

思考：给定文本标注词性

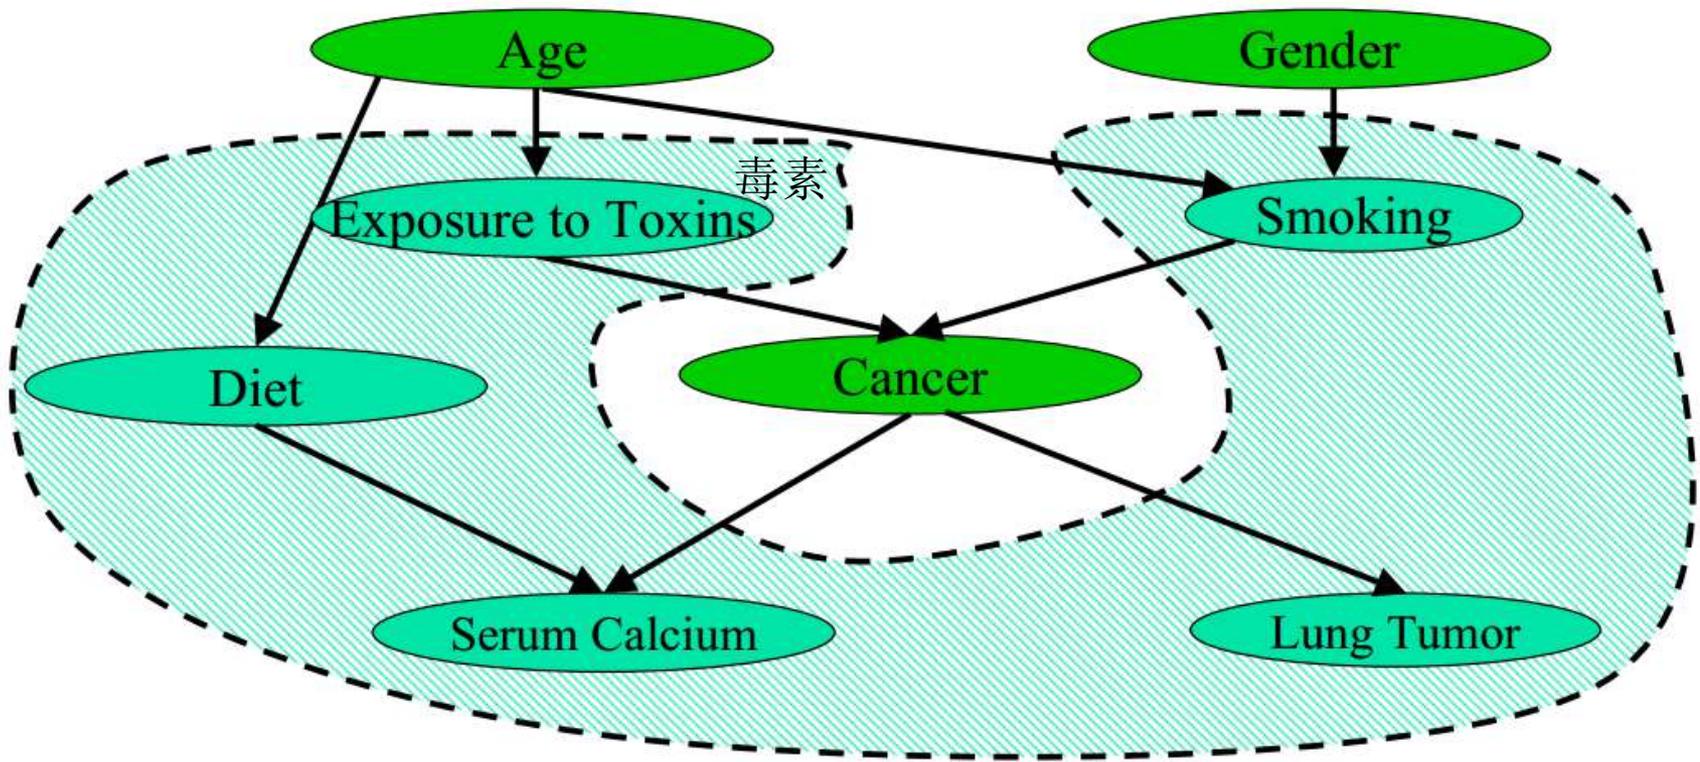
[PRP He] [VBZ reckons] [DT the] [JJ current] [NN account] [NN deficit] [MD will] [VB narrow] [TO to] [RB only] [# #] [CD 1.8] [CD billion] [IN in] [NNP September] [. .]

- 他估算当前的赤字总额在9月份仅仅降低到18亿。
- NN、NNS、NNP、NNPS、PRP、DT、JJ分别代表普通名词单数形式、普通名词复数形式、专有名词单数形式、专有名词复数形式、代词、限定词、形容词

复习：Markov Blanket

- 一个结点的Markov Blanket是一个集合，在这个集合中的结点都给定的条件下，该结点条件独立于其他所有结点。
- 即：一个结点的Markov Blanket是它的parents,children以及spouses(孩子的其他parent)

Markov Blanket

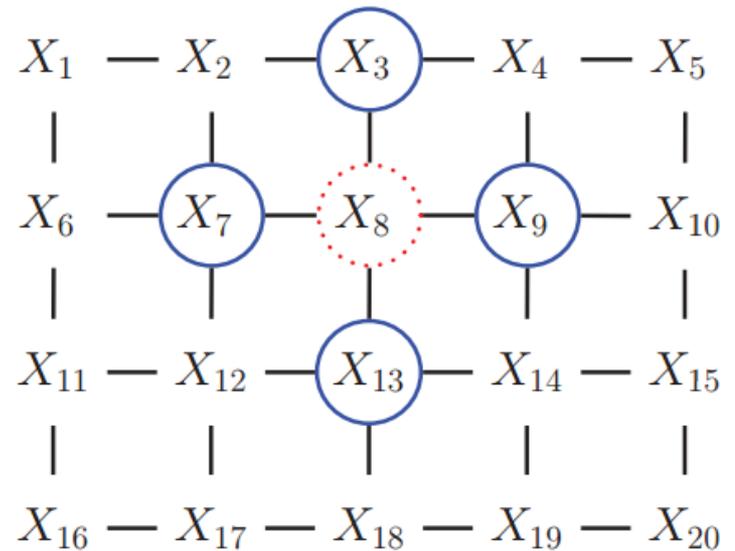
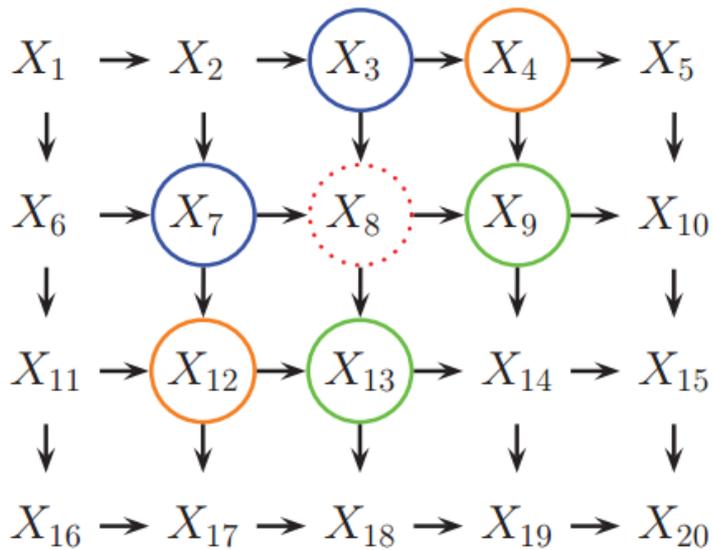


[Breese & Koller, 97]

补充知识: **Serum Calcium(血清钙浓度)** 高于 2.75mmol/L 即为高钙血症。许多恶性肿瘤可并发高钙血症。以乳腺癌、骨肿瘤、肺癌、胃癌、卵巢癌、多发性骨髓瘤、急性淋巴细胞白血病等较为多见, 其中乳腺癌约 $1/3$ 可发生高钙血症。

图像模型

- 考察 X_8 的马尔科夫毯(Markov blanket)



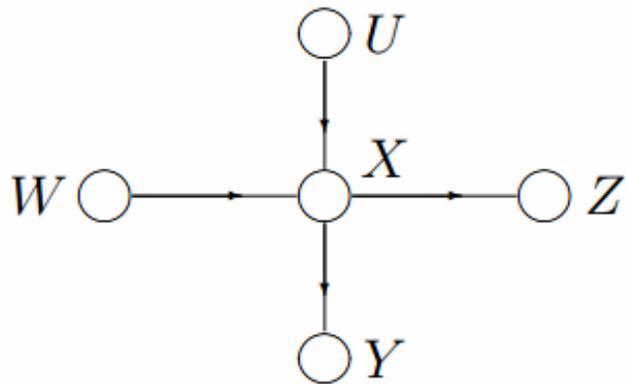
无向图模型

- 有向图模型，又称作贝叶斯网络(Directed Graphical Models, **DGM**, Bayesian Network)
- 在有些情况下，强制对某些结点之间的边增加方向是不合适的。
- 使用没有方向的无向边，形成了无向图模型(Undirected Graphical Model, **UGM**), 又被称为马尔科夫随机场或者马尔科夫网络(Markov Random Field, **MRF** or Markov network)

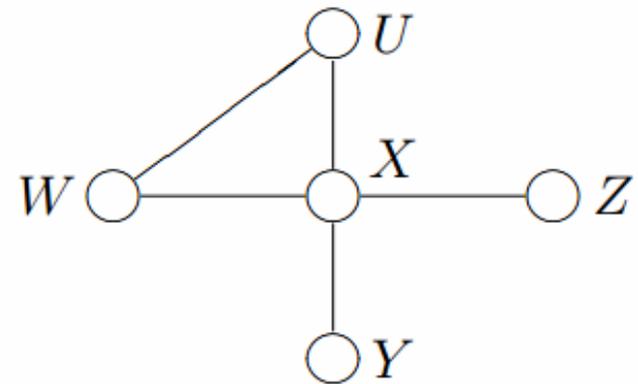
条件随机场

- 设 $X=(X_1, X_2 \dots X_n)$ 和 $Y=(Y_1, Y_2 \dots Y_m)$ 都是联合随机变量，若随机变量 Y 构成一个无向图 $G=(V, E)$ 表示的马尔科夫随机场(MRF)，则条件概率分布 $P(Y|X)$ 称为条件随机场(Conditional Random Field, CRF)
- 注：大量文献将MRF和CRF混用，包括经典著作。后面将考察为何会有该混用。

DGM转换成UGM

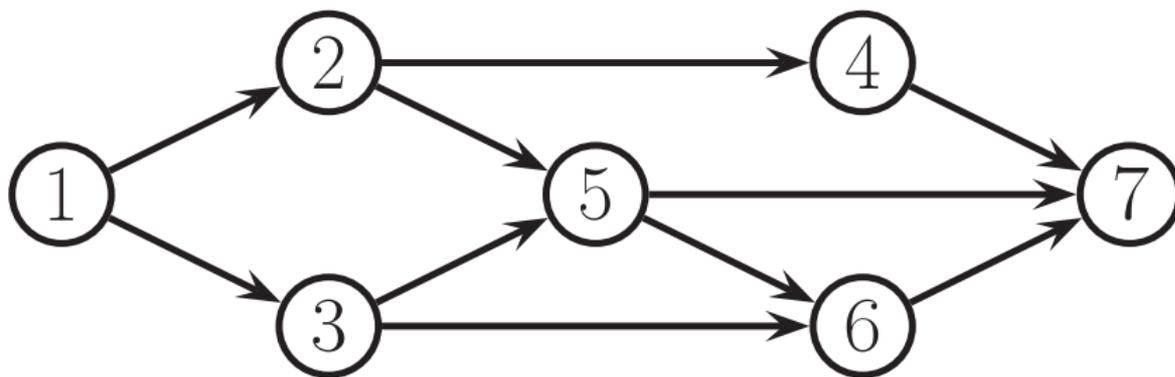


Bayesian network.

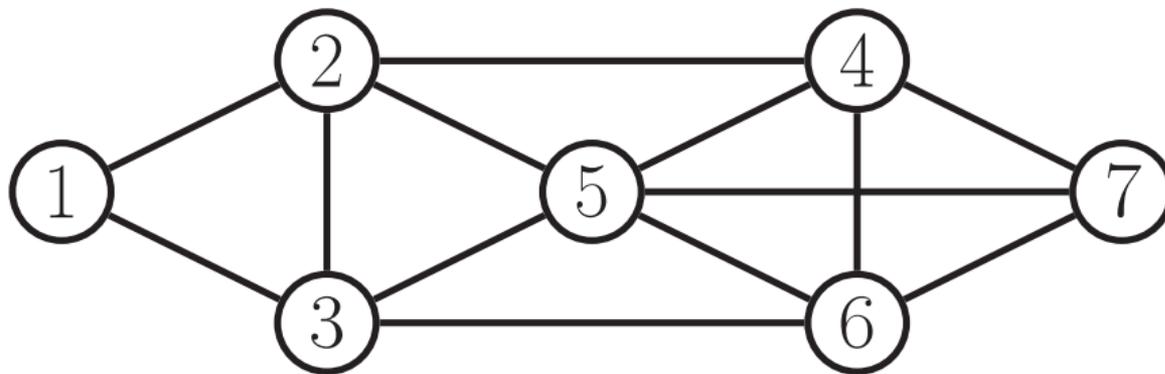


Markov random field.

DGM转换成UGM

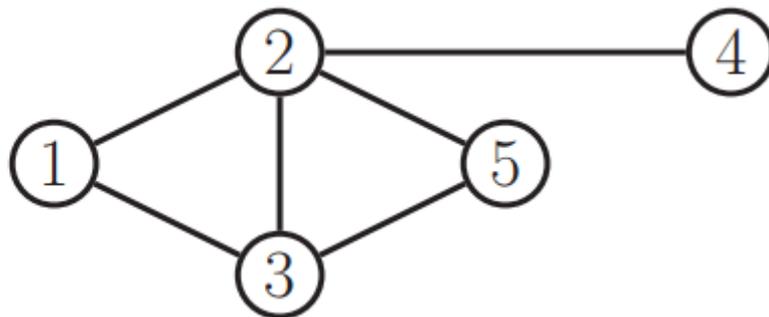
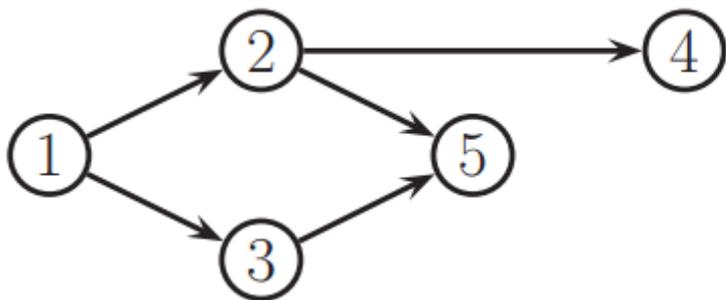


$4 \perp 5 | 2$



条件独立的破坏

- 靠考察是否有 $A \perp B | C$ ，则计算U的祖先图 (ancestral graph): $U = A \cup B \cup C$



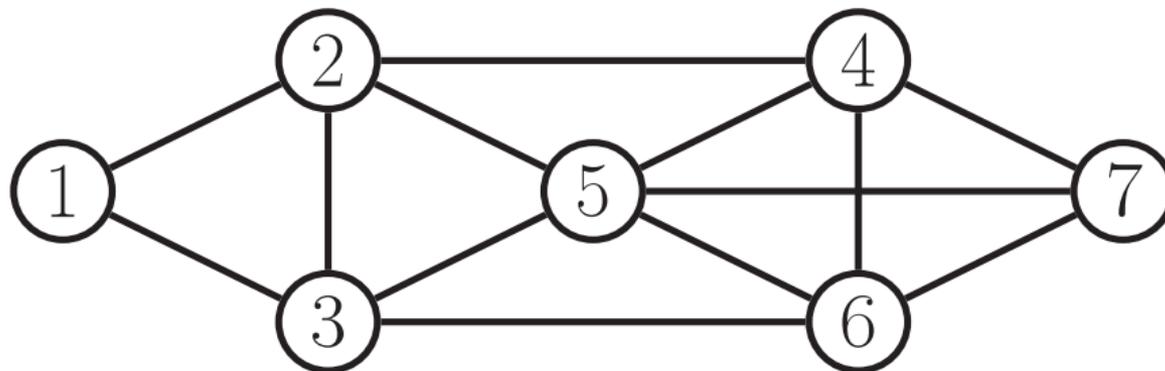
$$4 \perp 5 | 2$$

MRF的性质

- 成对马尔科夫性
 - pairwise Markov property
- 局部马尔科夫性
 - local Markov property
- 全局马尔科夫性
 - global Markov property

- 表述说明：随机变量 $Y=(Y_1, Y_2 \dots Y_m)$ 构成无向图 $G=(V, E)$ ，结点 v 对应的随机变量是 Y_v 。

考察结点间的独立性



Pairwise $1 \perp 7 | \text{rest}$

Local $1 \perp \text{rest} | 2, 3$

Global $1, 2 \perp 6, 7 | 3, 4, 5$

成对马尔科夫性

- 设 u 和 v 是无向图 G 中任意两个没有边直接连接的结点， G 中其他结点的集合记做 O ；则在给定随机变量 Y_o 的条件下，随机变量 Y_u 和 Y_v 条件独立。
- 即： $P(Y_u, Y_v | Y_o) = P(Y_u | Y_o) * P(Y_v | Y_o)$

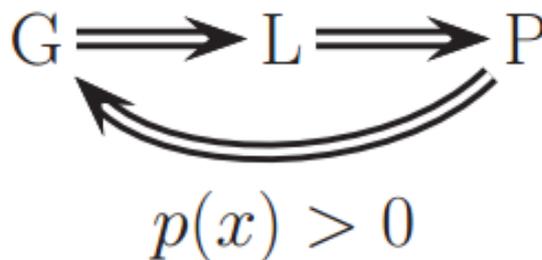
局部马尔科夫性

- 设 v 是无向图 G 中任意一个结点， W 是与 v 有边相连的所有结点， G 中其他结点记做 O ；则在给定随机变量 Y_w 的条件下，随机变量 Y_v 和 Y_o 条件独立。
- 即： $P(Y_v, Y_o | Y_w) = P(Y_v | Y_w) * P(Y_o | Y_w)$

全局马尔科夫性

- 设结点集合A, B是在无向图G中被结点集合C分开的任意结点集合, 则在给定随机变量 Y_C 的条件下, 随机变量 Y_A 和 Y_B 条件独立。
- 即: $P(Y_A, Y_B | Y_C) = P(Y_A | Y_C) * P(Y_B | Y_C)$

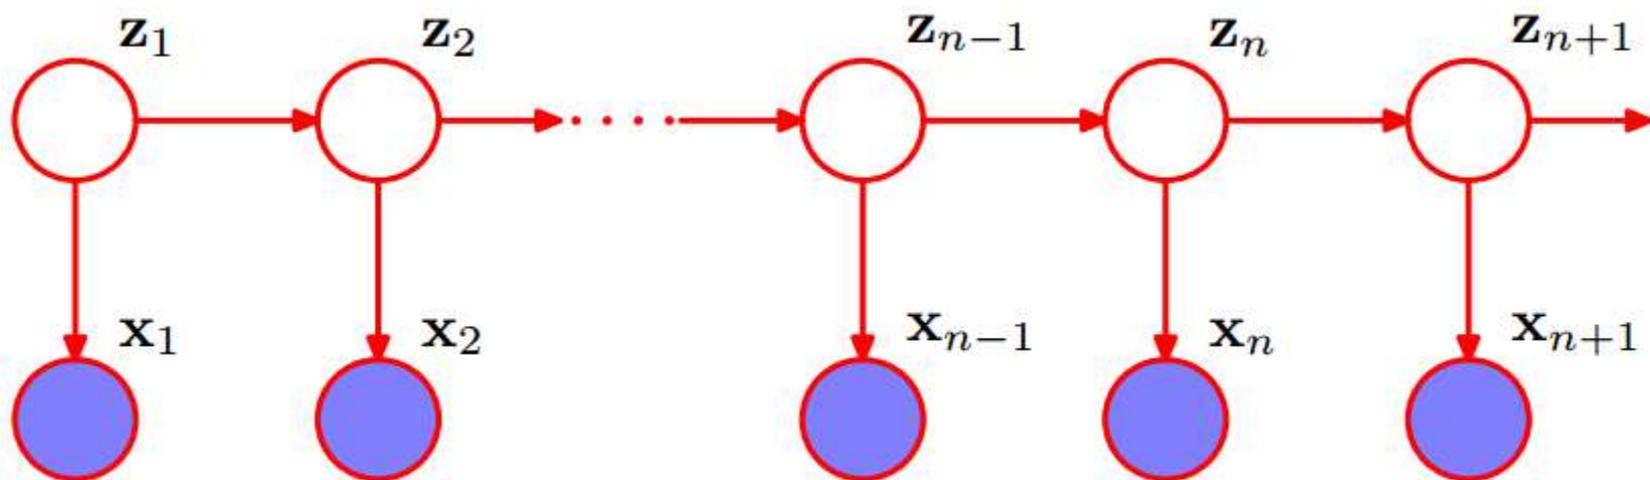
三个性质的等价性



- 根据全局马尔科夫性，能够得到局部马尔科夫性；
- 根据局部马尔科夫性，能够得到成对马尔科夫性；
- 根据成对马尔科夫性，能够得到全局马尔科夫性；

- 可以反向思考：满足这三个性质(或其一)的无向图，称为概率无向图模型。

复习：隐马尔科夫模型



HMM的确定

- HMM由初始概率分布 π 、状态转移概率分布A以及观测概率分布B确定。

$$\lambda = (A, B, \pi)$$

HMM的参数

- Q是所有可能的状态的集合
 - N是可能的状态数
- V是所有可能的观测的集合
 - M是可能的观测数

$$Q = \{q_1, q_2, \dots, q_N\}$$

$$V = \{v_1, v_2, \dots, v_M\}$$

HMM的参数

- I是长度为T的状态序列，O是对应的观测序列

$$I = \{i_1, i_2, \dots, i_T\} \quad O = \{o_1, o_2, \dots, o_T\}$$

- A是状态转移概率矩阵

$$A = [a_{ij}]_{N \times N}$$

- 其中 $a_{ij} = P(i_{t+1} = q_j | i_t = q_i)$
- a_{ij} 是在时刻t处于状态 q_i 的条件下时刻t+1转移到状态 q_j 的概率。

HMM的参数

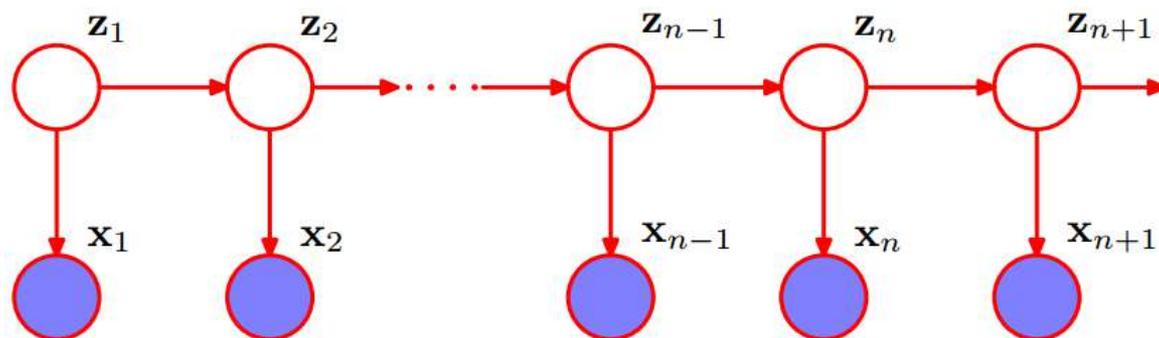
- B是观测概率矩阵 $B = [b_{ik}]_{N \times M}$
- 其中, $b_{ik} = P(o_t = v_k | i_t = q_i)$
 - b_{ik} 是在时刻t处于状态 q_i 的条件下生成观测 v_k 的概率。
- π 是初始状态概率向量: $\pi = (\pi_i)$
- 其中, $\pi_i = P(i_1 = q_i)$
 - π_i 是时刻t=1处于状态 q_i 的概率。

HMM的参数总结

- HMM由初始概率分布 π 、状态转移概率分布 A 以及观测概率分布 B 确定。 π 和 A 决定状态序列， B 决定观测序列。因此，HMM可以用三元符号表示，称为HMM的三要素：

$$\lambda = (A, B, \pi)$$

HMM的两个基本性质



- 齐次假设:

$$P(i_t | i_{t-1}, o_{t-1}, i_{t-2}, o_{t-2} \text{ L } i_1, o_1) = P(i_t | i_{t-1})$$

- 观测独立性假设:

$$P(o_t | i_T, o_T, i_{T-1}, o_{T-1} \text{ L } i_1, o_1) = P(o_t | i_t)$$

HMM的3个基本问题

□ 概率计算问题

- 给定模型 $\lambda = (A, B, \pi)$ 和观测序列 $O = \{o_1, o_2, \dots, o_T\}$, 计算模型 λ 下观测序列 O 出现的概率 $P(O | \lambda)$

□ 学习问题

- 已知观测序列 $O = \{o_1, o_2, \dots, o_T\}$, 估计模型 $\lambda = (A, B, \pi)$ 的参数, 使得在该模型下观测序列 $P(O | \lambda)$ 最大

□ 预测问题

- 即解码问题: 已知模型 $\lambda = (A, B, \pi)$ 和观测序列 $O = \{o_1, o_2, \dots, o_T\}$ 求对给定观测序列条件概率 $P(I | O)$ 最大的状态序列 I

概率计算问题

- 直接算法
 - 暴力算法
- 前向算法
- 后向算法
 - 这二者是理解HMM的算法重点

直接计算法

- 按照概率公式，列举所有可能的长度为T的状态序列 $I = \{i_1, i_2, \dots, i_T\}$ ，求各个状态序列I与观测序列 $O = \{o_1, o_2, \dots, o_T\}$ 的联合概率 $P(O, I | \lambda)$ ，然后对所有可能的状态序列求和，从而得到 $P(O | \lambda)$

直接计算法

- 状态序列 $I = \{i_1, i_2, \dots, i_T\}$ 的概率是:

$$P(I|\lambda) = \pi_{i_1} a_{i_1 i_2} a_{i_2 i_3} \dots a_{i_{T-1} i_T}$$

- 对固定的状态序列I, 观测序列O的概率是:

$$P(O|I, \lambda) = b_{i_1 o_1} b_{i_2 o_2} \dots b_{i_T o_T}$$

直接计算法

- O和I同时出现的联合概率是：

$$\begin{aligned} P(O, I | \lambda) &= P(O | I, \lambda) P(I | \lambda) \\ &= \pi_{i_1} b_{i_1 o_1} a_{i_1 i_2} b_{i_2 o_2} \text{L} a_{i_{T-1} i_T} b_{i_T o_T} \end{aligned}$$

- 对所有可能的状态序列I求和，得到观测序列O的概率P(O|λ)

$$\begin{aligned} P(O | \lambda) &= \sum_I P(O, I | \lambda) = \sum_I P(O | I, \lambda) P(I | \lambda) \\ &= \sum_{i_1, i_2, \text{L} i_T} \pi_{i_1} b_{i_1 o_1} a_{i_1 i_2} b_{i_2 o_2} \text{L} a_{i_{T-1} i_T} b_{i_T o_T} \end{aligned}$$

直接计算法

- 对于最终式

$$\begin{aligned} P(O|\lambda) &= \sum_I P(O, I|\lambda) = \sum_I P(O|I, \lambda) P(I|\lambda) \\ &= \sum_{i_1, i_2, \dots, i_T} \pi_{i_1} b_{i_1 o_1} a_{i_1 i_2} b_{i_2 o_2} \dots a_{i_{T-1} i_T} b_{i_T o_T} \end{aligned}$$

- 分析：加和符号中有 $2T$ 个因子， I 的遍历个数为 N^T ，因此，时间复杂度为 $O(T N^T)$ ，过高。

前向算法

- 定义：给定 λ ，定义到时刻 t 部分观测序列为 o_1, o_2, \dots, o_t 且状态为 q_i 的概率为前向概率，记做：

$$\alpha_t(i) = P(o_1, o_2, \dots, o_t, i_t = q_i | \lambda)$$

- 可以递推的求得前向概率 $\alpha_t(i)$ 及观测序列概率 $P(O|\lambda)$

前向算法

□ 初值: $\alpha_1(i) = \pi_i b_{io_1}$

□ 递推: 对于 $t=1, 2, \dots, T-1$

$$\alpha_{t+1}(i) = \left(\sum_{j=1}^N \alpha_t(j) a_{ji} \right) b_{io_{t+1}}$$

□ 最终: $P(O|\lambda) = \sum_{i=1}^N \alpha_T(i)$

后向算法

- 定义：给定 λ ，定义到时刻 t 状态为 q_i 的前提下，从 $t+1$ 到 T 的部分观测序列为 $o_{t+1}, o_{t+2}, \dots, o_T$ 的概率为后向概率，记做：

$$\beta_t(i) = P(o_{t+1}, o_{t+2}, \dots, o_T | i_t = q_i, \lambda)$$

- 可以递推的求得后向概率 $\beta_t(i)$ 及观测序列概率 $P(O|\lambda)$

后向算法

□ 初值: $\beta_T(i) = 1$

□ 递推: 对于 $t = T-1, T-2, \dots, 1$

$$\beta_t(i) = \left(\sum_{j=1}^N a_{ij} b_{j o_{t+1}} \beta_{t+1}(j) \right)$$

□ 最终: $P(O|\lambda) = \sum_{i=1}^N \pi_i b_{i o_1} \beta_1(i)$

后向算法的说明

- 为了计算在时刻 t 状态为 q_i 条件下时刻 $t+1$ 之后的观测序列为 $o_{t+1}, o_{t+2} \dots o_T$ 的后向概率 $\beta_t(i)$ ，只需要考虑在时刻 $t+1$ 所有可能的 N 个状态 q_j 的转移概率(a_{ij} 项)，以及在此状态下的观测 o_{t+1} 的观测概率($b_{j|o_{t+1}}$)项，然后考虑状态 q_j 之后的观测序列的后向概率 $\beta_{t+1}(j)$

前向后向概率的关系

- 根据定义，证明下列等式

$$P(i_t = q_i, O|\lambda) = \alpha_t(i)\beta_t(i)$$

$$P(O|\lambda) = \sum_{i=1}^N \alpha_t(i)\beta_t(i)$$

单个状态的概率

- 求给定模型 λ 和观测 O ，在时刻 t 处于状态 q_i 的概率。
- 记： $\gamma_t(i) = P(i_t = q_i | O, \lambda)$

单个状态的概率

- 根据前向后向概率的定义，

$$P(i_t = q_i, O|\lambda) = \alpha_t(i)\beta_t(i)$$

$$\gamma_t(i) = P(i_t = q_i | O, \lambda) = \frac{P(i_t = q_i, O|\lambda)}{P(O|\lambda)}$$

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{P(O|\lambda)} = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^N \alpha_t(i)\beta_t(i)}$$

γ 的意义

□ 在每个时刻 t 选择在该时刻最有可能出现的状态 i_t^* ，从而得到一个状态序列 $I^* = \{i_1^*, i_2^*, \dots, i_T^*\}$ ，将它作为预测的结果。

□ 给定模型和观测序列，时刻 t 处于状态 qi 的概率为：

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{P(O|\lambda)} = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^N \alpha_t(i)\beta_t(i)}$$

两个状态的联合概率

- 求给定模型 λ 和观测 O ，在时刻 t 处于状态 q_i 并且时刻 $t+1$ 处于状态 q_j 的概率。

$$\xi_t(i, j) = P(i_t = q_i, i_{t+1} = q_j | O, \lambda)$$

两个状态的联合概率

□ 根据前向后向概率的定义，

$$\xi_t(i, j) = P(i_t = q_i, i_{t+1} = q_j | O, \lambda) = \frac{P(i_t = q_i, i_{t+1} = q_j, O | \lambda)}{P(O | \lambda)} = \frac{P(i_t = q_i, i_{t+1} = q_j, O | \lambda)}{\sum_{i=1}^N \sum_{j=1}^N P(i_t = q_i, i_{t+1} = q_j, O | \lambda)}$$

$$P(i_t = q_i, i_{t+1} = q_j, O | \lambda) = \alpha_t(i) a_{ij} b_{j o_{t+1}} \beta_{t+1}(j)$$

期望

- 在观测O下状态i出现的期望：

$$\sum_{t=1}^T \gamma_t(i)$$

- 在观测O下状态i转移到状态j的期望：

$$\sum_{t=1}^{T-1} \xi_t(i, j)$$

学习算法

- 若训练数据包括观测序列和状态序列，则HMM的学习非常简单，是监督性学习；
- 若训练数据只有观测序列，则HMM的学习需要使用EM算法，是非监督学习。

再次分析二项分布的参数估计

- 极大似然估计
- 简单的例子
 - 10次抛硬币的结果是：正正反正正正反反正正
- 假设 p 是每次抛硬币结果为正的概率。则：
- 得到这样的实验结果的概率是：

$$\begin{aligned} P &= pp(1-p)ppp(1-p)(1-p)pp \\ &= p^7(1-p)^3 \end{aligned}$$

极大似然估计MLE

□ 目标函数: $\max P = \max_{0 \leq p \leq 1} p^7 (1 - p)^3$

□ 最优解是: $p=0.7$

■ 即: 使用样本的均值可以作为全体的均值估计

□ 一般形式:

$$L_{\bar{p}} = \prod_x p(x)^{\bar{p}(x)}$$

$p(x)$ 模型是估计的概率分布

$\bar{p}(x)$ 是实验结果的分布

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/708037042062007001>