

第1章 引论

1.1 引言

1.1.2 有限维分布和数字特征

知道了分布函数 $F_X(x) = P\{X \leq x\}$ 就能了解随机变量 X 。类似地,对随机过程 $\{X(t), t \in T\}$ 定义 $F_X(t) = P\{X(t) \leq x\}$ 为过程的一维分布, $X(t)$ 的期望 $E[X(t)]$ 为过程的均值函数, 记作 $\mu_X(t)$, 而 $\text{Var}\{X(t)\}$ 则被定义为过程的方差函数。不仅如此, 我们还需要了解随机变量 $X(t_1)$ 与 $X(t_2)$ 的联合分布 $P\{X(t_1) \leq x_1, X(t_2) \leq x_2\}$, 这也就是过程在 t_1, t_2 两个不同时刻的联合二维分布, 记作 $F_{X_1, X_2}(x_1, x_2)$, 数字特征 $E\{X(t_1)X(t_2)\}$ 和 $\text{Cov}\{X(t_1), X(t_2)\} = E\{[X(t_1) - \mu_X(t_1)][X(t_2) - \mu_X(t_2)]\}$ 称为过程的相关函数和协方差函数, 分别记为 $r_X(t_1, t_2)$ 和 $R_X(t_1, t_2)$ 。显然自相关函数和协方差函数有对称性, 即对任何 s, t 有 $r_X(t_1, t_2) = r_X(t_2, t_1)$ 和 $R_X(t_1, t_2) = R_X(t_2, t_1)$ 。当 $t_1 = t_2 = t$ 时, $R_X(t, t) = \text{Var}\{X(t)\}$, 容易证明自相关函数和协方差函数是非负的, 以协方差函数为例, 即对任何 $t_1, t_2, \dots, t_n \in T$

$$\sum_{i=1}^n \sum_{j=1}^n b_i b_j R_X(t_i, t_j) \geq 0. \quad (1.1)$$

知 (1.1) 成立, 故它是非负的。进而我们定义随机过程的有限维分布族, 它是 $F_{X_1, X_2, \dots, X_n}(x_1, \dots, x_n), t_1, \dots, t_n \in T$ 全体, 其中

$$F_{X_1, X_2, \dots, X_n}(x_1, \dots, x_n) = P\{X(t_1) \leq x_1, \dots, X(t_n) \leq x_n\}. \quad (1.2)$$

知道了随机过程的有限维分布族就知道过程 $\{X(t), t \in T\}$ 中任意 n 个随机变量的联合分布, 也就完全了解了这些变量之间的相互依赖关系。有限维分布也有对称性: 它与变量 $X(t_1), \dots, X(t_n)$ 的排序无关。对 $\{1, \dots, n\}$ 的任一置换 (i_1, \dots, i_n) 有

$$F_{X_{i_1}, \dots, X_{i_n}}(x_{i_1}, \dots, x_{i_n}) = F_{X_1, \dots, X_n}(x_1, \dots, x_n).$$

有限维分布还有相容性, 意思是当某些 $n \rightarrow \infty$ 时高维分布的边缘分布与相应的低维分布是一致的, 也即对 $m < n$ 有

$$F_{X_1, \dots, X_n}(x_1, \dots, x_m, \infty, \dots, \infty) = F_{X_1, \dots, X_m}(x_1, \dots, x_m).$$

有趣的是, 若一族给定的分布函数有上述对称性和相容性则保证了存在一个随机过程 $\{X(t), t \in T\}$, 使它的有限维分布族正好就是给定的分布函数族。这是 1931 年由 Kolmogorov 证明的相容性基本定理。

1.1.3 平稳过程和独立增量过程

如果两个随机变量 X_1, X_2 的分布函数 $F_{X_1}(x)$ 与 $F_{X_2}(x)$ 对任何 x 都是相等的, 则称它们是同分布的, 记作 $X_1 \stackrel{D}{=} X_2$ 。类似地, 如果一个随机向量 $X = (X_1, \dots, X_n)$ 与另一随机向量 $Y = (Y_1, \dots, Y_n)$ 有相同的联合分布, 则称它们也是同分布的, 记作 $X \stackrel{D}{=} Y$ 。有一类重要的随机过程, 它处于某种概率平衡状态, 其主要性质只与变量 t 有关。如果随机过程 $X(t)$ 对任意的 $t_1, \dots, t_n \in T$ 和任何 h 有

$$X(t_1 + h), \dots, X(t_n + h) \stackrel{D}{=} X(t_1), \dots, X(t_n), \quad (1.3)$$

则称为严格平稳的。

定义 1.3 如果随机过程的所有二阶矩存在并有 $E\{X(t)\} = m$ 及协方差函数 $R_X(t, s)$ 只与时间差 $t - s$ 有关, 则称为宽平稳的或二阶矩平稳的。

对于宽平稳过程, 由于对 $-\infty < s, t < \infty, R_X(s, t) = R_X(t, s)$, 所以可以记为 $R_X(t)$ 。显然对所有的 $t, R_X(-t) = R_X(t)$, 即为偶函数, 所以 $R_X(t)$ 的图形是关于坐标轴对称的, 其在 $t=0$ 点的值 $R_X(0)$ 就是过程的方差函数, 即 $R_X(0) = \text{Var}\{X(t)$ 。严格平稳和宽平稳不互推。当二阶矩存在时严格平稳 \Rightarrow 宽平稳, 当正态时宽平稳 \Rightarrow 严格平稳。

定义 1.4 如果对任意的 $t_1 < t_2 < \dots < t_n, t_1, \dots, t_n \in T$, 随机变量 $X(t_2) - X(t_1), X(t_3) - X(t_2), \dots, X(t_n) - X(t_{n-1})$ 是相互独立的, 则 $X(t)$ 称为独立增量过程。如果进一步对任意的 $t_1, t_2, X(t_1 + h) - X(t_1) \stackrel{D}{=} X(t_2 + h) - X(t_2)$, 则过程称为有平稳独立增量的过程。

可以证明有平稳独立增量过程的均值函数一定是 t 的线性函数。我们以后要介绍 Poisson 过程和 Brown 运动都是这类过程。这两类过程是过程理论中的两块

例 1.10 设 $Z_n, n = 0, 1, 2, \dots$, 是一串独立同分布的随机变量, 定义 $X_n = \sum_{i=0}^n Z_i$, 则过程 $\{X_n, n \geq 0\}$ 就是独立增量过程。一般称 X_n 为独立和。

1.2 条件期望和矩母函数

1.2.1 条件期望

极限总是存在。相应地, 定义给定 $Y = y$ 时, X 的条件分布函数为

$$P\{X \leq x | Y = y\} = \lim_{\Delta y \rightarrow 0} P\{X \leq x | Y \in \Delta y\}, \quad (1.7)$$

记作 $F(x|y)$ 。进一步, 如果存在一非负函数 (记为) $f(x|y)$, 使得对任何集合 A 恒有

$$P\{X \in A | Y = y\} = \int_A f(x|y) dx, \quad (1.8)$$

且 $\int f(x|y) dx = 1$, 则 $f(x|y)$ 称为在给定 $Y = y$ 时 X 的条件密度。不难看出条件分布函数是关于条件密度对变量 x 从 $-\infty$ 到 $+\infty$ 的积分, 即

$$F(x|y) = \int_{-\infty}^x f(x|y) dx. \quad (1.9)$$

如果把 X 与 Y 的联合密度 $f(x, y)$ 看作质量为 1 的平板的 (面) 密度, 则条件密度 $f(x|y)$ 就是固定 $Y = y$ 时的线密度。它们之间的关系是

$$f(x|y) = f(x, y) / f(y), \quad (1.10)$$

其中 $f(y)$ 为随机变量 Y 的边缘密度。此时, 给定 $Y = y$, X 的条件期望定义为

$$E\{X | Y = y\} = \int x f(x|y) dx. \quad (1.11)$$

(1.6) 式与 (1.11) 式本质上是一回事, 在更深一点的课程中人们把它们统一记为

$$E\{X | Y = y\} = \int x f(x|y) dy. \quad (1.12)$$

条件期望有些重要的性质我们总结为下面的命题。

命题 1.1 (a) 若 X 与 Y 独立, 则 $E\{X | Y = y\} = EX$, (b) 条件期望有所谓的平滑性:

$$EX = \int E\{X | Y = y\} dF_Y(y) = E[E\{X | Y\}]. \quad (1.14)$$

(c) 对随机变量 X, Y 的函数 $\phi(X, Y)$ 恒有

$$E\{\phi(X, Y) | Y = y\} = E\{\phi(X, y) | Y = y\}. \quad (1.15)$$

1.2.2 矩母函数及生成函数

定义 1.5 随机变量 X 的矩母函数定义为随机变量 $\exp\{tX\}$ 的期望, 记作 $g(t)$, 即

$$g(t) = E\{\exp\{tX\}\} = \int \exp\{tx\} dF(x). \quad (1.17)$$

矩母函数刻画了随机变量的许多特征, 是研究它们特性的重要工具。当矩母函数存在时, 它唯一地确定了 X 的分布。通过 $g(t)$ 可以求出 X 的各阶矩, 即有

$$E\{X^n\} = g^{(n)}(0), \quad n \geq 1, \quad (1.18)$$

其中 $g^{(n)}(t)$ 是 $g(t)$ 的 n 阶导数在 t 的取值。通过在积分号下求导容易得到 (1.18) 式的证明。对相互独立的随机变量 X 和 Y , 它们的矩母函数就等于于其矩母函数的积:

$$g_{X+Y}(t) = g_X(t)g_Y(t). \quad (1.19)$$

如果随机变量 Y 等于一串独立随机变量 X_1, X_2, \dots, X_N 的和, 且下标 N 也是一个整数随机变量, 则 Y 是随机变量的随机和。这在实际问题中常常会遇到。

例 1.12 随机和的矩母函数。记 X_1, X_2, \dots 为一串独立同分布的随机变量, N 为非负整数随机变量且与 X 序列相独立, Y 为随机和 $Y = \sum_{i=1}^N X_i$, 求 Y 的矩母函数 $g_Y(t)$ 。

解 为求 g_Y , 先解条件期望

$$E\{Y^N | N = n\} = E\left\{\exp\left\{t \sum_{i=1}^n X_i\right\} \middle| N = n\right\} = E\left\{\exp\left\{t \sum_{i=1}^n X_i\right\} \middle| N = n\right\} = [g_X(t)]^n.$$

于是有 $g_Y(t) = E\{\exp\{tY\}\} = E\{E[\exp\{tY\} | N]\} = E\{[g_X(t)]^N\}$ 。对 $g_Y(t)$ 关于 t 求导即有

$$g_Y'(t) = E\{N g_X(t)^{N-1} g_X'(t)\},$$

$$g_Y''(t) = E\{N(N-1) g_X(t)^{N-2} (g_X'(t))^2 + N g_X(t)^{N-1} g_X''(t)\}.$$

将 $t=0$ 代入上面两式得

$$EY = E\{N\}E\{X\} = EN \cdot EX,$$

$$EY^2 = EN \cdot \text{Var}\{X\} + E\{N^2\} \cdot E^2\{X\}, \quad (1.20)$$

$$\text{Var}\{Y\} = EN \cdot \text{Var}\{X\} + E^2\{X\} \cdot \text{Var}\{N}.$$

定义 1.6 若 X 为离散随机变量, 则期望 $E\{e^{sX}\}$ 为其概率生成函数, 记作 $\phi_X(s)$, 特别地, 若 $P\{X = k\} = p_k, k = 0, 1, 2, \dots$, 则 $\phi_X(s) = \sum_{k=0}^{\infty} p_k s^k$ 。

由定义知, $\phi_X(s)$ 是以概率 p_k 为系数的幂级数, $\phi_X(s)$ 与 X 的概率分布也是一一对应的, 而且只有 $p_0 = \phi_X(0)$ 。

$$p_k = \frac{1}{k!} \frac{d^k}{ds^k} \phi_X(s) \Big|_{s=1}, \quad k = 1, 2, \dots$$

与矩母函数的性质类似, 若 X, Y 为独立随机变量, 则它们和式的概率生成函数为

$$\phi_{X+Y}(s) = \phi_X(s)\phi_Y(s). \quad (1.22)$$

而 X 的期望及有关各阶矩也可由 $\phi_X(s)$ 关于 s 的导数在 $s=1$ 时的值求得:

$$EX = \phi_X'(s) \Big|_{s=1},$$

$$E\{X(X-1)\dots(X-r+1)\} = \frac{d^r}{ds^r} \phi_X(s) \Big|_{s=1}. \quad (1.23)$$

在随机和的情形, 若 N 为离散随机变量, 其概率生成函数为 $\phi_N(s)$, 则由 $Y = \sum_{i=1}^N X_i$ 有

$$\phi_Y(s) = E\{e^{sY}\} = E\{E\{e^{sY} | N\}\} = E\{(\phi_X(s))^N\} = \phi_N(\phi_X(s)). \quad (1.24)$$

也即 Y 的生成函数是由 N 与 X 的概率生成函数复合而成的。

1.3 收敛性

定义 1.7 设 $\{X_n, n \geq 1\}$ 是一列随机变量, 若存在随机变量 X , 使得对 $\forall \epsilon > 0$, 有

$$\lim_{n \rightarrow \infty} P\{|X_n - X| \geq \epsilon\} = 0, \quad (1.25)$$

则称随机变量序列 $\{X_n, n \geq 1\}$ 依概率收敛于 X , 记为 $X_n \xrightarrow{P} X$ 。如果事件 $\{\omega: \lim_{n \rightarrow \infty} (X_n(\omega) - X(\omega)) = 0\}$ 的概率为 1, 即

$$P\{\lim_{n \rightarrow \infty} (X_n - X) = 0\} = 1, \quad (1.26)$$

则称随机变量序列 $\{X_n, n \geq 1\}$ 几乎必然 (almost sure) 收敛于 X , 记为 $X_n \xrightarrow{a.s.} X$, 也称随机变量序列以概率 1 收敛于 X 。

定义 1.8 设随机变量 X 和 $X_n, n \geq 1$, 都有有限的二阶矩, 如果

$$\lim_{n \rightarrow \infty} E\{X_n - X\}^2 = 0, \quad (1.27)$$

则称 X_n 均方收敛于 X , 记为 $X_n \xrightarrow{L_2} X$ 。这里“均”是平均, “方”是平方。

这三种收敛性之间的关系是: 均方收敛和几乎必然收敛都蕴涵依概率收敛, 反过来不一定成立; 其次均方收敛和几乎必然收敛互不包含。

第2章 Poisson 过程

2.1 Poisson 过程

定义 2.1 一个整数取值随机过程 $\{N(t), t \geq 0\}$ 满足下述三个条件就称作强度为 $\lambda > 0$ 的 Poisson 过程:

- (i) $N(0) = 0$;
- (ii) $N(t)$ 是独立增量过程;
- (iii) 对任何 $t > 0, s \geq 0$, 增量 $N(s+t) - N(t)$ 服从参数为 λt 的 Poisson 分布, 即

$$P\{N(s+t) - N(t) = k\} = \frac{(\lambda t)^k \exp\{-\lambda t\}}{k!}, \quad k = 0, 1, \dots \quad (2.1)$$

定义的条件 (i) 告诉我们随机事件从时刻 0 开始计数, 条件 (ii) 是过程称为 Poisson 过程的直接理由, 由 Poisson 分布的性质我们马上可求出 $E\{N(t)\} = \text{Var}\{N(t)\} = \lambda t$, 增量 $N(s+t) - N(t)$ 代表时间区间 $(s, s+t)$ 中发生的随机事件数, 由条件 (ii), 这一增量的分布与 s 无关而增量具有平稳性。因此条件 (ii) 和 (iii) 充分刻画了模型所要求的两个性质, 前后的独立性与时问上的均匀性。强度 λ 有时也称为速率, 它描绘随机事件发生的频繁程度。

稀有事件的概率率那从 Poisson 分布, 这是由于当试验次数很多而每次试验成功的概率很小时, Poisson 分布可以逼近二项分布。若记 N 为试验次数, p 为成功概率, 而当 λ 很大时, Np 趋过一个常量 λ , 则 N 次试验中的总成功次数近似地服从参数为 λ 的 Poisson 分布。这一想法很自然地可以推广到随机过程的情况。记 $[0, \infty)$ 为观察过程的时间轴, 0 代表起始时刻, $N(t) - N(a)$ 代表时间区间 $(a, t]$ 上发生的事件数, 我们作如下假定:

- (1) 在不相交时间中事件发生的数目相互独立, 也即对任何整数 $n = 1, 2, \dots$, 设时标 $0 < t_1 < t_2 < \dots < t_n$, 增量 $N(t_1) - N(0), N(t_2) - N(t_1), \dots, N(t_n) - N(t_{n-1})$ 相互独立;
- (2) 对任何时刻 t 和正数 h , 随机变量 (增量) $N(t+h) - N(t)$ 的分布只依赖于区间长度 h 而不依赖于时刻 t ;
- (3) 存在正常数 λ , 当 $h \rightarrow 0$ 时, 使在长度为 h 的小区间中事件至少发生一次的概率

$$P\{N(t+h) - N(t) \geq 1\} = \lambda h + o(h),$$

(4) 在小区间 $(t, t+h)$ 发生两个或两个以上事件的概率为 $o(h)$ (可以忽略不计), 即当 $h \rightarrow 0$,

$$P\{N(t+h) - N(t) \geq 2\} = o(h).$$

从返远的观点看, (1) 说明试验是独立的, (2) 说明在每个长度相同的小区间上事件发生有相同的概率 p ; (3) 告诉我们成功 (事件发生) 概率 $p = \lambda h$, 而且 p 很小; (4) 是说明事件不发生的概率为 $1 - \lambda h \approx 1 - p$, 这正好是独立 Bernoulli 试验的模型。若观察区间为 $[0, 1]$, 则 $N = \frac{\lambda}{1}$, 所以当 $h \rightarrow 0$ 时, $N \rightarrow \infty$, 而 $Np = \lambda t$ 从而二项分布的极限是参数为 λt 的 Poisson 分布。从直观意义看, 如前所述 (1) 为前的独立性, (2) 为时间上的均匀性或齐次性; (3) 表明事件是稀有的, 而 (4) 则称为相溶性 (orderliness), 意思是事件是一件一件地发生的, 在同一瞬间同时发生多个事件的可能性很小很小, 基于这些假定我们可以证明如下结论。

命题 2.1 满足假定 (1)~(4) 的随机过程 $N(t)$ 为 Poisson 过程。

2.2 与 Poisson 过程相联系的若干分布

图 2.1 Poisson 过程的样本路径




图 2.1 中第 $n-1$ 次与第 n 次事件间的间隔时间记作 X_n , 而 $W_n = \sum_{i=1}^n X_i$ 为第 n 次事件的到达或等待时间, 我们来求 X_n 与 W_n 的分布。

命题 2.2 $X_n, n = 1, 2, \dots$ 是均值为 $\frac{1}{\lambda}$ 的独立同分布的指数随机变量, W_n 服从参数为 n 和 λ 的 Γ 分布。

的 Poisson 过程 $\{N(t), t \geq 0\}$, λ 越大表明事件平均间隔时间 $\frac{1}{\lambda}$ 越短, 事件的发生就越频繁, 强度也就越大。

给定了到时刻 t 总计发生了 n 件事, 在过去某时刻 $u < t$ 发生了 k 件事的条件概率可由问题 2 第 1 题知道是二项分布, 但人们常常对给定 $N(t) = n$ 事件发生后 W_1, \dots, W_n 的联合分布更感兴趣, 关于这一条件联合分布, 我们有如下定理。

定理 2.1 若 $N(t), t \geq 0$ 为 Poisson 过程, 则给定 $N(t) = n$ 下等待时间 W_1, \dots, W_n 的联合密度为

$$f_{W_1, \dots, W_n | N(t)=n}(\omega_1, \dots, \omega_n) = \frac{n!}{t^n}, \quad 0 < w_1 < \dots < w_n \leq t. \quad (2.6)$$

熟悉数理统计的读者马上可以看出联合密度 (2.6) 似曾相识, 若从 $[0, 1]$ 区间上的均匀分布抽取 n 个独立同分布的随机样本 U_1, \dots, U_n , 并按其大小排列成次序统计量, 记为 $U_{(1)} < U_{(2)} < \dots < U_{(n)}$, 则 $U_{(i)}, i = 1, \dots, n$ 的联合密度正好是 (2.6)。有关证明可参看陈希孺编著的《数理统计教程》, 上海科学技术出版社。

例 2.2 顾客依速率为 λ 的 Poisson 过程到达车站, 若火车在时刻 t 离站, 则在 $[0, t]$ 区间内顾客的平均等待时间是多少?

解 作为依 Poisson 过程到达的第一位顾客, 他的到达时间为 W_1 , 等到时刻 t 发车需等待 $t - W_1$, 而第 i 位顾客的等待时间为 $t - W_i$, 在 $(0, t]$ 区段总共来了 $N(t)$ 位客人, 所以总等待时间为 $\sum_{i=1}^{N(t)} (t - W_i)$, 而所要求的平均总等待时间就是

$$E\left\{\sum_{i=1}^{N(t)} (t - W_i)\right\}.$$

为求出它可以先求条件期望

$$E\left\{\sum_{i=1}^{N(t)} (t - W_i) \middle| N(t) = n\right\} = E\left\{\sum_{i=1}^n (t - W_i) \middle| N(t) = n\right\} = nt - E\left\{\sum_{i=1}^n W_i \middle| N(t) = n\right\}.$$

注意到给定 $N(t) = n, W_1, i = 1, \dots, n$ 的联合密度是 $(0, t]$ 上均匀分布中随机样本 $U_1, i = 1, \dots, n$ 的次序统计量 $U_{(i)}, i = 1, \dots, n$ 的联合密度一样的, 于是,

$$E\left\{\sum_{i=1}^n W_i \middle| N(t) = n\right\} = E\left\{\sum_{i=1}^n U_{(i)}\right\} = E\left\{\sum_{i=1}^n U_i\right\} = \frac{nt}{2}.$$

因此, 我们只需将 2.1 节中的假定 (3) 改为 (3'): $P\{N(t+h) - N(t) \geq 1\} = \lambda(t+h) + o(h)$ 就可以完全类似地证明。

命题 2.3 在 2.1 节的假定 (1), (4) 和本节假定 (3') 下过程 $N(t)$ 是参数为 $\lambda(t)$ 的非齐次 Poisson 过程, 过程增量 $N(t+h) - N(t)$ 的分布为 (2.8) 式。

例 2.3 (密度函数) 设随机变量 X_1, X_2, \dots 是一串独立同分布连续随机变量, 分布为 $F(t)$, 密度函数为 $f(t)$, 当 X_i 代表某元件的寿命时, $N(t) = j(t)$ 为 t 时刻已失效的数目, 它的直观意义是 $\lambda(t)$ 近似地等于 $P\{X_1 = t | X_1 \geq t\}$, 即元件在时刻 t 仍在工作而在下一瞬间 t 失效的条件概率密度, 记 $X_0 = 0$, 当 $X_n > \max\{X_1, \dots, X_{n-1}\}$ 时, 也就是当 X_n 为最大值时任何元件记录器在时刻 n 制了记录, X_n 则称为所制记录的记录值比 t 小的新记录的最大值记为 $N(t)$, 也即若记录值为 $N(t)$, 则第 n 次记录值在 t 时刻之前发生, 过程 $\{N(t), t \geq 0\}$ 为非齐次 Poisson 过程, 其强度函数正好是失效率 $\lambda(t)$, 比如,

因此,

$$E\left\{N\left(\sum_{i=1}^n (t - W_i) \middle| N(t) = n\right)\right\} = nt - \frac{nt^2}{2} = \frac{nt^2}{2}.$$

最后得到

$$E\left\{N\left(\sum_{i=1}^n (t - W_i)\right)\right\} = \frac{1}{2} E\{N(t)\} = \frac{\lambda t^2}{2}.$$

可以看到顾客平均总等待时间是和 t^2 成正比的, 比例因子的大小取决于 Poisson 过程的强度 λ 。

命题 3.3 如果状态 i 有周期 $d(i)$, 则存在整数 N_i 使得对所有的 $n > N_i$ 恒有 $P_{ii}^{(nd(i))} > 0$.

推论 3.1 如果 $P_{ii}^{(m)} > 0$, 则存在正整数 N 使得对 $n \geq N$ 恒有 $P_{ii}^{(m+nd(i))} > 0$.

是否存在? 存在的条件是什么? 如果存在又如何简便地求出它们? 周期性是一种等价类中全体状态共有的性质. 当周期为 1 时, Markov 链称为是非周期的. 对非周期不可约的 Markov 链我们有如下结论.

命题 3.4 令 P 为不可约, 非周期, 有限状态 Markov 链的转移概率阵, 则必存在 N , 使得当 $n \geq N$ 时, n 步转移概率阵 $P^{(n)}$ 的所有元素都非零. 这种存在 n 使 $P^{(n)}$ 的元素全部非零的 k 个状态 (记为 $0, 1, \dots, k-1$) 的 Markov 链称为是正周期的. 而最重要的事实是对一个正周期的有限状态 Markov 链, 极限 $\lim_{n \rightarrow \infty} P_{ij}^{(n)}$ 总是存在的, 记为 π_j (注意极限与初始状态 i 无关). 并且这些极限构成一概率分布, 即对 $\pi = (\pi_0, \pi_1, \dots, \pi_{k-1})$, 满足 $\pi_j > 0, j = 0, 1, \dots, k-1$, 及 $\sum_j \pi_j = 1$. 这些是一节极限定理和平稳分布所要讨论的内容.

3.2.2 常返 (recurrent) 与瞬过 (transient)
为了以下讨论的方便, 我们引入一个重要的概率 $f_{ii}^{(n)}$, 它表示从 i 出发在 n 步转移时首次到达 j 的概率. 用式子表示即是

$$f_{ii}^{(0)} = 0, \\ f_{ii}^{(n)} = P\{X_n = i, X_k \neq i, k = 1, \dots, n-1 | X_0 = i\},$$

而 $f_{ii}^{(\infty)}$ 就代表从 i 出发在第 n 次转移时首次回到状态 i 的概率. 因不曾出发就不可能有回来, 所以约定 $f_{ii}^{(0)} = 0$. 同样定义

$$f_{ij}^{(n)} = P\{X_n = i, X_k \neq i, k = 1, \dots, n-1 | X_0 = j\}.$$

记 $f_{ij} = \sum_{n=0}^{\infty} f_{ij}^{(n)}$, 它是从 i 出发最终转入状态 j 的概率. 当 $i \neq j$, 则 $i \rightarrow j$ 且仅当 $f_{ij} > 0$. 现在可以给出如下定义.

定义 3.5 如果 $f_{ii} = 1$, 我们称状态 i 是常返 (recurrent) 的, 一个非常返状态就称为瞬过 (transient) 的.

定理 3.2 状态 i 常返的充分必要条件是

$$\sum_{n=0}^{\infty} P_{ii}^{(n)} = \infty. \quad (3.8)$$

当然与此等价地, 状态 i 是瞬过的当且仅当

$$\sum_{n=0}^{\infty} P_{ii}^{(n)} < \infty. \quad (3.9)$$

推论 3.2 如果 i 是常返的, 且 $i \rightarrow j$, 则 j 也是常返的. 对常返状态 i , 我们定义 T_i 为首次返回状态 i 的时刻, 称作常返时. 记 $\mu_i = ET_i$, 则有

$$\mu_i = \sum_{n=1}^{\infty} n f_{ii}^{(n)}. \quad (3.10)$$

回想 $f_{ii}^{(n)}$ 代表从 i 出发在第 n 步转移时首次回到 i 的概率, 所以 μ_i 是首次返回 i 的期望步数, 也叫状态 i 的平均常返时. 利用 μ_i 可以对常返状态作进一步的分类, 分为常返常和非常返.

定义 3.6 一个常返状态 i 当且仅当 $\mu_i = \infty$ 时称为常返的, 而当且仅当 $\mu_i < \infty$ 时称为非常返的.

对于只有有限个状态的 Markov 链, μ_i 总是有限的, 所以只有在有可列无穷多个状态时才有可能出现非常返的状态 (参看习题 3 第 15 题). 当状态数目不大时直接

3.3 Markov 链的极限定理与平稳分布

在上节有关 Markov 链状态分类的讨论中已经引进了常返状态 i 的常返时 T_i , 它还可记为

$$T_i = \min\{n \geq 1: X_n = i\},$$

$$f_{ii}^{(n)} = P\{X_n = i, X_k \neq i, k = 1, \dots, n-1 | X_0 = i\} \\ = P\{T_i = n | X_0 = i\}, \quad n = 1, 2, \dots$$

表示了 T_i 的条件概率分布, $\mu_i = \sum_{n=1}^{\infty} n f_{ii}^{(n)}$ 则为 T_i 在给定 $X_0 = i$ 时的条件期望.

定理 3.3 Markov 链的基本极限定理
(a) 若状态 i 是瞬过的或者是常返的, 则

$$\lim_{n \rightarrow \infty} P_{ii}^{(n)} = 0. \quad (3.11)$$

(b) 若状态 i 是周期为 d 的常返状态, 则

$$\lim_{n \rightarrow \infty} P_{ii}^{(n)} = \frac{d}{\mu_i}. \quad (3.12)$$

(c) 当状态 i 是非周期的常返状态, 则

$$\lim_{n \rightarrow \infty} P_{ii}^{(n)} = \frac{1}{\mu_i}. \quad (3.13)$$

一个正常返非周期的状态也称作是遍历的 (ergodic). 定理 3.3(c) 告诉我们对遍历状态 i 有 $\lim_{n \rightarrow \infty} P_{ii}^{(n)} = \frac{1}{\mu_i}$, 其中 μ_i 是常返时的期望.

推论 3.3 如果状态 i 是遍历的, 则对所有的 $i \rightarrow j$ 有

$$\lim_{n \rightarrow \infty} P_{ij}^{(n)} = \lim_{n \rightarrow \infty} P_{ji}^{(n)} = \frac{1}{\mu_j}.$$

定义 3.7 Markov 链有转移概率阵 $P = (P_{ij})$, 一个概率分布 $\{\pi_i, i \geq 0\}$ 如果满足 $\pi_j = \sum_{i=0}^{\infty} \pi_i P_{ij}$, 则称为这一 Markov 链的平稳分布.

很容易看出, 如果过程的状态 X_0 有平稳概率分布 $\pi = (\pi_j, j \geq 0)$, 则有 $P(X_1 = j) = \sum_{i=0}^{\infty} P\{X_1 = j | X_0 = i\} P(X_0 = i) = \sum_{i=0}^{\infty} \pi_i P_{ij} = \pi_j$.

并由归纳法可得

$$P(X_n = j) = \sum_{i=0}^{\infty} P\{X_n = j | X_{n-1} = i\} P\{X_{n-1} = i\} = \sum_{i=0}^{\infty} \pi_i P_{ij} = \pi_j.$$

于是对所有的 n, X_n 有相同的分布. 再加上 Markov 性, 即可知对任何 $k \geq 0, X_0, X_{n+1}, \dots, X_{n+k}$ 联合分布不依赖于 n . 这就是说, $\{X_n, n \geq 0\}$ 作为随机过程是平

稳的, 平稳分布 π 由此得名. 有了这一概念我们可以讨论重要的定理.

定理 3.4 若一个不可约 Markov 链中的所有状态都是遍历的, 则对所有 i, j , 极限 $\lim_{n \rightarrow \infty} P_{ij}^{(n)} = \pi_j$ 存在且在 $\pi = (\pi_j, j \geq 0)$ 为平稳分布, 也即

$$\sum_{j=0}^{\infty} \pi_j = 1, \quad \pi_j > 0, \quad (3.15) \\ \sum_{i=0}^{\infty} \pi_i P_{ij} = \pi_j. \quad (3.16)$$

反之, 若一个不可约 Markov 链存在一个平稳分布, 即满足 (3.15) 式及 (3.16) 式, 且这个 Markov 链的所有状态都是遍历的, 则该平稳分布就是这个 Markov 链的极限分布, 即对任何 i 有

$$\lim_{n \rightarrow \infty} P_{ii}^{(n)} = \pi_j. \quad (3.17)$$

在实际应用中 $\{\pi_j\}$ 有两种解释: 如果作为 $P_{ij}^{(n)}$ 的极限分布, 它告诉我们在过程的长期运行中不论初始状态 i 是什么, 经过一段时期后发现过程处于状态 j 的概率就是 π_j . 另一解释是 π_j 也代表了就长期而言过程访问 j 的次数在总时间中的平均比例或比重. 这可以从下面的推理中看出. 设

且仅当 $p = q = \frac{1}{2}$. 于是有当 $p = \frac{1}{2}$ 时 $\sum_{n=1}^{\infty} P_{ii}^{(n)} = \infty$. 因此直线上的对称随机游动

是常返的. 显然, 当 $p \neq q$ 过程的状态是瞬过的. 有趣的是, 可以证明二维对称随机游动也是常返的, 而三维以上的对称随机游动却是瞬过的. 具体证明留作练习 (习题 3 第 13 题).

注推, 假设 i 是常返状态, 则 i 为非常返的一个充要条件: $\lim_{n \rightarrow \infty} P_{ii}^{(n)} = 0$, 非常返和正常返是一个等价命题类共有的性质.

定理 3.1 $i \rightarrow j$ 且 j 可约 i .
15. 考虑一有限状态 Markov 链. 试证明
(a) 至少有一个状态是常返的.
(b) 任何常返状态必定是正常返的.

第 4 章 平稳过程

4.1 定义和例子

以下设 T 为具有如下性质 T 的下标集合: 若 $t_1, t_2 \in T$, 则 $t_1 + t_2 \in T$. 通常 T 取如下几种集合之一:

- (i) $T = \{0, 1, 2, \dots\}$;
- (ii) $T = \{0, \pm 1, \pm 2, \dots\}$;
- (iii) $T = \{t: t \geq 0\}$;
- (iv) $T = \{t: t \leq 0\}$.

直观上, 下标集合可以理解为时间 (当然, T 也可以表示空间位置或其他).

定义 4.1 设 $X = \{X(t), t \in T\}$ 为随机过程, 若对任意正整数 k 及 T 中任意 k 个时刻 $t_1 < t_2 < \dots < t_k$, 及 T 中的 h , 有

$$\{X(t_1), \dots, X(t_k)\} \stackrel{d}{=} \{X(t_1+h), \dots, X(t_k+h)\}, \quad (4.1)$$

则随机过程 X 称为严平稳过程. 这里 “ d ” 表示等式两边 k 维随机向量的分布相同.

注 4.1 如果 $T = \{0, \pm 1, \dots\}$, 我们一般把 X 称为随机序列. 如果 X 还是平稳的, 则称为平稳序列. 以下不再一一说明.

设 $X = \{X(t), t \in T\}$ 为严平稳过程. 由定义如果均值函数 $m(t) = EX(t)$ 存在, 则必为常数, 即 $m(t) = m, t \in T$. 同样, 如果方差函数存在, 则 $\text{Var}(X(t)) = EX(t) - m)^2$ 也是一个常数. 记为 σ^2 . 设 X, Y (不妨设 $\sigma < 0$), 由平稳性, 其协方差函数

$$E(X(t) - m)(X(t+s) - m) = E(X(t-s) - m)(X(t) - m),$$

等式右端只依赖于时间差 $t-s$. 若记

$$R(t) = E(X(t) - m)(X(0) - m),$$

$$E(X(t+h) - m)(X(t) - m) = R(h),$$

即协方差函数仅与时间差有关, 而与起点无关. 当然, 由定义知 $\text{Var}(X(t)) = R(0)$. 此外, 易知 $r(\tau) = EX(t)(X(t+\tau))$ 与起点 t 无关. 我们分别称 $r(\tau)$ 和

$$\rho(\tau) = R(\tau)/R(0) = r(\tau)/R(0)$$

为平稳过程 X 的自相关函数和标准自相关函数. 由概率论中相关性性质易知 $|\rho(0)| = 1$ 及 $|\rho(\tau)| \leq 1$.

定义 4.2 设 $X = \{X(t), t \in T\}$ 为一实值随机过程, 如果对 $\forall t \in T, EX(t) < \infty, EX(t) = m$ 以及协方差函数 $E(X(t) - m)(X(s) - m)$ 仅与 $t-s$ 有关, 则称 X 为宽平稳随机过程. 一般说来, 这两个过程是互不包含的, 即严平稳由于不一定有二阶矩而不一定是宽平稳; 反之, 宽平稳由于其有限维联合分布可能不满足 (4.1) 式而不一定是严平稳. 但只要过程有二阶矩存在, 则严平稳过程一定是宽平稳过程.

例 4 设 Z 为非零随机变量, 考虑如下两个随机过程: $X = \{X(t) = tZ, t \in T\}, Y = \{Y(t) = Z, t \in T\}$. 试考察这两个随机过程的平稳性.

解 对随机过程 Y 而言, 由于在时刻 t 的取值与 t 无关, 故必然是严平稳的. 如果 $EZ^2 < \infty$, 则 Y 也是宽平稳的. 至于随机过程 X , 由于其一维分布与 t 有关, 所以必然不是严平稳的. 其次, 即使 $EZ^2 < \infty$, 如果 $EZ \neq 0$, 则 $EX(t) = tEZ$ 与 t 有关, 因此不是宽平稳. 如果 $EZ = 0$, 由于 $EX(t)X(s) = tEZ^2$ 与 t, s 有关, 故仍不是宽平稳的.

定义 4.3 设 $G = \{G(t, \tau), -\infty < t < \infty, \tau \in T\}$ 为一随机过程, 如果对任一正整数 k 以及 k 个时刻 $t_1 \leq t_2 \leq \dots \leq t_k, (G(t_1), G(t_2), \dots, G(t_k))$ 的联合分布为 k 维正态分布, 则称 G 为高斯(Gauss)过程.

我们知道, k 维正态分布完全由协方差矩阵和均值向量所唯一确定, 而这些量仅与它们的二阶矩有关, 所以对 Gauss 过程而言, 两个平稳的定义是等价的. 以下主要研究宽平稳过程. 为方便起见, 我们称宽平稳过程为平稳过程.

定义 4.4 设 $X = \{X(t), t \in T\}$ 为平稳过程, 如果在存在常数 λ 使

$$X(t+\pi) = X(t),$$

则 X 称为周期平稳过程, π 为过程的周期. 如果 X 是周期平稳过程, 则其协方差函数也是周期函数, 且与过程有相同的周期. 这是由于

还可以考虑复平稳过程. 其定义与定义 4.2 类似, 差别是一把 $X(t)$ 改为复值, 二是把协方差函数定义为 $E(X(t) - m)(\overline{X(s) - m})$, 这里 \overline{X} 表示 X 的共轭.

4.2 遍历性定理

定义 4.5 设 $X = \{X(t), -\infty < t < \infty\}$ 为一平稳过程(或序列), 若

$$\overline{X} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T X(t) dt \stackrel{a.s.}{=} m \quad (4.6)$$

或

$$\overline{X} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{k=-N}^N X(k) \stackrel{a.s.}{=} m, \quad (4.7)$$

则称 X 的均值有遍历性. 如果

$$\overline{R}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T (X(t) - m)(X(t+\tau) - m) dt \stackrel{a.s.}{=} R(\tau) \quad (4.8)$$

或

$$\overline{R}(\tau) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{k=-N}^N (X(k+\tau) - m)(X(k) - m) \stackrel{a.s.}{=} R(\tau), \quad (4.9)$$

则称 X 的协方差函数有遍历性. 若随机过程(或序列)的均值和协方差函数都有遍历性, 则称此随机过程有遍历性.

注意, 我们这里的遍历性是定义 1.8 中的均方极限, 以 (4.6) 式为例, 即

$$E\left(\frac{1}{2T} \int_{-T}^T X(t) dt - m\right)^2 \rightarrow 0 \quad (T \rightarrow \infty)$$

遍历性又称各态历经性. 直观上可以这样理解: 考虑只有有限个状态的平稳序列关于遍历性的定义式 (4.6) ~ (4.9). 当只取非常实数 (非非整数次) 时, 相应的积分和求和就限制在 $[0, \infty)$ 上. 例如, 相应于 (4.6) 式及 (4.7) 式的定义改为

$$\overline{X} = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T X(t) dt \stackrel{a.s.}{=} m \quad (4.10)$$

或

$$\overline{X} = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^N X(k) \stackrel{a.s.}{=} m. \quad (4.11)$$

定理 4.1 (均值遍历性定理)
(i) 设 $X = \{X_n, n = 0, \pm 1, \dots\}$ 为平稳序列, 其协方差函数为 $R(\tau)$, 则 X 有遍历性的充分必要条件是

$$\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{\tau=0}^{N-1} R(\tau) = 0.$$

(ii) 若 $X = \{X(t), -\infty < t < \infty\}$ 为平稳过程, 则 X 有遍历性的充分必要条件是

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T (1 - \frac{\tau}{T}) R(\tau) d\tau = 0.$$

推论 4.1 若 $\sum_{\tau=0}^{\infty} |R(\tau)| < \infty$, 则均值遍历性成立.

推论 4.2 对平稳序列而言, 若 $(R(\tau) - 0)(\tau \rightarrow \infty)$, 则均值遍历性成立.

定理 4.2 (协方差函数遍历性定理) 设 $X = \{X(t), -\infty < t < \infty\}$ 为平稳过程, $Y_t = \{Y(t), -\infty < t < \infty\}$ 其中 Y_t 由上面所定义, 则对给定的 τ, X 的协方差函数 $R(\tau)$ 有遍历性的充分必要条件是

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T (1 - \frac{\tau}{T}) (R(\tau_1) - R^2(\tau)) d\tau_1 = 0,$$

其中

$$R(\tau_1) = EX(t+\tau+\tau_1)X(t+\tau)X(t+\tau)X(t).$$

对于定义在 $[0, \infty)$ 上的平稳过程, 只要把遍历性理解为 (4.10), (4.11) 等式. 定理 4.1 和定理 4.2 仍成立.

定理 4.3 设 $X = \{X_n, n = 0, \pm 1, \dots\}$ 是均值为 0 的 Gauss 平稳过程, 如果

$$\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} R^2(k) = 0,$$

则 Gauss 过程的协方差函数有遍历性.

4.3 平稳过程的协方差函数和功率谱密度

4.3.1 协方差函数
对平稳过程 X 的协方差函数 $R(\tau)$, 容易由定义得到如下性质:

1. 对称性, 即 $R(-\tau) = R(\tau)$.
2. 有界性, 即 $|R(\tau)| \leq R(0)$.
3. 非负定性, 即对任意的时刻 t_k 及实数 $a_n, n = 1, 2, \dots, N$, 有

$$\sum_{n=1}^N \sum_{m=1}^N a_n a_m R(t_n - t_m) \geq 0.$$

4.3.2 功率谱密度
下面我们吧平均功率谱密度的概念推广到平稳过程 $X = \{X(t), -\infty < t < \infty\}$. 为此, 对每条样本轨道, 根据 (4.21) 式和 (4.24) 式 (设 $S(\omega)$ 存在), 则有

$$F(\omega) = \int_{-T}^T X(t) e^{-j\omega t} dt \quad (4.25)$$

和

$$\frac{1}{2T} \int_{-T}^T X^2(t) dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} |F(\omega)|^2 d\omega. \quad (4.26)$$

注意, (4.25) 和 (4.26) 两式中的量都是随机变量, 所以有意义的是它们的平均值. 我们把过程 X 的平均功率谱密度定义为 (如果极限存在的话)

$$S(\omega) = \lim_{T \rightarrow \infty} \frac{1}{2T} E|F(\omega, T)|^2.$$

如果把 $-\omega$ 处的谱密度加到 ω 处, 便谱密度只在正实轴上有定义, 则称为平均功率谱密度或单边谱密度. 如用 $G(\omega)$ 表示平均谱密度, 则

$$G(\omega) = \begin{cases} \lim_{T \rightarrow \infty} \frac{1}{2T} E|F(\omega, T)|^2, & \omega \geq 0, \\ 0, & \omega < 0, \end{cases}$$

$$= \begin{cases} 2S(\omega), & \omega \geq 0, \\ 0, & \omega < 0. \end{cases} \quad (4.32)$$

由 $S(\omega)$ 的定义可知

$$S(\omega) = S(\omega) \geq 0, \quad S(-\omega) = S(\omega).$$

这是因为 $|F(\omega, T)|^2 = F(\omega, T) \overline{F(-\omega, T)}$ 为实的, 非负偶函数. 其次, 由 (4.27) 定义的平均功率谱密度 $S(\omega)$ 和协方差函数 $R(\tau)$ (假定平稳过程的均值为零) 是一对 Fourier 变换. 一般由 (4.27) 定义的平均功率谱密度 $S(\omega)$ 和自相关函数 $r(\tau)$ 也是一对 Fourier 变换. 更具体地, 我们有如下定理.

定理 4.4 (Wiener-Khinchine 公式) 假定 $EX(t) = 0$, 且 $\int |R(\tau)| d\tau < \infty$, 则

$$S(\omega) = \int_{-\infty}^{\infty} R(\tau) e^{-j\omega\tau} d\tau, \quad (4.33)$$

注 4.2 由于 $R(\tau)$ 和 $S(\omega)$ 都是偶函数, 故 Wiener-Khinchine 公式还可以写为偶 Fourier 变换形式:

$$S(\omega) = 2 \int_0^{\infty} R(\tau) \cos \omega\tau d\tau, \quad (4.35)$$

$$R(\tau) = \frac{1}{2\pi} \int_{-\infty}^{\infty} S(\omega) e^{j\omega\tau} d\omega. \quad (4.34)$$

$$S(\omega) = 2 \int_0^{\infty} R(\tau) \cos \omega\tau d\tau, \quad (4.35)$$

$$R(\tau) = \frac{1}{2\pi} \int_{-\infty}^{\infty} S(\omega) \cos \omega\tau d\omega. \quad (4.36)$$

对平稳序列来说, 设 $R(\tau), \tau = 0, \pm 1, \pm 2, \dots$, 为其协方差函数, 且 $\sum |R(\tau)| < \infty$, $S(\omega)$ 为对应的谱密度 (即在 (4.25) 式中把积分号改为求和, 然后由 (4.27) 得到的平均功率谱密度), 则对应于 (4.37) 式和 (4.38) 式的 Wiener-Khinchine 公式为

$$S(\omega) = \sum_{\tau=-\infty}^{\infty} e^{-j\omega\tau} R(\tau), \quad (4.37)$$

$$R(\tau) = \frac{1}{2\pi} \int_{-\infty}^{\infty} S(\omega) \cos \omega\tau d\omega. \quad (4.38)$$

注 4.3 在 $EX(t) = m$ 时, 由 (4.27) 定义的平均功率谱密度和自相关函数是一 Fourier 变换, 即

$$S(\omega) = \int_{-\infty}^{\infty} r(\tau) e^{-j\omega\tau} d\tau, \\ r(\tau) = \frac{1}{2\pi} \int_{-\infty}^{\infty} S(\omega) e^{j\omega\tau} d\omega.$$

为方便起见, 以下我们总假定 $EX(t) =$