

概率图模型理论及应用

Theory and Applications of Probabilistic Graphical Models
(Lesson 2)

欧智坚

清华大学电子工程系

Addr: 罗姆楼 6-104

Tel: 62796193

Email: ozj@tsinghua.edu.cn

考核方式

❖ 课后作业 (4次): 20%

- 掌握基本概念和原理
- **按时**交至网络学堂，迟交分数打九折。

❖ 阅读及笔记 (scribe) 一次: 20%

- 13节课，课前微信群提交阅读摘要 (1页)：总结，提出问题；
- 课堂笔记；
- 课后扩展阅读和调研，综合你的阅读和课堂笔记，形成一节资料，当次课一周后 (周日23:59) email交初稿，两周后 (周日23:59) email交终稿，Latex模板。
- 若成组(≤ 3 人)，按组给分，说明分工

❖ 大作业 (自行选题的project): 60%

- Applying 应用解决实际问题
- Theoretic 偏理论探索
- **第17周报告**
- 若成组(≤ 2 人)，按组给分，说明分工

课程章节

- ❖ 第一章 引言 (**1**)
- ❖ 第二章 图模型的表示理论 (**2**)
 - **Semantics (DGM, UGM)**
 - **HMM, CRF**
- ❖ 第三章 图模型的推理理论 (**6**)
 - 精确推理: **variable-elimination, cluster-tree, triangulate**
 - 连续变量: **Kalman**
 - 采样近似: **sampling**
 - 变分近似: **variational**
- ❖ 第四章 图模型的学习理论 (**3**)
 - 参数学习: **maxlikelihoodEstimate, UGM Learning, BayesEstimate**
 - 结构学习: **Structure Learning**
- ❖ 第五章 一个综合例子 (**1**)

同学课前阅读

问题

- 1、贝叶斯网和马尔可夫网各有什么优势和劣势，分别适合建模哪些类别的问题？
- 2、计算机视觉中常用 CRF 对问题建模，很多情况下，CRF 模型其实就是数据项 + 平滑项，最优化的方法往往也采用非线性最小二乘的方法（Gauss-Newton 或 L-M），似乎没有学过图模型，也可以解决 CRF 问题。请问概率图模型到底给了计算机视觉中的 CRF 问题哪些新的东西？是否是更加高效的优化方法？

Why Graphical Model ?

❖ 丰富的模型表达能力（Representation）

- 统一了目前广泛应用的许多统计模型和方法
- 通过 **画图** 以建模；通过 **读图** 以分析变量间关系

❖ 强大的推理计算能力（Inference）

- 原理性算法，通用性，一般性
- 面对具体的新模型，运用原理而不必自己重新设计推理算法

求： $p(S=1|W=1)=?$ $p(R=1|W=1)=?$

❖ 全面的学习理论（Learning）

- 结构学习
- 拍脑袋+让数据来说话：领域知识与样本信息（数据）有机结合

View of a family of distributions 分布族的观点

- 一个图 g 的分布，一般而言，不是指一个具体的分布，而是指一族分布
 - 穷尽 x_v 的形式、每个结点处的局部条件分布 $\{ p(x_v | x_{pa(v)}) \}$ 的可能形式，得到一个分布的集合，记为 $\mathbb{M}(g)$

$$\mathbb{M}(g) = \left\{ p(x_V) : p(x_V) = \prod_{v \in V} p(x_v | x_{pa(v)}) \right\}$$
$$p(V) = \prod_{v \in V} p(v | pa(v))$$


- 一般讨论：对这一族分布中的每个分布都成立的结论
- 从一般到具体，可以有不同抽象层次看待一个图的分布。

$$p(C, R, S, W) = p(C)p(R|C)p(S|C)p(W|R, S)$$

$$R \perp S | C$$

$$W \perp C | S, R$$

C	$p(S=0 C)$	$p(S=1 C)$
0	0.5	0.5
1	0.9	0.1



图模型建模的四要素

❖ 当使用图模型去表示一个具体的概率分布时（**to describe a particular distribution**），需逐步明确以下四要素

❖ 语义（**Semantics**）

- 定义了图和概率分布如何发生联系（有向图、无向图、因子图、链图、...）


❖ 结构（**Structure**）

- 定义随机变量及之间联系（即明确图包含哪些结点以及边）

C	$p(S=0 C)$	$p(S=1 C)$
0	0.5	0.5
1	0.9	0.1

❖ 实现（**Implementation**）

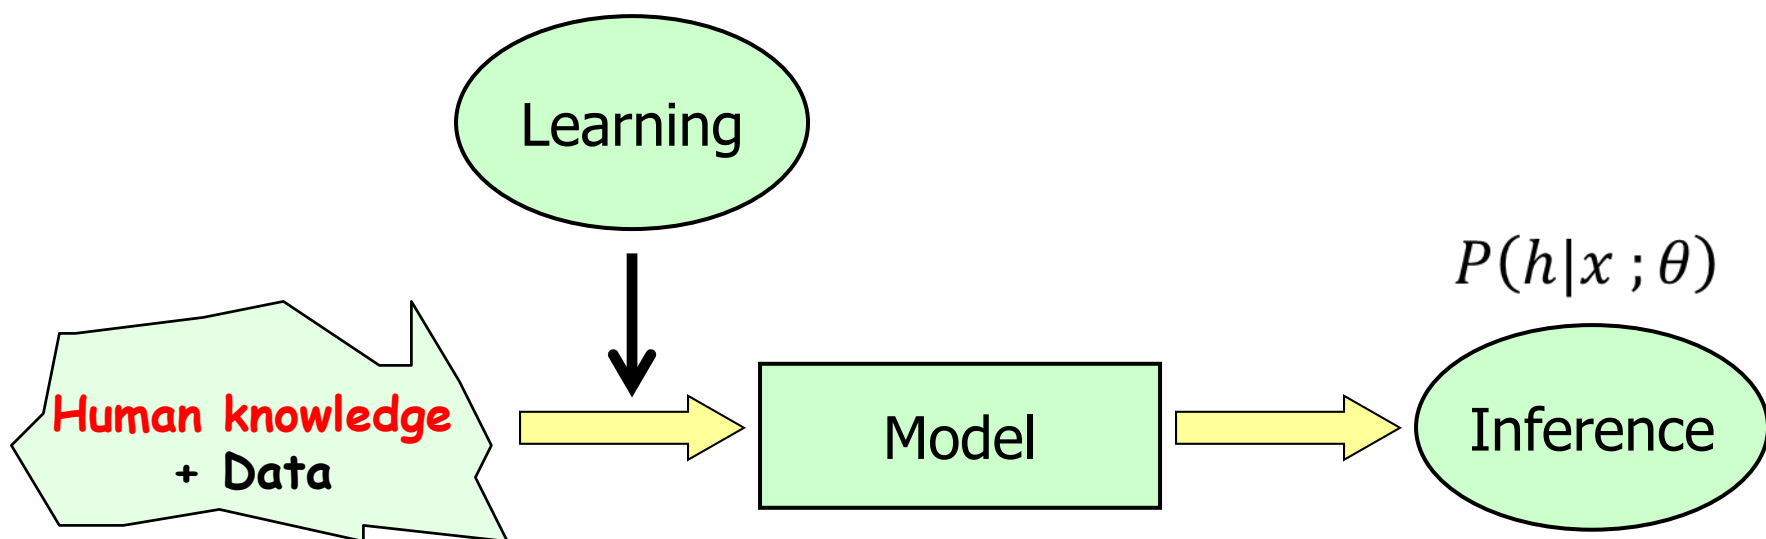
- 指定结点类型（**discrete/continuous**）以及局部函数的具体形式



❖ 参数（**Parameter**）

- 凭经验指定或利用数据进行估计——局部函数的待定参数的取值

图模型理论的三要素




$P(x, h; \theta)$: Generative model,
e. g. GMMs, HMMs, FA, MRFs, LDA, ...

$P(h|x; \theta)$: Discriminative model,
e. g. Logistic Regression, CRFs, NNs, ...


Graph Theory

Basic concepts – undirected edge, neighbor



we have an undirected edge between α and β	$\alpha \sim \beta$	If both ordered-pairs (α, β) and (β, α) belong to E
we also say that α and β are neighbors , α is a neighbour of β , or β is a neighbor of α		
the set of neighbors of β 邻居集	$ne(\beta)$	$ne(\beta) = \{\alpha : \alpha \sim \beta\}$

Basic concepts – directed edge, parent, child





we have an directed edge from α to β	$\alpha \rightarrow \beta$	If $(\alpha, \beta) \in E$ but $(\beta, \alpha) \notin E$
we also say that α is a parent of β , and that β is a child of α		
the set of parents of β 父结点集	$pa(\beta)$	$pa(\beta) = \{\alpha : \alpha \rightarrow \beta\}$
the set of children of α 子结点集	$ch(\alpha)$	$ch(\alpha) = \{\beta : \alpha \rightarrow \beta\}$

Basic concepts – un/directed graph

we say D is a directed graph		If <i>all</i> the edges of a graph D are directed
we say g is a undirected graph		If <i>all</i> the edges of a graph g are undirected

Basic concepts – family; boundary, closure



有向图

the family of β 家庭	$fa(\beta)$	$fa(\beta) = \{\beta\} \cup pa(\beta)$
------------------------------------	-------------	--

无向图


Boundary of node α 边界	$bd(\alpha)$	$bd(\alpha) = ne(\alpha)$
Closure of node α 闭包	$cl(\alpha)$	$cl(\alpha) = bd(\alpha) \cup \{\alpha\}$

Basic concepts – path, trail

path 路径		从 α_0 到 α_n 的一条长为 n 的路径，是指存在 $n+1$ 个不同结点构成的序列 $\alpha_0, \dots, \alpha_n$ ，且 $(\alpha_{i-1}, \alpha_i) \in E$ ， $i = 1, \dots, n$ 。
-------------------	--	---

- 一条路径不会和自己相交；不能逆着有向边的方向而行

we say that α leads to β α 可到达 β	$\alpha \mapsto \beta$	如果存在一条从 α 到 β 的路径
--	------------------------	--------------------------------



Basic concepts – cycle, DAG, trail

n -cycle 环		从 α_1 到 α_n 的一条长为 n 的环，是指存在 n 个不同结点构成的序列 $\alpha_1, \dots, \alpha_n$ ，且 $(\alpha_i, \alpha_{i+1}) \in E, i = 1, \dots, n-1, (\alpha_n, \alpha_1) \in E$
--------------	--	---

acyclic graph		If it does not possess any cycles
directed acyclic graph (DAG)		A directed graph which is acyclic


trail from α to β 迹		从 α_0 到 α_n 的一条长为 n 的迹，是指存在 $n+1$ 个不同结点构成的序列 $\alpha_0, \dots, \alpha_n$ ，且 $\alpha_{i-1} \rightarrow \alpha_i$, or $\alpha_i \rightarrow \alpha_{i-1}$, or $\alpha_{i-1} \sim \alpha_i, i = 1, \dots, n$.
-------------------------------------	--	---

- 一条迹不会和自己相交；可以逆着有向边的方向而行

Basic concepts – well-order of DAG

well-order of a DAG (Directed Acyclic Graph) 有向无环图的良好序		我们总可以对一个DAG的结点进行排序/编号，使得：图中的有向边总是从低编号的结点指向高编号的结点。这样一种排序称为 良序
--	--	---

predecessors of node α	$pr(\alpha)$	在DAG的一个良序中，结点编号比 α 小的结点集合称为 α 的 前辈结点集
--------------------------------------	--------------	--




Here is a well-ordering of the nodes in the DAG

Basic concepts – ancestors, non/descendants


有向图

ancestors (祖先) of node β	$an(\beta)$	$an(\beta) = \{\alpha : \alpha \mapsto \beta \text{ but not } \beta \mapsto \alpha\}$
descendants (后代) of α	$de(\alpha)$	$de(\alpha) = \{\beta : \alpha \mapsto \beta \text{ but not } \beta \mapsto \alpha\}$
non-descendants (非后代) of α	$nd(\alpha)$	$nd(\alpha) = V \setminus (\alpha \cup de(\alpha))$



$an(C) =$

$de(C) =$



$nd(D) =$

Conditional independence (CI)

Definition

❖ $X \perp Y | Z$

if and only if the following equivalent condition holds

- $p(x | y, z) \equiv p(x | z)$ if $p(y, z) > 0$
- $p(x | y, z)$ has the form $a(x, z)$ if $p(y, z) > 0$
- {
 - $p(x, y | z) \equiv p(x | z) p(y | z)$ if $p(z) > 0$
 - $p(x, y | z)$ has the form $a(x, z) b(y, z)$ if $p(z) > 0$}
- {
 - $p(x, y, z) \equiv p(x | z) p(y | z) p(z)$
 - $p(x, y, z) \equiv p(x, z) p(y, z) / p(z)$ if $p(z) > 0$
 - $p(x, y, z)$ has the form $a(x, z) b(y, z)$}

Properties of CI—条件独立性的运算法则

❖ The ternary relation $X \perp Y | Z$ has the following properties:

■ P1: Symmetry

If $X \perp Y | Z$ then $Y \perp X | Z$

■ P2: Decomposition

If $X \perp Y | Z$ and U is a function of X then $U \perp Y | Z$

■ P3: Weak Union

If $X \perp Y | Z$ and U is a function of X then $X \perp Y | (Z, U)$

■ P4: Contraction

If $X \perp Y | W$ and $X \perp Z | (W, Y)$ then $X \perp (Y, Z) | W$

■ P5: Intersection (hold under certain conditions)

If $X \perp Y | (Z, W)$ and $X \perp Z | (Y, W)$ then $X \perp (Y, Z) | W$

Properties of CI - Example of P5 fails

❖ $X \perp Y | Z$ and $X \perp Z | Y \Rightarrow ? X \perp (Y, Z)$

- Define: $p(X=Y=Z=1) = p(X=Y=Z=0) = 0.5$

Other configurations of X, Y and Z have 0 probability.

- $p(x|z) = \frac{p(x,z)}{p(z)} = \frac{0.5 \times \delta(x=z)}{0.5} = \delta(x=z)$ $p(y|z) = \delta(y=z)$

$$p(x,y|z) = \frac{p(x,y,z)}{p(z)} = \frac{0.5 \times \delta(x=y=z)}{0.5} = \delta(x=y=z)$$

$$= \delta(x=z)\delta(y=z) = p(x|z)p(y|z)$$

- This gives $X \perp Y | Z$. Similarly, $X \perp Z | Y$.

- $p(x|y=1, z=1) = \frac{p(x, y=1, z=1)}{p(y=1, z=1)} = \frac{0.5 \times \delta(x=1)}{0.5} = \delta(x=1)$

$$p(x=0) = p(x=1) = 0.5$$

- $X \perp (Y, Z)$ is not true. Given (Y, Z) , we know $X=Y=Z$.

Properties of CI - P5

❖ P5 is true when the distribution p is positive.

If $X \perp Y | (Z, W)$ and $p(x, y, z, w) > 0, \forall x, y, z, w$
 $X \perp Z | (Y, W)$

then $X \perp (Y, Z) | W$

■ Proof:
$$p(x, y, z, w) = g(x, z, w)h(y, z, w)$$
$$= k(x, y, w)l(y, z, w)$$

for suitable strictly positive functions g, h, k, l .

Thus, for all z we must have $k(x, y, w) = \frac{g(x, z, w)h(y, z, w)}{l(y, z, w)}$

Hence, choosing a fixed $z = z_0$, we have


$$k(x, y, w) = g(x, z_0, w) \frac{h(y, z_0, w)}{l(y, z_0, w)} = \pi(x, w) \rho(y, w)$$

Thus, $p(x, y, z, w) = \pi(x, w) \rho(y, w) \times l(y, z, w) \Rightarrow X \perp (Y, Z) | W$

第二章 图模型的表示理论

语义

一个图表示了怎样的概率分布




一个概率分布如何表示成一个图

Definition - (DF) property

赋予概率分布一新表述：先定义性质，性质诱导分布

❖ 称一个分布 $p(x_V)$ 服从 依图 D 的有向分解性，如果

$$p(x_V) = \prod_{v \in V} p(x_v | x_{pa(v)})$$



由依图 D 的有向分解性诱导了一族分布： $\mathbb{M}_{DF}(D)$


$$\mathbb{M}_{DF}(D) = \left\{ p(x_V) : p(x_V) = \prod_{v \in V} p(x_v | x_{pa(v)}) \right\}$$

Definition - (DO) property

称一个分布 $p(x_v)$ 服从依图 D 的有向有序Markov性，
如果在图 D 的某个良序下，成立

$$v \perp pr(v) \setminus pa(v) \mid pa(v)$$

由依图 D 的有向有序Markov性诱导了一族分布: $\mathbb{M}_{DO}(D)$



$p(A, C, S, R, W)$

在某个良序下，成立 $v \perp pr(v) \setminus pa(v) \mid pa(v)$



对图的结点数运用数学归纳法


$$p(V) = \prod_{v \in V} p(v \mid pa(v))$$



在任意良序下，成立 $v \perp pr(v) \setminus pa(v) \mid pa(v)$

不同良序下写出的CI是等价的，统称为DO

View of a family of distributions




❖ Theorem: $\mathbb{M}_{DF}(D) = \mathbb{M}_{DO}(D)$, 合记为 $\mathbb{M}(D)$

At the core of the graphical model representation

- 在建模和算法分析中，灵活地解读一个概率图

Three canonical DAG's - Serial

❖ Serial connection (Markov Chain)




$$p(x, y, z) = p(x) p(y|x) p(z|y)$$

$$X \perp Z \mid Y$$

- 当几个随机现象串行影响时，给定当前现象 Z 的直接原因 Y ，则当前现象 Z 的发生与更早的原因 X 无关。

Three canonical DAG's - Diverging

❖ Diverging connection




$$p(x, y, z) = p(x|y)p(y)p(z|y)$$

$$X \perp Z \mid Y$$

- 当一个随机现象 Y 是另两个随机现象 X, Z 的共同原因时，给定原因 Y ，则这两个随机现象 X, Z 彼此独立。

Three canonical DAG's - Converging

❖ Converging connection



$$p(x, y, z) = p(x) p(y | x, z) p(z)$$


$$X \perp Z$$

$$X \perp Z \mid Y \quad \times$$

Three canonical DAG's - Converging

❖ “Multiple, competing explanation” scenario

E	B	$p(A=1 E, B)$	$p(A=0 E, B)$
0	0	0.1	0.9
1	0	0.8	0.2
0	1	0.8	0.2
1	1	0.99	0.01




■ $p(B = 1 | A = 1) \neq p(B = 1 | A = 1, E = 1)$ $E \perp B | A$ ✗

- 当一个随机现象有两个竞争的原因，其中一个原因发生条件下，另一个原因发生的可能性减少（**explain away**）。

DAG的语义

一个图表示了怎样的概率分布




一个概率分布如何表示成一个图

一个DAG表示一个怎样的概率分布 (by definition)

- n 满足有向分解性
- n 满足有向有序Markov性

一个概率分布如何表示成一个DAG



$$p(C, R, S, W) = p(C)p(R|C)p(S|C)p(W|R, S)$$

I-map (independency map)

❖ 将一个分布 $p(\cdot)$ 所蕴含/满足/表示的 CI 记为 $\mathbb{I}(p)$

$$p(C, R, S, W) = p(C)p(R|C)p(S|C)p(W|R, S)$$


$$\left\{ \begin{array}{l} R \perp S | C \\ W \perp C | S, R \\ \dots \end{array} \right\}$$

称一个BN D 是一个分布 p 的 I-map, 如果

$$\mathbb{I}(\mathbb{M}(D)) \subseteq \mathbb{I}(p)$$

这时, 我们也称分布 p 可以表示成图 D 。

- 相对分布 p 所表示的条件独立性, 图 D 表示了较少的条件独立性。
- 分布 p 可以有一些条件独立性没有反映在图 D 中。
- 一个完备的有向无环图 是 任何分布的 I-map。



称一个BN D 是一个分布 p 的完美贝叶斯网络表示 (P-map), 如果

$$\mathbb{I}(\mathbb{M}(D)) = \mathbb{I}(p)$$

P-map的存在性

❖ 不是每一个分布都有完美贝叶斯网络表示。


例子 (KF p.81 example 3.6)

■ 考虑三个布尔随机变量 X, Y, Z 的如下联合分布

$$p(x, y, z) = \begin{cases} 1/12 & x \oplus y \oplus z = 0 \\ 1/6 & x \oplus y \oplus z = 1 \end{cases}$$


x	y	$x \oplus y$
0	0	0
0	1	1
1	0	1
1	1	0

- $(X \perp Y) \in \mathbb{I}(p)$
- $(X \perp Z) \in \mathbb{I}(p)$
- $(Y \perp Z) \in \mathbb{I}(p)$
- $(X \perp Y | Z) \notin \mathbb{I}(p)$
- $(XY \perp Z) \notin \mathbb{I}(p)$



DAG的语义

一个图表示了怎样的概率分布



一个概率分布如何表示成一个图

一个**DAG**表示一个怎样的概率分布（**by definition**）

- n 满足有向分解性
- n 满足有向有序Markov性

一个概率分布如何表示成一个**DAG**


- n 从条件独立性的包含关系上，寻找尽可能紧凑的I-map

❖ **DAG**适用于随机因素间具有明确依赖、影响关系，通过条件分布来表达的建模问题

- 通过画图来建模

信道译码应用举例

信道编译码




- 引入信道编码: 将信息比特 $u_{1:K}$ 为一组编码成码字比特 $x_{1:N}$
- 简单重复编码: $K=1$, 一个信息比特重复发两份, 利用 $\frac{y_{2k} + y_{2k+1}}{2}$ 判决
- 传输可靠性与传输效率

4/7 Hamming code

❖ 为信息比特加上奇偶校验位（parity-check bits）形成码字

■ $K=4, N=7$ Hamming code

$$\begin{matrix} (x_1, x_2, x_3, x_4, x_5, x_6, x_7) & \text{生成矩阵 } G \\ = (u_1, u_2, u_3, u_4) & \begin{pmatrix} 1 & 0 & 0 & 0 & 1 & 1 & 0 \\ 0 & 1 & 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 & 1 \end{pmatrix} \end{matrix}$$



$$\begin{matrix} (x_1, x_2, x_3, x_4, x_5, x_6, x_7) & \text{校验矩阵 } H \\ & \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} = (0, 0, 0) \end{matrix}$$

Hard decoding

n 对信道输出的前4位 $y_{1:4}$ 进行门限为0.5的硬判决，得到 $\hat{u}_{1:4}$


Algebraic decoding

n 对信道输出 $y_{1:7}$ 做硬判决，进行伴随式译码 $\hat{y}_{1:7} \cdot H = 0$?

Bayes net for a 4/7 Hamming code

(Exact) Probabilistic decoding: 基于 $u_{1:4}$ $x_{1:7}$ $y_{1:7}$ 的联合分布

$$\hat{u}_k = \arg \max_{u_k=0,1} p(u_k | y_{1:7})$$



- $p(u_k=0)=p(u_k=1)=0.5$ for $k=1,2,3,4$.

- $p(x_1 | u_1) = \delta(x_1, u_1)$

$$p(x_2 | u_2) = \delta(x_2, u_2)$$

$$p(x_3 | u_3) = \delta(x_3, u_3)$$

$$p(x_4 | u_4) = \delta(x_4, u_4)$$

$$p(x_5 | u_1, u_2, u_3) = \delta(x_5, u_1 + u_2 + u_3)$$

$$p(x_6 | u_1, u_2, u_4) = \delta(x_6, u_1 + u_2 + u_4)$$


$$p(x_7 | u_2, u_3, u_4) = \delta(x_7, u_2 + u_3 + u_4)$$

- $p(y_n | x_n) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_n - x_n)^2}{2\sigma^2}\right\}$ for $n=1, \dots, 7$

第二章 图模型的表示理论

无向图模型

一个图表示了怎样的概率分布




一个概率分布如何表示成一个图

Definition - (G) property

称一个分布 $p(x_V)$ 服从依图 g 的全局Markov性，如果对任意互不相交的三个结点子集 (A, B, S) ，其中 S 隔离了 A 和 B ，成立

$$x_A \perp x_B \mid x_S$$


由依图 g 的全局Markov性诱导了一族分布: $\mathbb{M}_G(g)$



S 隔离了 A 和 B : 从 A 到 B 的任一条路径都经过 S 中结点

Basic concepts – clique

clique 簇	C	称一个结点子集 C 为簇，如果 C 中结点在图中两两相邻
maximal clique 最大簇		不真包含于图中任何一个簇的簇



Definition - Factorization property (F)

称一个分布 $p(x_V)$ 服从依图 g 的分解性，如果对图中所有簇 C ，存在一个非负函数 $\phi(x_C)$ 一称为势函数，使得

$$p(x_V) = \frac{1}{Z} \prod_{C \in \mathcal{C}} \phi(x_C) \quad \text{或写成 } p(x_V) \propto \prod_{C \in \mathcal{C}} \phi(x_C)$$

其中 Z 是归一化常数 $Z = \sum_{x_V} \prod_{C \in \mathcal{C}} \phi(x_C)$


- \mathcal{C} 是图中所有簇的集合
- 只要求簇上势函数的存在性。这些势函数不是唯一确定的
- 不失一般性，可定义在最大簇上

由依图 g 的分解性诱导了一族分布： $\mathbb{M}_F(g)$


The fundamental theorem of random fields (Hammersley & Clifford)

$$\text{Theorem: } \mathbb{M}_G(g) = \mathbb{M}_F(g)$$

UGM Example




$$\begin{aligned}
 p(x_1, x_2, x_3, x_4, x_5, x_6) &\propto \phi(x_1)\phi(x_2)\phi(x_3)\phi(x_4)\phi(x_5)\phi(x_6) \stackrel{=1}{=} \\
 &\times \phi(x_1, x_2)\phi(x_1, x_3)\phi(x_2, x_4)\phi(x_3, x_5)\phi(x_2, x_5)\phi(x_2, x_6)\phi(x_5, x_6) \\
 &\times \phi(x_2, x_5, x_6)
 \end{aligned}$$



$$p(x_1, x_2, x_3, x_4, x_5, x_6) \propto \psi(x_1, x_2)\psi(x_1, x_3)\psi(x_2, x_4)\psi(x_3, x_5)\psi(x_2, x_5, x_6)$$

UGM的语义

一个图表示了怎样的概率分布



一个概率分布如何表示成一个图

一个UGM表示一个怎样的概率分布 (by definition)

- n 满足 分解性
- n 满足 Markov性

一个概率分布如何表示成一个UGM


- n 从条件独立性的包含关系上, 寻找尽可能紧凑的I-map

P-map的存在性

❖ 不是每一个分布都有完美无向图表示。


例子（KF p.122 example 4.8）

- 考虑三个随机变量 X, Y, Z 组成的V连接的贝叶斯网络所代表的分布 p , 试寻找一个无向图, 作为分布 p 的尽可能紧凑的I-map



UGM的语义

一个图表示了怎样的概率分布



一个概率分布如何表示成一个图

一个UGM表示一个怎样的概率分布 (by definition)

- n 满足 分解性
- n 满足 Markov性

一个概率分布如何表示成一个UGM

- n 从条件独立性的包含关系上, 寻找尽可能紧凑的I-map

UGM适用于随机因素间彼此影响, 通过局部函数的倾向性取值来表达的建模问题

- n 局部函数 $\phi(x_C)$ 体现 局部变量 x_C 取值的随机规律


Image de-noising (PRML p387)

Given the noisy image, to recover the original clean image


- x_i : original clean image pixel $\in \{-1, 1\}$, $i=1, \dots, N^2$
- y_i : observed noisy image pixel $\in \{-1, 1\}$

$$\hat{x}_{1:N^2} = \arg \max_{x_{1:N^2}} p(x_{1:N^2} | y_{1:N^2})$$

$$p(x_{1:N^2}, y_{1:N^2}) = ?$$



original clean x




noisy observation y

Ising model

- ❖ Consider a lattice of binary RV's, $x_i \in \{-1, 1\}$

$$p(x_{1:N^2}) \propto \exp\left\{\sum_{i-j} \phi(x_i, x_j)\right\} = \exp\left\{\beta \sum_{i-j} x_i x_j\right\} \quad \beta > 0$$



- β 表示 相邻变量取相同值 的可能性大小.
- β 取不同值时 Ising model 的随机采样结果:



$\beta = ?$



$\beta = 1$




$\beta = ?$

Image de-noising (PRML p387)


概率模型

- 相邻像素 x_i, x_j 取值的随机规律
- y_i 与 x_i 取值的随机规律


$$p(x, y) \propto \exp \left\{ \beta \sum_{i \sim j} x_i x_j + \gamma \sum_i x_i y_i \right\} \quad \beta > 0, \gamma > 0$$




Compute $\hat{x} = \arg \max_x p(x | y)$?



original clean x



noisy observation y



estimate \hat{x}

Graph semantics

无向图


Definition—无向图的F性质

- 称一个多变量的分布 $p(x_V)$ 服从依图 g 的分解性，如果对图中所有簇 C ，存在一个非负函数 $\phi(x_C)$ —称为势函数，使得

$$p(x_V) = \frac{1}{Z} \prod_{C \in \mathbf{C}} \phi(x_C)$$

$$\text{或写成 } p(x_V) \propto \prod_{C \in \mathbf{C}} \phi(x_C)$$

$$\text{其中 } Z \text{ 是归一化常数 } Z = \sum_x \prod_{C \in \mathbf{C}} \phi(x_C)$$




- \mathbf{C} 是图中所有簇的集合
- 只要求簇上势函数的存在性。这些势函数不是唯一确定的
- 不失一般性，可定义在最大簇上

Definition—无向图的P,L,G性质

❖ 称一个多变量的分布 $p(x_V)$ 服从

(P) 依图 g 的点对Markov性 (pairwise Markov property),
如果对图 g 中任意不相邻的结点 α, β , 成立

$$\alpha \perp \beta \mid V \setminus \{\alpha, \beta\}$$



(L) 依图 g 的局部Markov性 (local Markov property),
如果对图 g 中任意结点 α , 成立

$$\alpha \perp V \setminus cl(\alpha) \mid bd(\alpha)$$


(G) 依图 g 的全局Markov性 (global Markov property),
如果对图 g 中任意互不相交的三个结点子集 (A, B, S) , 其中 S 隔离了 A 和 B , 成立

$$A \perp B \mid S$$



Properties on undirected graphs

- ❖ For undirected graph g , $(F) \equiv (G) \equiv (L) \equiv (P)$, if the probability distribution $p(x_V)$ is positive.
- ❖ The set of probability distributions is denoted by $\mathbb{M}(g)$.



Example 3.10 in Lauritzen's book p.37

P5 fail example


Graph semantics

有向无环图

Definition—DAG的(DF)性质

- ❖ 称一个多变量的分布 $p(x_V)$ 服从 依图 D 的有向分解性，
如果

$$p(x_V) = \prod_{v \in V} p(x_v | x_{pa(v)})$$



Definition—DAG的(DO)(DL)性质

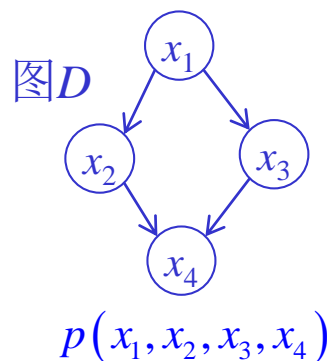
❖ 称一个多变量的分布 $p(x_v)$ 服从

(DO) 依图 D 的有向有序Markov性 (directed ordered Markov property) ,
如果在图 D 的某个良序下, 成立

$$v \perp pr(v) \setminus pa(v) \mid pa(v)$$

(DL) 依图 D 的有向局部Markov性 (directed local Markov property) ,
如果对图 D 中任意结点 v , 成立


$$v \perp nd(v) \setminus pa(v) \mid pa(v)$$



Definition—DAG的(DG)性质

- 称一个多变量的分布 $p(x_V)$ 服从依图 D 的有向全局Markov性（directed global Markov property），如果对图 D 中任意互不相交的三个结点子集 (A, B, S) ，其中 S 有向隔离了 A 和 B ，成立

$$A \perp B \mid S$$






Definition: d-separation

- ❖ 称结点集 A 和结点集 B 被结点集 S 有向隔离(d-separated), 如果从 A 到 B 的**所有**迹(all trails)都被 S 有向隔断(d-blocked)
- ❖ 称从结点 a 到结点 b 的一条迹 π 被结点集 S 有向隔断


如果 下列条件之一成立,

- ① 迹 π 上**存在**一个结点 $\gamma \in \pi$, $\gamma \in S$, 并且迹 π 在结点 γ 处的箭头不是V连接
- ② 迹 π 上**存在**一个结点 $\gamma \in \pi$, γ 与它的所有后代结点均 $\notin S$, 并且迹 π 在结点 γ 处的箭头是V连接



Properties on DAG

$(DF) \Leftrightarrow (DG) \Leftrightarrow (DL) \Leftrightarrow (DO)$



$X_2 \perp X_3 \mid \{X_1, X_6\} ?$

- ① 迹 π 上存在一个结点 $\gamma \in \pi$, $\gamma \in S$, 并且迹 π 在结点 γ 处的箭头不是 V 连接
- ② 迹 π 上存在一个结点 $\gamma \in \pi$, γ 与它的所有后代结点均 $\notin S$, 并且迹 π 在结点 γ 处的箭头是 V 连接

课程章节

- ❖ 第一章 引言 (**1**)
- ❖ 第二章 图模型的表示理论 (**2**)
 - **Semantics (DGM, UGM)**
 - **HMM, CRF**
- ❖ 第三章 图模型的推理理论 (**6**)
 - 精确推理: **variable-elimination, cluster-tree, triangulate**
 - 连续变量: **Kalman**
 - 采样近似: **sampling**
 - 变分近似: **variational**
- ❖ 第四章 图模型的学习理论 (**3**)
 - 参数学习: **maxlikelihoodEstimate, UGM Learning, BayesEstimate**
 - 结构学习: **StructureLearning**
- ❖ 第五章 一个综合例子 (**1**)