

Key concepts:

- *Markov* 链;
- *Chapman-Kolmogorov* 方程;
- 不变分布。

考虑一个随机序列 $\{X_n, n = 0, 1, 2, \dots, n\}$, 我们关心联合分布

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n)$$

若有独立性,

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = P(X_0 = i_0)P(X_1 = i_1) \cdots P(X_n = i_n)$$

这是我们初等概率论中经常关心的情况, 但如果没有独立性,

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n)$$

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

当序列长度 n 较大时, 条件概率 $P(X_n = i_n | X_{n-1} = i_{n-1}, \dots, X_0 = i_0)$ 难以研究, 一种合理的简化是 *Markov* 性。

4.1 离散时间 Markov 链

Definition 4.1 (离散时间 Markov 链) 设 E 是一个可数集合, 不妨为 $\mathbb{N}^+ = \{1, 2, \dots\}$ 。称状态空间为 E 的离散时间随机过程 $\{X_n, n = 0, 1, 2, \dots\}$ 为一个离散时间 *Markov* 链, 如果对于任意 $n \geq 0$, 任意状态 $i_0, i_1, \dots, i_{n-1}, i, j \in E$, 有 *Markov* 性:

$$P\{X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0\} = P\{X_{n+1} = j | X_n = i\} \quad (4.1)$$

成立。称 $P(n, i; n+1, j) \triangleq P\{X_{n+1} = j | X_n = i\}$ 为时刻 n 处于状态 i , 时刻 $n+1$ 转移到状态 j 的转移函数。若它与 n 无关, 则记为 P_{ij} , 此时称 $\{X_n\}$ 为一个时齐 Markov 链, 矩阵 $P = (P_{ij})_{i, j \in E}$ 称为一步转移矩阵。我们之后都考虑时齐 Markov 链。

注1. Markov性(4.1)等价于

$$\begin{aligned} & P\{X_{n+1} = j, X_{n-1} = i_{n-1}, \dots, X_0 = i_0 | X_n = i\} \\ &= P\{X_{n+1} = j | X_n = i\} \cdot P\{X_{n-1} = i_{n-1}, \dots, X_0 = i_0 | X_n = i\} \end{aligned} \quad (4.2)$$

即验证:

$$P(C | BA) = P(C | B) \Leftrightarrow P(CA | B) = P(C | B)P(A | B)$$

其中 A 表示“过去”, B 表示“现在”, C 表示“未来”, 用条件概率的初等定义即可验证。

(4.2)说明 Markov性等价于在已知“现在”的条件下, “过去”和“未来”是独立的。

注2. Markov性(4.1)意味着

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = P(X_0 = i_0) \prod_{k=1}^n P(k-1, i_{k-1}; k, i_k). \quad (4.3)$$

(4.3)有的地方称为链式法则(chain rule)。可以看出, Markov链的有限维联合分布由初始分布和转移函数决定, 在时齐情形,

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = P(X_0 = i_0) \prod_{k=1}^n P_{i_{k-1}i_k}.$$

注3. 若矩阵 $P = (P_{ij})_{i, j \in E}$ 满足:

$$\begin{aligned} & P_{ij} \geq 0, \quad i, j \in E \\ & \sum_{j \in E} P_{ij} = 1, \quad \forall i \in E \end{aligned}$$

则称 P 为 E 上的转移矩阵 (transition matrix), 或者随机矩阵 (stochastic matrix)。称 P_{ij} 为从状态 i 到 j 的转移概率。

注4. 算子视角。记 $\mathcal{B}(E)$ 为 E 上所有有界函数 $f: E \rightarrow \mathbb{R}$ 的集合, 可以定义算子

$$\begin{aligned} & P: f \in \mathcal{B}(E) \rightarrow P[f] \in \mathcal{B}(E), \\ & f(x) \mapsto P[f](x) \triangleq \sum_{j \in E} P_{ij} f(j) = \mathbb{E}[f(X_{n+1}) | X_n = i] \end{aligned}$$

下面定理说明了Markov链可以看成是一个“噪声”驱动的动力系统(Dynamical Systems)。

Theorem 4.2 设 $\{Z_n\}_{n \geq 1}$ 是一个独立同分布的随机变量序列, 取值于任意空间 F 。设 E 是一个可数空间, $f: E \times F \rightarrow E$ 是某个函数。设 X_0 是一个在 E 中取值的随机变量, 与 $\{Z_n\}_{n \geq 1}$ 独立。则递推方程

$$X_{n+1} = f(X_n, Z_{n+1}) \quad (4.4)$$

定义了一个时齐Markov链。

Proof: 对递推关系式 (4.4) 进行迭代可知, 对所有 $n \geq 1$, 存在一个函数 g_n , 使得 $X_n = g_n(X_0, Z_1, \dots, Z_n)$, 因此

$$\begin{aligned} P(X_{n+1} = j \mid X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) \\ &= P(f(i, Z_{n+1}) = j \mid X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) \\ &= P(f(i, Z_{n+1}) = j), \end{aligned}$$

因为事件 $\{X_0 = i_0, \dots, X_{n-1} = i_{n-1}, X_n = i\}$ 可由 X_0, Z_1, \dots, Z_n 表示, 因此与 Z_{n+1} 独立。类似地,

$$P(X_{n+1} = j \mid X_n = i) = P(f(i, Z_{n+1}) = j)$$

因此我们得到一个时齐Markov链, 而且

$$P_{ij} = P(f(i, Z_1) = j). \quad (4.5)$$

■

注1. 上面的条件可以适当放宽, 不再满足 $\{Z_n\}$ 独立, 仅要求 $n \geq 1$ 时, 在给定 X_n 的条件下, Z_{n+1} 和 $\{X_0, Z_1, Z_2, \dots, Z_n\}$ 独立, 即

$$\begin{aligned} P(Z_{n+1} = m_{n+1} \mid X_n = i_n, Z_{n-1} \\ = m_{n-1}, \dots, Z_1 = m_1) = P(Z_{n+1} = m_{n+1} \mid X_n = i_n) \end{aligned}$$

同样可以证明 $\{X_n\}_{n \geq 1}$ 是 Markov 链, 且当 $\{Z_n\}$ 同分布时, 该链仍然是时齐的, 一步转移概率为

$$P_{ij} = P(f(i, Z_1) = j \mid X_0 = i)$$

注2. 不是所有的时齐Markov链都可以写成由噪声驱动的动力系统形式。参考: Pierre Brémaud, Markov Chains (Second Edition), 2020, Springer. Example 2.1.3

4.2 例子

Example 4.3 (一维简单随机游走) 考虑一个在 \mathbb{Z} 上运动的粒子，它每一次等可能地向左或向右移动一步，即

$$P_{i,i+1} = P_{i,i-1} = \frac{1}{2}, \quad \forall i \in \mathbb{Z}.$$

粒子在 \mathbb{Z} 上的位置为一个随机过程，称为一维简单随机游走。

我们可以用随机变量序列驱动来构造随机游走。假设 ξ_1, ξ_2, \dots 独立同分布于

$$P(\xi_1 = 1) = P(\xi_1 = -1) = \frac{1}{2}.$$

假设 S_0 为取整数值的随机变量，且它独立于 ξ_1, ξ_2, \dots ，令

$$S_n \triangleq S_0 + \xi_1 + \dots + \xi_n = S_{n-1} + \xi_n.$$

那么 S_n 为从 S_0 出发的一维简单随机游走。

ξ_n 可以服从更一般的分布，此时， S_n 称为一般随机游走。

Example 4.4 (Ehrenfest模型) 在统计热力学的研究中，一个经典的模型是 *Ehrenfest* 模型，用来模拟气体分子在两个容器中的扩散过程。考虑甲乙两个容器，其中总共的气体分子为 $2N$ 。假设单位时间内，有且只有一个分子在甲乙两个容器之间扩散，扩散的分子是随机选取的。

记 n 时间后甲容器内的气体分子数为 $X_n + N$ ，则 $\{X_n\}$ 的状态空间为 $E = \{-N, -N + 1, \dots, 0, 1, \dots, N\}$ ，可以表示为

$$X_{n+1} = X_n + Z_{n+1}$$

其中驱动噪声 Z_n 是取值为 ± 1 的随机变量，满足

$$P(Z_{n+1} = 1 | X_n = i) = \frac{N - i}{2N}, \quad P(Z_{n+1} = -1 | X_n = i) = \frac{N + i}{2N}$$

则由定理 4.2 注 1， $\{X_n\}$ 为一个离散时间 *Markov* 链，转移概率为

$$P(X_{n+1} = j | X_n = i) = \begin{cases} \frac{N-i}{2N}, & j = i + 1 \\ \frac{N+i}{2N}, & j = i - 1 \\ 0, & |j - i| \neq 1 \end{cases}$$

注. 直观上, 如果一开始甲容器里没有气体分子, 经过自由扩散, 两个容器中的气体分子数量应该会趋于一致。这本质上是热力学第二定律描述的熵增现象, 说明在封闭系统中, 微观随机行为会导致宏观熵的增加。

Example 4.5 (图上的随机游走) 设 $G = (\mathcal{V}, \mathcal{E})$ 为一个图, 对于节点 $i, j \in \mathcal{V}$, 如果 $(i, j) \in \mathcal{E}$, 则称节点 i, j 相邻, 记为 $i \sim j$.

考虑一个位置位于图上节点的粒子, 它每次随机地移动到相邻节点上。记 X_n 为它在时刻 n 所处的位置, 则 $\{X_n\}$ 是一个状态空间为 \mathcal{V} 的离散时间 Markov 链, 转移概率为

$$P_{ij} = \begin{cases} \frac{1}{\deg(i)} & \text{if } j \sim i, \\ 0 & \text{otherwise.} \end{cases}$$

其中 $\deg(i)$ 为节点 i 的度 (degree), 表示节点 i 相邻的节点的数目。

4.3 Chapman-Kolmogorov 方程

记时齐 Markov 链的 n 步转移概率为

$$P_{ij}^{(n)} = P\{X_{n+m} = j | X_m = i\}, \quad n \geq 0, \quad i, j \geq 0.$$

Proposition 4.6 (Chapman-Kolmogorov 方程) 对任意 $i, j \in E, m, n \geq 0$,

$$P_{ij}^{(n+m)} = \sum_{k \in E} P_{ik}^{(n)} P_{kj}^{(m)}$$

Proof:

$$\begin{aligned} P_{ij}^{(n+m)} &= P\{X_{n+m} = j | X_0 = i\} \\ &= \sum_{k \in E} P\{X_{n+m} = j, X_n = k | X_0 = i\} \\ &= \sum_{k \in E} P\{X_{n+m} = j | X_n = k, X_0 = i\} P\{X_n = k | X_0 = i\} \\ &= \sum_{k \in E} P_{kj}^{(m)} P_{ik}^{(n)}. \end{aligned}$$



记 $P^{(n)}$ 为 n 步转移矩阵, 则由Chapman-Kolmogorov 方程

$$P^{(n+m)} = P^{(n)} \cdot P^{(m)},$$

其中 \cdot 为矩阵乘法, 那么

$$P^{(n)} = P \cdot P^{(n-1)} = P \cdot P \cdot P^{(n-2)} = \dots = P^n.$$

Example 4.7 (两状态的Markov链 I) 设离散时间 *Markov* 链的样本空间只有两个状态。一步转移概率矩阵为

$$P = \begin{pmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{pmatrix}$$

其中 $\alpha, \beta \in (0, 1)$ 。我们想要计算它的 n 步转移矩阵, 由 *Chapman-Kolmogorov* 方程, 只需要计算 P^n 。

做特征值分解, P 的两个特征值为

$$\lambda_0 = 1, \quad \lambda_1 = 1 - \alpha - \beta$$

可得

$$P = \frac{1}{\alpha + \beta} \begin{pmatrix} 1 & \alpha \\ 1 & -\beta \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 1 - \alpha - \beta \end{pmatrix} \begin{pmatrix} \beta & \alpha \\ 1 & -1 \end{pmatrix}$$

那么

$$\begin{aligned} P^n &= \frac{1}{\alpha + \beta} \begin{pmatrix} 1 & \alpha \\ 1 & -\beta \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & (1 - \alpha - \beta)^n \end{pmatrix} \begin{pmatrix} \beta & \alpha \\ 1 & -1 \end{pmatrix} \\ &= \frac{1}{\alpha + \beta} \begin{pmatrix} \beta & \alpha \\ \beta & \alpha \end{pmatrix} + \frac{(1 - \alpha - \beta)^n}{\alpha + \beta} \begin{pmatrix} \alpha & -\alpha \\ -\beta & \beta \end{pmatrix} \end{aligned}$$

注意到, 随着 $n \rightarrow \infty$, n 步转移概率存在极限

$$\begin{aligned} \lim_{n \rightarrow \infty} P_{00}^{(n)} &= \lim_{n \rightarrow \infty} P_{10}^{(n)} = \frac{\beta}{\alpha + \beta} \\ \lim_{n \rightarrow \infty} P_{11}^{(n)} &= \lim_{n \rightarrow \infty} P_{01}^{(n)} = \frac{\alpha}{\alpha + \beta} \end{aligned}$$

这是我们之后要学习的遍历性。

思考: 如果 $|1 - \alpha - \beta| = 1$, 即 $\alpha = \beta = 1$ 时会发生什么?

4.4 不变分布

设 $\{X_n\}$ 是一个转移矩阵为 P 的 Markov 链, 初始分布为 $X_0 \sim \mu$, 则 X_1 的分布列为

$$\begin{aligned} P(X_1 = j) &= \sum_{k \in E} P(X_0 = k)P(X_1 = j|X_0 = k) \\ &= \sum_{k \in E} \mu_k P_{kj}, \quad j \in E \end{aligned}$$

把分布 μ 视为状态空间 E 上的行向量, 那么 X_1 的分布 μ_1 为 μP . 自然地, X_n 的分布为 $\mu P^{(n)} = \mu P^n$.

Definition 4.8 (不变测度) 设 $\pi = \{\pi_i, i \in E\}$ 为 E 上的测度, 若 π 满足不变方程

$$\pi_j = \sum_{k \in E} \pi_k P_{kj}, \quad \forall j \in E$$

则称 π 为 P 的不变测度 (*invariant measure*). 进一步, 若 $\sum_{i \in E} \pi_i = 1$, 则称 π 为不变分布。也称 π 为以 P 为转移矩阵的 Markov 链的不变测度。

注1. 显然, $\pi_i = 0, \forall i \in E$ 是一个平凡的不变测度。若 π 是非平凡的, 且 $\sum_{i \in E} \pi_i < \infty$ 的不变测度, 那么我们总可以将其归一化得到不变分布

$$\frac{\pi_i}{\sum_{k \in E} \pi_k}, \quad i \in E$$

注2. 设 π 为不变分布, 如果 $X_0 \sim \pi$, 那么

$$(X_0, X_1, \dots, X_n) \stackrel{d}{=} (X_m, X_{m+1}, \dots, X_{m+n}), \quad \forall n, m \geq 1. \quad (4.6)$$

满足(4.6)的随机过程称为平稳过程 (Stationary Process), 即任何时刻 m 作为起点, 相同时间间隔 n 随机过程的有限维分布都是相同的。因此不变分布 π 也被称为平稳分布 (Stationary Distribution).

注3. 若 E 是有限的, 把 π 视为行向量, 不变分布 π 就是矩阵 \mathbf{P} 的特征值为 1 的左特征向量, 于是我们可以通过解线性方程组

$$\pi = \pi P$$

来求不变分布。

注4. 一般而言, Markov链可以没有不变分布, 例如一维简单随机游动 (思考); 也可以有多个不变分布, 例如以单位矩阵为转移矩阵的Markov链, 或者一个非平凡的例子: 转移矩阵为

$$P = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

的Markov链, 它的不变分布为

$$\left(\frac{\alpha}{2}, \frac{\alpha}{2}, \frac{\beta}{2}, \frac{\beta}{2} \right), \quad \alpha, \beta \geq 0, \alpha + \beta = 1$$

有无穷多个。

Example 4.9 (两状态的Markov链 II)

考虑状态空间为 $\{0, 1\}$, 转移矩阵为

$$P = \begin{pmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{pmatrix}$$

的Markov链, 它的不变分布 π 满足:

$$\pi_0(1 - \alpha) + \pi_1\beta = \pi_0$$

$$\pi_0\alpha + \pi_1(1 - \beta) = \pi_1$$

结合 $\pi_0 + \pi_1 = 1$, 可以解得

$$\pi_0 = \frac{\beta}{\alpha + \beta}, \pi_1 = \frac{\alpha}{\alpha + \beta}.$$

回顾转移概率的极限:

$$\lim_{n \rightarrow \infty} P^{(n)} = \frac{1}{\alpha + \beta} \begin{pmatrix} \beta & \alpha \\ \beta & \alpha \end{pmatrix} = \begin{pmatrix} \pi & \pi \\ \pi & \pi \end{pmatrix}.$$

和不变分布之间有什么关系呢?