

隐藏式马科夫模型 (Hidden Markov Models)



概率原理复习


- Conditional probability $P(x|y) = \frac{P(x, y)}{P(y)}$
- Product rule $P(x, y) = P(x|y)P(y)$
- Chain rule
$$\begin{aligned} P(X_1, X_2, \dots, X_n) &= P(X_1)P(X_2|X_1)P(X_3|X_1, X_2)\dots \\ &= \prod_{i=1}^n P(X_i|X_1, \dots, X_{i-1}) \end{aligned}$$
- X, Y independent if and only if: $\forall x, y : P(x, y) = P(x)P(y)$
- X and Y are conditionally independent given Z if and only if: $X \perp\!\!\!\perp Y|Z$
 $\forall x, y, z : P(x, y|z) = P(x|z)P(y|z)$

在时间或空间上的推理

- 通常，我们的推理是建立在一序列的观察值上面的
 - 语音识别
 - 机器人定位
 - 用户的注意力 User attention
 - 医疗监测
- 需要引入时间(或空间)到我们的模型里

马科夫模型 (Markov Models)


- X 在某个时刻的值是一个随机变量，也叫做一个 **状态**



$$P(X_1) \quad P(X_t|X_{t-1}) \quad P(X_t) = ?$$

- 参数: **转移概率** 或 动态参数, 指定状态随时间的发展是如何演变的 (参数还包括, 初始状态概率分布)
- 稳定性假设: 转移概率不随时间发生变化
- 与 MDP 的转移模型类似, 但不存在行动上的选择


马科夫假设：条件独立性



- 条件独立性的基本性质：
 - 过去和未来给定现在是相互独立的
 - 每个时刻的状态只依赖于上一个时刻的状态
 - 这也叫做(一级) 马科夫属性
- A (growable) BN: 可以应用 贝叶斯网络上推理, 当链的长度被剪裁到一个固定长度的时候



马科夫链举例：Weather

- 状态： $X = \{\text{rain}, \text{sun}\}$
- 初始分布：1.0 sun
- CPT $P(X_t | X_{t-1})$:




两种用图的方式来表达 CPT

X_{t-1}	X_t	$P(X_t X_{t-1})$
sun	sun	0.9
sun	rain	0.1
rain	sun	0.3
rain	rain	0.7



马科夫链举例：Weather

- 初始分布：1.0 sun
- 在过去一个时刻后天气的概率分布变成了什么？




$$\begin{aligned} P(X_2 = sun) &= \sum_{x_1} P(x_1, X_2 = sun) \\ &= \sum_{x_1} P(X_2 = sun | x_1) P(x_1) \end{aligned}$$

$$P(X_2 = sun) = P(X_2 = sun | X_1 = sun) P(X_1 = sun) + P(X_2 = sun | X_1 = rain) P(X_1 = rain)$$

$$0.9 \cdot 1.0 + 0.3 \cdot 0.0 = 0.9$$

Mini-Forward 算法


- 问题：在某一天 t ， $P(X)$ 是多少？



$$P(x_1) = \text{known}$$


$$\begin{aligned} P(x_t) &= \sum_{x_{t-1}} P(x_{t-1}, x_t) \\ &= \sum_{x_{t-1}} P(x_t | x_{t-1}) P(x_{t-1}) \end{aligned}$$

↑
前向模拟 *Forward simulation*




运行Mini-Forward 算法的例子

- 从初始观察到 sun



- 从初始观察到 rain




- 从另一个初始分布 $P(X_1)$:



Video of Demo Ghostbusters Basic Dynamics



Video of Demo Ghostbusters Circular Dynamics



Video of Demo Ghostbusters Whirlpool Dynamics



静态分布



(Stationary Distributions)

- 对于大部分马科夫链来说：
 - 初始分布的影响随时间的发展变得越来越小
 - 最终的分布是独立于初始分布的
- 静态分布：
 - 这个最终的分布叫做这个马科夫链的 **静态分布** P_∞
 - 满足以下关系：

$$P_\infty(X) = P_{\infty+1}(X) = \sum_x P(X|x)P_\infty(x)$$

举例：静态分布

问题： $P(X)$ =? 当 $t = \text{infinity}$



$$P_{\infty}(\text{sun}) = P(\text{sun}|\text{sun})P_{\infty}(\text{sun}) + P(\text{sun}|\text{rain})P_{\infty}(\text{rain})$$

$$P_{\infty}(\text{rain}) = P(\text{rain}|\text{sun})P_{\infty}(\text{sun}) + P(\text{rain}|\text{rain})P_{\infty}(\text{rain})$$

$$P_{\infty}(\text{sun}) = 0.9P_{\infty}(\text{sun}) + 0.3P_{\infty}(\text{rain})$$

$$P_{\infty}(\text{rain}) = 0.1P_{\infty}(\text{sun}) + 0.7P_{\infty}(\text{rain})$$

$$P_{\infty}(\text{sun}) = 3P_{\infty}(\text{rain})$$


$$P_{\infty}(\text{rain}) = 1/3P_{\infty}(\text{sun})$$

X_{t-1}	X_t	$P(X_t X_{t-1})$
sun	sun	0.9
sun	rain	0.1
rain	sun	0.3
rain	rain	0.7

$$P_{\infty}(\text{sun}) = 3/4$$

$$P_{\infty}(\text{rain}) = 1/4$$


Also: $P_{\infty}(\text{sun}) + P_{\infty}(\text{rain}) = 1$



静态分布的应用：网页链接分析


■ 网页图上的 网页等级排序 PageRank

- 每个网页是一个随机状态的可能的值
- 初始分布：均匀分布在所有网页上
- 过渡转移：
 - 均匀跳转到一个随机的网页，概率为 c （虚线所示，没有显示全部）
 - 随机根据一个外向链接转移到下一个网页，概率为 $1-c$ ，（实线所示）



■ 静态分布

- 更多的时间会停留在访问频率高的网页上
- 例如，许多路径走到 Acrobat Reader 的下载页面
- 比较有效地对抗垃圾链接
- Google 1.0 搜索算法 返回的网页包括所有你输入的关键词，并已排序结果的降序显示出来
- 现在所有的搜索引擎使用网页的链接分析，并结合许多其他的因素（随着时间的推移，等级 rank 实际上变得越来越不重要）



静态分布的应用：Gibbs 采样

- 在所有隐藏和查询变量上的联合的实例化，即每一组赋值表示为一个状态： $\{X_1, \dots, X_n\} = H \cup Q$

- 过渡转移：

- 以概率为 $1/n$ ，重新采样变量 X_j 根据以下分布

$$P(X_j \mid x_1, x_2, \dots, x_{j-1}, x_{j+1}, \dots, x_n, e_1, \dots, e_m)$$

- 静态分布：


- 条件概率分布 $P(X_1, X_2, \dots, X_n \mid e_1, \dots, e_m)$
- 意味着当运行 Gibbs 采样一段长时间后，我们将会从我们所希望的概率分布上进行采样
- 这个结论是可以证明的！

隐藏式马科夫模型


Hidden Markov Models



Pacman – Sonar (P4)




Video of Demo Pacman – Sonar (no beliefs)




隐藏式马科夫模型


- 马科夫链对于大多数智能体来说不是非常有用
 - 需要用观察到的信息来更新 隐藏变量的置信度 (belief) (概率分布)
- 隐式马科夫模型 (HMMs)
 - 马科夫链构建在变量 X 上
 - 在每个时刻，你观察到输出结果 (E 的值)，这个输出依赖于 X



举例：Weather HMM



$$P(X_t | X_{t-1})$$



■ HMM 的构成：

- 初始的分布： $P(X_1)$
- 转移模型： $P(X_t | X_{t-1})$
- 释放/输出模型：

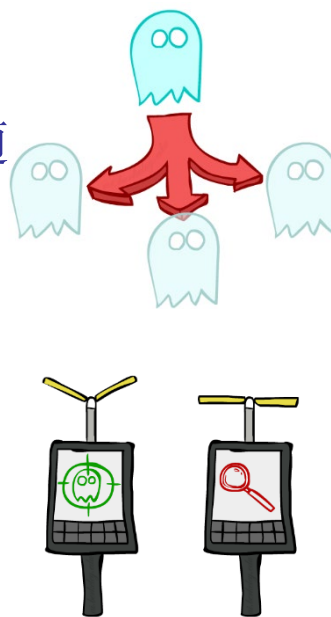
$$P(E_t | X_t)$$

R_{t-1}	R_t	$P(R_t R_{t-1})$
+r	+r	0.7
+r	-r	0.3
-r	+r	0.3
-r	-r	0.7

R_t	U_t	$P(U_t R_t)$
+r	+u	0.9
+r	-u	0.1
-r	+u	0.2
-r	-u	0.8

举例：幽灵追捕者的 HMM

- $P(X_1)$ = 均匀分布
- $P(X|X')$ = 大体顺时针移动，但有时也随机向其他方向移动，或呆在原地不动
- $P(R_{ij}|X)$ = 与之前相同的传感器模型：
红色表示靠近，绿色表示离得还远




1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

$P(X_1)$

1/6	1/6	1/2
0	1/6	0
0	0	0

$P(X|X' = \langle 1, 2 \rangle)$



幽灵追捕者视频演示


Circular Dynamics -- HMM



条件独立性

- HMMs 有两个重要的独立性属性：

- 马科夫隐式过程：未来的状态依赖于过去的，仅通过当前的状态
- 当前的观察值(E_i)独立于所有其他的状态，当给定当前的状态(X_i)



- 这意味着观察变量(E)之间是保证独立的吗？

- [不是，它们通过隐藏状态趋向于相互关联]

真实的 HMM 应用举例




- 机器人追踪定位：
 - 观察到的是距离传感器的读数 range readings (连续的数值)
 - 隐藏状态是机器人在地图上的位置 (连续的)
- 语音识别 HMMs：
 - 观察值是语音信号 (连续数值)
 - 状态是在特定词语里的具体位置 (字母或字母组合)
- 机器翻译 HMMs：
 - 观察值是单词 (成千上万的)
 - 状态是翻译选项

过滤 / 监测

- 过滤或监测 (Filtering/monitoring), 指的是随时间的发展追踪某个状态的置信分布 $B_t(X) = P_t(X_t \mid e_1, \dots, e_t)$
- 开始于一个初始的概率分布 $B_1(X)$, 通常是均匀分布的
- 随着时间的推移, 基于我们获取到的观察 (observations), 我们更新 $B(X)$
- 卡尔曼滤波 (Kalman filter) 发明于60' 年代, 最早实现的此类方法, 在阿波罗登月计划中用于航天器的轨迹估计

举例：机器人定位追踪



Example from
Michael Pfeiffer



$t=0$

传感器模型：能够获取到在哪些方向上有一堵墙，误判不超过1
移动模型：存在一个小概率不会按指令执行相应的动作

举例：机器人定位追踪



Prob



0

1

$t=1$

浅灰色：有可能的情况，因为探测可能会在某一个方向上有错误，但可能性相应比较小（ $1/4$ 的概率）

举例：机器人定位追踪




Prob

0

1

$t=2$

举例：机器人定位追踪




Prob



0

1

$t=3$



举例：机器人定位追踪



Prob





0

1

$t=4$

举例：机器人定位追踪



Prob



0

1

t=5

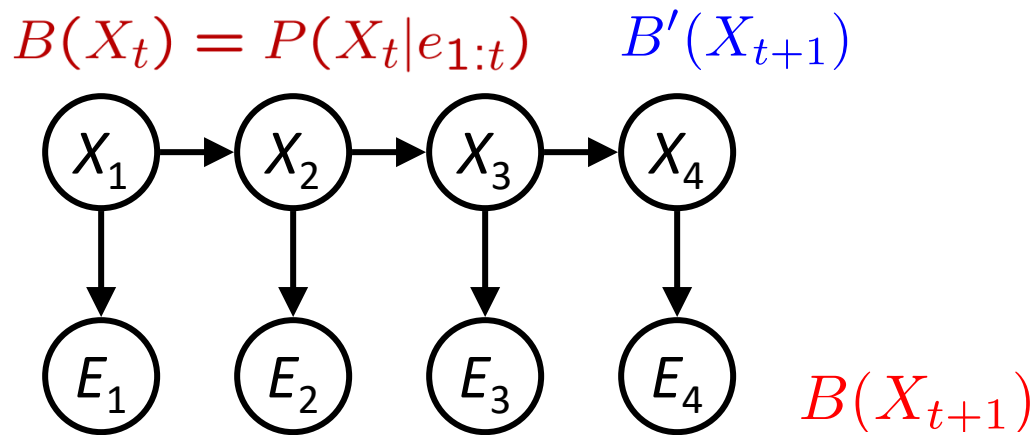
推理：给定观察到的找到状态的分布

- 在每一时刻我们获得传感器的观察值，并想知道：





$$B_t(X) = P(X_t | e_{1:t})$$

- 想法：从 $P(X_1)$ 开始 从 B_{t-1} 推导 B_t
 - 等价于，从 B_t 推导 B_{t+1}

两个步骤：时间推移 + 观察过滤



推理：基础情况



$P(X_2)$

$P(X_1|e_1)$


$$P(X_1|E_1 = e_1) = \frac{P(E_1 = e_1|X_1)P(X_1)}{\sum_{X_1} P(E_1 = e_1|X_1)P(X_1)}$$
$$= \alpha P(E_1 = e_1|X_1)P(X_1)$$
$$P(X_2) = \sum_{x_1} P(x_1, X_2)$$
$$P(X_2) = \sum_{x_1} P(X_2|x_1)P(x_1)$$

时间上的推移

- 假设当前的置信分布是 $P(X \mid \text{给定所有当前的观察})$

$$B(X_t) = P(X_t | e_{1:t})$$

- 然后，在下一个时刻里：



$$P(X_{t+1} | e_{1:t}) = \sum_{x_t} P(X_{t+1}, x_t | e_{1:t})$$

$$= \sum_{x_t} P(X_{t+1} | x_t, e_{1:t}) P(x_t | e_{1:t})$$

- 或简要表示为：

$$= \sum_{x_t} P(X_{t+1} | x_t) P(x_t | e_{1:t})$$

$$B'(X_{t+1}) = \sum_{x_t} P(X' | x_t) B(x_t)$$

- 基本想法：根据转移模型“推移”置信分布
 - 在标记“B”里，应注意时间 t 和所包括的观察值（哪一时刻的）

举例：时间上的推移

■ 随时间的推移，不确定性逐渐“积累”

<0.01	<0.01	<0.01	<0.01	<0.01	<0.01
<0.01	<0.01	<0.01	<0.01	<0.01	<0.01
<0.01	<0.01	1.00	<0.01	<0.01	<0.01
<0.01	<0.01	<0.01	<0.01	<0.01	<0.01

T = 1

<0.01	<0.01	<0.01	<0.01	<0.01	<0.01
<0.01	<0.01	0.06	<0.01	<0.01	<0.01
<0.01	0.76	0.06	0.06	<0.01	<0.01
<0.01	<0.01	0.06	<0.01	<0.01	<0.01

T = 2

0.05	0.01	0.05	<0.01	<0.01	<0.01
0.02	0.14	0.11	0.35	<0.01	<0.01
0.07	0.03	0.05	<0.01	0.03	<0.01
0.03	0.03	<0.01	<0.01	<0.01	<0.01

T = 5

(这里的转移模型：幽灵通常沿顺时针方向移动)



观察（更新）

- 假设当前的置信分布是 $P(X \mid \text{之前的观察})$ ：

$$B'(X_{t+1}) = P(X_{t+1} | e_{1:t})$$

- 那么，获得当前时刻 $(t+1)$ 观察值之后：

$$P(X_{t+1} | e_{1:t+1}) = P(X_{t+1}, e_{t+1} | e_{1:t}) / P(e_{t+1} | e_{1:t})$$

$$\propto_{X_{t+1}} P(X_{t+1}, e_{t+1} | e_{1:t})$$


$$= P(e_{t+1} | e_{1:t}, X_{t+1}) P(X_{t+1} | e_{1:t})$$

$$= P(e_{t+1} | X_{t+1}) P(X_{t+1} | e_{1:t})$$

输出模型/观察模型

- 或简单表示为：

$$B(X_{t+1}) \propto_{X_{t+1}} P(e_{t+1} | X_{t+1}) B'(X_{t+1})$$



举例：观察

- 获得观察值后，置信分布得到再权重变化更新，从而降低了不确定性

0.05	0.01	0.05	<0.01	<0.01	<0.01
0.02	0.14	0.11	0.35	<0.01	<0.01
0.07	0.03	0.05	<0.01	0.03	<0.01
0.03	0.03	<0.01	<0.01	<0.01	<0.01


观察之前

<0.01	<0.01	<0.01	<0.01	0.02	<0.01
<0.01	<0.01	<0.01	0.83	0.02	<0.01
<0.01	<0.01	0.11	<0.01	<0.01	<0.01
<0.01	<0.01	<0.01	<0.01	<0.01	<0.01

观察之后




$$B(X) \propto P(e|X)B'(X)$$



在线置信度更新 (Online Belief Updates)


- 在每一时刻，开始于当前的置信分布 $P(X | \text{evidence})$
- 随时间推移进行更新：

$$P(x_t | e_{1:t-1}) = \sum_{x_{t-1}} P(x_{t-1} | e_{1:t-1}) \cdot P(x_t | x_{t-1})$$



- 根据观察到的证据进行更新：

$$P(x_t | e_{1:t}) \propto_X P(x_t | e_{1:t-1}) \cdot P(e_t | x_t)$$



- 前向算法 (forward algorithm) 每次执行这两步 (但不进行规范化)

前向推移算法

(The Forward Algorithm)

- 在每一时刻我们都获得观察证据，并想知道：

$$B_t(X) = P(X_t|e_{1:t})$$

- 可以推导出下面的更新过程：

$$\begin{aligned} P(x_t|e_{1:t}) &\propto_X P(x_t, e_{1:t}) \\ &= \sum_{x_{t-1}} P(x_{t-1}, x_t, e_{1:t}) \\ &= \sum_{x_{t-1}} P(x_{t-1}, e_{1:t-1}) P(x_t|x_{t-1}) P(e_t|x_t) \\ &= P(e_t|x_t) \sum_{x_{t-1}} P(x_t|x_{t-1}) P(x_{t-1}, e_{1:t-1}) \end{aligned}$$


如果我们想知道 $P(x|e)$ 可以在每一时刻进行正规化，或再最后一起做一次正规化

举例：Weather HMM



$$\begin{array}{l}
 B(+r) = 0.5 \\
 B(-r) = 0.5 \\
 \nearrow \\
 \begin{array}{l}
 B'(+r) = 0.5 \\
 B'(-r) = 0.5 \\
 \downarrow \\
 \begin{array}{l}
 B(+r) = 0.818 \\
 B(-r) = 0.182 \\
 \nearrow \\
 \begin{array}{l}
 B'(+r) = 0.627 \\
 B'(-r) = 0.373 \\
 \downarrow \\
 \begin{array}{l}
 B(+r) = 0.883 \\
 B(-r) = 0.117
 \end{array}
 \end{array}
 \end{array}
 \end{array}
 \end{array}$$

R_t	R_{t+1}	$P(R_{t+1} R_t)$
+r	+r	0.7
+r	-r	0.3
-r	+r	0.3
-r	-r	0.7



R_t	U_t	$P(U_t R_t)$
+r	+u	0.9
+r	-u	0.1
-r	+u	0.2
-r	-u	0.8

Pacman – Sonar (P4)



Pacman视频演示

声波定位幽灵 (通过幽灵位置的置信分布)

