

隐马尔可夫模型(1)

(HMM)

徐静

2018-06-13



0.马尔可夫链

1.隐马尔可夫模型的基本概念

2.概率计算算法

3.参考文献

4.下次预告

5.问题与讨论



0. 马尔可夫链

1. 马尔可夫链的概念

1. 马尔可夫链的概念¹

1. Markov过程是一类重要的随机过程(啥是随机过程?)。应用场景:物理学,生物学,通信,信息,信号处理,语言处理,自动化控制等领域



2. Markov性: 已知随机过程在时刻 t_i 所处的状态的条件下, 过程在时刻 $t(>t_i)$ 所处的状态与过程在时刻 t_i 以前的状态无关, 而仅与过程在 t_i 所处状态有关, 则称该过程为 Markov过程。

T 表示时间空间 E 表示状态空间

1. T 连续, E 连续 -- 连续Markov过程
2. T 连续, E 离散 -- 离散Markov过程
3. T 离散, E 连续 -- Markov序列
4. T 离散, E 离散 -- Markov链

[1] 是一种非常经典又相对简单的概率图模型<http://dataxujing.coding.me/page2/>




一个随机变量的序列称为**马尔可夫链**，如果他们满足**马尔可夫性质**：

$$\Pr(X_i | X_1, \dots, X_{i-1}) = \Pr(X_i | X_{i-1}), \quad \forall i$$

一个随机变量的序列称为**马尔可夫链**，如果他们满足**马尔可夫性质**：

$$\Pr(X_i | X_1, \dots, X_{i-1}) = \Pr(X_i | X_{i-1}), \quad \forall i$$



Markov Chain的性质:

0.条件独立 $\{X_1, \dots, X_{i-1}\} \perp \{X_{i+1}, \dots, X_N\} | X_i$

$$\Pr(X_1, \dots, X_N) = \Pr(X_1) \prod_{i=2}^N \Pr(X_i | X_{i-1})$$

1.马尔可夫性

2.转移概率 (转移矩阵)

$$p_{ij}^k = \Pr(X^{k+1} = j | X^k = i, X^{k-1}, \dots, X^1) = \Pr(X^{k+1} = j | X^k = i)$$

第 k 个时刻从第 i 个状态转移到第 j 个状态的转移概率

3.齐次马尔可夫链

4.n步转移概率

5.稳态分布*(啥是稳态分布?)

小栗子：

假设现有商品ABC今年的市场占率分别为20%、20%和40%，A商品每年流失30%到B，流失30%到C；B商品下一年会流失20%到A，流失30%到C；C商品每年会流失40%到A，流失40%到B，则刚开始ABC的市场占有率形成的矩阵 $[A_0 \ B_0 \ C_0]=[0.2 \ 0.2 \ 0.4]$ ，商品流动率形成的马尔科夫矩阵 $p=[0.4 \ 0.3 \ 0.3; 0.2 \ 0.5 \ 0.3; 0.4 \ 0.4 \ 0.2]$ ，（这里要注意一下马尔科夫矩阵的性质：矩阵的每行的和为1，矩阵的每列的和也为1）。然后我们可以利用马尔科夫链推算下一年的商品ABC的市场占有率 $[A_1 \ B_1 \ C_1]=p[A_0 \ B_0 \ C_0]=[0.26 \ 0.26 \ 0.24]$ 。如果ABC商品市场占有率满足马氏性，那么最终（平稳）的商品市场占有率为 $[A_n \ B_n \ C_n]=p^n[A_0 \ B_0 \ C_0]=[0.2556 \ 0.2556 \ 0.2556]$

Markov Chain现实应用：

1. HTTP服务请求预测：Google 依据用户即将访问某一界面的概率提前做好该界面以提高查询速度。
2. 关键词集群识别：将关键词按不同集群分类，并根据关键词集群确定用户未来搜索路径。
3. 检索推荐：根据用户行为自动为用户推荐链接和检索
4. 评分：根据马尔科夫链可确定权威搜索模式，判定用户的搜索行为



1. 隐马尔可夫模型的基本概念

0. HMM的定义

1. 小栗子

2. 观测序列的生成过程

3. 隐马尔可夫的3个基本问题

0.HMM的定义

定义 (隐马尔可夫模型) 隐马尔可夫模型是关于时序的概率模型，描述由一个隐藏的马尔可夫链随机生成不可观测的状态随机序列，再由各个状态生成一个观测而产生观测随机序列的过程。隐藏的马尔可夫链随机生成的状态的序列称为状态序列(state sequence);每个状态生成一个观测，而由此产生的观测的随机序列，称为观测序列(observation sequence)。序列的每一个位置又可以看做一个时刻。

- 
- HMM由初始概率分布，状态转移概率分布，观测概率分布确定

- 
- HMM由初始概率分布，状态转移概率分布，观测概率分布确定
 - 设 Q 是所欲可能的状态的集合， V 是所有可能的观测的集合

$$Q = \{q_1, \dots, q_N\}, \quad V = \{v_1, \dots, v_M\}$$

其中 N 是可能的状态数， M 是可能的观测数。

- HMM由初始概率分布，状态转移概率分布，观测概率分布确定
- 设 Q 是所欲可能的状态的集合， V 是所有可能的观测的集合

$$Q = \{q_1, \dots, q_N\}, \quad V = \{v_1, \dots, v_M\}$$

其中 N 是可能的状态数， M 是可能的观测数。+ I 是长度为 T 的状态序列， O 是对应的观测序列

$$I = (i_1, \dots, i_T), \quad O = (o_1, \dots, o_T)$$

- HMM由初始概率分布，状态转移概率分布，观测概率分布确定
- 设 Q 是所欲可能的状态的集合， V 是所有可能的观测的集合

$$Q = \{q_1, \dots, q_N\}, \quad V = \{v_1, \dots, v_M\}$$

其中 N 是可能的状态数， M 是可能的观测数。+ I 是长度为 T 的状态序列， O 是对应的观测序列

$$I = (i_1, \dots, i_T), \quad O = (o_1, \dots, o_T)$$

- A 是状态转移矩阵

- HMM由初始概率分布，状态转移概率分布，观测概率分布确定
- 设 Q 是所欲可能的状态的集合， V 是所有可能的观测的集合

$$Q = \{q_1, \dots, q_N\}, \quad V = \{v_1, \dots, v_M\}$$

其中 N 是可能的状态数， M 是可能的观测数。+ I 是长度为 T 的状态序列， O 是对应的观测序列

$$I = (i_1, \dots, i_T), \quad O = (o_1, \dots, o_T)$$

- A 是状态转移矩阵
- B 是观测概率矩阵

$$B = [b_j(k)]_{N \times M}$$

其中 $b_j(k) = \Pr(o_t = v_k | i_t = q_j), k = 1, \dots, M; j = 1, \dots, N$

- HMM由初始概率分布，状态转移概率分布，观测概率分布确定
- 设 Q 是所欲可能的状态的集合， V 是所有可能的观测的集合

$$Q = \{q_1, \dots, q_N\}, \quad V = \{v_1, \dots, v_M\}$$

其中 N 是可能的状态数， M 是可能的观测数。+ I 是长度为 T 的状态序列， O 是对应的观测序列

$$I = (i_1, \dots, i_T), \quad O = (o_1, \dots, o_T)$$

- A 是状态转移矩阵
- B 是观测概率矩阵

$$B = [b_j(k)]_{N \times M}$$

其中 $b_j(k) = \Pr(o_t = v_k | i_t = q_j), k = 1, \dots, M; j = 1, \dots, N$

- π 是初始状态概率向量：

$$\pi = (\pi_i)$$

其中 $\pi_i = \Pr(i_i = q_i), i = 1, \dots, N$ 是时刻 $t = 1$ 处于状态 q_i 的概率

- HMM由初始概率分布，状态转移概率分布，观测概率分布确定
- 设 Q 是所欲可能的状态的集合， V 是所有可能的观测的集合

$$Q = \{q_1, \dots, q_N\}, \quad V = \{v_1, \dots, v_M\}$$

其中 N 是可能的状态数， M 是可能的观测数。+ I 是长度为 T 的状态序列， O 是对应的观测序列

$$I = (i_1, \dots, i_T), \quad O = (o_1, \dots, o_T)$$

- A 是状态转移矩阵
- B 是观测概率矩阵

$$B = [b_j(k)]_{N \times M}$$

其中 $b_j(k) = \Pr(o_t = v_k | i_t = q_j), k = 1, \dots, M; j = 1, \dots, N$

- π 是初始状态概率向量：

$$\pi = (\pi_i)$$

其中 $\pi_i = \Pr(i_1 = q_i), i = 1, \dots, N$ 是时刻 $t = 1$ 处于状态 q_i 的概率

- HMM： $\lambda = (A, B, \pi)$ ， A, B, π 称为HMM的三要素

- 状态转移概率矩阵与初始的状态概率向量确定了马尔可夫链，生成不可观测的状态序列。观测概率矩阵确定了如何从状态生成观测，与状态序列综合决定了如何产生观测序列

- 齐次马尔可夫性假设

$$\Pr(i_t | i_{t-1}, o_{t-1}, \dots, i_1, o_1) = \Pr(i_t | i_{t-1}), \quad t = 1, 2, \dots, T$$

- 观测独立性假设：任意时刻的观测仅依赖于该时刻的马尔可夫链的状态，与其他观测和状态无关

$$\Pr(o_t | i_T, o_T, i_{T-1}, o_{T-1}, \dots, i_{t+1}, o_{t+1}, i_{t-1}, o_{t-1}, \dots, i_1, o_1) = \Pr(o_t | i_t)$$

1.小栗子

(盒子和球模型) 假设有4个盒子，每个盒子里都装有红白两种颜色的球，如下表

Show entries

Search:

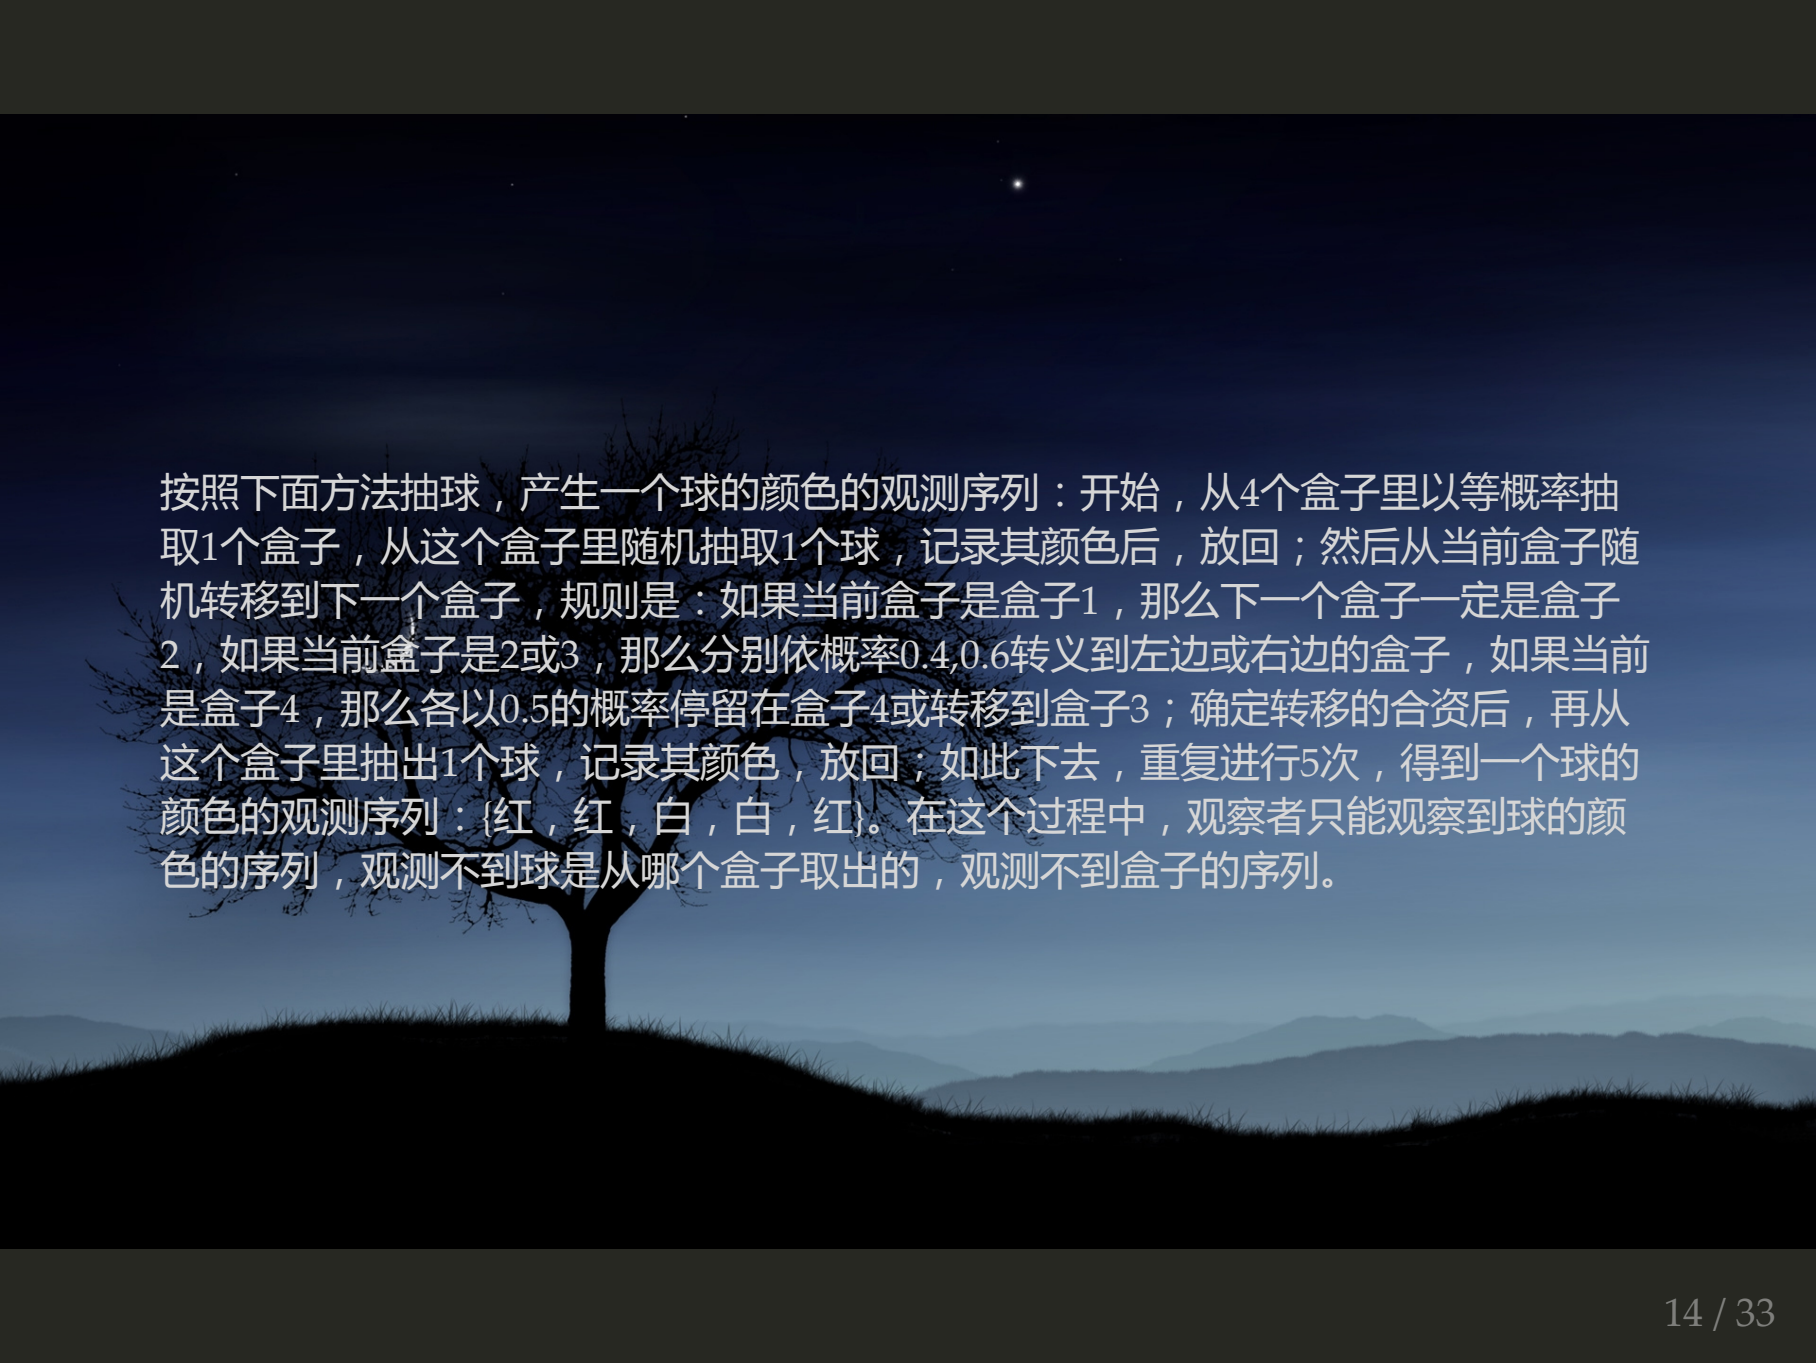
	盒子 ↕	红球数 ↕	白球数 ↕
1	1	5	5
2	2	3	7
3	3	6	4
4	4	8	2

Showing 1 to 4 of 4 entries

Previous

1

Next



按照下面方法抽球，产生一个球的颜色观测序列：开始，从4个盒子里以等概率抽取1个盒子，从这个盒子里随机抽取1个球，记录其颜色后，放回；然后从当前盒子随机转移到下一个盒子，规则是：如果当前盒子是盒子1，那么下一个盒子一定是盒子2，如果当前盒子是2或3，那么分别依概率0.4,0.6转移到左边或右边的盒子，如果当前是盒子4，那么各以0.5的概率停留在盒子4或转移到盒子3；确定转移的盒子后，再从这个盒子里抽出1个球，记录其颜色，放回；如此下去，重复进行5次，得到一个球的颜色观测序列：{红，红，白，白，红}。在这个过程中，观察者只能观察到球的颜色序列，观测不到球是从哪个盒子取出的，观测不到盒子的序列。

- 智能观测到球的颜色的序列，观测不到球从哪个盒子取出，观测不到盒子的序列
- 两个盒子的序列：盒子的序列(状态序列)，球的颜色的观测序列(观测序列)，前者是隐藏的后者是可观测的
- 这是一个HMM的例子 $Q = \{\text{盒子1}, \text{盒子2}, \text{盒子3}, \text{盒子4}\}$, $V = \{\text{红}, \text{白}\}$, $T = 5$, $\pi = (0.25, 0.25, 0.25, 0.25)^T$

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0.4 & 0 & 0.6 & 0 \\ 0 & 0.4 & 0 & 0.6 \\ 0 & 0 & 0.5 & 0.5 \end{bmatrix}$$

$$B = \begin{bmatrix} 0.5 & 0.5 \\ 0.3 & 0.7 \\ 0.6 & 0.4 \\ 0.8 & 0.2 \end{bmatrix}$$

2.观测序列的生成过程

输入：隐马尔可夫模型 $\lambda = (A, B, \pi)$, 观测序列长度 T ;

输出：观测序列 $O = (o_1, \dots, o_T)$

(1)按照初始状态分布 π 产生状态 i_1

(2)令 $t = 1$

(3)按照状态 i_t 的观测概率分布 $b_{i_t}(k)$ 生成 o_t

(4)按照状态 i_t 的状态转移概率分布 $\{a_{i_t i_{t+1}}\}$ 产生状态 i_{t+1}

(5)令 $t = t + 1$ 如果 $t < T$, 转(3);否则终止

3.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 $O = (o_1, \dots, o_T)$ 计算在模型 λ 下观测序列出现的概率 $\Pr(O|\lambda)$

- 学习问题

知道观测序列，估计HMM模型的参数，使得在该模型下观测序列的概率 $\Pr(O|\lambda)$ 最大

- 预测问题

也称为解码问题，知道HMM模型和观测序列，求对给定观测序列条件概率 $\Pr(I/O)$ 最大的状态序列 $I = (i_1, \dots, i_T)$ ，即给定观测序列，求最优可能的对应的状态序列

2. 概率计算算法

0. 直接计算法

1. 前向算法

2. 后向算法

3. 如何自己实现HMM

4. 相关的工具包

5. HMM的应用场景

0.直接算法

- 仅在概念上可行¹
- 最直接的方法时按照概率公式直接计算
- 列举所有可能的长度为 T 的状态序列 I
- 求每个状态序列与观测序列 O 的联合概率 $\Pr(O, I|\lambda)$
- 然后对所有状态序列对应的联合概率求和，得到 $\Pr(O|\lambda)$

[1].具体公式比较简单我就不列了，计算量是 $O(TN^T)$ ，显然不可行

1.前向算法

定义(前向概率)：给定HMM,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, 记作

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

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

(观测序列概率的前向传播)

输入：隐马尔可夫模型 λ , 观测序列 O

输出：观测序列概率 $\Pr(O|\lambda)$

(1)初值

$$\alpha_1(i) = \pi_i b_i(o_1) \quad i = 1, 2, \dots, N$$

(2)递推 对 $t = 1, \dots, T - 1$

$$\alpha_{t+1}(i) = \left[\sum_{j=1}^N \alpha_t(j) a_{ji} \right] b_i(o_{t+1})$$

(3)终止

$$\Pr(O|\lambda) = \sum_{i=1}^N \alpha_T(i)$$

[1].这是啥意思？

2.后向算法

定义 (后向概率) 给定隐马尔可夫模型 λ , 定义在时刻 t 状态为 q_i 的条件下, 从 $t+1$ 到 T 的部分观测序列为 o_{t+1}, \dots, o_T 的概率为后向概率, 记作

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

可以用递推的方法求得后向概率 $\beta_t(i)$ 及观测序列的概率 $\Pr(O|\lambda)$

(观测序列概率的后向传播算法)

输入: 隐马尔可夫模型 λ , 观测序列 O

输出: 观测序列概率 $\Pr(O|\lambda)$

(1)

$$\beta_T(i) = 1, \quad i = 1, 2, \dots, N$$

(2) 对 $t = T - 1, T - 2, \dots, 1$

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(a_{t+1} \beta_{t+1}(j))$$

(3)

$$\Pr(O|\lambda) = \sum_{i=1}^N \pi_i b_i(o_1) \beta_1(i)$$

[1].这是啥意思？

3.如何自己实现HMM

- 观测序列的生成Python实现

```
import numpy as np
class HMM():
```

'''
算法首先初始化两个长度为T的向量，接着按照初始状态分布pi生成第一个状态，取出状态对应的观测的概率分布生成一个观测。接下来都是按前一个状态取出状态转移概率分布生成状态，再取出状态对应的观测的概率分布生成一个观测。重复该步骤就得到长度为T的观测和状态向量。
'''

```
def __init__(self, A, B, pi):
    self.A = A
    self.B = B
    self.pi = pi
def simulate(self, T):
    # draw_from接受一个概率分布，然后生成该分布下的一个样本。
    def draw_from(probs):
        return np.where(np.random.multinomial(1,probs) == 1)[0][0]
    observations = np.zeros(T, dtype=int)
    states = np.zeros(T, dtype=int)
    states[0] = draw_from(self.pi)
    observations[0] = draw_from(self.B[states[0], :])
    for t in range(1, T):
        states[t] = draw_from(self.A[states[t-1], :])
        observations[t] = draw_from(self.B[states[t], :])
    return states, observations
```

- 前向算法Python实现

```
def forward(self, obs_seq):  
    """  
    前向算法  
    """  
    N = self.A.shape[0]  
    T = len(obs_seq)  
    F = np.zeros((N, T))  
    F[:, 0] = self.pi * self.B[:, obs_seq[0]]  
    for t in range(1, T):  
        for n in range(N):  
            F[n, t] = np.dot(F[:, t-1], (self.A[:, n])) * self.B[n, obs_seq[t]]  
    return F
```


- 后向算法Python实现

```
def backward(self, obs_seq):  
    """后向算法"""  
    N = self.A.shape[0]  
    T = len(obs_seq)  
    M = np.zeros((N, T))  
    M[:, T-1] = 1  
    # 或者M[:, -1:] = 1, 列上表示最后一行  
    for t in reversed(range(T-1)):  
        for n in range(N):  
            M[n, t] = np.dot(self.A[n, :], M[:, t+1]) * self.B[n, obs_seq[t]]  
    return M
```

4.相关的工具包

R

- `RHmm`
- `depmixS4`
- `HMM`

Python

- `hmmlearn`
- `seqlearn`

[1].我们都是“调包侠”

5.HMM的应用场景

- 寻找一个失误在一段时间里的变化模式(规律)
- 这些模式可以发生在很多领域...
- 文本分词, 语音识别, 金融衍生品, 管理决策...

A silhouette of a tree on a hill against a blue twilight sky with mountains in the background. The tree is the central focus, with its branches spread out. The sky is a gradient of blue, and the mountains in the distance are also silhouetted. The overall mood is serene and contemplative.

4.下次预告

4. 下次预告

1. 学习算法

- 问题2的解决办法

2. 预测算法

- 问题3的解决办法

3. 隐马尔可夫模型和生成语音识别的变体

- 基于GMM-HMM构建声学模型
- 基于轨迹和隐藏动态模型的语音建模和识别
- 基于生成模型HMM及其变体解决语音识别问题

5.参考文献

- [1]. 机器学习[M],周志华
- [2]. 统计学习方法[M],李航
- [3]. 解析深度学习语音识别实践[M],俞凯, 钱彦旻
- [4]. 深度学习导论及案例分析[M],李玉鑑, 张婷



6.问题与讨论

1. Markov链的性质有哪些？
2. 生成学习与传统判别学习的区别在哪？
3. HMM三个基本问题是什么？
4. HMM的应用场景有哪些？

A silhouette of a tree on a hill against a blue sky with mountains in the background. The text "Thanks For Your Attention!" is overlaid in white.

Thanks For Your Attention!