

# DAY 3

## 大偏差定理·续

对闭集  $F \in B$ ,  $\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(F) \leq -\inf_{x \in F} I(x)$ .

对开集  $G \in B$ ,  $\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(G) \geq -\inf_{x \in G} I(x)$ .

对于满足条件,  $\inf_{x \in \mathbb{R}^d} I(x) = \inf_{x \in \mathbb{R}^d} I(x) - I(x)$ .  $\mu_n(\mathbb{R}^d) \sim \exp(-n \cdot \inf_{x \in \mathbb{R}^d} I(x))$ .

$\mathbb{R}^d$  取值为 1 会是什么? 对于点  $\mu_n(x, x+dx) = p(x) dx \sim \exp(-n I(x)) dx$ .

为什么这是对的? 由 Laplace 所证.  $F(n) = \int_{\mathbb{R}^d} p(x) dx = \int_{\mathbb{R}^d} \exp(-n I(x)) dx$ .

$\Rightarrow \lim_{n \rightarrow \infty} \frac{1}{n} \log F(n) = \sup_{x \in \mathbb{R}^d} -I(x) = -\inf_{x \in \mathbb{R}^d} I(x)$ . 这也就和大概结果对上子.

2. (证明) 速率函数的正确解释. 核心 = 我们要求一个被构造出来的分布/期望.

考虑  $\lim_{n \rightarrow \infty} \frac{1}{n} \log \mathbb{E}_{x \sim \mu_n}(\exp(n \phi(x)))$ .  $\phi(x)$  是某函数:  $\mu_n$  点均值的分布

$= \lim_{n \rightarrow \infty} \frac{1}{n} \log \int \exp(n \phi(x)) d\mu_n$

$= \lim_{n \rightarrow \infty} \frac{1}{n} \log \int \exp(n \phi(x)) \cdot \exp(-n I(x)) dx$

$= \lim_{n \rightarrow \infty} \frac{1}{n} \log \int \exp(n(\phi(x) - I(x))) dx$

$\sim$  (Laplace).  $\sup_{x \in \mathbb{R}^d} \phi(x) - I(x)$

取  $\phi(x) = \lambda x \Rightarrow \mathbb{E}(\exp(n \lambda x))$   
 $= \mathbb{E}(\exp(n \lambda \bar{x}))$

$= \mathbb{E}(\exp(\lambda \bar{x})^n)$

$= [\mathbb{E}(\exp(\lambda \bar{x}))]^n$

$= M(\lambda)^n$

$\frac{1}{n} \log (M(\lambda))^n = \Lambda(\lambda)$ .

$\Lambda(\lambda)$  与  $I(x)$  自由能变换.

> 大偏差定理的导引证明.

1). 上界估计: 直接考虑  $\mu_n(J_\lambda)$ .  $J_\lambda = [x, +\infty)$ . 考虑  $J_\lambda$ . 两次放缩.

$$\begin{aligned} \text{开始考虑: } \mu_n(J_\lambda) &= \int_{-\infty}^{+\infty} \mu_n(dy) \\ &= \int_{-\infty}^{+\infty} \exp(-n\lambda y) \cdot \exp(n\lambda y) \mu_n(dy) \\ &\leq \exp(-n\lambda x) \cdot \int_{-\infty}^{+\infty} \exp(n\lambda y) \mu_n(dy) \\ &\leq \exp(-n\lambda x) \cdot \int_{-\infty}^{+\infty} \exp(n\lambda y) \mu_n(dy) \\ &= \exp(-n\lambda x) \cdot \mathbb{E}(\exp(n\lambda x)) \rightarrow \mathbb{E}(\exp(\lambda \sum_{i=1}^n X_i)) = [M(\lambda)]^n \end{aligned}$$

$\Rightarrow \mu_n(J_\lambda) \leq \exp(-n\lambda x) \cdot [M(\lambda)]^n$ . 把它变成大偏差的形式.

$$\begin{aligned} \Rightarrow \frac{1}{n} \cdot \log \mu_n(J_\lambda) &\leq -(\lambda x - \Lambda(\lambda)). \quad \text{for all } \lambda. \\ &\leq -\sup_{\lambda} (\lambda x - \Lambda(\lambda)). = -I(x). \end{aligned}$$

从而我们得到: 对  $J_\lambda \in [x, +\infty)$ .  $\frac{1}{n} \log \mu_n(J_\lambda) \leq -I(x)$ .

同样, 对  $J_\lambda = (-\infty, x]$ .  $\frac{1}{n} \log \mu_n(J_\lambda) \leq -I(x)$ .

现在考虑闭区间  $F \subset \mathbb{R}$ . 若  $0 \leq F$  则由  $I(x)$  的凸性及单调性,  $\inf_{x \in F} I(x) = 0$ . 上界估计自然成立的.

例如:  $(\quad)$

$$\begin{aligned} \Rightarrow F \subset J_{x_1} \cup J_{x_2} &\Rightarrow \lim_{n \rightarrow \infty} \sup \frac{1}{n} \log \mu_n(F) \leq \max. (\limsup \frac{1}{n} \log \mu_n(J_{x_1}), \limsup \frac{1}{n} \log \mu_n(J_{x_2})) \\ &\leq -\min_{x \in F} (I(x_1), I(x_2)) \\ &= -\inf_{x \in F} I(x). \end{aligned}$$



2) 下界估计. 只考虑  $\sup \{ \lambda x - \Lambda(\lambda_0) \}$  的极值在  $\lambda = \lambda_0$  处取到的情形.  $\Rightarrow I(x) = \lambda_0 x - \Lambda(\lambda_0)$ . 关键: 构造 tilt distribution.  
 定义所谓 tilt dist.  $\tilde{\mu}(dy) = \frac{1}{M(\lambda_0)} \exp(\lambda_0 y) \mu(dy)$ .  $\mu$  为切值的分布.  
 $\lambda = \Lambda'(\lambda) |_{\lambda=\lambda_0} = \frac{M'(\lambda_0)}{M(\lambda_0)}$  并只取  $(x-\delta, x+\delta)$  附近的测度.

首先我们有它确实是一个测度.  $\int \tilde{\mu}(dy) = \frac{1}{M(\lambda_0)} \int \exp(\lambda_0 y) \mu(dy) = \frac{1}{M(\lambda_0)} \mathbb{E}(\exp(\lambda_0 y)) = 1$ .

其次看它的期望值  $\int y \tilde{\mu}(dy) = \frac{1}{M(\lambda_0)} \int y \exp(\lambda_0 y) \mu(dy) = \frac{1}{M(\lambda_0)} M'(\lambda) |_{\lambda=\lambda_0} = \lambda$ .

我们要估计  $\mu_n(x)$  的下界. 我们利用  $\tilde{\mu}$  与  $(x-\delta, x+\delta)$  上的测度作比较.

$$\begin{aligned} \mu_n(x) &\geq \mu_n([x-\delta, x+\delta]) \\ &= \int \{ \prod_{i=1}^n \tilde{\mu}(y_i - x) < \delta \} \mu(dy_1) \dots \mu(dy_n) \\ &= \int \{ \prod_{i=1}^n \exp(-\lambda_0 y_i) \exp(\lambda_0 y_i) \exp(-\lambda_0 y_i) \exp(\lambda_0 y_i) < \delta \} \dots \\ &\geq \exp(-n \lambda_0 (x+\delta)) \int \{ \prod_{i=1}^n \exp(\lambda_0 y_i) \exp(\lambda_0 y_i) \dots \mu(dy_1) \dots \mu(dy_n) \} \\ &= \exp(-n \lambda_0 (x+\delta)) \int \{ \prod_{i=1}^n \tilde{\mu}(dy_i) \} \tilde{\mu}(dy_1) \dots \tilde{\mu}(dy_n). \end{aligned}$$

而由于  $\mathbb{E}[X] = \lambda$ .  $\Rightarrow$  由(6)大数定律.  $\int \{ \prod_{i=1}^n \tilde{\mu}(dy_i) \} \tilde{\mu}(dy_1) \dots \tilde{\mu}(dy_n) \rightarrow 1$ .

$$\rightarrow \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x) \geq -\lambda_0 (x+\delta) + \Lambda(\lambda_0) = -I(x) - \lambda_0 \delta$$

首先利用  $\delta$  的任意性.  $\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x) \geq -I(x)$ . ( $\delta \rightarrow 0$ ).

其次利用  $\lambda$  的任意性.  $\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mu_n(x) \geq \sup_{\lambda \in \mathbb{R}} (-I(x)) = -\inf_{\lambda \in \mathbb{R}} I(x)$ .

下面我们开始讨论随机过程。 → 随机过程是什么？一系列随机变量。  $(t, \omega) \rightarrow \mathbb{R}$  的函数。

## 离散时间 Markov 链

例子：Ehrenfest 的气体扩散模型。想象一个箱子内共有  $N$  个气体分子，其在右侧用隔板隔开。

每隔  $\Delta t$  时间，就会在右侧所有分子中随机选择一，使其从右侧“自游移”到左侧，或从左侧“自游移”到右侧。

设  $i$  状态代表左侧有多少分子  $\Rightarrow$  “转移矩阵”。

右状态 $j$	左状态 $i$				
	0	1	2	$N$	
0	0	1	0	...	0
1	$\frac{1}{N}$	0	$\frac{N-1}{N}$		
2		$\frac{2}{N}$	0	$\frac{N-2}{N}$	
$\vdots$					
$\vdots$					
$N$				$\frac{N-1}{N}$	0

我们需要研究一个随机过程 我们最熟悉的一定是它的联合分布

$$P(X_n = i_n, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0).$$

$$= P(X_0 = i_0) \cdot P(X_1 = i_1 | X_0 = i_0) \cdot P(X_2 = i_2 | X_1 = i_1, X_0 = i_0) \dots P(X_n = i_n | X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0).$$

如果一个随机过程可以“忘却往事”，使得上式被写成：

$$= P(X_0 = i_0) \cdot P(X_1 = i_1 | X_0 = i_0) \cdot P(X_2 = i_2 | X_1 = i_1) \dots P(X_n = i_n | X_{n-1} = i_{n-1}).$$

则这样的随机过程称为 离散时间马尔可夫链。（我们要求状态空间离散且有限。）

自然地，我们可以写出

$$P(X_n = j | X_0 = i) = \sum_{k_1} \sum_{k_2} \dots \sum_{k_{n-1}} P(X_1 = k_1 | X_0 = i) \cdot P(X_2 = k_2 | X_1 = k_1) \cdot P(X_3 = k_3 | X_2 = k_2) \dots P(X_n = j | X_{n-1} = k_{n-1}).$$

对所有可能的路径求和，如同求曼哈顿距离。

上式可被写成更紧凑的形式。将时刻  $t$  与所有链位于状态的概率写成一个行向量。

$$\mu_t = \begin{bmatrix} P(X_1=0) \\ \vdots \\ P(X_t=S) \end{bmatrix}$$

并引入转移矩阵  $P$ 。其元素  $p_{ij} = P(X_{n+1}=j | X_n=i)$ 。

$$\mu_t P = \begin{bmatrix} \mu_t \end{bmatrix} \begin{bmatrix} P \end{bmatrix} = \begin{bmatrix} \downarrow \end{bmatrix} \begin{bmatrix} I \end{bmatrix}$$

$$= (\mu_t)_0(P)_{00} + (\mu_t)_1(P)_{01} + \dots$$

$$= P(X_{t+1}=0 | X_t=0).$$

从而，马氏链在任意时间的概率分布可以被简单地写为  $\mu_t = \mu_0 P^t$ 。

这立刻给我们提出新的问题：如果一个分布  $\pi$  满足  $\pi P = \pi$  (所谓的稳态分布) 这样的分布是否存在？唯一吗？

为解决这个问题，我们需要在马氏链上定义一些其他概念。

- 给定  $i, j$ 。若存在  $k_1, k_2, \dots, k_s$  使得  $p_{ik_1}, p_{k_1 k_2}, \dots, p_{k_s j} > 0$ 。则称状态  $j$  是从状态  $i$  可达的。
- 若从  $i$  可达  $j$  且  $j$  可达  $i$ ，则称  $i, j$  是互通的。互通是马氏链上的一种等价关系，可以通过这种等价关系在马氏链上聚类。

在整个链上，我们可以定义两个性质。

- 我们称一个马氏链是不可约的，若马氏链上任意两节点  $i, j$  是互通的。
- 我们称一个马氏链是本原的 (primitive)，若  $\exists s, \forall i, j$ ，转移矩阵的幂次  $(P^s)_{ij} > 0$ 。

马氏链的不变分布的存在性与唯一性。

- 若一个马氏链是不可约的，则它存在唯一不变分布  $\pi$ 。(这是一个高等代数问题，这里暂不给出证明)。
- 若一个马氏链是本原的，则从任意初始分布开始，都有  $\mu_n = \mu_0 P^n \rightarrow \pi$ 。

我们现在来证明第2)点。给定两个分布  $\mu, \tilde{\mu}$ ，定义它们之间的距离为  $d(\mu, \tilde{\mu}) = \frac{1}{2} \sum_i |\mu_{0,i} - \tilde{\mu}_{0,i}|$ 。

$$\text{使用记号 } a^+ = \max(a, 0), \quad a^- = \max(-a, 0).$$

$$\text{若取 } \mu_0 = \mu_0 P^0, \quad \tilde{\mu}_0 = \tilde{\mu}_0 P^0 \quad \text{则 } \mu_{0,i} = \sum_j \mu_{0,j} (P^0)_{ji}, \quad \tilde{\mu}_{0,i} = \sum_j \tilde{\mu}_{0,j} (P^0)_{ji}.$$

$$\text{按我们之前定义: } d(\mu_0, \tilde{\mu}_0) = \frac{1}{2} \sum_{i \in S} \left( \sum_{j \in S} (\mu_{0,j} (P^0)_{ji} - \tilde{\mu}_{0,j} (P^0)_{ji}) \right)$$

$$\text{由于有性质: } 0 = \sum_i (\mu_{0,i} - \tilde{\mu}_{0,i}) = \sum_i (\mu_{0,i} - \tilde{\mu}_{0,i})^+ - \sum_i (\mu_{0,i} - \tilde{\mu}_{0,i})^-$$

→ 把上面的距离重写为:

$$d(\mu_0, \tilde{\mu}_0) = \sum_{i \in S} \left( \sum_{j \in S} (\mu_{0j} - \tilde{\mu}_{0j}) (p^j)_{ji} \right)^2 \\ \leq \sum_{i \in B^+} (p^j)_{ji} \sum_j (\mu_{0j} - \tilde{\mu}_{0j})^2$$

$B^+$  是标号满足  $\sum_{j \in S} (\mu_{0j} - \tilde{\mu}_{0j}) (p^j)_{ji} > 0$  的集合.

注:  $B^+$  中任何标号全部包含. 若  $B^+$  中各标号所有, 则会有对每一个标号  $i$  都有  $(\mu_0 p^j)_{ji} > (\tilde{\mu}_0 p^j)_{ji}$ , 而这显然不可能.

从而我们立刻得到:  $d(\mu_0, \tilde{\mu}_0) \leq d(\mu_0, \tilde{\mu}_0) (1-\alpha)$ . (\*)

由于  $d(0,0) \leq 1$ , 从而

$$d(\mu_n, \mu_{n+1}) \leq d(\mu_{n-1}, \mu_{n-1-\alpha}) (1-\alpha)^n \leq (1-\alpha)^n \Rightarrow \mu_n \text{ 是柯西列}$$

又由(\*)式中的压缩映射性质, 收敛是唯一的.

Example: Markov Decision Process.

$$p(s_{t+1} | s_t, a_t)$$

MDP 的转移概率不是  $S \times S \rightarrow \mathbb{R}$  的映射, 而是  $S \times A \times S \rightarrow \mathbb{R}$  的映射. 此外, 给定  $\pi: S \rightarrow [0, 1]^A$ ,  $\pi(s_{t+1}) = [p_1(a_1), p_2(a_2), \dots]$

$$\text{给定 } R: S \times A \rightarrow \mathbb{R}, \quad r(s_t, a_t) = r_t.$$

一个 MDP 问题被表述为: 给定不变的转移概率,  $p(s_{t+1} | s_t, a_t)$ ,  $r(s_t, a_t) = r_t$ , 和固定的折扣系数  $\gamma$ .

求  $\pi(a|s)$ . 最大  $J_\pi = \sum_{t=0}^{\infty} \gamma^t \cdot \text{Mar}(s_t)$  (折扣奖励).

这里只介绍一种方法: Policy Gradient. 也称之为可微奖励率梯度. 用  $\tau$  表示一条轨迹,  $\tau = \{s_1, a_1, r_1, s_2, a_2, r_2, \dots\}$ .

$$\mathbb{E}_{\tau \sim p_\theta(\tau)} (R(\tau)) = \sum_{\tau} R(\tau) \cdot p_\theta(\tau)$$

$$\Rightarrow \mathbb{D} \mathbb{E}_{\tau \sim p_\theta(\tau)} (R(\tau)) = \sum_{\tau} R(\tau) \cdot \mathbb{D} p_\theta(\tau) = \sum_{\tau} R(\tau) \cdot p_\theta(\tau) \cdot \frac{\mathbb{D} p_\theta(\tau)}{p_\theta(\tau)} = \sum_{\tau} R(\tau) \cdot p_\theta(\tau) \cdot \log p_\theta(\tau) = \mathbb{E}_{\tau \sim p_\theta(\tau)} [R(\tau) \cdot \log p_\theta(\tau)].$$

在实际使用的时候应该怎么办? 直接采样求期望和梯度.

$$\text{Gradient} = \sum_{\tau} R(\tau) \cdot \mathbb{D} \log p_\theta(\tau)$$

$$= \sum_{\tau} \left( r(s_1, a_1) + \gamma \cdot r(s_2, a_2) + \gamma^2 \cdot r(s_3, a_3) + \dots \right) \cdot \mathbb{D} \left( \sum_i \log p(s_{i+1} | s_i, a_i) \cdot \pi(a_i | s_i) \right)$$