

- E.g., Boolean functions

$$\text{NorthAmerican} \Leftrightarrow \text{Canadian} \vee \text{US} \vee \text{Mexican}$$

- E.g., 连续变量之间的数值关系

$$\frac{\partial \text{Level}}{\partial t} = \text{inflow} + \text{precipitation} - \text{outflow} - \text{evaporation}$$

紧致的条件分布

❖ **不确定情况**：噪声或 (noisy-or) 逻辑关系能够刻画多个不交互的子句


- 父节点 $U_1 \dots U_k$ 列出了所有可能的原因（可以增加遗漏节点）
- 每个父节点具有独立的失败概率 q_i

$$\Rightarrow P(X|U_1 \dots U_j, \neg U_{j+1} \dots \neg U_k) = 1 - \prod_{i=1}^j q_i$$

<i>Cold</i>	<i>Flu</i>	<i>Malaria</i>	$P(\text{Fever})$	$P(\neg \text{Fever})$
F	F	F	0.0	1.0
F	F	T	0.9	0.1
F	T	F	0.8	0.2
F	T	T	0.98	$0.02 = 0.2 \times 0.1$
T	F	F	0.4	0.6
T	F	T	0.94	$0.06 = 0.6 \times 0.1$
T	T	F	0.88	$0.12 = 0.6 \times 0.2$
T	T	T	0.988	$0.012 = 0.6 \times 0.2 \times 0.1$

混合网络（离散+连续）*

- ❖ 离散量 (*subsidy?* 和 *Buys?*) + 连续量 (*Harvest* 和 *Cost*)



- ❖ 选项1：离散化 —— 可能导致大的误差和庞大的 CPT

- ❖ 选项2：有限参数的规范化表示

- 1) 连续变量 (e.g., *Cost*): 离散+连续的父节点
- 2) 离散变量 (e.g., *Buys?*): 连续的父节点

连续子变量 *

❖ 需要一个条件概率密度函数


- 对应单个可能的离散数值，刻画了给定连续父节点下，子节点的概率分布
- 最常用的是线性高斯 (Linear Gaussian, LG) 模型， e.g.,

$$\begin{aligned} P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy?} = \text{true}) \\ &= N(a_t h + b_t, \sigma_t)(c) \\ &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right) \end{aligned}$$

表示了 *Cost* 随着 *Harvest* 的线性变化，这儿方差是固定的

- 全范围内的线性关系是不合理的，不过，如果 *Harvest* 的可能范围很小，它是适用的

连续子变量 *



❖ 具有 LG 分布的全连续网络


- 完全联合分布是一个多变量高斯分布

❖ 离散 + 连续的 LG 网络是条件高斯网络

- 针对每个离散量的组合，是其他连续量的多变量高斯分布

离散变量 w/o 连续父节点 *

- ❖ 给定 $Cost$, $Buys?$ 的概率应该是 “soft” threshold 的




- ❖ Probit 分布使用 Gaussian 积分

$$\Phi(x) = \int_{-\infty}^x N(0, 1)(x)dx$$

$$P(Buys? = true \mid Cost = c) = \Phi((-c + \mu)/\sigma)$$

为什么使用 Probit ? *

- ❖ 它具有合适的概率分布曲线
- ❖ 可以看作为位置被噪声干扰的 hard threshold




离散变量 *

- ❖ Sigmoid (or logit) 分布在神经网络中经常使用

$$P(\text{Buys?} = \text{true} \mid \text{Cost} = c) = \frac{1}{1 + \exp(-2\frac{-c+\mu}{\sigma})}$$

- ❖ Sigmoid 与 Probit 具有相似的形状，但具有更长的尾



总结

- ❖ 贝叶斯网络为条件独立性（因果推理）提供了一种天然表达方法
- ❖ 拓扑 + CPTs = 联合概率分布的紧致化表达
- ❖ 对领域专家来说，通常是容易构建的

- ❖ 规范化分布 (e.g., noisy-or) = CPTs 的紧致化表达
- ❖ 连续变量 → 参数化分布 (e.g., linear Gaussian) *

谢谢聆听！

