

应用随机过程

李育强 编著

2018年7月

This page intentionally left blank

前言

《随机过程》作为一门大学课程以介绍研究复杂随机现象的若干理论、方法与应用为主要内容, 长期以来作为专业课程和研究类课程在数学相关专业的高年级和一些工程专业的研究生阶段开设。然而, 随着社会与科技的发展, 该课程被越来越多的学科了解与重视, 开设该课程的专业越来越多, 开设的时间也被提前到大学二、三年级。在这种背景下, 在保留课程特色与精华的同时降低学习门槛成为该课程教学中需要面对的挑战。迎接这一挑战的首要任务就是选择或编写一本适当的教材, 使得教学内容不依赖于高深的数学知识, 同时又能以这些教学内容为载体, 系统且不失严谨地介绍随机过程的基本思想、方法、理论与应用。这本《应用随机过程》就是笔者在多年的教学过程中不断尝试与探索的总结。

本书共七章, 第一章简要地回顾并补充了初等概率论的部分内容。第二章除了介绍随机过程的基本概念外, 为了让读者能对随机过程所讨论问题, 所涉及的思想和方法以及其相关应用形成初步的认识和了解, 我们还展开介绍了直线上简单随机游动和泊松过程这两类最基本的随机模型。此后我们分别简要地介绍了离散状态马氏链(第三、四章)、更新过程(第五章)、布朗运动(第六章)与离散时间鞅(第七章)的理论、方法与应用。本书设定读者具有高等数学, 线性代数和概率论与数理统计等数学基础。在内容选择与展开时, 在保证内容自洽的前提下我们避免使用较深奥的数学概念与工具, 因此凡具备上述三门课程知识的读者都可阅读本书。

根据笔者经验, 全部讲完本书内容需要54 – 72个学时。对于短学时的课程, 建议依据教学目标与学生基础的不同, 选择教学内容。为了便于学习和理解随机过程的各种理论及其应用, 本书包含大大小小近120个例子, 其中许多例子具有明确的应用背景。笔者仍然希望本书读者能把阅读重点放在对随机模型的理论与方法的理解与学习上。既要理解它们背后的思想与逻辑, 也要学习他们背后的技巧, 并通过完成每章节后的练习加深理解(带*的内容与练习, 初学者可略过)。

本书初稿在华东师范大学统计学院的统计学与金融工程学专业反复试用过多次, 收到许多反馈意见。在此对这些专业的同学表示衷心的感谢。由于编者水平有限, 错误之处在所难免, 恳请广大读者批评指正。

李育强

2018年6月30日

2

目录

第一章	预备知识	1
1.1	概率论简述	1
1.1.1	样本空间, 随机事件与概率	1
1.1.2	单个随机变量及相关刻画	2
1.1.3	有限多个随机变量	4
1.2	条件数学期望	10
1.2.1	随机事件下的条件分布与均值	10
1.2.2	随机变量下的条件数学期望	11
1.2.3	条件数学期望的推广与一般化	15
1.3	特征函数、拉普拉斯变换与母函数	21
1.3.1	特征函数	21
1.3.2	拉普拉斯变换	22
1.3.3	母函数	24
1.4	收敛性与极限定理	27
1.4.1	三类收敛的定义和极限定理	27
1.4.2	Borel-Cantelli 引理	28
1.4.3	柯西基本列*	31
1.4.4	收敛的简单性质	32
第二章	随机过程概述	37
2.1	随机过程简介	37
2.1.1	随机过程的基本概念	37
2.1.2	随机过程的刻画	39
2.1.3	典型随机过程举例	41
2.2	直线上简单随机游动	45
2.2.1	模型及其刻画	45
2.2.2	基本性质	47
2.2.3	应用举例	52
2.3	泊松(Poisson)过程	55
2.3.1	计数过程	55
2.3.2	泊松过程及其刻画	56
2.3.3	到达时间的条件分布	61
2.3.4	稀疏过程	63
2.3.5	非齐次泊松过程	65
第三章	离散时间马氏链	71
3.1	马氏链的定义与举例	71
3.1.1	条件独立与马氏链	71
3.1.2	马氏链的等价刻画	73
3.1.3	转移概率矩阵与C-K方程	75
3.1.4	有限维分布	78

3.2	状态分类.....	81
3.2.1	互通、本质与不可约	81
3.2.2	周期性	82
3.2.3	常返与非常返	84
3.3	首访概率与时间.....	90
3.3.1	访问概率与分布	90
3.3.2	平均访问时间	95
3.4	转移概率极限与平稳分布	100
3.4.1	正常返, 零常返与转移概率极限	100
3.4.2	平稳分布	103
第四章	马氏链的一些简单应用	111
4.1	存储与排队模型	111
4.1.1	存储模型	111
4.1.2	排队模型	114
4.2	可逆马氏链与蒙特卡罗模拟	120
4.2.1	可逆马氏链	120
4.2.2	马氏链蒙特卡罗(MCMC)方法*	123
4.3	分枝过程.....	128
4.3.1	Galton-Watson分枝过程	128
4.3.2	带移民的Galton-Watson分枝过程	129
4.3.3	分枝过程参数估计*	130
4.4	隐马尔科夫链	133
4.4.1	隐马尔科夫链及其性质	133
4.4.2	状态估计与预测*	136
4.4.3	隐Markov模型的参数估计*	138
第五章	更新过程.....	141
5.1	更新过程与更新方程	141
5.1.1	更新过程与更新性	141
5.1.2	更新函数与更新方程	144
5.1.3	更新过程的几个统计量	147
5.2	更新极限定理	150
5.2.1	大数定律与中心极限定理	150
5.2.2	更新定理	151
5.3	两类广义更新过程	157
5.3.1	有偿更新过程	157
5.3.2	可终止更新过程	160
第六章	布朗运动.....	165
6.1	布朗运动及其分布	165
6.1.1	布朗运动	165
6.1.2	布朗运动的分布	167
6.1.3	轨道性质*	170
6.2	反射原理与极值分布	172
6.2.1	反射原理	172
6.2.2	极值与首达时分布	173
6.2.3	零点概率*	175
6.3	几何布朗运动与Black-Scholes公式	178
6.3.1	几何布朗运动	178
6.3.2	期权定价原理	178
6.3.3	Black-Scholes公式	180

6.4	高斯过程与积分布朗运动	184
6.4.1	高斯过程与布朗桥.....	184
6.4.2	与布朗运动有关的简单积分.....	186
第七章	离散鞅	189
7.1	鞅与停时.....	189
7.1.1	鞅的定义及举例	189
7.1.2	鞅的简单性质	192
7.1.3	停时及其简单性质	194
7.2	鞅的停时定理	197
7.2.1	有界停时定理.....	197
7.2.2	一般停时定理.....	198
7.2.3	停时定理应用举例.....	200
7.3	鞅不等式与极限	204
7.3.1	极大不等式与Doob不等式.....	204
7.3.2	下穿不等式	206
7.3.3	Doob收敛定理	207

第一章 预备知识

本章我们将简要回顾概率论有关知识并补充或深化一些必要内容.

1.1 概率论简述

1.1.1 样本空间, 随机事件与概率

给定一个集合 Ω , 若它包含了所研究随机现象的全部基本事件, 我们就称这个集合为样本空间. 称由 Ω 中子集构成的集类 \mathfrak{F} 为 σ -代数, 若它满足

- (1) $\Omega \in \mathfrak{F}$;
- (2) $A \in \mathfrak{F} \Rightarrow \bar{A} \in \mathfrak{F}$;
- (3) $A_k \in \mathfrak{F}, k = 1, 2, \dots \Rightarrow \bigcup_{k \geq 1} A_k \in \mathfrak{F}$.

称 \mathfrak{F} 中每个元素为随机事件, 它是样本空间的子集. 从应用角度看, \mathfrak{F} 中包含的随机事件才是人们的兴趣所在. \mathbb{P} 是 $\mathfrak{F} \rightarrow [0, 1]$ 上的函数, 用来度量 \mathfrak{F} 中随机事件发生的可能性. 我们称它为概率, 如果满足如下条件

- (1) 对任意 $A \in \mathfrak{F}$, $\mathbb{P}(A) \geq 0$;
- (2) $\mathbb{P}(\emptyset) = 0$, $\mathbb{P}(\Omega) = 1$;
- (3) $A_k \in \mathfrak{F}, k = 1, 2, \dots$ 互不相交 $\Rightarrow \mathbb{P}\left(\bigcup_{k \geq 1} A_k\right) = \sum_{k \geq 1} \mathbb{P}(A_k)$.

称 n 个随机事件 A_1, \dots, A_n 是独立的, 若其中任意 k , $2 \leq k \leq n$, 个事件独立, 即对任意 A_{i_1}, \dots, A_{i_k} ,

$$\mathbb{P}(A_{i_1} A_{i_2} \cdots A_{i_k}) = \mathbb{P}(A_{i_1}) \mathbb{P}(A_{i_2}) \cdots \mathbb{P}(A_{i_n}).$$

任意给定两个随机事件 A, B . 假定事件 B 发生的概率为正, 那么在事件 B 发生前提下事件 A 发生的条件概率(随机事件下的条件概率)为

$$\mathbb{P}(A|B) = \mathbb{P}(AB)/\mathbb{P}(B).$$

本质上, 随机事件下的条件概率可以看作是一个将样本空间 Ω “缩小”为 B 后的概率.

随机事件概率有如下的基本计算公式.

- (1) (全概率公式) 设随机事件 B_1, \dots, B_n 为样本空间 Ω 的一个分割, 即 B_1, \dots, B_n 互不相交且它们的并集为全空间 Ω , 那么对任意一个随机事件 A

$$\mathbb{P}(A) = \sum_{k=1}^n \mathbb{P}(AB_k).$$

- (2) (乘法公式) 对任意两个随机事件 A, B ,

$$\mathbb{P}(AB) = \mathbb{P}(B)\mathbb{P}(A|B).$$

- (3) (贝叶斯公式) 设随机事件 B_1, \dots, B_n 为样本空间 Ω 的一个分割, 那么

$$\mathbb{P}(B_i|A) = \frac{\mathbb{P}(AB_i)}{\sum_{k=1}^n \mathbb{P}(A|B_k)\mathbb{P}(B_i)}.$$

通常把样本空间 Ω , 随机事件集 \mathfrak{F} 以及概率 \mathbb{P} 三者看作一个整体, 称为概率空间, 记作 $(\Omega, \mathfrak{F}, \mathbb{P})$.

1.1.2 单个随机变量及相关刻画

称定义在样本空间 Ω (概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$)上的(实值)函数 $X(\omega)$ 为随机变量, 若对任意 $x \in \mathbb{R}$,

$$\{\omega \in \Omega, X(\omega) \leq x\} = \{X \leq x\} \in \mathfrak{F}.$$

通常简记随机变量为 X, Y, Z . 称随机变量 X, Y 是几乎处处相等的(记作 $X \stackrel{a.s.}{=} Y$), 如果 $\mathbb{P}(X = Y) = 1$. 称函数

$$F(x) = \mathbb{P}(X \leq x)$$

为随机变量 X 的分布函数. F 是分布函数当且仅当 F 右连续, 单调不降而且

$$F(-\infty) = 0, \quad F(+\infty) = 1.$$

(A) 离散型随机变量

若随机变量可能的取值是有限的或可用自然数的次序将所有取值一一排列出来(可列的), 那么该随机变量称为是离散的. 设离散型随机变量 X 的可能取值为

$$x_0, x_1, \dots, x_n, \dots$$

我们称

$$p_i = \mathbb{P}(X = x_i), \quad i = 0, 1, \dots,$$

为 X 的概率分布列(离散分布). 称

$$\mathbb{E}(X^k) = \sum_{i=0}^{\infty} x_i^k p_i, \quad k \geq 1$$

为 X 的 k 阶(原点)矩, 如果上式右边的求和有意义. 特别 $k = 1$ 时, 称为 X 的数学期望(均值). 称

$$\text{Var}(X) = \sum_{i=0}^{\infty} (x_i - \mathbb{E}(X))^2 p_i$$

为 X 的方差.

下面我们列举几个简单的常用离散分布(变量).

(1) 两点分布 $b(1, p)$: $X \in \{0, 1\}$ 且 $\mathbb{P}(X = 1) = p$, $\mathbb{P}(X = 0) = 1 - p$, $p \in (0, 1)$.

(2) 二项分布 $b(n, p)$: $X \in \{0, 1, \dots, n\}$ 且

$$\mathbb{P}(X = k) = C_n^k p^k (1 - p)^{n-k}, \quad k = 0, 1, \dots, n, \quad p \in (0, 1).$$

(3) 几何分布 $Ge(p)$: $X \in \{0, 1, 2, \dots, n, \dots\}$ 且

$$\mathbb{P}(X = k) = p(1 - p)^k, \quad k \geq 0, \quad p \in (0, 1).$$

(4) 泊松分布 $P(\lambda)$ (称参数 λ 为强度): $X \in \{0, 1, 2, \dots, n, \dots\}$ 且

$$\mathbb{P}(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k \geq 0, \quad \lambda > 0.$$

(B) 连续型随机变量

若存在非负函数 $f(x)$ 使得随机变量 X 的分布函数

$$F(x) = \int_{-\infty}^x f(t) dt,$$

则称随机变量 X 是连续型的, 称函数 $f(t)$ 为是 X 的分布密度函数.

对任意 $k \geq 1$, 称

$$\mathbb{E}(X^k) := \int_{-\infty}^{\infty} x^k f(x) dx$$

为 X 的 k 阶(原点)矩, 如果上式右边积分有意义. 特别称 $\mathbb{E}(X)$ 为 X 的数学期望(均值). 称

$$\text{Var}(X) = \int_{-\infty}^{\infty} (x - \mathbb{E}(X))^2 f(x) dx$$

为 X 的方差.

一些典型连续型分布(变量)如下.

(1) 均匀分布: X 服从 (a, b) 上均匀分布 $U(a, b)$, 若分布密度函数

$$f(x) = \begin{cases} 1/(b-a) & x \in (a, b) \\ 0, & \text{其他.} \end{cases}$$

(2) 指数分布: X 服从 $(0, \infty)$ 上参数为 $\lambda > 0$ 的指数分布 $Exp(\lambda)$, 若密度函数为

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0, & \text{其他.} \end{cases}$$

(3) 伽玛分布: X 服从 $(0, \infty)$ 上形状参数 $a > 0$, 尺度参数 $\lambda > 0$ 的伽玛分布 $Ga(a, \lambda)$, 若密度

函数

$$f(x) = \begin{cases} \frac{\lambda^a x^{a-1}}{\Gamma(a)} e^{-\lambda x} & x \geq 0 \\ 0, & \text{其他.} \end{cases}$$

(4) 正态分布: X 服从 \mathbb{R} 上均值为 μ , 方差为 σ^2 的正态分布 $N(\mu, \sigma^2)$, 若密度函数

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

1.1.3 有限多个随机变量

同时考虑样本空间 Ω (概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$) 上随机变量 X_1, \dots, X_n . 通常称

$$X := (X_1, \dots, X_n)$$

为 n 元随机变量, 记作 $X \in \mathbb{R}^n$. 当 $n > 1$ 时, 统称为多元随机变量. 为表示方便, 我们也称 $X = (X_1, \dots, X_n)$ 为 n 维向量值随机变量(简称为向量值随机变量).

(A) 联合分布、协方差

若 X 为 n 元连续型随机变量, 那么存在非负函数 $f(x_1, x_2, \dots, x_n)$ 使得

$$F(x_1, x_2, \dots, x_n) = \int_{-\infty}^{x_1} dt_1 \int_{-\infty}^{x_2} dt_2 \cdots \int_{-\infty}^{x_n} f(t_1, t_2, \dots, t_n) dt_n.$$

称该多元函数 f 为 (X_1, \dots, X_n) 的联合密度函数. 此时也称单个随机变量 X_i 的分布函数

$$F_{X_i}(x) = \mathbb{P}(X_i \leq x)$$

为该联合分布的边际(边缘)分布; 称 X_i 的分布密度函数 $f_{X_i}(x)$ (若存在) 为边际(边缘) 密度函数, 而且

$$\begin{aligned} F_i(x) &= \int_{-\infty}^x dt_i \int_{-\infty}^{\infty} dt_1 \cdots \int_{-\infty}^{\infty} f(t_1, \dots, t_i, \dots, t_n) dt_n, \\ f_i(x) &= \int_{-\infty}^{\infty} dt_1 \cdots \int_{-\infty}^{\infty} f(t_1, \dots, x, \dots, t_n) dt_n. \end{aligned}$$

若 X_1, X_2, \dots, X_n 都是离散随机变量, 记所有可能的取值为

$$\{x_{ij}, i = 1, \dots, n, j = 0, 1, \dots\}.$$

那么 X 的联合分布列为

$$p_{k_1, k_2, \dots, k_n} = \mathbb{P}(X_1 = x_{1k_1}, X_2 = x_{2k_2}, \dots, X_n = x_{nk_n})$$

相应随机变量 X_i 的边际分布列

$$p_k^{(i)} = \mathbb{P}(X_i = x_{ik}) = \sum_{r=1, r \neq i}^n \sum_{k_r=0}^{\infty} \mathbb{P}(X_1 = x_{1k_1}, \dots, X_i = x_{ik}, \dots, X_n = x_{nk_n}).$$

n 元随机变量 X 的函数 $g(X) = g(X_1, X_2, \dots, X_n)$ 的数学期望定义为

$$\mathbb{E}(g(X)) = \begin{cases} \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} g(x_1, \dots, x_n) f(x_1, \dots, x_n) dx_1 \cdots dx_n, & \text{连续型} \\ \sum_{i=1}^n \sum_{k_i=0}^{\infty} g(x_{1k_1}, \dots, x_{nk_n}) p_{k_1, \dots, k_n}, & \text{离散型.} \end{cases}$$

任意两个随机变量之间的协方差为

$$\begin{aligned} \text{Cov}(X_i, X_j) &= \mathbb{E}((X_i - \mathbb{E}(X_i))(X_j - \mathbb{E}(X_j))) \\ &= \begin{cases} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mathbb{E}(X_i))(y - \mathbb{E}(X_j)) f_{ij}(x, y) dx dy, & \text{连续型,} \\ \sum_{k_i=0}^{\infty} \sum_{k_j=0}^{\infty} (x_{ik_i} - \mathbb{E}(X_i))(x_{jk_j} - \mathbb{E}(X_j)) p_{k_i, k_j}^{(i,j)}, & \text{离散型,} \end{cases} \end{aligned}$$

这里 $f_{ij}(x, y), p_{k_i, k_j}^{(i,j)}$ 表示由 X_i, X_j 这两个随机变量所得到的联合分布密度函数或联合分布列.

称 n 阶方阵 $D = (\text{Cov}(X_i, X_j))$ 为 n 个随机变量 X_1, X_2, \dots, X_n 的协方差矩阵.

n 元正态分布的是一个重要连续型多元联合分布. 当 $n = 2$ 时我们说 (X_1, X_2) 服从二元正态分布 $N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$, 若它们的联合分布密度函数

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{1-\rho^2}\left(\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{x-\mu_1}{\sigma_1}\frac{y-\mu_2}{\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right)\right\},$$

其中 $\mu_1 = \mathbb{E}(X_1), \mu_2 = \mathbb{E}(X_2), \sigma_1^2 = \text{Var}X_1, \sigma_2^2 = \text{Var}X_2, \rho = \text{Cov}(X_1, X_2)/(\sigma_1\sigma_2)$ 为相关系数. 引进协方差矩阵

$$D = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}.$$

那么 $|D| = \sigma_1^2\sigma_2^2(1-\rho^2)$,

$$D^{-1} = \frac{1}{|D|} \begin{pmatrix} \sigma_2^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & \sigma_1^2 \end{pmatrix} = \frac{1}{1-\rho^2} \begin{pmatrix} \sigma_1^{-2} & -\rho\sigma_1^{-1}\sigma_2^{-1} \\ -\rho\sigma_1^{-1}\sigma_2^{-1} & \sigma_2^{-2} \end{pmatrix}.$$

记 $(\mathbf{x} - \boldsymbol{\mu}) = (x - \mu_1, y - \mu_2)^T$, 那么利用矩阵表示二元正态分布密度函数可写成

$$f(x, y) = \frac{1}{2\pi\sqrt{|D|}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T D^{-1}(\mathbf{x}-\boldsymbol{\mu})}.$$

一般地 n 元正态随机变量 (X_1, \dots, X_n) 的密度函数定义为

$$f(x_1, x_2, \dots, x_n) = \frac{1}{(2\pi)^{n/2}\sqrt{|D|}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T D^{-1}(\mathbf{x}-\boldsymbol{\mu})},$$

其中 D 为正定矩阵, $\mathbf{x} - \boldsymbol{\mu} = (x_1 - \mu_1, \dots, x_n - \mu_n)^T$, μ_1, \dots, μ_n 为常数. 此时对任意 i , $\mathbb{E}(X_i) = \mu_i$, 而且 D 就是 X_1, \dots, X_n 之间的协方差矩阵.

下面这个例子介绍了参数为 (p_1, p_2, \dots, p_m) 的多元二项分布.

例1.1 向 m 个罐子里抛硬币, 硬币落入第 i 个罐子的概率设为 p_i , $p_1 + \dots + p_m = 1$. 连续独立地抛 n 次. 以 X_i 表示落入第 i 个罐子的可能硬币数. 求 (X_1, X_2, \dots, X_m) 的联合分布.

解 以 n_i 表示第 i 个罐子落入的硬币数, 那么 $0 \leq n_i \leq n$, 而且 $n_1 + \cdots + n_m = n$. 随机事件

$$(X_i = n_i, i = 1, 2, \dots, m)$$

发生的组合数为

$$C_n^{n_1} C_{n-n_1}^{n_2} \cdots C_{n-n_1-\cdots-n_{m-2}}^{n_{m-1}} = \frac{n!}{n_1! n_2! \cdots n_m!},$$

由实验的独立同分布性可知每一组合发生的概率为 $p_1^{n_1} p_2^{n_2} \cdots p_m^{n_m}$, 因此

$$\mathbb{P}(X_i = n_i, i = 1, 2, \dots, n) = \begin{cases} \frac{n!}{n_1! n_2! \cdots n_m!} p_1^{n_1} p_2^{n_2} \cdots p_m^{n_m}, & n_i \geq 0, \sum_{i=1}^m n_i = n, \\ 0, & \text{其它.} \end{cases}$$

容易看出任意前 k 项 ($k < m$) 的分布列为

$$\mathbb{P}(X_i = n_i, i = 1, 2, \dots, k) = \begin{cases} \frac{n!}{n_1! \cdots n_k! m_k!} p_1^{n_1} \cdots p_k^{n_k} q_k^{m_k}, & n_i \geq 0, \sum_{i=1}^k n_i \leq n, \\ 0, & \text{其它,} \end{cases}$$

其中 $q_k = 1 - \sum_{i=1}^k p_i$, $m_k = n - \sum_{i=1}^k n_i$. □

(B) 随机变量独立性

称 n 个随机变量 X_1, X_2, \dots, X_n 是独立的, 如果对任意 $x_1, \dots, x_n \in \mathbb{R}$,

$$\mathbb{P}(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n) = \mathbb{P}(X_1 \leq x_1) \mathbb{P}(X_2 \leq x_2) \cdots \mathbb{P}(X_n \leq x_n).$$

称无穷多个随机变量 X_1, \dots, X_n, \dots 是独立的, 若对任意 $k \geq 2$, X_1, X_2, \dots, X_k 是独立的.

若 X_1, \dots, X_n 为连续型随机变量, 那么 X_1, X_2, \dots, X_n 独立当且仅当它们的联合密度等于各自密度函数的乘积, 即

$$f(x_1, x_2, \dots, x_n) = f_{X_1}(x_1) f_{X_2}(x_2) \cdots f_{X_n}(x_n).$$

随机变量相互独立的概念和性质还可推广到多元随机变量的情形.

定义 1.2 设 $\mathbf{X}_i = (X_{i,1}, \dots, X_{i,k_i})$, $i = 1, \dots, n$, 分别是 k_1, \dots, k_n 维的随机变量, 其中每个 $k_i \geq 1$. 称多元随机变量 $\mathbf{X}_1, \dots, \mathbf{X}_n$ 是独立的, 若任意的 $x_{i,j} \in (-\infty, +\infty)$, 其中 $1 \leq j \leq k_i$, $1 \leq i \leq n$,

$$\mathbb{P}(X_{i,j} \leq x_{i,j}, 1 \leq j \leq k_i, 1 \leq i \leq n) = \prod_{i=1}^n \mathbb{P}(X_{i,j} \leq x_{i,j}, 1 \leq j \leq k_i).$$

由多元随机变量独立性的定义可知, 若随机变量 X_1, \dots, X_n 是独立的, 将其分成不相交的任意 k 组, 将每组看成一个多元随机变量, 记作 $\mathbf{X}_1, \dots, \mathbf{X}_k$, 那么这 k 个多元随机变量也是独立的, 并且随机变量 $Y_i := f_i(\mathbf{X}_i)$, $i = 1, \dots, k$, 也相互独立.

(C) 随机变量函数的分布

设 n 元随机变量 $X = (X_1, \dots, X_n)$ 的取值区域为 \mathcal{D} , Φ 是从 \mathcal{D} 到 $\mathcal{A} \in \mathbb{R}^n$ 的可逆函数, n 元

随机变量 $Y := (Y_1, \dots, Y_n) = \Phi(X)$, 那么

(1) 若 X 是离散的, 对任意 $y = (y_1, \dots, y_n)$, 设 $\Phi^{-1}(y) = (x_1, \dots, x_n)$, 那么

$$\mathbb{P}(Y_1 = y_1, \dots, Y_n = y_n) = \mathbb{P}(X_1 = x_1, \dots, X_n = x_n).$$

(2) 若 X 是连续型随机变量, Φ 连续、可微且 Jacobi 行列式

$$J_\Phi = \left| \frac{\partial y_i}{\partial x_j} \right|_{i,j=1,\dots,n}$$

处处不为 0, 其中 y_i 表示函数 Φ 的第 i 个分量. 那么对任意 $(u_1, \dots, u_n) \in \mathcal{A}$,

$$f_Y(u_1, \dots, u_n) = \frac{f_X(\Phi^{-1}(u_1, \dots, u_n))}{|J_\Phi|_{\Phi^{-1}(u_1, \dots, u_n)}},$$

其中 f_Y, f_X 分别表示 Y, X 的联合密度函数.

例1.2 设 $\{T_k, k \geq 1\}$ 是非负随机变量序列 $\{W_i, i \geq 1\}$ 的部分和序列, 即

$$T_k = \sum_{i=1}^k W_i.$$

若 (T_1, \dots, T_k) 的联合密度函数为

$$f_T(t_1, \dots, t_n) = \begin{cases} \lambda^n e^{-\lambda t_n}, & 0 < t_1 < t_2 < \dots < t_n \\ 0, & \text{其它.} \end{cases}$$

那么 $W_i, i = 1, \dots, n$, 服从参数为 λ 的指数分布且相互独立.

证明 定义一个从 $\mathcal{A} = \{(t_1, \dots, t_n) : 0 \leq t_1 \leq t_2 \leq \dots \leq t_n\}$ 到 $\bar{\mathbb{R}}_+^n$ 的映射 Φ , 使得

$$\Phi(t_1, t_2, \dots, t_n) = (t_1, t_2 - t_1, \dots, t_n - t_{n-1}).$$

显然 Φ 是连续、可微的可逆函数, Jacobi 行列式 $J_\Phi \equiv 1$ 且

$$(W_1, \dots, W_n) = \Phi(T_1, \dots, T_n).$$

因此 (W_1, \dots, W_n) 在 $\bar{\mathbb{R}}_+^n$ 上的联合密度函数

$$\begin{aligned} f_W(x_1, x_2, \dots, x_n) &= \frac{f_T(\Phi^{-1}(x_1, \dots, x_n))}{|J_\Phi|_{\Phi^{-1}(x_1, \dots, x_n)}} \\ &= f_T(\Phi^{-1}(x_1, \dots, x_n)) = \lambda^n e^{-\lambda \sum_{i=1}^n x_i}. \end{aligned}$$

由此可知 W_1 的分布密度为

$$f_{W_1}(x_1) = \int_0^\infty dx_2 \cdots \int_0^\infty \lambda^n e^{-\lambda \sum_{i=1}^n x_i} dx_n = \lambda e^{-\lambda x_1}.$$

类似计算可得 $W_i, i \geq 2$, 的分布密度为 $f_{W_i}(x_i) = \lambda e^{-\lambda x_i}$. 因此

$$f_W(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f_{W_i}(x_i).$$

所以 $W_i, i = 1, \dots, n$ 是服从参数为 λ 的指数分布的独立同分布随机变量. \square

(D) 独立随机变量的和与极值的分布

若 X, Y 独立且分布函数分别为 $F_X(x)$ 和 $F_Y(y)$, 那么 $X + Y$ 的分布函数 $G(z) = \mathbb{P}(X + Y \leq z)$

z) 可用卷积表示, $G = F_X * F_Y$, 即对任意 $z \in \mathbb{R}$

$$G(z) = F_X * F_Y(z) = \begin{cases} \sum_{x_k} p_X(x_k) F_Y(z - x_k) & X \text{ 为离散随机变量,} \\ \int_{-\infty}^{\infty} f_X(x) F_Y(z - x) dx, & X \text{ 为连续随机变量.} \end{cases}$$

特别, 若 X, Y 均是连续型随机变量, 那么 $X + Y$ 也是连续型随机变量, 它的分布密度函数

$$g(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z - x) dx.$$

若 X_1, X_2, \dots, X_n 是独立同分布的随机变量, 共同分布为 F , 那么对任意 $2 \leq k \leq n$,

$$X_1 + X_2 + \dots + X_k$$

的分布函数

$$F_k(z) := \mathbb{P}(X_1 + X_2 + \dots + X_k \leq z) = F^{*k}(z) = F^{*k-1} * F,$$

其中 $F^{*1} = F$. 若 F 有密度函数 f , 那么 $X_1 + X_2 + \dots + X_k$ 的分布密度函数

$$f_k(z) = \int_{-\infty}^{\infty} f_{k-1}(x) f(z - x) dx,$$

其中 $f_1 = f$. 此时它们中最大值和最小值的分布函数分别为

$$F_{\max}(z) = [F(z)]^n, \quad F_{\min}(z) = 1 - (1 - F(z))^n,$$

密度函数分别为

$$f_{\max}(z) = n[F(z)]^{n-1} f(z), \quad f_{\min}(z) = n(1 - F(z))^{n-1} f(z).$$

例1.3 (1) 若 X_1, X_2, \dots, X_n 是分别服从 $\text{Ga}(a_1, \lambda), \text{Ga}(a_2, \lambda), \dots, \text{Ga}(a_n, \lambda)$ 分布的独立随机变量, 那么

$$X_1 + \dots + X_n \sim \text{Ga}(a_1 + \dots + a_n, \lambda).$$

(2) 若 X_1, X_2, \dots, X_n 是分别服从 $N(\mu_1, \sigma_1^2), N(\mu_2, \sigma_2^2), \dots, N(\mu_n, \sigma_n^2)$ 分布的独立随机变量, 那么

$$X_1 + \dots + X_n \sim N(\mu_1 + \dots + \mu_n, \sigma_1^2 + \dots + \sigma_n^2).$$

作为本节的结束, 最后我们指出随机变量的两个基本不等式.

(1) 若随机变量 X 的 p 阶矩存在, 那么对任意 $x > 0$

$$\mathbb{P}(|X| \geq x) \leq \frac{\mathbb{E}(|X|^p)}{x^p}, \quad p > 0 \quad (\text{切比雪夫不等式}).$$

(2) 若随机变量 X, Y 的二阶矩都存在, 那么

$$[\mathbb{E}(XY)]^2 \leq \mathbb{E}(X^2)\mathbb{E}(Y^2), \quad (\text{Schwarz 不等式}).$$

练习题

1.1 设 X_1, X_2, \dots, X_n 独立且几何分布 $\text{Ge}(p)$, 求 $X_1 + X_2 + \dots + X_n$ 的分布列.

1.2 设 X_1, X_2, X_3 独立且服从均匀分布 $U(0, 1)$, 分别用 $X_{(1)}, X_{(2)}, X_{(3)}$ 表示其中最大, 其次和最小的随机变量. 求 $X_{(1)}, X_{(2)}, X_{(3)}$ 的联合密度函数.

1.3 设二元随机变量 $\mathbf{X} = (X_1, X_2)$, $\mathbf{Y} = (Y_1, Y_2)$ 独立. 证明 X_1 与 Y_1 独立, 并举例说明 X_1, X_2 可以不独立.

1.4 用 Schwarz 不等式证明若 X 的二阶矩存在, 那么 $\mathbb{P}(|X| > 0) \geq [\mathbb{E}(X)]^2 / \mathbb{E}(X^2)$.

1.5 若对任意 $k \geq 0$, $\{a_n(k), n \geq 1\}$ 为非单调不降数列, 且 $\lim_{n \rightarrow \infty} a_n(k) = a(k)$, 证明

$$\sum_{k=0}^{\infty} a(k) = \lim_{n \rightarrow \infty} \sum_{k=0}^{\infty} a_n(k).$$

1.6 利用习题 1.5 的结论证明

(1) 若离散随机变量 X 的取值为 $0, 1, 2, \dots$, 那么 $\mathbb{E}(X) = \sum_{k=1}^{\infty} \mathbb{P}(X \geq k)$.

(2) 若 X 是非负连续随机变量, 那么 $\mathbb{E}(X) = \int_0^{\infty} \mathbb{P}(X > x) dx$.

1.7* 利用习题 1.5 的结论证明(无穷求和或积分的交换次序公式)

(1) 若对任意 n, k , $b_{n,k}$ 是非负实数, 证明 $\sum_{n=1}^{\infty} \sum_{k=1}^n b_{n,k} = \sum_{k=1}^{\infty} \sum_{n=k}^{\infty} b_{n,k}$.

(2) 若 $f(x, y)$ 是非负可积函数, 那么 $\int_0^{\infty} dx \int_0^x f(x, y) dy = \int_0^{\infty} dy \int_y^{\infty} f(x, y) dx$.

1.8* 设非负随机变量 X 服从离散分布 F , 称 $S = \{x : \mathbb{P}(\{x\}) > 0\}$ 为分布 F 的支撑集. 若存在非负实数 $d > 0$ 使得 $S \subset \{nd : n \geq 0\}$, 则称 X 服从格子点分布. 若存在互素的非负整数 $n_k, k \geq 0$ 使得 $S = \{n_k d, k \geq 0\}$, 则称 d 为 F 的步长. 证明格子点分布的步长总存在且唯一.

1.9* 设正整数 k_1, \dots, k_s 的最大公因数为 d . 证明存在正整数 N , 当 $n > N$ 时存在非负整数 c_1, \dots, c_s 使得 $nd = c_1 k_1 + c_2 k_2 + \dots + c_s k_s$.

1.2 条件数学期望

对任意随机变量 X , 不论是离散的还是连续的, 我们知道数学期望是刻画它的一个非常重要的数值特征量. 这一节我们将进一步介绍一个非常重要的概念——条件数学期望。

1.2.1 随机事件下的条件分布与均值

任意给定的两个随机变量 (X, Y) , 利用初等概率中随机事件下的条件概率定义可知, 在事件 $\{Y \in A\}$ 发生的条件下 X 的分布函数为

$$F_{X|A}(x) := \mathbb{P}(X \leq x | Y \in A) = \frac{\mathbb{P}(X \leq x, Y \in A)}{\mathbb{P}(Y \in A)}.$$

注意到随机事件下的条件概率实质上是某个新的样本空间上的概率, 因此我们在初等概率论学习的许多问题可以在条件概率下讨论. 比如, 在 $Y \in A$ 条件下我们可以定义 X 的函数 $g(X)$ 的数学期望为

$$\mathbb{E}(g(X)|Y \in A) = \begin{cases} \frac{\sum_x g(x)\mathbb{P}(X=x, Y \in A)}{\mathbb{P}(Y \in A)}, & X \text{ 离散} \\ \int_{-\infty}^{\infty} g(x)f(x, A)dx, & X \text{ 连续.} \end{cases}$$

其中 $f(x, A)$ 为分布函数 $F_{X|A}(x)$ 的密度函数.

例2.1 设 (X, Y) 服从 $(0, 1) \times (0, 2)$ 上的均匀分布, 求 $\mathbb{E}(X|Y > 1)$.

解 令 $A = (1, \infty)$. 当 (X, Y) 为连续随机变量时,

$$f(x, A) = \frac{\int_A f(x, y)dy}{\int_{-\infty}^{\infty} dx \int_A f(x, y)dy},$$

其中 $f(x, y)$ 为 (X, Y) 的联合密度函数. 由于 (X, Y) 服从 $(0, 1) \times (0, 2)$ 上的均匀分布,

$$f(x, y) = 1/2, \quad 0 < x < 1, 0 < y < 2.$$

代入计算得

$$f(x, A) = 1, \quad 0 < x < 1.$$

从而

$$\mathbb{E}(X|Y > 1) = \int_0^1 xf(x, A)dx = 1/2. \quad \square$$

特别, 给定两元离散随机变量 (X, Y) , y 是 Y 的一个可能值. 在随机事件 $\{Y = y\}$ 条件下, X 的(条件)分布列为

$$\mathbb{P}(X = x|Y = y) = \frac{\mathbb{P}(X = x, Y = y)}{\mathbb{P}(Y = y)} = \frac{\mathbb{P}(X = x, Y = y)}{\sum_x \mathbb{P}(X = x, Y = y)},$$

其中 x 表示 X 的可能取值. 在随机事件 $\{Y = y\}$ 条件下, X 的(条件)数学期望为

$$\mathbb{E}(X|Y = y) = \sum_x x\mathbb{P}(X = x|Y = y) = \frac{\sum_x x\mathbb{P}(X = x, Y = y)}{\mathbb{P}(Y = y)}. \quad (1.2.1)$$

二元函数 $\Phi(X, Y)$ 在随机事件 $\{Y = y\}$ 条件下变成 $\Phi(X, y)$, 从而(条件)数学期望为

$$\mathbb{E}(\Phi(X, Y)|Y = y) = \sum_x \Phi(x, y)\mathbb{P}(X = x|Y = y) = \frac{\sum_x \Phi(x, y)\mathbb{P}(X = x, Y = y)}{\mathbb{P}(Y = y)}.$$

例2.2 设 X, X_1 分别服从二项分布 $b(n, p)$ 和 $b(m, p)$ 且独立, $m < n$. 求

$$\mathbb{E}(X|X + X_1 = n).$$

解 令 $Y = X + X_1$, 则 $Y \sim (n + m, p)$ 二项分布.

$$\begin{aligned}\mathbb{E}(X|X + X_1 = n) &= \mathbb{E}(X|Y = n) = \frac{\sum_k k\mathbb{P}(X = k, Y = n)}{\mathbb{P}(Y = n)} \\ &= \frac{\sum_{k=n-m}^n k\mathbb{P}(X = k, X_1 = n - k)}{\mathbb{P}(Y = n)} = \frac{\sum_{k=0}^m (n - k)C_n^k C_m^{m-k}}{C_{n+m}^m}.\end{aligned}$$

注意到 $\sum_{k=0}^m C_{n-1}^k C_m^{m-k} = C_{n+m-1}^m$,

$$\mathbb{E}(X|X + X_1 = n) = \frac{n \sum_{k=0}^m C_{n-1}^k C_m^{m-k}}{C_{n+m}^m} = n \frac{C_{n+m-1}^m}{C_{n+m}^m} = \frac{n^2}{n + m}. \quad \square$$

当 (X, Y) 是二元连续随机变量时, 虽然随机事件 $\{Y = y\}$ 发生的概率为0, 但由初等概率论可知, 此时我们可以引进 X 的(条件)密度函数

$$f(x|y) = \frac{f(x, y)}{f_Y(y)} = \frac{f(x, y)}{\int_{-\infty}^{\infty} f(x, y)dx},$$

其中 $f(x, y)$ 为 (X, Y) 的联合密度函数. 从而在随机事件 $\{Y = y\}$ 条件下, X 的(条件)数学期望定义为

$$\mathbb{E}(X|Y = y) = \int_{-\infty}^{\infty} xf(x|y)dx = \frac{\int_{-\infty}^{\infty} xf(x, y)dx}{f_Y(y)}. \quad (1.2.2)$$

类似对二元函数 $\Phi(X, Y)$ 在随机事件 $\{Y = y\}$ 条件下的数学期望为

$$\mathbb{E}(\Phi(X, Y)|Y = y) = \int_{-\infty}^{\infty} \Phi(x, y)f(x|y)dx.$$

例2.3 对任意 $y > 0$, 求 $\mathbb{E}(X|Y = y)$, 其中 (X, Y) 的联合密度函数为

$$f(x, y) = 6/(1 + x + y)^4, \quad 0 < x, y < \infty.$$

解 对任意 $x > 0$

$$f(x|y) = \frac{f(x, y)}{\int_0^{\infty} f(x, y)dx} = \frac{3(1 + y)^3}{(1 + x + y)^4}.$$

因此

$$\mathbb{E}(X|Y = y) = \int_0^{\infty} xf(x|y)dx = (1 + y)^3 \int_0^{\infty} \frac{3x}{(1 + x + y)^4} dx = \frac{1 + y}{2}. \quad \square$$

1.2.2 随机变量下的条件数学期望

一般而言, 当条件事件 $\{Y = y\}$ 变化时, 对应的条件数学期望也会发生改变, 从而我们可以设计一个从 $\Omega \rightarrow \mathbb{R}$ 的映射, 使得对任意 $\omega \in \Omega$,

$$\omega \in \Omega \rightarrow \mathbb{E}(X|Y = y) \quad \text{其中 } y = Y(\omega). \quad (1.2.3)$$

然而这个映射可能有缺陷, 因为若(1.2.1)或(1.2.2)的分母为0, 表达式 $\mathbb{E}(X|Y = y)$ 没有意义.

但此时若令

$$\mathcal{Y} = \begin{cases} \{y : \mathbb{P}(Y = y) > 0\}, & Y \text{离散}, \\ \{y : f_Y(y) \neq 0\}, & Y \text{连续}, \end{cases}$$

以及 $\Omega_Y = \{\omega : Y(\omega) \in \mathcal{Y}\}$, 那么映射在集合 Ω_Y 上是明确、可行的.

定义2.1 设 (X, Y) 是连续型或离散型二元随机变量, X 的数学期望存在. 若存在随机变量 Z 使得

- (1) Z 为随机变量 Y 的函数, 即存在函数 g 使得 $Z = g(Y)$;
- (2) 对任意 $\omega \in \Omega_Y$,

$$Z(\omega) = g(Y(\omega)) = \mathbb{E}(X|Y = y) \quad \text{其中 } y = Y(\omega), \quad (1.2.4)$$

则称 Z 为 X 关于随机变量 Y 的条件数学期望, 简称为条件数学期望.

从条件数学期望定义可看出函数 g 满足: 对任意 $y \in \mathcal{Y}$, $g(y) = \mathbb{E}(X|Y = y)$. 进一步, 条件数学期望 Z 只能保证在 Ω_Y 上是明确、唯一的; 对 Ω_Y 外的 ω , 定义本身并没有明确要求; 因此条件数学期望可能是不唯一的. 但这样定义出来的任意两个可能的条件数学期望 Z_1, Z_2 必满足 $\Omega_Y \subset \{Z_1 = Z_2\}$. 注意到

$$\bar{\Omega}_Y := \Omega \setminus \Omega_Y = \{\omega : Y \in \{y; f_Y(y) = 0\}\}.$$

因此

$$\mathbb{P}(\bar{\Omega}_Y) = \mathbb{P}(Y \in \{y; f_Y(y) = 0\}) = \int_A f_Y(y) dy = 0,$$

其中 $A = \{y; f_Y(y) = 0\}$. 这表明由定义2.1给出的任意两个条件数学期望, 除在一个零概率事件上可能不同外, 是完全一致的, 即 Z_1 与 Z_2 几乎处处相同. 一般而言, 零概率事件不影响讨论, 几乎处处相等的随机变量的差别可以忽略. 因此在几乎处处相等意义上, 定义2.1 中的条件数学期望是唯一的.

注2.1 通常把该“唯一”的条件数学期望记作 $\mathbb{E}(X|Y)$. 此后凡涉及条件数学期望及其性质时, 若有必要都在“几乎处处成立”这一前提下理解, 即除了一个零概率事件, 对应的性质成立.

例2.4 给定样本空间 $\Omega = (0, 1)$ 以及合适的事件集和概率, 使得对任意 $(a, b) \subset (0, 1)$,

$$\mathbb{P}((a, b)) = b - a.$$

设 X, Y 均是 Ω 上的随机变量满足

$$X(\omega) = \begin{cases} -1, & \omega \in (0, 1/2) \\ 1, & \omega \in [1/2, 1), \end{cases} \quad Y(\omega) = \begin{cases} 0, & \omega \in (0, 1/4) \\ 1, & \omega = 1/4, \\ 2, & \omega \in (1/4, 1). \end{cases}$$

求 $\mathbb{E}(X|Y)$.

解 按定义 $\mathbb{P}(Y=0)=1/4$, $\mathbb{P}(Y=1)=0$ 且 $\mathbb{P}(Y=2)=3/4$. 因此 $\mathcal{Y}=\{0, 2\}$. 从而

$$g(0) = \mathbb{E}(X|Y=0) = \frac{-\mathbb{P}(X=-1, Y=0) + \mathbb{P}(X=1, Y=0)}{\mathbb{P}(Y=0)} = -1,$$

$$g(2) = \mathbb{E}(X|Y=2) = \frac{-\mathbb{P}(X=-1, Y=2) + \mathbb{P}(X=1, Y=2)}{\mathbb{P}(Y=2)} = 1/3.$$

因此

$$\mathbb{E}(X|Y)(\omega) = \begin{cases} g(0) = -1, & \omega \in (0, 1/4), \\ g(2) = 1/3, & \omega \in [1/4, 1), \end{cases}$$

这里我们补充(自由)定义 $\mathbb{E}(X|Y)$ 在 $\omega=1/4$ 的值为 $1/3$. □

例2.5 设 (X, Y) 为二元正态随机变量, 联合分布密度函数如下, 求 $\mathbb{E}(X|Y)$.

$$f(x, y) = \frac{1}{\sqrt{3}\pi} e^{-\frac{2}{3}(x^2 - xy + y^2)}, \quad (x, y) \in \mathbb{R}^2.$$

解 注意到

$$f(x, y) = \frac{1}{\sqrt{3}\pi} e^{-\frac{2}{3}(x-y/2)^2} e^{-\frac{y^2}{2}},$$

直接计算可知

$$f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx = \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}}.$$

因此

$$f(x|y) = \frac{f(x, y)}{f_Y(y)} = \frac{1}{\sqrt{3\pi/2}} e^{-\frac{(x-y/2)^2}{3/2}},$$

由此可得 $\mathcal{Y}=\mathbb{R}$, 且对任意 $y \in \mathbb{R}$,

$$g(y) = \mathbb{E}(X|Y=y) = \int_{-\infty}^{\infty} x f(x|y) dx = \frac{y}{2}.$$

所以对任意 ω , $\mathbb{E}(X|Y)(\omega) = g(Y(\omega)) = Y(\omega)/2$. 即 $\mathbb{E}(X|Y) = Y/2$. □

例2.6 (X, Y) 的联合分布密度函数为 $f(x, y)$. 设 $a < b$ 且 $\mathbb{P}(a \leq Y \leq b) > 0$. 证明

$$\int_a^b \mathbb{E}(X|Y=y) f_Y(y) dy = \mathbb{E}(X|a \leq Y \leq b) \mathbb{P}(a \leq Y \leq b),$$

其中 $f_Y(y)$ 为 Y 的密度函数.

证明 随机事件 $A = \{a \leq Y \leq b\}$ 发生条件下, 随机变量 X 的密度函数为

$$f_{X|A}(x) = \frac{\int_a^b f(x, y) dy}{\int_{-\infty}^{\infty} \int_a^b f(x, y) dx dy},$$

因此

$$\begin{aligned} \mathbb{E}(X|a \leq Y \leq b) &= \int_{-\infty}^{\infty} x f_{X|A}(x) dx = \frac{\int_{-\infty}^{\infty} dx \int_a^b x f(x, y) dy}{\int_{-\infty}^{\infty} \int_a^b f(x, y) dx dy} \\ &= \frac{\int_{-\infty}^{\infty} dx \int_a^b x f(x, y) dy}{\mathbb{P}(A)}. \end{aligned}$$

另一方面, 记 $\mathbb{E}(X|Y)$ 为 $g(Y)$, 那么

$$\begin{aligned} \int_a^b \mathbb{E}(X|Y=y) f_Y(y) dy &= \int_a^b dy \int_{-\infty}^{\infty} x f(x|y) f_Y(y) dx \\ &= \int_{-\infty}^{\infty} dx \int_a^b x f(x, y) dy \end{aligned}$$

因此

$$\mathbb{P}(a \leq Y \leq b) \mathbb{E}(X|a \leq Y \leq b) = \int_a^b \mathbb{E}(X|Y=y) f_Y(y) dy.$$

□

随机变量下的条件数学期望有如下重要性质.

性质2.1 假设以下数学期望与条件数学期望总有意义.

- (1) 若 X 与 Y 独立, 则 $\mathbb{E}(X|Y) = \mathbb{E}(X)$.
- (2) 若 $a \leq \Phi(X, Y) \leq b$, 则 $a \leq \mathbb{E}(\Phi(X, Y)|Y) \leq b$, 从而 $\mathbb{E}(a|Y) = a$, 其中 a, b 为常数.
- (3) $\mathbb{E}(\sum_{i=1}^n a_i X_i|Y) = \sum_{i=1}^n a_i \mathbb{E}(X_i|Y)$, 其中 a_i 非随机.
- (4) $|\mathbb{E}(X|Y)| \leq \mathbb{E}(|X||Y|)$.
- (5) $\mathbb{E}(X) = \mathbb{E}(\mathbb{E}(X|Y))$; (全概率公式).
- (6) 对任意 $\omega \in \Omega$, 记 $y = Y(\omega)$, 那么

$$\mathbb{E}(\Phi(X, Y)|Y)(\omega) = \mathbb{E}(\Phi(X, y)|Y=y).$$

特别对任意随机变量 $Z = f(X), W = g(Y)$

$$\mathbb{E}(f(X)g(Y)|Y) = g(Y)\mathbb{E}(f(X)|Y), \quad \mathbb{E}(g(Y)|Y) = g(Y).$$

证明 我们仅以连续型随机变量为例证明(1),(5)和(6).

- (1) 按此前关于条件数学期望的解释, 我们只需要证明对任意 $\omega \in \Omega_Y$, 等式成立即可. 任取 $\omega \in \Omega_Y$, 记 $y = Y(\omega)$,

$$\begin{aligned} \mathbb{E}(X|Y)(\omega) &= \mathbb{E}(X|Y=y) = \int_{-\infty}^{\infty} x f(x|y) dx \\ &= \int_{-\infty}^{\infty} x f_X(x) dx = \mathbb{E}(X), \end{aligned}$$

其中 $f_X(x)$ 表示随机变量 X 的分布密度函数.

(5) 直接计算得

$$\begin{aligned}\mathbb{E}(\mathbb{E}(X|Y)) &= \int_{-\infty}^{\infty} \mathbb{E}(X|Y=y) f_Y(y) dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x|y) dx f_Y(y) dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x,y) dx dy = \mathbb{E}(X).\end{aligned}$$

(6) 为叙述简单, 仅考虑对任意给定的 y 函数 $\phi_y(x) := \Phi(x, y)$ 关于 x 单调的情形. 此时记 $Z = \Phi(X, Y)$, 那么 (Z, Y) 的联合分布密度函数为

$$g(z, y) = \frac{f(x, y)}{|\phi'_y(x)|} \Big|_{x=\phi_y^{-1}(z)}.$$

此时由随机变量下条件期望定义

$$\mathbb{E}(\Phi(X, Y)|Y)(\omega) = \mathbb{E}(Z|Y)(\omega) = \mathbb{E}(Z|Y=y) = \frac{\int_{-\infty}^{\infty} z g(z, y) dz}{\int_{-\infty}^{\infty} g(z, y) dz}.$$

作变量代换 $x = \phi_y^{-1}(z)$, 那么

$$\begin{aligned}\mathbb{E}(\Phi(X, Y)|Y)(\omega) &= \frac{\int_{-\infty}^{\infty} \phi_y(x) f(x, y) dx}{\int_{-\infty}^{\infty} f(x, y) dx} \\ &= \frac{\int_{-\infty}^{\infty} \Phi(x, y) f(x, y) dx}{\int_{-\infty}^{\infty} f(x, y) dx} = \mathbb{E}(\Phi(X, y)|Y=y).\end{aligned}$$

其他请读者自己完成, 参见练习2-5. \square

例2.7 某矿工身陷在有三个门的矿井中, 选择第1个门的通道进行2小时后他将到达安全地, 选择第2个门的通道后将在3个小时后回到原地, 选择第3个门的通道后将在5个小时后回到原地. 假定这个矿工每次都随机地选取一个门, 问他到达安全地的平均时间是多少?

解 记 X 为矿工到达安全地的时间, N 为矿工第一次选择的通道. 由于矿工回到原地后仍然是随机选择通道, 因此当矿工回到原地后面对的问题与开始时相同. 由问题假设我们可得

$$\mathbb{E}(X|N=1) = 2, \quad \mathbb{E}(X|N=2) = 3 + \mathbb{E}(X), \quad \mathbb{E}(X|N=3) = 5 + \mathbb{E}(X).$$

由全概率公式

$$\begin{aligned}\mathbb{E}(X) &= \mathbb{E}(\mathbb{E}(X|N)) \\ &= \mathbb{E}(X|N=1)\mathbb{P}(N=1) + \mathbb{E}(X|N=2)\mathbb{P}(N=2) + \mathbb{E}(X|N=3)\mathbb{P}(N=3) \\ &= \frac{1}{3}(2 + 3 + 5 + 2\mathbb{E}(X)).\end{aligned}$$

由此可知 $\mathbb{E}(X) = 10$. \square

1.2.3 条件数学期望的推广与一般化

条件数学期望还可推广到多个条件随机变量情形. 下面的定义以多元连续型随机变量为

例. 对离散情形, 可类似定义.

定义2.3 设 (X, Y_1, \dots, Y_n) 是连续型随机变量且 X 的数学期望存在. 令

$$\mathcal{Y} = \{(y_1, \dots, y_n); f_Y(y_1, \dots, y_n) \neq 0\},$$

$$\Omega_Y = \{\omega; (Y_1(\omega), \dots, Y_n(\omega)) \in \mathcal{Y}\},$$

其中 $f_Y(y_1, \dots, y_n)$ 为 (Y_1, \dots, Y_n) 的边际密度. 若随机变量

$$Z = g(Y_1, Y_2, \dots, Y_n)$$

满足: 对任意 $\omega \in \Omega_Y$,

$$\begin{aligned} Z(\omega) &= g(Y_1(\omega), \dots, Y_n(\omega)) = \mathbb{E}(X|Y_1 = y_1, \dots, Y_n = y_n) \\ &= \int_{-\infty}^{\infty} xf(x, y_1, \dots, y_n, \dots, y_n) dx / f_Y(y_1, \dots, y_n) \end{aligned}$$

其中 $y_k = Y_k(\omega)$, $f(x, y_1, \dots, y_n)$ 为 (X, Y_1, \dots, Y_n) 的联合密度函数, 则称 Z 为 X 关于随机变量 Y_1, \dots, Y_n 的条件数学期望, 记作 $\mathbb{E}(X|Y_1, \dots, Y_n)$.

此时条件数学期望仍遵循定义2.1后对条件数学期望概念的解释和说明, 并且对应的性质2.1仍然成立. 比如

- (1) 若 X 与 Y_1, \dots, Y_n 独立, 则 $\mathbb{E}(X|Y_1, \dots, Y_n) = \mathbb{E}(X)$;
- (2) $\mathbb{E}\left(\sum_{i=1}^n a_i X_i | Y_1, \dots, Y_n\right) = \sum_{i=1}^n a_i \mathbb{E}(X_i | Y_1, \dots, Y_n)$, 其中 a_i 非随机.
- (3) $\mathbb{E}(\Phi(X, Y_1, \dots, Y_n) | Y_1 = y_1, \dots, Y_n = y_n)$
 $= \mathbb{E}(\Phi(X, y_1, \dots, y_n) | Y_1 = y_1, \dots, Y_n = y_n);$
- (4) $\mathbb{E}(\mathbb{E}(\Phi(X, Y_1, \dots, Y_n) | Y_1, \dots, Y_n)) = \mathbb{E}(\Phi(X, Y_1, \dots, Y_n)).$

作为全概率公式的拓展, 此时我们还有如下的所谓平滑性质.

性质2.2 对任意 $n > m$, $\mathbb{E}(\mathbb{E}(h(X) | Y_1, \dots, Y_n) | Y_1, \dots, Y_m) = \mathbb{E}(h(X) | Y_1, \dots, Y_m)$.

证明* 只考虑连续型随机变量的情形.

设 (X, Y_1, \dots, Y_n) 的密度函数为 $f(x, y_1, \dots, y_n)$, 那么 (Y_1, \dots, Y_n) 的密度函数

$$f_{Y_{1-m}}(y_1, \dots, y_n) = \int_{-\infty}^{\infty} f(x, y_1, \dots, y_n) dx,$$

(Y_1, \dots, Y_m) 的密度函数 $f_{Y_{1-m}}(y_1, \dots, y_m)$ 为

$$\int_{\mathbb{R}^{n-m+1}} f(x, y_1, \dots, y_m, y_{m+1}, \dots, y_n) dx dy_{m+1} \dots dy_n.$$

记 $g(Y_1, \dots, Y_n) = \mathbb{E}(h(X) | Y_1, \dots, Y_n)$, 对任意 $k \leq n$, 令

$$\mathcal{Y}_{1-k} = \{(y_1, \dots, y_k) : f_{Y_{1-k}}(y_1, \dots, y_k) \neq 0\}.$$

任取 $(y_1, \dots, y_m) \in \mathcal{Y}_{1-m}$,

$$\mathbb{E}(\mathbb{E}(h(X) | Y_1, \dots, Y_n) | Y_1 = y_1, \dots, Y_m = y_m)$$

$$\begin{aligned}
&= \mathbb{E}(g(Y_1, \dots, Y_n) | Y_1 = y_1, \dots, Y_m = y_m) \\
&= \frac{\int_{-\infty}^{\infty} dy_{m+1} \cdots \int_{-\infty}^{\infty} (g f_{Y_{1-n}})(y_1, \dots, y_{m+1}, \dots, y_n) dy_n}{f_{Y_{1-m}}(y_1, \dots, y_m)}.
\end{aligned}$$

由条件数学期望定义, 当 $(y_1, \dots, y_n) \in \mathcal{Y}_{1-n}$ 时,

$$g(y_1, \dots, y_{m+1}, \dots, y_n) = \frac{\int_{-\infty}^{\infty} h(x) f(x, y_1, \dots, y_{m+1}, \dots, y_n) dx}{f_{Y_{1-n}}(y_1, \dots, y_{m+1}, \dots, y_n)},$$

而当 $(y_1, \dots, y_n) \notin \mathcal{Y}_{1-n}$ 时, 可以令 $g(y_1, \dots, y_{m+1}, \dots, y_n) = 0$. 因此

$$\begin{aligned}
&\mathbb{E}(\mathbb{E}(h(X) | Y_1, \dots, Y_n) | Y_1 = y_1, \dots, Y_m = y_m) \\
&= \frac{\int_{-\infty}^{\infty} dy_{m+1} \cdots \int_{-\infty}^{\infty} dy_n \int_{-\infty}^{\infty} h(x) f(x, y_1, \dots, y_{m+1}, \dots, y_n) dx}{f_{Y_{1-m}}(y_1, \dots, y_m)} \\
&= \mathbb{E}(h(X) | Y_1 = y_1, \dots, Y_m = y_m).
\end{aligned}$$

由条件数学期望定义及其说明可知性质2.2成立. \square

注2.2 条件数学期望还可推广到更一般的情形, 具体的细节不再展开. 要指出的是此后凡涉及随机变量下的条件期望时, 我们总认为它已有恰当定义, 而且相应的性质2.1 和性质2.2也成立.

例2.8 设 X, Y 为独立同分布随机变量, 求 $\mathbb{E}(X|X + Y)$.

解 由于 X, Y 为独立同分布随机变量,

$$\mathbb{E}(Y|X + Y) = \mathbb{E}(Y|Y + X) = \mathbb{E}(X|X + Y).$$

因此

$$\begin{aligned}
2\mathbb{E}(X|X + Y) &= \mathbb{E}(X|X + Y) + \mathbb{E}(Y|X + Y) \\
&= \mathbb{E}(X + Y|X + Y) = X + Y.
\end{aligned}$$

由此可得 $\mathbb{E}(X|X + Y) = (X + Y)/2$. \square

例2.9 设 $\{X_n; n \geq 1\}$ 是一族独立随机变量, 对任意 $n \geq 1$, $S_n = X_1 + \dots + X_n$, 证明对任意 $n \geq 1$

$$\mathbb{E}(S_{n+1}|S_1, \dots, S_n) = \mathbb{E}(S_{n+1}|S_n).$$

证明 由独立性假设可知 $S_{n+1} - S_n = X_{n+1}$ 与 X_1, \dots, X_n 独立, 进而与 S_1, S_2, \dots, S_n 独立, 因此由条件数学期望性质

$$\begin{aligned}
\mathbb{E}(S_{n+1}|S_1, \dots, S_n) &= \mathbb{E}(S_n|S_1, \dots, S_n) + \mathbb{E}(X_{n+1}|S_1, \dots, S_n) \\
&= S_n + \mathbb{E}(X_{n+1}) \\
&= \mathbb{E}(S_n|S_n) + \mathbb{E}(X_{n+1}|S_n) = \mathbb{E}(S_{n+1}|S_n). \quad \square
\end{aligned}$$

例2.10 设某仪器寿命服从参数为 λ 的指数分布, 假定仪器损坏后能及时更换新仪器, 而且仪

器之间的寿命相互没有影响, 问从仪器新装上开始的 t 时间内平均使用的仪器数量.

[分析] 记 $N(t)$ 为 t 时间内使用的仪器数量, 问题所求为 $\mathbb{E}(N(t))$. 记第一个仪器的寿命为 W , 显然, 若 $W = w > t$, 那么 $N(t) = 1$, 而如果 $W = w \leq t$ 且记从 w 到 t 这段时间用的仪器个数为 $N(w, t)$, 那么 $N(t) = 1 + N(w, t)$. 注意到 $N(w, t)$ 只与 w 时刻之后用的新仪器有关, 根据假设, 作为一个随机变量与第一台仪器的寿命 W 无关而且与从 0 开始 $t - W$ 时间内的仪器使用数量 $N(t - w)$ 分布相同, 即

$$\mathbb{E}(N(t)|W = w) = \begin{cases} 1, & w > t, \\ 1 + \mathbb{E}(N(w, t)|W = w), & w \leq t, \end{cases} = \begin{cases} 1, & w > t, \\ 1 + \mathbb{E}(N(t - w)), & w \leq t. \end{cases}$$

解 记 $N(t)$ 为 $[0, t]$ 内使用仪器数, 第一台仪器寿命为 W , 那么 $W \sim \text{Exp}(\lambda)$. 由条件数学期望性质可知

$$\begin{aligned} \mathbb{E}(N(t)) &= \mathbb{E}(\mathbb{E}(N(t)|W)) = \int_0^\infty \mathbb{E}(N(t)|W = w) \lambda e^{-\lambda w} dw \\ &= \int_t^\infty \lambda e^{-\lambda w} dw + \int_0^t (1 + \mathbb{E}(N(t - w))) \lambda e^{-\lambda w} dw. \end{aligned}$$

令 $u(t) = \mathbb{E}(N(t))$, 则

$$u(t) = 1 + \int_0^t \lambda e^{-\lambda(t-s)} u(s) ds = 1 + \lambda e^{-\lambda t} \int_0^t e^{\lambda s} u(s) ds.$$

两边关于 t 求导得,

$$u'(t) = -\lambda(u(t) - 1) + \lambda u(t) = \lambda.$$

故 $u(t) = \lambda t + c$. 再由 $u(0) = \mathbb{E}(N(0)) = 1$ 得 $c = 1$, 从而 $\mathbb{E}(N(t)) = u(t) = 1 + \lambda t$. \square

对任意随机事件 A , 利用其示性函数 $\mathbf{1}_A(\omega) = \begin{cases} 1, & \omega \in A; \\ 0, & \omega \notin A, \end{cases}$ 我们也可以定义随机变量

下的条件概率: 对任意随机事件 A , 称

$$\mathbb{P}(A|Y_1, \dots, Y_n) := \mathbb{E}(\mathbf{1}_A|Y_1, \dots, Y_n).$$

为 A 在随机变量 Y_1, \dots, Y_n 条件下的条件概率. 显然随机变量条件下的条件概率是个 $[0, 1]$ 区间取值的随机变量.

例2.11 设二维连续随机变量的联合分布密度函数

$$f(x, y) = \lambda^2 y e^{-\lambda y(1+x)}, \quad x, y \geq 0,$$

求条件概率 $\mathbb{P}(X < Y|Y)$.

解 对任意 $y \geq 0$, 由定义

$$\mathbb{P}(X < Y|Y = y) = \mathbb{E}(\mathbf{1}_{\{X < Y\}}|Y = y) = \mathbb{E}(\mathbf{1}_{\{X < y\}}|Y = y) = \frac{\int_0^y \lambda^2 y e^{\lambda y(1+x)} dx}{\int_0^\infty \lambda^2 y e^{\lambda y(1+x)} dx}$$

$$= \frac{\lambda(e^{-\lambda y} - e^{-\lambda y(1+y)})}{\lambda e^{-\lambda y}} = 1 - e^{-\lambda y^2},$$

因此 $\mathbb{P}(X < Y|Y) = 1 - e^{-\lambda Y^2}$. \square

与通常的数学期望和方差的关系一样, 利用条件数学期望可定义条件方差:

$$\mathbf{Var}(X|Y) = \mathbb{E}((X - \mathbb{E}(X|Y))^2|Y) = \mathbb{E}(X^2|Y) - (\mathbb{E}(X|Y))^2.$$

显然, 条件方差仍是随机变量. 且对任意 $\omega \in \Omega$, 记 $y = Y(\omega)$,

$$\mathbf{Var}(X|Y)(\omega) = \mathbb{E}((X - \mathbb{E}(X|Y))^2|Y = y) = \mathbb{E}((X - \mathbb{E}(X|Y = y))^2|Y = y).$$

例2.12 接例2.3, 求 $\mathbf{Var}(X|Y)$.

解 由例2.3易知 $\mathbb{E}(X|Y) = (1+Y)/2$, 而且对任意 $y > 0$,

$$\mathbb{E}(X^2|Y = y) = (1+y)^3 \int_0^\infty \frac{3x^2}{(1+x+y)^4} dx = (1+y)^2.$$

因此 $\mathbb{E}(X^2|Y) = (1+Y)^2$, 进而 $\mathbf{Var}(X|Y) = (1+Y)^2 - (1+Y)^2/4 = 3(1+Y)^2/4$. \square

性质2.3 若 X 的二阶矩存在, 那么 $\mathbf{Var}(X) = \mathbb{E}(\mathbf{Var}(X|Y)) + \mathbf{Var}(\mathbb{E}(X|Y))$.

证明 由全概率公式可得

$$\begin{aligned} \mathbf{Var}(X) &= \mathbb{E}((X - \mathbb{E}(X))^2) = \mathbb{E}(\mathbb{E}((X - \mathbb{E}(X))^2|Y)) \\ &= \mathbb{E}(\mathbb{E}((X - \mathbb{E}(X|Y) + \mathbb{E}(X|Y) - \mathbb{E}(X))^2|Y)) \\ &= \mathbb{E}(\mathbb{E}[(X - \mathbb{E}(X|Y))^2|Y]) + \mathbb{E}(\mathbb{E}[(\mathbb{E}(X|Y) - \mathbb{E}(X))^2|Y]) \\ &= \mathbb{E}(\mathbf{Var}(X|Y)) + \mathbb{E}((\mathbb{E}(X|Y) - \mathbb{E}(X))^2) \\ &= \mathbb{E}(\mathbf{Var}(X|Y)) + \mathbf{Var}(\mathbb{E}(X|Y)). \end{aligned} \quad \square$$

例2.13 设 $\{X_t, t \in T\}$ 是一族随机变量, N 是取值在 T 上的随机变量. 若 X_N 是按函数复合方式定义的新的随机变量, 即对任意 ω ,

$$X_N(\omega) := X_{N(\omega)}(\omega),$$

则称 X_N 为复合随机变量. 现假设 $X_i, i = 1, 2, \dots$, 是独立同分布的随机变量, 二阶矩存在. N 是非负整数值的随机变量, 与 $\{X_i\}$ 独立且二阶矩也存在. 令 $S_N = \sum_{k=1}^N X_k$. 求复合随机变量 S_N 的均值与方差.

解 对任意 $\omega \in \Omega$, 记 $n = N(\omega)$. 由独立性和条件期望性质

$$\begin{aligned} \mathbb{E}(S_N|N)(\omega) &= \mathbb{E}\left(\sum_{k=1}^N X_k|N = n\right) = \mathbb{E}\left(\sum_{i=1}^n X_i|N = n\right) = n\mathbb{E}(X_1) \\ \mathbf{Var}(S_N|N)(\omega) &= \mathbb{E}((\sum_{k=1}^N X_k - n\mathbb{E}(X_1))^2|N = n) = \mathbb{E}\left(\left(\sum_{i=1}^n (X_i - \mathbb{E}(X_i))\right)^2|N = n\right) \\ &= \mathbb{E}\left(\left(\sum_{i=1}^n (X_i - \mathbb{E}(X_i))\right)^2\right) = n\mathbf{Var}(X_1). \end{aligned}$$

因此 $\mathbb{E}(S_N|N) = N\mathbb{E}(X_1)$, $\text{Var}(S_N|N) = N\text{Var}(X_1)$. 从而

$$\begin{aligned}\mathbb{E}(S_N) &= \mathbb{E}(\mathbb{E}(S_N|N)) = \mathbb{E}(N)\mathbb{E}(X_1); \\ \text{Var}(S_N) &= \mathbb{E}(\text{Var}(S_N|N)) + \text{Var}(\mathbb{E}(S_N|N)) \\ &= \mathbb{E}(N)\text{Var}(X_1) + [\mathbb{E}(X_1)]^2\text{Var}(N).\end{aligned}$$

□

练习题

2.1 $X_i, i \geq 1$, 是独立同分布的随机变量, 且 $\mathbb{P}(X_1 = 1) = p$, $\mathbb{P}(X_1 = 0) = 1 - p$. 任取整数 $1 \leq k \leq n$, 对任意 $1 \leq i \leq n$, 求

$$\mathbb{P}(X_i = 1 | X_1 + X_2 + \dots + X_n = k).$$

2.2 设二元随机变量 (X, Y) 的联合分布密度函数为 $f(x, y) = 6x^2y$, $0 < x, y < 1$. 求 $\mathbb{E}(X|Y)$, $\mathbb{E}(X|X+Y)$.

2.3 设抛硬币出现正反面的概率分别是 $p, 1 - p$, 每次抛硬币都是独立的. 假定直至连续出现 k 次正面抛硬币才结束, 证明抛掷硬币次数 N 的平均值

$$\mathbb{E}(N) = \frac{1 - p^k}{p^k(1 - p)}.$$

2.4 一对新婚夫妇希望他们至少有一个男孩和一个女孩而且只要男孩女孩都有了就不再生育. 现假设他们一直都有生育能力而且男孩的出生率为 p , $0 < p < 1$. 求他们孩子中男孩的预期比例.

2.5* 在连续型随机变量情形下证明性质 2.1 中 (2), (3), (4).

2.6 设 X, Y 是两有界随机变量且 $\mathbb{E}(X|Y) = Y$, $\mathbb{E}(Y|X) = X$, 证明 $\mathbb{P}(X = Y) = 1$.

1.3 特征函数、拉普拉斯变换与母函数

特征函数, Laplace变换与母函数是我们刻画分布函数的重要工具.

1.3.1 特征函数

定义3.1 设随机变量 X 的分布函数为 F . 我们称复值函数

$$\begin{aligned}\psi_X(t) &= \mathbb{E}(e^{itX}) = \int_{-\infty}^{\infty} e^{itx} dF(x) \\ &= \int_{-\infty}^{\infty} \cos(tx) dF(x) + i \int_{-\infty}^{\infty} \sin(tx) dF(x) \\ &= \mathbb{E}(\cos(tX)) + i\mathbb{E}(\sin(tX)), \quad t \in (-\infty, \infty) \text{ } i \text{ 为虚数单位.}\end{aligned}$$

为 X 的特征函数.

由定义可知对任意 $t \in \mathbb{R}$, $|\psi_X(t)| \leq \psi_X(0) = 1$. 而且作为变量 t 的函数 ψ_X 在 \mathbb{R} 上一致连续.

特征函数与分布函数之间有如下关联:

定理3.1(唯一性定理) 特征函数与概率分布相互唯一确定. 即不同的分布函数有不同的特征函数; 特征函数不同则对应的分布函数也不同.

定理3.2(连续性定理) 设随机变量 X_n 的特征函数为 $\psi_{X_n}(t)$. 那么存在随机变量 X 使得 $X_n \xrightarrow{d} X$ 的充要条件是对任意 $t \in \mathbb{R}$, $\psi_{X_n}(t)$ 收敛而且 $\lim_{t \rightarrow 0} \lim_{n \rightarrow \infty} \psi_{X_n}(t) = 1$.

性质3.3 (1) $\overline{\psi_X(t)} = \psi_X(-t) = \psi_{-X}(t)$; (2) $\psi_{aX+b}(t) = \psi_X(at)e^{ibt}$; (3) 若 X, Y 独立, 那么 $\psi_{X+Y}(t) = \psi_X(t)\psi_Y(t)$, $t \in \mathbb{R}$.

利用特征函数我们还可以方便地求出 X 的各阶原点矩.

性质3.4 若 X 的 n 阶绝对矩 $\mathbb{E}(|X|^n) < \infty$, 那么对任意 $k \leq n$, $\mathbb{E}(X^k) = i^{-k}\psi^{(k)}(0)$.

特征函数也可推广到多元随机变量的情形. 设 $X = (X_1, \dots, X_n)$ 为 n 元随机变量, 联合分布函数为 $F(x_1, \dots, x_n)$, 称 n 元复值函数

$$\begin{aligned}\psi_{(X_1, X_2, \dots, X_n)}(t_1, \dots, t_n) &= \mathbb{E}(e^{i(t_1X_1 + \dots + t_nX_n)}) \\ &= \int_{-\infty}^{\infty} e^{i(t_1x_1 + \dots + t_nx_n)} dF(x_1, \dots, x_n)\end{aligned}$$

为 (X_1, \dots, X_n) 的特征函数, 其中 $t_1, \dots, t_n \in \mathbb{R}$.

与一元随机变量的特征函数一样, 多元特征函数也具有唯一性.

定理3.1'(唯一性定理) n 元特征函数与 n 维随机变量的分布函数相互唯一确定.

由此我们可得如下利用特征函数判别随机变量独立性的方法.

性质3.5 随机变量 X_1, \dots, X_n 相互独立当且仅当对任意的 $t_1, \dots, t_n \in \mathbb{R}$

$$\psi_{(X_1, X_2, \dots, X_n)}(t_1, \dots, t_n) = \prod_{i=1}^n \psi_{X_i}(t_i).$$

几个常用的分布的特征函数如下：

- (1) 指数分布 $\text{Exp}(\lambda)$ 的特征函数为 $\psi(t) = \lambda/(\lambda - it)$;
- (2) 伽玛分布 $\text{Ga}(a, \lambda)$ 的特征函数为 $\psi(t) = [\lambda/(\lambda - it)]^a$;
- (3) 正态分布 $\text{N}(\mu, \sigma^2)$ 的特征函数是 $\psi(t) = \exp\left\{\text{i}\mu t - \frac{\sigma^2 t^2}{2}\right\}$.

1.3.2 拉普拉斯变换

对于非负随机变量分布的刻画, 用所谓的拉普拉斯(Laplace)变换会更方便些.

定义3.1 若 X 为非负随机变量, 称函数 $L(\theta) = \mathbb{E}(e^{-\theta X})$ 为 X 的拉普拉斯变换, 其中变量 $\theta \in [0, +\infty)$.

若记 X 的分布函数为 F , 通常也把拉普拉斯变换 $L(\theta)$ 记作

$$L(\theta) = \int_0^\infty e^{-\theta x} dF(x),$$

此时也称 $L(\theta)$ 是分布 F 的拉普拉斯变换.

当 $F(x)$ 是具有密度为 $f(x)$ 的连续分布时,

$$L(\theta) = \int_0^\infty e^{-\theta x} f(x) dx,$$

当 $F(x)$ 是具有分布列 $p_i = \mathbb{P}(X = x_i)$, $i = 1, 2, \dots, \infty$, 的离散分布时,

$$L(\theta) = \sum_{i=1}^{\infty} e^{-\theta x_i} p_i,$$

特别若 x_i 取非负整数, 令 $p_k = \mathbb{P}(X = k)$, 那么

$$L(\theta) = \sum_{k=0}^{\infty} e^{-\theta k} p_k.$$

定理3.6 (拉普拉斯变换反演公式) 设 F 是 $[0, \infty)$ 上的分布函数, $L(\theta)$ 是 F 的拉普拉斯变换, 那么对 F 的任意连续点 x , 有

$$F(x) = \lim_{n \rightarrow \infty} \sum_{k=0}^{\lfloor nx \rfloor} \frac{(-1)^k}{k!} n^k L^{(k)}(n).$$

证明* 只证明 $F(x)$ 为连续分布的情形. 设其密度函数为 f .

对任意 $\theta > 0$, 可以对 L 求 k 阶导数,

$$L^{(k)}(\theta) = \int_0^\infty (-x)^k e^{-\theta x} f(x) dx.$$

对任意给定的 $x \geq 0$, 取 $\theta = n$, 则

$$\sum_{k=0}^{\lfloor nx \rfloor} \frac{(-1)^k}{k!} n^k L^{(k)}(n) = \int_0^\infty \sum_{k=0}^{\lfloor nx \rfloor} e^{-ny} \frac{(ny)^k}{k!} f(y) dy.$$

设 $X_i, i \geq 1$ 为独立同分布的随机变量, 服从强度为 y 的泊松分布, 那么 $\mathbb{E}(X_1) = \text{Var}(X_1) = y$ 且

$$X_1 + X_2 + \cdots + X_n$$

服从强度为 ny 的泊松分布. 此时

$$\mathbb{P}(X_1 + X_2 + \cdots + X_n \leq \lfloor nx \rfloor) = \sum_{k=0}^{\lfloor nx \rfloor} e^{-ny} \frac{(ny)^k}{k!}.$$

对任意 $\epsilon > 0$, 当 $y - x \geq \epsilon$ 时, 由切比雪夫不等式

$$\begin{aligned} \sum_{k=0}^{\lfloor nx \rfloor} e^{-ny} \frac{(ny)^k}{k!} &= \mathbb{P}\left(\frac{X_1 + X_2 + \cdots + X_n - ny}{n} \leq \frac{\lfloor nx \rfloor - ny}{n}\right) \\ &\leq \mathbb{P}\left(\frac{|X_1 + X_2 + \cdots + X_n - ny|}{n} \geq \frac{|\lfloor nx \rfloor - ny|}{n}\right) \\ &\leq \frac{n^2}{(ny - \lfloor nx \rfloor)^2} \frac{\text{Var}(X_1)}{n} \leq \frac{y}{n(y - x)^2} \leq \frac{1}{n} \left(\frac{x}{\epsilon^2} + \frac{1}{\epsilon}\right). \end{aligned}$$

另一方面, 当 $y - x \leq -\epsilon$ 时

$$\begin{aligned} 1 - \sum_{k=0}^{\lfloor nx \rfloor} e^{-ny} \frac{(ny)^k}{k!} &= \mathbb{P}(X_1 + X_2 + \cdots + X_n > \lfloor nx \rfloor) \\ &\leq \mathbb{P}(X_1 + X_2 + \cdots + X_n \geq nx) \\ &= \mathbb{P}\left(\frac{X_1 + X_2 + \cdots + X_n - ny}{n} \geq x - y\right) \\ &\leq \frac{1}{(x - y)^2} \frac{y}{n} \leq \frac{x}{n\epsilon^2}. \end{aligned}$$

因此

$$\begin{aligned} \left| \sum_{k=0}^{\lfloor nx \rfloor} \frac{(-1)^k}{k!} n^k L^{(k)}(n) - F(x) \right| &\leq \int_0^{(x-\epsilon)\vee 0} \left| \sum_{k=0}^{\lfloor nx \rfloor} e^{-ny} \frac{(ny)^k}{k!} - 1 \right| f(y) dy \\ &\quad + \int_{x+\epsilon}^{\infty} \sum_{k=0}^{\lfloor nx \rfloor} e^{-ny} \frac{(ny)^k}{k!} f(y) dy + 2 \int_{(x-\epsilon)\vee 0}^{x+\epsilon} f(y) dy \\ &\leq \frac{1}{n} \left(\frac{x}{\epsilon^2} + \frac{1}{\epsilon}\right) + 2(F(x + \epsilon) - F(x - \epsilon)). \end{aligned}$$

令 $n \rightarrow \infty$, 我们可得

$$\limsup_{n \rightarrow \infty} \left| \sum_{k=0}^{\lfloor nx \rfloor} \frac{(-1)^k}{k!} n^k L^{(k)}(n) - F(x) \right| \leq 2(F(x + \epsilon) - F(x - \epsilon)).$$

由于 ϵ 的任意性以及 $\lim_{\epsilon \rightarrow 0} F(x + \epsilon) - F(x - \epsilon) = 0$, 我们可得

$$\limsup_{n \rightarrow \infty} \left| \sum_{k=0}^{\lfloor nx \rfloor} \frac{(-1)^k}{k!} n^k L^{(k)}(n) - F(x) \right| = 0.$$

因此

$$\lim_{n \rightarrow \infty} \sum_{k=0}^{\lfloor nx \rfloor} \frac{(-1)^k}{k!} n^k L^{(k)}(n) = F(x).$$

由定理3.2 我们可以立即得到如下的拉普拉斯变换的唯一性定理.

定理3.7 $[0, \infty)$ 上不同的概率分布有不同的拉普拉斯变换.

对于拉普拉斯变换也有所谓的连续性定理. 定理的证明超出了本课程范畴, 省略. 感兴趣的同学可以参阅参考书目 [10]和 [1]中有关内容.

定理3.8 设非负随机变量 X_n 的拉普拉斯变换为 $L_{X_n}(\theta)$. 那么存在r.v. X 使得 $X_n \xrightarrow{d} X$ 的充要条件是对任意 $\theta > 0$, $L_{X_n}(\theta)$ 收敛而且 $\lim_{\theta \rightarrow 0} \lim_{n \rightarrow \infty} L_{X_n}(\theta) = 1$.

注 定理3.8可以推广为如下的所谓广义连续性定理: $X_n \xrightarrow{d} X$ 当且仅当存在 $\lambda > 0$ 使得对任意 $\theta > \lambda$, $L_{X_n}(\theta) \rightarrow L_X(\theta)$.

此外, 由拉普拉斯变换定义容易验证如下性质成立:

性质3.9 (1) 对任意 $\theta > 0$, $0 \leq L_X(\theta) \leq L_X(0) = 1$;

(2) 对任意 $a > 0, b > 0$, $L_{aX+b}(\theta) = L_X(a\theta)e^{-b\theta}$;

(3) 若 X, Y 独立非负随机变量, 那么 $L_{X+Y}(\theta) = L_X(t)L_Y(\theta)$, $t \geq 0$;

(4) 对任意正整数 k , $\mathbb{E}(X^k) = (-1)^k L_X^{(k)}(0)$, 其中 $L_X^{(k)}$ 表示 L_X 的 k 阶导数.

例3.1 设 X 服从均匀分布 $U(0, 1)$, 那么 $L_X(\theta) = (1 - e^{-\theta})/\theta$.

例3.2 若 X 指数分布 $Exp(\lambda)$, 那么

$$L_X(\theta) = \int_0^\infty e^{-\theta x} \lambda e^{-\lambda x} dx = \lambda / (\theta + \lambda).$$

例3.3 若 X 服从伽玛分布 $Ga(a, \lambda)$, 那么

$$L_X(\theta) = \int_0^\infty e^{-\theta x} \frac{\lambda^a x^{a-1}}{\Gamma(a)} e^{-\lambda x} dx = \int_0^\infty \frac{\lambda^a x^{a-1}}{\Gamma(a)} e^{-(\theta+\lambda)x} dx = \left(\frac{\lambda}{\theta + \lambda} \right)^a.$$

例3.4 设 X_n 服从二项分布 $b(n, \frac{1}{n})$, 那么对任意 $\theta > 0$, 当 $n \rightarrow \infty$

$$L_{X_n}(\theta) = \sum_{k=0}^n C_n^k \left(1 - \frac{1}{n}\right)^{n-k} \frac{1}{n^k} e^{-\theta k} = \left(1 - \frac{1 - e^{-\theta}}{n}\right)^n \rightarrow e^{-(1 - e^{-\theta})}.$$

注意 $e^{-(1 - e^{-\theta})}$ 是强度为1的泊松分布的拉普拉斯变换. 因此当 $n \rightarrow \infty$ 时, X_n 依分布收敛到一个强度为1的泊松分布的随机变量. \square

1.3.3 母函数

在研究只取有限或无限个非负整数值的随机变量时, 用所谓母函数来代替特征函数或拉普拉斯变换较为方便.

定义3.3 设 X 为非负整数值的随机变量, 称函数 $\phi_X(s) = \mathbb{E}(s^X)$ 为 X 的(概率)母函数, 其中变量 $s \in (-1, 1)$.

设 X 的分布列为

$$p_k = \mathbb{P}(X = k), \quad k \geq 0,$$

那么

$$\phi_X(s) = \sum_{k=0}^{\infty} p_k s^k.$$

对照母函数和Laplace变换, 容易看出所谓母函数就是 X 为非负整数值的随机变量条件下的Laplace变换, 只不过将其中的 $e^{-\theta}$ 记作 s . 因此母函数也拥有Laplace变换的性质, 我们不再赘述, 请读者自己补充. 下面我们主要介绍和解释母函数性质的一些变化.

性质3.10 若非负整数值随机变量 X 的 n 阶矩存在, 那么对任意 $s \in [-1, 1]$, 母函数 ψ_X 的 k 阶导数 $\phi_X^{(k)}(s)$ 存在, 且 X 的 n 阶矩可由 $\phi_X(s)$ 前 n 阶导数在 $s = 1$ 表示. 特别

$$\mathbb{E}(X) = \phi'_X(1), \quad \mathbb{E}(X^2) = \phi''_X(1) + \phi'_X(1).$$

证明 由数学分析中幂级数一致收敛性质可知结果成立, 细节请读者补充. \square

定理3.11(反演公式) 若非负整数值随机变量 X 的母函数为 $\psi_X(s)$. 那么对任意 $k \geq 0$

$$\mathbb{P}(X = k) = \phi_X^{(k)}(0)/k!.$$

证明 由 $\phi_X(s) = \sum_{n=0}^{\infty} p_n s^n$ 可知

$$\phi_X^{(k)}(s) = \sum_{n=k}^{\infty} p_n s^{n-k} n(n-1)\cdots(n-k+1).$$

因此 $\phi_X^{(k)}(0) = k! p_k$. \square

例3.5 设 X 服从几何分布 $\text{Ge}(p)$, 那么

$$\phi_X(s) = \sum_{k=0}^{\infty} s^k p(1-p)^k = p \sum_{k=0}^{\infty} s^k (1-p)^k = \frac{p}{1-(1-p)s}.$$

例3.6 设 $X_i, i \geq 0$ 是独立随机变量, 且服从均匀分布 $U(0, 1)$. Y 与 $X_k, k \geq 1$ 独立, 服从几何分布 $\text{Ge}(p)$, 令 $S = \sum_{i=0}^Y X_i$, 求 S 的拉普拉斯变换 $L_S(\theta)$.

解 由定义和条件数学期望性质

$$\begin{aligned} L_S(\theta) &= \mathbb{E}(e^{-\theta S}) = \mathbb{E}(\mathbb{E}(e^{-\theta S}|Y)) = \mathbb{E}(\mathbb{E}(e^{-\theta \sum_{i=0}^Y X_i}|Y)) \\ &= \sum_{k=0}^{\infty} \mathbb{E}(e^{-\theta \sum_{i=0}^Y X_i}|Y = k)p(1-p)^k = \sum_{k=0}^{\infty} \mathbb{E}(e^{-\theta \sum_{i=0}^k X_i}|Y = k)p(1-p)^k. \end{aligned}$$

由于

$$\mathbb{E}(e^{-\theta \sum_{i=0}^k X_i}|Y = k) = \mathbb{E}(e^{-\theta \sum_{i=0}^k X_i}) = [\mathbb{E}(e^{-\theta X_1})]^{k+1} = \left(\frac{1-e^{-\theta}}{\theta}\right)^{k+1},$$

因此

$$L_S(\theta) = \sum_{k=1}^{\infty} \left(\frac{1-e^{-\theta}}{\theta}\right)^k p(1-p)^{k-1} = \frac{p(1-e^{-\theta})}{\theta - (1-p)(1-e^{-\theta})}. \quad \square$$

容易将母函数的定义推广到多元非负整数值的随机变量, 得到联合分布的母函数. 为简单, 下面仅介绍二元随机变量情形.

定义3.4 设 X_1, X_2 为非负整数值的随机变量, 联合分布列为

$$p_{n,m} = \mathbb{P}(X_1 = n, X_2 = m), \quad n, m \geq 0$$

称 $[-1, 1] \times [-1, 1]$ 上的二元函数

$$\phi_{(X_1, X_2)}(s, t) = \mathbb{E}(s^{X_1} t^{X_2}) = \sum_{n=0}^{\infty} \sum_{m=0}^{\infty} s^n t^m p_{n,m}.$$

为二元随机变量 (X_1, X_2) 的母函数.

与定理3.10一样, 此时我们有反演公式

$$p_{n,m} = \left. \frac{\partial^{n,m} \phi_{(X_1, X_2)}(s, t)}{\partial s^n \partial t^m} \right|_{\substack{s=0 \\ t=0}}.$$

性质3.12 非负整数值随机变量 X_1, X_2 相互独立当且仅当对任意的 $s, t \in [-1, 1]$

$$\phi_{(X_1, X_2)}(s, t) = \phi_{X_1}(s) \phi_{X_2}(t) = \phi_{(X_1, X_2)}(s, 1) \phi_{X_2}(1, t).$$

注3.1 拉普拉斯变换和母函数可以不做任何改变地适用于以正概率取 $+\infty$ 的非负随机变量.

此时, 独立随机变量和的拉普拉斯变换/母函数仍为各自拉普拉斯变换/母函数的乘积.

练习题

3.1 在 X 是连续型非负随机变量条件下证明其拉普拉斯变换 $L_X(t)$ 在 $[0, +\infty)$ 内是一致连续的.

3.2 设 X 是连续型非负随机变量, 分布函数为 $F(x)$, 证明对任意 $t > 0$, 其拉普拉斯变换 $L_X(t)$ 满足

$$\frac{1 - L_X(t)}{t} = \int_0^\infty e^{-tx} (1 - F(x)) dx.$$

3.3 $X_i, i \geq 1$, 独立且服从指数分布 $\text{Exp}(\lambda)$. N 是服从泊松分布 $P(\lambda)$ 且与 $X_k, k \geq 1$ 独立.

令 $S = \sum_{i=1}^N X_i$, 求 S 的拉普拉斯变换 $L_S(\theta)$.

3.4 X 是连续型非负随机变量, $\mathbb{E}(X^{2n}) < +\infty$. 对任意 $k \leq 2n$, 令 $\mu_k = \mathbb{E}(X^k)$. 证明对任意 $\theta > 0$,

$$\sum_{k=0}^{2n-1} \frac{(-\theta)^k \mu_k}{k!} \leq L_X(\theta) \leq \sum_{k=0}^{2n} \frac{(-\theta)^k \mu_k}{k!}.$$

3.5 设独立同分布的标准正态分布随机变量簇 $W_i, i \geq 1$ 与 $\{N(n), n \geq 1\}$ 独立, 其中 $N(n)$ 服从泊松分布 $P(n)$. 令 $Y_n = \sum_{k=1}^{N(n)} W_k$. 求 Y_n 的特征函数, 并证明当 $n \rightarrow +\infty$ 时, Y_n/\sqrt{n} 依分布收敛到一个服从标准正态分布的随机变量.

3.6 记非负整数值随机变量 ξ 的母函数为 $A(s)$. 证明若 $\mathbb{E}(\xi) > 1$ 且 $\mathbb{P}(\xi = 0) > 0$, 那么在区间 $[0, 1)$ 内 $A(s) = s$ 有唯一解; 若 $\mathbb{E}(\xi) \leq 1$ 且 $\mathbb{P}(\xi = 1) < 1$, 那么 $A(s) = s$ 在 $[0, 1)$ 内无解.

3.7 证明性质3.9.

1.4 收敛性与极限定理

在初等概率论中我们还简单地研究过无穷可列多随机变量的收敛问题. 主要介绍了三类收敛, 并得到了一些大数定律与中心极限定理. 为了后续方便, 这一节我们将对这些内容做一些展开和补充.

1.4.1 三类收敛的定义和极限定理

设 X_1, \dots, X_n, \dots 为概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上一列随机变量.

- (1) 依分布收敛: 对任意 n , 记 X_n 的分布函数为 $F_n(x)$, 称 X_n 依分布收敛到随机变量 X (记作 $X_n \xrightarrow{d} X$), 若对 X 分布函数 $F(x)$ 的每个连续点 x 都有

$$\lim_{n \rightarrow \infty} F_n(x) = F(x).$$

- (2) 依概率收敛: 称 X_n 依概率收敛到随机变量 X (记作 $X_n \xrightarrow{P} X$), 若对任意 $\varepsilon > 0$,

$$\lim_{n \rightarrow \infty} \mathbb{P}(|X_n - X| > \varepsilon) = 0.$$

- (3) 几乎必然(处处)收敛: 称随机变量 X_n 几乎必然(几乎处处, 以概率1)收敛到随机变量 X (记作 $X_n \xrightarrow{a.s.} X$), 若

$$\mathbb{P}\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1,$$

即至多存在一个例外集 $A \in \Omega$ 使得 $\mathbb{P}(A) = 0$ 且对任意 $\omega \in \Omega \setminus A$, 数列 $X_n(\omega) \rightarrow X(\omega)$.

注4.1 依概率收敛和几乎必然收敛意义下的极限, 在几乎处处相等意义下是唯一的. 此外

- (1) $X_n \xrightarrow{d} X$ 当且仅当 X_n 的特征函数 $\psi_n(t)$ 点点收敛到 X 的特征函数 $\psi(t)$. 若 X_n 是非负随机变量, 还可将特征函数用 Laplace 变换代替.

- (2) 对几乎必然收敛, 用 $\varepsilon - N$ 语言可表述成 $X_n \xrightarrow{a.s.} X$ 当且仅当存在一个集合 $A \in \mathfrak{F}$ 满足 $\mathbb{P}(A) = 0$, 对任意 $\omega \in \Omega \setminus A$ 以及任意 $\varepsilon > 0$, 存在一个 $N = N(\varepsilon, \omega)$ 使得当 $n > N$ 时 $|X_n(\omega) - X(\omega)| < \varepsilon$.

利用这三种极限, 初等概率论已经介绍了如下的大数定律和中心极限定理.

定理4.1 (弱大数定律) 设 $X_n, n \geq 1$, 为一列独立同分布的随机变量, 若 $\mathbb{E}(|X_n|) < \infty$, 那么依概率有

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n X_k = \mathbb{E}(X_1).$$

定理4.2 (中心极限定理) 设 $X_n, n \geq 1$, 为一列独立同分布的随机变量, 二阶矩存在, 即其均

值和标准差分别为 μ 和 σ , 那么对任意 $x \in (-\infty, +\infty)$

$$\mathbb{P}\left(\frac{\sum_{i=1}^n(X_i - \mu)}{\sigma\sqrt{n}} \leq x\right) \rightarrow \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du,$$

即 $\frac{\sum_{i=1}^n(X_i - \mu)}{\sigma\sqrt{n}} \xrightarrow{d} N(0, 1)$, 其中 $N(0, 1)$ 表示一个服从标准正态分布的随机变量.

极限与收敛性是研究和了解随机过程性质的常用手段. 为此我们对几乎必然收敛和依概率收敛做些必要的补充.

1.4.2 Borel-Cantelli 引理

引理4.4 设 X, X_1, X_2, \dots 为一列随机变量, 令

$$A_{n,m} = \{|X_n - X| < \frac{1}{m}\},$$

那么

$$\{\lim_{n \rightarrow \infty} X_n = X\} = \bigcap_{m=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n \geq N} A_{n,m}.$$

证明 任取 $\omega \in \{\lim_{n \rightarrow \infty} X_n = X\}$, 那么对任意 $m > 0$, 存在 $N(m, \omega)$, 当 $n \geq N$ 时, $|X_n(\omega) - X(\omega)| < 1/m$, 即

$$\omega \in \{|X_n - X| < \frac{1}{m}\},$$

故

$$\omega \in \bigcap_{n \geq N(m, \omega)} \{|X_n - X| < \frac{1}{m}\} \subset \bigcup_{N=1}^{\infty} \bigcap_{n \geq N} \{|X_n - X| < \frac{1}{m}\}.$$

再由 m 的任意性可得

$$\omega \in \bigcap_{m=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n \geq N} \{|X_n - X| < \frac{1}{m}\} = \bigcap_{m=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n \geq N} A_{n,m}$$

反之, 任取 $\omega \in \bigcap_{m=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n \geq N} A_{n,m}$. 对任意 $m > 1$, 存在 N , 当 $n > N$ 时 $\omega \in A_{n,m}$. 这表明

$$|X_n(\omega) - X(\omega)| \leq \frac{1}{m}.$$

所以 $\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$, 即 $\omega \in \{\lim_{n \rightarrow \infty} X_n = X\}$. 因此引理结论成立. \square

定理4.5 设 X, X_1, X_2, \dots 为一列随机变量, 下列结论等价:

- (1) $X_n \xrightarrow{a.s.} X$;
- (2) $\mathbb{P}(\bigcup_{m=1}^{\infty} \bigcap_{N=1}^{\infty} \bigcup_{n \geq N} \{|X_n - X| \geq \frac{1}{m}\}) = 0$;
- (3) 对任意 $\varepsilon > 0$, $\mathbb{P}(\bigcap_{N=1}^{\infty} \bigcup_{n \geq N} \{|X_n - X| \geq \varepsilon\}) = 0$;
- (4) 对任意 $\varepsilon > 0$, $\lim_{N \rightarrow \infty} \mathbb{P}(\bigcup_{n \geq N} \{|X_n - X| \geq \varepsilon\}) = 0$.

证明 (1) \Leftrightarrow (2): 引理4.4的自然推论.

(2) \Rightarrow (3): 显然成立,

(3) \Rightarrow (2): 注意到对任意 $m > 0$, 存在 $\varepsilon > 0$ 使得 $1/m > \varepsilon$, 从而由(3)可知

$$\mathbb{P}\left(\bigcap_{N=1}^{\infty} \bigcup_{n \geq N} \{|X_n - X| \geq \frac{1}{m}\}\right) = 0.$$

因此

$$\mathbb{P}\left(\bigcup_{m=1}^{\infty} \bigcap_{N=1}^{\infty} \bigcup_{n \geq N} \{|X_n - X| \geq \frac{1}{m}\}\right) \leq \sum_{m=1}^{\infty} \mathbb{P}\left(\bigcap_{N=1}^{\infty} \bigcup_{n \geq N} \{|X_n - X| \geq \frac{1}{m}\}\right) = 0.$$

即(2)成立.

(3) \Leftrightarrow (4): 此时注意到

$$\bigcup_{n \geq N+1} \{|X_n - X| \geq \varepsilon\} \subset \bigcup_{n \geq N} \{|X_n - X| \geq \varepsilon\}.$$

由概率连续性,

$$\mathbb{P}\left(\bigcap_{N=1}^{\infty} \bigcup_{n \geq N} \{|X_n - X| \geq \varepsilon\}\right) = \lim_{N \rightarrow \infty} \mathbb{P}\left(\bigcup_{n \geq N} \{|X_n - X| \geq \varepsilon\}\right) = 0,$$

从而(3)与(4)等价. \square

注4.2 注意到若 $\omega \in \bigcap_{n=1}^{\infty} \bigcup_{k \geq n} A_k$, 则意味着对任意 $n > 1$, 至少存在一个 A_k , $k > n$, 使得 $\omega \in A_k$, 反之也成立. 这意味着, 事件 $\bigcap_{n=1}^{\infty} \bigcup_{k \geq n} A_k$ 发生当且仅当有无穷多个 A_k 事件发生. 即

$$\bigcap_{n=1}^{\infty} \bigcup_{k \geq n} A_k = \{\text{无穷多个} A_k \text{事件发生}\} \stackrel{\Delta}{=} \{A_k, \text{i.o.}\}$$

其中 i.o 是 infinitely occur 的缩写.

定理4.6(Borel-Cantelli引理) 设 A_1, A_2, \dots 是 $(\Omega, \mathfrak{F}, \mathbb{P})$ 中一列随机事件, $p_k = \mathbb{P}(A_k)$,

- 1) 若 $\sum_{k=1}^{\infty} p_k < \infty$, 那么 $\mathbb{P}(A_k, \text{i.o.}) = 0$;
- 2) 若 $\sum_{k=1}^{\infty} p_k = \infty$ 且 A_k 相互独立, 那么 $\mathbb{P}(A_k, \text{i.o.}) = 1$.

证明 1) 当 $\sum_{k=1}^{\infty} p_k < \infty$ 时, 对任意 $\varepsilon > 0$ 存在正整数 N 使得

$$0 \leq \mathbb{P}\left(\bigcap_{n=1}^{\infty} \bigcup_{k \geq n} A_k\right) \leq \mathbb{P}\left(\bigcup_{k \geq N} A_k\right) \leq \sum_{k \geq N} \mathbb{P}(A_k) = \sum_{k \geq N} p_k < \varepsilon.$$

令 $\varepsilon \rightarrow 0$ 可得 $\mathbb{P}(A_k, \text{i.o.}) = 0$.

2) 由不等式 $1 - x \leq e^{-x}$ 及随机事件独立性可得, 对任意 $n \geq 1$

$$\begin{aligned} 0 \leq \mathbb{P}\left(\bigcap_{k \geq n} \bar{A}_k\right) &= \prod_{k \geq n} \mathbb{P}(\bar{A}_k) = \prod_{k \geq n} (1 - \mathbb{P}(A_k)) \\ &\leq \prod_{k \geq n} e^{-p_k} = e^{-\sum_{k \geq n} p_k} = 0 \end{aligned}$$

因此 $\mathbb{P}(\bigcup_{n \geq 1} \bigcap_{k \geq n} \bar{A}_k) = 0$, 即 $\mathbb{P}(A_k, \text{i.o.}) = 1$. \square

注3.3 由定理4.5和定理4.6可知, 若对任意 $\varepsilon > 0$

$$\sum_{n=1}^{\infty} \mathbb{P}(|X_n - X| > \varepsilon) < \infty, \quad (1.4.1)$$

那么 $X_n \xrightarrow{a.s.} X$. (1.4.1) 也是我们常用的判断几乎必然收敛的充分条件.

性质4.7 若 $X_n \xrightarrow{P} X$, 那么存在 $\{X_n\}$ 的一个子列 $\{X_{n_k}\}$ 使得

$$X_{n_k} \xrightarrow{a.s.} X.$$

证明 因为 $X_n \xrightarrow{P} X$, 对任意 $k \geq 1$, 由 $\mathbb{P}(|X_n - X| > 1/2^k) \rightarrow 0$ 可知存在 n_k 使得

$$\mathbb{P}(|X_{n_k} - X| > 1/2^k) < 1/2^k$$

而且 n_k 单调不降. 由此, 对任意 $\varepsilon > 0$, 令 M 为正常数使得 $\varepsilon > 1/2^M$,

$$\begin{aligned} \sum_{k=1}^{\infty} \mathbb{P}(|X_{n_k} - X| > \varepsilon) &\leq \sum_{k=1}^M \mathbb{P}(|X_{n_k} - X| > \varepsilon) + \sum_{k=M+1}^{\infty} \mathbb{P}(|X_{n_k} - X| > 1/2^k) \\ &\leq M + 1 < \infty, \end{aligned}$$

即(1.4.1)对序列 $\{X_{n_k}\}$ 成立, 从而推论成立. \square

例4.1 设 $X = \{X_k, k \geq 1\}$ 为独立同分布的随机变量, 且 $X_k \sim b(1, p)$, 试用 Borel-Cantelli 引理证明

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n X_k = p, \quad \text{a.s.} \quad (1.4.2)$$

证明 对任意 $\varepsilon > 0$, 令

$$A_k = \left\{ \left| \frac{1}{k} \sum_{i=1}^k X_i - p \right| > \varepsilon \right\},$$

那么

$$\mathbb{P}(A_k) = \mathbb{P}\left(\left| \sum_{i=1}^k (X_i - p) \right| > k\varepsilon\right) \leq \frac{1}{k^4 \varepsilon^4} \mathbb{E}\left(\left(\sum_{i=1}^k (X_i - p) \right)^4\right)$$

直接计算可知

$$\mathbb{E}\left(\left(\sum_{i=1}^k (X_i - p) \right)^4\right) = kpq(p^3 + q^3) + 3k(k-1)p^2q^2. \quad (1.4.3)$$

因此 $\sum_{k=1}^{\infty} \mathbb{P}(A_k) < \infty$. 所以(1.4.2)成立. \square

事实上例4.1的结论对一阶矩存在的独立同分布的随机变量序列都成立. 我们不加证明地给出如下的所谓强大数定律.

定理4.3 (强大数定律) 设 $X_n, n \geq 1$, 为一列独立同分布的随机变量, 若 $\mathbb{E}(|X_n|) < \infty$, 那么

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n X_k = \mathbb{E}(X_1), \quad \text{a.s.}$$

1.4.3 柯西基本列*

定义4.1 称随机变量序列 $\{X_n\}$ 是几乎必然意义下的基本列或柯西(Cauchy)列, 若至多存在一个零概率集 A , 使得对任意 $\omega \in \Omega \setminus A$ 以及任意 $\varepsilon > 0$, 存在一个 $N = N(\varepsilon, \omega)$ 使得当 $n, m > N$ 时 $|X_n(\omega) - X_m(\omega)| < \varepsilon$.

显然, 由于收敛的数列当且仅当它是柯西数列我们容易推得

命题4.8 $\{X_n\}$ 几乎必然收敛当且仅当 $\{X_n\}$ 是几乎必然收敛意义下的基本列.

与定理3.5类似, 我们有如下结果. 证明请读者自己补充.

定理4.9 设 X_1, X_2, \dots 为一列随机变量, 下列结论等价:

(1) $\{X_n\}$ 是几乎必然意义下的基本列

(2) 对任意 $\varepsilon > 0$,

$$\mathbb{P}\left(\bigcap_{n=1}^{\infty} \bigcup_{v=1}^{\infty} \{|X_{n+v} - X_n| \geq \varepsilon\}\right) = 0.$$

(3) 对任意 $\varepsilon > 0$,

$$\mathbb{P}\left(\bigcup_{v=1}^{\infty} \{|X_{n+v} - X_n| \geq \varepsilon\}\right) \rightarrow 0.$$

由定理4.9, 我们易得下面的推论.

推论4.10 $\{X_n\}$ 是几乎必然意义下的基本列当且仅当存在非负数列 δ_k 使得

$$\sum_{k=1}^{\infty} \delta_k < \infty \text{ 而且 } \sum_{k=1}^{\infty} \mathbb{P}(|X_{k+1} - X_k| \geq \delta_k) < \infty.$$

证明 注意到对任意 $\varepsilon > 0$, 存在 n 使得 $\sum_{k=n}^{\infty} \delta_k < \varepsilon$, 进而对任意 $m > n$,

$$\begin{aligned} \{|X_{m+v} - X_m| \geq \varepsilon\} &\subset \{|X_{m+v} - X_m| \geq \sum_{k=m}^{m+v} \delta_k\} \\ &\subset \bigcup_{k=m}^{v-1} \{|X_{k+1} - X_k| \geq \delta_k\} \subset \bigcup_{k=m}^{\infty} \{|X_{k+1} - X_k| \geq \delta_k\}. \end{aligned}$$

因此由定理4.9可知结论成立. \square

定义4.2 称随机变量序列 $\{X_n\}$ 是依概率收敛意义下的基本列或Cauchy列, 若对任意 $\varepsilon > 0$, $\delta > 0$ 存在一个 $N = N(\varepsilon, \delta)$ 使得当 $n, m > N$ 时

$$\mathbb{P}(|X_n(\omega) - X_m(\omega)| \geq \varepsilon) \leq \delta.$$

由关系式 $\{|X_n - X_m| \geq \varepsilon\} \subset \{|X_n - X| \geq \varepsilon/2\} \cup \{|X_m - X| \geq \varepsilon/2\}$ 可知依概率收敛的序列一定是依概率收敛的基本列, 进而几乎必然收敛的基本列一定是依概率收敛的基本列.

命题4.11 依概率收敛的基本列一定存在一个子列使其为几乎必然收敛的基本列.

证明 设 $\{X_n\}$ 是任一依概率收敛的基本列. 取 $\varepsilon = 1/2^k$ $\delta = 1/2^k$, 存在单调增加的 n_k 使得对

任意 $m > n_k$

$$\mathbb{P}(|X_m(\omega) - X_{n_k}(\omega)| \geq 1/2^k) \leq 1/2^k.$$

取子列 $\{X_{n_k}\}$, 那么

$$\sum_{k=1}^{\infty} \mathbb{P}(|X_{n_{k+1}} - X_{n_k}| \geq 1/2^k) < \infty.$$

由推论4.8可知 $\{X_{n_k}\}$ 就是几乎必然意义下的基本列. \square

记该基本列的极限为 X , 由

$$\{|X_n - X| \geq \varepsilon\} \subset \{|X_{n_k} - X| \geq \varepsilon/2\} \cup \{|X_n - X_{n_k}| \geq \varepsilon/2\}$$

可知 $\{X_n\}$ 是概率收敛的. 因此 $\{X_n\}$ 依概率收敛当且仅当它是概率收敛的基本列.

1.4.4 收敛的简单性质

性质4.12 对依概率收敛和几乎必然收敛, 以下运算性质成立.

(1) 若对任意 $k, X_n^{(k)} \xrightarrow{a.s.} X^{(k)}$ (或 $X_n^{(k)} \xrightarrow{P} X^{(k)}$), c_k 为常数, 那么

$$\sum_{k=1}^m c_k X_n^{(k)} \xrightarrow{a.s.} \sum_{k=1}^m c_k X^{(k)} \quad (\text{相应地 } \sum_{k=1}^m c_k X_n^{(k)} \xrightarrow{P} \sum_{k=1}^m c_k X^{(k)}).$$

(2) 若 $X_n \xrightarrow{a.s.} X$ (或 $X_n \xrightarrow{P} X$), $Y_n \xrightarrow{a.s.} Y$ (相应地 $Y_n \xrightarrow{P} Y$), 那么

$$X_n Y_n \xrightarrow{a.s.} XY \quad (\text{相应地 } X_n Y_n \xrightarrow{P} XY).$$

(3) 若 $Y_n \xrightarrow{a.s.} Y$ (或 $Y_n \xrightarrow{P} Y$) 且 $\mathbb{P}(Y = 0) = 0$, 那么

$$1/Y_n \xrightarrow{a.s.} 1/Y \quad (\text{相应地 } 1/Y_n \xrightarrow{P} 1/Y),$$

其中当 $Y_n = 0$ 时 $1/Y_n$ 可以自由定义.

证明 我们只证(2), 其他的参见习题4.4.

若 $X_n \xrightarrow{a.s.} X$ 且 $Y_n \xrightarrow{a.s.} Y$, 那么存在零概率集 A, B 使得对任意 $\omega \in \Omega \setminus A$ 和任意 $\omega_1 \in \Omega \setminus B$ 有

$$X_n(\omega) \rightarrow X(\omega), \quad Y_n(\omega_1) \rightarrow Y(\omega_1).$$

令 $C = A \cup B$, 那么 C 也是零概率集, 而且对任意 $\omega \in \Omega \setminus C$,

$$X_n(\omega) Y_n(\omega) \rightarrow X(\omega) Y(\omega).$$

这表明 $X_n Y_n \xrightarrow{a.s.} XY$.

若 $X_n \xrightarrow{P} X$ 且 $Y_n \xrightarrow{P} Y$. 对任意 $\delta > 0$, 存在 $M > 0$ 使得

$$\mathbb{P}(|Y| \geq M) < \delta/4, \quad \mathbb{P}(|X| \geq M-1) < \delta/8.$$

由于 $X_n \xrightarrow{P} X$, 因此存在 N_1 , 当 $n > N_1$ 时 $\mathbb{P}(|X_n - X| > 1) < \delta/8$, 进而

$$\mathbb{P}(|X_n| < M) \geq \mathbb{P}(|X_n - X| \leq 1, |X| < M-1)$$

$$\geq 1 - \mathbb{P}(|X_n - X| > 1) - \mathbb{P}(|X| \geq M - 1) = 1 - \delta/4.$$

可得 $\mathbb{P}(|X_n| \geq M) \leq \delta/4$. 进一步, 由概率收敛条件, 对任意 $\varepsilon > 0$, 存在 $N > N_1$, 使得当 $n \geq N$ 时

$$\mathbb{P}(|Y_n - Y| \geq \varepsilon/2M) \leq \delta/4, \quad \mathbb{P}(|X_n - X| \geq \varepsilon/2M) \leq \delta/4.$$

因此当 $n > N$ 时

$$\begin{aligned} \mathbb{P}(|X_n Y_n - XY| \geq \varepsilon) &= \mathbb{P}(|X_n Y_n - X_n Y + X_n Y - XY| \geq \varepsilon) \\ &\leq \mathbb{P}(|X_n Y_n - X_n Y| + |X_n Y - XY| \geq \varepsilon) \\ &\leq \mathbb{P}(|X_n||Y_n - Y| \geq \varepsilon/2) + \mathbb{P}(|Y||X_n - X| \geq \varepsilon/2) \\ &\leq \mathbb{P}(|X_n| \geq M) + \mathbb{P}(|Y_n - Y| \geq \varepsilon/2M) \\ &\quad + \mathbb{P}(|Y| \geq M) + \mathbb{P}(|X_n - X| \geq \varepsilon/2M) \\ &\leq \delta/4 + \delta/4 + \delta/4 + \delta/4 = \delta. \end{aligned}$$

这表明 $X_n Y_n \xrightarrow{P} XY$.

□

注4.4 上面我们介绍的几乎必然收敛和依概率收敛隐含地假定了极限 X 几乎必然有限. 在几乎处处收敛意义下, 利用数学分析中数列收敛到无穷的定义, 我们也可以考虑极限 X 以正概率取无穷的情形, 比如当收敛到正无穷时,

$$\{X_n(\omega) \rightarrow +\infty\} = \bigcap_{m=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n=N}^{\infty} \{X_n \geq m\}. \quad (1.4.4)$$

对依概率收敛到可正概率取无穷的极限的定义与表示, 我们不再展开.

为了后面引用方便, 在本节最后, 我们介绍一个与随机变量数学期望有关的极限定理. 为此, 我们先给出数学期望的全概率公式.

引理4.13 设事件集 $\{A_i, i \geq 1\}$ 是样本空间 Ω 的一个分割, 即 A_i 两两不交且 $\bigcup_{i=1}^{\infty} A_i = \Omega$. 若 X 是非负随机变量或 X 的数学期望存在, 那么

$$\mathbb{E}(X) = \sum_{k=1}^{\infty} \mathbb{E}(X \mathbf{1}_{A_k}). \quad (\text{全概率公式})$$

证明 只证 X 是非负连续的情形, 对其他情形感兴趣的读者可参阅[9]. 此时,

$$\mathbb{E}(X) = \int_0^{\infty} x f_X(x) dx = \lim_{M \rightarrow \infty} \int_0^M x f_X(x) dx = \lim_{M \rightarrow \infty} \mathbb{E}(X \mathbf{1}_{\{X \leq M\}}).$$

由于 $\{A_i, i \geq 1\}$ 是样本空间 Ω 的一个分割, 对任意 $n \geq 1$, $\mathbf{1}_{\Omega} = \sum_{i=1}^n \mathbf{1}_{A_i} + \mathbf{1}_{\bigcup_{k=n+1}^{\infty} A_i}$,

$$\begin{aligned} \mathbb{E}(X \mathbf{1}_{\{X \leq M\}}) &= \mathbb{E}\left(X \mathbf{1}_{\{X \leq M\}} \left(\sum_{i=1}^n \mathbf{1}_{A_i} + \mathbf{1}_{\bigcup_{k=n+1}^{\infty} A_i} \right)\right) \\ &= \sum_{i=1}^n \mathbb{E}(X \mathbf{1}_{\{X \leq M\}} \mathbf{1}_{A_i}) + \mathbb{E}(X \mathbf{1}_{\{X \leq M\}} \mathbf{1}_{\bigcup_{k=n+1}^{\infty} A_i}). \end{aligned}$$

再由 $1 = \sum_{i=1}^{\infty} \mathbb{P}(A_i)$ 可知 $n \rightarrow \infty$ 时,

$$\mathbb{E}(X \mathbf{1}_{\{X \leq M\}} \mathbf{1}_{\cup_{k=n+1}^{\infty} A_i}) \leq M \mathbb{P}(\cup_{k=n+1}^{\infty} A_i) \rightarrow 0.$$

因此

$$\begin{aligned} \mathbb{E}(X \mathbf{1}_{\{X \leq M\}}) &= \lim_{n \rightarrow \infty} \sum_{i=1}^n \mathbb{E}(X \mathbf{1}_{\{X \leq M\}} \mathbf{1}_{A_i}) \\ &= \sum_{i=1}^{\infty} \mathbb{E}(X \mathbf{1}_{\{X \leq M\}} \mathbf{1}_{A_i}) \leq \sum_{i=1}^{\infty} \mathbb{E}(X \mathbf{1}_{A_i}). \end{aligned}$$

由此可得

$$\mathbb{E}(X) \leq \sum_{k=1}^{\infty} \mathbb{E}(X \mathbf{1}_{A_k}).$$

另一方面, 对任意 $n \geq 1$,

$$\mathbb{E}(X) \geq \mathbb{E}(X \mathbf{1}_{\cup_{k=1}^n A_k}) = \sum_{k=1}^n \mathbb{E}(X \mathbf{1}_{A_k}).$$

令 $n \rightarrow \infty$ 得

$$\mathbb{E}(X) \geq \sum_{k=1}^{\infty} \mathbb{E}(X \mathbf{1}_{A_k}).$$

综合两方面, 可知引理4.13成立. \square

定理4.14(单调收敛定理) 设 X_n 为非负随机变量且对任意 $n \geq 1$, $X_n \leq X_{n+1}$ 几乎处处成立.

记 $X = \lim_{n \rightarrow \infty} X_n$, a.s. 那么

$$\mathbb{E}(\lim_{n \rightarrow \infty} X_n) = \mathbb{E}(X) = \lim_{n \rightarrow \infty} \mathbb{E}(X_n).$$

证明 由条件可知, 存在一个概率为0的事件 A , 使得在 \bar{A} 上, $\{X_n, n \geq 1\}$ 为单调不降数列, 从而极限存在(可能为 ∞), 记其为 X . 因此 $X_n \xrightarrow{a.s.} X$. 若 $\mathbb{P}(X = \infty) = p > 0$, 由(1.4.4) 可知对任意 $M > 0$,

$$\begin{aligned} p &= \mathbb{P}(X_n \rightarrow +\infty) = \mathbb{P}\left(\bigcap_{m \geq 1} \bigcup_{N \geq 1} \bigcap_{n > N} \{X_n > m\}\right) \\ &\leq \mathbb{P}\left(\bigcup_{N \geq 1} \bigcap_{n > N} \{|X_n| > M\}\right) = \lim_{N \rightarrow \infty} \mathbb{P}\left(\bigcap_{n > N} \{|X_n| > M\}\right). \end{aligned}$$

这表明存在 $m(M)$, 当 $n > m$ 时 $\mathbb{P}(X_n > M) > p/2$, 从而 $\mathbb{E}(X_n) > Mp/2$,

$$\lim_{n \rightarrow \infty} \mathbb{E}(X_n) = \infty = \mathbb{E}(X).$$

若 $\mathbb{P}(X = \infty) = 0$. 此时由数学期望全概率公式

$$\mathbb{E}(X_n) = \sum_{k=1}^{\infty} \mathbb{E}(X_n \mathbf{1}_{\{k-1 \leq X < k\}}), \quad \mathbb{E}(X) = \sum_{k=1}^{\infty} \mathbb{E}(X \mathbf{1}_{\{k-1 \leq X < k\}}).$$

记 $a_n(k) = \mathbb{E}(X_n \mathbf{1}_{\{k-1 \leq X < k\}})$, $a(k) = \mathbb{E}(X \mathbf{1}_{\{k-1 \leq X < k\}})$. 对任意 $k \geq 1$, 显然 $a_n(k)$, $a(k)$ 非负, 且 $a_n(k)$ 随 n 增加单调不降. 注意到

$$|a_n(k) - a(k)| \leq \mathbb{E}(|X_n - X| \mathbf{1}_{\{k-1 \leq X < k\}})$$

$$\begin{aligned}
&= \mathbb{E}(|X_n - X| \mathbf{1}_{\{k-1 \leq X < k\} \cap \{|X_n - X| > \epsilon\}}) \\
&\quad + \mathbb{E}(|X_n - X| \mathbf{1}_{\{k-1 \leq X < k\} \cap \{|X_n - X| \leq \epsilon\}}) \\
&\leq k \mathbb{P}(|X_n - X| > \epsilon) + \epsilon
\end{aligned}$$

由于 $X_n \rightarrow X, a.s.$ 因此随 $n \rightarrow \infty$, $k \mathbb{P}(|X_n - X| > \epsilon) \rightarrow 0$. 再由 ϵ 的任意小性可知当 $n \rightarrow \infty$ 时

$$a_n(k) \rightarrow a(k).$$

由数列级数收敛知识(见习题1.5)可得

$$\mathbb{E}(X) = \sum_{k=1}^{\infty} a(k) = \lim_{n \rightarrow \infty} \sum_{k=1}^{\infty} a_n(k) = \lim_{n \rightarrow \infty} \mathbb{E}(X_n).$$

定理得证. \square

练习题

4.1 若存在随机变量 X 使得随机序列 $S_n/n \rightarrow X, a.s.$ 成立, 而且非负整数值随机序列 $N_n \rightarrow \infty, a.s.$ 成立. 证明 $S_{N_n}/N_n \rightarrow X, a.s.$

4.2 试构造一个随机序列 $\{X_n\}$ 使得 $X_n \xrightarrow{P} 0$ 但 $\mathbb{P}(X_n \rightarrow 0) = 0$.

4.3 设 $f(x)$ 在 $[0, +\infty)$ 上连续有界, 单调上升且 $f(0) = 0$, 证明随机变量 X_n 依概率收敛于 0 当且仅当 $\lim_{n \rightarrow \infty} \mathbb{E}(f(|X_n|)) = 0$.

4.4 设随机变量 $X_k, k \geq 1$, 为独立随机变量且 $\mathbb{E}(X_k) = 0, \text{Var}(X_k) = k$. 对任意 $n \geq 1$, 令

$$Y_n = \sum_{k=1}^n X_k/k$$

证明对任意 $r > 1/2$, 当 $n \rightarrow \infty$ 时 Y_n/n^r 几乎必然收敛到 0.

4.5 验证(1.4.3)成立.

4.6* 证明性质4.12中(1)和(3).

4.7* 证明定理4.9.

$$\left(\begin{array}{l} \text{提示: 先证明} \\ \text{以及} \end{array} \quad \{X_n \text{是Cauchy列}\} = \bigcap_{m=1}^{\infty} \bigcup_{n=1}^{\infty} \bigcap_{v=1}^{\infty} \{|X_{n+v} - X_n| \leq \frac{1}{m}\}, \\ \bigcup_{v=1}^{\infty} \{|X_{n+v} - X_n| \geq \epsilon\} \subset \bigcap_{k=1}^n \bigcup_{v=1}^{\infty} \{|X_{k+v} - X_k| \geq \epsilon/2\}. \end{array} \right)$$

第二章 随机过程概述

本章我们将简要地解释随机过程的基本概念并介绍两类基础随机模型：直线上简单随机游动与泊松过程。这两类随机过程在一定意义上可以看作是独立同分布随机变量部分和及其“逆”。它们在应用领域有着广泛的应用。

2.1 随机过程简介

随机过程简单而言是人们为认识复杂随机现象动态变化规律而建立的一种数学模型，通常以一族(通常是无穷多的)随机变量的形式出现.

2.1.1 随机过程的基本概念

先看下面两个具体的例子.

例5.1 观察赌场里某个赌徒正在进行的赌博(比如抽扑克牌比大小). 若赌徒在输完筹码才会离开，问要进行多少局，赌局才会结束？由于赌局的随机性，每一局后赌徒拥有的赌资是随机的. 要对这个问题做出估计，可以用随机变量 $Y(n)$ 表示第 n 局后赌徒拥有的筹码，那么所估计的赌局数为

$$k = \inf\{n; Y(n) \leq 0\}.$$

要合理估计 k 值，一般要掌握随机变量族 $\{Y(n), n \geq 0\}$ 的随机变化规律.

例5.2 观察一只股票的价格波动，是否存在“稳赢”的投资策略？一般地，股票价格变化具有一定的随机性(如下图所示).



用随机变量 $X(t)$ 表示股票在 t 时刻的价格, 如果想通过买卖该股票获利, 那么我们应该掌握随机变量族 $\{X(t); t \geq 0\}$ 的统计规律. 当我们想通过某种策略获利, 比如13元买入15元卖出, 我们首先要解决的问题就是对应的买入时机和卖出时机是否存在? 在什么时候?

以上例子表明, 许多问题会涉及动态变化的随机现象. 为了解决问题, 我们可以用一族(一般是无穷多)随机变量刻画(描述)这些现象. 通常我们就称这族随机变量是一个随机过程. 介绍随机过程的各种统计规律和研究方法就是随机过程课程的主要内容.

定义5.1 称 $X = \{X(t); t \in T\}$ 为概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上随机过程, 若它是该概率空间上一族随机变量(可以是向量值的). 称 $X(t), t \in T$, 的所有可能取值域 S 为随机过程 X 的状态空间, T 称为是指标集或参数集, 特别若指标集具有时间属性时, 也称之为时间参数.

按指标集和状态空间的不同, 通常我们把随机过程分成四类: 连续参数离散状态、连续参数连续状态、离散参数离散状态、离散参数连续状态随机过程.

注5.1 对随机过程还可从其他角度进行分类. 比如, 若对所有 $t \in T$, $X(t) \in R^d$ 其中 $d > 1$, 则也称 X 是向量值随机过程; 若 $T \in R^n$ 的子集时(此时 T 往往对应空间或时空指标), 我们又称 X 为随机场. 为了简单, 本书不讨论随机场这种情形. 从现在起本书讨论的随机过程, 如无特别说明, 都是实值随机过程, 即 $S \subset R$, $T \subset R$.

从映射(函数)角度看, 随机过程也是 $T \times \Omega \rightarrow R$ 的二元函数. 对给定的时刻 t, ω , $X(t, \omega)$ 是一个实数; 对给定的 t 和变化的 ω , 随机过程 $X(t, \cdot)$ 为随机变量; 对变化的 t 和给定的 $\omega \in \Omega$, $X(\cdot, \omega)$ 是一个指标集 T 上的函数:

$$X(\cdot, \omega) : T \rightarrow R \text{ 对任意 } t \in T, X(\cdot, \omega)(t) = X(t, \omega).$$

通常我们称函数 $X(\cdot, \omega)$ 为随机过程 X 的轨道(函数)或样本(函数).

2.1.2 随机过程的刻画

对概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上有限个随机变量 X_1, \dots, X_m , 我们一般用联合分布函数

$$F(x_1, x_2, \dots, x_m) \stackrel{\triangle}{=} \mathbb{P}(X_1 \leq x_1, X_2 \leq x_2, \dots, X_m \leq x_m),$$

其中 $x_1, \dots, x_m \in \mathbb{R}$ 刻画他们的统计规律. 对于随机过程, 我们可以借用这一工具.

定义5.2 任取 $X = \{X(t); t \in T\}$ 的 k 个参数, t_1, t_2, \dots, t_k , 称 X_{t_1}, \dots, X_{t_k} 的联合分布函数

$$F_{t_1, t_2, \dots, t_k}(x_1, x_2, \dots, x_k)$$

为随机过程 X 的一个 k 阶有限维分布, 称函数族

$$\{F_{t_1, t_2, \dots, t_k}(x_1, x_2, \dots, x_k); t_1, \dots, t_k \in T, k \geq 1\}$$

为随机过程 X 的有限维分布族.

注5.2 当 S 为离散时, 有限维分布族可用如下有限维分布列代替

$$P_{t_1, \dots, t_k}(x_1, \dots, x_k) := \mathbb{P}(X_{t_1} = x_1, \dots, X_{t_k} = x_k); x_1, \dots, x_k \in S.$$

性质5.1 随机过程的有限维分布满足

(1) 对称性, 即对任意 k 以及 $(1, 2, \dots, k)$ 的一个置换 (i_1, i_2, \dots, i_k) ,

$$F_{t_1, t_2, \dots, t_k}(x_1, x_2, \dots, x_k) = F_{t_{i_1}, t_{i_2}, \dots, t_{i_k}}(x_{i_1}, x_{i_2}, \dots, x_{i_k}).$$

(2) 相容性, 即对任意 $n > m$,

$$F_{t_1, \dots, t_m, \dots, t_n}(x_1, \dots, x_m, +\infty, \dots, +\infty) = F_{t_1, \dots, t_m}(x_1, \dots, x_m).$$

证明 性质由有限维分布定义直接可得. □

下面定理表明有限维分布族在一定意义上确定唯一的随机过程; 证明省略.

定理5.2*(Kolmogorov) 设 $\{F_{t_1, t_2, \dots, t_k}(x_1, x_2, \dots, x_k); t_1, \dots, t_k \in T, k \geq 1\}$ 是满足对称性和相容性的概率分布函数族, 则在样本空间

$$\Omega = S^T = \{(s_t; t \in T); s_t \in S\},$$

以及 σ -代数

$$\begin{aligned} \mathfrak{F} = \sigma &\left\{ \{(s_t, t \in T); (s_{t_1}, \dots, s_{t_n}) \in B\}; \right. \\ &\left. B \subset \mathfrak{B}(S^n), t_1, \dots, t_n \in T, n \geq 1 \right\} \end{aligned}$$

上存在唯一的概率 \mathbb{P} , 使得 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上随机过程 $X = \{X(t), t \in T\}$, 其中

$$X(t, \omega) = \omega_t, \quad \omega = (\omega_t)_{t \in T},$$

的有限维分布族恰好是 $\{F_{t_1, t_2, \dots, t_k}(x_1, x_2, \dots, x_k); t_1, \dots, t_k \in T, k \geq 1\}$.

注5.3* 定理中 $\mathfrak{B}(S^n)$ 表示由 S^n 中所有开集产生的 σ -代数, 通常称之为Borel代数. 特别, 若

S^n 为离散集, 那么 $\mathfrak{B}(S^n)$ 就是由 S^n 中所有子集构成的集合类.

下面是一个解释在数学上如何利用Kolmogorov定理给出随机过程及对应概率空间的严格构造的简单例子.

例5.3* 从装有 M 个红球和 N 个白球的袋中重复做有放回的抽取, 若抽到红色记作0, 白球记作1, 试建立严格的数学模型描述随机抽取的动态变化.

解 令 $p = \frac{N}{N+M}$, $q = 1 - p$, a_i , $i \geq 1$, 取值为0或1. 显然该过程中任意抽取 s 次, 抽取结果为 a_1, \dots, a_s 的概率为

$$p^{a_1+\dots+a_s} q^{s-(a_1+\dots+a_s)}.$$

由抽取过程我们可以得到如下的有限分布列族

$$\{P_{n_1, n_2, \dots, n_s}(a_1, \dots, a_s); n_1, n_2, \dots, n_s \text{ 为互不相同的正整数},$$

$$a_i \in \{0, 1\}, i = 1, 2, \dots, s, s \geq 1\}$$

其中 $P_{n_1, n_2, \dots, n_s}(a_1, \dots, a_s) = p^{a_1+\dots+a_s} q^{s-(a_1+\dots+a_s)}$. 容易验证, 该有限维分布列簇是对称的且具有相容性. 因此由Kolmogorov定理, 令

$$\begin{aligned} \Omega &= \{0, 1\}^{\mathbf{N}} = \{(a_1, a_2, \dots); a_i = 0, 1, i = 1, 2, \dots\}, \\ \mathfrak{F} &= \sigma \left\{ \{(\omega_i, i \geq 1); \omega_{i_1} = a_{i_1}, \dots, \omega_{i_k} = a_{i_k}\}; \right. \\ &\quad \left. i_l \in T, a_{i_l} \in \{0, 1\}, l = 1, \dots, k, k \geq 1 \right\} \end{aligned}$$

存在唯一概率 \mathbb{P} 使得随机过程 $X = \{X_n, n \geq 1\}$, 其中 $X_n(\omega) = \omega_n$ 的有限维分布与已知观察一致. 此时 Ω 中随机事件

$$\{(\omega_n; n \geq 1); \omega_{i_k} = a_{i_k}, k = 1, 2, \dots, s\}$$

发生概率 $P = p^{a_{i_1}+\dots+a_{i_s}} q^{s-(a_{i_1}+\dots+a_{i_s})}$. \square

定义5.3 设 $X = \{X_t; t \in T\}$, $Y = \{Y_t; t \in T\}$ 都是概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上的随机过程, 称 Y 是 X 的一个版本(Version), 若 X, Y 有限维分布族相同; 称 Y 是 X 的一个修正(Modification), 若对任意 $t \in T$, $\mathbb{P}(X_t = Y_t) = 1$; 称 X 与 Y 不可区分(Indistinguish), 若 $\mathbb{P}(X_t = Y_t, t \in T) = 1$.

显然衡量两个过程是否一样, 概念“不可区分”是最强的. 两个随机过程是不可区分的, 那么他们一定互为修正; 两个过程互为修正则一定互为版本. 这两个结论一般都逆不真, 但若 X, Y 为离散参数随机过程, 那么“不可区分”与“修正”等价.

定义5.4 设 $X = \{X_t; t \in T\}$, $Y = \{Y_u; u \in T\}$ 都是概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上的随机过程, 若对任意 $k, m \geq 1$, $t_1, \dots, t_k, u_1, \dots, u_m \in T$, $(X_{t_1}, \dots, X_{t_k})$ 与 $(Y_{u_1}, \dots, Y_{u_m})$ 独立, 则称 X 和 Y 是独立的.

例5.4 设 $W_i, i \geq 1$ 是独立同分布的随机变量, S_n 为 W_i 的部分和序列, N 为一个固定常数. 对任意 $k \geq 1$, 令 $T_k = S_{N+k} - S_N$. 那么随机过程 $\{T_k, k \geq 1\}$ 与 $\{S_n, 1 \leq n \leq N\}$ 独立. 事实上对任意 $m \geq 1$, 任取 $k_1, \dots, k_m \geq 1$, 由 $W_i, i \geq 1$ 独立同分布可知

$$(T_{k_1}, T_{k_2}, \dots, T_{k_m}) = \left(\sum_{i=N+1}^{N+k_1} W_i, \sum_{i=N+1}^{N+k_2} W_i, \dots, \sum_{i=N+1}^{N+k_m} W_i \right)$$

与

$$(S_1, S_2, \dots, S_N) = (W_1, W_1 + W_2, \dots, \sum_{i=1}^N W_i)$$

是独立的. \square

我们也可以通过随机变量的数值特征在一定程度上了解随机过程.

定义5.5 设 $X = \{X(t); t \in T\}$ 是定义在概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上的随机过程, 分别称如下的函数

$$\begin{aligned} m_X(t) &= \mathbb{E}(X(t)), & D_X(t) &= \text{Var}(X(t)), \\ R_X(s, t) &= \mathbb{E}(X(s)X(t)), & \text{Cov}_X(s, t) &= \text{Cov}(X(s), X(t)) \end{aligned}$$

为随机过程 X 的均值函数, 方差函数, 自相关函数与协方差函数.

2.1.3 典型随机过程举例

定义5.6 若对任意的 $t_1 < \dots < t_n \in T$ 以及 $h \in T$,

$$(X(t_1), \dots, X(t_n)) \text{ 与 } (X(t_1 + h), \dots, X(t_n + h))$$

同分布, 则称对随机过程 $X = \{X(t), t \in T\}$ 为严平稳过程.

严平稳过程的一个具体例子就是在初等概率论中介绍的独立同分布随机变量序列. 但是严平稳过程要求太高了, 应用中人们更多地考虑如下的所谓平稳过程.

定义5.7 若对任意 $t \in T$, $\mathbb{E}(X(t))$ 与 t 无关, 且对任意 $t, h \in T$, 协方差函数 $\text{Cov}(X(t), X(t+h))$ 与 t 无关, 则称随机过程 X 为平稳过程.

显然若 X 是平稳过程, 那么对任意 $t \in T$, $\mathbb{E}(X^2(t)) < \infty$, 即 $X(t)$ 的二阶矩存在(简称这样的过程为二阶矩过程); 二阶矩存在的严平稳过程一定是平稳过程.

平稳过程的有关理论是时间序列分析的基础, 本书对平稳过程的分析与介绍从略.

定义5.8 称随机过程 $X = \{X(t); t \in T\}$ 是独立增量过程, 若对任意 n 以及 $t_1 < \dots < t_n \in T$

$$X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})$$

相互独立(若指标集 T 有最小元素 t_0 , 那么还要求

$$X(t_0), X(t_1) - X(t_0), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})$$

相互独立). 进一步, 若对任意 $t, t+h, s, s+h \in T$, $X(t+h) - X(t)$ 与 $X(s+h) - X(s)$ 的分布相同, 则称 X 为平稳独立增量过程.

如果 $X = \{X(t), t \geq 0\}$ 为平稳独立增量过程, 均值函数 $m(t)$ 与方差函数 $D(t)$ 都存在且连续. 那么对任意 $t \geq 0$,

$$m(t) = Ct + \mathbb{E}(X(0)), \quad D(t) = C_1t + \text{Var}(X(0)), \quad (2.1.1)$$

其中 $C = \mathbb{E}(X(1)) - \mathbb{E}(X(0))$, $C_1 = \text{Var}(X(1)) - \text{Var}(X(0))$.

如果 T 为非负整数, 那么独立增量过程就是一列相互独立随机变量的部分和; 初值为 0 的平稳独立增量过程就是一列独立同分布随机变量的部分和.

具体的平稳独立增量过程有很多, 常见的例子包括本章后面要介绍的随即游动, 泊松过程以及第六章介绍的布朗运动.

数学期望有限的独立增量过程还具有如下两个重要性质: (为了方便理解, 假设 T 是非负整数)

1 对任意 $s, t \in T$ 且 $s < t$, 以及对任意 $x \in \mathbb{R}$,

$$\begin{aligned} \mathbb{P}(X(t) < x | X_0, X_1, \dots, X_s) &= \mathbb{P}(X(t) - X(s) < x - X(s) | X_0, X_1, \dots, X_s) \\ &= \mathbb{P}(X(t) - X(s) < x - X(s) | X_s) = \mathbb{P}(X(t) < x | X_s). \end{aligned}$$

2 若对任意 $s, t \in T$, $\mathbb{E}(X(t) - X(s)) = 0$, 那么对任意 $s < t \in T$

$$\begin{aligned} \mathbb{E}(X(t) | X_0, X_1, \dots, X_s) &= \mathbb{E}(X(t) - X(s) | X_0, \dots, X_s) + \mathbb{E}(X(s) | X_0, \dots, X_s) \\ &= \mathbb{E}(X(t) - X(s)) + X(s) = X(s). \end{aligned}$$

通常称满足性质1的随机过程为马氏过程, 满足性质2的过程为鞅(过程). 我们将分别在第三、四章和第七章对这两类过程做进一步介绍.

在本节最后, 我们介绍一个具体的简单随机过程并举例说明它的应用.

定义5.9 随机过程 $X = \{X_n; n \geq 1\}$ 称为伯努利过程, 若 $\{X_n; n \geq 1\}$ 为独立同分布(i.i.d)随机变量, 且

$$\mathbb{P}(X_n = 1) = p, \quad \mathbb{P}(X_n = 0) = q = 1 - p, \quad 0 < p < 1, n \geq 1.$$

例5.3中构造的随机模型其实就是一个伯努利过程. 伯努利过程常用来描述一列独立重复实验, 通常将 $\mathbb{P}(X_n = 1) = p$ 看作第 n 次实验成功概率, $\mathbb{P}(X_n = 0) = q$ 看作第 n 次实验失败的概率. 显然, 伯努利过程是严平稳的.

令 $T_1 = \inf\{n > 0; X_n = 1\}$, 其中规定 $\inf \emptyset = +\infty$. 直观地看 T_1 表示第一次实验成功的时刻. 但是这个时刻是随机的, 而且可以取 $+\infty$. 进一步分析可知, 判定 $T_1 = n$ 这个事件是否

发生, 我们可以通过观察 n 及 n 之间实验的结果: 若 n 之前实验都没成功而在 n 时刻实验恰好成功, 那么事件 $T_1 = n$ 发生; 否则该事件没有发生. 即

$$\{T_1 = n\} = \{X_n = 1, X_1, \dots, X_{n-1} \text{ 均不为 } 1\}. \quad (2.1.2)$$

在随机过程研究中, 具有像 T_1 这种性质的(广义)随机变量是非常重要的工具; 一般地, 称这种随机变量为随机时间或停时. 它的定义如下:

定义5.10 称非负整数值的随机变量(可取 $+\infty$) T 是随机过程 $X = \{X_n\}_{n \geq 0}$ 的停时(Stopping time), 若对任意非负整数 n , 随机事件 $\{T = n\}$ 可以通过 X_0, \dots, X_n 表示, 也即随机变量 $\mathbf{1}_{\{T=n\}}$ 可表示成 X_0, \dots, X_n 的函数. 当无需强调“参考”过程 X 时, 我们简称 T 为停时.

注5.4 定义5.10只是给出了离散时间随机过程的停时定义; 对这类停时性质的讨论, 我们将在第七章第一节展开. 对于连续时间随机过程的停时的一般定义, 感兴趣的同学可以参阅[12]; 本教材将结合具体问题介绍和讨论.

回到伯努利过程. 对任意 $k > 1$, 我们可同样定义 $T_k = \inf\{n > T_{k-1}; X_n = 1\}$. 那么 T_k 表示第 k 次伯努利实验成功的时刻而且也是停时.

任取数列 $\{f(n); n \geq 1\}$. 由

$$f(T_k) = f(T_{k-1} + 1)X_{T_{k-1}+1} + \dots + f(T_k - 1)X_{T_k-1} + f(T_k)X_{T_k},$$

可知

$$\sum_{k=1}^{\infty} f(T_k) = \sum_{n=1}^{\infty} f(n)X_n.$$

这表明若 $\sum_{n \geq 1} |f(n)| < \infty$, 则对任意 $\varepsilon > 0$, 存在 $m > 0$ 使得

$$\sum_{n=1}^m f(n)X_n - \varepsilon \leq \sum_{k=1}^{\infty} f(T_k) \leq \sum_{n=1}^m f(n)X_n + \varepsilon$$

因此

$$\mathbb{E}\left(\sum_{k=1}^{\infty} f(T_k)\right) = \lim_{m \rightarrow \infty} \mathbb{E}\left(\sum_{n=1}^m f(n)X_n\right) = p \sum_{n=1}^{\infty} f(n). \quad (2.1.3)$$

例5.5 设在某种仪器在单位时间内损坏事件构成一个伯努利过程, 若损坏后更换的费用为 c 元, 为使仪器损坏时用户能免费更换, 厂方在卖出产品时应合理定价, 假设投资 1 元到下一个单位时间可增值到 $1/\alpha$ 元, 问厂家预期应至少多定价多少?

解: 以 T_k 表示第 k 次损坏一个仪器的时间, 此时更换仪器要 c 元, 为此厂家需额外收取 $c\alpha^{T_k}$ 元费用. 要保证长期使用则应多收取的费用为 $\sum_{k=1}^{\infty} c\alpha^{T_k}$. 因此由(2.1.3), 预期应增收费用为

$$D = \mathbb{E}\left(\sum_{k=1}^{\infty} c\alpha^{T_k}\right) = cp \sum_{k=1}^{\infty} \alpha^k = \frac{cp\alpha}{1-\alpha}. \quad \square$$

练习题

- 5.1 试解释对离散参数随机过程而言，“不可区分”与“修正”等价.
- 5.2 验证(2.1.1)中 $m(t)$ 与 $D(t)$ 的表达式.
- 5.3 证明随机过程 $\{X_t, t \in T\}$ 与 $\{Y_t, t \in T\}$ 独立当且仅当对任意 $m \geq 1$ 以及任意选取的 $t_1, \dots, t_m \in T$, $(X_{t_1}, \dots, X_{t_m})$ 与 $(Y_{t_1}, \dots, Y_{t_m})$ 独立.

2.2 直线上简单随机游动

随机游动是一类简单、直观的随机模型，有着广泛的应用。本节将简要地介绍直线上简单随机游动的理论和应用。

2.2.1 模型及其刻画

定义6.1 设 $X_n, n \geq 1$ 为独立同分布的随机变量，随机变量 X_0 与 $\{X_n, n \geq 1\}$ 独立。令

$$W_n = \sum_{k=0}^n X_k, \quad n \geq 0.$$

称随机过程 $W = \{W_n; n \geq 0\}$ 为(直线上)随机游动或一维随机游动。称 X_0 的取值为随机游动 W 的初值或初始位置。若随机游动 W 定义中 X_0 是整数值随机变量且

$$\mathbb{P}(X_n = 1) = p, \quad \mathbb{P}(X_n = -1) = q = 1 - p,$$

则称随机过程 $W = \{W_n; n \geq 0\}$ 为直线上的简单随机游动或 (q, p) -简单随机游动。其中 $p = q = 1/2$ 时简称 W 为简单对称随机游动。

注6.1 由定义可知随机游动 W 是平稳独立增量过程。

注6.2 用初等概率论的眼光看，随机游动 W 实质就是独立同分布随机变量的部分和。但当我们把 X_n 形象地理解成在一条直线上随机走出的一步时， W 就描述了在该直线上随机走过的路线。这也是我们称 W 为随机游动的一种形象解释。为了叙述方便，有时也形象地称 X_n 为第 n 步的步长。

为讨论方便，以下我们只介绍整数值的随机游动，即 $X_k, k \geq 0$ ，都是整数值随机变量。令

$$p_n(x, y) := \mathbb{P}(W_n = y | W_0 = x), \quad n \geq 0,$$

并简记 $p_n(0, y)$ 为 $p_n(y)$ 。显然， $p_n(x, y)$ 表示随机游动在初值为 x 条件下，时刻 n 时值为 y 的概率；特别 $p_0(x, y) = \delta_x(y) = \begin{cases} 1 & y = x; \\ 0 & y \neq x. \end{cases}$

对任意 $k \geq 0, n \geq 1$ ，条件概率

$$\mathbb{P}(W_{k+n} = y | W_k = x) = \frac{\mathbb{P}(W_{n+k} = y, W_k = x)}{\mathbb{P}(W_k = x)} = \frac{\mathbb{P}(\sum_{i=k+1}^{n+k} X_i = y - x, W_k = x)}{\mathbb{P}(W_k = x)}.$$

由 $X_k, k \geq 0$ 的独立性质可得

$$\begin{aligned} \mathbb{P}(W_{k+n} = y | W_k = x) &= \mathbb{P}\left(\sum_{i=k+1}^{n+k} X_i = y - x\right) \mathbb{P}(W_k = x) / \mathbb{P}(W_k = x) \\ &= \mathbb{P}\left(\sum_{i=k+1}^{n+k} X_i = y - x\right). \end{aligned} \tag{2.2.1}$$

再由 $X_k, k \geq 0$ 的同分布性质可知

$$\mathbb{P}(W_{k+n} = y | W_k = x) = \frac{\mathbb{P}(\sum_{i=1}^n X_i = y - x, X_0 = 0)}{\mathbb{P}(X_0 = 0)} = \mathbb{P}(W_n = y - x | W_0 = 0).$$

由此可知

$$\mathbb{P}(W_{k+n} = y | W_k = x) = \mathbb{P}(W_n = y | W_0 = x) = p_n(x, y) = p_n(y - x). \quad (2.2.2)$$

因此 $p_n(x, y)$ 不仅表示随机游动起点由 x 出发经 n 步到达位置 y 的概率, 也表示从任一时刻所在位置 x 出发经过 n 步到位置 y 的概率, 他们都等于从位置 0 出发经 n 步到达位置 $y - x$ 的概率.

为获得随机游动 W 的任意有限维分布, 任取

$$0 = k_0 < k_1 < \cdots < k_n, \quad r_0, r_1, \dots, r_n \in \mathbf{Z}.$$

由(2.2.1)和(2.2.2)可得

$$\begin{aligned} & \mathbb{P}(W_{k_0} = r_0, W_{k_1} = r_1, \dots, W_{k_n} = r_n) \\ &= \mathbb{P}\left(X_0 = r_0, \sum_{i=k_0+1}^{k_1} X_i = r_1 - r_0, \dots, \sum_{i=k_{n-1}+1}^{k_n} X_i = r_n - r_{n-1}\right) \\ &= \mathbb{P}(X_0 = r_0) \mathbb{P}\left(\sum_{i=k_0+1}^{k_1} X_i = r_1 - r_0\right) \cdots \mathbb{P}\left(\sum_{i=k_{n-1}+1}^{k_n} X_i = r_n - r_{n-1}\right) \\ &= \mathbb{P}(X_0 = r_0) p_{k_1}(r_0, r_1) p_{k_2-k_1}(r_1, r_2) \cdots p_{k_n-k_{n-1}}(r_{n-1}, r_n). \end{aligned} \quad (2.2.3)$$

可见条件概率簇 $\{p_n(x, y)\}$ 是我们认识随机游动的统计规律的基础.

命题6.1 若 W 是整数值的随机游动, 那么对任意 $0 \leq k < m$ 以及 $i_0, \dots, i_m \in \mathbf{Z}$,

$$\begin{aligned} & \mathbb{P}(W_m = i_m, \dots, W_{k+1} = i_{k+1} | W_k = i_k, \dots, W_0 = i_0) \\ &= \mathbb{P}(W_{m-k} = i_m - i_k, \dots, W_1 = i_{k+1} - i_k | W_0 = 0). \end{aligned}$$

证明 对任意 $n \geq 1$ 以及整数 x, y , 令 $p_n(x, y) := \mathbb{P}(W_n = y | W_0 = x)$. 由(2.2.3)可知

$$\begin{aligned} \mathbb{P}(W_m = i_m, \dots, W_k = i_k, \dots, W_0 = i_0) &= \mathbb{P}(X_0 = i_0) \prod_{r=0}^{m-1} p_1(i_r, i_{r+1}), \\ \mathbb{P}(W_k = i_k, \dots, W_0 = i_0) &= \mathbb{P}(X_0 = i_0) \prod_{r=0}^{k-1} p_1(i_r, i_{r+1}). \end{aligned}$$

从而

$$\mathbb{P}(W_m = i_m, \dots, W_{k+1} = i_{k+1} | W_k = i_k, \dots, W_0 = i_0) = \prod_{r=k}^{m-1} p_1(i_r, i_{r+1}).$$

另一方面由(2.2.3)和(2.2.2)可知

$$\begin{aligned} & \mathbb{P}(W_{m-k} = i_m - i_k, \dots, W_1 = i_{k+1} - i_k | W_0 = 0) \\ &= p_1(0, i_{k+1} - i_k) \prod_{r=k+1}^{m-1} p_1(i_r - i_k, i_{r+1} - i_k) \end{aligned}$$

$$= p_1(i_k, i_{k+1}) \prod_{r=k+1}^{m-1} p_1(i_r, i_{r+1}) = \prod_{r=k}^{m-1} p_1(i_r, i_{r+1}).$$

由此可知命题6.1成立. \square

一般地, 若令 $\tilde{A}_n = \{i - i_k : i \in A_n\} := A_n - i_k$ 其中 $A_n \subset \mathbf{Z}$, $k < n \leq m$, 那么

$$\begin{aligned} & \mathbb{P}(W_m \in A_m, \dots, W_{k+1} \in A_{k+1} | W_k = i_k, \dots, W_0 = i_0) \\ &= \mathbb{P}(W_{m-k} \in \tilde{A}_m, \dots, W_1 \in \tilde{A}_{k+1} | W_0 = 0). \end{aligned} \quad (2.2.4)$$

证明请读者自己完成(见习题6-5).

对简单随机游动, 我们可以非常方便地计算 $\{p_n(x, y)\}$. 由于简单随机游动每次步长只能是 +1(向前一步)或 -1(向后一步), 要从位置 x 出发经 n 步到达 y , 意味着其中有 $(n + y - x)/2$ 步向前, $(n + x - y)/2$ 步向后. 所以

$$p_n(x, y) = \begin{cases} C_n^{(n+y-x)/2} p^{(n+y-x)/2} q^{(n+x-y)/2}, & |y - x| \leq n \text{ 且同奇偶;} \\ 0, & \text{其他.} \end{cases} \quad (2.2.5)$$

例6.1 设 W 是 (q, p) -简单随机游动. 对 $s \in [0, 1]$, 令 $\phi(s) = \sum_{n=0}^{\infty} p_n(0, 0) s^n$. 求 $\phi(s)$.

解 由(2.2.5)可得

$$p_n(0, 0) = \begin{cases} 0, & n = 2k - 1, \\ C_{2k}^k p^k q^k, & n = 2k. \end{cases}$$

因此

$$\begin{aligned} \phi(s) &= 1 + \sum_{k=1}^{\infty} C_{2k}^k p^k q^k s^{2k} = 1 + \sum_{k=1}^{\infty} \frac{(2k)!}{k! k!} (pq s^2)^k = 1 + \sum_{k=1}^{\infty} \frac{(2k-1)!!}{k!} (2pq s^2)^k \\ &= 1 + \sum_{k=1}^{\infty} \frac{-\frac{1}{2}(-\frac{1}{2}-1) \cdots (-\frac{1}{2}-(k-1))}{k!} (-4pq s^2)^k \end{aligned}$$

注意到函数 $(1+x)^{-1/2}$ 的幂级数展开式为

$$(1+x)^{-1/2} = 1 + \sum_{k=1}^{\infty} \frac{-\frac{1}{2}(-\frac{1}{2}-1) \cdots (-\frac{1}{2}-(k-1))}{k!} x^k, \quad |x| < 1.$$

因此所求函数 $\phi(s) = (1 - 4pq s^2)^{-1/2}$. \square

2.2.2 基本性质

定义6.2 称整数值的随机游动不带右跳(或右连续), 若其步长满足条件

$$\mathbb{P}(X_n = 1) > 0 \text{ 而且 } \sum_{k=-\infty}^1 \mathbb{P}(X_n = k) = 1.$$

对任意整数 i , 令

$$\tau_i = \inf\{n \geq 1; W_n = i\}$$

通常我们分别称之为首回时. 直观看, 若 $W_0 = i$, τ_i 表示 W 首次回到位置 i 的时间. 由定义可知, 若 W 是初值为 0 的不带右跳整数值的随机游动, 那么 $i \geq 0$ 时,

$$\begin{aligned}\{\tau_i = n\} &= \{W_1 \neq i, \dots, W_{n-1} \neq i, W_n = i\} \\ &= \{W_1 < W_n, \dots, W_{n-1} < W_n, W_n = i\}.\end{aligned}\quad (2.2.6)$$

定理6.2 设 W 是初值为 0 不带右跳的整数值随机游动, 对任意正整数 m, n ,

$$\mathbb{P}(\tau_m = n | W_0 = 0) = \frac{m}{n} \mathbb{P}(W_n = m | W_0 = 0).$$

我们先证明一个排列组合方面的结论.

引理6.3 对任意正整数 m , 在满足 $x_1 + \dots + x_n = m$, 其中 $x_i \leq 1, i = 1, \dots, n$, 的任意一个整数解(可以是负数) (u_1, u_2, \dots, u_n) 的 n 个循环排列中恰有 m 个循环排列使得其前 $n-1$ 项部分和都严格小于 m .

例如, 取 $n = 5, m = 2$, 那么 $(-2, 1, 1, 1, 1), (1, -2, 1, 1, 1), (1, 1, -2, 1, 1), (1, 1, 1, -2, 1), (1, 1, 1, 1, -2)$, 这一组的循环排列有 5 种, 分别是

$$(-2, 1, 1, 1, 1), (1, -2, 1, 1, 1), (1, 1, -2, 1, 1), (1, 1, 1, -2, 1), (1, 1, 1, 1, -2),$$

其中只有第一, 第二两种排列满足前 $n-1 = 4$ 项部分和严格小于 $m = 2$. 事实上排列 $(-2, 1, 1, 1, 1)$ 和 $(1, -2, 1, 1, 1)$ 的前 4 项部分和分别是 $(-2, -1, 0, 1)$ 和 $(1, -1, 0, 1)$.

证明* 设 (u_1, u_2, \dots, u_n) 是方程 $x_1 + \dots + x_n = m$ 的整数解. 由于 (u_1, u_2, \dots, u_n) 的循环都是整数解, 因此我们可以选择一个好的循环作为分析的对象. 记 $\{u_i\}$ 的部分和序列为 S_1, \dots, S_n . 设其最大值为 M 并令 $l = \min\{k, S_k = M\}$. 那么 $M \geq m, u_l = 1$ 且对任意 $l < i \leq n$, $u_{l+1} + \dots + u_i \leq 0$. 选择循环排列 $(u_{l+1}, \dots, u_n, u_1, \dots, u_l)$ 作为我们分析对象, 并将其重新记为 (v_1, v_2, \dots, v_n) . 可得:

- (1) 对任意 $k < n$, 部分和 $v_1 + \dots + v_k < v_1 + \dots + v_n = m$.
- (2) 由于部分和 $v_1 + \dots + v_{n-l} = u_{l+1} + \dots + u_n \leq 0$ 而且 v_i 最大只能取到 $+1$, 因此对任意 $1 \leq j \leq m$, 一定存在一个指标 n_k 使得部分和

$$v_1 + \dots + v_{n_k} = j$$

并记这些指标中最小的指标为 k_j , 其中 k_0 规定为 0. 由(1)知 $k_m = n$, 并且由于部分序列 $v_1 + \dots + v_i$ 是从 0 值开始而且 v_i 最大只能取到 $+1$ 可得 k_j 随着 j 的增加而增加.

- (3) 对任一 $-j < m$, 序列块 $(v_{k_j+1}, \dots, v_{k_{j+1}})$ 一定满足

$$v_{k_j+1} + \dots + v_{k_{j+1}} = 1, \quad v_{k_{j+1}} = 1$$

而且若存在 $k_j + 1 \leq i < k_{j+1}$, 则 $v_{k_j+1} + \dots + v_i \leq 0$ (否则 $i \geq k_{j+1}$ 导出矛盾).

由此我们可以检验 (v_1, v_2, \dots, v_n) 的循环排列中所有

$$(v_{k_j+1}, \dots, v_n, v_1, \dots, v_{k_j}), \quad j = 0, 1, \dots, m-1$$

满足引理要求. 其他的任何一个循环

$$(v_i, \dots, v_n, v_1, \dots, v_{i-1})$$

都不满足引理要求, 因为此时存在一个 j 使得 $k_j + 1 < i \leq k_{j+1}$, 该循环的前 $n - i + k_j$ 的部分和为

$$\begin{aligned} v_i + \dots + v_n + v_1 + \dots + v_{k_j} &= v_1 + \dots + v_n - (v_{k_j+1} + \dots + v_{i-1}) \\ &= m - (v_{k_j+1} + \dots + v_{i-1}) \geq m. \end{aligned}$$

所以在 (v_1, v_2, \dots, v_n) 的循环排列中有且仅有 m 个满足引理要求. \square

利用该引理, 我们很容易证明定理6.2. 证明如下.

证明 记 $A = \{W_n = m, W_0 = 0\} = \{X_1 + \dots + X_n = m\}$,

$$\begin{aligned} B &= \{\tau_m = n, W_0 = 0\} \\ &= \{W_1 < W_n, \dots, W_{n-1} < W_n, W_n = m, W_0 = 0\} \\ &= \{X_1 + \dots + X_k < m, k = 1, \dots, n-1, X_1 + \dots + X_n = m\} \end{aligned}$$

任取 A 中一个基本事件 $u = (u_1, \dots, u_n)$, 该基本事件的 n 个循环排列也是 A 中的基本事件, 记 u 及其循环排列事件构成的集合为 Γ_u , 此时

$$A = \bigcup_{\substack{\Gamma_u \in A \\ \text{且互不相交}}} \Gamma_u,$$

并且由于 A 中至多有可数个基本事件 u , 因此上式只涉及至多可数个事件 Γ_u 的并. 另一方面, 由引理6.3, 对任意 $u \in A$, Γ_u 中有且仅有 m 个循环排列事件属于 B . 注意到 X_i 是独立同分布的随机变量, 每个循环排列发生概率相同, 因此

$$\frac{\mathbb{P}(B \cap \Gamma_u)}{\mathbb{P}(A \cap \Gamma_u)} = \frac{m}{n}.$$

注意到 $B \subset A$, 我们可得

$$\mathbb{P}(B \cap \Gamma_u) = \mathbb{P}(B \cap A \cap \Gamma_u) = \frac{\mathbb{P}(B \cap \Gamma_u)}{\mathbb{P}(A \cap \Gamma_u)} \mathbb{P}(A \cap \Gamma_u) = \frac{m}{n} \mathbb{P}(A \cap \Gamma_u).$$

因此由全概率公式

$$\mathbb{P}(B) = \mathbb{P}(B \cap \bigcup_{\substack{\Gamma_u \in A \\ \text{且互不相交}}} \Gamma_u) = \sum_{\substack{\Gamma_u \in A \\ \text{且互不相交}}} \mathbb{P}(B \cap \Gamma_u) = \frac{m}{n} \sum_{\substack{\Gamma_u \in A \\ \text{且互不相交}}} \mathbb{P}(A \cap \Gamma_u) = \frac{m}{n} \mathbb{P}(A).$$

所以定理6.2成立. \square

例6.2 设 W 是 (q, p) 简单随机游动. 对任意 $i \geq 0$, 求 $\mathbb{P}(\tau_i = n | W_0 = 0)$.

解 注意到 (q, p) 简单随机游动是右连续的. 由定理6.2以及(2.2.5) 可知对任意*i* ≥ 1 ,

$$\begin{aligned}\mathbb{P}(\tau_i = n | W_0 = 0) &= \frac{i}{n} \mathbb{P}(W_n = i | W_0 = 0) \\ &= \begin{cases} \frac{i}{n} C_n^{(n+i)/2} p^{(n+i)/2} q^{(n-i)/2}, & \frac{n+i}{2} \leq n \text{ 且为正整数;} \\ 0, & \text{其他.} \end{cases}\end{aligned}$$

由于简单随机游动必须偶数步才可能从位置0回到0, 对任意*k* ≥ 0 ,

$$\mathbb{P}(\tau_0 = 2k + 1 | W_0 = 0) = 0.$$

另一方面, 由全概率公式

$$\mathbb{P}(\tau_0 = 2k | W_0 = 0) = \mathbb{P}(\tau_0 = 2k, W_1 = 1 | W_0 = 0) + \mathbb{P}(\tau_0 = 2k, W_1 = -1 | W_0 = 0).$$

注意到

$$\begin{aligned}\mathbb{P}(\tau_0 = 2k, W_1 = 1 | W_0 = 0) &= \frac{\mathbb{P}(\tau_0 = 2k, W_1 = 1, W_0 = 0)}{\mathbb{P}(W_1 = 1, W_0 = 0)} \frac{\mathbb{P}(W_1 = 1, W_0 = 0)}{\mathbb{P}(W_0 = 0)} \\ &= \mathbb{P}(W_1 = 1 | W_0 = 0) \mathbb{P}(\tau_0 = 2k | W_1 = 1, W_0 = 0) \\ &= p \mathbb{P}(W_{2k} = 0, W_i \neq 0, 1 < i < 2k | W_1 = 1, W_0 = 0).\end{aligned}$$

由(2.2.4)和(2.2.6)可知

$$\begin{aligned}\mathbb{P}(W_{2k} = 0, W_i \neq 0, 1 < i < 2k | W_1 = 1, W_0 = 0) \\ &= \mathbb{P}(W_{2k-1} = -1, W_i \neq -1, 0 < i < 2k-1 | W_0 = 0) \\ &= \mathbb{P}(\tau_{-1} = 2k-1 | W_0 = 0).\end{aligned}$$

注意从0出发的 (q, p) 简单随机游动首达-1的时间与从0出发的 (p, q) 简单随机游动首达1的时间分布相同, 由例6.2可得

$$\mathbb{P}(\tau_{-1} = 2k-1 | W_0 = 0) = \frac{1}{2k-1} \frac{(2k-1)!}{k!(k-1)!} q^k p^{k-1} = \frac{(2k-2)!}{k!(k-1)!} q^k p^{k-1}.$$

从而

$$\mathbb{P}(\tau_0 = 2k, W_1 = 1 | W_0 = 0) = p \mathbb{P}(\tau_{-1} = 2k-1 | W_0 = 0) = \frac{(2k-2)!}{k!(k-1)!} q^k p^k.$$

同理可得

$$\mathbb{P}(\tau_0 = 2k, W_1 = -1 | W_0 = 0) = q \mathbb{P}(\tau_1 = 2k-1) = \frac{(2k-2)!}{k!(k-1)!} q^k p^k.$$

由此可得

$$\mathbb{P}(\tau_0 = 2k | W_0 = 0) = 2 \frac{(2k-2)!}{k!(k-1)!} q^k p^k = \begin{cases} 2pq, & k = 1, \\ \frac{(2k-3)!! (4pq)^k}{2^k k!}, & k \geq 2. \end{cases} \quad \square$$

利用随机游动的平稳独立增量性质, 我们还能得到如下的对称原理.

定理6.4(对称原理) 若 W 是初值为0的随机游动, 那么对任意 $n \geq 1$ 以及 $b > a \geq 0$,

$$\mathbb{P}(W_1 > 0, \dots, W_{n-1} > 0, W_n \in [a, b]) = \mathbb{P}(W_1 < W_n, \dots, W_{n-1} < W_n, W_n \in [a, b]).$$

证明 令 $Y_1 = X_n, Y_2 = X_{n-1}, \dots, Y_n = X_1$ 以及对任意 $k = 1, \dots, n$,

$$S_k = \sum_{i=1}^k Y_i = \sum_{i=n}^{n-k+1} X_i = W_n - \sum_{i=1}^{n-k} X_i = W_n - W_{n-k}.$$

由于 X_1, \dots, X_n 是独立同分布的随机变量, 因此 (X_1, \dots, X_n) 与 (Y_1, \dots, Y_n) 有相同分布.

从而

$$(W_1, \dots, W_n) \text{ 与 } (S_1, \dots, S_n)$$

分布相同. 因此

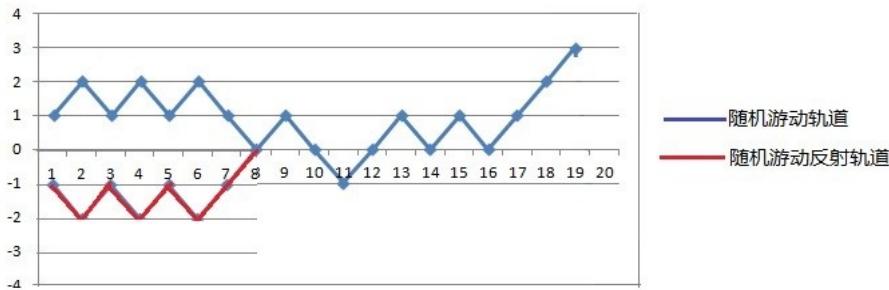
$$\begin{aligned} \mathbb{P}(W_1 > 0, \dots, W_{n-1} > 0, W_n \in [a, b]) &= \mathbb{P}(S_1 > 0, \dots, S_{n-1} > 0, S_n \in [a, b]) \\ &= \mathbb{P}(W_n - W_{n-1} > 0, \dots, W_n - W_1 > 0, W_n \in [a, b]) \\ &= \mathbb{P}(W_1 < W_n, \dots, W_{n-1} < W_n, W_n \in [a, b]). \end{aligned}$$

□

对简单随机游动还有如下的反射原理.

引理6.5(反射原理) 设 x, y 为正整数, 对简单随机游动 W 而言, 从 (n, x) 到 $(n+m, y)$ 并途中位置回到零点的轨道数与从 $(n, -x)$ 到 $(n+m, y)$ 的轨道数相同.

所谓随机游动的轨道就是将随机游动 W 中其各位置点 (n, W_n) 在平面上绘点, 并按 n 的次序用直线依次相连所得到的折线. 参见下图蓝色折线.



证明 令 A 表示从 (n, x) 到 $(n+m, y)$ 并途中位置回到零点的所有轨道, B 为从 $(n, -x)$ 到 $(n+m, y)$ 的所有轨道.

任取 A 中一个轨道

$$(n, x), (n+1, s_1), \dots, (n+k, s_k), \dots, (n+m, y),$$

设从 n 开始首次到达位置零点的时刻为 $n+k$, 即 $s_k = 0$, 但 s_1 到 s_{k-1} 都大于0. 将 (n, x) 到 $(n+k, 0)$ 的轨道沿时间轴翻转得到一条连接 $(n, -x)$ 与 $(n+k, 0)$ 的轨道(如上图红线所示), 再与原来 $(n+k, 0)$ 到 $(n+m, y)$ 轨道拼接, 得到一条从 $(n, -x)$ 到 $(n+m, y)$ 的轨道. 显然这种轨

道产生方式是一对一的, 因此 A 中轨道数不超过 B 中轨道数.

反过来, 任取 B 中一轨道

$$(n, -x), (n+1, s_1), \dots, (n+k, s_k), \dots, (n+m, y).$$

由于简单随机游动每次只能移动一步, 而 $-x < 0 < y$, 因此由 $(n, -x)$ 到 $(n+m, y)$ 的过程中必有某个时刻到达位置 0. 设 $n+k$ 是首个这样的时刻. 同样可将 $(n, -x)$ 到 $(n+k, 0)$ 的轨道沿时间轴翻转得到一条由 (n, x) 到 $(n+k, 0)$ 的轨道, 进而得到一条从 (n, x) 到 $(n+m, y)$ 的轨道. 显然这种轨道产生方式也是一对一的, 因此 B 中轨道数不超过 A 中轨道数.

综合两方面可知 A, B 中轨道数相同. \square

命题6.6 若 W 是简单对称随机游动, 那么对任意 $x, y > 0$,

$$\mathbb{P}(W_{n+m} = y, \min_{n < k < n+m} W_k \leq 0 | W_n = x) = \mathbb{P}(W_{n+m} = y | W_n = -x).$$

证明 注意到 W 是对称随机游动, 即 $p = q = 1/2$ 时, 随机游动每一步向上或向下走的机会是对称的. 将 W 的任意两个可能点 $(n, x), (n+m, y)$ 它们连接起来的轨道是等可能的, 而且与从 (n, x) 出发走过 m 步的任一轨道发生的概率相同. 注意到从 (n, x) 出发走过 m 步的轨道数为 2^m , 由引理6.5得

$$\begin{aligned} \mathbb{P}(W_{n+m} = y, \min_{n < k < m} W_k \leq 0 \mid W_n = x) &= \frac{A \text{ 中轨道数}}{2^m} \\ &= \frac{B \text{ 中轨道数}}{2^m} = \mathbb{P}(W_{n+m} = y | W_n = -x). \quad \square \end{aligned}$$

2.2.3 应用举例

例6.3 某娱乐公司为了吸引顾客推出一种特别活动. 活动规则如下: 顾客可以参与一种赌博游戏, 输赢概率各 50%. 公司为顾客第一局买单: 即赢了的顾客获得一个筹码而输了的顾客则无需付出. 若顾客继续游戏, 那么按正常游戏规则执行, 即赢了的顾客获得一个筹码而输了的顾客付出一个筹码. 假设某个顾客参与了该活动但没有购买任何筹码, 包括第一局, 问他至少能玩 10 局的机会是多少?

解 以 W_n 表示该顾客第 n 局结束后手上有的筹码数, 那么 W 是初值为 0 的简单对称随机游动, 所求概率为

$$\mathbb{P}(W_1 > 0, W_2 > 0, \dots, W_{10} \geq 0).$$

因此 $W_1 > 0$ 意味着 $W_1 = 1$, 而且 W_{10} 只取偶数, 因此由全概率公式

$$\mathbb{P}(W_1 > 0, \dots, W_{10} \geq 0) = \sum_{k=0}^{\infty} \mathbb{P}(W_1 > 0, W_2 > 0, \dots, W_9 > 0, W_{10} = 2k)$$

$$= \sum_{k=1}^{\infty} \mathbb{P}(W_1 = 1, \min_{1 \leq m \leq 9} W_m > 0, W_9 = 2k - 1)$$

利用 $\{\min_{1 \leq m \leq 9} W_m > 0\}$ 的对立事件 $\{\min_{1 \leq m \leq 9} W_m \leq 0\}$ 得

$$\begin{aligned} & \mathbb{P}(W_1 > 0, \dots, W_{10} \geq 0) \\ &= \sum_{k=1}^{\infty} [\mathbb{P}(W_1 = 1, W_9 = 2k - 1) - \mathbb{P}(W_1 = 1, \min_{1 \leq m \leq 9} W_m \leq 0, W_9 = 2k - 1)] \\ &= \sum_{k=1}^{\infty} \mathbb{P}(W_1 = 1) [\mathbb{P}(W_9 = 2k - 1 | W_1 = 1) \\ &\quad - \mathbb{P}(\min_{1 \leq m \leq 9} W_m \leq 0, W_9 = 2k - 1 | W_1 = 1)]. \end{aligned}$$

由命题6.6可知

$$\begin{aligned} \mathbb{P}(W_1 > 0, \dots, W_{10} \geq 0) &= \mathbb{P}(W_1 = 1) \sum_{k=1}^{\infty} [p_8(1, 2k - 1) - p_8(-1, 2k - 1)] \\ &= \mathbb{P}(W_1 = 1) \sum_{k=1}^{\infty} [p_8(2k - 2) - p_8(2k)] = \frac{p_8(0)}{2} = \frac{35}{256}. \end{aligned}$$

□

例6.4(选票问题), 在一次选举中候选人A得到了 n 张票, 候选人B得到 m 张票, $n > m$. 问计票过程中A始终领先B的可能性有多大?

解 以 $X_i = 1$ 表示第 i 个人投票给了 A, $X_i = -1$ 表示第 i 个人投票给了 B. 假定 X_i 是独立同分布的, 投票给 A, B 的概率分别为 $p, q = 1 - p$. 以随机游动 $W_k = X_1 + \dots + X_k$ 表示计票过程中得票变化情况. 结果为 $W_{n+m} = n - m > 0$. 所求问题转为求 (q, p) 随机游动的如下条件概率

$$\mathbb{P}(W_1 > 0, W_2 > 0, \dots, W_{n+m-1} > 0 | W_{n+m} = n - m).$$

由对称原理及定理6.2

$$\begin{aligned} & \mathbb{P}(W_1 > 0, W_2 > 0, \dots, W_{n+m-1} > 0, W_{n+m} = n - m) \\ &= \mathbb{P}(W_1 < W_{n+m}, \dots, W_{n+m-1} < W_{n+m}, W_{n+m} = n - m) \\ &= \frac{n-m}{n+m} \mathbb{P}(W_{n+m} = n - m). \end{aligned}$$

从而

$$\begin{aligned} & \mathbb{P}(W_1 > 0, W_2 > 0, \dots, W_{n+m-1} > 0 | W_{n+m} = n - m) \\ &= \frac{\mathbb{P}(W_1 > 0, W_2 > 0, \dots, W_{n+m-1} > 0, W_{n+m} = n - m)}{\mathbb{P}(W_{n+m} = n - m)} \\ &= \frac{n-m}{n+m}. \end{aligned}$$

□

练习题

6.1 (接例6.5) 若此人玩了至少10局, 试预测他在第10局结束时的筹码数.

6.2 对初值为0的简单对称随机游动 W ,

(1) 对任意 $n \geq 1$, 证明 $\mathbb{P}(W_1 \neq 0, W_2 \neq 0, \dots, W_{2n} \neq 0) = \mathbb{P}(W_{2n} = 0)$.

(2) 令 $F_1(s) = \sum_{k=1}^{\infty} \mathbb{P}(\tau_1 = k | W_0 = 0) s^k$ 其中 $|s| < 1$, 求 $F_1(s)$.

(3) 求概率 $\mathbb{P}(\cap_{i=1}^8 \{0 < W_i < 5\})$.

6.3 考虑一个简单的股票价格变化模型. 假设股票只有涨跌两种状态, 且机会均等. 当股票上涨时涨幅为6%, 当股票下跌时跌幅以同等概率取-4%, -8%. 若股票每日的波动是独立的. 自某个设定的观察日开始,

(1) 求在首次下跌后, 股票平均总涨跌幅.

(2) 求在10天内上涨天数总比下跌天数多的概率.

(3) 在首次观察到下跌与上涨天数一样多时, 计算股票平均总涨跌幅.

6.4 证明(2.2.4).

2.3 泊松(Poisson)过程

泊松过程是一种应用广泛的简单随机过程, 它与指数分布密切相关, 因而具有良好的性质.

2.3.1 计数过程

用数学模型刻画随机现象时, 最基本的工作就是观察所关心随机事件发生的次数. 由此所得到的数学模型常被称为计数过程, 其准确定义如下:

定义7.1 称非负整数值的随机过程 $N = \{N(t); t \geq 0\}$ 为计数过程或点过程, 若其样本函数为右连续的单调不降函数. 若还有 $\mathbb{P}(N(t) - N(t-) \leq 1 \text{ 对任意 } t \geq 0) = 1$, 则称 N 是简单计数过程, 其中 $N(t-)$ 表示 N 在 t 点的左极限.

直观地看简单计数过程要求在同一时刻至多发生一次随机事件.

对任意给定的 $\omega \in \Omega$, 由于计数过程的样本函数 $N(t, \omega)$ 关于 t 单调不降且右连续. 因此对任意给定的整数 $k \geq 1$,

$$T_k(\omega) := \inf\{t \geq 0; N(t, \omega) \geq k\}$$

有意义, 其中 $T_0 \equiv 0$ 并约定 $\inf \emptyset = \infty$. 由定义可知,

(1) T_k 就是第 k 次事件发生的随机时刻, 通常称之为第 k 次(随机事件)到达时间.

(2) 对任意 $u \geq 0$ 以及 $\omega \in \Omega$, $u \in \{t \geq 0, N(t, \omega) \geq N(u, \omega)\}$, 因此 $T_{N(u, \omega)}(\omega) \leq u$. 这表明对任意 $t \geq 0$, $T_{N(t)} \leq t$.

(3) 对任意 $\omega \in \Omega$, 若 $T_k(\omega) < \infty$, 那么由 T_k 定义, 存在一列 t_n 单调下降地收敛到 $T_k(\omega)$ 并且 $N(t_n, \omega) \geq k$. 由 N 的右连续性,

$$N(T_k(\omega), \omega) = \lim_{n \rightarrow \infty} N(t_n, \omega) \geq k.$$

即对任意 ω , $N(T_k(\omega), \omega) \geq k$. 特别 N 为简单计数过程时, 对几乎所有的 ω 都有 $N(T_k) = k$.

由以上分析可知, 计数过程 N 可表示成

$$N(t) = \sup\{k \geq 0; T_k \leq t\}, \quad (2.3.1)$$

即对任意 ω , $N(t, \omega) = \sup\{k; T_k(\omega) \leq t\}$, 其中约定 $\sup \emptyset = 0$. 因此 $N(t)$ 表示时刻 t 之前(包含 t) 发生的随机事件总数.

注* 与随机游动一样, 我们也可以从随机变量的部分和序列出发认识计数过程.

设 $S = \{S_k, k \geq 0\}$ 是非负随机变量 $X_i, i \geq 0$, 的部分和序列. 对任意给定的 ω , 当 X_i 恒正时, S_k 是严格增加的. 映射 $k \rightarrow S_k$ 可逆. 逆映射 $S^{-1} : D = \{x_k; x_k = S_k, k \geq 0\} \mapsto \mathbb{N}$ 使得 $S^{-1}(x_k) = k$. 容易看出这个逆映射还可推广到非负实数 \mathbb{R}_+ 上, 使得对任意 $x \in \mathbb{R}_+$,

当 $x_k \leq x < x_{k+1}$ 时 $S^{-1}(x) = k$, 即

$$S^{-1}(x) = \sup\{k \geq 0; S_k \leq x\}. \quad (2.3.2)$$

如果 X_i 可以为 0, 那么 S_k 作为 k 的函数不一定可逆, 但(2.3.2)定义的函数 $S^{-1}(x)$ 仍有意义, 而且 $S^{-1}(x)$ 就是使部分和 $S_k \leq x$ 成立的最大求和项数. 通常, 我们称过程

$$S^{-1} = \{S^{-1}(t), t \geq 0\}$$

为部分和序列 $\{S_k, k \geq 0\}$ 的逆过程.

对计数过程 N 而言, 令 $W_k = T_k - T_{k-1}$. 那么 W_k 表示第 $k-1$ 个事件与第 k 个事件之间的时间间隔, 一般地我们称其为第 k 个等待时间, 称 $W = \{W_k, k \geq 1\}$ 为等待时间序列. 此时事件发生的时间 $\{T_k, k \geq 0\}$ 就是等待时间序列的部分和. 由(2.3.1)可知, 计数过程 N 就是部分和序列 $\{T_k, k \geq 0\}$ 的逆过程.

2.3.2 泊松过程及其刻画

定义7.2 称计数过程 $N = \{N(t); t \geq 0\}$ 是强度为 λ 的泊松过程, 若 N 具有独立同分布的等待时间序列 $\{W_k; k \geq 1\}$ 且等待时间分布服从参数为 λ 的指数分布.

例7.1 假设某房间只有一盏电灯, 而且电灯泡坏了能得到及时更换. 由于灯泡的寿命一般假定独立且服从相同的指数分布, 以 $N(t)$ 表示在 $[0, t]$ 时间内更换下来的灯泡数, 那么 N 就是泊松过程.

由初等概率论可知指数分布 $\text{Exp}(\lambda)$ 具有以下性质.

- (1) 对任意 $n \geq 1$, 若 X_1, \dots, X_n 是服从参数为 λ 的指数分布的独立变量, 那么 $X_1 + X_2 + \dots + X_n$ 服从伽玛分布 $\text{Ga}(n, \lambda)$. 该分布的密度函数为

$$\gamma_n(x) = \begin{cases} \frac{\lambda^n x^{n-1} e^{-\lambda x}}{(n-1)!}, & x > 0, \\ 0, & x \leq 0. \end{cases}$$

- (2) 若 X_1, \dots, X_n 是分别服从参数为 λ_i 的指数分布的独立随机变量, 那么 $\min_{1 \leq k \leq n} X_k$ 服从参数为 $\lambda_1 + \dots + \lambda_n$ 的指数分布.

- (3) 若 X 是非负连续型随机变量. X 服从指数分布当且仅当 X 是无记忆的, 即对任意 $t, s \geq 0$,
- $$\mathbb{P}(X > t + s | X > s) = \mathbb{P}(X > t).$$

以 $W_k, k = 1, 2, \dots$ 表示泊松过程的等待时间变量簇, 那么它们是独立且服从参数为 λ 的指数分布的随机变量列. 对任意 $k \geq 1$, 第 k 次事件发生时刻 $T_k = \sum_{i=1}^k W_i$ 服从 $\text{Ga}(k, \lambda)$ 分布, 概率密度函数为 $\gamma_k(x)$. 并且对任意 $t \geq 0$, 泊松过程

$$N(t) = \sup\{k \geq 0; T_k \leq t\} = \sup\{k \geq 0; \sum_{n=1}^k W_n \leq t\}, \quad t \geq 0,$$

其中约定 $\sum_{n=1}^0 = 0$.

由 $\{N(0) > 0\} \subset \{W_1 = 0\}$ 以及

$$\{\text{存在 } t \geq 0 \text{ 使得 } N(t) - N(t-) \geq 2\} = \{\text{存在某个 } k \text{ 使得 } W_k = 0\}$$

可得 $\mathbb{P}(N(0) = 0) = 1 - \mathbb{P}(N(0) \geq 1) \geq 1 - \mathbb{P}(W_1 = 0) = 1$ 而且

$$\mathbb{P}(\text{存在 } t \geq 0 \text{ 使得 } N(t) - N(t-) \geq 2) \leq \sum_{k=1}^{\infty} \mathbb{P}(W_k = 0) = 0.$$

因此泊松过程是初值为0的简单计数过程.

下面的命题在一定程度上解释了为什么我们称 $N = \{N(t)\}$ 为泊松过程.

命题7.3 强度为 λ 的泊松过程在任一时刻 $t > 0$ 都服从强度为 λt 的泊松分布. 因此

$$\mathbb{E}(N(t)) = \lambda t, \quad \text{Var}(N(t)) = \lambda t.$$

证明 对任意给定的 $t > 0$ 和非负整数 k , 由(2.3.1)可知

$$\{N(t) = k\} = \{T_k \leq t < T_{k+1}\}, \quad (2.3.3)$$

因此

$$\begin{aligned} \mathbb{P}(N(t) = k) &= \mathbb{P}(T_k \leq t < T_{k+1}) = \mathbb{P}(T_k \leq t) - \mathbb{P}(T_{k+1} \leq t) \\ &= \int_0^t [\gamma_k(x) - \gamma_{k+1}(x)] dx = \int_0^t \left[\frac{\lambda^k x^{k-1}}{(k-1)!} - \frac{\lambda^{k+1} x^k}{k!} \right] e^{-\lambda x} dx \end{aligned}$$

由分部积分可得

$$\mathbb{P}(N(t) = k) = \frac{(\lambda t)^k}{k!} e^{-\lambda t}.$$

这表明 $N(t)$ 服从强度为 λt 的泊松分布. \square

定理7.4 强度为 λ 的泊松过程是一个平稳独立增量过程且对任意 $t, s \geq 0$, $N(t+s) - N(s)$ 服从强度为 λt 的泊松分布, 即对任意整数 $k \geq 0$,

$$\mathbb{P}(N(s+t) - N(s) = k) = \frac{(\lambda t)^k}{k!} e^{-\lambda t}. \quad (2.3.4)$$

证明* 由习题7.9可知, 只要证明对任意 $n \geq 1$ 以及 $0 = t_0 < t_1 < \dots < t_n$ 和非负整数 k_1, \dots, k_n , 总有

$$\mathbb{P}(N(t_r) = \sum_{i=1}^r k_i, r = 1, 2, \dots, n) = e^{-\lambda t_n} \prod_{i=1}^n \frac{[\lambda(t_i - t_{i-1})]^{k_i}}{k_i!}. \quad (2.3.5)$$

为了表示简便, 记 N 的等待时间序列为 $\{W_r\}$, 事件发生时刻为 $\{T_r\}$. 对任意 $r \geq 1$, 令 $s_r = \sum_{i=1}^r k_i$ 以及

$$A_r = \{T_{s_1} \leq t_1, T_{s_1+1} > t_1, \dots, T_{s_{r-1}} \leq t_{r-1}, T_{s_{r-1}+1} > t_{r-1}\},$$

$$B_r = \{T_{s_r} \leq t_r, T_{s_r+1} > t_r\},$$

$$C_r = \{T_{s_1} \leq t_1, T_{s_1+1} > t_1, \dots, T_{s_{r-1}} \leq t_{r-1}\}.$$

利用等式(2.3.3), (2.3.5)可简写为

$$\mathbb{P}(A_{n+1}) = e^{-\lambda t_n} \prod_{i=1}^n \frac{[\lambda(t_i - t_{i-1})]^{k_i}}{k_i!}. \quad (2.3.6)$$

当 $n = 1$ 时由命题7.3可知(2.3.6)显然成立. 下设 $n = m - 1$ 时成立, 即

$$\mathbb{P}(A_m) = e^{-\lambda t_{m-1}} \prod_{i=1}^{m-1} \frac{[\lambda(t_i - t_{i-1})]^{k_i}}{k_i!}.$$

当 $n = m$ 时, 注意到 $A_{m+1} = A_m B_m$, 由归纳假设,

$$\begin{aligned} \mathbb{P}(A_{m+1}) &= \mathbb{P}(A_m) \mathbb{P}(B_m | A_m) \\ &= \mathbb{P}(B_m | A_m) e^{-\lambda t_{m-1}} \prod_{i=1}^{m-1} \frac{[\lambda(t_i - t_{i-1})]^{k_i}}{k_i!}. \end{aligned} \quad (2.3.7)$$

下面我们分情况讨论.

(1) 当 $k_m = 0$ 时, $s_m = s_{m-1}$, $B_m = \{T_{s_{m-1}} < t_m, T_{s_{m-1}+1} > t_m\}$.

$$\begin{aligned} \mathbb{P}(B_m | A_m) &= \frac{\mathbb{P}(A_m B_m)}{\mathbb{P}(A_m)} = \frac{\mathbb{P}(C_m, T_{s_{m-1}+1} > t_m)}{\mathbb{P}(C_m, T_{s_{m-1}+1} > t_{m-1})} \\ &= \frac{\mathbb{E}(\mathbf{1}_{C_m} \mathbb{P}(W_{s_{m-1}+1} > t_m - T_{s_{m-1}} | T_1, \dots, T_{s_{m-1}}))}{\mathbb{E}(\mathbf{1}_{C_m} \mathbb{P}(W_{s_{m-1}+1} > t_{m-1} - T_{s_{m-1}} | T_1, \dots, T_{s_{m-1}}))} \\ &= \frac{\mathbb{E}(\mathbf{1}_{C_m} e^{-\lambda(t_m - T_{s_{m-1}})})}{\mathbb{E}(\mathbf{1}_{C_m} e^{-\lambda(t_{m-1} - T_{s_{m-1}})})} = e^{-\lambda(t_m - t_{m-1})}. \end{aligned} \quad (2.3.8)$$

(2) 当 $k_m = 1$ 时, $s_m = s_{m-1} + 1$, $B_m = \{T_{s_m} < t_m, T_{s_m+1} > t_m\}$, 因此

$$\mathbb{P}(B_m | A_m) = \frac{\mathbb{P}(A_m B_m)}{\mathbb{P}(A_m)} = \frac{\mathbb{P}(C_m, t_{m-1} < T_{s_m} < t_m, T_{s_m+1} > t_m)}{\mathbb{P}(C_m, T_{s_{m-1}+1} > t_{m-1})}.$$

与(2.3.8)类似处理可得

$$\begin{aligned} &\mathbb{P}(C_m, t_{m-1} < T_{s_m} < t_m, T_{s_m+1} > t_m) \\ &= \mathbb{E}\left(\mathbf{1}_{C_m} \int_{t_{m-1}-T_{s_{m-1}}}^{t_m-T_{s_{m-1}}} \lambda e^{-\lambda s} ds \int_{t_m-T_{s_{m-1}}-s}^{\infty} \lambda e^{-\lambda u} du\right) \\ &= \mathbb{E}(\mathbf{1}_{C_m} \lambda(t_m - t_{m-1}) e^{-\lambda(t_m - T_{s_{m-1}})}) \\ &= \lambda(t_m - t_{m-1}) e^{\lambda(t_m - t_{m-1})} \mathbb{E}(\mathbf{1}_{C_m} e^{-\lambda(t_{m-1} - T_{s_{m-1}})}) \end{aligned}$$

因此 $k_m = 1$ 时,

$$\begin{aligned} \mathbb{P}(B_m | A_m) &= \frac{\lambda(t_m - t_{m-1}) e^{\lambda(t_m - t_{m-1})} \mathbb{E}(\mathbf{1}_{C_m} e^{-\lambda(t_{m-1} - T_{s_{m-1}})})}{\mathbb{E}(\mathbf{1}_{C_m} e^{-\lambda(t_{m-1} - T_{s_{m-1}})})} \\ &= \lambda(t_m - t_{m-1}) e^{\lambda(t_m - t_{m-1})}. \end{aligned} \quad (2.3.9)$$

(3) 当 $k_m > 1$ 时, $s_m \geq s_{m-1} + 2$, $B_m = \{T_{s_m} < t_m, T_{s_m+1} > t_m\}$, 因此

$$\begin{aligned} \mathbb{P}(A_m B_m) &= \mathbb{P}(C_m \cap \{T_{s_{m-1}+1} > t_{m-1}\} \cap B_m) \\ &= \mathbb{P}(C_m, t_m - T_{s_{m-1}} > T_{s_{m-1}+1} - T_{s_{m-1}}, T_{s_m+1} - T_{s_m} > t_m - T_{s_m}), \\ &\quad T_{s_m} - T_{s_{m-1}+1} < t_m - T_{s_{m-1}+1}, T_{s_m+1} - T_{s_m} > t_m - T_{s_m}). \end{aligned} \quad (2.3.10)$$

由 $\{T_k\}$ 的独立增量性, 以及对任意 $k > l$,

$$T_k - T_l \sim \gamma_{k-l}(x) = \frac{\lambda^{k-l}}{(k-l-1)!} x^{k-l-1} e^{-\lambda x}, \quad x > 0,$$

(2.3.10) 等于

$$\begin{aligned} & \mathbb{E}\left(\mathbf{1}_{C_m} \int_{t_{m-1}-T_{s_{m-1}}}^{t_m-T_{s_{m-1}}} \lambda e^{-\lambda s} ds \int_0^{t_m-s-T_{s_{m-1}}} \gamma_{k_m-1}(u) du \int_{t_m-T_{s_{m-1}}-s-u}^{\infty} \lambda e^{-\lambda v} dv\right) \\ &= \mathbb{E}\left(\mathbf{1}_{C_m} e^{-\lambda(t_m-T_{s_{m-1}})} \int_{t_{m-1}-T_{s_{m-1}}}^{t_m-T_{s_{m-1}}} ds \int_0^{t_m-s-T_{s_{m-1}}} \frac{\lambda^{k_m} u^{k_m-2}}{(k_m-2)!} du\right) \\ &= \mathbb{E}\left(\mathbf{1}_{C_m} e^{-\lambda(t_m-T_{s_{m-1}})} \frac{\lambda^{k_m} (t_m-t_{m-1})^{k_m}}{k_m!}\right). \end{aligned}$$

因此 $k_m > 1$ 时,

$$\mathbb{P}(B_m | A_m) = \frac{\mathbb{P}(A_m B_m)}{\mathbb{P}(A_m)} = \frac{\lambda^{k_m} (t_m-t_{m-1})^{k_m}}{k_m!} e^{-\lambda(t_m-t_{m-1})}. \quad (2.3.11)$$

分别将(2.3.8), (2.3.9)和(2.3.11)代入(2.3.7)可知不论 k_m 取什么值, (2.3.6)对 $n = m$ 也成立. 由归纳法原理, (2.3.6)对一切 $n \geq 1$ 都成立, 因而定理得证. \square

定理7.5 N 为泊松过程当且仅当 N 是初值为0的非零简单计数过程且具有平稳独立增量.

记 N 的等待时间序列为 $\{W_k; k \geq 1\}$, 令 $T_k = \sum_{i=1}^k W_i, k \geq 1$. 为证明定理7.5, 我们需要如下的引理.

引理7.6* $\{W_k; k \geq 1\}$ 为服从参数为 λ 的指数分布的独立同分布随机变量列当且仅当对任意 $k \geq 1$ 及任意 $0 < t_1 \leq t_2 \leq \dots \leq t_n$,

$$\mathbb{P}(T_k \leq t_k, k = 1, 2, \dots, n) = \int_0^{t_1} ds_1 \int_{s_1}^{t_2} ds_2 \dots \int_{s_{n-1}}^{t_n} \lambda^n e^{-\lambda s_n} ds_n. \quad (2.3.12)$$

证明 由数学归纳法容易证明必要性, 留作习题. 充分性由例1.2可得, 此略. \square

引理7.7* 若计数过程 N 初值为零且具有平稳独立增量, 那么对任意 $0 \leq t_0 < t_1 < \dots < t_n < t_{n+1}$ 以及非负整数 $k_0 < k_1 < \dots < k_{n+1}$,

$$\begin{aligned} \mathbb{P}(N(t_{n+1}) \geq k_{n+1} | N(t_m) = k_m, N(t_m-) = k_m - 1, 0 \leq m \leq n) \\ = \mathbb{P}(N(t_{n+1} - t_n) \geq k_{n+1} - k_n). \end{aligned}$$

证明 由于计数过程单调不降, 对任意 $t \geq 0$, $N(t-) = \lim_{s \uparrow t} N(s)$. 因此,

$$\begin{aligned} & \mathbb{P}(N(t_{n+1}) \geq k_{n+1}, N(t_m) = k_m, N(t_m-) = k_m - 1, 0 \leq m \leq n) \\ &= \lim_{\varepsilon \rightarrow 0} \mathbb{P}(N(t_{n+1}) \geq k_{n+1}, N(t_m) = k_m, N(t_m - \varepsilon) = k_m - 1, 0 \leq m \leq n). \end{aligned}$$

不妨设 $0 < \varepsilon < \min_{1 \leq k \leq n} \{t_k - t_{k-1}\}$, 由平稳独立增量性可得

$$\begin{aligned} & \mathbb{P}(N(t_{n+1}) \geq k_{n+1}, N(t_m) = k_m, N(t_m-) = k_m - 1, 0 \leq m \leq n) \\ &= \mathbb{P}(N(t_{n+1}) - N(t_n) \geq k_{n+1} - k_n) \\ &\quad \times \lim_{\varepsilon \rightarrow 0} \mathbb{P}(N(t_m) = k_m, N(t_m - \varepsilon) = k_m - 1, 0 \leq m \leq n). \end{aligned}$$

$$= \mathbb{P}(N(t_{n+1} - t_n) \geq k_{n+1} - k_n) \mathbb{P}(N(t_m) = k_m, N(t_m-) = k_m - 1, 0 \leq m \leq n).$$

由此可知引理成立. \square

定理7.5的证明* 必要性由定理7.4和泊松过程简单性质可得. 下证充分性. 为此, 我们需证明 $W_k, k \geq 1$ 为独立同分布随机变量且服从参数为 λ 的指数分布. 由引理7.6, 我们只需证明(2.3.12) 对任意 $n \geq 1$ 成立.

当 $n = 1$ 时, 对任意 $t \geq 0$, 注意到

$$\mathbb{P}(T_1 \leq t) = \mathbb{P}(N(t) \geq 1) = 1 - \mathbb{P}(N(t) = 0)$$

令 $f(t) = \mathbb{P}(N(t) = 0)$. 对任意 $s, t > 0$, 由平稳独立增量性以及条件 $N(0) = 0$ 可得

$$f(s+t) = \mathbb{P}(N(s+t) = 0) = \mathbb{P}(N(s+t) = 0, N(t) = 0) = f(s)f(t).$$

由于 $N(t)$ 右连续且不恒为 0, $0 \leq f(t) < 1$ 且右连续. 因此

$$f(t) \equiv 0 \text{ 或存在 } \lambda > 0 \text{ 使得 } f(t) = e^{-\lambda t}.$$

若 $f(t) \equiv 0$, 则 $\mathbb{P}(N(t+s) - N(s) \geq 1) = 1 - f(t) = 1$, 从而对任意 $1 > s > 0$, 由

$$\{\{N(1) - N(s) \geq 2\} \supset \{N(1) - N(\frac{1+s}{2}) \geq 1\} \cap \{N(\frac{1+s}{2}) - N(s) \geq 1\},$$

可知

$$\mathbb{P}(N(1) - N(s) \geq 2) = 1.$$

令 $s \rightarrow 1$ 得

$$\mathbb{P}(N(1) - N(1-) \geq 2) = 1.$$

这与 N 为简单计数过程矛盾, 因此

$$\mathbb{P}(T_1 \leq t) = \mathbb{P}(N(t) \geq 1) = \int_0^t \lambda e^{-\lambda s} ds, \quad (2.3.13)$$

即 $n = 1$ 时(2.3.12)成立.

下设 $n = m - 1$ 时(2.3.12)也成立, 那么 $n = m$ 时, 由归纳假设

$$\begin{aligned} \mathbb{P}(T_k \leq t_k, 1 \leq k \leq m) &= \int_0^{t_1} ds_1 \cdots \int_{s_{m-2}}^{t_{m-1}} \lambda^{m-1} e^{-\lambda s_{m-1}} \\ &\quad \times \mathbb{P}(T_m \leq t_m | T_k = s_k, 1 \leq k < m) ds_{m-1}. \end{aligned} \quad (2.3.14)$$

由于 N 是初值为 0 的简单计数过程, 具有平稳独立增量, 由引理7.7 和(2.3.13) 可知

$$\begin{aligned} &\mathbb{P}(T_m \leq t_m | T_k = s_k, 1 \leq k < m) \\ &= \mathbb{P}(N(t_m) \geq m | N(s_k) = k, N(s_k-) = k-1, 1 \leq k < m) \\ &= \mathbb{P}(N(t_m - s_{m-1}) \geq 1) \\ &= \int_0^{t_m - s_{m-1}} \lambda e^{-\lambda s_m} ds_m = \int_{s_{m-1}}^{t_m} \lambda e^{-\lambda(s_m - s_{m-1})} ds_m. \end{aligned}$$

将其代入(2.3.14)整理后即得(2.3.12). \square

由定理7.4和7.5可知不恒为0的计数过程 N 是强度为 λ 的泊松过程当且仅当 N 是初值为0简单计数过程且具有平稳独立增量, 增量 $N(t+s)-N(s)$ 服从泊松分布 $P(\lambda t)$.

例7.2 假设某银行顾客按强度为 λ 的泊松过程 N 到达, 已知 T 时刻到达银行的顾客数是10.

问(1)再经过时间 T , 新增顾客的平均数 c . (2)再等待5位顾客的平均时间 t .

解 (1) 所求新增顾客平均数 $c = \mathbb{E}(N(2T) - N(T))$. 由平稳独立增量性可知

$$c = \mathbb{E}(N(T)) = \lambda T.$$

(2)对任意 t , 令 $\tilde{N}(t) = N(t+T) - N(T)$. 那么由 N 的平稳独立增量性可知 \tilde{N} 仍然具有平稳增量性, 从而还是强度为 λ 的泊松过程. 因此要再等待5位顾客对 \tilde{N} 而言意味着还要计数到5. 所以所求平均时间 $t = \mathbb{E}(T_5)$. 由 T_5 服从 $\Gamma(5, \lambda)$ 分布可知 $t = 5/\lambda$. \square

2.3.3 到达时间的条件分布

定理7.8 设 $\{T_n, n \geq 1\}$ 是强度为 λ 的泊松过程 $N = \{N(t), t \geq 0\}$ 的到达时刻序列, 那么对任意 $0 \leq s_1 < t_1 < \dots < s_n < t_n \leq t$,

$$\mathbb{P}(T_j \in (s_j, t_j], 1 \leq j \leq n | N(t) = n) = \frac{n!}{t^n} \prod_{j=1}^n (t_j - s_j).$$

证明 任取 $0 = t_0 \leq s_1 < t_1 \leq s_2 < \dots < s_n < t_n \leq t$,

$$\begin{aligned} & \mathbb{P}(T_j \in (s_j, t_j], 1 \leq j \leq n | N(t) = n) \\ &= \mathbb{P}(N(t_j) - N(s_j) = 1, N(s_j) - N(t_{j-1}) = 0, \\ & \quad 1 \leq j \leq n, N(t) - N(t_n) = 0 | N(t) = n) \\ &= \prod_{j=1}^n [\lambda(t_j - s_j) e^{-\lambda(t_j - t_{j-1})}] e^{-\lambda(t-t_n)} / [\frac{(\lambda t)^n}{n!} e^{-\lambda t}] = \frac{n!}{t^n} \prod_{j=1}^n (t_j - s_j). \end{aligned}$$

定理得证. \square

已知 n 个独立 $(0, t]$ 上均匀分布随机变量 X_1, X_2, \dots, X_n 的次序统计量

$$(X_{(1)}, X_{(2)}, \dots, X_{(n)})$$

的概率密度函数为

$$p(x_1, \dots, x_n) = n! t^{-n}, \quad 0 < x_1 < x_2 < \dots < x_n < t,$$

从而对任意 $0 \leq s_1 < t_1 < \dots < s_n < t_n \leq t$, 概率

$$\mathbb{P}(X_{(j)} \in (s_j, t_j], 1 \leq j \leq n) = \frac{n!}{t^n} \prod_{j=1}^n (t_j - s_j).$$

比较上式与定理7.8结论, 我们可知在分布意义下

$$(T_1, T_2, \dots, T_n | N(t) = n) \stackrel{d}{=} (X_{(1)}, X_{(2)}, \dots, X_{(n)}),$$

即给定条件 $N(t) = n$ 后, T_1, \dots, T_n 可看作 n 个独立的 $(0, t]$ 上均匀分布随机变量的次序统计量.

例7.3 (接例7.2) 求第10位顾客到达的时间分布和平均时间.

解 由定理7.8, 在条件 $N(T) = 10$ 下, 第10个顾客到达时间 T_{10} 与10个独立的 $(0, T]$ 上均匀分布随机变量的最大次序统计量相同. 因此 T_{10} 的密度函数为

$$f(x) = 10 \frac{x^9}{T^{10}}.$$

平均时间

$$\mathbb{E}(T_{10}) = \int_0^T x f(x) dx = 10T \int_0^1 x^{10} dx = \frac{10T}{11}. \quad \square$$

作为定理7.8的应用, 我们有如下推论.

推论7.9 设 n 元函数 $f(x_1, x_2, \dots, x_n)$ 满足对于任意一个 n 级排列 (t_1, t_2, \dots, t_n) 都有

$$f(x_1, x_2, \dots, x_n) = f(x_{t_1}, x_{t_2}, \dots, x_{t_n}).$$

那么

$$\mathbb{E}(f(T_1, T_2, \dots, T_n) | N(t) = n) = \mathbb{E}(f(X_1, X_2, \dots, X_n)),$$

其中 X_1, \dots, X_n 服从 $(0, t]$ 上均匀分布的独立随机变量.

证明 由定理7.8可知

$$\mathbb{E}(f(T_1, T_2, \dots, T_n) | N(t) = n) = \mathbb{E}(f(X_{(1)}, X_{(2)}, \dots, X_{(n)})).$$

由于次序统计量只是 X_1, \dots, X_n 的一种排列, 由 f 的条件假设可知

$$\mathbb{E}(f(X_{(1)}, X_{(2)}, \dots, X_{(n)})) = \mathbb{E}(f(X_1, \dots, X_n)),$$

进而结论成立. \square

例7.4 旅客依强度为 λ 的泊松过程到达车站, 若火车在时刻 t 离站, 求在 $(0, t)$ 区间内到达的旅客的平均总等待时间.

解 记第 k 位旅客到达时刻为 T_k , t 之前到达总旅客数位 $N(t)$, 则总等待时间为

$$T = \sum_{i=1}^{N(t)} (t - T_i).$$

所求平均总等待时间为

$$\begin{aligned} \bar{T} &= \mathbb{E}(T) = \mathbb{E}\left(\sum_{i=1}^{N(t)} (t - T_i)\right) = \mathbb{E}\left(\mathbb{E}\left(\sum_{i=1}^{N(t)} (t - T_i) | N(t)\right)\right) \\ &= \sum_{n=1}^{\infty} \mathbb{E}\left(\sum_{i=1}^n (t - T_i) | N(t) = n\right) \mathbb{P}(N(t) = n) \end{aligned}$$

显然改变 T_i 次序不会影响 $\sum_{i=1}^n(t - T_i)$ 的结果, 由推论7.9,

$$\begin{aligned}\bar{T} &= \sum_{n=1}^{\infty} \mathbb{E}\left(\sum_{i=1}^n(t - X_i)\right) \mathbb{P}(N(t) = n) = \sum_{n=1}^{\infty} \left(nt - \mathbb{E}\left(\sum_{i=1}^n X_i\right)\right) \mathbb{P}(N(t) = n) \\ &= \sum_{n=1}^{\infty} \frac{nt}{2} \mathbb{P}(N(t) = n) = \frac{t}{2} \mathbb{E}(N(t)) = \frac{\lambda t^2}{2}.\end{aligned}\quad \square$$

例7.5* 设泊松过程 N 的强度为 λ , T_k 为到达时刻, $k \geq 1$. 若 $\int_0^\infty |f(t)|dt < \infty$, 证明

$$\mathbb{E}\left(\sum_{n=1}^{\infty} f(T_n)\right) = \lambda \int_0^\infty f(t)dt.$$

证明 先设 f 非负. 此时由单调收敛定理(定理4.14)

$$\begin{aligned}\mathbb{E}\left(\sum_{n=1}^{\infty} f(T_n)\right) &= \sum_{n=1}^{\infty} \mathbb{E}(f(T_n)) = \sum_{n=1}^{\infty} \int_0^\infty f(t) \frac{\lambda^n t^{n-1}}{(n-1)!} e^{-\lambda t} dt \\ &= \int_0^\infty f(t) \sum_{n=1}^{\infty} \frac{\lambda^n t^{n-1}}{(n-1)!} e^{-\lambda t} dt = \lambda \int_0^\infty f(t)dt.\end{aligned}$$

对一般的 f , 注意到 $f = f^+ - f^- = f \vee 0 - (-f) \vee 0$. 由 f 非负情形的讨论可知

$$\mathbb{E}\left(\sum_{n=1}^{\infty} |f(T_n)|\right) < \infty, \quad \mathbb{E}\left(\sum_{n=1}^{\infty} f^+(T_n)\right) < \infty, \quad \mathbb{E}\left(\sum_{n=1}^{\infty} f^-(T_n)\right) < \infty.$$

这表明级数 $\sum_{n=1}^{\infty} f(T_n)$, $\sum_{n=1}^{\infty} f^+(T_n)$ 和 $\sum_{n=1}^{\infty} f^-(T_n)$ 都几乎处处收敛. 因此

$$\sum_{n=1}^{\infty} f(T_n) = \sum_{n=1}^{\infty} (f^+(T_n) - f^-(T_n)) = \sum_{n=1}^{\infty} f^+(T_n) - \sum_{n=1}^{\infty} f^-(T_n),$$

几乎处处成立. 从而

$$\begin{aligned}\mathbb{E}\left(\sum_{n=1}^{\infty} f(T_n)\right) &= \mathbb{E}\left(\sum_{n=1}^{\infty} f^+(T_n)\right) - \mathbb{E}\left(\sum_{n=1}^{\infty} f^-(T_n)\right) \\ &= \lambda \int_0^\infty [f^+(t) - f^-(t)]dt = \lambda \int_0^\infty f(t)dt.\end{aligned}\quad \square$$

2.3.4 稀疏过程

对于计数过程 $N = \{N(t)\}$ 记录的随机事件, 有时我们需要对随机事件进行分类, 比如我们记录到达银行的顾客, 可以将顾客按性别分成两类, 对应地计数过程就会被分拆. 特别, 如果我们要求每个事件独立于其他事件以概率 p_i 归为第*i*类事件, 其中 $i = 1, \dots, m$ 且 $\sum_{i=1}^m p_i = 1$, 那么我们称记录第*i*类事件发生次数的计数过程 $N_i = \{N_i(t)\}$ 为 N 的稀疏过程.

计数过程 N 与它的稀疏过程 N_i 之间满足: 对任意 t ,

$$N(t) = \sum_{i=1}^m N_i(t).$$

对任意 $s < t$, 在给定 $(s, t]$ 时段内总的随机事件数 $N(t) - N(s)$ 条件下, 该区间内各类事件发生次数

$$(N_1(t) - N_1(s), N_2(t) - N_2(s), \dots, N_m(t) - N_m(s))$$

的联合分布是以 p_1, p_2, \dots, p_m 为发生概率的多元二项分布(参见例1.1), 而且与其它不相交区间发生的随机事件无关. 即对任意非负整数 $k_i, 1 \leq i \leq m$, 令 $k = \sum_{i=1}^m k_i$, 那么

$$\mathbb{P}(N_i(t) - N_i(s) = k_i, 1 \leq i \leq m | N(t) - N(s) = k) = \frac{k!}{k_1! k_2! \cdots k_m!} p_1^{k_1} p_2^{k_2} \cdots p_m^{k_m}, \quad (2.3.15)$$

而且对任意 $0 = t_0 < t_1 < \cdots < t_n$, 以及非负整数 $k_{ij}, 1 \leq i \leq m, 1 \leq j \leq n$,

$$\begin{aligned} & \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{ij}, 1 \leq i \leq m, 1 \leq j \leq n | N(t_l) - N(t_{l-1}), l = 1, \dots, n) \\ &= \prod_{j=1}^n \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{ij}, 1 \leq i \leq m | N(t_j) - N(t_{j-1})). \end{aligned} \quad (2.3.16)$$

定理7.10 若 N 是强度为 λ 的泊松过程, 那么它的稀疏过程 N_1, N_2, \dots, N_m 是独立的泊松过程, 强度分别 $\lambda p_1, \dots, \lambda p_m$.

证明* 我们先证明对任意 $i \geq 1$, N_i 是强度为 λp_i 的泊松过程.

对任意 $n \geq 1$, 任取 $0 = t_0 < t_1 < \cdots < t_n$ 以及非负整数 k_1, \dots, k_n . 由 N 的独立增量性和(2.3.16) 可知

$$\begin{aligned} & \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_j, j = 1, \dots, n) \\ &= \mathbb{E}[\mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_j, j = 1, \dots, n | N(t_l) - N(t_{l-1}), l = 1, \dots, n)] \\ &= \mathbb{E}\left[\prod_{j=1}^n \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_j | N(t_j) - N(t_{j-1}))\right] \\ &= \prod_{j=1}^n \mathbb{E}[\mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_j | N(t_j) - N(t_{j-1}))] \\ &= \prod_{j=1}^n \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_j). \end{aligned}$$

因此 N_i 具有独立增量. 注意到对任意 $t > s \geq 0$ 以及非负整数 k ,

$$\begin{aligned} & \mathbb{P}(N_i(t) - N_i(s) = k) = \sum_{r=0}^{\infty} \mathbb{P}(N_i(t) - N_i(s) = k, N(t) - N(s) = k+r) \\ &= \sum_{r=0}^{\infty} \mathbb{P}(N_i(t) - N_i(s) = k | N(t) - N(s) = k+r) \mathbb{P}(N(t) - N(s) = k+r). \end{aligned}$$

由(2.3.15)得

$$\begin{aligned} & \mathbb{P}(N_i(t) - N_i(s) = k) = \sum_{r=0}^{\infty} C_{k+r}^k p_i^k (1-p_i)^r \frac{[\lambda(t-s)]^{k+r}}{(k+r)!} e^{-\lambda(t-s)} \\ &= \frac{[p_i \lambda(t-s)]^k e^{-\lambda(t-s)}}{k!} \sum_{r=0}^{\infty} \frac{[\lambda(1-p_i)(t-s)]^r}{r!} \\ &= \frac{[p_i \lambda(t-s)]^k e^{-\lambda(t-s)}}{k!} e^{\lambda(1-p_i)(t-s)} = \frac{[p_i \lambda(t-s)]^k}{k!} e^{-\lambda p_i(t-s)}. \end{aligned}$$

因此 N_i 有平稳增量且增量 $N_i(t) - N_i(s)$ 服从强度为 $p_i \lambda(t-s)$ 的泊松分布. 由定理7.5 可知 N_i 是强度为 λp_i 的泊松过程.

对任意 $n \geq 1$ 以及任意 $0 = t_0 < t_1 < \cdots < t_n$, 任取非负整数 $k_{i,j}$, $1 \leq i \leq m$, $1 \leq j \leq n$,

并令 $k_j = \sum_{i=1}^m k_{i,j}$ 以及

$$A = \{N(t_j) - N(t_{j-1}) = k_j, 1 \leq j \leq n\}.$$

由条件概率公式和(2.3.16)可得

$$\begin{aligned} & \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{i,j}, 1 \leq i \leq m, 1 \leq j \leq n) \\ &= \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{i,j}, 1 \leq i \leq m, 1 \leq j \leq n | A) \mathbb{P}(A) \\ &= \mathbb{P}(A) \prod_{j=1}^n \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{i,j}, 1 \leq i \leq m | N(t_j) - N(t_{j-1}) = k_j). \end{aligned}$$

再由(2.3.15)和 N 的独立增量泊松分布可知

$$\begin{aligned} & \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{i,j}, 1 \leq i \leq m, 1 \leq j \leq n) \\ &= \prod_{j=1}^n \left[\frac{k_j!}{k_{1,j}! k_{2,j}! \cdots k_{m,j}!} p_1^{k_{1,j}} \cdots p_m^{k_{m,j}} \frac{[\lambda(t_j - t_{j-1})]^{k_j}}{k_j!} e^{-\lambda(t_j - t_{j-1})} \right] \\ &= \prod_{i=1}^m \left[\prod_{j=1}^n \frac{[\lambda p_i(t_j - t_{j-1})]^{k_{i,j}}}{k_{i,j}!} e^{-\lambda p_i(t_j - t_{j-1})} \right] \\ &= \prod_{i=1}^m \mathbb{P}(N_i(t_j) - N_i(t_{j-1}) = k_{i,j}, 1 \leq j \leq n). \end{aligned}$$

因此 $(N_i(t_1), \dots, N_i(t_n))$, $i = 1, \dots, m$ 相互独立. 由随机过程独立性判别条件(参见习题5-3)可知稀疏过程 N_i , $i = 1, \dots, m$ 独立. \square

例7.6 某商场顾客以一个强度为每小时20人的泊松过程到达, 其中10%为男性, 90%为女性.

(1) 问半个小时内至少有1个男顾客到达的概率 p . (2) 已知一小时内有4个男顾客到达条件下, 到达顾客总数的期望 n .

解 以 $N_1(t)$, $N_2(t)$ 分别记录 t 之前男, 女顾客到达的人数. 那么 N_1 , N_2 分别是强度为2和18的泊松过程且独立. 所以

(1) 所求概率 $p = \mathbb{P}(N_1(0.5) \geq 1) = 1 - \mathbb{P}(N_1(0.5) = 0) = 1 - e^{-1}$.

(2) 所求期望为 $n = 4 + \mathbb{E}(N_2(1) | N_1(1) = 4) = 4 + \mathbb{E}(N_2(1)) = 4 + 18 = 22$. \square

2.3.5 非齐次泊松过程

泊松过程要求强度为常数, 这个条件使泊松过程简单易处理, 但与现实情况会有较大差异. 泊松过程的一种推广是所谓非齐次泊松过程, 它的定义如下:

定义7.3 称计数过程 $N = \{N(t), t \geq 0\}$ 是一个强度为 $\lambda(t)$ 的非齐次泊松过程, 若她满足:

- (1) $N(0) = 0$;
- (2) N 具有独立增量;

(3) 对任意 $0 \leq s < t$, $N(t) - N(s)$ 服从强度为 $\int_s^t \lambda(u)du$ 的泊松分布.

由定义可知对非齐次的泊松过程, 在任意时刻 t , $N(t)$ 服从强度为 $\int_0^t \lambda(u)du$ 的泊松分布.

因此此计数过程首个事件发生时间 T_1 的分布满足

$$\mathbb{P}(T_1 > t) = \mathbb{P}(N(t) = 0) = e^{-\int_0^t \lambda(u)du},$$

从而密度函数为

$$f(t) = \lambda(t)e^{-\int_0^t \lambda(u)du}, \quad t \geq 0.$$

例7.7 已知某网店在不同时间段顾客访问事件是独立的, 在晚上11:00到11:30, 顾客按10人/小时的速度访问, 而11:30-12:00按6人/小时的速度访问. 问在11:00-12:00没有顾客访问的概率?

解 由于假定不同时间段顾客访问事件是独立的, 而且不同时间访问速度不同, 因此可以用非齐次泊松过程刻画 $N(t)$. 以晚11:00为起始时间, 在 $0 < t \leq 0.5$ 时间段内 $N(t)$ 的强度为10, 在 $0.5 < t \leq 1$ 时间段内强度为6. 因此所求概率 $p = e^{-8}$. \square

非齐次泊松过程也会自然出现在泊松过程的稀疏过程中, 推广定理7.10得:

定理7.11 若强度为 λ 的泊松过程在任意时刻 t 记录的事件以概率 $p_i(t)$ 归为第 i 类事件, 且与其他事件独立, 其中 $i = 1, \dots, m$ 且 $\sum_{i=1}^m p_i(t) = 1$. 那么记录第 i 类事件发生次数的计数过程 $N_i = \{N_i(t)\}$ 就是一个强度为 $\lambda p_i(t)$ 的非齐次泊松过程, 而且 N_1, N_2, \dots, N_m 相互独立.

证明* 首先, 从定理条件假设容易看出, (2.3.16)仍然成立.

对任给的 $0 \leq s < t$ 和非负整数 n , 任取非负整数 n_1, \dots, n_m 使得 $n_1 + \dots + n_m = n$. 将指标 $1, 2, \dots, n$ 随机地分成 m 组使得每组中指标个数分别是 n_1, n_2, \dots, n_m . 将所有这种分法的集合记成 A . 由组合数计算可知 A 中共有 $K := \frac{n!}{n_1!n_2!\dots n_m!}$ 种分法, 并用记号 $b_i, 1 \leq i \leq K$ 表示. 以 $B_i(j), 1 \leq j \leq m$ 表示在 b_i 这种分法下落入第 j 组的 n_j 个指标构成的集合. 对任意 $(x_1, x_2, \dots, x_n) \in (s, t]^n$, 定义

$$f(x_1, x_2, \dots, x_n) = \sum_{i=1}^K \prod_{r \in B_i(1)} p_1(x_r) \prod_{r \in B_i(2)} p_2(x_r) \cdots \prod_{r \in B_i(m)} p_m(x_r).$$

函数 f 满足

(1) 任意调换 (x_1, x_2, \dots, x_n) 的次序(记调换后的结果为 (y_1, y_2, \dots, y_n)), 由组合的无次序性以及乘法的可交换性可知

$$\begin{aligned} f(y_1, y_2, \dots, y_n) &= \sum_{i=1}^K \prod_{r \in B_i(1)} p_1(y_r) \prod_{r \in B_i(2)} p_2(y_r) \cdots \prod_{r \in B_i(m)} p_m(y_r) \\ &= \sum_{i=1}^K \prod_{r \in B_i(1)} p_1(y_r) \prod_{r \in B_i(2)} p_2(y_r) \cdots \prod_{r \in B_i(m)} p_m(y_r) \end{aligned}$$

$$= f(x_1, x_2, \dots, x_n).$$

(2) 若考察条件概率

$$\mathbb{P}(N_i(t) - N_i(s) = n_i, 1 \leq i \leq m | T_1, \dots, T_n, N(t) - N(s) = n)$$

其中 T_1, \dots, T_n 表示 N 在 (s, t) 内 n 次事件发生的时刻. 此时事件

$$\{N_i(t) - N_i(s) = n_i, 1 \leq i \leq m\}$$

可看作在 n 个具有 m 种可能结果的独立随机实验中(每次实验结果出现的概率可以不同), 各种结果出现次数分别为 n_1, n_2, \dots, n_m 的随机事件. 因此构成该随机事件的所有可能的组合方法恰为集合 A , 而 A 每种组合 b_i 出现的概率为

$$\prod_{r \in B_i(1)} p_1(T_r) \prod_{r \in B_i(2)} p_2(T_r) \cdots \prod_{r \in B_i(m)} p_m(T_r).$$

因此

$$\begin{aligned} & \mathbb{P}(N_i(t) - N_i(s) = n_i, 1 \leq i \leq m | T_1, \dots, T_n, N(t) - N(s) = n) \\ &= \sum_{i=1}^K \prod_{r \in B_i(1)} p_1(T_r) \prod_{r \in B_i(2)} p_2(T_r) \cdots \prod_{r \in B_i(m)} p_m(T_r) \\ &= f(T_1, T_2, \dots, T_n). \end{aligned}$$

由泊松过程的平稳独立增量性质, 推论7.9以及条件数学期望性质可知

$$\begin{aligned} & \mathbb{P}(N_i(t) - N_i(s) = n_i, 1 \leq i \leq m | N(t) - N(s) = n) \\ &= \mathbb{E}(f_n(T_1, \dots, T_n) | N(t) - N(s) = n) = \mathbb{E}(f(X_1, \dots, X_n)) \\ &= \sum_{i=1}^K \mathbb{E}\left(\prod_{r \in B_i(1)} p_1(X_r) \prod_{r \in B_i(2)} p_2(X_r) \cdots \prod_{r \in B_i(m)} p_m(X_r)\right) \\ &= \frac{n!}{n_1! n_2! \cdots n_m!} \left[\frac{1}{t-s} \int_s^t p_1(u) du \right]^{n_1} \cdots \left[\frac{1}{t-s} \int_s^t p_m(u) du \right]^{n_m}, \quad (2.3.17) \end{aligned}$$

其中 X_1, \dots, X_n 为 n 个独立的 (s, t) 均匀分布随机变量.

将(2.3.17)替换(2.3.15), 重复定理7.10的证明可得定理结论. \square

例7.8 假设商场顾客按强度为 K 人/小时的泊松过程到达, 每个顾客在商场停留时间服从速率 λ 的指数分布. 商场监控系统在 c 时开始工作、 $c + d$ 时停止, 假设顾客被监控系统捕捉到的概率 p 与商场监控系统工作时顾客在商场停留时间 u 满足关系式 $p = 1 - e^{-u}$, 求商场监控系统工作 d 小时捕捉到的平均顾客数 m (假定顾客行为是相互独立的).

解 记任意时刻 t 进入商场的顾客停留时间为 U_t . 那么由题设可知, 当 $t \leq c$ 时, 顾客被监控到的概率

$$p_t = \mathbb{E}(\mathbf{1}_{\{c-t \leq U_t\}} (1 - e^{-(U_t - c+t) \wedge d})) = \frac{1 - e^{-d(1+\lambda)}}{1 + \lambda} e^{\lambda(t-c)}.$$

当 $d + c > t > c$ 时, 顾客被监控到的概率

$$p_t = \mathbb{E}(1 - e^{-U_t \wedge (d+c-t)}) = \frac{1 - e^{(1+\lambda)(t-c-d)}}{1 + \lambda}.$$

因此在 $[0, c+d]$ 时段内, 被监控到的顾客按强度为 Kp_t 的非齐次泊松过程到达. 从而被监控的平均顾客数为

$$m = K \int_0^{d+c} p_t dt = K \left[\frac{(1 - e^{-d(1+\lambda)})(1 - e^{-\lambda c})}{\lambda(1 + \lambda)} + \frac{d}{1 + \lambda} - \frac{1 - e^{-(1+\lambda)d}}{(1 + \lambda)^2} \right]. \quad \square$$

练习题 以下总设 $N = \{N(t), t \geq 0\}$ 是强度为 λ 的泊松过程.

7.1 设 $T_0 = 0$, $\{T_k\}_{k \geq 1}$ 是单调不降的非负随机变量序列. 对任意 $t \geq 0$, 令 $N(t) = \sup\{k \geq 0 :$

$T_k \leq t\}$. 证明

(1) 对任意 $k \geq 1$, $T_k = \inf\{t : N(t) \geq k\}$. (2) $N(t) + 1 = \inf\{k \geq 0 : T_k > t\}$.

7.2* 若例 7.2 中泊松过程 N 的强度 λ 未知, 试给出 λ 的极大似然估计并由此计算 c 和 t .

7.3 对任意 $0 < s < t$, $n \geq 1$, 证明

$$\mathbb{P}(N(s) = k | N(t) = n) = C_n^k \left(\frac{s}{t}\right)^k \left(1 - \frac{s}{t}\right)^{n-k}, \quad k = 0, 1, \dots, n$$

7.4 设随机变量 T 与 N 独立且对任意 $t > 0$, $\mathbb{P}(T > t) = e^{-\mu t}$. 证明

$$\mathbb{P}(N(T) = k) = \frac{\mu}{\lambda + \mu} \left(\frac{\lambda}{\lambda + \mu}\right)^k, \quad k = 0, 1, 2, \dots$$

7.5 对任意 $k \geq 0$, 令 T_k 表示第 k 次随机事件发生的时间序列. 对任意 $t > x > 0$, 求(1)

$\mathbb{P}(t - T_k > x | N(t) = k)$, (2) $\mathbb{P}(t - T_{N(t)} > x)$.

7.6 对任意 $k \geq 1$, 令 W_k 表示第 k 次事件的等待时间, 对任意 $x > 0$, 求(1) $\mathbb{P}(W_{k+1} > x | N(t) = k)$, (2) $\mathbb{P}(W_{N(t)+1} > x)$.

7.7 电影院观众到达服从强度为 50 人每小时的泊松过程, 其中 40% 是男性, 60% 是女性. 假定观众到达是完全独立的. (1) 求前三个到达的观众是女性的概率?; (2) 已知最后两名观众在放映前 5 分钟内到达, 问他们是放映前两分钟到达的概率? (3) 假定观众 50% 可能不买爆米花, 30% 买 1 袋爆米花, 20% 买 2 袋爆米花. 以 N_0, N_1, N_2 分别表示一小时内没买, 买一袋, 买两袋爆米花人数, 求 (N_0, N_1, N_2) 的联合分布.

7.8* 证明引理 7.6 的必要性.

7.9* 若 $N(0) = 0$ 且对任意 $n \geq 1$ 以及 $0 = t_0 < t_1 < \dots < t_n$ 和非负整数 k_1, \dots, k_n , (2.3.5) 总成立, 证明 $N = \{N(t), t \geq 0\}$ 是平稳独立增量过程且对任意 $t, s \geq 0$, $N(t+s) - N(s)$ 服从强度为 λt 的泊松分布

7.10 考虑一个简单的高速公路入口模型. 假设汽车以速率为每分钟 5 辆的泊松过程到达高速公路甲入口, 进入高速后每辆汽车立即独立地以 40% 的可能去 A 地, 60% 的可能去往方向

不同的B地，并且以均匀分布选择(80, 120)间的某一速度匀速行驶. (1) 从某时刻开始到观察到连续两辆汽车都往A地结束，求这段时间的平均长度. (2) 若在一小时内观察到往A地汽车100辆，问在此一小时内最后一辆前往B地汽车到达甲入口的平均时间？(若此一小时内没有往B地的汽车，则认为到达时间为0) (3) 某车从甲入口进入高速后以100公里每小时速度前往B地，求20分钟内超过该车或被该车超过的汽车数量平均数.

第三章 离散时间马氏链

上一章介绍的两类随机过程都具有平稳独立增量性质。这种性质给我们讨论带来很大的方便，但在现实问题中这样的性质并不常有。人们更容易观察或更能近似观察到一种所谓的条件独立性。对这种现象建模可以使用所谓的马氏过程。本章介绍其中一类简单的模型——离散时间离散状态的马氏过程。

3.1 马氏链的定义与举例

3.1.1 条件独立与马氏链

定义8.1 称随机事件 A, B 在事件 C (要求 $\mathbb{P}(C) > 0$)，发生条件下独立，若

$$\mathbb{P}(AB|C) = \mathbb{P}(A|C)\mathbb{P}(B|C).$$

简称 A, B 条件独立。

对条件独立，如下性质成立

性质8.1 设 A, B, C 均为概率非0事件，那么以下三条等价：

- (1) A, B 在事件 C 下条件独立；
- (2) $\mathbb{P}(A|BC) = \mathbb{P}(A|C)$ ；
- (3) $\mathbb{P}(B|AC) = \mathbb{P}(B|C)$ 。

证明 (1) \Rightarrow (2), (3): 由 $\mathbb{P}(AB|C) = \mathbb{P}(A|C)\mathbb{P}(B|C)$ 可得

$$\mathbb{P}(ABC) = \mathbb{P}(A|C)\mathbb{P}(B|C)\mathbb{P}(C) = \mathbb{P}(AC)\mathbb{P}(B|C) = \mathbb{P}(A|C)\mathbb{P}(BC)$$

从而

$$\mathbb{P}(A|BC) = \mathbb{P}(A|C), \quad \mathbb{P}(B|AC) = \mathbb{P}(B|C).$$

(2) \Rightarrow (1): 由 $\mathbb{P}(A|BC) = \mathbb{P}(A|C)$ 可知

$$\mathbb{P}(ABC) = \mathbb{P}(A|C)\mathbb{P}(BC)$$

两边除以 $\mathbb{P}(C)$ 得 $\mathbb{P}(AB|C) = \mathbb{P}(A|C)\mathbb{P}(B|C)$ 。

类似可得(3) \Rightarrow (1). 证毕. \square

将条件独立的假设用到随机过程上就可定义所谓的马氏性(Markov Property). 直观而言就是要求在随机过程已知任一时刻 t 的确切状态后, t 之后发生的随机事件与 t 之前的随机事件独立. 比如

例8.1 假定例5.1中的赌徒在某个时刻 t (现在)手中筹码为 x , 经验告诉我们, 他在此后(未来)的输赢取决于此刻的筹码数而与 t 之前(过去)的筹码及输赢无关.

例8.2 假定一个罐子里有红白两种颜色共 $2N$ 个球, 做如下的抽球游戏并观察其中红球的动态变化: 从罐中任意抽出一个球, 如果是红球就放入一个白球, 如果抽出是白球就放入一个红球. 以 X_n 表示第 n 次抽取后罐里红球数. 若已知第 k (现在)次抽取后罐里有 m 个红球, 那么 k 之后(未来)从罐里取出红/白球的情况与 k 之前(过去)取出红/白球情况无关.

称具有这种马氏性的随机过程为马氏过程. 本课程只介绍其中具有离散参数和离散状态的情形, 我们称这种马氏过程为离散时间马氏链, 简称为马氏链. 由于可数状态空间中元素总可以通过适当标号区分, 因此本章内容对状态离散的向量值随机过程也成立. 但为叙述方便, 以下我们总设状态空间 S 为整数构成的集合. 马氏链定义如下:

定义8.2 设 $X = \{X_n; n \geq 0\}$ 是概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上随机过程, 状态空间 $S \subset \mathbf{Z}$, 称 $X = \{X_n; n \geq 0\}$ 为离散时间马氏链, 如果对任意 $n \geq 1$, $i_0, \dots, i_{n-1}, i, j \in S$,

$$\mathbb{P}(X_{n+1} = j | X_0 = i_0, \dots, X_{n-1} = i_{n-1}, X_n = i) = \mathbb{P}(X_{n+1} = j | X_n = i). \quad (3.1.1)$$

例8.3(存储模型) 设 $\xi_i, i = 1, 2, \dots$ 为独立同分布的非负整数值随机变量, 令

$$X_0 = K, \quad X_n = \begin{cases} 0 \vee (X_{n-1} - \xi_n), & k < X_{n-1} \leq K, \\ 0 \vee (K - \xi_n), & X_{n-1} \leq k, \end{cases} \quad n \geq 1,$$

其中 $k < K$ 为给定的两个正整数. 那么 $X = \{X_n, n \geq 0\}$ 为离散时间马氏链.

证明 显然 X 的状态空间 $S = \{0, 1, \dots, K\}$. 对任意 $n \geq 1$ 以及 $i_1, \dots, i_{n+1} \in S$,

$$\begin{aligned} & \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n, \dots, X_1 = i_1, X_0 = K) \\ &= \begin{cases} \mathbb{P}((K - \xi_{n+1}) \vee 0 = i_{n+1} | X_n = i_n, \dots, X_0 = K), & i_n \leq k, \\ \mathbb{P}((i_n - \xi_{n+1}) \vee 0 = i_{n+1} | X_n = i_n, \dots, X_0 = K), & k < i_n \leq K, \end{cases} \end{aligned}$$

对任意 $i \geq 1$, 由 X_i 的定义可知 X_i 为 X_{i-1} 与 ξ_i 的函数, 如此递归代入后可知 X_i 是随机变量 ξ_1, \dots, ξ_i 的函数. 这表明事件

$$\{X_n = i_n, \dots, X_1 = i_1, X_0 = K\}$$

由随机变量 ξ_1, \dots, ξ_n 确定. 再由 $\{\xi_i, i \geq 1\}$ 的独立性

$$\begin{aligned} & \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n, \dots, X_1 = i_1, X_0 = K) \\ &= \begin{cases} \mathbb{P}((K - \xi_{n+1}) \vee 0 = i_{n+1}), & i_n \leq k, \\ \mathbb{P}((i_n - \xi_{n+1}) \vee 0 = i_{n+1}), & k < i_n \leq K, \end{cases} \\ &= \begin{cases} \mathbb{P}((K - \xi_{n+1}) \vee 0 = i_{n+1} | X_n = i_n), & i_n \leq k, \\ \mathbb{P}((i_n - \xi_{n+1}) \vee 0 = i_{n+1} | X_n = i_n), & k < i_n \leq K, \end{cases} \\ &= \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n). \end{aligned}$$

所以 X 为离散时间马氏链. \square

一般称该马氏链为离散存储模型, 其中 ξ_i 表示第*i*个周期的市场需求量, X_i 表示第*i*个周期末的商品仓储量, K 为最大库存量, k 为补货策略边界值, 即若在每个周期末若商品仓储量大于 k 则不补货, 若不大于 k , 则在下一个周期开始时补足货物到 K . 在物流管理问题中常关心的问题是确定合适的 k, K 值使得仓储成本最小.

注8.2 需要指出的是在马氏过程定义中要求确切知道现在*n*时刻的状态. 若现在的状态不是唯一已知的, 那么即使是马氏链, 条件独立性也可能不成立. 例如, 由习题6.1可知(q, p)-随机游动 W 是马氏链, 若 $\mathbb{P}(X_0 = 0) = \mathbb{P}(X_0 = 2) = 1/2$ 且 $p \neq q$, 则

$$p = \mathbb{P}(W_2 = 2 | W_1 \in \{1, 3\}, W_0 = 0) \neq \mathbb{P}(W_2 = 2 | W_1 \in \{1, 3\}) = \frac{p + pq}{1 + p}.$$

3.1.2 马氏链的等价刻画

在马氏性中我们还可以对代表过去与未来的随机事件用更宽泛的形式表示.

定理8.2 X 是马氏链当且仅当对任意 $n \geq 1$, 非负整数 $0 \leq t_1 < t_2 < \dots < t_n < t$, 以及整数 $i_1, \dots, i_{n+1} \in S$, 都有

$$\mathbb{P}(X_t = i_{n+1} | X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n) = \mathbb{P}(X_t = i_{n+1} | X_{t_n} = i_n). \quad (3.1.2)$$

证明* 只需要证明必要性. 首先注意到由全概率公式和(3.1.1), 对任意 $n \geq k \geq 0$

$$\begin{aligned} & \mathbb{P}(X_{n+1} = i_{n+1} | X_k = i_k, \dots, X_{n-1} = i_{n-1}, X_n = i_n) \\ &= \frac{\mathbb{P}(X_{n+1} = i_{n+1}, X_n = i_n, \dots, X_k = i_k)}{\mathbb{P}(X_n = i_n, \dots, X_k = i_k)} \\ &= \sum_{j_0, \dots, j_{k-1} \in S} \frac{\mathbb{P}(X_{n+1} = i_{n+1}, X_n = i_n, \dots, X_k = i_k, X_{k-1} = j_{k-1}, \dots, X_0 = j_0)}{\mathbb{P}(X_n = i_n, \dots, X_k = i_k)} \\ &= \sum_{j_0, \dots, j_{k-1} \in S} \left[\frac{\mathbb{P}(X_{n+1} = i_{n+1}, X_n = i_n, \dots, X_k = i_k, X_{k-1} = j_{k-1}, \dots, X_0 = j_0)}{\mathbb{P}(X_n = i_n, \dots, X_k = i_k, X_{k-1} = j_{k-1}, \dots, X_0 = j_0)} \right] \end{aligned}$$

$$\begin{aligned} & \times \frac{\mathbb{P}(X_n = i_n, \dots, X_k = i_k, X_{k-1} = j_{k-1}, \dots, X_0 = j_0)}{\mathbb{P}(X_n = i_n, \dots, X_k = i_k)} \Big] \\ & = \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n) \end{aligned} \quad (3.1.3)$$

下面我们证明对任意 $m \geq 1, n \geq 0$,

$$\begin{aligned} & \mathbb{P}(X_{n+1} = i_{n+1}, \dots, X_{n+m} = i_{n+m} | X_k = i_k, X_{k+1} = i_{k+1}, \dots, X_n = i_n) \\ & = \mathbb{P}(X_{n+1} = i_{n+1}, \dots, X_{n+m} = i_{n+m} | X_n = i_n), \quad 0 \leq k \leq n. \end{aligned} \quad (3.1.4)$$

当 $m = 1$ 时(3.1.4)显然对任意 $n \geq 0$ 以及 $0 \leq k \leq n$ 成立. 设 $m \leq l - 1$ 时(3.1.4)显然对任意 $n \geq 0$ 以及 $0 \leq k \leq n$ 成立, 那么当 $m = l$ 时, 对任意 $n \geq 0$ 以及 $0 \leq k \leq n$, 记

$$\begin{aligned} A &= \{X_k = i_k, \dots, X_{n-1} = i_{n-1}\}, \quad B = \{X_n = i_n\}, \quad C = \{X_{n+1} = i_{n+1}\}, \\ D &= \{X_{n+2} = i_{n+2}, \dots, X_{n+l} = i_{n+l}\}. \end{aligned}$$

此时由归纳假设可得

$$\mathbb{P}(D|ABC) = \mathbb{P}(D|C) = \mathbb{P}(D|BC), \quad \mathbb{P}(C|AB) = \mathbb{P}(C|B).$$

因此

$$\begin{aligned} \text{l.h.s of (3.1.4)} &= \mathbb{P}(CD|AB) = \mathbb{P}(ABCD)/\mathbb{P}(AB) \\ &= \mathbb{P}(D|ABC)\mathbb{P}(C|BA) = \mathbb{P}(D|C)\mathbb{P}(C|B) = \mathbb{P}(D|CB)\mathbb{P}(C|B) \\ &= \mathbb{P}(DC|B) = \text{r.h.s of (3.1.4)}. \end{aligned}$$

由数学归纳法可知(3.1.4)显然对任意 $m \geq 1, n \geq 0$ 以及 $0 \leq k \leq n$ 成立.

最后我们注意到, 由全概率公式

$$\begin{aligned} & \mathbb{P}(X_t = i_{n+1} | X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n) \\ &= \frac{\mathbb{P}(X_t = i_{n+1}, X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n)}{\mathbb{P}(X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n)} \\ &= \sum_{j_s \in S, 0 \leq s < t}^{s \neq t_1, \dots, t_n} \frac{\mathbb{P}(X_t = i_{n+1}, X_{t_k} = i_k, X_s = j_s, t_1 \leq s < t, s \neq t_k, 1 \leq k \leq n)}{\mathbb{P}(X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n)} \end{aligned}$$

再由(3.1.4)得

$$\begin{aligned} & \mathbb{P}(X_t = i_{n+1} | X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n) \\ &= \sum_{j_s \in S, t_n < s < t} \mathbb{P}(X_t = i_{n+1}, X_s = j_s, t_n < s < t | X_{t_n} = i_n) \\ & \quad \times \sum_{j_s \in S, 0 \leq s < t_n}^{s \neq t_1, \dots, t_n} \frac{\mathbb{P}(X_{t_k} = i_k, X_s = j_s, t_1 \leq s < t_n, s \neq t_k, 1 \leq k \leq n)}{\mathbb{P}(X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n)} \\ &= \mathbb{P}(X_t = i_{n+1} | X_{t_n} = i_n) \end{aligned}$$

因此 X 是马氏链. □

进一步, 由(3.1.4)易证对任意一个时刻 n 之后的随机事件

$$A = \{X_{n+k_1} = i_{n+1}, \dots, X_{n+k_l} = i_{n+l}\},$$

和任意一个 n 之前的随机事件

$$B = \{X_{t_1} = i_1, \dots, X_{t_m} = i_m\}$$

其中 $0 \leq t_1 < \dots < t_m < n$, 都有

$$\mathbb{P}(AB|X_n = i_n) = \mathbb{P}(A|X_n = i_n)\mathbb{P}(B|X_n = i_n). \quad (3.1.5)$$

具体证明请读者完成(参见习题8.6).

3.1.3 转移概率矩阵与C-K方程

由(3.1.2)和(3.1.1)可知, 对离散时间马氏链, 下面的条件概率是基本的

$$\mathbb{P}(X_{n+m} = j|X_n = i).$$

定义8.3 称条件概率 $\mathbb{P}(X_{n+m} = j|X_n = i)$ 为马氏链 X 由时刻 n 状态 i 经 m 步转移到状态 j 的转移概率, 记作 $p_{i,j}^{(n,n+m)}$ 或 $p(n, i; n+m, j)$. 若对任意 i, j, m , $p_{i,j}^{(n,n+m)}$ 与 n 无关, 即

$$\mathbb{P}(X_{n+m} = j|X_n = i) = \mathbb{P}(X_m = j|X_0 = i)$$

对任意 i, j, n, m 成立, 则称转移概率是时齐的(或平稳的). 此时常将 $p_{i,j}^{(n,n+m)}$ 简记成 $p_{i,j}^{(m)}$, 称之为从状态 i 到状态 j 的 m 步转移概率. 特别简记 $p_{i,j}^{(1)}$ 为 $p_{i,j}$, 并简称为从状态 i 到状态 j 的转移

概率. 约定 $p_{i,j}^{(0)} = \delta_{ij} = \begin{cases} 1, & i = j \\ 0, & i \neq j. \end{cases}$

定义8.4 称马氏链 X 是时齐的, 如果 X 的转移概率是平稳的.

定理8.3 设 $X = \{X_n; n \geq 0\}$ 是时齐马氏链, 则对任意 $n, m \geq 1$ 及 $i, j \in S$

$$p_{i,j}^{(n+m)} = \sum_{k \in S} p_{i,k}^{(n)} p_{k,j}^{(m)}. \quad (3.1.6)$$

由此可知 $p_{i,j}^{(n)} = \sum_{j_1 \in S} \dots \sum_{j_{n-1} \in S} p_{i,j_1} p_{j_1, j_2} \dots p_{j_{n-1}, j}$.

证明 只需证明(3.1.6). 由全概率公式

$$p_{i,j}^{(n+m)} = \mathbb{P}(X_{n+m} = j|X_0 = i) = \sum_{k \in S} \mathbb{P}(X_{n+m} = j, X_n = k|X_0 = i).$$

再由条件概率公式与马氏性(3.1.2)

$$\begin{aligned} \mathbb{P}(X_{n+m} = j, X_n = k|X_0 = i) &= \frac{\mathbb{P}(X_{n+m} = j, X_n = k, X_0 = i)}{\mathbb{P}(X_0 = i)} \\ &= \frac{\mathbb{P}(X_{n+m} = j, X_n = k, X_0 = i)}{\mathbb{P}(X_n = k, X_0 = i)} \frac{\mathbb{P}(X_n = k, X_0 = i)}{\mathbb{P}(X_0 = i)} \\ &= \mathbb{P}(X_{n+m} = j|X_n = k) \mathbb{P}(X_n = k|X_0 = i) = p_{k,j}^{(m)} p_{i,k}^{(n)} \end{aligned}$$

由此可知(3.1.6)成立. \square

通常称(3.1.6)为Chapmann-Kolmogorov(C-K)方程. 证明C-K方程中所用全概率公式、条件概率公式以及马氏性的组合方法是研究马氏链的基本技巧.

以后若无特别说明, 本课程所涉及马氏链 X 都是时齐的.

定义8.5 将马氏链 $X = \{X_n; n \geq 0\}$ 所有的转移概率排成矩阵形式 $\mathbf{P} = (p_{i,j})_{i,j \in S}$, 称此矩阵为 X 的转移概率矩阵; 称 $\mathbf{P}^{(n)} = (p_{i,j}^{(n)})_{i,j \in S}$ 为 X 的 n 阶(步)转移概率矩阵.

注8.4 转移概率矩阵满足:

$$(1) p_{i,j} \geq 0, i, j \in S, \quad (2) \sum_{j \in S} p_{i,j} = 1, i \in S.$$

一般称满足这两条件的矩阵为随机矩阵.

例8.4 由习题6.1以及(2.2.2)可知直线上的 (q, p) 随机游动是一个时齐马氏链, 转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} \cdots & \cdots & \cdots & \cdots & \cdots \\ \cdots & 0 & p & 0 & 0 & 0 & \cdots \\ \cdots & q & 0 & p & 0 & 0 & \cdots \\ \cdots & 0 & q & 0 & p & 0 & \cdots \\ \cdots & 0 & 0 & q & 0 & p & \cdots \\ \cdots & 0 & 0 & 0 & q & 0 & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \end{pmatrix}.$$

当 S 只有有限个状态时, 比如 $S = \{1, 2, \dots, N\}$, 由C-K方程, 对任意 $n, m > 0$

$$\begin{aligned} \mathbf{P}^{(n+m)} &= (p_{i,j}^{(n+m)})_N = \left(\sum_{k=1}^N p_{i,k}^{(n)} p_{k,j}^{(m)} \right)_{N \times N} \\ &= (p_{i,j}^{(n)})_N (p_{i,j}^{(m)})_N = \mathbf{P}^{(n)} \mathbf{P}^{(m)} = \mathbf{P}^{n+m}. \end{aligned}$$

类似的记法也可用到 S 有无穷多个状态的情形. 因此我们总有

$$\mathbf{P}^{(n+m)} = \mathbf{P}^{(n)} \mathbf{P}^{(m)} = \mathbf{P}^{n+m}.$$

显然, 对状态有限的马氏链, 要了解其 n 步转移概率矩阵, 可以通过线性代数中学过的矩阵运算实现.

例8.5 通常我们把社会划分为若干个阶层, 比如上, 中, 下3种, 分别以1, 2, 3表示. 为了研究社会阶层的流动情况, 任意选取某个家族. X_n 表示该家族第 n 代所处的社会阶层. 一个简单的社会学模型认为第 $n+1$ 代的社会地位只取决于其父代的社会地位. 若假定

$$\mathbb{P}(X_{n+1} = 1 | X_n = 1) = 0.8, \quad \mathbb{P}(X_{n+1} = 2 | X_n = 1) = 0.1,$$

$$\mathbb{P}(X_{n+1} = 3 | X_n = 1) = 0.1, \quad \mathbb{P}(X_{n+1} = 1 | X_n = 2) = 0.3,$$

$$\mathbb{P}(X_{n+1} = 2|X_n = 2) = 0.4, \quad \mathbb{P}(X_{n+1} = 3|X_n = 2) = 0.3,$$

$$\mathbb{P}(X_{n+1} = 1|X_n = 3) = 0.05, \quad \mathbb{P}(X_{n+1} = 2|X_n = 3) = 0.1,$$

$$\mathbb{P}(X_{n+1} = 3|X_n = 3) = 0.85.$$

那么 $\{X_n\}$ 构成一个马氏链, 转移概率矩阵

$$\mathbf{P} = \begin{pmatrix} 0.8 & 0.1 & 0.1 \\ 0.3 & 0.4 & 0.3 \\ 0.05 & 0.1 & 0.85 \end{pmatrix}.$$

由高等代数知识可知, \mathbf{P} 有三个不同特征值1,0.3和0.75, 对应特征向量可取为

$$(1, 1, 1)', (1, -6, 1)' 和 (-26, -6, 19)'.$$

因此

$$\mathbf{P} = \begin{pmatrix} 1 & 1 & -26 \\ 1 & -6 & -6 \\ 1 & 1 & 19 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & 0.3 & 0 \\ 0 & 0 & 0.75 \end{pmatrix} \left[\frac{1}{315} \begin{pmatrix} 108 & 45 & 162 \\ 25 & -45 & 20 \\ -7 & 0 & 7 \end{pmatrix} \right].$$

从而对任意 $n \geq 1$,

$$\mathbf{P}^{(n)} = \mathbf{P}^n = \begin{pmatrix} 1 & 1 & -26 \\ 1 & -6 & -6 \\ 1 & 1 & 19 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & 0.3^n & 0 \\ 0 & 0 & 0.75^n \end{pmatrix} \left[\frac{1}{315} \begin{pmatrix} 108 & 45 & 162 \\ 25 & -45 & 20 \\ -7 & 0 & 7 \end{pmatrix} \right].$$

计算后可知 n 步转移概率矩阵 $\mathbf{P}^{(n)}$ 为

$$\frac{1}{315} \begin{pmatrix} 108 + 25 \cdot 0.3^n + 182 \cdot 0.75^n & 45 - 45 \cdot 0.3^n & 162 + 20 \cdot 0.3^n - 182 \cdot 0.75^n \\ 108 - 150 \cdot 0.3^n + 42 \cdot 0.75^n & 45 + 270 \cdot 0.3^n & 162 - 120 \cdot 0.3^n - 42 \cdot 0.75^n \\ 108 + 25 \cdot 0.3^n - 133 \cdot 0.75^n & 45 - 45 \cdot 0.3^n & 162 + 20 \cdot 0.3^n + 133 \cdot 0.75^n \end{pmatrix}.$$

比如 $n = 5$ 时,

$$\mathbf{P}^{(5)} = \begin{pmatrix} 0.480 & 0.143 & 0.377 \\ 0.373 & 0.145 & 0.482 \\ 0.243 & 0.142 & 0.615 \end{pmatrix}.$$

由此可知

$$p_{2,3}^{(5)} = \mathbb{P}(X_5 = 3|X_0 = 2) = 0.482.$$

在该模型下, 祖父为社会中层的家庭到他曾孙辈有48.2%的概率处于社会下层. \square

3.1.4 有限维分布

定理8.4 设 $\mathbf{P} = (p_{i,j})_{i,j \in S}$ 是马氏链 X 的转移概率矩阵, 且设 $\mathbb{P}(X_0 = i) = p_i$, 那么对任意 $0 \leq t_1 < t_2 < \dots < t_n$ 以及 $i_1, \dots, i_n \in S$,

$$\mathbb{P}(X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_n} = i_n) = \sum_{i \in S} p_i p_{i,i_1}^{(t_1)} p_{i_1,i_2}^{(t_2-t_1)} \cdots p_{i_{n-1},i_n}^{(t_n-t_{n-1})}.$$

证明 由条件概率公式与马氏性

$$\begin{aligned} & \mathbb{P}(X_{t_1} = i_1, \dots, X_{t_n} = i_n) \\ &= \mathbb{P}(X_{t_n} = i_n | X_{t_{n-1}} = i_{n-1}, \dots, X_{t_1} = i_1) \mathbb{P}(X_{t_{n-1}} = i_{n-1}, \dots, X_{t_1} = i_1) \\ &= p_{i_{n-1},i_n}^{(t_n-t_{n-1})} \mathbb{P}(X_{t_{n-1}} = i_{n-1}, \dots, X_{t_1} = i_1) = \cdots \\ &= p_{i_{n-1},i_n}^{(t_n-t_{n-1})} \cdots p_{i_1,i_2}^{(t_2-t_1)} \sum_{i \in S} \mathbb{P}(X_{t_1} = i_1, X_0 = i) \\ &= \sum_{i \in S} p_i p_{i,i_1}^{(t_1)} p_{i_1,i_2}^{(t_2-t_1)} \cdots p_{i_{n-1},i_n}^{(t_n-t_{n-1})}. \end{aligned} \quad \square$$

定理8.4表明马氏链的有限维分布由初始分布以及转移矩阵唯一确定. 进而, 对任意给定的随机矩阵 \mathbf{P} 以及初始分布 $\pi = \{p_i, i \in S\}$, 由Kolmogorov 定理可知存在一个马氏链 X 使其转移概率矩阵恰为 \mathbf{P} .

例8.6(排队模型) 设 $\xi_i, i \geq 1$ 为独立同分布的非负整数值随机变量, 另设 X_0 也为一非负整数值随机变量且与 $\{\xi_i, i \geq 1\}$ 独立, 对 $n \geq 1$, 令

$$X_n = \begin{cases} X_{n-1} - 1 + \xi_n, & X_{n-1} > 0, \\ \xi_n, & X_{n-1} = 0. \end{cases}$$

证明 $X = \{X_n; n \geq 0\}$ 为离散时间马氏链. 若记 $p_k = \mathbb{P}(\xi_1 = k)$, 求 X 的转移概率矩阵. 进一步若设 $u_k = \mathbb{P}(X_0 = k)$, 求 $\mathbb{P}(X_0 = 1, X_1 = 2, X_3 = 4)$.

证明 显然 X 的状态空间 $S = \{0, 1, \dots\}$. 对任意 $n \geq 1$ 以及非负整数 i_0, \dots, i_{n+1} ,

$$\begin{aligned} & \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n, \dots, X_1 = i_1, X_0 = i_0) \\ &= \begin{cases} \mathbb{P}(i_n - 1 + \xi_{n+1} = i_{n+1} | X_n = i_n, \dots, X_0 = i_0), & i_n > 0, \\ \mathbb{P}(\xi_{n+1} = i_{n+1} | X_n = i_n, \dots, X_0 = i_0), & i_n = 0, \end{cases} \end{aligned}$$

与例8.3类似的分析可知 $\{X_n = i_n, \dots, X_1 = i_1, X_0 = i_0\}$ 由随机变量 X_0, ξ_1, \dots, ξ_n 确定. 因此由独立性假设,

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

$$\begin{aligned}
&= \begin{cases} \mathbb{P}(i_n - 1 + \xi_{n+1} = i_{n+1}), & i_n > 0, \\ \mathbb{P}(\xi_{n+1} = i_{n+1}), & i_n = 0, \end{cases} \\
&= \begin{cases} \mathbb{P}(i_n - 1 + \xi_{n+1} = i_{n+1} | X_n = i_n), & i_n > 0, \\ \mathbb{P}(\xi_{n+1} = i_{n+1} | X_n = i_n), & i_n = 0, \end{cases} \\
&= \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n).
\end{aligned}$$

所以 X 为离散时间马氏链. 直接计算可知

$$\begin{aligned}
p_{i,j} &= \mathbb{P}(X_1 = j | X_0 = i) = \begin{cases} \mathbb{P}(\xi_1 = j + 1 - i), & i \neq 0 \\ \mathbb{P}(\xi_1 = j), & i = 0 \end{cases} \\
&= \begin{cases} p_{j+1-i}, & i \neq 0 \text{ 且 } j + 1 - i \geq 0, \\ 0; & i \neq 0 \text{ 且 } j + 1 - i < 0, \\ p_j; & i = 0. \end{cases}
\end{aligned}$$

因此 X 的转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} p_0 & p_1 & p_2 & p_3 & p_4 & \cdots \\ p_0 & p_1 & p_2 & p_3 & p_4 & \cdots \\ 0 & p_0 & p_1 & p_2 & p_3 & \cdots \\ 0 & 0 & p_0 & p_1 & p_2 & \cdots \\ 0 & 0 & 0 & p_0 & p_1 & \cdots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \cdots \end{pmatrix} \quad \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \\ \cdot \end{matrix}$$

由定理8.4, 有限维分布

$$\begin{aligned}
&\mathbb{P}(X_0 = 1, X_1 = 2, X_3 = 4) = u_1 p_{1,2} p_{2,4}^{(2)} \\
&= u_1 p_2 (p_{2,1} p_{1,4} + p_{2,2} p_{2,4} + p_{2,3} p_{3,4} + p_{2,4} p_{4,4} + p_{2,5} p_{5,4}) \\
&= u_1 p_2 (p_0 p_4 + p_1 p_3 + p_2 p_2 + p_3 p_1 + p_4 p_0) \\
&= u_1 p_2 (2p_0 p_4 + 2p_1 p_3 + p_2 p_2). \quad \square
\end{aligned}$$

练习题

8.1 在仓储模型中设 $\mathbb{P}(\xi_1 = 0) = 0.1, \mathbb{P}(\xi_1 = 1) = 0.2, \mathbb{P}(\xi_1 = 2) = 0.3, \mathbb{P}(\xi_1 = 3) = 0.2, \mathbb{P}(\xi_1 = 4) = 0.2, k = 2, K = 4$. 求该模型的转移概率矩阵.

8.2 设马氏链的状态空间 $S = \{0, 1, 2\}$, 转移概率矩阵 $\mathbf{P} = \begin{pmatrix} 1 & 0 & 0 \\ 1/4 & 1/2 & 1/4 \\ 0 & 0 & 1 \end{pmatrix}$, 求 n 阶转移矩阵 $\mathbf{P}^{(n)}$.

8.3 设 $N = \{N(t), t \geq 0\}$ 为泊松过程. 任取 $t_0 > 0$. 证明 $Y = \{N(nt_0), n \geq 0\}$ 是马氏链.

8.4 (Wright-Fisher 模型) 考虑一个有 N 个基因的固定群体, 基因是 A 或 a 这两种类型. 假定这个群体在 $n+1$ 时基因的状态是通过时刻 n 的状态变异得到. 进一步假设每个基因发生变异的机会是等可能的, 由 A 变异为 a 的概率为 p , 由 a 变异为 A 的概率为 q . 以 X_n 表示 n 时刻基因中 A 的个数, 那么此时 $\{X_n\}$ 就是个马氏链. 试写出该模型的转移概率矩阵.

8.5 设 X 是状态空间为 S 的时齐马氏链, 证明对任意 $n \geq 1, i \in S$ 以及 $S_m \subset S, m \geq 0$,

$$\mathbb{P}\left(\bigcap_{m=n+1}^{\infty} \{X_m \in S_m\} \mid X_n = i, \bigcap_{m=0}^{n-1} \{X_m \in S_m\}\right) = \mathbb{P}\left(\bigcap_{m=1}^{\infty} \{X_m \in S_{n+m}\} \mid X_0 = i\right).$$

8.6* 试证明(3.1.5).

3.2 状态分类

以下总设马氏链 $X = \{X_n; n \geq 0\}$ 的转移概率矩阵 $\mathbf{P} = (p_{i,j})_{i,j \in S}$. 为方便, 分别记 $\mathbb{E}(\cdot | X_0 = i)$ 和 $\mathbb{P}(\cdot | X_0 = i)$ 为 $\mathbb{E}_i(\cdot)$ 和 $\mathbb{P}_i(\cdot)$.

3.2.1 互通、本质与不可约

定义9.1 如果存在 $n \geq 0$ 使得 $p_{i,j}^{(n)} > 0$, 则称状态 i 可达状态 j , 记作 $i \rightarrow j$. 反之, 则对任意 $n \geq 0$, $p_{i,j}^{(n)} = 0$, 称状态 i 不可达状态 j , 记作 $i \not\rightarrow j$. 若 $i \rightarrow j$ 且 $j \rightarrow i$, 则称 i, j 互通, 记作 $i \leftrightarrow j$.

由于 $p_{i,j}^{(0)} = \delta(i,j) = \begin{cases} 1, & i=j \\ 0, & i \neq j \end{cases}$, 因此对任意状态 i , 它与自己总是互通的.

命题9.1 互通是一种等价关系. 即互通关系满足

- (1) 反身性 $i \leftrightarrow i$;
- (2) 对称性; $i \leftrightarrow j \Rightarrow j \leftrightarrow i$;
- (3) 传递性 $i \leftrightarrow j, j \leftrightarrow k \Rightarrow i \leftrightarrow k$.

证明 只需证明(3)传递性. 由 $i \leftrightarrow j, j \leftrightarrow k$ 可知, 存在非负整数 n, m, r, l 使得

$$p_{i,j}^{(n)} > 0, \quad p_{j,i}^{(m)} > 0, \quad p_{j,k}^{(r)} > 0, \quad p_{k,j}^{(l)} > 0.$$

由C-K方程可知,

$$p_{i,k}^{(n+r)} \geq p_{i,j}^{(n)} p_{j,k}^{(r)} > 0; \quad p_{k,i}^{(l+m)} \geq p_{k,j}^{(l)} p_{j,i}^{(m)} > 0.$$

因此 $i \leftrightarrow k$. □

定义9.2 记 $C(i) = \{k \in S; k \leftrightarrow i\}$, 称 $C(i)$ 为包含状态 i 的互通类. 由互通等价性可知 $C(i)$ 中任意两状态互通而且

$$C(i) \cap C(j) \neq \emptyset \Leftrightarrow C(i) = C(j).$$

特别, 若 $p_{ii} = 1$, 则称 i 为吸收的, 此时 $C(i) = \{i\}$. 反过来, 由 $C(i) = \{i\}$ 不能推出 i 是吸收的.

例9.1 若马氏链 X 的转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} 1/3 & 2/3 & 0 & 0 & 0 \\ 0 & 1/2 & 1/2 & 0 & 0 \\ 3/4 & 1/4 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{pmatrix} \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \end{matrix}$$

那么由 $0 \rightarrow 1, 1 \rightarrow 2, 2 \rightarrow 0$ 可知 $\{0, 1, 2\} \subset C(0)$. 再由 $0 \not\rightarrow 3, 0 \not\rightarrow 4$ 可知 $\{0, 1, 2\} = C(0)$.

同样可知 $C(3) = \{3\}, C(4) = \{4\}$. 因此 X 的状态空间包含 3 个互通类 $C(0), C(3), C(4)$. 此

时 X 不是不可约的马氏链. \square

定义9.3 称状态 i 是本质的, 若对任意 $j \in S$, 由 $i \rightarrow j$ 可得 $j \rightarrow i$.

显然吸收态是本质的, 进一步容易看出

性质9.2 若 i 是本质的, 那么 $C(i)$ 中所有状态都是本质的. 此时我们称 $C(i)$ 为本质类.

证明 任取 $j \in C(i)$, 若 $j \rightarrow k$, 则由 $i \rightarrow j$ 可知 $i \rightarrow k$, 再由 i 本质可知, $k \rightarrow i$, 从而 $k \in C(i)$, $k \rightarrow j$. 即 j 是本质的. \square

定义9.4 若马氏链 X 的所有状态都是互通的, 即对任意 $i \in S$, $S = C(i)$, 则称 X 是不可约的(irreducible).

不可约链的状态都是本质的.

例9.2 若马氏链 X 的转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} 1/3 & 2/3 & 0 & 0 & 0 \\ 0 & 1/2 & 1/2 & 0 & 0 \\ 3/4 & 0 & 0 & 0 & 1/4 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{pmatrix} \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \end{matrix}$$

那么由 $0 \rightarrow 1, 1 \rightarrow 2, 2 \rightarrow 0, 2 \rightarrow 4, 4 \rightarrow 3, 3 \rightarrow 2$ 可知, X 是不可约的. \square

例9.3 若马氏链 X 的转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} 1/3 & 2/3 & 0 & 0 & 0 \\ 0 & 1/2 & 1/2 & 0 & 0 \\ 3/4 & 1/4 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 \end{pmatrix} \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \end{matrix}$$

那么由 $0 \rightarrow 1, 1 \rightarrow 2, 2 \rightarrow 0$ 可知, $\{0, 1, 2\} \subset C(0)$. 再由 $0 \not\rightarrow 3, 0 \not\rightarrow 4$ 可知 $\{0, 1, 2\} = C(0)$.

同样可知 $C(3) = \{3, 4\}$. 因此 X 的状态空间包含2个互通类 $C(0), C(3)$. 此时 X 不是不可约的马氏链. \square

3.2.2 周期性

定义9.5 设 i 是马氏链 X 的一个状态, 若正整数集 $\{n \geq 1; p_{i,i}^{(n)} > 0\}$ 非空, 其中元素的最大公因数 d_i 称为是状态 i 的周期. 若对所有 $n \geq 1$, $p_{i,i}^{(n)} = 0$, 则约定 i 的周期是 ∞ . 若 i 的周期为1, 即 $d_i = 1$, 则称 i 是非周期的.

由周期定义可知, 若 $d_i \nmid n$, 则 $p_{i,i}^{(n)} = 0$.

命题9.3 同一个互通类中的状态周期相同, 即对任意 $j \in C(i)$, $d_i = d_j$.

证明 由 $i \leftrightarrow j$ 可知, 存在正整数 $n, m > 0$ 使得 $p_{i,j}^{(n)} > 0, p_{j,i}^{(m)} > 0$. 则由C-K方程,

$$p_{i,i}^{(n+m)} \geq p_{i,j}^{(n)} p_{j,i}^{(m)} > 0, \quad p_{j,j}^{(n+m)} \geq p_{j,i}^{(m)} p_{i,j}^{(n)} > 0.$$

因此 $d_i | n+m, d_j | n+m$. 另外, 对任意 $l > 0$, 若 $p_{i,i}^{(l)} > 0$, 则

$$p_{j,j}^{(n+m+l)} \geq p_{j,i}^{(m)} p_{i,i}^{(l)} p_{i,j}^{(n)} > 0.$$

这表明 $d_j | l+m+n$, 从而 $d_j | l$. 由此可得 $d_j | d_i$. 类似可得 $d_i | d_j$. 因此 $d_i = d_j$. \square

定义9.6 若马氏链 X 的每一个状态都有相同的周期 d , 称 X 是 d 周期马氏链. 特别, 若 $d = 1$, 则称 X 是非周期的.

例9.4 (q, p) -简单随机游动 W 是个周期 $d = 2$ 的不可约马氏链. 事实上对任意 $i, j \in \mathbf{Z}$ (不妨设 $j > i$),

$$p_{i,j}^{(j-i)} = p^{j-i} > 0, \quad p_{j,i}^{(j-i)} = q^{j-i} > 0.$$

所以 $i \leftrightarrow j$, 即 $\mathbf{Z} = C(0)$, 从而 W 是不可约的. 对任意 $i \in \mathbf{Z}$, 由

$$p_{i,i}^{(n)} = p_{0,0}^{(n)} = \begin{cases} 0, & n = 2k - 1, \\ C_{2k}^k p^k q^k, & n = 2k, \end{cases}$$

可知 $d_i = 2$, 因此 W 的周期 $d = 2$. \square

例9.5 考虑例7.6中定义的排队模型 X , 若 $0 < p_0$ 且 $p_0 + p_1 < 1$, 那么 X 是不可约的非周期马氏链.

证明 由 $0 < p_0$ 以及 $0 < p_0 + p_1 < 1$ 可知, 必存在 $k \geq 2$ 使得 $p_k > 0$. 对任意 $i, j \geq 0$, 不妨设 $j > i$, 由 $p_{j,i}^{(j-i)} = p_0^{j-i} > 0$ 可知 $j \rightarrow i$.

反过来, 当 $i \neq 0$ 时

$$p_{i,j}^{((k-1)(j-i))} \geq p_{i,i+(k-1)(j-i)}^{(j-i)} p_{i+(k-1)(j-i),j}^{((k-2)(j-i))} \geq p_k^{j-i} p_0^{(k-2)(j-i)} > 0,$$

即 $i \rightarrow j$; 而当 $i = 0$ 时, 由 $p_k > 0$ 可知 $0 \rightarrow k$ 以及 $k \rightarrow j$ 可知 $0 \rightarrow j$.

因此, 对任意 $i, j \in S$, $i \leftrightarrow j$, 从而 X 是不可约的. 注意到 $p_{0,0} = p_0 > 0$, 状态 0 的周期为 $d_0 = 1$. 由命题9.2可知 X 的所有状态周期均为 1, 因此 X 是非周期的. \square

定理9.4 设状态 i 的周期为 d , 则存在正整数 N 使得对任意 $n \geq N$, $p_{i,i}^{(nd)} > 0$.

证明 由周期定义, 存在 $1 \leq n_1, \dots, n_s$ 使得 $p_{i,i}^{(n_k)} > 0$, $k = 1, \dots, s$, 而且 n_1, \dots, n_s 的最大公因数为 d . 由习题1.9, 存在正整数 N , 对任意 $n \geq N$, 存在正整数 r_1, \dots, r_s 使得

$$nd = r_1 n_1 + r_2 n_2 + \dots + r_s n_s.$$

从而

$$p_{i,i}^{(nd)} \geq \prod_{k=1}^s (p_{i,i}^{(n_k)})^{r_k} > 0.$$

这表明结论成立. \square

由此易得如下两个推论.

推论9.5 记状态*i*的周期为*d_i*, 若 $p_{j,i}^{(m)} > 0$, 那么存在*N*使得 $p_{j,i}^{(m+nd_i)} > 0$, $n \geq N$.

推论9.6 若状态*i*是非周期的, 那么存在*N*使得对任意*n*使得 $p_{i,i}^{(n)} > 0$.

3.2.3 常返与非常返

定义9.7 对任意状态*i* $\in S$, 称

$$\tau_i = \inf\{n \geq 1; X_n = i\}$$

为状态*i*的首次回访时间, 其中规定 $\inf \emptyset = +\infty$.

注9.1 τ_i 是一个可能取值 $+\infty$ 的随机变量, 由全概率公式可知

$$\{\tau_i \leq n\} = \bigcup_{k=1}^n \{\tau_i = k\} = \bigcup_{k=1}^n \{X_k = i, X_{k-1} \neq i, \dots, X_1 \neq i\},$$

因此对任意*n* ≥ 1 , 事件 $\{\tau_i \leq n\}$ 是否发生只与*X*在*n*及*n*之前的状态有关而与*n*之后的状态无关.

对任意*i, j* $\in S$, 令

$$f_{i,j}^{(n)} = \mathbb{P}_i(\tau_j = n) = \mathbb{P}(X_n = j, X_{n-1} \neq j, \dots, X_1 \neq j | X_0 = i), \quad (3.2.1)$$

$$f_{i,j} = \mathbb{P}_i(\tau_j < \infty) = \sum_{n=1}^{\infty} f_{i,j}^{(n)}. \quad (3.2.2)$$

由定义可知, 当 $j \neq i$ 时, $f_{i,j}^{(n)}$ 表示从*i*出发后第*n*步首次到达*j*的概率, 而 $f_{i,j}$ 表示从状态*i*出发, 在有限时间内达到状态*j*的概率. 当 $i = j$ 时 $f_{i,i}^{(n)}$ 表示从*i*出发后第*n*步首次回到*i*的概率, 而 $f_{i,i}$ 表示从*i*出发有限时间内回到状态*i*的概率. 显然, 对任意*i, j*, 若*i* $\not\rightarrow j$, 则 $f_{i,j} = 0$. 此外由

$$f_{i,j} = \sum_{n=1}^{\infty} \mathbb{P}(X_n = j, X_{n-1} \neq j, \dots, X_1 \neq j | X_0 = i) = \mathbb{P}_i(\bigcup_{k=1}^{\infty} \{X_k = j\}),$$

可得

$$0 \leq f_{i,j}^{(n)} \leq p_{i,j}^{(n)} \leq f_{i,j} \leq 1. \quad (3.2.3)$$

定义9.8 称状态*i*是常返的(recurrent), 如果 $f_{i,i} = 1$; 否则称为非常返的或暂留的(transient).

性质9.7 若*i*是常返的, $i \rightarrow j$, 那么 $f_{j,i} = 1$.

证明 定义

$$e_{i,j}^{(n)} = \mathbb{P}_i(X_n = j, X_v \neq i, v = 1, \dots, n-1). \quad (3.2.4)$$

它表示从*i*出发, 中途不仅过*i*而在第*n*步到达*j*的概率(禁忌概率). 因为 $i \rightarrow j$, 存在 $k > 0$, 使得 $e_{i,j}^{(k)} > 0$. 若 $f_{j,i} < 1$, 那么

$$\begin{aligned} \mathbb{P}_i(\tau_i = \infty) &\geq \mathbb{P}_i(X_k = j, X_n \neq i, 1 \leq n \neq k) \\ &= \mathbb{P}_i(X_k = j, X_n \neq i, 1 \leq n < k) \mathbb{P}(X_v \neq i, v > k | X_k = j, X_n \neq i, 1 \leq n < k) \\ &= e_{ij}^{(k)} \mathbb{P}(X_n \neq i, n \geq 1 | X_0 = j) = e_{ij}^{(k)} (1 - f_{j,i}) > 0. \end{aligned}$$

此与*i*常返矛盾, 因此 $f_{j,i} = 1$. \square

由性质9.7以及(3.2.3)可知, 若*i*常返, 那么*i*是本质的.

定理9.8 状态*i*常返当且仅当 $\sum_{n=0}^{\infty} p_{i,i}^{(n)} = \infty$. 若*i*非常返, 则

$$\sum_{n=0}^{\infty} p_{i,i}^{(n)} = \frac{1}{1 - f_{i,i}}.$$

证明 令 $F_{i,j}(s) = \sum_{n=1}^{\infty} s^n f_{i,j}^{(n)}$, $P_{i,i}(s) = \sum_{n=0}^{\infty} s^n p_{i,i}^{(n)}$, $s \in (-1, 1)$. 对任意 $i, j \in S$,

$$\begin{aligned} p_{i,j}^{(n)} &= \sum_{k=1}^n \mathbb{P}_i(\tau_j = k, X_n = j) = \sum_{k=1}^n \mathbb{P}_i(X_k = j, X_v \neq j, 1 \leq v < k, X_n = j) \\ &= \sum_{k=1}^n \left[\mathbb{P}(X_n = j | X_k = j, X_v \neq j, 1 \leq v < k, X_0 = i) \right. \\ &\quad \times \left. \mathbb{P}_i(X_k = j, X_v \neq j, 1 \leq v < k) \right] \\ &= \sum_{k=1}^n f_{i,j}^{(k)} p_{j,j}^{(n-k)}. \end{aligned} \quad (3.2.5)$$

因此

$$\begin{aligned} P_{i,i}(s) &= 1 + \sum_{n=1}^{\infty} s^n p_{i,i}^{(n)} = 1 + \sum_{n=1}^{\infty} s^n \sum_{k=1}^n f_{i,i}^{(k)} p_{i,i}^{(n-k)} \\ &= 1 + \sum_{k=1}^{\infty} s^k f_{i,i}^{(k)} \sum_{r=0}^{\infty} s^r p_{i,i}^{(r)} = 1 + F_{i,i}(s) P_{i,i}(s). \end{aligned}$$

由此可得

$$P_{i,i}(s) = \frac{1}{1 - F_{i,i}(s)}. \quad (3.2.6)$$

注意到 $F_{i,i}(s)$ 与 $P_{i,i}(s)$ 均为非负系数的幂级数函数, 由习题1.5可知

$$f_{i,i} = F_{i,i}(1-), \quad \sum_{n=0}^{\infty} p_{i,i}^{(n)} = P_{i,i}(1-).$$

因此 $f_{i,i} = 1 \Leftrightarrow \sum_{n=0}^{\infty} p_{i,i}^{(n)} = \infty$, 而且

$$f_{i,i} < 1 \Rightarrow \sum_{n=0}^{\infty} p_{i,i}^{(n)} = \frac{1}{1 - f_{i,i}},$$

即定理结论成立. \square

由定理9.8容易推出

推论9.9 设状态*i*是常返的, 那么 $C(i)$ 中所有状态都常返, 此时称 $C(i)$ 为常返类.

证明 对任意 $j \in C(i)$, $i \leftrightarrow j$. 存在 $m, n > 0$ 使得 $p_{i,j}^{(m)} > 0, p_{j,i}^{(n)} > 0$. 因此

$$\sum_{k=0}^{\infty} p_{j,j}^{(k)} \geq \sum_{k=m+n}^{\infty} p_{j,i}^{(n)} p_{i,i}^{(k-n-m)} p_{i,j}^{(m)} = p_{j,i}^{(n)} p_{i,j}^{(m)} \sum_{k=0}^{\infty} p_{i,i}^{(k)} = +\infty,$$

这表明*j*是常返的. \square

由推论9.9可知, 一个互通类中状态或全是常返的或全是非常返的, 若全是常返的称该互通类为常返类, 否则称为非常返类. 若不可约链的状态空间为常返类, 则称该马氏链为不可约常返链, 否则称为不可约非常返链.

例9.6 由泰勒展式, 对任意 $-1 < s < 1$,

$$1 - (1 - 4pq s^2)^{1/2} = 2pq s^2 + \sum_{k=2}^{\infty} \frac{(2k-3)!!}{2^k} \frac{(4pq)^k}{k!} s^{2k}.$$

对照例6.2结果可得

$$f_{0,0} = \sum_{k=1}^{\infty} f_{0,0}(2k) = \lim_{s \uparrow 1} F_{0,0}(s) = 1 - \sqrt{1 - 4pq} = \begin{cases} 1, & p = q = 1/2, \\ 1 - |p - q|, & p \neq q. \end{cases}$$

因此 (q, p) -简单随机游动的状态0 是常返的当且仅当 $p = q = 1/2$. 另一方面, 例9.2表明 (q, p) -简单随机游动是不可约的. 因此 (q, p) -简单随机游动是常返的当且仅当 $p = q = 1/2$.

例9.7 (高维简单对称随机游动) 直线上简单随机游动也可推广到高维空间. 以对称随机游动为例:

- (1) 若 $X = \{X_n, n \geq 0\}$ 是取值在 $\mathbb{Z}^2 = \{(i, j) : i, j \in \mathbb{Z}\}$ 的时齐马氏链使得对任意 $(i, j) \in \mathbb{Z}^2$, $p_{(i,j),(i+1,j)} = p_{(i,j),(i-1,j)} = p_{(i,j),(i,j+1)} = p_{(i,j),(i,j-1)} = 1/4$, 则称 X 是平面上简单对称随机游动(或平面整数格子点上对称随机游动).
- (2) 若 $X = \{X_n, n \geq 0\}$ 是取值在 $\mathbb{Z}^3 = \{(i, j, k) : i, j, k \in \mathbb{Z}\}$ 的时齐马氏链使得对任意 $(i, j, k) \in \mathbb{Z}^3$,

$$\begin{aligned} p_{(i,j,k),(i+1,j,k)} &= p_{(i,j,k),(i-1,j,k)} = p_{(i,j,k),(i,j+1,k)} = p_{(i,j,k),(i,j-1,k)} \\ &= p_{(i,j,k),(i,j,k+1)} = p_{(i,j,k),(i,j,k-1)} = 1/6, \end{aligned}$$

则称 X 是空间简单对称随机游动(或空间整数格子点上对称随机游动).

容易证明平面和空间的简单对称随机游动都是周期为2、不可约的马氏链. 此外我们还有平面上简单对称随机游动是常返的, 但空间简单对称随机游动是非常返的. 事实上, 对空间简单

对称随机游动我们可如下计算其 n 步转移概率

$$p_{(0,0,0),(0,0,0)}^{(n)} = \begin{cases} 0, & n = 2k - 1, \\ \sum_{r+l+s=k} \frac{(2k)!}{r!l!l!s!s!} \frac{1}{6^{2k}}, & n = 2k. \end{cases}$$

因此

$$\begin{aligned} \sum_{n=0}^{\infty} p_{(0,0,0),(0,0,0)}^{(n)} &= \sum_{k=0}^{\infty} \sum_{r+l+s=k} \frac{(2k)!}{r!l!l!s!s!} \frac{1}{6^{2k}} \\ &= \sum_{k=0}^{\infty} \frac{1}{6^{2k}} \frac{(2k)!}{k!k!} \sum_{r=0}^k \sum_{l=0}^{k-r} \left[\frac{k!}{r!l!(k-r-l)!} \right]^2 \\ &\leq \sum_{k=0}^{\infty} \frac{1}{6^{2k}} \frac{(2k)!}{k!k!} \max_{0 \leq r \leq m \leq k} \left\{ \frac{k!}{r!(m-r)!(k-m)!} \right\} \sum_{r=0}^k \sum_{l=0}^{k-r} \frac{k!}{r!l!(k-r-l)!} \end{aligned}$$

注意到 $\frac{k!}{r!l!(k-r-l)!}$ 是多项式 $(x+y+z)^k$ 展开后的系数, 因此

$$\sum_{r=0}^k \sum_{l=0}^{k-r} \frac{k!}{r!l!(k-r-l)!} = 3^k.$$

另一方面, 对任意满足条件 $0 \leq r \leq m \leq k$ 的非负整数 r, m ,

$$\frac{k!}{r!(m-r)!(k-m)!} = C_k^m C_m^r.$$

注意到对任意正整数 $m \geq r$, 组合数

$$C_m^r \leq C_m^{\lfloor m/2 \rfloor},$$

其中 $\lfloor \cdot \rfloor$ 表示取整运算, 因此

$$\frac{k!}{r!(m-r)!(k-m)!} \leq C_k^m C_m^{\lfloor m/2 \rfloor}.$$

又由

$$\frac{C_k^m C_m^{\lfloor m/2 \rfloor}}{C_k^{m-1} C_{m-1}^{\lfloor (m-1)/2 \rfloor}} = \frac{k+1-m}{m-\lfloor m/2 \rfloor}, \quad 1 \leq m \leq k$$

可知 $C_k^m C_m^{\lfloor m/2 \rfloor}$ 在 $m = m_k = k - \lfloor k/3 \rfloor$ 处取最大值. 由此可得

$$\sum_{n=0}^{\infty} p_{(0,0,0),(0,0,0)}^{(n)} \leq \sum_{k=0}^{\infty} \frac{3^k}{6^{2k}} \frac{(2k)!}{k!(k-m_k)![\lfloor m_k/2 \rfloor]!(m_k - \lfloor m_k/2 \rfloor)!}$$

注意到 $m_k \approx 2k/3$, 由 k 充分大时的Stirling公式 $k! \approx \sqrt{2\pi k}(k/e)^k$, 近似计算后得

$$\frac{(2k)!}{k!(k-m_k)![\lfloor m_k/2 \rfloor]!(m_k - \lfloor m_k/2 \rfloor)!} \approx \frac{3\sqrt{3}}{2\pi\sqrt{\pi}} \frac{2^{2k} 3^k}{k^{3/2}}.$$

因此存在常数 $M > 0$ 使得

$$\sum_{n=0}^{\infty} p_{(0,0,0),(0,0,0)}^{(n)} \leq M \sum_{k=1}^{\infty} \frac{1}{k^{3/2}} < \infty.$$

这表明 $(0,0,0)$ 是非常返的, 从而由不可约性可知空间简单对称随机游动是非常返的. 平面上简单对称随机游动的常返性检验更简单, 参见习题9.6. \square

命题9.10 令 $g_{i,i}(m) = \mathbb{P}_i(\text{至少有 } m \text{ 个 } n \geq 1 \text{ 使得 } X_n = i)$, $g_{i,i} = \mathbb{P}_i(\{X_n = i\}, \text{ i.o.})$, 那

么 $g_{i,i}(m) = f_{i,i}^m$. 从而, 若 i 常返则 $g_{i,i} = 1$; 若 i 非常返则 $g_{i,i} = 0$.

证明 由全概率公式以及条件概率公式

$$\begin{aligned} g_{i,i}(m+1) &= \mathbb{P}_i(\text{至少有 } m+1 \text{ 个 } n \geq 1 \text{ 使得 } X_n = i) \\ &= \sum_{k=1}^{\infty} \mathbb{P}_i(\tau_i = k, \text{ 至少有 } m \text{ 个 } n \geq k+1 \text{ 使得 } X_n = i) \\ &= \sum_{k=1}^{\infty} \mathbb{P}_i(\text{至少有 } m \text{ 个 } n \geq k+1 \text{ 使得 } X_n = i | \tau_i = k) \mathbb{P}_i(\tau_i = k) \end{aligned}$$

由时齐马氏性(参见习题8.5)

$$\begin{aligned} g_{i,i}(m+1) &= \sum_{k=1}^{\infty} \mathbb{P}(\text{至少有 } m \text{ 个 } n \geq 1 \text{ 使得 } X_n = i | X_0 = i) \mathbb{P}_i(\tau_i = k) \\ &= g_{i,i}(m) \sum_{k=1}^{\infty} f_{i,i}^{(k)} = g_{i,i}(m) f_{i,i}. \end{aligned}$$

由此递归关系并注意到 $g_{i,i}(1) = f_{i,i}$ 可得, 对任意 $m \geq 1$,

$$g_{i,i}(m) = f_{i,i}^m.$$

令 $m \rightarrow \infty$, 由概率连续性可知 $g_{i,i} = \lim_{m \rightarrow \infty} f_{i,i}^m$, 因此后一结论自然成立. \square

由命题9.10可知, 状态 i 是常返的, 那么从 i 出发几乎必然可以无穷次地回访 i , 这正是“常返”的字面含义; 若 i 是非常返(暂留)的, 那么由 $\mathbb{P}_i(\{X_n = i\}, \text{ i.o.}) = 0$ 可知, 对几乎所有的 ω , 都存在一个时刻 $N(\omega)$ 使得在 $N(\omega)$ 后 X 不再访问 i .

定理9.11 记马氏链 X 首次回到状态 i 的时间为 τ_i . 设 $\tau_i < \infty$. 令 $Y_n = X_{\tau_i+n}$, 即对任意 ω , $Y_n(\omega) = X_{\tau_i(\omega)+n}(\omega)$. 那么 $Y = \{Y_n, n \geq 0\}$ 是与 X 有相同转移概率矩阵的马氏链且与 $(\tau_i, X_0, \dots, X_{\tau_i})$ 相互独立.

证明 首先注意到 $Y_0 = X_{\tau_i} = i$ 是常量, 对任意 $n \geq 1$, $k_0 \in S, k_1, \dots, k_{n-1} \in S \setminus \{i\}$, $m \geq 1$,

$$\begin{aligned} 0 \leq n_1 < \dots < n_m, j_1, \dots, j_m \in S. \text{ 令 } k_n = i, \\ &\mathbb{P}\left(\bigcap_{l=0}^{n-1} \{X_l = k_l\} \cap \{\tau_i = n\} \cap \bigcap_{r=1}^m \{Y_{n_r} = j_r\}\right) \\ &= \mathbb{P}\left(\bigcap_{l=0}^n \{X_l = k_l\} \cap \bigcap_{r=1}^m \{X_{n+n_r} = j_r\}\right) \\ &= \mathbb{P}\left(\bigcap_{l=0}^{n-1} \{X_l = k_l\} \cap \{X_n = i\}\right) \mathbb{P}\left(\bigcap_{r=1}^m \{X_{n+n_r} = j_r\} | X_n = i\right) \\ &= \mathbb{P}\left(\bigcap_{l=0}^{n-1} \{X_l = k_l\} \cap \{X_n = i\}\right) \mathbb{P}_i\left(\bigcap_{r=1}^m \{X_{n_r} = j_r\}\right). \end{aligned}$$

两边对全部的 $n \geq 1$, $k_0 \in S$ 以及 $k_1, \dots, k_{n-1} \in S \setminus \{i\}$ 求和得

$$\mathbb{P}\left(\bigcap_{r=1}^m \{Y_{n_r} = j_r\}\right) = \mathbb{P}_i\left(\bigcap_{r=1}^m \{X_{n_r} = j_r\}\right).$$

进而

$$\begin{aligned} & \mathbb{P}\left(\bigcap_{l=0}^{n-1}\{X_l = k_l\} \cap \{\tau_i = n\} \cap \bigcap_{r=1}^m\{Y_{n_r} = j_r\}\right) \\ &= \mathbb{P}\left(\bigcap_{l=0}^{n-1}\{X_l = k_l\} \cap \{X_n = i\}\right)\mathbb{P}_i\left(\bigcap_{r=1}^m\{Y_{n_r} = j_r\}\right). \end{aligned}$$

因此 Y 是与 X 有相同转移概率函数的马氏链且与 $(\tau_i, X_0, \dots, X_{\tau_i})$ 相互独立. \square

定理9.11表明将 τ_i 看作起点, 此后的随机过程 Y 本质就是 0 点从 i 出发的的马氏链 X , 而且 τ_i 之后的随机事件与 τ_i 之前的事件相互独立.

练习题 除特别说明外, 以下总设 X 为马氏链, 转移概率矩阵为 $(p_{i,j})_{i,j \in S}$.

9.1 设 C 是 X 的一个具有有限状态的非本质互通类. 对几乎所有的 ω , 若 $X_0(\omega) \in C$, 证明存在 $N(\omega)$ 使得对所有的 $n \geq N(\omega)$, $X_n(\omega) \notin C$.

9.2 试构造马氏链 X 使得它的状态空间至少包含一个具有无穷多状态的非本质互通类(记作 C)而且当 $X_0 \in C$ 时 $P(X_n \in C, n \geq 1) > 0$.

9.3 若 $i \leftrightarrow j$ 且记它们的周期为 d , 若 $p_{i,j}^{(n)} > 0, p_{j,i}^{(m)} > 0$, 证明 $d | n - m$.

9.4 若状态 i 非常返, 那么对任意 $j \in S$, $\lim_{n \rightarrow \infty} p_{j,i}^{(n)} = 0$.

9.5 若 j 为吸收状态, 那么 $\lim_{n \rightarrow \infty} p_{i,j}^{(n)} = f_{i,j}$.

9.6 若 $C(i), C(j)$ 是两不相同的本质互通类, 那么 $f_{i,j} = 0$.

9.7 元素有限的本质类必是常返类.

9.8 证明平面上简单对称随机游动是常返的.

9.9 设 $X = \{X_n, n \geq 0\}$ 不可约 d 周期马氏链, 状态空间为 S . 对任意 $i \in S$, 令

$$S_k = \{j \in S, p_{i,j}^{nd+k} > 0, n \geq 0\}, \quad k = 0, \dots, d-1.$$

证明(1) $S_k, 0 \leq k \leq d-1$ 互不相交而且 $S = \bigcup_{k=0}^{d-1} S_k$.

(2) 令 $Y_n = X_{nd}$, 那么 $Y = \{Y_n, n \geq 0\}$ 是以 $\mathbf{P}^{(d)}$ 为一步转移概率矩阵的非周期马氏链. 特别, 若 $X_0 \in S_k$, 那么 Y 是状态空间为 S_k 的非周期马氏链.

9.10 设 $X = \{X(n); n \geq 0\}$ 为马氏链, 令 $\tau_i^{(0)} = 0, \tau_i^{(k)} = \inf\{n > \tau_i^{(k-1)}; X(n) = i\}$,

$$W_i^{(k)} = \tau_i^{(k)} - \tau_i^{(k-1)}, \quad k \geq 1.$$

证明 $W_i^{(k)}, k \geq 1$, 相互独立, 而且 $W_i^{(k)}, k \geq 2$, 有相同分布.

9.11* 若状态 j 的周期为 d , 那么集合 $\{n \geq 1; f_{j,j}^{(n)} > 0\}$ 的最大公因子也为 d .

3.3 首访概率与时间

在马氏链的研究和应用当中, 状态的首次到达时间或首次回访时间是非常重要的观察变量. 这一节我们将通过寻找恰当的计算方法, 进一步讨论这类随机变量的分布、性质与应用. 为叙述方便, 若无特别声明, 本节总设马氏链 $X = \{X_n; n \geq 0\}$ 的转移概率矩阵 $\mathbf{P} = (p_{i,j})_{i,j \in S}$.

3.3.1 访问概率与分布

首先我们将单个状态 i 的回访时间 τ_i 推广到状态空间 S 中任一子集 A 上. 令

$$\tau_A = \inf\{n \geq 1, X_n \in A\}.$$

τ_A 表示首次进入(回到)集合 A 的时间. 对任意正整数 $n \geq 1$, 令

$$f_{i,A}^{(n)} = \mathbb{P}_i(\tau_A = n), \quad f_{i,A} = \sum_{n=1}^{\infty} f_{i,A}^{(n)},$$

以及对任意 $u \in [0, 1]$, 定义

$$F_{i,A}(u) = \sum_{n=1}^{\infty} f_{i,A}^{(n)} u^n.$$

那么 $f_{i,A}$ 就是从 i 出发在有限时间内访问(回访) A 的概率. 由于级数 $\sum_{n=1}^{\infty} f_{i,A}^{(n)} \leq 1$, $f_{i,A} = F_{i,A}(1)$. 当 $f_{i,A} = 1$ 时, 序列 $\{f_{i,A}^{(n)}\}$ 就是随机变量 τ_A 的分布列, $F_{i,A}(u)$ 就是对应的母函数; 当 $f_{i,A} < 1$ 时, 从 i 出发在有限时间内到达 A 的事件可能不发生, 但由幂级数与系数关系可知序列 $\{f_{i,A}^{(n)}\}$ 与函数 $F_{i,A}(u)$ 仍是一一对应的.

定理10.1 对任意给定的 $A \subset S$ 以及 $u \in [0, 1]$, $\{F_{i,A}(u); i \in S\}$ 是线性方程组

$$z_i = \sum_{k \notin A} u p_{i,k} z_k + u \sum_{j \in A} p_{i,j}, \quad i \in S, \quad (3.3.1)$$

的最小非负解. 即 $\{F_{i,A}(u); i \in S\}$ 本身是方程组 (3.3.1) 的非负解而且对该方程组的任意非负解 $\{g_i(u); i \in S\}$, $F_{i,A}(u) \leq g_i(u)$ 对一切 $i \in S$ 都成立.

证明 记 $A(i, n, u) = \sum_{m=1}^n f_{i,A}^{(m)} u^m$, 则 $\lim_{n \rightarrow \infty} A(i, n, u) = F_{i,A}(u)$. 由

$$\begin{aligned} A(i, n+1, u) &= \sum_{m=1}^{n+1} f_{i,A}^{(m)} u^m = f_{i,A}^{(1)} u + \sum_{m=2}^{n+1} f_{i,A}^{(m)} u^m \\ &= \sum_{j \in A} p_{i,j} u + \sum_{m=2}^{n+1} \sum_{k \notin A} \mathbb{P}_i(X_m \in A, X_1 = k, X_v \notin A, 1 < v < m) u^m \end{aligned}$$

由马氏性和时齐性可知

$$\mathbb{P}_i(X_m \in A, X_1 = k, X_v \notin A, 1 < v < m)$$

$$= \mathbb{P}_i(X_1 = k) \mathbb{P}(X_m \in A, X_v \notin A, 2 < v < m | X_1 = k) = p_{i,k} f_{k,A}^{(m-1)}.$$

因此

$$\begin{aligned} A(i, n+1, u) &= u \sum_{j \in A} p_{i,j} + \sum_{k \notin A} \sum_{m=2}^{n+1} u p_{i,k} f_{k,A}^{(m-1)} u^{m-1} \\ &= u \sum_{j \in A} p_{i,j} + u \sum_{k \notin A} p_{i,k} A(k, n, u). \end{aligned}$$

两边令 $n \rightarrow \infty$ 得 (参见习题3-1)

$$F_{i,A}(u) = u \sum_{j \in A} p_{i,j} + u \sum_{k \notin A} p_{i,k} F_{k,A}(u).$$

因此 $\{F_{i,A}(u), i \in S\}$ 确实为方程组(3.3.1)的非负解.

任取(3.3.1)的一组非负解 $\{g_i(u), i \in S\}$, 由

$$g_i(u) = u \sum_{j \in A} p_{i,j} + u \sum_{k \notin A} p_{i,k} g_k(u)$$

可知

$$g_i(u) \geq A(i, 1, u) = u \sum_{j \in A} p_{i,j}$$

对任意 $i \in S$ 成立. 设对任意 $i \in S$, $g_i(u) \geq A(i, k, u)$ 对 $k = n - 1$ 成立, 那么由

$$A(i, n, u) = \sum_{j \in A} u p_{i,j} + \sum_{k \notin A} u p_{i,k} A(k, n-1, u) \leq \sum_{j \in A} u p_{i,j} + \sum_{k \notin A} u p_{i,k} g_k(u) = g_i(u)$$

可知对任意 $i \in S$, $g_i(u) \geq A(i, k, u)$ 对 $k = n$ 也成立.

由数学归纳法可知, 对任意 $i \in S$ 以及任意 n 都有

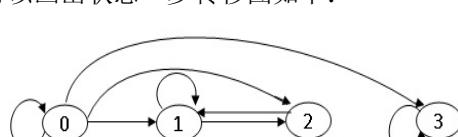
$$g_i(u) \geq A(i, n, u).$$

令 $n \rightarrow \infty$ 得 $g_i(u) \geq F_{i,A}(u)$ 对所有 $i \in S$ 成立. 因此 $F_{i,A}(u)$ 为(3.3.1)的最小非负解. \square

定理10.1为我们提供了通过求解代数方程获得 τ_A 分布的方法. 特别, 若 X 是有限状态马氏链, 那么由定理10.1, 我们可以通过求解含有限个变量的线性方程组获得 τ_A 的分布信息.

例10.1 设马氏链 X 的转移概率矩阵为 $\begin{pmatrix} 1/4 & 1/4 & 1/4 & 1/4 \\ 0 & 1/3 & 2/3 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$. 求 $F_{i,1}(u)$ 以及 $\mathbb{P}_0(\tau_1 = n)$, 其中 $i = 0, 1, 2, 3, n$ 为任意正整数.

解 由转移概率矩阵我们可以画出状态一步转移图如下:



由此可知 $3 \not\rightarrow 1$, 因此对任意 $u \in [0, 1]$, $F_{3,1}(u) = 0$, 进而由定理10.1(取 $A = \{1\}$)可得

$$\begin{cases} F_{0,1}(u) = up_{0,0}F_{0,1}(u) + up_{0,2}F_{2,1}(u) + up_{0,1}, \\ F_{2,1}(u) = up_{2,0}F_{0,1}(u) + up_{2,2}F_{2,1}(u) + up_{2,1}, \\ F_{1,1}(u) = up_{1,0}F_{0,1}(u) + up_{1,2}F_{2,1}(u) + up_{1,1}. \end{cases}$$

由前两个方程得

$$\begin{pmatrix} 1 - up_{0,0} & -up_{0,2} \\ -up_{2,0} & 1 - up_{2,2} \end{pmatrix} \begin{pmatrix} F_{0,1}(u) \\ F_{2,1}(u) \end{pmatrix} = \begin{pmatrix} up_{0,1} \\ up_{2,1} \end{pmatrix}.$$

将 $p_{0,0} = p_{0,2} = p_{0,1} = 1/4, p_{2,0} = p_{2,2} = 0, p_{2,1} = 1$ 代入并计算得

$$F_{0,1}(u) = \frac{u + u^2}{4 - u}, \quad F_{2,1}(u) = u.$$

将此结果代入第三个方程并注意到 $p_{1,0} = 0, p_{1,1} = 1/3, p_{1,2} = 2/3$, 我们可得

$$F_{1,1}(u) = \frac{2}{3}u^2 + \frac{1}{3}u.$$

对任意 $0 \leq u \leq 1$, 由幂级数展开式,

$$\sum_{k=1}^{\infty} f_{0,1}^{(k)} u^k = F_{0,1}(u) = \left[\frac{u}{4} + \frac{u^2}{4} \right] \sum_{k=0}^{\infty} \frac{u^k}{4^k} = \frac{u}{4} + \sum_{k=2}^{\infty} \frac{5u^k}{4^k}$$

可知 $f_{0,1}^{(1)} = 1/4, f_{0,1}^{(k)} = 5/4^k, k \geq 2$. □

例10.2 设 $W = \{W_n\}$ 为直线上 (q, p) -简单随机游动, 求 $F_{0,1}(u), u \in [0, 1]$.

解 由定理9.1可知 $\{F_{i,1}(u)\}_{i \in \mathbb{Z}}$ 是方程组

$$z_i = \sum_{k \neq 1} up_{i,k}z_k + up_{i,1}, \quad i \in \mathbb{Z},$$

的最小非负解. 从而

$$F_{0,1}(u) = up + uqF_{-1,1}(u). \tag{3.3.2}$$

注意到对任意 $n \geq 1$ 以及任意 $i \in \mathbb{Z}, j \geq 2$, 由独立增量性

$$\begin{aligned} f_{i,i+j}^{(n)} &= \mathbb{P}(\tau_{i+j} = n | W_0 = i) = \mathbb{P}(W_n = i + j, W_k < i + j, 0 < k < n | W_0 = i) \\ &= \mathbb{P}(W_n - W_0 = j, W_k - W_0 < j, 0 < k < n) \\ &= \mathbb{P}(W_n = j, W_k < j, 0 < k < n | W_0 = 0) = f_{0,j}^{(n)}. \end{aligned}$$

特别

$$\begin{aligned} f_{0,2}^{(n)} &= \mathbb{P}(W_n = 2, W_k < 2, 0 < k < n | W_0 = 0) \\ &= \sum_{j=1}^{n-1} \mathbb{P}(W_n = 2, W_k < 2, j < k < n, W_j = 1, W_l < 1, 0 < l < j | W_0 = 0) \end{aligned}$$

由马氏性

$$\mathbb{P}(W_n = 2, W_k < 2, j < k < n, W_j = 1, W_l < 1, 0 < l < j | W_0 = 0)$$

$$= \mathbb{P}(W_j = 1, W_l < 1, 0 < l < j | W_0 = 0) \mathbb{P}(W_n = 2, W_k < 2, j < k < n | W_j = 1)$$

注意到 W 还是时齐的,

$$\mathbb{P}(W_n = 2, W_k < 2, j < k < n | W_j = 1)$$

$$= \mathbb{P}(W_{n-j} = 2, W_k < 2, 0 < k < n-j | W_0 = 1) = f_{1,2}^{(n-j)}.$$

因此

$$f_{0,2}^{(n)} = \sum_{j=1}^{n-1} f_{0,1}^{(j)} f_{1,2}^{(n-j)} = \sum_{j=1}^{n-1} f_{0,1}^{(j)} f_{0,1}^{(n-j)}.$$

由此可得

$$\begin{aligned} F_{-1,1}(u) &= F_{0,2}(u) = \sum_{n=2}^{\infty} f_{0,2}^{(n)} u^n = \sum_{n=2}^{\infty} \sum_{j=1}^{n-1} f_{0,1}^{(j)} u^j f_{0,1}^{(n-j)} u^{n-j} \\ &= \sum_{j=1}^{\infty} f_{0,1}^{(j)} u^j \sum_{k=1}^{\infty} f_{0,1}^{(k)} u^k = [F_{0,1}(u)]^2 \end{aligned}$$

将其带入(3.3.2), 注意到 $F_{0,1}(u)$ 为最小非负解, 解得

$$F_{0,1}(u) = \frac{2pu}{1 + \sqrt{1 - 4pqu^2}}. \quad \square$$

注意到 $f_{i,j} = \lim_{u \rightarrow 1^-} F_{i,j}(u)$. 由定理10.1容易得到如下关于访问概率的常用结果.

推论10.2 对任意给定的 $j \in S$, $\{f_{i,j}; i \in S\}$ 是线性方程组

$$z_i = \sum_{k \neq j} p_{i,k} z_k + p_{i,j}, \quad i \in S, \quad (3.3.3)$$

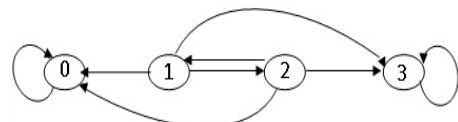
的最小非负解.

例10.3 一家银行将贷款分类为全部付清(0), 信誉良好(1), 拖欠(2)或者呆账(3). 贷款按照如下转移概率在不同的类别之间转移:

$$\begin{pmatrix} 1 & 0 & 0 & 0 \\ 0.1 & 0.8 & 0.1 & 0 \\ 0.1 & 0.4 & 0.4 & 0.1 \\ 0 & 0 & 0 & 1 \end{pmatrix}.$$

求处于信誉良好级别的贷款最终全部付清的比例.

解 由转移概率矩阵我们可以画出状态一步转移图如下:



所求比例为概率 f_{10} . 由于 $3 \not\rightarrow 0$, $f_{3,0} = 0$. 由推论9.2可知

$$\begin{cases} f_{1,0} = p_{1,1}f_{1,0} + p_{1,2}f_{2,0} + p_{1,0} = 0.8f_{1,0} + 0.1f_{2,0} + 0.1, \\ f_{2,0} = p_{2,1}f_{1,0} + p_{2,2}f_{2,0} + p_{2,0} = 0.4f_{1,0} + 0.4f_{2,0} + 0.1. \end{cases}$$

由此解得 $f_{10} = 7/8$, 即最终付清得比例为 87.5%. \square

方程组(3.3.1)与(3.3.3)在理论上也很重要, 它给我们提供了一种通过判断方程组的解的性质确定马氏链常返性的方法.

定理10.3 设 X 不可约, 那么 X 常返当且仅当存在一个状态 $j \in S$ 使得方程组(3.3.3)的任意一组非负解 $\{u_i; i \in S\}$ 满足 $u_i \geq 1$ 对一切 $i \in S$ 成立.

证明 “必要性”: 若不可约链 X 常返, 则由推论9.9和性质9.7可知对任意 $i, j \in S$, $f_{i,j} = 1$. 从而方程组(3.3.1)的最小非负解 $\{f_{i,j}; i \in S\}$ 恒为 1, 因此 $u_i \geq 1$ 对一切 $i \in S$ 成立.

“充分性”: 由假设可知 $\{u_i \equiv 1; i \in S\}$ 为(3.3.3)的最小非负解, 从而由推论10.2 可知 $f_{j,j} = 1$, 即 j 为常返的, 再由推论9.9 可知不可约链 X 为常返的. \square

例10.4 设马氏链 X 的状态空间为非负整数, 转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} r_0 & p_0 & 0 & 0 & 0 & \cdots & 0 \\ q_1 & r_1 & p_1 & 0 & 0 & \cdots & 1 \\ 0 & q_2 & r_2 & p_2 & 0 & \cdots & 2 \\ 0 & 0 & q_3 & r_3 & p_3 & \cdots & 3 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \end{pmatrix}$$

其中 $p_0 > 0$, $r_0 + p_0 = 1$, $q_i + r_i + p_i = 1$, $p_i, q_i > 0$, $i \geq 1$. 通常我们称 X 为(广义)带一个反射壁的随机游动. 讨论 X 的常返性.

解 在条件假设下容易证明 X 是不可约马氏链. 取 $j = 0$, 考察如下方程组

$$\begin{cases} z_0 = \sum_{k \neq 0} p_{0,k}z_k + p_{0,0} = p_0z_1 + r_0 \\ z_1 = \sum_{k \neq 0} p_{1,k}z_k + p_{1,0} = r_1z_1 + p_1z_2 + q_1 \\ z_n = \sum_{k \neq 0} p_{n,k}z_k + p_{n,0} = q_nz_{n-1} + r_nz_n + p_nz_{n+1}, \quad n \geq 2. \end{cases} \quad (3.3.4)$$

可得

$$z_{n+1} - z_n = \frac{q_n}{p_n}(z_n - z_{n-1}) = \cdots = \frac{q_1q_2 \cdots q_n}{p_1p_2 \cdots p_n}(z_1 - 1).$$

由此可知(3.3.4)的非负解必满足 $z_0 = p_0z_1 + r_0$, 而且对任意 $n \geq 1$,

$$z_{n+1} = z_1 + (z_1 - 1) \sum_{k=1}^n \frac{q_1 \cdots q_k}{p_1 \cdots p_k}.$$

因此(1)当 $\sum_{k=1}^{\infty} \frac{q_1 \cdots q_k}{p_1 \cdots p_k} = \infty$ 时, 由 $\{z_n, n \geq 0\}$ 非负可知 $z_1 \geq 1$, 从而 $z_n \geq 1$, $n \geq 0$. 由定

理10.3, 此时 X 常返.

(2) 当 $A = \sum_{k=1}^{\infty} \frac{q_1 \cdots q_k}{p_1 \cdots p_k} < \infty$ 时, 可取 $z_1 \in (A/(1+A), 1)$, 使得

$$0 < z_0 = p_0 z_1 + r_0 < 1 \quad \text{而且} \quad 0 < z_1 + A(z_1 - 1) < z_n \leq z_1 < 1$$

对所有 $n \geq 1$ 都成立, 即(3.3.3)存在非负解 $\{z_i, i \geq 0\}$ 使得 $z_1 < 1$. 此时由定理10.3可知 X 是非常返的. \square

3.3.2 平均访问时间

对任意 $i \in S$ 和 $A \subset S$ 我们还可以定义

$$m_{i,A} = \sum_{n=1}^{\infty} n f_{i,A}^{(n)}. \quad (3.3.5)$$

当 $f_{i,A} = 1$, 即 $\mathbb{P}_i(\tau_A < \infty) = 1$ 时,

$$m_{i,A} = \sum_{n=1}^{\infty} n \mathbb{P}_i(\tau_A = n) = \mathbb{E}_i(\tau_A)$$

表示从 i 出发首次到达状态 j 的平均时间. 特别, 若 i 是常返的, $m_{i,i}$ 表示首次回到 i 的平均时间, 称为平均回访时间.

注10.1 当 $f_{i,A} < 1$ 时上面的概率解释不成立, 但 $m_{i,A}$ 仍在一定条件下刻画了 τ_A 的“均值”信息.

注意到

$$m_{i,A} = \left. \frac{dF_{i,A}(u)}{du} \right|_{u=1}.$$

因此若解方程(3.3.1)得到函数 $F_{i,A}(u)$, 我们可以通过求导运算方便地算出 $m_{i,A}$.

例10.5 对例10.1中 X , 求 $m_{i,1}$, 其中 $i = 0, 1, 2, 3$.

解 对例10.1中结果 $F_{i,1}(u)$ 求导, 并在导函数中令 $u = 1$ 可得

$$m_{0,1} = 11/9, \quad m_{1,1} = 5/3, \quad m_{2,1} = 1, \quad m_{3,1} = 0. \quad \square$$

通过求解方程组(3.3.1)得到函数 $F_{i,A}(u)$ 有时候并不方便, 下面的定理给出了通过解方程直接得到 $m_{i,A}$ 的方法.

定理10.4 对任意给定的 $A \subset S$, $\{m_{i,A}; i \in S\}$ 是线性方程组

$$z_i = \sum_{k \notin A} p_{i,k} z_k + f_{i,A}, \quad i \in S \quad (3.3.6)$$

的最小非负解.

证明 记 $b_{i,A}(k) = \sum_{m=1}^n m f_{i,A}^{(m)}$, 则 $n \rightarrow \infty$ 时 $b_{i,A}(n) \uparrow m_{i,A}$. 由

$$b_{i,A}(n+1) = \sum_{m=1}^{n+1} m f_{i,A}^{(m)} = \sum_{m=1}^n m f_{i,A}^{(m+1)} + \sum_{m=1}^{n+1} f_{i,A}^{(m)}$$

$$\begin{aligned}
&= \sum_{m=1}^{n+1} f_{i,A}^{(m)} + \sum_{m=1}^n \sum_{k \notin A} m \mathbb{P}_i(X_{m+1} \in A, X_1 = k, X_v \notin A, 2 \leq v \leq m) \\
&= \sum_{m=1}^{n+1} f_{i,A}^{(m)} + \sum_{k \notin A} p_{i,k} \sum_{m=1}^n m f_{k,A}^{(m)} = \sum_{k \notin A} p_{i,k} b_{k,A}(n) + \sum_{m=1}^{n+1} f_{i,A}^{(m)}.
\end{aligned}$$

两边令 $n \rightarrow \infty$ 得

$$m_{i,A} = f_{i,A} + \sum_{k \neq j} p_{i,k} m_{k,A}.$$

因此 $\{m_{i,A}\}_{i \in S}$ 确实为方程组(3.3.6)的非负解. 任取(3.3.6)的一组非负解 $\{u_i\}_{i \in S}$, 由

$$u_i = f_{i,A} + \sum_{k \notin A} p_{i,k} u_k$$

可知 $u_i \geq b_{i,A}(1) = f_{i,A}^{(1)}$ 对任意 $i \in S$ 成立.

设对任意 $i \in S$, $u_i \geq b_{i,A}(k)$ 对 $k = n - 1$ 成立, 那么由

$$b_{i,A}(n) = \sum_{m=1}^{n+1} f_{i,A}^{(m)} + \sum_{k \notin A} p_{i,k} b_{k,A}(n-1) \leq f_{i,j} + \sum_{k \notin A} p_{i,k} u_k = u_i$$

可知对任意 $i \in S$, $u_i \geq b_{i,A}(k)$ 对 $k = n$ 也成立.

由数学归纳法可知, 对任意 $i \in S$ 以及任意 n 都有

$$u_i \geq b_{i,A}(n).$$

令 $n \rightarrow \infty$ 得 $u_i \geq m_{i,A}$ 对所有 $i \in S$ 成立, 因此 $m_{i,A}$ 为(3.3.6)的最小非负解. \square

例10.6 设有 $n+1, n \geq 1$, 个选手依次两两进行比赛, 获胜者接连比赛下去直到有一名选手连续地击败其余 n 名选手才结束. 假设每场比赛中两名选手获胜的概率各为 $1/2$, 求平均需比赛次数.

解 以 X_k 表示第 k 次比赛结束时比赛胜者的连赢场次. $X_0 = 0$ 且 $X = \{X_k, k \geq 0\}$ 为时齐马氏链, 转移概率矩阵

$$\mathbf{P} = \begin{pmatrix} 0 & 1 & 0 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 1/2 & 1/2 & 0 & 0 & 0 & \cdots & 1 \\ 0 & 1/2 & 0 & 1/2 & 0 & 0 & \cdots & 2 \\ 0 & 1/2 & 0 & 0 & 1/2 & 0 & \cdots & 3 \\ 0 & 1/2 & 0 & 0 & 0 & 1/2 & \cdots & 4 \\ \vdots & \vdots \end{pmatrix}$$

由此可知状态集 $C(1) = \{1, 2, \dots\}$ 是 X 的一个互通类,

$$f_{1,1} = \sum_{m=1}^{\infty} f_{1,1}^{(m)} = \sum_{m=1}^{\infty} \frac{1}{2^m} = 1.$$

所以 $C(1)$ 是 X 的不可约常返类, 进而 $f_{i,j} = 1, i, j \geq 1$. 比赛结束的条件是 $X_k = n$, 比赛结束

的时间为

$$\tau_n = \inf\{k \geq 1, X_k = n\}.$$

从而平均比赛次数

$$T = \mathbb{E}_0(\tau_n) = m_{0,n}.$$

显然 $m_{0,n} = m_{1,n} + 1$, 由定理9.4可知 $m_{i,n}, 1 \leq i < n$, 是方程组

$$\begin{cases} z_i = z_1/2 + z_{i+1}/2 + 1, & 1 \leq i < n-1, \\ z_{n-1} = z_1/2 + 1. \end{cases}$$

的最小非负解. 由此可得

$$\begin{cases} z_i = 2z_{i-1} - z_1 - 2, & 2 \leq i \leq n-1 \\ z_{n-1} = z_1/2 + 1. \end{cases}$$

因此对任意 $2 \leq i \leq n-1$,

$$\begin{aligned} z_i &= 2^2 z_{i-2} - 2z_1 - 2^2 - z_1 - 2 \\ &= 2^{i-1} z_1 - (2^{i-2} + \dots + 2 + 1) z_1 - (2^{i-1} + \dots + 2) \\ &= z_1 - (2^i - 2) \end{aligned}$$

从而由 $z_{n-1} = z_1 - 2^{n-1} + 2 = z_1/2 + 1$ 可知 $z_1 = 2^n - 2$. 因此所求比赛次数

$$T = m_{0,n} = m_{1,n} + 1 = z_1 + 1 = 2^n - 1.$$

□

例10.7 设 X 是带一个反射壁的 (q, p) -随机游动, 即在例10.4中 $r_0 = 0, p_0 = 1$; 而对一切 $i \geq 1$, $r_i = 0, q_i = q, p_i = p$. 若 $q > p$, 求 $m_{n,0}, n \geq 0$.

解 由例10.4可知 $q > p$ 时, X 常返, 对 $n \geq 0, f_{n,0} = 1$. $\{m_{n,0}\}_{n \geq 0}$ 为下列方程组的最小非负解:

$$\begin{cases} z_0 = \sum_{k \neq 0} p_{0,k} z_k + 1 = z_1 + 1 \\ z_1 = \sum_{k \neq 0} p_{1,k} z_k + 1 = p z_2 + 1 \\ z_n = \sum_{k \neq 0} p_{n,k} z_k + 1 = q z_{n-1} + p z_{n+1} + 1, \quad n \geq 2 \end{cases} \quad (3.3.7)$$

由此可得

$$\begin{cases} z_0 = \sum_{k \neq 0} p_{0,k} z_k + 1 = z_1 + 1 \\ z_2 - z_1 = r z_1 - \frac{1}{p} \\ z_{n+1} - z_n = r(z_n - z_{n-1}) - \frac{1}{p}, \quad n \geq 2 \end{cases}$$

其中 $r = q/p$. 所以对 $n \geq 1$

$$z_{n+1} - z_n = r^n z_1 - \frac{1}{p}[1 + r + \dots + r^{n-1}] = r^n z_1 - \frac{1}{p} \frac{r^n - 1}{r - 1},$$

进而

$$z_{n+1} = z_1 \sum_{k=0}^n r^k - \frac{1}{p(r-1)} (\sum_{k=0}^n r^k - n - 1) = z_1 \sum_{k=0}^n r^k - \frac{1}{q-p} (\sum_{k=0}^n r^k - n - 1).$$

上式两边除以 $\sum_{k=0}^n r^k$ 得,

$$\frac{z_{n+1}}{\sum_{k=0}^n r^k} = z_1 - \frac{1}{q-p} \left(1 - \frac{n+1}{\sum_{k=0}^n r^k} \right), n \geq 1.$$

由 $r = q/p > 1$ 可知当 $n \rightarrow \infty$ 时

$$\sum_{k=0}^n r^k \rightarrow \infty \text{ 而且 } n/\sum_{k=0}^n r^k \rightarrow 0.$$

因此作为(3.3.7)的非负解 $z_n, n \geq 0$, 必有

$$z_1 \geq \frac{1}{q-p},$$

从而

$$z_n \geq \frac{n}{q-p}, \quad n \geq 1.$$

直接验证可知

$$z_0 = 1 + \frac{1}{q-p}, \quad z_n = n/(q-p), \quad n \geq 1$$

为方程(3.3.7)的一组非负解从而为最小非负解. 因此由定理10.4

$$m_{0,0} = 1 + \frac{1}{q-p} = \frac{2q}{q-p}; \quad m_{n,0} = \frac{n}{q-p}, \quad n \geq 1. \quad \square$$

值得注意的是, 当 $i \neq j$ 时 $f_{i,j}, m_{i,j}$ 只依赖于到达 j 之前各状态的转移概率, 与从 j 出发的转移概率 $p_{j,\cdot}$ 无关. 从而改变 $p_{j,\cdot}$ 不影响 $f_{i,j}, m_{i,j}$ 的取值与判断.

例10.8 设 X 为 (q,p) -随机游动, $q > p$, 求 $m_{a,0}$ 其中 $a > 0$.

解: 将 0 的转移概率 $p_{0,k}$ 重新定义为 $p_{0,k} = \begin{cases} 1, & k = 1 \\ 0, & k \neq 1 \end{cases}$. 此时从 $a > 0$ 出发的随机游动即为带反射壁的 (q,p) -随机游动. 因此由例10.7 可知 $m_{a,0} = a/(q-p)$. \square

练习题

10.1 设 X 的转移概率矩阵 $\mathbf{P} = \begin{pmatrix} 0 & 1/2 & 1/2 & 0 \\ 1/2 & 0 & 0 & 1/2 \\ 0 & 0 & 1/3 & 2/3 \\ 0 & 0 & 1/2 & 1/2 \end{pmatrix}$, 求 $(f_{i,j})$ 与 $(m_{i,j})$.

10.2 若一篇文稿有 n 个错误, 每次校阅至少能发现一个, 但留下来的错误数在 0 到 $n-1$ 之间等可能存在. 设原稿共有 a 个错误, 问为了改正全部错误平均需要校阅几次?

10.3 若马氏链 X 只有三个状态且 $(m_{i,j}) = \begin{pmatrix} 2 & 3 & 3 \\ 1 & 4 & 4 \\ 1 & 4 & 4 \end{pmatrix}$, 求 X 的转移概率矩阵 \mathbf{P} .

10.4 设 X 是带反射壁的 (q, p) -随机游动, $n > 0$, (1) 若 $q < p$, 求 $f_{n,0}$, (2) 若 $q > p$, 求 $m_{0,n}$.

10.5 (Ehrenfest模型) 设一个坛子内装有红白两色共 N 个球, 每次随机地从坛子中抽出一个球, 把它换成别的颜色后放回. 以 X_n 表示经 n 次抽放后坛中的红球数, 那么 $X = \{X_n, n \geq 0\}$ 为时齐马氏链. 若开始时坛内只有一个红球, 问平均要抽放多少次才能使坛内全是白球?

3.4 转移概率极限与平稳分布

上一节我们介绍了首访时间(回访周期)的“均值” $m_{i,j}$. 这是一个非常重要的概念, 不仅体现在应用上, 还是刻画马氏链性质的重要指标.

3.4.1 正常返, 零常返与转移概率极限

首先我们利用回访周期的平均值, 把常返状态进一步区分为.

定义11.1 设 $i \in S$ 常返, 称*i*是正常返的, 若 $m_{i,i} < \infty$; 称*i*是零常返的, 若 $m_{i,i} = +\infty$.

直观而言状态*i*是正常返的意味着从*i*出发能“较大概率”地在短时间内回访自己, 而零常返则意味着虽然从*i*出发一定会回访自己, 但从回访时间平均看, 可以说“遥不可及”.

定理11.1 对一切 $i \in S$,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{i,i}^{(k)} = \begin{cases} 1/m_{i,i}, & i \text{正常返}, \\ 0, & \text{其他.} \end{cases}$$

证明定理之前我们先介绍一个关于数列的比极限的结论.

引理11.2 设 $\{a_n; n \geq 0\}$ 为一个不全为0的非负数列且满足条件

$$\lim_{n \rightarrow \infty} \frac{a_n}{\sum_{k=0}^n a_k} = 0.$$

若 $\{b_n; n \geq 0\}$ 为收敛数列, 那么

$$\lim_{n \rightarrow \infty} \frac{\sum_{k=0}^n a_k b_{n-k}}{\sum_{k=0}^n a_k} = \lim_{n \rightarrow \infty} b_n.$$

证明 由所设条件, 对任意给定 $N \geq 1$, 有

$$\lim_{n \rightarrow \infty} \frac{\sum_{k=n-N+1}^n a_k}{\sum_{k=0}^n a_k} = 0.$$

若 b_n 极限有限, 记作 b , 那么对任意 $\varepsilon > 0$, 存在 N , 使得当 $n \geq N$ 时, $|b_n - b| < \varepsilon$. 于是存在 $B < \infty$ 使得 $|b_n - b| < B$ 对一切 n 成立. 进而

$$\left| \sum_{k=0}^n a_k (b_{n-k} - b) \right| \leq \varepsilon \sum_{k=0}^{n-N} a_k + B \sum_{k=n-N+1}^n a_k$$

两边同除以 $\sum_{k=0}^n a_k$, 不难看出此时结论成立.

若 b_n 的极限为无穷, 不妨设是 $+\infty$, 则对一切 $M > 0$, 存在 N , 使得当 $n \geq N$ 时, $b_n \geq M$.

于是

$$\sum_{k=0}^n a_k b_{n-k} \geq M \sum_{k=0}^{n-N} a_k + (\min_{0 \leq n \leq N} b_n) \sum_{k=n-N+1}^n a_k.$$

同样两边同除以 $\sum_{k=0}^n a_k$, 不难看出此时结论也成立. \square

定理11.1的证明 按 n 之前最后离开状态 i 的时刻可将随机事件 $\{X_n = j\}$ 分解为不相容事件

$$\{X_n = j\} = \bigcup_{k=0}^{n-1} \{X_n = j, X_k = i, X_v \neq i, v = k+1, \dots, n-1\}.$$

从而, 由马氏性及(3.2.4)

$$\begin{aligned} p_{i,j}^{(n)} &= \mathbb{P}_i(X_n = j) = \mathbb{P}_i(\bigcup_{k=0}^{n-1} \{X_n = j, X_k = i, X_v \neq i, v = k+1, \dots, n-1\}) \\ &= \sum_{k=0}^{n-1} p_{i,i}^{(k)} \mathbb{P}_i(X_n = j, X_v \neq i, v = k+1, \dots, n-1 | X_k = i) \\ &= \sum_{k=0}^{n-1} p_{i,i}^{(k)} e_{ij}^{(n-k)}, \end{aligned} \quad (3.4.1)$$

进而

$$\begin{aligned} n &= \sum_{j \in S} \sum_{m=1}^n p_{i,j}^{(m)} = \sum_{j \in S} \sum_{m=1}^n \sum_{k=0}^{m-1} p_{i,i}^{(k)} e_{ij}^{(m-k)} \\ &= \sum_{j \in S} \sum_{k=0}^{n-1} p_{i,i}^{(k)} \sum_{m=1}^{n-k} e_{ij}^{(m)} = \sum_{k=0}^{n-1} p_{i,i}^{(k)} \sum_{m=1}^{n-k} \sum_{j \in S} e_{ij}^{(m)} \end{aligned}$$

注意到

$$\begin{aligned} \sum_{j \in S} e_{ij}^{(m)} &= \mathbb{P}_i(\bigcup_{j \in S} \{X_m = j, X_v \neq i, v = 1, \dots, m\}) \\ &= \mathbb{P}_i(X_v \neq i, v = 1, \dots, m-1) = \mathbb{P}_i(\tau_i \geq m). \end{aligned}$$

因此

$$n = \sum_{k=0}^{n-1} p_{i,i}^{(k)} \sum_{m=1}^{n-k} \mathbb{P}_i(\tau_i \geq m)$$

令 $b_n = \sum_{m=1}^n \mathbb{P}_i(\tau_i \geq m)$, 则 $n = \sum_{k=0}^{n-1} p_{i,i}^{(k)} b_{n-k}$. 若*i*正常返, $\lim_{n \rightarrow \infty} b_n = m_{ii} < \infty$; 若*i*零常返或非常返, $\lim_{n \rightarrow \infty} b_n = \infty$. 由引理11.2可知定理成立. \square

由定理11.1, 容易得到如下结果, 证明简单, 此略.

推论11.3 *i*正常返当且仅当 $\limsup_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{i,i}^{(k)} > 0$.

推论11.4 设状态*i*是正常返的, 如果*i* \rightarrow *j*, 那么*j*也是正常返的且*j* $\in C(i)$.

证明 由*i*常返可知*i*本质进而*j* $\in C(i)$, 因此存在*m, n* > 0 使得 $p_{j,i}^{(m)} > 0, p_{i,j}^{(n)} > 0$. 由C-K方程,

$$\lim_{k \rightarrow \infty} \frac{1}{k} \sum_{v=1}^k p_{j,j}^{(v)} = \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{v=m+n+1}^k p_{j,j}^{(v)} \geq p_{j,i}^{(m)} p_{i,j}^{(n)} \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{v=1}^{k-n-m} p_{i,i}^{(v)} > 0,$$

因此*j*正常返. \square

推论11.4表明若*i*正常返那么*C(i)*中所有状态都正常返, 即正常返性也是互通类中元素共有的性质, 此时称*C(i)*为正常返类. 结合此前关于常返与非常返的讨论, 我们可将互通类按其中状态的常返性分成正常返类, 零常返类和非常返类这三种情形. 类似, 我们也可以定义正常返、零常返和非常返马氏链, 若它的每个状态都是正常返、零常返和非常返的.

例11.1 直线上 (q, p) -随机游动 W 当 $p = q = 1/2$ 时是零常返的.

解 已知 $p = q = 1/2$ 时 W 常返. 此时对 $n = 2k, 2k+1$, 当 $k \geq 1$ 充分大时由striling公式可知

$$\sum_{m=0}^n p_{0,0}^{(m)} = 1 + \sum_{m=1}^k \frac{C_{2m}^m}{4^m} \approx \sum_{m=1}^k \frac{1}{\sqrt{\pi m}}.$$

因此

$$\sum_{m=0}^n p_{0,0}^{(m)} \approx \sqrt{\frac{2n}{\pi}}.$$

这表明 $\frac{1}{n} \sum_{m=0}^n p_{0,0}^{(m)} \rightarrow 0$, 从而状态0为零常返的. 由 W 不可约可知 W 零常返. \square

定理11.5 对任意 $i, j \in S$ 以及 $u \in [0, 1]$,

$$\lim_{n \rightarrow \infty} \frac{\sum_{k=1}^n p_{i,j}^{(k)} u^k}{\sum_{k=0}^n p_{j,j}^{(k)} u^k} = F_{i,j}(u).$$

证明 $u = 0$ 时结果显然成立. 下设 $u \in (0, 1]$. 由(3.2.5)可得对任意 $n \geq 1$,

$$\sum_{k=1}^n p_{i,j}^{(k)} u^k = \sum_{k=1}^n \sum_{r=1}^k f_{ij}^{(r)} p_{j,j}^{(k-r)} u^k = \sum_{r=1}^n f_{ij}^{(r)} u^r \sum_{k=0}^{n-r} p_{j,j}^{(k)} u^k = \sum_{k=0}^{n-1} p_{j,j}^{(k)} u^k \sum_{r=1}^{n-k} f_{ij}^{(r)} u^r.$$

令

$$a_n = p_{jj}^{(n)} u^n, \quad b_n = \sum_{r=1}^n f_{ij}^{(r)} u^r.$$

那么 $b_n \rightarrow F_{i,j}(u)$, 而且不论 j 是否常返引理11.2条件成立. 由此可知定理成立. \square

推论11.6 对任意 $i, j \in S$, $\frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)}$ 极限存在, 而且

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} = \begin{cases} f_{ij}/m_{jj}, & j \text{正常返}, \\ 0, & j \text{为其他状态}. \end{cases}$$

证明 由定理11.1与定理11.5(令 $u = 1$)立刻可得. \square

注11.1 对任意 $i \in S$, 若 j 是非周期正常返的, 那么 $\lim_{n \rightarrow \infty} p_{i,j}^{(n)} = f_{i,j}/m_{j,j}$; 若 j 是零常返的, 那么 $\lim_{n \rightarrow \infty} p_{i,j}^{(n)} = 0$; 若 j 是非常返的, $\lim_{n \rightarrow \infty} p_{i,j}^{(n)} = 0$. 后一结论是定理11.5的推论, 前两结论我们将在第五章第二节给出解释和证明.

对任意 $i, j \in S$, 令 $P_{i,j}(s) = \sum_{n=1}^{\infty} p_{i,j}^{(n)} s^n$. 由定理11.5和(3.2.6)可得

推论11.7 对任意 $i, j \in S$, $u \in [0, 1)$, $P_{i,j}(u) = F_{i,j}(u)/(1 - F_{j,j}(u))$. 此外 $u = 1$ 时

$$\sum_{n=1}^{\infty} p_{i,j}^{(n)} = P_{i,j}(1) = \begin{cases} f_{i,j}/(1 - f_{j,j}), & f_{j,j} < 1; \\ 0, & f_{i,j} = 0 \text{且} f_{j,j} = 1; \\ \infty, & f_{i,j} > 0 \text{且} f_{j,j} = 1. \end{cases}$$

3.4.2 平稳分布

定义11.2 称不恒为零的非负有限数列 $\mathbf{u} = (u_i; i \in S)$ 为马氏链的不变测度, 若对任意 $i \in S$

$$u_i = \sum_{k \in S} u_k p_{k,i}. \quad (3.4.2)$$

当 $\sum_{i \in S} u_i = 1$, 即 $(u_i; i \in S)$ 是概率分布时, 称 \mathbf{u} 是 X 的平稳分布.

显然, 若 \mathbf{u} 为 X 的不变测度, 对任意 $n \geq 1$, 由 C-K 方程, $u_i = \sum_{k \in S} u_k p_{k,i}^{(n)}$. 这表明若 X 以平稳分布 $(\pi_i, i \in S)$ 为初始分布, 那么 X 在每一个时刻的分布都与初始分布相同. 这也是我们称其为“平稳分布”的原因所在.

对只有有限个状态的马氏链, 我们可以借助线性方程组, 方便地找到它可能的平稳分布: 设 X 是有 n 个状态的马氏链, 转移概率矩阵 $\mathbf{P} = (p_{i,j})$, 记其可能的平稳分布为

$$\pi = (\pi_1, \pi_2, \dots, \pi_n)^T,$$

那么 π 是下列方程组解

$$\left\{ \begin{array}{l} p_{1,1}\pi_1 + p_{2,1}\pi_2 + \dots + p_{n,1}\pi_n = \pi_1; \\ \dots \\ p_{1,n-1}\pi_1 + p_{2,n-1}\pi_2 + \dots + p_{n,n-1}\pi_n = \pi_{n-1}; \\ p_{1,n}\pi_1 + p_{2,n}\pi_2 + \dots + p_{n,n}\pi_n = \pi_n; \\ \pi_1 + \dots + \pi_n = 1. \end{array} \right.$$

由于转移概率矩阵满足 $\sum_{j=1}^n p_{i,j} = 1$, 因此前 $n-1$ 个方程加到第 n 个方程会得到恒等式

$$\pi_1 + \dots + \pi_n = \pi_1 + \dots + \pi_n.$$

这意味着该方程组与把第 n 个方程去掉的方程组

$$\left\{ \begin{array}{l} p_{1,1}\pi_1 + p_{2,1}\pi_2 + \dots + p_{n,1}\pi_n = \pi_1; \\ \dots \\ p_{1,n-1}\pi_1 + p_{2,n-1}\pi_2 + \dots + p_{n,n-1}\pi_n = \pi_{n-1}; \\ \pi_1 + \dots + \pi_n = 1, \end{array} \right.$$

同解, 也即我们只须求解如下的矩阵方程

$$\mathbf{Q}^T \pi = \pi',$$

其中矩阵 \mathbf{Q} 是将转移概率矩阵 \mathbf{P} 最后一列替换为 $(1, 1, \dots, 1)^T$ 后所得到的矩阵, 而 π' 是将 π 最后一个分量替换为 1 后所得向量.

例11.2 设 X 的转移概率矩阵为 $\begin{pmatrix} 0 & 1/2 & 1/2 \\ 0 & 1/4 & 3/4 \\ 1 & 0 & 0 \end{pmatrix}$, 求 X 的平稳分布.

解 令 $\mathbf{Q} = \begin{pmatrix} 0 & 1/2 & 1 \\ 0 & 1/4 & 1 \\ 1 & 0 & 1 \end{pmatrix}$, 解方程组 $\mathbf{Q}^T \pi = \pi'$, 即

$$\begin{cases} \pi_3 = \pi_1 \\ \pi_1/2 + 3\pi_2/4 = \pi_2 \\ \pi_1 + \pi_2 + \pi_3 = 1 \end{cases}$$

可得唯一非负解 $(\pi_1, \pi_2, \pi_3) = (3/8, 1/4, 3/8)$. 此即为 X 的平稳分布. \square

不是所有的马氏链都有平稳分布. 不可约马氏链的平稳分布与回访周期相关.

定理11.8 设 X 为不可约马氏链, X 是正常返的当且仅当 X 存在平稳分布 $(\pi_i, i \in S)$. X 的平稳分布唯一而且

$$\pi_i = 1/m_{i,i} > 0, \quad i \in S.$$

证明 先证前一个结论的必要性. 为此我们只需验证 $\{1/m_{j,j}, j \in S\}$ 是平稳分布. 由C-K方程可知

$$\frac{1}{n} \sum_{k=1}^n p_{j,j}^{(k)} = \frac{1}{n} \sum_{k=1}^n \sum_{i \in S} p_{j,i}^{(k-1)} p_{i,j} = \sum_{i \in S} \left[\frac{1}{n} \sum_{k=1}^n p_{j,i}^{(k-1)} \right] p_{i,j}. \quad (3.4.3)$$

因为 X 是正常返的, 那么对任意 $i, j \in S$,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{j,j}^{(k)} = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} = \frac{1}{m_{j,j}} > 0.$$

令(3.4.3)式两边 $n \rightarrow \infty$ 得

$$\frac{1}{m_{j,j}} \geq \lim_{N \rightarrow \infty} \sum_{i \in A_N} \frac{p_{i,j}}{m_{ii}} = \sum_{i \in S} \frac{p_{i,j}}{m_{i,i}}.$$

其中 A_N 表示 S 中元素个数为 N 的有限子集且

$$A_N \subset A_{N+1} \subset \cdots, \quad \bigcup_N A_n = S.$$

另一方面, 由

$$1 = \sum_{i \in S} \left[\frac{1}{n} \sum_{k=1}^n p_{j,i}^{(k)} \right]$$

可知

$$1 \geq \lim_{N \rightarrow \infty} \sum_{i \in A_N} \frac{1}{m_{i,i}} = \sum_{i \in S} \frac{1}{m_{i,i}}.$$

因此

$$1 \geq \sum_{j \in S} \frac{1}{m_{j,j}} \geq \sum_{j \in S} \sum_{i \in S} \frac{p_{i,j}}{m_{i,i}} \geq \lim_{N \rightarrow \infty} \sum_{i \in A_N} \left[\lim_{M \rightarrow \infty} \sum_{j \in A_M} \frac{p_{i,j}}{m_{i,i}} \right] = \sum_{i \in S} \frac{1}{m_{i,i}}.$$

这表明对任意 $j \in S$,

$$\frac{1}{m_{j,j}} = \sum_{i \in S} \frac{p_{i,j}}{m_{i,i}}.$$

由此进一步可得

$$\frac{1}{m_{j,j}} = \sum_{i \in S} \frac{1}{m_{i,i}} \left[\frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} \right],$$

注意到 $1 \geq \sum_{i \in S} \frac{1}{m_{i,i}}$, 由一致收敛级数求和与极限可交换性质可得, 当 $n \rightarrow \infty$ 时,

$$\frac{1}{m_{j,j}} = \sum_{i \in S} \frac{1}{m_{i,i} m_{j,j}}. \quad (3.4.4)$$

这表明 $\sum_{i \in S} 1/m_{i,i} = 1$, 因此 $(1/m_{j,j}, j \in S)$ 为 X 的平稳分布.

再证前一个结论的充分性. 设 $(\pi_j, j \in S)$ 是 X 的任一平稳分布. 对任意 $j \in S$,

$$\pi_j = \sum_{i \in S} \pi_i p_{i,j} = \sum_{i \in S} \pi_i \left[\frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} \right]. \quad (3.4.5)$$

由推论10.6

$$\pi_j = \sum_{i \in S} \pi_i \left[\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} \right] = \begin{cases} [\sum_{i \in S} \pi_i f_{i,j}] / m_{j,j}, & j \text{ 正常返,} \\ 0, & \text{其他.} \end{cases}$$

另一方面, 由 $\sum_{j \in S} \pi_j = 1$ 可知存在 $j_0 \in S$ 使得 $\pi_{j_0} > 0$. 由于 $j_0 \rightarrow j$, 存在 N 使得 $p_{j_0,j}^{(N)} > 0$. 因此

$$\pi_j = \sum_{i \in S} \pi_i p_{i,j} = \sum_{i \in S} \pi_i p_{i,j}^{(N)} \geq \pi_{j_0} p_{j_0,j}^{(N)} > 0.$$

这说明 j 正常返状态, 又由于 X 是不可约的, 因此 X 是正常返链.

由于对任意 $i, j \in S$, $f_{i,j} = 1$, 由(3.4.5)知 $0 < \pi_j = 1/m_{j,j}$. 这表明平稳分布必唯一. 因此定理后一个结论也成立. \square

对不可约的马氏链而言, 由定理11.8可知, 只有正常返链才有平稳分布, 这时我们可以选择这个平稳分布为初始分布使得对应的马氏链在任何时刻的分布都保持不变. 更有意思的是:

定理11.9 若 $X = \{X_n\}$ 是不可约正常返马氏链, 记其平稳分布为 $\pi = (\pi_i, i \in S)$, 其中 $\pi_i = 1/m_{ii}$. 那么对任意 $i, j \in S$,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^n p_{i,j}^{(k)} = \pi_j. \quad (3.4.6)$$

进一步, 若 X 还是非周期的, 任意给定 X 的一个初始分布 $\mu = (\mu_i, i \in S)$, 那么随着 $n \rightarrow \infty$, X_n 的分布收敛到 π , 即对任意 $j \in S$, $\mathbb{P}(X_n = j) \rightarrow \pi_j$.

证明 由于 X 是不可约常返的, 由性质8.7可知, 对任意 $i, j \in S$, $f_{i,j} = 1$. 由推论10.6可知前半部分结论成立.

进一步, 若 X 还是非周期的, 由注10.1可知, 对任意的 $i, j \in S$,

$$p_{i,j}^{(n)} \rightarrow \frac{1}{m_{jj}} = \pi_j.$$

因此当 X 的初始分布为 μ 时,

$$\begin{aligned}\mathbb{P}(X_n = j) &= \sum_{i \in S} \mathbb{P}(X_n = j, X_0 = i) \\ &= \sum_{i \in S} \mathbb{P}(X_0 = i) \mathbb{P}(X_n = j | X_0 = i) = \sum_{i \in S} \mu_i p_{i,j}^{(n)}.\end{aligned}$$

由于 $\sum_{i \in S} \mu_i = 1$, 级数 $\sum_{i \in S} \mu_i p_{i,j}^{(n)}$ 对 n 一致收敛. 因此 $n \rightarrow \infty$ 时, 我们可得

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = j) = \lim_{n \rightarrow \infty} \sum_{i \in S} \mu_i p_{i,j}^{(n)} = \sum_{i \in S} (\mu_i \lim_{n \rightarrow \infty} p_{i,j}^{(n)}) = \sum_{i \in S} \mu_i \pi_j = \pi_j.$$

即定理后半部分也成立. \square

例11.3 (例8.5续) 问如果社会阶层的转换机制不改变, 长时间后社会阶层的比例是多少.

解 由转移概率矩阵可知, 表示社会阶层变化的马氏链 X 是不可约非周期的. 令

$$\mathbf{Q} = \begin{pmatrix} 0.8 & 0.1 & 1 \\ 0.3 & 0.4 & 1 \\ 0.05 & 0.1 & 1 \end{pmatrix}.$$

解方程 $\mathbf{Q}^T \pi = \pi'$, 即

$$\begin{cases} 0.8\pi_1 + 0.3\pi_2 + 0.05\pi_3 = \pi_1 \\ 0.1\pi_1 + 0.4\pi_2 + 0.1\pi_3 = \pi_2 \\ \pi_1 + \pi_2 + \pi_3 = 1 \end{cases}$$

得唯一非负解

$$(\pi_1, \pi_2, \pi_3) = (12/35, 5/35, 18/35).$$

此即为长时间后社会阶层的比例. \square

此外, 注意到 $N_n(j) = \sum_{k=1}^n \mathbf{1}_{\{X_k=j\}}$ 表示过程 X 在时刻 n 之前(含 n)到达状态 j 的次数.

$$\mathbb{E}(N_n(j)) = \mathbb{E}\left(\sum_{k=1}^n \mathbf{1}_{\{X_k=j\}}\right) = \sum_{k=1}^n \mathbb{P}(X_k = j)$$

表示 X 在时刻 n 之前(含 n)到达状态 j 平均次数, $\mathbb{E}(N_n(j))/n$ 则表示到达状态 j 的平均比率.

由(3.4.6), 对 X 的任意初始分布 $\mu = (\mu_i, i \in S)$,

$$\frac{\mathbb{E}(N_n(j))}{n} = \frac{1}{n} \sum_{k=1}^n \mathbb{P}(X_k = j) = \frac{1}{n} \sum_{k=1}^n \sum_{i \in S} \mu_i p_{i,j}^{(k)} = \sum_{i \in S} \left[\mu_i \left(\frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} \right) \right].$$

令 $n \rightarrow \infty$ 得

$$\frac{\mathbb{E}(N_n(j))}{n} \rightarrow \pi_j.$$

这表明平稳分布还刻画了马氏链在长时间内访问各状态的比率.

例11.4 在研究人们消费习惯时常会调查人们对具有相同功能不同品牌的产品的消费情况.

假设有三个品牌的手机1, 2, 3, 令 X_n 表示消费者在第 n 次购买时选择的品牌. 顾客购买这三个品牌后下次选择相同品牌的概率分别为 0.8, 0.6, 0.8, 若他们改变品牌则会在另外两个品牌中随机挑选一个. 问一个顾客长期消费后在各个品牌上的消费比例?

解 容易看出 $X = \{X_n\}$ 是一个转移概率矩阵为

$$\mathbf{P} = \begin{pmatrix} 0.8 & 0.1 & 0.1 \\ 0.2 & 0.6 & 0.2 \\ 0.1 & 0.1 & 0.8 \end{pmatrix}$$

的时齐马氏链. X 是不可约非周期的. 令

$$\mathbf{Q} = \begin{pmatrix} 0.8 & 0.1 & 1 \\ 0.2 & 0.6 & 1 \\ 0.1 & 0.1 & 1 \end{pmatrix}.$$

解方程 $\mathbf{Q}^T \pi = \pi'$, 即

$$\begin{cases} 0.8\pi_1 + 0.2\pi_2 + 0.1\pi_3 = \pi_1 \\ 0.1\pi_1 + 0.6\pi_2 + 0.1\pi_3 = \pi_2 \\ \pi_1 + \pi_2 + \pi_3 = 1 \end{cases}$$

可得唯一非负解

$$(\pi_1, \pi_2, \pi_3) = (2/5, 1/5, 2/5).$$

此即为顾客在长期消费当中各个品牌的消费比例. \square

由定理11.8可知, 不可约链 X 的平稳分布中每一分量都为正数. 由此我们得到一个判别马氏链是否正常返的方法.

推论11.10 不可约马氏链 X 是正常返的当且仅当方程组

$$u_i = \sum_{k \in S} u_k p_{k,i}$$

存在一个全不为零的非负解 $\{u_i; i \in S\}$ 使得 $\sum_{i \in S} u_i < \infty$.

证明 此时 $\{u_i / \sum_{i \in S} u_i\}$ 为平稳分布, 从而推论成立. \square

例11.5 讨论例10.4中广义带反射壁随机游动 X 的正常返性.

解 由例10.4可知 X 常返 $\Leftrightarrow \sum_{k=1}^{\infty} \frac{q_1 \cdots q_k}{p_1 \cdots p_k} = \infty$. 记 $\rho_k = \frac{q_1 \cdots q_k}{p_1 \cdots p_k}$. 解方程组

$$z_i = \sum_{k=0}^{\infty} z_k p_{k,i}, \quad i \geq 0.$$

由 $r_0 + p_0 = 1, r_n + p_n + q_n = 1, n \geq 1$, 可得

$$\begin{cases} q_1 z_1 - p_0 z_0 = 0 \\ q_{n+1} z_{n+1} - p_n z_n = q_n z_n - p_{n-1} z_{n-1}, n \geq 1. \end{cases}$$

因此对任意 $n \geq 0, q_{n+1} z_{n+1} = p_n z_n$, 继而

$$z_{n+1} = \frac{p_n \cdots p_0}{q_{n+1} \cdots q_1} z_0 = \frac{p_0}{p_{n+1} \rho_{n+1}} z_0.$$

由推论11.9, X 正常返当且仅当

$$\sum_{n=0}^{\infty} z_i < \infty \Leftrightarrow z_0 \sum_{n=1}^{\infty} \frac{p_0}{p_n \rho_n} < \infty \Leftrightarrow \sum_{n=1}^{\infty} \frac{1}{p_n \rho_n} < \infty.$$

此即为 X 正常返的条件. \square

练习题

11.1 证明任意不可约有限状态马氏链必是正常返的.

11.2 设不可约链 X 存在状态 j 使得方程组

$$z_i = \sum_{k \neq j} p_{i,k} z_k + f_{ij}, \quad i \neq j$$

的一组有限解 $\{u_i, i \neq j\}$ 满足

$$\sum_{k \neq j} p_{j,k} u_k < \infty.$$

若 j 是常返的, 证明 j 是正常返的.

11.3 设 X 是一个不可约非常返的马氏链, 令 $l_j = \sup\{n \geq 0, X_n = j, X_k \neq j, k \geq n\}$,

即 l_j 是 X 最后一次到达状态 j 的时间. 假定 X 从 j 出发, 求 l_j 的分布列和均值. ([提示] 均值为 $m_{ii}/(1-f_{ii})$)

11.4 设 X 的转移概率矩阵为 $\begin{pmatrix} 0 & 1 & 0 \\ 1/4 & 1/2 & 1/4 \\ 0 & 1 & 0 \end{pmatrix}$, 求 X 的平稳分布.

11.5 设 X 的转移概率满足: 对任意 $i, j \in S = \{0, 1, 2, \dots\}$,

$$p_{i,j} = \begin{cases} \lambda_i + (1 - \lambda_i)u_i, & i = j, \\ (1 - \lambda_i)u_j, & i \neq j, \end{cases}$$

其中 $u_j > 0, \sum_{j=0}^{\infty} u_j = 1, 0 < \lambda_i < 1$. 证明

(1) X 是常返的;

(2) X 正常返当且仅当 $\sum_{i=0}^{\infty} u_i / (1 - \lambda_i) < \infty$.

11.6 证明不可约正常返马氏链的不变测度 μ 必是有限测度(即 $\sum_{i \in S} \mu(i) < \infty$).

11.7 设 X 为不可约正常返马氏链, 证明对任意 $i, j \in S$, $\pi_j = \pi_i e_{ij}$, 其中 $\{\pi_i; i \in S\}$ 为 X 的平稳分布, $e_{ij} = \sum_{n=1}^{\infty} e_{ij}^{(n)}$.

第四章 马氏链的一些简单应用

马氏链在实际问题中有着广泛应用. 这一章我们介绍一些与应用有关的具体马氏链模型及相关理论, 解决一些应用问题.

4.1 存储与排队模型

4.1.1 存储模型

先看一个马氏链在商品存储决策中简单应用的例子. 为此我们先给出一个重要的极限定理(遍历性定理).

定理12.1 记不可约正常返马氏链 $X = \{X_n; n \geq 0\}$ 的平稳分布为 $\pi = \{\pi_i; i \in S\}$. 若 S 上函数 g 满足 $\sum_{j \in S} |g(j)|\pi_j < \infty$, 那么

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n g(X_k) = \sum_{j \in S} g(j)\pi_j := \mathbb{E}_\pi(g), \quad a.s.$$

证明 由于 $g = g^+ - g^- = g \vee 0 - (-g) \vee 0$. 不妨设 g 非负. 定义 $\tau_i(0) = 0$,

$$\tau_i(k) = \inf\{n > \tau_i(k-1), X_n = i\}, \quad W_i(k) = \tau_i(k) - \tau_i(k-1), \quad k \geq 1.$$

由定理9.11易知 $\{W_i(k), k \geq 2\}$ 为i.i.d序列, 且 $\mathbb{E}(W_i(2)) = m_{i,i} < \infty$. 由强大数定律

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n W_i(k) = \lim_{n \rightarrow \infty} \frac{1}{n} \tau_i(n) = m_{i,i}, \quad a.s.$$

再令

$$Y_k = \sum_{n=\tau_i(k)+1}^{\tau_i(k+1)} g(X_m).$$

仍由定理9.11可知 $Y_k, k \geq 1$, 为独立同分布随机变量. 注意到

$$\begin{aligned} \mathbb{E}(Y_1) &= \mathbb{E}\left(\sum_{m=\tau_i(k)+1}^{\tau_i(k+1)} g(X_m)\right) = \mathbb{E}_i\left(\sum_{m=1}^{\tau_i(1)} g(X_m)\right) = \mathbb{E}_i\left(\sum_{m=1}^{\tau_i} g(X_m)\right) \\ &= g(i) + \sum_{n=1}^{\infty} \mathbb{P}_i(\tau_i = n) \mathbb{E}_i\left(\sum_{m=1}^{n-1} g(X_m) \mid \tau_i = n\right) \end{aligned}$$

$$\begin{aligned}
&= g(i) + \sum_{n=1}^{\infty} \mathbb{P}_i(\tau_i = n) \sum_{m=1}^{n-1} \sum_{j \neq i} g(j) \mathbb{P}_i(X_m = j | \tau_i = n) \\
&= g(i) + \sum_{n=1}^{\infty} \sum_{m=1}^{n-1} \sum_{j \neq i} g(j) \mathbb{P}_i(X_m = j, \tau_i = n).
\end{aligned}$$

由于是非负项求和, 我们可以交换 n, m 的求和次序, 得

$$\begin{aligned}
\mathbb{E}(Y_1) &= g(i) + \sum_{m=1}^{\infty} \sum_{j \neq i} g(j) \mathbb{P}_i(X_m = j, \tau_i \geq m+1) \\
&= g(i) + \sum_{m=1}^{\infty} \sum_{j \neq i} g(j) e_{i,j}^{(m)} = g(i) + \sum_{j \neq i} g(j) e_{i,j}.
\end{aligned}$$

由习题11.5及定理11.7可知

$$\mathbb{E}(Y_1) = \sum_{j \in S} g(j) \pi_j / \pi_i = m_{i,i} \mathbb{E}_{\pi}(g) < \infty.$$

由强大数定律

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^n Y_k = m_{i,i} \mathbb{E}_{\pi}(g), \quad a.s. \quad (4.1.1)$$

以 $N_n = \sum_{k=1}^n \mathbf{1}_{\{X_k=i\}}$ 表示 n 之前访问 i 的次数. 由于 i 常返, 由命题9.10可知 $N_n \rightarrow \infty$, a.s. 因此由习题4.1可得

$$\tau_i(N_n)/N_n \rightarrow m_{ii} \quad a.s. \quad \text{以及} \quad \frac{1}{N_n} \sum_{k=1}^{N_n} Y_k = m_{ii} \mathbb{E}_{\pi}(g), \quad a.s.$$

注意到

$$\tau_i(N_n) \leq n \leq \tau_i(N_n + 1).$$

由

$$\frac{\tau_i(N_n)}{N_n} \leq \frac{n}{N_n} < \frac{\tau_i(N_n + 1)}{N_n},$$

以及

$$\sum_{k=0}^{N_n-1} Y_k = \sum_{m=1}^{\tau_i(N_n)} g(X_m) \leq \sum_{m=1}^n g(X_m) \leq \sum_{m=1}^{\tau_i(N_n+1)} g(X_m) = \sum_{k=1}^{N_n} Y_k,$$

进而

$$\frac{N_n - 1}{n} \left[\frac{1}{N_n - 1} \sum_{k=0}^{N_n-1} Y_k \right] \leq \frac{1}{n} \sum_{m=1}^n g(X_m) \leq \frac{N_n}{n} \left[\frac{1}{N_n} \sum_{k=1}^{N_n} Y_k \right],$$

可知结论成立. □

在定理12.1假设前提下, 进一步我们可得如下推论.

推论12.2 若 g 为非负函数, 那么

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n g(X_k) = \sum_{i \in S} g(i) \pi_i, \quad a.s.$$

证明 若 $\sum_{i \in S} g(i) \pi_i < \infty$, 那么推论12.2就是定理12.1 的直接应用. 若 $\sum_{i \in S} g(i) \pi_i = \infty$, 那么对

任意 N , 定义函数 $g_N(i) = i \wedge N$. 应用定理12.1 得

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n X_k \geq \limsup_{N \rightarrow \infty} \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n g_N(X_k) = \limsup_{N \rightarrow \infty} \mathbb{E}_\pi g_N = \sum_{i \in S} g(i)\pi_i = \infty.$$

因此推论12.2成立. \square

例12.1 考虑例8.1中的 (k, K) 商品存储模型 X , 其中 $K = 3$, 表示需求的随机变量 ξ 满足

$$p_0 = \mathbb{P}(\xi = 0) = 0.3, p_1 = \mathbb{P}(\xi = 1) = 0.4, p_2 = \mathbb{P}(\xi = 2) = 0.2, p_3 = \mathbb{P}(\xi = 3) = 0.1$$

若每销售一件商品可以获利12元, 每件商品存储一个单位时间需花费2元, 试确定最优的 k 使得从长期看平均收益最大.

解 对任意给定的 $k \in \{0, 1, 2\}$, 根据进货策略, 在第 n 个单位时间获得的净利润 r_n 为

$$r_n = \begin{cases} 12(3 - X_n) - 2X_n = 36 - 14X_n, & X_{n-1} \leq k \\ 12(X_{n-1} - X_n) - 2X_n = 12X_{n-1} - 14X_n, & k < X_{n-1} \leq 3 \end{cases} =: g(X_{n-1}, X_n).$$

由假设, X 的转移概率矩阵 $(p_{i,j})_4$ 满足

$$p_{i,j} = \begin{cases} \mathbb{P}((3 - \xi) \vee 0 = j) = \mathbb{P}(\xi = 3 - j) = p_{3-j}, & i \leq k, \\ \mathbb{P}((i - \xi) \vee 0 = j) = p_{i-j}, & k < i \leq 3, 0 < j \leq i \\ \mathbb{P}((i - \xi) \vee 0 = j) = p_i + \dots + p_3, & k < i \leq 3, j = 0 \\ \mathbb{P}((i - \xi) \vee 0 = j) = 0, & k < i \leq 3, i < j \leq 3 \end{cases}$$

显然 X 是有限状态不可约马氏链, 从而正常返, 记其平稳分布为

$$\pi = (\pi_0, \pi_1, \pi_2, \pi_3).$$

由习题12.3及定理12.1可知平均利润

$$\begin{aligned} \frac{1}{n} \sum_{m=1}^n r_m &= \frac{1}{n} \sum_{m=1}^n g(X_{m-1}, X_m) \rightarrow r(k) = \sum_{i=0}^3 \sum_{j=0}^3 g(i, j)\pi_i p_{i,j} \\ &= \sum_{i=0}^k \sum_{j=0}^3 (36 - 14j)\pi_i p_{3-j} + \sum_{i=k+1}^3 \sum_{j=0}^3 (12i - 14j)\pi_i p_{i,j} \\ &= 9.4 \sum_{i=0}^k \pi_i + 12 \sum_{i=k+1}^3 i\pi_i - 14 \sum_{i=k+1}^3 \left(\pi_i \sum_{j=1}^i jp_{i-j} \right). \end{aligned}$$

直接计算可知, 当 $k = 2$ 时

$$r(2) = 9.4 \sum_{i=0}^2 \pi_i + 36\pi_3 - 14\pi_3 \sum_{j=1}^3 jp_{3-j} = 9.4 \sum_{i=0}^3 \pi_i = 9.4.$$

当 $k = 1$ 时由

$$(p_{i,j}) = \begin{pmatrix} 0.1 & 0.2 & 0.4 & 0.3 \\ 0.1 & 0.2 & 0.4 & 0.3 \\ 0.3 & 0.4 & 0.3 & 0 \\ 0.1 & 0.2 & 0.4 & 0.3 \end{pmatrix}$$

可求得平稳分布

$$\pi = (19/110, 30/110, 40/110, 21/110).$$

此时平均收益极限

$$\begin{aligned} r(1) &= 9.4(\pi_0 + \pi_1) + 12(2\pi_2 + 3\pi_3) - 14(\pi_2 + 1.9\pi_3) \\ &= 9.4 + 0.6\pi_2 \approx 9.62. \end{aligned}$$

当 $k = 0$ 时由

$$(p_{i,j}) = \begin{pmatrix} 0.1 & 0.2 & 0.4 & 0.3 \\ 0.7 & 0.3 & 0 & 0 \\ 0.3 & 0.4 & 0.3 & 0 \\ 0.1 & 0.2 & 0.4 & 0.3 \end{pmatrix}$$

可求得平稳分布

$$\pi = (343/1070, 300/1070, 280/1070, 147/1070).$$

此时平均收益极限

$$\begin{aligned} r(0) &= 9.4\pi_0 + 12(\pi_1 + 2\pi_2 + 3\pi_3) - 14(0.3\pi_1 + \pi_2 + 1.9\pi_3) \\ &= 9.4 - 1.6\pi_1 + 0.6\pi_2 \approx 9.11. \end{aligned}$$

因此 $(1, 3)$ 策略是长期平均利润准则下的最优策略. □

4.1.2 排队模型

我们现在考虑马氏链在服务系统中应用的例子. 在介绍这个例子之前我们需要两个判断马氏链是否(正)常返的工具.

定理12.3 设不可约链 X 的状态空间 $S = \{0, 1, 2, \dots\}$, 若存在 $\{y_i; i \in S\}$ 及某个状态 j 使得对任意 $i \neq j$,

$$\sum_{k \in S} p_{i,k} y_k \leq y_i, \tag{4.1.2}$$

而且 $\lim_{i \rightarrow +\infty} y_i = +\infty$, 那么 X 为常返的.

证明 不失一般性可设对任意 $i \in S$, $y_i > 0$, 令 $\tilde{p}_{i,s} = \begin{cases} p_{i,s}, & i \neq j, \\ \delta_{j,s}, & i = j \end{cases}$, Y 是转移概率矩阵

为 $\tilde{\mathbf{P}} = (\tilde{p}_{i,j})$ 的时齐马氏链. 则对 Y 而言,

$$(1) \tilde{f}_{ij} = \mathbb{P}_i(\tau_j(Y) < \infty) = \mathbb{P}_i(\tau_j(X) < \infty) = f_{i,j}.$$

(2) j 为吸收态. 对任意 $i \in S$, 若 $i \neq j$, 由 $i \rightarrow j$ 可知 i 非常返, 注 11.1 表明对任意 $k \in S$, $\tilde{p}_{k,i}^{(n)} \rightarrow 0$; 若 $i = j$, 由习题 9.3 可知 $\tilde{p}_{k,j}^{(n)} \rightarrow \tilde{f}_{kj}$.

对任给的 $i \in S$, $i \neq j$, 迭代 (4.1.2) 可得,

$$\sum_{k \in S} \tilde{p}_{i,k}^{(n)} y_k \leq y_i.$$

对任意 $\varepsilon > 0$, 由 $y_n \rightarrow \infty$ 可知, 存在充分大的 $N > j$, 使得

$$\inf_{n > N} y_n \geq y_i / \varepsilon.$$

由

$$\inf_{n > N} y_n \sum_{k > N} \tilde{p}_{i,k}^{(n)} \leq \sum_{k > N} \tilde{p}_{i,k}^{(n)} y_k \leq y_i$$

可得

$$\sum_{k > N} \tilde{p}_{i,k}^{(n)} < \varepsilon.$$

因此

$$\sum_{0 \leq k \leq N} \tilde{p}_{i,k}^{(n)} > 1 - \varepsilon$$

令 $n \rightarrow \infty$ 并结合上面的观察(2)可知 $\tilde{f}_{i,j} \geq 1 - \varepsilon$. 再令 $\varepsilon \rightarrow 0$ 得 $\tilde{f}_{i,j} = 1$. 由上面的观察(1)及定理 10.1 可知 $f_{jj} = 1$. 因此 j 是常返的, 进而不可约链 X 是常返的. \square

定理 12.4 不可约链 X 正常返的充要条件是存在非负数列 $\{z_i; i \in S\}$ 及一个状态(或任一状态) j 使得

$$\begin{cases} \sum_{k \in S} p_{i,k} z_k \leq z_i - 1, & i \neq j, \\ \sum_{k \in S} p_{j,k} z_k < \infty. \end{cases} \quad (4.1.3)$$

证明“必要性”: 令 $z_j = 0$ 以及 $z_i = m_{ij}$, $i \neq j$. 由定理 10.3.

$$\sum_{k \in S} p_{j,k} z_k = \sum_{k \neq j} p_{j,k} m_{k,j} < m_{jj} < \infty$$

而对任意 $i \neq j$,

$$\sum_{k \in S} p_{i,k} z_k = \sum_{k \neq j} p_{i,k} m_{k,j} = m_{ij} - f_{ij} = m_{ij} - 1 = z_i - 1.$$

即存在(任)一个状态 j 以及非负数列 $\{z_i; i \in S\}$ 使得 (4.1.3) 成立.

“充分性”：记 $\delta = \sum_{k \in S} p_{j,k} z_k$, 则 $0 < \delta < \infty$. 任取*i* ≠ *j*, 对任意*n* ≥ 2, 迭代(4.1.3) 可得,

$$\begin{aligned} 0 \leq \sum_k p_{i,k}^{(n)} z_k &= \sum_{k \in S} \sum_{l \in S} p_{i,l}^{(n-1)} p_{l,k} z_k = \sum_{l \in S} p_{i,l}^{(n-1)} \sum_{k \in S} p_{l,k} z_k \\ &= \sum_{l \neq j} p_{i,l}^{(n-1)} (z_l - 1) + p_{i,j}^{(n-1)} \delta = \sum_{l \neq j} p_{i,l}^{(n-1)} z_l - 1 + p_{i,j}^{(n-1)} (1 + \delta) \\ &\leq \sum_{l \in S} p_{i,l}^{(n-1)} z_l - 1 + p_{i,j}^{(n-1)} (1 + \delta) \leq \dots \\ &\leq z_i - n + \sum_{k=1}^{n-1} p_{i,j}^{(k)} (1 + \delta). \end{aligned}$$

这表明

$$\sum_{k=1}^{n-1} p_{i,j}^{(k)} (1 + \delta) \geq n - z_i.$$

两边除*n*并令*n* → ∞得

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{i,j}^{(k)} \geq \frac{1}{1 + \delta} > 0.$$

由推论11.6可知*j*为正常返状态, 从而*X*是正常返的. □

例12.2 观察服务系统中的某一个窗口, 问平均会有多少人在排队? 窗口没人的时间占多大比例?

要回答这样的实际问题, 我们通常需要做些假设. 设顾客相继随机到达, 一般认为达到的时间间隔构成一列独立同分布的随机变量序列, 顾客到达后通常按“先来先服务”的原则接受服务台的服务, 假设为每个顾客的服务时间也是独立同分布的随机变量且与顾客到达的时间间隔相互独立, 称满足这些假定的服务系统为*G/G/s* 系统, 其中第一个*G*表示顾客到达的时间间隔分布, 第二个*G*表示服务时间分布, *s* 为服务台(窗口)的数量.

为了简单, 现假设顾客到达时间间隔分布服从参数为 λ 的指数分布, 服务时间服从密度函数为 g 的连续分布, 只考虑一个窗口. 以 X_n 表示第*n*个顾客服务完毕离开时, 在窗口等待服务的顾客数, 初始时刻取为第一个顾客到达时刻, 即 $X_0 = 1$. 那么可验证 $X = \{X_n; n \geq 0\}$ 为例6.2中马氏链. 事实上以 U_n 表示第*n*个顾客接受服务的时长, ξ_n 表示在第*n* 个顾客接受服务期间到达的顾客数, 由指数分布无记忆性可知 $\{\xi_n; n \geq 1\}$ 是独立同分布的随机变量, 分布列为

$$p_k = \mathbb{P}(\xi_n = k) = \mathbb{E}(\mathbb{P}(\xi_n = k | U_n)) = \int_0^\infty \frac{(\lambda t)^k}{k!} e^{-\lambda t} g(t) dt,$$

而且

$$X_n = \begin{cases} X_{n-1} - 1 + \xi_n, & X_{n-1} > 0, \\ \xi_n, & X_{n-1} = 0. \end{cases}$$

此时 X 的转移概率 $p_{i,j}$ 满足条件：对任意 $j \geq 0$, $p_{0,j} = p_j$. 而 $i > 0$ 时，对任意 $j \geq i-1$, $p_{i,j} = p_{j-i+1}$, 对任意 $0 \leq j < i-1$, $p_{i,j} = 0$. 一般地，我们称 X 为 $M(\lambda)/G/1$ 排队系统的嵌入链，所求问题可以通过计算如下统计量获得有用信息

$$(1) \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n X_k, \quad (2) \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n \mathbf{1}_{\{X_k=0\}}.$$

下面我们总设 $0 < p_0$, $p_0 + p_1 < 1$, $\rho = \sum_{k=1}^{\infty} kp_k = \mathbb{E}(\xi_1) < \infty$. 对任意 $s \in [0, 1]$, 令

$$A(s) = \sum_{k=0}^{\infty} p_k s^k$$

表示服务期间到达顾客分布的母函数. 显然 $\rho = A'(1)$ 而且由习题4.7可知, $\rho > 1$ 时, 方程 $A(s) = s$ 在 $(0, 1)$ 内存在唯一解. 我们首先指出

命题12.5 若 $\rho > 1$, X 非常返; 若 $\rho = 1$, X 零常返; 若 $\rho < 1$, X 正常返.

证明 当 $\rho > 1$ 时, 记 $A(s) = s$ 在 $(0, 1)$ 中的唯一解为 u , 那么对任意 $i \geq 0$, 令 $z_i = u^i$, 那么

$$\begin{aligned} z_i &= u^i = u^{i-1} A(u) = \sum_{k=0}^{\infty} p_k u^{k+i-1} \\ &= \sum_{k=i-1}^{\infty} p_{k-i+1} z_k = \sum_{k=i-1}^{\infty} p_{i,k} z_k = \sum_{k \neq 0} p_{i,k} z_k + p_{i,0}, \quad i \neq 0 \end{aligned}$$

由于 $\{f_{i,0}\}_{i \neq 0}$ 是方程组

$$z_i = \sum_{k \neq 0} p_{i,k} z_k + p_{i,0}, \quad i \neq 0$$

的最小非负解, 因此 $f_{i,0} < 1$. 这表明状态 0 非常返, 从而 X 非常返.

当 $\rho \leq 1$ 时, 对任意 $i \geq 1$, 令 $y_i = i$,

$$\begin{aligned} y_i &= i - 1 + 1 \geq i - 1 + \rho = i - 1 + \sum_{k=0}^{\infty} kp_k = \sum_{k=0}^{\infty} (k + i - 1)p_k \\ &= \sum_{k=i-1}^{\infty} p_{k+1-i} k = \sum_{k \in S} p_{i,k} y_k. \end{aligned}$$

由定理12.3 可知此时 X 是常返的.

当 $\rho < 1$ 时, 由

$$i - 1 + \rho = \sum_{k=0}^{\infty} p_{i,k} k, \quad i \geq 1$$

可得

$$\frac{i}{1-\rho} - 1 = \sum_{k=0}^{\infty} p_{i,k} \frac{k}{1-\rho}$$

且

$$\sum_{k=0}^{\infty} p_{0,k} \frac{k}{1-\rho} = \frac{\sum_{k=0}^{\infty} kp_k}{1-\rho} \leq \frac{1}{1-\rho} < \infty.$$

由定理12.4可知, 此时 X 正常返.

当 $\rho = 1$ 时, 若 X 正常返, 则记其不变测度为 $\pi = \{\pi_k\}_{k \geq 0}$. 对任意 $s \in [0, 1]$, 令

$$\pi(s) = \sum_{k \geq 0} \pi_k s^k.$$

那么由

$$\pi_i = \sum_{k \in S} \pi_k p_{k,i} = \pi_0 p_i + \sum_{k=1}^{i+1} \pi_k p_{i+1-k}$$

可知对任意 $0 < s < 1$,

$$\begin{aligned} \pi(s) &= \sum_{i \geq 0} \pi_i s^i = \pi_0 \sum_{i \geq 0} p_i s^i + \sum_{k=1}^{\infty} \sum_{m=0}^{\infty} \pi_k p_m s^{m+k-1} \\ &= \pi_0 A(s) + \frac{1}{s} (\pi(s) - \pi_0) A(s). \end{aligned}$$

由此可得

$$\pi(s) = \frac{\pi_0(s-1)A(s)}{s-A(s)} \quad (4.1.4)$$

以及

$$\frac{A(s)-1}{s-1} = 1 - \pi_0 \frac{A(s)}{\pi(s)}.$$

令 $s \rightarrow 1-$ 得

$$\rho = A'(1) = 1 - \pi_0 \quad (4.1.5)$$

因此 $\rho = 1$ 意味着 $\pi_0 = 0$ 从而状态 0 非正常返, 这与 X 正常返假设矛盾. \square

注意到 X 正常返条件下(4.1.4)是平稳分布的母函数, 结合(4.1.5)可知

$$\pi(s) = (1-\rho) \frac{(1-s)A(s)}{s-A(s)},$$

从而

$$\pi'(s) = (1-\rho) \left\{ \frac{(s-1)A'(s)}{s-A(s)} + \frac{A(s)[s-A(s)-(1-A'(s))(s-1)]}{(s-A(s))^2} \right\}$$

由推论12.2, 推论11.6, 当 $\rho < 1$ 时

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n \mathbb{P}(X_k = 0) = \pi_0 = 1 - \rho,$$

进一步若要求 $A''(1-) = \mathbb{E}(\xi_1^2) - \mathbb{E}(\xi_1) < \infty$, 由 $s \rightarrow 1$ 时 $s - A(s) \sim (1-\rho)(s-1)$ 可得

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n X_k = \sum_{k=0}^{\infty} k \pi_k = \pi'(1-) = \rho + \frac{A''(1-)}{2(1-\rho)}.$$

练习题

12.1 在例11.1中若令 $p_0 = p_1 = p_2 = p_3 = 0.25$, 其他条件不变, 求最佳策略 $(k, 3)$.

12.2 对 $M(\lambda)/G/1$ 嵌入链 X , 若服务台的服务时间 G 服从参数为 μ 的指数分布且 $\lambda < \mu$. 求长时间的平均队长和窗口无人的时间比例.

12.3* 设不可约正常返马氏链 X 的转移概率矩阵为 $(p_{i,j})_{i,j \in S}$, $\pi = \{\pi_i\}_{i \in S}$ 为平稳分布.

令 $Y_n = (X_n, X_{n+1})$. 证明 $Y = \{Y_n, n \geq 0\}$ 是状态空间为 $\mathcal{M} = \{(i, j), i, j \in S, p_{i,j} > 0\}$ 的不可约正常返马氏链, 平稳分布为 $\{\pi_i p_{i,j}\}_{(i,j) \in \mathcal{M}}$.

12.4* 设 X 是状态空间 $S = \{0, 1\}$ 的两状态时齐马氏链, 转移概率矩阵

$$\mathbb{P} = \begin{pmatrix} p & 1-p \\ 1-q & q \end{pmatrix},$$

其中 $0 < p, q < 1$. 若已知 X_0, \dots, X_n 的一组观察值 x_0, \dots, x_n , 其中依时间先后次序相邻的两个观察值为 00, 01, 10, 11 的分别有 $n_{00}, n_{01}, n_{10}, n_{11}$ 对.

(1) 证明 p, q 的极大似然估计分别是

$$\hat{p}_n = \frac{n_{00}}{n_{00} + n_{01}}, \quad \hat{q}_n = \frac{n_{11}}{n_{10} + n_{11}}.$$

(2) 证明 $\lim_{n \rightarrow \infty} \hat{p}_n = p, a.s.$

4.2 可逆马氏链与蒙特卡罗模拟

一个用Markov链描述的系统, 常常可以利用它的长时间后的稳定分布, 作为其参数的稳定设计的依据. 在前面我们已经看到, 在很宽的条件下, 不变分布就是这个稳定分布. 而求不变分布需要解一个方程, 一般来说需要很大的工作量. 所幸的是, 在实际中有很多问题满足一种对称性条件, 即所谓可逆性条件. 对于满足这种条件的Markov链, 有一种求不变分布的简便方法. 在本节中, 我们将给出这方面的理论和应用.

4.2.1 可逆马氏链

定义13.1 以 $\mathbf{P} = (p_{i,j})_{i,j \in S}$ 为转移矩阵的Markov链 X , 称为可逆的, 如果存在概率分布 $\mu = \{\mu_i : i \in S\}$ 使得对任意 $i, j \in S$,

$$\mu_i p_{i,j} = \mu_j p_{j,i}. \quad (4.2.1)$$

μ 称为 X 的可逆初分布, 简称可逆分布. 物理学中称(4.2.1)为细致平衡条件.

由此定义可,

$$\sum_i \mu_i p_{i,j} = \sum_i \mu_j p_{j,i} = \mu_j.$$

即 μ 是 X 的平稳分布. 这表明若 X 是可逆不可约链, 那么它的可逆分布唯一而且平稳分布可以利用方程(4.2.1)求出.

例13.1 考察状态 $S = \{0, 1, \dots, M\}$, 转移概率为

$$0 < p_{i,i+1} = \alpha_i = 1 - p_{i,i-1} < 1, \quad i = 1, \dots, M-1,$$

$$0 < p_{0,1} = \alpha_0 = 1 - p_{0,0} \leq 1, \quad 0 \leq p_{M,M} = \alpha_M = 1 - p_{M,M-1} < 1,$$

的马氏链 X , 求 X 的平稳分布.

解 容易看出 X 是不可约的. 对任意 $M > i \geq 0$,

$$\nu_i p_{i,i+1} = \nu_{i+1} p_{i+1,i},$$

即对任意 $M > i \geq 0$

$$\nu_i \alpha_i = \nu_{i+1} (1 - \alpha_{i+1}).$$

由此可得, 对任意 $M > i \geq 0$, $\nu_{i+1} = \prod_{k=1}^{i+1} \frac{\alpha_{k-1}}{1-\alpha_k} \nu_0$. 再令 $\sum_{i=0}^M \nu_i = 1$ 可得

$$\nu_0 = \frac{1}{1 + \sum_{i=1}^M \prod_{k=1}^i \frac{\alpha_{k-1}}{1-\alpha_k}}.$$

此时 $\nu = (\nu_0, \nu_1, \dots, \nu_M)$ 为 X 的可逆分布, 进而也是 X 的平稳分布. \square

命题13.1 记可逆不可约马氏链 X 的可逆分布为 $\mu = \{\mu_i : i \in S\}$. 那么对任意 $i \in S$, $\mu_i > 0$, 而且对任意 $j \in S$, $p_{i,j} = 0$ 当且仅当 $p_{j,i} = 0$.

证明 由(4.2.1)以及数学归纳法容易证明对任意 $n \geq 1$,

$$\begin{aligned}\mu_i p_{i,j}^{(n)} &= \mu_i \sum_{k \in S} p_{i,k} p_{k,j}^{(n-1)} = \sum_{k \in S} \mu_i p_{i,k} p_{k,j}^{(n-1)} \\ &= \sum_{k \in S} \mu_k p_{k,i} p_{k,j}^{(n-1)} = \sum_{k \in S} \mu_k p_{k,j}^{(n-1)} p_{k,i} \\ &= \sum_{k \in S} \mu_j p_{j,k}^{(n-1)} p_{k,i} = \mu_j p_{j,i}^{(n)}.\end{aligned}\quad (4.2.2)$$

由于 μ 为分布以及 X 不可约, 存在 $i_0 \in S$ 使得 $\mu_{i_0} > 0$ 以及对任意 $i_0 \neq i \in S$, 存在 $n \geq 0$ 使得 $p_{i_0,i}^{(n)} > 0$. 将其代入上式可知

$$\mu_i p_{i,i_0}^{(n)} > 0.$$

这表明 $\mu_i > 0$. 再由(4.2.1)可知对任意 $j \in S$, $p_{i,j} = 0$ 当且仅当 $p_{j,i} = 0$. \square

由定理10.8可知可逆不可约马氏链一定是正常返的; 反之不真.

一般地, 对于可逆不可约马氏链而言, 任取 $i_0 \in S$, 对任意 $j \in S$, 存在一条路径使得 $i_0 \rightarrow j$. 不妨设该路径为

$$i_0 \leftrightarrow i_1 \leftrightarrow \cdots \leftrightarrow i_n \leftrightarrow j,$$

这里 \leftrightarrow 表示“一步可达”, 那么

$$p_{i_0,i_1} p_{i_1,i_2} \cdots p_{i_n,j} > 0$$

此时由命题13.2可知

$$p_{j,i_n} \cdots p_{i_2,i_1} p_{i_1,i_0} > 0.$$

在利用(4.2.1)可得, 对可逆分布 $\mu = \{\mu_i, i \in S\}$,

$$\begin{aligned}\mu_{i_0} p_{i_0,i_1} p_{i_1,i_2} \cdots p_{i_n,j} &= \mu_{i_1} p_{i_1,i_2} \cdots p_{i_n,j} p_{i_1,i_0} \\ &= \mu_{i_2} p_{i_2,i_3} \cdots p_{i_n,j} p_{i_2,i_1} p_{i_1,i_0} \\ &= \cdots = \mu_j p_{j,i_n} \cdots p_{i_2,i_1} p_{i_1,i_0}.\end{aligned}$$

记

$$v(i_0, j) = \frac{p_{i_0,i_1} p_{i_1,i_2} \cdots p_{i_n,j}}{p_{j,i_n} \cdots p_{i_2,i_1} p_{i_1,i_0}} \in (0, \infty),$$

那么 $v(i_0, i_0) = 1$ 且对任意 $j \in S$, $\mu_j = \mu_{i_0} v(i_0, j)$. 由

$$1 = \sum_{j \in S} \mu_j = \sum_{j \in S} v(i_0, j) \mu_{i_0}$$

可知对任意 $j \in S$

$$\mu_j = \frac{v(i_0, j)}{\sum_{j \in S} v(i_0, j)}. \quad (4.2.3)$$

下面定理为我们判断不可约正常返链是否可逆提供了一个更直观的方法.

定理13.2 对于只要 $p_{i,j} = 0$ 就有 $p_{j,i} = 0$ 的不可约正常返马氏链 X , 它是可逆马氏链的充要条件是从它任意一状态出发回到该状态的路径与它的反向路径有相同的概率. 即对于一切状态 i, i_1, i_2, \dots, i_n 有

$$p_{i,i_1} p_{i_1, i_2} \cdots p_{i_n, i} = p_{i, i_n} p_{i_n, i_{n-1}} \cdots p_{i_1, i}. \quad (4.2.4)$$

证明 前面分析已给出了必要性, 下证充分性. 任取 $i, j \in S$ 使得 $i \neq j$ 且 $p_{i,j} > 0$. 对任意 $n \geq 1$, 由(4.2.4) 可知,

$$p_{i,i_1} p_{i_1, i_2} \cdots p_{i_{n-1}, j} p_{j,i} = p_{i,j} p_{j, i_{n-1}} \cdots p_{i_2, i_1} p_{i_1, i}.$$

关于所有 i_1, \dots, i_{n-1} 求和得

$$p_{i,j}^{(n)} p_{j,i} = p_{i,j} p_{j,i}^{(n)}.$$

进一步关于 n 求和并求平均得

$$\lim_{k \rightarrow \infty} \frac{1}{k} \sum_{n=1}^k p_{i,j}^{(n)} p_{j,i} = p_{i,j} \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{n=1}^k p_{j,i}^{(n)}.$$

由于 X 不可约且正常返, 由推论11.6以及定理11.8可知

$$\pi_j p_{j,i} = \pi_i p_{i,j},$$

其中 $\pi = \{\pi_i, i \in S\}$ 是 X 的平稳分布. 因此 X 可逆. \square

定理13.3 任取一个离散分布 π , 记其所有取值概率为正的点构成的集合为 S , 即 $\pi = \{\pi_i, i \in S\}$, 其中 $\pi_i > 0$ 且 $\sum_{i \in S} \pi_i = 1$. 一定存在 S 上的可逆不可约马氏链 X , 使得 π 是 X 的平稳分布.

证明 任取一个 S 上不可约的马氏链 Y 使其转移概率矩阵为 $\mathbf{Q} = (q_{i,j})_{i,j \in S}$ 满足

$$q_{i,j} = 0 \Leftrightarrow q_{j,i} = 0.$$

对任意 $i \neq j \in S$, 令

$$\alpha_{i,j} = \min\left\{\frac{\pi_j q_{j,i}}{\pi_i q_{i,j}}, 1\right\}, \quad p_{i,j} = q_{i,j} \alpha_{i,j},$$

以及

$$p_{i,i} = q_{i,i} + \sum_{j \neq i} q_{i,j} (1 - \alpha_{i,j}).$$

容易检验 $\mathbf{P} = (p_{i,j})_{i,j \in S}$ 是个随机矩阵而且由构造可知对任意 $i \neq j$,

$$p_{i,j} > 0 \Leftrightarrow q_{i,j} > 0.$$

因此由 Y 的不可约性可知, 以 \mathbf{P} 为转移概率矩阵的马氏链 X 也是不可约的. 进一步, 对任

意 $i \neq j$, 由

$$\pi_i p_{i,j} = \pi_i q_{i,j} \alpha_{i,j}$$

可知, 若 $\alpha_{i,j} < 1$, 则 $\alpha_{j,i} = 1$ 且

$$\pi_i p_{i,j} = \pi_j q_{j,i} = \pi_j q_{j,i} \alpha_{j,i} = \pi_j p_{j,i},$$

而 $\alpha_{i,j} = 1$ 时, 若 $\pi_i q_{i,j} = \pi_j q_{j,i}$ 则 $\alpha_{j,i} = 1$, 且

$$\pi_i p_{i,j} = \pi_i q_{i,j} = \pi_j q_{j,i} = \pi_j q_{j,i};$$

若 $\pi_i q_{i,j} > \pi_j q_{j,i}$ 则 $\alpha_{j,i} < 1$, 且

$$\pi_i p_{i,j} = \pi_i q_{i,j} = \pi_j q_{j,i} \alpha(j, i) = \pi_j q_{j,i}.$$

总之, 此时 π 为 X 的可逆分布, 从而为 X 的平稳分布. \square

注13.1 若对不可约马氏链 Y 还要求存在某个 i 使得 $p_{i,i} > 0$, 那么 X 还是非周期的, 从而由定理11.9可知 π 还是 X 的极限分布, 即 X_n 的分布收敛到 π .

注13.2 称定理13.3证明中构造转移矩阵 \mathbf{P} 进而得到可逆马氏链的方法为Hastings-Metropolis 算法, 称转移矩阵 $\mathbf{Q} = (q_{i,j})_{i,j \in S}$ 为预选矩阵.

4.2.2 马氏链蒙特卡罗(MCMC)方法*

在复杂的统计问题中,许多统计量很难直接进行理论分析或计算, 需要借助随机模拟完成. 比如, 当我们直接计算诸如 $E(h(X))$ 这样的算式有困难时, 一种自然的方法是借助大数定律, 通过生成一列与 X 同分布的随机数 x_1, x_2, \dots, x_n , 然后用 $\sum_{i=1}^n h(x_i)/n$ 近似. 但当生成 X 的随机数有困难时, 这种方案实现起来就有一定难度. 马氏链蒙特卡罗(MCMC)方法是能解决这类问题的一种随机模拟方法. 该方法的主要思想是将特定分布设计成某个马氏链的平稳分布, 基于马氏链的极限定理(定理11.9)和遍历性定理(定理12.1和推论12.2), 通过模拟马氏链的轨道(实现), 近似生成特定分布的随机数或估计所需要的各种统计量. 下面我们结合两种典型采样方法简单介绍MCMC方法.

(A) Metropolis采样

Metropolis采样就是基于Hastings-Metropolis算法生成一个可逆马氏链样本轨道的抽样方法. 由定理13.3, 要模拟这样的马氏链, 关键是模拟转移机制 $(p_{i,j})$, 也即在给定 $X_n = i$ 的条件下, 模拟分布列 $\{p_{i,j}, j = 1, 2, \dots\}$. 注意到 $j \neq i$ 时 $p_{i,j} = q_{i,j} \alpha_{i,j}$. 设 Y 服从分布

列 $(q_{i,1}, q_{i,2}, \dots)$, $Z \sim U[0, 1]$ 且与 Y 独立. 令

$$W = \begin{cases} Y, & Z \leq \alpha_{i,Y}; \\ i, & \text{其它}, \end{cases}$$

那么 $j \neq i$ 时

$$\mathbb{P}(W = j) = \mathbb{P}(Y = j)\mathbb{P}(Z \leq \alpha_{i,j}) = q_{i,j}\alpha_{i,j} = p_{i,j},$$

而 $\mathbb{P}(W = i) = 1 - \sum_{j \neq i} p_{i,j} = p_{i,i}$. 即 W 是服从分布列 $(p_{i,1}, p_{i,2}, \dots)$ 的随机变量. 因此可用如下算法实现模拟转移机制 $(p_{i,j})$.

- (s1) 设当前时刻 $X_n = i$.
- (s2) 产生一个分布列为 $(q_{i,1}, q_{i,2}, \dots)$ 的随机数, 假设为 j ;
- (s3) 计算 $\alpha_{i,j}$;
- (s4) 独立地取一个服从 $[0, 1]$ 上均匀分布的随机数 u , 如果 $u \leq \alpha_{i,j}$, 则将状态更新为 $X_{n+1} = j$ 并回到(s1), 否则状态不更新, 即令 $X_{n+1} = i$, 并回到(s1).

考虑到 $\alpha_{i,j} = \frac{\pi_j q_{j,i}}{\pi_i q_{i,j}} \wedge 1$, 我们可以将上述算法中(s3),(s4)两步优化为

- (s3) 若 $\frac{\pi_j q_{j,i}}{\pi_i q_{i,j}} \geq 1$, 则将状态更新为 $X_{n+1} = j$ 并回到(s1); 否则进行(s4);
- (s4) 独立地取一个服从 $[0, 1]$ 上均匀分布的随机数 u , 如果 $u \leq \frac{\pi_j q_{j,i}}{\pi_i q_{i,j}}$, 则将状态更新为 $X_{n+1} = j$ 并回到(s1), 否则状态不更新, 即令 $X_{n+1} = i$, 并回到(s1).

例13.2 将所有 n 级排列所组成的集合 \mathfrak{F} 看作一个样本空间, 在 \mathfrak{F} 上可以定义一种离散分布 π 使得对任意 $v \in \mathfrak{F}$, $\pi_v = cT(v)$, 其中 $T(v)$ 表示排列 v 中数 n 的位置, $c = (n+1)!/2$ 为所有 $T(v)$ 的和. 比如 $n=3$ 时, 将3级排列依次记作

$$v_1 = 123; v_2 = 213; v_3 = 231; v_4 = 132; v_5 = 312; v_6 = 321.$$

此时 $\mathfrak{F} = \{v_1, v_2, v_3, v_4, v_5, v_6\}$, 而且

$$T(v_1) = 3; T(v_2) = 3; T(v_3) = 2; T(v_4) = 2; T(v_5) = 1; T(v_6) = 1.$$

直接计算可知 $c = 12$, 离散分布 π 为

$$\pi_1 = T(v_1)/12 = 1/4; \pi_2 = T(v_2)/12 = 1/4; \pi_3 = T(v_3)/12 = 1/6;$$

$$\pi_4 = T(v_4)/12 = 1/6; \pi_5 = T(v_5)/12 = 1/12; \pi_6 = T(v_6)/12 = 1/12.$$

试用Metropolis采样法生成 $n = 50$ 时分布 π 的一个样本.

算法设计: 为了利用Metropolis采样法, 我们需要设计一个预选矩阵, 为此对任意一个50级排列 $v \in \mathfrak{F}$, 令

$$N(v) = \{u \in S, u \text{可由 } v \text{最多经过一次相邻对换得到}\}.$$

对任意 v, u , 令

$$q_{v,u} = \begin{cases} 0, & u \notin N(v) \\ 1/|N(v)| = 1/50, & u \in N(v), \end{cases}$$

其中 $|N(v)|$ 表示集合 $N(v)$ 中的元素个数. 由于任意两个不同的 50 级排列总可通过相邻对换相互转换, 因此可以验证以 $(q_{v,u})$ 为转移概率矩阵的马氏链是不可约的, 而且

$$q(v, u) = 0 \Leftrightarrow q(u, v) = 0.$$

由于要得到的分布 π 满足对任意 $v \in \mathfrak{F}$, $\pi_v = cT(v)$, 其中 c 为常数. 因此

$$\alpha(v, u) = \min\left(\frac{\pi_u q_{u,v}}{\pi_v q_{v,u}}, 1\right) = \min\left(\frac{T(u)}{T(v)}, 1\right).$$

注意到 $q_{v,v} > 0$, 由 Hastings-Metropolis 算法得到的马氏链 X 是不可约非周期可逆马氏链, π 是 X 的极限分布.

下面我们用 Metropolis 采样法模拟马氏链 X 在一个样本轨道下的序列 $\{X_k\}$, 当 k 足够大时, X_k 的值就是 π 的一个近似取样. 基本模拟流程如下

- (s1) 给 X_0 任意赋予一个 50 级排列.
- (s2) 设当前时刻 $X_k = v$, v 表示一个 n 级排列.
- (s3) 产生一个在 0 到 49 整数点上均匀分布的随机数, 假设为 j , 令 u 表示对换 v 中第 j 和 $j+1$ 位置上的数所得到的排列, 当 $j=0$ 时 $u=v$;
- (s4) 若 $\frac{T(u)}{T(v)} \geq 1$, 则将状态更新为 $X_{k+1} = u$ 并回到(s2); 否则进行(s5);
- (s5) 独立地取一个 $U[0, 1]$ 的随机数 U , 如果 $U \leq \frac{T(u)}{T(v)}$, 则将状态更新为 $X_{k+1} = u$ 并回到(s2), 否则状态不更新, 即令 $X_{k+1} = v$, 并回到(s2).

基于这些流程, 可以编写计算机程序实现对分布 π 的采样, 请读者自己完成.

(B) Gibbs 采样

Gibbs 采样是 MCMC 模拟中使用的最为广泛的一种马氏链轨道采样方法. 它本质上仍是一种特殊的 Hastings-Metropolis 算法. 我们简述如下:

设 $X = (X_1, X_2, \dots, X_n)$ 是离散随机向量. 记其所有可能的取值集合为 S . 假设

- (h1) X 的分布满足: 对任意 $x = (x_1, x_2, \dots, x_n) \in S$,

$$\mathbb{P}(X = x) = cg(x),$$

其中 c 为常数.

- (h2) 对任意 $1 \leq i \leq n$ 以及任意 x_j , 其中 $1 \leq j \leq n$ 且 $j \neq i$, 条件分布

$$\mathbb{P}(X_i = \cdot | X_j = x_j, j \neq i)$$

存在且已知.

注13.4 由概率分布的归一性可知 $c = [\sum_{x \in S} g(x)]^{-1}$, 但在很多时候 $g(x)$ 的求和计算不容易实现, 此时我们可以认为 c 是未知的.

注13.5 上述条件(h2)表明在已知了 X 的任意 $n - 1$ 个分量取值后, 我们就可以一定的分布确定 X 的取值.

在以上条件假设下, Gibbs采样法模拟生成的向量值马氏链 $Y = \{Y_n, n \geq 0\}$ 按如下的转移方式生成样本:

- (s1) 假设目前的状态是 $Y_k = x = (x_1, x_2, \dots, x_n)$;
- (s2) 随机地在1到 n 中选取一个下标, 比如是 i ;
- (s3) 固定所有 $x_j, j \neq i$, 的值, 按条件分布 $\mathbb{P}(X_i = \cdot | X_j = x_j, j \neq i)$ 生成 x_i 的随机数, 比如 $x_i = y$;
- (s4) 将 Y_{k+1} 的值取成 $y = (x_1, \dots, x_{i-1}, y, x_{i+1}, \dots, x_n)$ 并回到(s1).

记如上方式生成的马氏链 Y 的一步转移概率为 $q(x, y)$, 那么

- (q1) 当 x, y 至少有两个分量不同时 $q(x, y) = 0$;
- (q2) 当 x, y 只有一个分量不同时, 假设不同的分量下标为 i ,

$$q(x, y) = \frac{1}{n} \mathbb{P}(X_i = y_i | X_j = x_j, j \neq i) = \frac{cg(y)}{n \mathbb{P}(X_j = x_j, j \neq i)};$$

- (q3) 当 $x = y$ 时

$$q(x, x) = 1 - \sum_{y \neq x} q(x, y).$$

容易检验此时 Y 是一个不可约马氏链, $q(x, y) = 0 \Leftrightarrow q(y, x) = 0$ 而且 $q(x, x) > 0$. 进一步, 此时 Hastings-Metropolis 算法中的函数

$$\alpha(x, y) = \min \left(\frac{cg(y)q(y, x)}{cg(x)q(x, y)}, 1 \right) = \min \left(\frac{cg(y)cg(x)}{cg(x)cg(y)}, 1 \right) = 1,$$

这表明 Gibbs 抽样法得到的马氏链 Y 也是按 Hastings-Metropolis 算法构造的非周期不可约可逆马氏链并以 X 的分布为平稳分布, 因此当模拟的马氏链 Y 运行足够多的步骤后, 即 k 足够大后, Y_k 的值就可以看作 X 分布的一个取样点.

例13.3 已知离散随机向量 $X = (X_1, \dots, X_{50})$ 的每一个分量的可能取值都是 1 和 -1. 对 X 的每一个可能取值 $x = (x_1, x_2, \dots, x_{50})$,

$$\mathbb{P}(X = x) = ce^{-\frac{1}{2} \sum_{i=1}^{49} x_i x_{i+1}}.$$

试用 Gibbs 抽样法给出 X 分布的一个近似取样.

算法设计: 基本流程如下:

- (s1) 给 X_0 任意赋予一个初值 $(x_1^{(0)}, x_2^{(0)}, \dots, x_{50}^{(0)})$;
- (s2) 假设目前的状态是 $Y_k = \mathbf{x} = (x_1, x_2, \dots, x_{50})$;
- (s3) 随机地在1到50中选取一个下标, 比如是*i*;
- (s4) 固定所有 $x_j, j \neq i$, 的值, 按条件分布 $\mathbb{P}(X_i = \cdot | X_j = x_j, j \neq i)$ 生成 x_i 的随机数, 比如 $x_i = y$;
- (s5) 将 Y_{k+1} 的值取成 $\mathbf{y} = (x_1, \dots, x_{i-1}, y, x_{i+1}, \dots, x_{50})$ 并回到(s2).

具体的程序编写, 请读者自己完成.

最后我们指出的是MCMC方法不仅可以用来近似模拟离散分布的随机数, 还可以用来模拟连续分布的随机数; 不仅可以模拟随机数还可以结合Bayes方法估计参数以及求复杂样本空间上函数的极值. 对这些内容感兴趣的读者请参阅有关参考文献, 本书不再详述.

练习题

- 13.1 证明当 $q > p$ 时带反射的简单随机游动是可逆的, 并由此求 $m_{0,0}$.
- 13.2 总共 m 个白球和 m 个黑球分别放在A,B两个坛子中, 每个坛子有 m 个球, 每次从这两个坛子中各随机地取一个球并把它们交换后放回. 以 X_n 表示经过 n 次后A坛中黑球个数. 求 X_n 的平稳分布.
- 13.3* 试通过编程将例13.2($n = 50$)和例13.3在计算机上实现.

4.3 分枝过程

这一节我们介绍一类特殊的马氏模型——分枝过程. 这类过程源于家族姓氏消亡的统计调查, 现在生物, 经济, 金融以及社会学研究等领域有着广泛应用.

4.3.1 Galton-Watson分枝过程

一类理想的分枝过程定义如下:

定义14.1 设 $\{Y_{n,k}, n \geq 1, k \geq 1\}$ 为一族独立同分布的非负整数值的随机变量, 递归定义随机过程 $\{X_n, n \geq 0\}$ 如下

$$X_{n+1} = \sum_{k=1}^{X_n} Y_{n+1,k}, \quad n \geq 0,$$

其中 X_0 是给定的非负整数值随机变量且与 $\{Y_{n,k}, n \geq 1, k \geq 1\}$ 独立. 称随机过程 $\{X_n, n \geq 0\}$ 为G-W(Galton-Watson)分枝过程.

若以 X_n 表示第 n 代的个体数, $Y_{n+1,k}$ 则表示第 n 代中第 k 个个体的后代数. 直观看, G-W分枝过程理想地假设了家族中每个个体产生后代的行为是一样的且彼此无关. 容易证明此时 $X = \{X_n; n \geq 0\}$ 是一个时齐马氏链, 转移概率

$$p_{i,j} = \mathbb{P}(Y_{1,1} + \cdots + Y_{1,i} = j).$$

由定义可知 $p_{0,0} = 1$, 即状态0为吸收态. 记 $p_k = \mathbb{P}(Y = k)$. 为避免平凡, 以下总设 $p_1 < 1$. 若 $p_0 > 0$, 则对任意 i , $p_{i,0} = p_0^i > 0$, 这表明 $i \rightarrow 0$. 假定 $X_0 = 1$,

$$\tau_0 = \inf\{n \geq 1, X_n = 0\}$$

那么所求概率

$$q = \mathbb{P}_1(\tau_0 < \infty) = f_{10} = \lim_{n \rightarrow \infty} p_{1,0}^{(n)}.$$

注意到若初始时刻有 k 个个体, 要使姓氏消亡, 意味着每个个体及其后代的姓氏都得消亡, 又由于每个个体及其后代的表现是相互独立的, 因此

$$f_{k,0} = \mathbb{P}_k(\tau_0 < \infty) = f_{10}^k = q^k, \quad p_{k,0}^{(n)} = \mathbb{P}_k(X_n = 0) = (p_{1,0}^{(n)})^k.$$

命题14.1 若每个个体产生后代的平均值不超过1, 即 $m = \mathbb{E}(Y) \leq 1$, 那么 X_n 必然消亡, 即 $q = 1$.

证明 由定理10.1可知

$$q = f_{1,0} = \sum_{k=1}^{\infty} p_{1,k} f_{k,0} + p_{1,0} = \sum_{k=1}^{\infty} p_k q^k + p_0.$$

令 $A(s) = \sum_{k=0}^{\infty} p_k s^k$. 那么 q 满足方程 $q = A(q)$. 由于 $0 \leq q \leq 1$, 而由习题4.7可知该方程在 $[0, 1]$ 内无解. 直接验算可知 $q = 1$. \square

命题14.2 若每个个体产生后代的平均值超过1, 即 $m = \mathbb{E}(Y) > 1$, 那么 X_n 以正概率不消亡, 即 $q < 1$.

证明 由命题12.6可知 q 是 $A(s) = s$ 在区间 $[0, 1]$ 上一个解. 注意到0是吸收状态, 对任意 $n \geq 2$

$$p_{1,0}^{(n)} = \sum_{k=1}^{\infty} p_{1,k} p_{k,0}^{(n-1)} + p_{1,0} = \sum_{k=1}^{\infty} p_k (p_{1,0}^{(n-1)})^k + p_0 = A(p_{1,0}^{(n-1)}),$$

其中 $p_{1,0}^{(1)} = p_0$. 对方程 $s = A(s)$ 的任意非负解 u 以及任意 n , 都满足

$$\begin{aligned} u &= A^n(u) = A^{n-1}(A(u)) \\ &\geq A^{n-1}(A(p_0)) = A^{n-1}(p_{1,0}^2) \\ &\geq \cdots \geq A(p_{1,0}^{(n)}) = p_{1,0}^{(n+1)}. \end{aligned}$$

令 $n \rightarrow \infty$, 得 $q = f_{1,0} \leq u$. 这表明 q 是 $s = A(s)$ 的最小非负解. 由习题4.7可知当 $m > 1$ 时, $A(s) = s$ 在 $[0, 1]$ 内有唯一非负解, 从而 $0 < q < 1$. \square

4.3.2 带移民的Galton-Watson分枝过程

对G-W模型而言, 0是吸收态而所有非零状态都是非常返的(参见习题14.1), 因此若 X 不灭绝则意味着 X_n 要趋向正无穷, 直观而言就是人口会爆炸. 这种两极化现象显然与人们的直观感知不一致. 一种对G-W模型简单的修正是引进所谓的“移民”, 得到如下的带移民G-W过程.

定义14.2 设 $\{Y_{n,k}, n \geq 1, k \geq 1\}$ 为一族独立同分布的非负整数值随机变量, $\{I_n, n \geq 1\}$ 也是一族独立同分布的非负整数值随机变量且与 $\{Y_{n,k}, n \geq 1, k \geq 1\}$ 独立, 称随机过程 $\{X_n, n \geq 0\}$ 为带移民的G-W过程, 如果

$$X_{n+1} = \sum_{k=1}^{X_n} Y_{n+1,k} + I_{n+1}, \quad n \geq 0,$$

其中 X_0 是给定的非负整数值随机变量且与 $\{Y_{n,k}, n \geq 1, k \geq 1\}$ 与 $\{I_n, n \geq 1\}$ 独立.

直观看, 在带移民的G-W过程模型中 I_n 表示第 n 代移入的人口数而且移入数量与 n 之前的人口数无关, 与第 n 代新生的人口也无关. 由独立性假设, 容易验证此时 $X = \{X_n, n \geq 0\}$ 仍为时齐马氏链. 记 $p_k = \mathbb{P}(Y = k)$, $q_k = \mathbb{P}(I_1 = k)$. 为简单, 我们约定 $1 > p_0, q_0 > 0$. 对任意 $i \geq 0$, 由

$$p_{i,0} = \mathbb{P}(Y_{11} + \cdots + Y_{1i} + I_1 = 0) = p_0^i q_0 > 0, \quad p_{0,i} = \mathbb{P}(I_1 = i) = q_i$$

可知 X 是不可约非周期的.(见习题14.2)

记 $m = \mathbb{E}(Y)$, $\sigma^2 = \text{Var}(Y)$, $\lambda = \mathbb{E}(I_1)$, $\beta^2 = \text{Var}(I_1)$. 由习题14.3可知

命题14.3 对带移民的G-W分枝过程 X , 如下的条件矩公式成立.

- (1) $\mathbb{E}(X_n | X_{n-1}) = mX_{n-1} + \lambda$;
- (2) $\mathbb{E}(X_n^2 | X_{n-1}) = (mX_{n-1} + \lambda)^2 + \sigma^2 X_{n-1} + \beta^2$.

命题14.4 若 $m < 1$, $0 < \lambda < \infty$, 那么 X 正常返.

证明 若 X 不是正常返的, 那么由注11.1可知, 对任意 $i \geq 0$, $p_{1,i}^{(n)} \rightarrow 0$. 这意味着对正常数 $M = \frac{2\lambda}{1-m} + 2$, 存在充分大的 n , 使得对任意 $0 \leq k < M$, $p_{1,k}^{(n)} < \frac{1}{2M}$. 因此

$$\mathbb{P}_1(X_n \geq M) = 1 - \sum_{k=0}^{M-1} p_{1,k}^{(n)} > 1/2,$$

从而 $\mathbb{E}_1(X_n) > 1 + \frac{\lambda}{1-m}$. 但另一方面, 由命题14.3中(1)可知

$$\begin{aligned} \mathbb{E}_1(X_n) &= \mathbb{E}_1(\mathbb{E}(X_n | X_{n-1})) = m\mathbb{E}_1(X_{n-1}) + \lambda \\ &= \dots = \lambda(1 + \dots + m^{n-2}) + m^{n-1} \leq \frac{\lambda}{1-m} + 1. \end{aligned}$$

矛盾表明 X 一定正常返. \square

4.3.3 分枝过程参数估计*

在人口稳定条件下, 人们自然关心模型里一些重要参数的估计. 比如衡量后代平均个数的参数 m 和每代平均移入个数的参数 λ .

下面我们在 σ^2 和 β^2 有限条件下考虑 m, λ 的参数估计.

总设 $m < 1$, $0 < \lambda < \infty$. 记此时的平稳分布为 $\pi = \{\pi_i\}_{i \geq 0}$. 注意 X_{n-1} 已知条件下, X_n 的最佳估计是条件期望

$$\mathbb{E}(X_n | X_{n-1}) = mX_{n-1} + \lambda.$$

在给定样本 X_0, \dots, X_n 条件下, 通过使得表示误差的函数

$$Q(m, \lambda) = \sum_{k=1}^n (X_k - mX_{k-1} - \lambda)^2$$

达到最小值, 我们可以得到参数 m, λ 的某种表示, 称其为 (m, λ) 的最小二乘估计. 直接计算可知 m, λ 的最小二乘估计量为

$$\hat{m}_n = \frac{n \sum_{k=1}^n X_{k-1} X_k - \sum_{k=1}^n X_{k-1} \sum_{k=1}^n X_k}{n \sum_{k=1}^n X_{k-1}^2 - (\sum_{k=1}^n X_{k-1})^2},$$

以及

$$\hat{\lambda}_n = \frac{1}{n} \left(\sum_{k=1}^n X_k - \hat{m}_n \sum_{k=1}^n X_{k-1} \right).$$

由推论12.2以及习题12.3可知

$$\begin{aligned}\hat{m}_n &= \frac{\frac{\sum_{k=1}^n X_{k-1} X_k}{n} - \frac{\sum_{k=1}^n X_{k-1}}{n} \frac{\sum_{k=1}^n X_k}{n}}{\frac{\sum_{k=1}^n X_{k-1}^2}{n} - (\frac{\sum_{k=1}^n X_{k-1}}{n})^2} \\ &\rightarrow \frac{\sum_{i=0}^{\infty} i\pi_i \sum_{j=0}^{\infty} j p_{i,j} - (\sum_{i=0}^{\infty} i\pi_i)^2}{\sum_{i=0}^{\infty} i^2\pi_i - (\sum_{i=0}^{\infty} i\pi_i)^2} \\ &= \frac{\sum_{i=0}^{\infty} i(m_i + \lambda)\pi_i - (\sum_{i=0}^{\infty} i\pi_i)^2}{\sum_{i=0}^{\infty} i^2\pi_i - (\sum_{i=0}^{\infty} i\pi_i)^2}, \quad a.s.\end{aligned}\quad (4.3.1)$$

下面我们计算 $\sum_{i=0}^{\infty} i\pi_i$ 以及 $\sum_{i=0}^{\infty} i^2\pi_i$. 为此我们假设 X 的初始分布为 π , 那么 X_0, X_1 的分布都是 π , 从而由命题14.3(1),

$$\sum_{i=0}^{\infty} i\pi_i = \mathbb{E}_{\pi}(X_0) = \mathbb{E}_{\pi}(X_1) = \mathbb{E}_{\pi}(\mathbb{E}_{\pi}(X_1|X_0)) = \mathbb{E}_{\pi}(mX_0 + \lambda)$$

因此

$$\sum_{i=0}^{\infty} i\pi_i = \frac{\lambda}{1-m}.$$

同样由命题14.3(2),

$$\begin{aligned}\sum_{i=0}^{\infty} i^2\pi_i &= \mathbb{E}_{\pi}(X_0^2) = \mathbb{E}_{\pi}(X_1^2) = \mathbb{E}_{\pi}(\mathbb{E}_{\pi}(X_1^2|X_0)) \\ &= m^2\mathbb{E}_{\pi}(X_0^2) + (2\lambda m + \sigma^2)\mathbb{E}_{\pi}(X_0) + \lambda^2 + \beta^2\end{aligned}$$

可得

$$\sum_{i=0}^{\infty} i^2\pi_i = (\frac{\sigma^2\lambda}{1-m} + \beta^2)\frac{1}{1-m^2} + \frac{\lambda^2}{(1-m)^2}.$$

因此

$$\begin{aligned}\sum_{i=0}^{\infty} i^2\pi_i - (\sum_{i=0}^{\infty} i\pi_i)^2 &= (\frac{\sigma^2\lambda}{1-m} + \beta^2)\frac{1}{1-m^2}, \\ \sum_{i=0}^{\infty} i(m_i + \lambda)\pi_i - (\sum_{i=0}^{\infty} i\pi_i)^2 &= (\frac{\sigma^2\lambda}{1-m} + \beta^2)\frac{m}{1-m^2}.\end{aligned}$$

将以上结果代入(4.3.1)得

$$\hat{m}_n \rightarrow m, \quad a.s.$$

进而由定理12.1得

$$\hat{\lambda}_n \rightarrow \frac{\lambda}{1-m} - m\frac{\lambda}{1-m} = \lambda, \quad a.s.$$

即 $\hat{m}_n, \hat{\lambda}_n$ 分别是 m 和 λ 在几乎必然收敛意义下的相合估计.

练习题

14.1 不论 p_0 是否为零, 证明 Galton-Watson 模型所有非零状态都是非常返的.

14.2 证明 $1 > p_0, q_0 > 0$ 时带移民分枝过程是非周期不可约的.

14.3 证明命题14.3.

4.4 隐马尔科夫链

本节我们简要介绍离散时间离散状态的隐马尔科夫模型.

4.4.1 隐马尔科夫链及其性质

定义15.1 设 $X_n, Y_n, n \geq 0$, 是分别取值于集合 S 和 W 上的离散随机变量. 称 $Z = \{Z_n = (X_n, Y_n), n \geq 0\}$ 为隐马尔科夫链, 若存在随机矩阵 $\mathbf{P} = (p_{i,j})_{i,j \in S}$ 和 $\mathbf{Q} = (q_{k,l})_{k \in S, l \in W}$ 使得对任意 $n \geq 0$

$$\mathbb{P}(Z_{n+1} = (i_{n+1}, j_{n+1}) | Z_k = (i_k, j_k), 0 \leq k \leq n) = p_{i_n, i_{n+1}} q_{i_{n+1}, j_{n+1}}, \quad (4.4.1)$$

对任意 $i_0, i_1, \dots, i_{n+1} \in S, j_0, j_1, \dots, j_{n+1} \in W$ 都成立.

利用全概率公式, 由定义可得

$$\begin{aligned} & \mathbb{P}(Z_{n+1} = (i_{n+1}, j_{n+1}) | Z_k = (i_k, j_k), 0 \leq k \leq n) \\ &= \mathbb{P}(Z_{n+1} = (i_{n+1}, j_{n+1}) | Z_n = (i_n, j_n)) \\ &= \mathbb{P}(Z_{n+1} = (i_{n+1}, j_{n+1}) | X_n = i_n). \end{aligned} \quad (4.4.2)$$

因此隐马氏链是一种具有特定转移概率机制的向量值时齐马氏链, 其转移概率

$$p_{(i_n, j_n), (i_{n+1}, j_{n+1})} = p_{i_n, i_{n+1}} q_{i_{n+1}, j_{n+1}},$$

并且在已知 X 在 n 时刻的值时, Z 的“历史”与“未来”独立.

另外, 仍由全概率公式可得

$$\mathbb{P}(X_{n+1} = i_{n+1} | X_k = i_k, 0 \leq k \leq n) = \mathbb{P}(X_{n+1} = i_{n+1} | X_n = i_n) = p_{i_n, i_{n+1}}.$$

因此 $X = \{X_n, n \geq 0\}$ 是一个以 $\mathbf{P} = (p_{i,j})$ 为转移概率矩阵的时齐马氏链. 而对任意时刻 n , 过程 $Y = \{Y_n, n \geq 0\}$ 满足

$$\begin{aligned} & \mathbb{P}(Y_n = j_n | X_n = i_n, X_k = i_k, Y_k = j_k, 0 \leq k \leq n-1) \\ &= \mathbb{P}(Y_n = j_n | X_n = i_n, X_k = i_k, 0 \leq k \leq n-1) \\ &= \mathbb{P}(Y_n = j_n | X_n = i_n, Y_k = j_k, 0 \leq k \leq n-1) \\ &= \mathbb{P}(Y_n = j_n | X_n = i_n) = q_{i_n, j_n}. \end{aligned}$$

因此, Y 本身可以不是马氏的, 它在任何时刻是一个依赖于同期 X 取值的一个随机变量, 并且分布列由矩阵 $\mathbf{Q} = (q_{k,l})$ 的行向量给出.

在实际应用时, 模型 Z 中往往只有过程 Y 才是可观测、可记录的, 而马氏链 X 是隐含的、不可观测的. 这就是我们称 Z 为隐马尔科夫链的主要原因.

例15.1 以 $Y = \{Y_n, n \geq 0\}$ 记录某只股票每日的涨跌幅度. Y 是可观测的. 容易设想的是, 股票的涨跌与股票的“牛”, “熊”密切相关, 即与股票是否在上升(1)、下跌(-1)或者横盘(0)等状态有关. 以 $X = \{X_n\}$ 表示股票每日所处的状态, 显然 X 是不可直接观测的. 一个简单的股票价格波动模型将(1)每日股票的涨跌看作是当日股票状态的随机表现, 即给定当日股票状态 i 之后, 股票涨跌服从某种具有参数 i 的随机分布, 记该分布列为 $(q_{i,l})$; (2) 每日股票的状态过程 X 看作是一个(时齐)马氏链, 转移概率矩阵为 $(p_{i,j})$. 由此构建的模型 $Z_n = (X_n, Y_n)$ 就是一个刻画股票价格波动率的隐马氏链模型.

例15.2 评估一台机器的生产状态. 将机器状态 X_n 分为好(状态1)和差(状态2) 两种, 要求依据机器生产产品的质量情况 Y_n 实时评判机器的生产状态. 假定产品的质量分布只依赖于机器当前生产状态, 而机器状态的转变构成一个马氏链, 那么 $Z_n = (X_n, Y_n)$ 就构成了一个隐马尔科夫链.

例15.3 设 X_n 是取值于状态空间 $S = \{1, 2, \dots, L\}$ 的 Markov 链, 其样本不能被实际测量得到, 而能测量到的是如下的 Y_n 的样本,

$$Y_n = g(X_n) + w_n,$$

其中 g 是一个未知函数, $\{w_n\}$ 是独立同分布的随机干扰, 只取有限个值, 且与随机过程 $\{X_n\}$ 独立. 那么 (X_n, Y_n) 就是一个隐 Markov 模型.

以下总设 $Z_n = (X_n, Y_n)$ 是一个隐马尔科夫链, 若已知 X_0 的初始分布 $\pi = (\pi_i, i \in S)$, 那么由马氏链的有限维分布表示可知, 对任意 $n \geq 0$ 以及 $i_0, i_1, \dots, i_n \in S, j_0, j_1, \dots, j_n \in W$,

$$\mathbb{P}(Z_k = (i_k, j_k), 0 \leq k \leq n) = \pi_{i_0} q_{i_0, j_0} \prod_{k=1}^n p_{i_{k-1}, i_k} q_{i_k, j_k}. \quad (4.4.3)$$

这表明初始分布 π 以及随机矩阵 \mathbf{P}, \mathbf{Q} 完全确定了 Z 的统计特征. 通常称 $(\pi, \mathbf{P}, \mathbf{Q})$ 为隐马尔科夫链 Z 的参数组.

给定 $j_0, j_1, \dots, j_n \in W$. 对任意 $0 \leq m \leq n$, 令

$$F_m(i) = \mathbb{P}(X_m = i, Y_k = j_k, 0 \leq k \leq m), \quad i \in S.$$

那么由(4.4.2)和全概率公式

$$F_0(i) = \pi_i q_{i, j_0}$$

$$\begin{aligned} F_m(i) &= \sum_{i_{m-1} \in S} \mathbb{P}(X_{m-1} = i_{m-1}, X_m = i, Y_k = j_k, 0 \leq k \leq m) \\ &= \sum_{i_{m-1} \in S} \left[\mathbb{P}(X_m = i, Y_m = j_m | X_{m-1} = i_{m-1}, Y_k = j_k, 0 \leq k \leq m-1) \right. \\ &\quad \times \left. \mathbb{P}(X_{m-1} = i_{m-1}, Y_k = j_k, 0 \leq k \leq m-1) \right] \end{aligned}$$

$$= q_{i,j_m} \sum_{i_{m-1} \in S} p_{i_{m-1},i} F_{m-1}(i_{m-1}), \quad m \geq 1. \quad (4.4.4)$$

对任意 $0 \leq m < n$, 令

$$B_m(i) = \mathbb{P}(Y_n = j_n, \dots, Y_{m+1} = j_{m+1} | X_m = i),$$

类似地, 再由(4.4.2), 条件概率公式和全概率公式可得

$$B_m(i) = \sum_{i_{m+1} \in S} p_{i,i_{m+1}} q_{i_{m+1},j_{m+1}} B_{m+1}(i_{m+1}), \quad m \leq n-1. \quad (4.4.5)$$

其中约定 $B_n(i) \equiv 1$.

基于公式(4.4.4)和(4.4.5), 我们可以通过递推的方法得到 $F_m(i)$ 和 $B_m(i)$.

由 $F_m(i)$ 和 $B_m(i)$ 的定义可得

$$\mathbb{P}(Y_k = j_k, 0 \leq k \leq n) = \sum_{i \in S} \mathbb{P}(X_n = i, Y_k = j_k, 0 \leq k \leq n) = \sum_{i \in S} F_n(i) \quad (4.4.6)$$

$$\begin{aligned} &= \sum_{i \in S} \mathbb{P}(X_0 = i, Y_k = j_k, 0 \leq k \leq n) \\ &= \sum_{i \in S} \pi_i q_{i,j_0} B_0(i). \end{aligned} \quad (4.4.7)$$

更一般地, 对任意 $0 \leq m \leq n$, 由马氏性

$$\begin{aligned} \mathbb{P}(Y_k = j_k, 0 \leq k \leq n) &= \sum_{i \in S} \mathbb{P}(X_m = i, Y_k = j_k, 0 \leq k \leq n) \\ &= \sum_{i \in S} \mathbb{P}(X_m = i, Y_k = j_k, 0 \leq k \leq m) \\ &\quad \times \mathbb{P}(Y_k = j_k, m < k \leq n | X_m = i, Y_k = j_k, 0 \leq k \leq m) \\ &= \sum_{i \in S} F_m(i) \mathbb{P}(Y_k = j_k, m < k \leq n | X_m = i) = \sum_{i \in S} F_m(i) B_m(i). \end{aligned} \quad (4.4.8)$$

因此

$$\mathbb{P}(X_m = i | Y_k = j_k, 0 \leq k \leq n) = \frac{F_m(i) B_m(i)}{\sum_{i \in S} F_m(i) B_m(i)}. \quad (4.4.9)$$

$$\begin{aligned} \mathbb{P}(Y_{n+1} = j | Y_k = j_k, 0 \leq k \leq n) &= \sum_{i, i_{n+1} \in S} \mathbb{P}(Y_{n+1} = j, X_{n+1} = i_{n+1}, X_n = i | Y_k = j_k, 0 \leq k \leq n) \\ &= \sum_{i, i_{n+1} \in S} \frac{p_{i,i_{n+1}} q_{i_{n+1},j} F_n(i)}{\sum_{i \in S} F_n(i)}. \end{aligned} \quad (4.4.10)$$

例15.4 假设例15.1中股票价格波动率分 $-1, 0, 1$ 三个层次, 在股票状态只有 $-1, 1$ 两种情形. 在股票状态为 1 时, 股票价格波动率分 $-1, 0, 1$ 的概率分别为 $0.2, 0.3, 0.5$, 而在股票状态为 -1 时, 股票价格波动率分 $-1, 0, 1$ 的概率分别为 $0.6, 0.2, 0.2$. 假定股票状态转移概率为

$$p_{-1,1} = 1/4, p_{-1,-1} = 3/4, p_{1,1} = 4/5, p_{1,-1} = 1/5.$$

若已知 $\mathbb{P}(X_0 = 1) = 4/5$ 以及 3 天的价格波动率 $Y_0 = 1, Y_1 = 0, Y_2 = -1$. 试问(1)第三个观察

日股票在状态1的概率, (2)估计第四个观察日股票价格波动最可能的层次.

解 (1) 给定 $j_0 = 1, j_1 = 0, j_2 = -1$, 套用公式(4.4.4), 计算可知

$$F_0(1) = \pi_{1,0} q_{1,1} = 0.8 \times 0.5 = 0.4, \quad F_0(-1) = \pi_{-1,0} q_{-1,1} = 0.2 \times 0.2 = 0.04;$$

$$F_1(1) = q_{1,0} [p_{-1,1} F_0(-1) + p_{1,1} F_0(1)] = 0.099,$$

$$F_1(-1) = q_{-1,0} [p_{-1,-1} F_0(-1) + p_{1,-1} F_0(1)] = 0.022;$$

$$F_2(1) = q_{1,-1} [p_{-1,1} F_1(-1) + p_{1,1} F_1(1)] = 0.01684,$$

$$F_2(-1) = q_{-1,-1} [p_{-1,-1} F_1(-1) + p_{1,-1} F_1(1)] = 0.02178.$$

因此由(4.4.9)(取 $m = n = 2$, 此时 $B_m(i) = 1$),

$$\mathbb{P}(X_2 = 1 | Y_0 = 1, Y_1 = 0, Y_2 = -1) = \frac{0.01684}{0.01684 + 0.02178} = \frac{842}{1931} \approx 0.4355.$$

(2) 为了计算方便, 我们令

$$a(1) = p_{1,1} q_{1,1} + p_{1,-1} q_{-1,1} = 0.44, \quad a(-1) = p_{-1,1} q_{1,1} + p_{-1,-1} q_{-1,1} = 0.275;$$

$$b(1) = p_{1,1} q_{1,0} + p_{1,-1} q_{-1,0} = 0.28, \quad b(-1) = p_{-1,1} q_{1,0} + p_{-1,-1} q_{-1,0} = 0.225;$$

$$c(1) = p_{1,1} q_{1,-1} + p_{1,-1} q_{-1,-1} = 0.28, \quad c(-1) = p_{-1,1} q_{1,-1} + p_{-1,-1} q_{-1,-1} = 0.5.$$

由(4.4.10)可得(取 $n = 2$)

$$\mathbb{P}(Y_3 = 1 | Y_0 = 1, Y_1 = 0, Y_2 = -1) = \frac{a(1) F_2(1) + a(-1) F_2(-1)}{F_2(1) + F_2(-1)} \approx 0.3469;$$

$$\mathbb{P}(Y_3 = 0 | Y_0 = 1, Y_1 = 0, Y_2 = -1) = \frac{b(1) F_2(1) + b(-1) F_2(-1)}{F_2(1) + F_2(-1)} \approx 0.2490;$$

$$\mathbb{P}(Y_3 = -1 | Y_0 = 1, Y_1 = 0, Y_2 = -1) = \frac{c(1) F_2(1) + c(-1) F_2(-1)}{F_2(1) + F_2(-1)} \approx 0.4041.$$

因此第四个观察日股票价格波动最可能的层次为-1.

4.4.2 状态估计与预测*

对隐Markov 模型, 在应用中我们常碰到这样的问题: 已知模型参数($\pi, \mathbf{P}, \mathbf{Q}$)和一段观测序列 $\{Y_k, k \leq n\}$, 需要估计 $X_m, m \leq n$ 的最佳值. 下面我们基于极大似然的思想讨论这类问题, 也即我们认为 X_m 的最佳值是在给定观察序列条件下 X_m 以最大概率取到的值.

给定一段序列 $\{Y_k, k \leq n\}$ 的观察值 y_0, \dots, y_n . 当我们只估计 n 之前某一个时刻 m 的最佳值时, 由(4.4.9)

$$\mathbb{P}(X_m = i | Y_k = j_k, 0 \leq k \leq n) = \frac{F_m(i) B_m(i)}{\sum_{i \in S} F_m(i) B_m(i)}$$

可知, X_m 的最佳值就是使得 $F_m(i) B_m(i)$ 取值最大的 i .

若我们需要估计 n 及 n 之前所有时刻的最佳值, 那么由

$$\begin{aligned} & \max_{i_k \in S, 0 \leq k \leq n} \mathbb{P}(X_k = i_k, Y_k = j_k, 0 \leq k \leq n) \\ &= \max_{i_k \in S, 0 \leq k \leq n} [p_{i_{n-1}, i_n} q_{i_n, j_n} \mathbb{P}(X_k = i_k, Y_k = j_k, 0 \leq k < n)] \\ &= \max_{i_n \in S} \left\{ q_{i_n, j_n} \max_{i_k \in S, 0 \leq k < n} [p_{i_{n-1}, i_n} \mathbb{P}(X_k = i_k, Y_k = j_k, 0 \leq k < n)] \right\}, \end{aligned} \quad (4.4.11)$$

可知, 对任意 $0 \leq m \leq n$, 若令

$$\begin{aligned} M_m(i) &= \max_{i_k \in S, 0 \leq k < m} \mathbb{P}(X_m = i, X_k = i_k, Y_k = j_k, 0 \leq k < m) \\ &= \max_{i_k \in S, 0 \leq k < m} [p_{i_{m-1}, i} \mathbb{P}(X_k = i_k, Y_k = j_k, 0 \leq k < m)], \end{aligned}$$

则由马氏性可得

$$\begin{aligned} M_m(i) &= \max_{\substack{i_k \in S \\ 0 \leq k < m}} [p_{i_{m-1}, i} q_{i_{m-1}, j_{m-1}} p_{i_{m-2}, i_{m-1}} \mathbb{P}(X_k = i_k, Y_k = j_k, 0 \leq k < m-1)] \\ &= \max_{i_{m-1} \in S} [p_{i_{m-1}, i} q_{i_{m-1}, j_{m-1}} M_{m-1}(i_{m-1})], \end{aligned} \quad (4.4.12)$$

并且由(4.4.11)可得

$$\max_{i_k \in S, 0 \leq k \leq n} \mathbb{P}(X_k = i_k, Y_k = j_k, 0 \leq k \leq n) = \max_{i \in S} [q_{i, j_n} M_n(i)]. \quad (4.4.13)$$

注意到对任意 $i \in S$, $M_0(i) = \pi_i$ 其中 π 是 X 的初始分布, 利用(4.4.12), 由递归计算可得任意的 $M_m(i)$, 进而由上式可知 n 及 n 之前所有时刻的 X 的最佳值与 Y 的观测值的联合概率.

为了获得 n 及 n 之前所有时刻的 X 的最佳值, 由(4.4.13)和(4.4.12)进一步可知 n 及 n 之前所有时刻的 X 的最佳值 i_0, i_1, \dots, i_n 中

- (1) i_n 是使函数 $q_{i, j_n} M_n(i)$, $i \in S$, 取到最大值的一个状态;
- (2) 对任意 $1 \leq m \leq n$, 给定 i_m, i_{m-1} 就是使得函数

$$p_{i, i_m} q_{i, j_{m-1}} M_{m-1}(i), \quad i \in S,$$

取最大值的一个状态.

对任意 $0 \leq m < n$ 以及 $u \in S$, 记 $I_m(u) \in S$ 使得

$$p_{I_m(u), u} q_{I_m(u), j_m} M_m(I_m(u)) = \max_{i \in S} p_{i, u} q_{i, j_m} M_m(i).$$

那么

$$i_{n-1} = I_{n-1}(i_n), i_{n-2} = I_{n-2}(i_{n-1}), \dots, i_0 = I_0(i_1).$$

给定了观测序列的观测值, 上面寻找最可能的状态序列的方法称为Viterbi算法.

例15.5 (接例15.4) 问前三个观察日该股票最可能的状态序列是什么?

解 给定 $j_0 = 1, j_1 = 0, j_2 = 1$. 由假设可知 $M_0(1) = 0.8, M_0(-1) = 0.2$,

$$M_1(1) = \max_{i=-1, 1} p_{i, 1} q_{i, j_0} M_0(i) = \max_{i=-1, 1} p_{i, 1} q_{i, 1} M_0(i) = 0.32, \quad I_0(1) = 1$$

类似可知

$$M_1(-1) = \max_{i=-1,1} p_{i,-1} q_{i,j_0} M_0(i) = 0.08, \quad I_0(-1) = 1.$$

$$M_2(1) = \max_{i=-1,1} p_{i,1} q_{i,j_1} M_1(i) = 0.0768, \quad I_1(1) = 1.$$

$$M_2(-1) = \max_{i=-1,1} p_{i,-1} q_{i,j_1} M_1(i) = 0.0192, \quad I_1(-1) = 1.$$

由于 $\max_{i=-1,1} q_{i,j_2} M_2(i) = \max_{i=-1,1} q_{i,-1} M_2(i) = 0.01536$ 在 $i = 1$ 时取到最大值. 因此前三个观察日该股票最可能的状态序列是 $i_2 = 1, i_1 = I_1(1) = 1, i_0 = I_0(1) = 1$. \square

4.4.3 隐Markov模型的参数估计*

应用时对隐Markov 模型我们还常需要从一段观测序列 $\{Y_k, k \leq n\}$ 出发估计模型参数 $\theta = (\pi, \mathbf{P}, \mathbf{Q})$. 这类问题又称为学习问题, 属于参数估计范畴.

若假设 $\{X_k, k \geq 1\}$ 的样本也已知, 此时作为马氏链 $Z = \{Z_k, k \geq 0\}$ 是完全已知的. 那么只要有充分长的样本, 对任意 $i, j \in S$, 把 X 中从状态 i 到下一个时刻为状态 j 的频数记为 $A_{i,j}$, 把状态 i 出现的频数记作 A_i , 由习题9.10 以及大数定律可以证明, 只要 i 常返就可以用

$$\hat{p}_{i,j} = \frac{A_{i,j}}{A_i}$$

作为 $p_{i,j}$ 的相合估计, 同样若以 $B_{i,l}$ 表示 X 取值 i 的同时 Y 取值 l 的频数, 则类似可证明

$$\hat{q}_{i,l} = \frac{B_{i,l}}{A_i}$$

是 $q_{i,l}$ 相合估计. 然而这种方法只是“理想”的, 因为实际模型中 X 往往是不可测量的.

下面我们仅给定 Y 的一组观测值 l_0, l_1, \dots, l_N . 极大似然原理告诉我们 θ 的最大似然估计 $\hat{\theta}$ 满足

$$\mathbb{P}(Y_k = l_k, 0 \leq k \leq N | \hat{\theta}) = \max_{\theta} \mathbb{P}(Y_k = l_k, 0 \leq k \leq N | \theta),$$

其中 $\mathbb{P}(\cdot | \theta)$ 表示给定参数 θ 下的概率.

一般而言, 直接求解该问题非常困难. 一种折中方案是通过构造一个关于参数 θ 的递推算法, 使之能逐步提高条件概率 $\mathbb{P}(Y_k = l_k, 0 \leq k \leq N | \theta)$ 的取值, 并将递推算法的最终结果作为参数 θ 的估计. 算法的具体步骤如下:

- (s1) 给定参数 $\theta_n = (\pi(n), \mathbf{P}(n) = (p_{i,j}(n))_{i,j \in S}, \mathbf{Q}(n) = (q_{i,l}(n))_{i \in S, l \in W})$;
- (s2) 对任意 $\theta = (\pi, \mathbf{P} = (p_{i,j})_{i,j \in S}, \mathbf{Q} = (q_{i,l})_{i \in S, l \in W})$, 令

$$\begin{aligned} T(\theta | \theta_n) &= \sum_{i_k \in S, 0 \leq k \leq N} \left[\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N | \theta_n) \right. \\ &\quad \times \ln(\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N | \theta)) \Big]. \end{aligned}$$

(s3) 求 θ^* 使得 $T(\theta^*|\theta_n) = \max_{\theta} T(\theta|\theta_n)$.

(s4) 令 $\theta_{n+1} = \theta^*$ 并回到(s1).

按上述算法,

$$\begin{aligned} 0 &\leq T(\theta_{n+1}|\theta_n) - T(\theta_n|\theta_n) \\ &= \sum_{i_k \in S, 0 \leq k \leq N} \left[\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_n) \right. \\ &\quad \times \ln \left(\frac{\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_{n+1})}{\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_n)} \right) \left. \right] \end{aligned}$$

因为对任意 $x \in (0, \infty)$, $\ln x < x - 1$, 由上式可得

$$\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_{n+1}) \geq \mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_n).$$

这表明上述算法得到的参数 θ_n 确实能使条件概率 $\mathbb{P}(Y_k = j_k, 0 \leq k \leq N|\theta_n)$ 随着算法次数的增加而优化(增加).

将函数 $T(\theta|\theta_n)$ 展开得

$$\begin{aligned} T(\theta|\theta_n) &= \sum_{\substack{i_k \in S \\ 0 \leq k \leq N}} \left[\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_n) \ln(\pi_{i_0} q_{i_0, l_0} \prod_{n=1}^N p_{i_{n-1}, i_n} q_{i_n, l_n}) \right] \\ &= \sum_{i_k \in S, 0 \leq k \leq N} \left[\mathbb{P}(X_k = i_k, Y_k = l_k, 0 \leq k \leq N|\theta_n) \right. \\ &\quad \times \left. (\ln \pi_{i_0} + \sum_{n=0}^N \ln q_{i_n, l_n} + \sum_{n=1}^N \ln p_{i_{n-1}, i_n}) \right] \\ &= \sum_{i_0 \in S} \mathbb{P}(X_0 = i_0, Y_k = l_k, 0 \leq k \leq N|\theta_n) \ln \pi_{i_0} \\ &\quad + \sum_{i_n \in S} \sum_{n=0}^N \mathbb{P}(X_n = i_n, Y_k = l_k, 0 \leq k \leq N|\theta_n) \ln q_{i_n, l_n} \\ &\quad + \sum_{i_{n-1}, i_n \in S} \sum_{n=1}^N \mathbb{P}(X_{n-1} = i_{n-1}, X_n = i_n, Y_k = l_k, 0 \leq k \leq N|\theta_n) \ln p_{i_{n-1}, i_n}. \end{aligned}$$

或重写为

$$\begin{aligned} T(\theta|\theta_n) &= \sum_{i \in S} \mathbb{P}(X_0 = i, Y_k = l_k, 0 \leq k \leq N|\theta_n) \ln \pi_i \\ &\quad + \sum_{\substack{i \in S \\ l \in W}} \sum_{n=0}^N \mathbb{P}(X_n = i, Y_k = l_k, 0 \leq k \leq N|\theta_n) \mathbf{1}_{\{Y_n=l\}} \ln q_{i,l} \\ &\quad + \sum_{i,j \in S} \sum_{n=1}^N \mathbb{P}(X_{n-1} = i, X_n = j, Y_k = l_k, 0 \leq k \leq N|\theta_n) \ln p_{i,j}. \end{aligned}$$

由习题15.1可知, 当 $\theta = (\pi^*, \mathbf{P}^*, \mathbf{Q}^*)$ 时 $T(\theta|\theta_n)$ 取到最大值, 其中, 对任意 $i, j \in S, l \in W$,

$\pi^* = (\pi_i^*)$, $\mathbf{P}^* = (p_{i,j}^*)$, $\mathbf{Q}^* = (q_{i,l}^*)$ 满足

$$\pi_i^* = \frac{\mathbb{P}(X_0 = i, Y_k = l_k, 0 \leq k \leq N | \theta_n)}{\sum_{i \in S} \mathbb{P}(X_0 = i, Y_k = l_k, 0 \leq k \leq N | \theta_n)}, \quad (4.4.14)$$

$$p_{i,j}^* = \frac{\sum_{n=1}^N \mathbb{P}(X_{n-1} = i, X_n = j, Y_k = l_k, 0 \leq k \leq N | \theta_n)}{\sum_{i,j \in S} \sum_{n=1}^N \mathbb{P}(X_{n-1} = i, X_n = j, Y_k = l_k, 0 \leq k \leq N | \theta_n)}, \quad (4.4.15)$$

$$q_{i,l}^* = \frac{\mathbb{P}(X_n = i, Y_k = l_k, 0 \leq k \leq N | \theta_n) \mathbf{1}_{\{Y_n=l\}}}{\sum_{i \in S} \sum_{n=0}^N \mathbb{P}(X_n = i, Y_k = l_k, 0 \leq k \leq N | \theta_n) \mathbf{1}_{\{Y_n=l\}}}. \quad (4.4.16)$$

令 $\theta_{n+1} = (\pi^*, \mathbf{P}^*, \mathbf{Q}^*)$, 我们得到了参数 θ_{n+1} 与 θ_n 之间的递推公式.

一般称(4.4.14)-(4.4.16)为Welch-Baum 公式. 上面的算法被称为EM 算法. 其中E和M 分别指代步骤(s2)和(s3), 求数学期望与求最大值. EM算法是针对在测量数据不完全时,求参数的一种近似于最大似然估计的统计方法. 隐Markov 模型参数的估计, 是EM 算法的一种典型运用.

对隐Markov 模型, 人们在应用时还会关心许多其他的问题, 比如对于一个特定的观测链 $\{Y_k, k \leq n\}$, 已知它可能是由已经学习好的若干模型之一所得的观测, 要决定此观测究竟是得自其中哪一个模型. 这类问题也称为识别问题, 属于分类范畴. 对于这些问题, 我们不展开, 对此感兴趣的读者可以参阅相关资料, 进一步学习和了解.

练习题

15.1 设 $z_i > 0$ ($i \in T$). 证明

$$\sum_{i \in T} z_i \ln \left(\frac{z_i}{\sum_{i \in T} z_i} \right) = \sup_{\substack{x_i > 0, i \in T \\ \sum_i x_i = 1}} \sum_{i \in T} z_i \ln x_i.$$

15.2* 试寻找一些具体问题, 用隐Markov 模型建模并做出分析和预测.

第五章 更新过程

马氏过程需要条件独立性, 要求在已知现在状态的条件下, 未来与过去无关. 本章介绍的更新过程, 是Poisson过程的推广; 一般而言, 更新过程不具有马氏性, 但对某些特定的时刻却有“更新”的特征.

5.1 更新过程与更新方程

给定概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 及其上计数过程 $N = \{N(t); t \geq 0\}$. 由第二章第三节可知, 对任意整数 $k \geq 1$,

$$T_k = \inf\{t \geq 0; N(t) \geq k\} \quad \text{以及} \quad W_k = T_k - T_{k-1},$$

其中 $T_0 = 0$, 分别为第 k 次(随机事件)发生时间和第 k 个等待时间. 计数过程 N 与到达时刻序列 $\{T_k; k \geq 1\}$ 满足如下关系

$$N(t) = \sup\{k; T_k \leq t\} = \sum_{k=1}^{\infty} \mathbf{1}_{\{T_k \leq t\}},$$

而且对任意 $k \geq 0$ 以及 $t \geq 0$

$$\{N(t) \geq k\} = \{T_k \leq t\}, \tag{5.1.1}$$

$$\{N(t) = k\} = \{T_k \leq t < T_{k+1}\}, \tag{5.1.2}$$

$$N(t) + 1 = \inf\{k, T_k > t\}. \tag{5.1.3}$$

5.1.1 更新过程与更新性

定义16.1 若计数过程 $N = \{N(t); t \geq 0\}$ 具有独立同分布的等待时间序列, 即存在独立同分布的非负随机变量序列 $\{W_k; k \geq 1\}$, 使得

$$N(t) = \sup\{k \geq 0 : \sum_{i=1}^k W_i \leq t\}. \tag{5.1.4}$$

则称 N 为更新过程. 称 W_k 的分布(函数) F 为等待时间分布.

显然泊松过程是一个更新过程. 因此更新过程可看作泊松过程的推广. 此外, 为了避免 $N(t) \equiv \infty$ 这种平凡情形, 总设 $F(0) < 1$.

对任意 $t \geq 0$ 以及到达时刻 T_n ,

$$N(t + T_n) - n = \sum_{k=n+1}^{\infty} \mathbf{1}_{\{T_k - T_n \leq t\}} = \sum_{k=n+1}^{\infty} \mathbf{1}_{\{\sum_{i=n+1}^k W_i \leq t\}}.$$

注意到 $W_i, i \geq 1$, 是独立同分布的随机变量, $T_n = \sum_{k=1}^n W_k$ 只依赖于 n 之前的 W_i , 因此 $N(t + T_n) - n$ 与 T_n 独立, 且

$$\{N(t + T_n) - n; t \geq 0\} \stackrel{f.d.}{=} \left\{ \sum_{k=1}^{\infty} \mathbf{1}_{\{\sum_{i=1}^k W_i \leq t\}}; t \geq 0 \right\} = \{N(t); t \geq 0\}.$$

这表明从恰好发生第 n 事件的时刻 T_n 往后看, 更新过程增量与 T_n 独立且增量的随机变化就像是从零时刻开始的更新过程. 直观地说, 在 T_n 之后, 过程 $N(t)$ 从“新”开始. 我们把这种性质称为更新性, 我们也常称 T_n 为(第 n 次)更新时刻.

例16.1 假设 $X = \{X_n; n \geq 1\}$ 为伯努利过程, N_n 表示 n 次试验之前(含第 n 次)成功的次数, 并规定 $N_0 = 0$. 对任意 $t \geq 0$, 令 $N(t) = N_{[t]}$. 那么 $N = \{N(t); t \geq 0\}$ 就是一个更新过程. 此时到达时间间隔 W_i 服从几何分布:

$$\mathbb{P}(W_1 = k) = \mathbb{P}(X_1 = 0, \dots, X_{k-1} = 0, X_k = 1) = (1-p)^{k-1}p.$$

例16.2 某型商品专卖店采取 (s, S) -式进货仓储策略, 即商店商品数不超过 s 时将商品补足到 S 个, 假设开始时商店有 S 件商品而且补充的商品能立即进货. 若顾客按强度为 λ 的泊松过程 $N(t)$ 到达, 而且每个顾客购买的商品数是独立同分布的随机变量 ξ_i . 令 $C(t)$ 表示 $(0, t]$ 时段内的补货次数, 那么 $C(t)$ 就是一个更新过程, 等待时间 W 分布为

$$\mathbb{P}(W > t) = \mathbb{P}\left(\sum_{i=1}^{N(t)} \xi_i < S - s\right).$$

比如, 若还假设 $\{\xi_i\}$ 与 $N(t)$ 独立, $s = 2$, $S = 4$, 并设

$$\mathbb{P}(\xi_i = 1) = p, \quad \mathbb{P}(\xi_i = 2) = q = 1 - p.$$

那么我们可得

$$\begin{aligned} \mathbb{P}(W > t) &= \mathbb{P}(\{(0, t]\) 内没有顾客\} \cup \{(0, t]\) 内只有 1 个顾客且只买了 1 件商品\}) \\ &= e^{-\lambda t} + p\lambda t e^{-\lambda t}. \end{aligned}$$

注意到 $T_k = \sum_{i=1}^k W_i$ 为独立随机变量之和, 由强大数定律可知

$$T_n/n \rightarrow \mu = \mathbb{E}(W_1), \quad \text{a.s.}$$

因此 $T_n \rightarrow \infty$, a.s. 此外

$$\mathbb{P}(T_n \leq t) = F^{*n}(t),$$

其中 $F^{*0}(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases}$, 进而 $N(t)$ 的分布列为
 $\mathbb{P}(N(t) = k) = \mathbb{P}(T_k \leq t) - \mathbb{P}(T_{k+1} \leq t) = F^{*k}(t) - F^{*(k+1)}(t),$

并且对一切 $t \geq 0, n \in \mathbf{N}$,

$$\begin{aligned} \mathbb{P}(N(t) < \infty) &= \lim_{n \rightarrow \infty} \mathbb{P}(N(t) < n) = \lim_{n \rightarrow \infty} \mathbb{P}(T_n > t) = 1, \\ \lim_{t \rightarrow \infty} \mathbb{P}(N(t) < n) &= \lim_{t \rightarrow \infty} \mathbb{P}(T_n > t) = 0. \end{aligned}$$

因此, $N(t)$ 取有限值且由其单调非降性可得 $t \rightarrow \infty$ 时 $N(t) \rightarrow \infty$, a.s.

定理16.1 更新过程 $N = \{N(t); t \geq 0\}$ 的任意阶矩存在, 即对任意 $t \geq 0, k \geq 1$,

$$\mathbb{E}[(N(t))^k] < +\infty,$$

特别, $m(t) := \mathbb{E}(N(t)) = \sum_{n=1}^{\infty} F^{*n}(t).$

证明 对任意固定的 $t \geq 0$,

$$\begin{aligned} \mathbb{E}[(N(t))^k] &= \sum_{n=1}^{\infty} n^k \mathbb{P}(N(t) = n) \leq \sum_{n=1}^{\infty} n^k \mathbb{P}(N(t) \geq n) \\ &= \sum_{n=1}^{\infty} n^k \mathbb{P}(T_n \leq t) = \sum_{n=1}^{\infty} n^k F^{*n}(t). \end{aligned}$$

由 $\lim_{n \rightarrow \infty} \mathbb{P}(T_n \leq t) = 0$ 可知, 存在正整数 m 使得

$$a = F^{*m}(t) < 1.$$

又因为对一切 $n \geq 0$,

$$F^{*(m+n)}(t) = \int_0^t F^{*m}(t-s) dF^{*n}(s) \leq F^{*m}(t) F^{*n}(t).$$

所以对任意 $l = 0, 1, 2, \dots, r = 0, 1, 2, \dots, m-1$,

$$F^{*(lm+r)}(t) \leq (F^{*m}(t))^l = a^l.$$

因此

$$\begin{aligned} \mathbb{E}[(N(t))^k] &\leq \sum_{n=1}^{\infty} n^k F^{*n}(t) = \sum_{l=0}^{\infty} \sum_{r=0}^{m-1} (lm+r)^k F^{*(lm+r)}(t) \\ &\leq m^{k+1} \sum_{l=0}^{\infty} (l+1)^k a^l < +\infty. \end{aligned} \tag{5.1.5}$$

此时

$$\begin{aligned} m(t) = \mathbb{E}(N(t)) &= \sum_{n=1}^{\infty} n \mathbb{P}(N(t) = n) = \sum_{n=1}^{\infty} n (F^{*n}(t) - F^{*(n+1)}(t)) \\ &= F(t) + \sum_{n=2}^{\infty} [n - (n-1)] F^{*n}(t) = \sum_{n=1}^{\infty} F^{*n}(t). \end{aligned} \quad \square$$

特别, 若 N 是泊松过程, 容易检验

$$m(t) = \sum_{n=1}^{\infty} F^{*n}(t) = \sum_{n=1}^{\infty} \int_0^t \frac{\lambda^n s^{n-1}}{(n-1)!} e^{-\lambda s} ds = \int_0^t \lambda e^{-\lambda s} \sum_{n=0}^{\infty} \frac{\lambda^n s^{n-1}}{(n-1)!} ds = \lambda t,$$

这与命题7.3相关结果一致.

5.1.2 更新函数与更新方程

定义16.2 称 $m(t) = \mathbb{E}(N(t))$ 为更新过程 $N = \{N(t); t \geq 0\}$ 的更新函数. 当 N 的等待时间分布为 F 时, 也称 m 是分布 F 的更新函数.

注16.1 为了叙述方便, 若无特别说明, 本章此后更新过程的等待时间分布 F 都是离散格子点分布(参见习题1.8) 或者 $(0, +\infty)$ 上的连续分布且具有局部有界(即在任一有界区间上都有界) 的概率密度函数.

当 F 是步长为 d 的离散格子点分布时, 此时由习题16.7可知 $m(t)$ 为阶梯函数, 每个阶梯的跳跃点都可表示成 nd 的形式.

当 F 连续时, 假设密度函数为 f , 那么对任意 $k \geq 1$, 由

$$F^{*k}(t) = \int_0^t F^{*(k-1)}(t-s)f(s)ds$$

可知 $F^{*k}(t)$ 的密度函数存在, 记其为 $f_k(t)$, 其中 $f_1(t) \equiv f(t)$ 且

$$f_k(t) = \int_0^t f_{k-1}(t-s)f(s)ds.$$

定理16.1的证明告诉我们级数 $\sum_{n=1}^{\infty} F^{*n}(t)$ 关于 t 在任意有界集上是一致收敛的. 因此密度函数 f 局部有界时, 由

$$\begin{aligned} \sum_{n=1}^{\infty} f_n(t) &= \left[f(t) + \sum_{n=2}^{\infty} \int_0^t f_{n-1}(t-s)f(s)ds \right] \\ &\leq \sup_{0 \leq s \leq t} f(s) [1 + \sum_{n=1}^{\infty} \int_0^t f_n(s)ds] \\ &= \sup_{0 \leq s \leq t} f(s) [1 + \sum_{n=1}^{\infty} F^{*n}(t)] < \infty, \end{aligned}$$

可知

$$\frac{dm(t)}{dt} = \sum_{n=1}^{\infty} \frac{dF^{*n}(t)}{dt} = \sum_{n=1}^{\infty} f_n(t).$$

即 $m(t)$ 是连续可微的.

定义16.3 设 $b(t)$ 是 $[0, \infty)$ 上局部有界函数, 称如下形式的方程

$$B(t) = b(t) + \int_0^t B(t-s)dF(s), \quad (5.1.6)$$

为更新方程, 其中 $B(t)$ 为未知函数, $F(s)$ 是非负随机变量的分布函数.

注16.2 一般地, 方程(3.2.2)中右边的积分 $\int_0^t B(t-s)dF(s)$ 是所谓的R-S(Riemann-Stieltjes)积

分。对此积分本书不展开介绍。在注16.1条件下该积分分别对应为离散求和与牛顿-莱布尼茨积分：当 F 是离散型分布时，该积分是和式

$$\sum_{0 \leq x_k \leq t} B(t - x_k) p_k,$$

其中 x_k 为 F 支撑集(见例1.8)中的元素；当 F 是密度函数为 f 的连续分布时，该积分为牛顿-莱布尼茨积分

$$\int_0^t B(t-s) f(s) ds.$$

除特别说明外，此后我们不区分 F 是连续还是离散分布，统一用积分 $\int_0^t \phi(s) dF(s)$ 表示对函数 ϕ 的求和或牛顿-莱布尼茨积分。

定理16.2 更新函数 $m(t)$ 满足如下积分方程

$$m(t) = F(t) + \int_0^t m(t-s) dF(s). \quad (5.1.7)$$

证明 由全概率公式

$$m(t) = \mathbb{E}(N(t)) = \mathbb{E}(\mathbb{E}(N(t)|T_1)) = \int_0^\infty \mathbb{E}(N(t)|T_1=s) dF(s).$$

当 $s = T_1 > t$ 时， $N(t) = 0$ ；当 $s = T_1 < t$ 时，由更新性，

$$N(t) = N(t - T_1 + T_1) - 1 + 1 \stackrel{d}{=} 1 + N(t - T_1) = 1 + N(t-s).$$

$$\text{因此 } \mathbb{E}(N(t)|T_1=s) = \begin{cases} 0, & s > t, \\ 1 + \mathbb{E}(N(t-s)) = 1 + m(t-s), & s < t. \end{cases}$$

$$m(t) = \int_0^t [1 + m(t-s)] dF(s) = F(t) + \int_0^t m(t-s) dF(s). \quad \square$$

注16.3 通常把利用全概率公式和更新性建立更新方程的方法称为更新技巧(方法)。

例16.3 设更新过程 $N(t)$ 的等待时间分布 F 为 $[0, 1]$ 上的均匀分布，求对应的更新函数 $m(t)$ ，其中 $0 < t \leq 1$ 。

解 对任意 $0 < t \leq 1$ ，所求更新函数满足的更新方程为

$$m(t) = F(t) + \int_0^t m(t-s) dF(s) = t + \int_0^t m(s) ds.$$

两边关于 t 求导得 $m'(t) = 1 + m(t)$ 。因此 $\frac{dm(t)}{1+m(t)} = dt$ 。由此可解得

$$\ln(1 + m(t)) = c + t \Rightarrow m(t) = Ce^t - 1.$$

由 $m(0) = 0$ 可知 $C = 1$ ，即 $m(t) = e^t - 1$ 。 \square

利用更新函数我们可以给出更新方程唯一局部有界解的显示方式，证明省略。

定理16.3 设 $b(t)$ 为局部有界函数，更新方程(5.1.6)有唯一局部有界解

$$B(t) = b(t) + \int_0^t b(t-s) dm(s), \quad (5.1.8)$$

其中 $m(s)$ 是 F 的更新函数.

注16.4 (1) 方程(5.1.8)中的积分 $\int_0^t b(t-s)dm(s)$ 仍是 R-S 积分. 在注16.1条件下, 当 F 是具有局部有界密度函数的连续分布时, $m(s)$ 连续可微, 该积分与如下牛顿-莱布尼茨积分一致

$$\int_0^t b(t-s)m'(s)ds;$$

当 F 是步长为 d 的格子点分布时, $m(s)$ 是阶梯函数, 跳跃点在 kd , 该积分是离散求和:

$$\sum_{kd \leq t} b(t-kd)(m(kd) - m((k-1)d)),$$

其中约定 $m(-d) = 0$.

(2) 由 $N(t)$ 的单调非降和右连续性可知 $m(t)$ 是单调非降右连续函数,

$$dm(t) = d\left(\sum_{n=1}^{\infty} F^{*n}(t)\right) \approx \sum_{n=1}^{\infty} \mathbb{P}(t < T_n \leq t + dt).$$

因此 $dm(t)$ 可直观地理解为 N 在时间区间 $(t, t+dt]$ 发生跳跃的概率.

由定理16.2与定理16.3, 我们可以得到更新函数 $m(t)$ 的另一种表示:

$$m(t) = F(t) + \int_0^t F(t-s)dm(s) \quad (5.1.9)$$

例16.4 对任意 $t, s \geq 0$, 求 $\mathbb{E}(N^2(t))$.

解 记 $K(t) = \mathbb{E}(N^2(t))$. 由全概率公式

$$K(t) = \mathbb{E}(\mathbb{E}(N^2(t)|T_1)) = \int_0^\infty \mathbb{E}(N^2(t)|T_1 = u)dF(u).$$

由更新性

$$\mathbb{E}(N^2(t)|T_1 = u) = \begin{cases} 0, & u > t \\ \mathbb{E}((1 + N(t-u))^2), & u < t. \end{cases}$$

$$\text{即 } \mathbb{E}(N^2(t)|T_1 = u) = \begin{cases} 0, & u > t \\ 1 + 2m(t-u) + K(t-u), & u < t. \end{cases}$$

所以 $K(t)$ 满足方程

$$\begin{aligned} K(t) &= \int_0^t (1 + 2m(t-u) + K(t-u))dF(u) \\ &= F(t) + 2 \int_0^t m(t-u)dF(u) + \int_0^t K(t-u)dF(u) \\ &= 2m(t) - F(t) + \int_0^t K(t-u)dF(u). \end{aligned}$$

由定理16.1易知 $K(t)$ 是局部有界函数. 由定理16.3以及(5.1.9)可得

$$\begin{aligned} K(t) &= 2m(t) - F(t) + \int_0^t (2m(t-s) - F(t-s))dm(s) \\ &= m(t) + 2 \int_0^t m(t-s)dm(s). \end{aligned}$$

□

例16.5 求如下方程的局部有界解

$$g(t) = t + \int_0^t g(t-s)2e^{-2s}ds.$$

解 令 $dF(s) = 2e^{-2s}ds$, 即 F 是参数为2的指数分布. 再令 $b(t) = t$. 由定理16.3, 所求方程的唯一局部有界解为

$$g(t) = b(t) + \int_0^t b(t-s)dm(s),$$

其中 $m(s)$ 是分布 F 的更新函数. 由于以 F 为等待时间的更新过程是强度为2的泊松过程, 由命题7.3可知 $m(s) = 2s$. 因此

$$g(t) = t + \int_0^t (t-s)2ds = t^2 + t. \quad \square$$

5.1.3 更新过程的几个统计量

定义16.4 设 $N = \{N(t); t \geq 0\}$ 为更新过程. 令

$$A(t) = t - T_{N(t)}, \quad R(t) = T_{N(t)+1} - t, \quad L(t) = T_{N(t)+1} - T_{N(t)},$$

分别称 $A(t), R(t), L(t)$ 为更新过程 N 在时刻 t 的年龄, 剩余寿命和总寿命.

显然, $0 \leq A(t) \leq t, t \geq 0$ 且对任意 $x \geq 0, 0 \leq y \leq t$,

$$\begin{aligned} \{R(t) > x, A(t) \geq y\} &= \{(t-y, t+x] \text{ 中 } N \text{ 无跳跃}\} \\ &= \{R(t-y) > x+y\} = \{A(t+x) \geq x+y\}. \end{aligned}$$

取 $y = 0$ 得

$$\{R(t) > x\} = \{A(t+x) \geq x\}.$$

定理16.4 设 N 的等待时间分布 F 均值有限. 令 $\bar{F} = 1 - F(t)$, 则对任意 $x, t \geq 0$,

$$\mathbb{P}(R(t) > x) = \bar{F}(t+x) + \int_0^t \bar{F}(t-s+x)dm(s), \quad (5.1.10)$$

$$\mathbb{E}(R(t)) = \int_t^\infty \bar{F}(t)dt + \int_0^t \int_{t-s}^\infty \bar{F}(u)dudm(s), \quad (5.1.11)$$

证明 注意到对任意 $x \geq 0$,

$$\mathbb{P}(R(t) > x | T_1 = s) = \begin{cases} 1, & s > t+x; \\ 0, & t < s \leq t+x; \\ \mathbb{P}(R(t-s) > x), & s \leq t. \end{cases}$$

利用更新技巧得

$$\mathbb{P}(R(t) > x) = \mathbb{E}(\mathbb{P}(R(t) > x | T_1)) = \int_0^\infty \mathbb{P}(R(t) > x | T_1 = s)dF(s)$$

$$\begin{aligned}
&= \int_{t+x}^{\infty} dF(s) + \int_0^t \mathbb{P}(R(t-s) > x) dF(s) \\
&= \bar{F}(t+x) + \int_0^t \mathbb{P}(R(t-s) > x) dF(s).
\end{aligned}$$

由定理16.3可知(5.1.10)成立. 再注意到对任意 $t \geq 0$

$$\mathbb{E}(R(t)|T_1 = s) = \begin{cases} s - t, & s > t; \\ \mathbb{E}(R(t-s)), & s \leq t. \end{cases}$$

利用更新技巧

$$\begin{aligned}
\mathbb{E}(R(t)) &= \mathbb{E}(\mathbb{E}(R(t)|T_1)) = \int_0^{\infty} \mathbb{E}(R(t)|T_1 = s) dF(s) \\
&= \int_t^{\infty} (u-t) dF(u) + \int_0^t \mathbb{E}(R(t-s)) dF(s) \\
&= \int_t^{\infty} \bar{F}(u) du + \int_0^t \mathbb{E}(R(t-s)) dF(s). \tag{5.1.12}
\end{aligned}$$

此外由(5.1.10)可得

$$\mathbb{P}(R(t) > x) \leq \bar{F}(x) + \bar{F}(x)m(t).$$

因此

$$\mathbb{E}(R(t)) = \int_0^{\infty} \mathbb{P}(R(t) > x) dx \leq \int_0^{\infty} \bar{F}(x) dx (1 + m(t)) = \mu(1 + m(t))$$

是局部有界函数. 将定理16.3应用到方程(5.1.12)即得式(5.1.11). \square

对于 $A(t), L(t)$ 也可计算类似问题, 做为习题请读者自己完成.

值得指出的是, 对任意 $x > 0$, 若 $A(t) > x$, 那么 $\mathbb{P}(L(t) > x) = 1$; 若 $0 \leq s = A(t) \leq x$ 则意味着 t 时刻的总寿命一定大于 s , 此时由更新性

$$\mathbb{P}(L(t) > x | A(t) = s) = \mathbb{P}(L(s) > x | A(s) = s) = \mathbb{P}(W > x | W > s) \geq \mathbb{P}(W > x),$$

其中 W 表示更新过程的任意一个等待时间. 因此不论 t 时刻的年龄如何, 总有

$$\mathbb{P}(L(t) > x | A(t)) \geq \mathbb{P}(W > x),$$

从而

$$\mathbb{P}(L(t) > x) \geq \mathbb{P}(W > x). \tag{5.1.13}$$

这表明我们在某个固定 t 时刻观察到的等待时间会比通常“理论上”的等待时间长些——对于泊松过程我们可以给出更清楚的计算(参见习题7.6和16.4). 这种现象被称为长度偏离取样(length-biased sampling) 或 检验悖论. 它在统计意义上的直观解释是: 由于长的等待时间比短的等待时间更可能包含给定的时刻 t , 因此 t 时刻观察到的等待时间会更长.

练习题

16.1 设更新过程 N 的等待时间分布 F 的密度函数为 $f(t) = te^{-t}$, $t > 0$,

- (1) 对任意 $0 < t_1 < t_2$ 以及正整数 n, m , 求 $\mathbb{P}(N(t_1) = n, N(t_2) = m)$.
- (2) 对任意 $t > 0$, 求更新函数 $m(t)$.

16.2 求例 16.3 中 $m(t)$ 其中 $t \in (1, 2]$.

16.3 求积分方程 $g(t) = t + \int_0^t g(t-s)3e^{-2s}ds$ 的局部有界解.

16.4 求 $\mathbb{P}(A(t) \geq x)$, $\mathbb{E}(A(t))$ 以及 $\mathbb{P}(L(t) \geq x)$, $\mathbb{E}(L(t))$.

16.5 设 N 是强度为 λ 的泊松过程, 试计算其在时刻 t 时年龄 $A(t)$ 、剩余寿命 $R(t)$ 以及总寿命 $L(t)$ 的数学期望.

16.6 设 N 是更新过程, 等待时间分布期望为 μ , 证明 $\mathbb{E}(T_{N(t)+1}) = \mu(1 + m(t))$.

16.7* 设 F 是步长为 d 的格子点分布, $m(t)$ 是 F 的更新函数, 证明 $m(t)$ 是阶梯函数, 跳跃点 t 必能被 d 整除, 而且存在充分大的 N , 当 $n > N$ 时 nd 是跳跃点.

5.2 更新极限定理

上一节我们对更新过程与更新函数的趋势作了简单介绍, 下面我们研究更新过程极限的更精细性质并简要说明这些性质的应用.

5.2.1 大数定律与中心极限定理

定理17.1 对更新过程 $N = \{N(t); t \geq 0\}$

$$\lim_{t \rightarrow \infty} \frac{N(t)}{t} = \frac{1}{\mu}, \quad a.s.$$

其中 $\mu = \infty$ 时 $1/\mu$ 为 0.

证明 由 T_n 的定义可知 $T_{N(t)} \leq t < T_{N(t)+1}$, 从而

$$\frac{T_{N(t)}}{N(t)} \leq \frac{t}{N(t)} \leq \frac{T_{N(t)+1}}{N(t)} = \frac{T_{N(t)+1}}{N(t)+1} \frac{N(t)+1}{N(t)}. \quad (5.2.1)$$

注意到 $N(t) \rightarrow \infty$, a.s. 以及 $T_n/n \rightarrow \mu$, a.s. 由习题4.2可知

$$\lim_{t \rightarrow \infty} \frac{T_{N(t)}}{N(t)} = \mu, \quad , a.s.$$

将此结果应用于(5.2.1)两边得 $t/N(t) \rightarrow \mu$, a.s. 从而 $N(t)/t \rightarrow 1/\mu$, a.s. \square

通常称 $1/\mu$ 为更新过程的速率.

例17.1 假设伯努利实验中成功的概率为 p , 失败的概率为 $q = 1 - p$, 连续做若干次实验直至连续成功 k 次或连续失败 k 次为此, 问平均实验次数.

[分析] 以连续成功或连续失败 k 次为一次计数事件 A , 假定伯努利实验在计数事件 A 发生后从新开始, 以 $N(n)$ 表示到第 n 次实验时事件 A 出现的次数, 那么 N 是一个更新过程. 若以连续成功 k 次为一次计数事件 B , 以 $N_1(n)$ 表示到第 n 次实验时事件 B 出现的次数, 那么 N_1 也是一个更新过程; 同样以连续失败 k 次为一次计数事件 C , 以 $N_2(n)$ 表示到第 n 次实验时事件 C 出现的次数, 那么 N_2 也是一个更新过程. 显然 $N = N_1 + N_2$. 由定理13.1, N 的更新速率为 N_1 , N_2 的更新速率之和.

解: 如上述分析建立更新过程 N, N_1, N_2 . 由习题2.3可知 N_1, N_2 的平均等待时长分别为

$$\mu_1 = \frac{1-p^k}{p^k(1-p)}, \quad \mu_2 = \frac{1-q^k}{q^k(1-q)}.$$

因此 N 的更新速率为

$$\frac{1}{\mu} = \frac{p^k(1-p)}{1-p^k} + \frac{q^k(1-q)}{1-q^k}.$$

所以平均实验次数为

$$\mu = \frac{(1-p^k)(1-q^k)}{pq(p^{k-1} + q^{k-1} - p^{k-1}q^{k-1})}. \quad \square$$

定理17.2 设更新过程 $N = \{N(t); t \geq 0\}$ 满足条件

$$\mathbb{E}(W_1) = \mu < \infty, \text{Var}(W_1) = \sigma^2 < \infty,$$

则对一切实数 y ,

$$\lim_{t \rightarrow \infty} \mathbb{P}\left(\frac{N(t) - t/\mu}{\sigma \sqrt{t/\mu^3}} \leq y\right) = \Phi(y),$$

其中 $\Phi(y)$ 是标准正态分布函数.

证明 令 $r_t = t/\mu + y\sigma\sqrt{t/\mu^3}$, $\hat{r}_t = [r_t] + 1$, 则

$$\begin{aligned} \mathbb{P}\left(\frac{N(t) - t/\mu}{\sigma \sqrt{t/\mu^3}} \leq y\right) &= \mathbb{P}(N(t) \leq [r_t]) = \mathbb{P}(N(t) < \hat{r}_t) \\ &= \mathbb{P}(T_{\hat{r}_t} > t) = \mathbb{P}\left(\frac{T_{\hat{r}_t} - \hat{r}_t \mu}{\sigma \sqrt{\hat{r}_t}} > \frac{t - \hat{r}_t \mu}{\sigma \sqrt{\hat{r}_t}}\right). \end{aligned}$$

注意到 $\hat{r}_t \rightarrow \infty$,

$$\lim_{t \rightarrow \infty} \frac{t - \hat{r}_t \mu}{\sigma \sqrt{\hat{r}_t}} = \lim_{t \rightarrow \infty} \frac{-y\sigma\sqrt{t/\mu}}{\sigma\sqrt{t/\mu + y\sigma\sqrt{t/\mu^3}}} = -y,$$

以及

$$\frac{T_{\hat{r}_t} - \hat{r}_t \mu}{\sigma \sqrt{\hat{r}_t}} = \frac{1}{\sigma \sqrt{\hat{r}_t}} \sum_{k=1}^{\hat{r}_t} (W_k - \mu),$$

由中心极限定理可知结论成立. \square

例17.2 一台机器相继不间断地加工某一种零件, 假定加工一件零件的时间服从1到3分钟的均匀分布, 估计100个小时内以0.95的概率至少可加工的零件个数.

解: 以分为时间单位, 加工一件零件时间的均值为2, 方差为1/3. 以 $N(t)$ 表示到 t 时刻加工完成的零件数. 由定理17.2, 当 t 很大时 $N(t)$ 近似服从均值为 $t/2$, 方差为 $t/24$ 的正态分布. 设所求零件个数为 x , 那么

$$0.95 = \mathbb{P}(N(6000) > x) = \mathbb{P}\left(\frac{N(6000) - 3000}{\sqrt{6000/24}} > \frac{x - 3000}{5\sqrt{10}}\right) \approx 1 - \Phi\left(\frac{x - 3000}{5\sqrt{10}}\right).$$

由此可知 $x \approx 3000 - 1.64 \times 5\sqrt{10} \approx 2974$. \square

5.2.2 更新定理

下面的所谓关键更新定理是我们研究更新方程局部有界解极限的重要工具.

定理17.3 设 F 为非负随机变量的分布函数, 期望为 μ (可以是 ∞), $m(t)$ 是 F 的更新函数. $h(t)$ 是 $[0, \infty)$ 上非负可积函数. B 是更新方程的局部有界解,

$$B(t) = h(t) + \int_0^t B(t-s) dF(s) = h(t) + \int_0^t h(t-s) dm(s). \quad (5.2.2)$$

(1) 如果 F 是步长为 d 的格子点分布, 那么对任意 $0 \leq c < d$,

$$\lim_{n \rightarrow \infty} B(c + nd) = \begin{cases} d \sum_{n=0}^{\infty} h(c + nd)/\mu, & \mu < \infty \\ 0, & \mu = \infty \end{cases}.$$

(2) 若 F 具有局部有界密度函数且存在 $M > 0$ 使得 $h(t)$ 在 $[M, \infty)$ 上单调不增, 那么

$$\lim_{t \rightarrow \infty} B(t) = \lim_{t \rightarrow \infty} \int_0^t h(t-s) dm(s) = \frac{1}{\mu} \int_0^{\infty} h(s) ds,$$

其中若 $\mu = \infty$, 上式右端理解为 0.

证明* (1) 当 F 是步长为 d 的格子点分布时, 由更新方程, 对任意 $n \geq 1$

$$B(c + nd) = h(c + nd) + \sum_{k=0}^n B(c + (n-k)d)\nu(kd),$$

其中 $\nu(kd) = F(kd) - F((k-1)d) = \mathbb{P}(X = kd)$. 为方便, 对任意 $n \geq 0$, 记

$$a_n = B(c + nd), \quad b_n = h(c + nd), \quad u_n = \nu(nd).$$

则

$$a_n = b_n + \sum_{k=0}^n a_{n-k} u_k. \quad (5.2.3)$$

注意, 由 u_k 的定义及条件可知, 存在 m_1, m_2, \dots, m_r 使得

$$u_{m_1}, \dots, u_{m_r} > 0 \text{ 且 } m_1, \dots, m_r \text{ 互素.}$$

由习题 1.9, 存在正整数 J , 对任意正整数 $j \geq J$ 存在非负整数 l_1, \dots, l_r , 使得

$$j = l_1 m_1 + l_2 m_2 + \dots + l_r m_r. \quad (5.2.4)$$

下面我们将证明分三步.

第一步, 证明 $\{a_n\}$ 为有界数列.

注意到 $\sum_{k=0}^{\infty} u_k = 1$, $u(0) < 1$, 令

$$c_n = \frac{\sum_{k=0}^n |b_k|}{1 - u_0}, \quad n \geq 0, \quad c_{-1} = 0.$$

由 h 的假设条件可知

$$\sum_{k=0}^{\infty} |b_k| = \sum_{k=0}^{\infty} |h(c + kd)| < \infty.$$

注意到 c_k 为单调增加数列, 由数学归纳法容易证明, 对任意 $n \geq 0$,

$$|a_n| \leq \frac{|b_n|}{1 - u_0} + c_{n-1} = c_n.$$

因此 $\{a_n\}$ 为有界数列. 记 $M = \sup_{n \geq 0} |a_n|$.

$$\text{第二步, 证明 } \limsup_{n \rightarrow \infty} a_n \leq \begin{cases} d \sum_{n=0}^{\infty} h(c + nd)/\mu, & \mu < \infty, \\ 0, & \mu = \infty. \end{cases}$$

为此记 $l = \limsup_{n \rightarrow \infty} a_n$. 此时存在 $n_i \rightarrow \infty$ 使得 $a_{n_i} \rightarrow l$. 任取 m_k , $1 \leq k \leq r$, 若 $n_i \rightarrow$

∞ 时 $a_{n_i-m_k} \not\rightarrow l$, 那么存在 $l' < l$ 以及无穷多个 i 使得 $a_{n_i-m_k} \leq l'$. 令 $\varepsilon = u_{m_k}(l - l')/4$.

由 $\sum_{k=0}^{\infty} u_k = 1$ 可知存在 $N > m_k$, 当 $n \geq N$ 时

$$\sum_{k=n}^{\infty} u_k < \varepsilon/M$$

进而存在 $n_j \geq N$ 使得

$$a_{n_j} > l - \varepsilon, \quad a_{n_j-m_k} < l', \quad |b_{n_j}| \leq \varepsilon$$

而且对一切 $n \geq n_j - N$, $a_n \leq l + \varepsilon$ 成立. 此时

$$\begin{aligned} a_{n_j} &\leq \sum_{k=0}^{n_j} a_{n_j-k} u_k + \varepsilon < \sum_{k=0}^N a_{n_j-k} u_k + M \sum_{k=N+1}^{n_j} u_k + \varepsilon \\ &< (1 - u_{m_k})(l + \varepsilon) + u_{m_k} l' + 2\varepsilon \\ &< l + 3\varepsilon - u_{m_k}(l - l') = l - \varepsilon. \end{aligned}$$

矛盾表明 $\lim_{n_i \rightarrow \infty} a_{n_i-m_k} = l$. 进一步反复使用以上方法可得对任意非负整数 l_1, \dots, l_k ,

$$\lim_{n_i \rightarrow \infty} a_{n_i - \sum_{k=1}^r l_k m_k} = l.$$

由(5.2.4)可知, 对任意 $j \geq J$, $\lim_{n_i \rightarrow \infty} a_{n_i-j} = l$. 记 $n'_i = (n_i - J) \vee 1$, 对任意 $j \geq 0$,

$$\lim_{n'_i \rightarrow \infty} a_{n'_i-j} = l.$$

令 $U_n = \sum_{k=n+1}^{\infty} u_k$, 由关系式 $u_k = U_{k-1} - U_k$ 以及 $U_{-1} = 1$, (5.2.3) 可改写为

$$U_0 a_n + U_1 a_{n-1} + \dots + U_n a_0 = U_0 a_{n-1} + U_1 a_{n-2} + \dots + U_{n-1} a_0 + b_n, \quad n \geq 1.$$

记 $A_n = \sum_{k=0}^n U_k a_{n-k}$, 那么 $A_0 = b_0$ 且 $A_n = A_{n-1} + b_n$, 进而 $A_n = \sum_{k=0}^n b_k$. 因此对任意 N ,

$$U_0 a_{n'_i} + \dots + U_N a_{n'_i-N} \leq A_{n'_i} \leq \sum_{k=0}^{\infty} |b_k|.$$

先令 $n'_i \rightarrow \infty$ 再令 $N \rightarrow \infty$ 并注意到 $\sum_{k=0}^{\infty} U_k = \sum_{k=1}^{\infty} k u_k$ 得

$$l \leq \frac{\sum_{k=0}^{\infty} b_k}{\sum_{k=1}^{\infty} k u_k} = \begin{cases} d \sum_{n=0}^{\infty} h(c + nd)/\mu, & \mu < \infty, \\ 0, & \mu = \infty. \end{cases}$$

第三步, 证明 $\liminf_{n \rightarrow \infty} a_n \geq$

$$\begin{cases} d \sum_{n=0}^{\infty} h(c + nd)/\mu, & \mu < \infty, \\ 0, & \mu = \infty. \end{cases}$$

令 $\underline{l} = \liminf_{n \rightarrow \infty} a_n$, 由第二步的类似讨论同样可知存在 n_i 使得对任意 $k \geq 0$,

$$a_{n_i-k} \rightarrow \underline{l}.$$

记 $g(N) = \sum_{k=N+1}^{\infty} U_k$, 由 $\mu = \sum_{k=0}^{\infty} U_k < \infty$ 可知 $g(N) \rightarrow 0$. 注意到

$$\sum_{k=0}^{n_i} b_k = \sum_{k=0}^{n_i} U_k a_{n_i-k} \leq \sum_{k=0}^N U_k a_{n_i-k} + g(N)M.$$

先令 $n_i \rightarrow \infty$ 再令 $N \rightarrow \infty$ 得

$$\underline{l} \geq \frac{\sum_{k=0}^{\infty} b_n}{\sum_{k=1}^{\infty} k u_k} = \begin{cases} d \sum_{n=0}^{\infty} h(c+nd)/\mu, & \mu < \infty, \\ 0, & \mu = \infty. \end{cases}$$

综合第二、三两步的结果可知(1)成立.

(2) 此时证明更复杂, 此略 □

注17.1 事实上(2)对一切非格子点分布都成立.

注17.2 在(1)证明中我们得到了如下结果:

若数列 $\{b_n\}$ 和非负数列 $\{a_n\}, \{c_n\}$ 满足

$$(1) \sum_{n=0}^{\infty} |b_n| < \infty,$$

(2) $\sum_{n=0}^{\infty} c_n = 1$ 且数集 $\{n \geq 1, c_n > 0\}$ 的最大公因子为1,

$$(3) \text{ 对任意 } n \geq 0, a_n = b_n + \sum_{k=0}^n a_{n-k} c_k.$$

那么

$$\lim_{n \rightarrow \infty} a_n = \frac{\sum_{n=0}^{\infty} b_n}{\sum_{n=1}^{\infty} n c_n},$$

其中商式分母为 $+\infty$ 时取值为0.

例17.3 设 X 是以 $P = (p_{i,j})_{i,j \in S}$ 为转移概率的马氏链, 若 j 非周期常返, 证明

$$\lim_{n \rightarrow \infty} p_{i,j}^{(n)} = \begin{cases} 0, & j \text{ 是零常返,} \\ f_{ij}/m_{jj}, & j \text{ 是正常返.} \end{cases}$$

证明 注意到对任意 $n \geq 1$,

$$\begin{aligned} p_{i,j}^{(n)} &= \mathbb{P}_i(X_n = j) = \mathbb{P}_i(X_n = j, X_{n-1} = j) + \mathbb{P}_i(X_n = j, X_{n-1} \neq j) \\ &= \sum_{k=1}^n \mathbb{P}_i(X_n = j, X_k = j, X_v \neq j, v = k+1, \dots, n-1) \\ &\quad + \mathbb{P}_i(X_n = j, X_v \neq j, v = 1, \dots, n-1) \\ &= f_{ij}^{(n)} + \sum_{k=1}^{n-1} p_{i,j}^{(k)} f_{jj}^{(n-k)} = f_{ij}^{(n)} + \sum_{k=1}^{n-1} p_{i,j}^{(n-k)} f_{jj}^{(k)} \end{aligned}$$

对 $n \geq 1$, 令 $a_n = p_{i,j}^{(n)}$, $b_n = f_{ij}^{(n)}$, $c_n = f_{jj}^{(n)}$, 并约定 $a_0 = b_0 = c_0 = 0$, 那么由 j 非周期常返可知 $\sum_{n=0}^{\infty} c_n = 1$ 以及集合 $\{n : c_n > 0\}$ 中所有元素的最大公因子为1(参见习题9.7). 容易验证注

记17.1中其他两条件对 $\{a_n\}, \{b_n\}$ 也成立, 因此

$$\lim_{n \rightarrow \infty} p_{i,j}^{(n)} = \lim_{n \rightarrow \infty} a_n = \frac{\sum_{n=0}^{\infty} b_n}{\sum_{n=1}^{\infty} n c_n} = \frac{\sum_{n=0}^{\infty} f_{ij}^{(n)}}{\sum_{n=1}^{\infty} n f_{jj}^{(n)}} = \begin{cases} 0, & j \text{是0常返,} \\ f_{ij}/m_{jj}, & j \text{是正常返.} \end{cases} \quad \square$$

推论17.4(初等更新定理) $\lim_{t \rightarrow \infty} m(t)/t = 1/\mu$.

证明 当 F 是连续分布时, 对任意 $a > 0$, 令 $h(s) = \mathbf{1}_{[0,a]}(s)$, 那么 $h(s)$ 为非负单调不增函数, 由关键更新定理可知

$$\lim_{t \rightarrow \infty} (m(t) - m(t-a)) = \lim_{t \rightarrow \infty} \int_0^t h(t-s) dm(s) = \frac{a}{\mu}$$

从而对任意非负整数 N ,

$$\lim_{N \rightarrow \infty} \frac{m(N)}{N} = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N (m(k) - m(k-1)) = \frac{1}{\mu_F}.$$

又因为 $m(t)$ 单调不降, 由

$$\frac{m([t])}{t} \leq \frac{m(t)}{t} \leq \frac{m([t]+1)}{t}$$

可得推论成立.

当 F 是格子点分布的时, 利用习题17.7的结论, 同样可证明推论成立. 细节请读者自己补充. \square

例17.4 设更新过程 N 的等待时间分布 F 连续且均值 μ 与方差 σ^2 都有限. $L(t)$ 是 N 在时刻 t 的总寿命, 求 $\lim_{t \rightarrow \infty} \mathbb{E}(L(t))$.

解 由习题16.3可知,

$$\mathbb{E}(L(t)) = \int_t^\infty s dF(s) + \int_0^t \int_{t-s}^\infty u dF(u) dm(s).$$

令 $h(t) = \int_t^\infty s dF(s)$. 显然 $h(t)$ 是单调不增的. 而且由于 F 均值 μ 与方差 σ^2 都有限,

$$\int_0^\infty h(t) dt = \int_0^\infty \int_t^\infty u dF(u) dt = \int_0^\infty u^2 dF(u) = \sigma^2 + \mu^2 < \infty.$$

因此由关键更新定理可得

$$\lim_{t \rightarrow \infty} \mathbb{E}(L(t)) = \frac{\int_0^\infty h(t) dt}{\mu} = \mu + \frac{\sigma^2}{\mu}. \quad \square$$

上例计算结果表明, 随着 $t \rightarrow \infty$, t 时刻总寿命的均值收敛到一个严格大于平均等待时间的极限. 这从另外一个角度验证了我们在上节中提到的长度偏离取样或检验悖论现象.

例17.5 设顾客按强度为 λ 的泊松过程来到某个只有一个服务窗口的服务台, 设服务台服务每个顾客所需时间是独立同分布的连续随机变量, 分布为 G , 期望为 $1/\mu$, 其中 $\mu > \lambda$. 若顾客到达发现需要等待则立刻离开, 否则接受服务; 问长时间后系统空闲的比例.

[分析] 从0时间开始观察, 那么服务台空闲、忙碌再空闲, 这样周而复始. 记第*i*个周期中的忙碌时长为 Y_i , 空闲时长为 U_i . 由假设可知 Y_i 就是第*i*个顾客的服务时间, 相互独立

且 $\mathbb{E}(Y_i) = 1/\mu$; U_i 就是从第 $i - 1$ 个顾客服务完到第 i 个顾客到达的时间间隔, 由指数分布的无记忆性, U_i 服从参数为 λ 的指数分布, $\mathbb{E}(U_i) = 1/\lambda$. 若以一个空闲与忙碌为周期, 那么观察到的服务系统就是一个更新过程. 更新系统的一个等待时长为 $W_i = Y_i + U_i$, 平均等待间长为 $1/\lambda + 1/\mu$. 令 $A_t = \{t\text{时刻系统空闲}\}$, 所求比例为 $\lim_{t \rightarrow \infty} \mathbb{P}(A_t)$.

解 如上定义 Y_i, U_i, W_i . 记 W_i 的分布为 F . 则 F 是均值为 $1/\mu + 1/\lambda$ 的连续分布. 那么

$$\begin{aligned} f(t) := \mathbb{P}(A_t) &= \mathbb{E}(\mathbb{P}(A_t|T_1)) = \int_0^\infty \mathbb{P}(A_t|T_1=s)dF(s) \\ &= \int_t^\infty \mathbb{P}(U_1 > t|W_1=s)dF(s) + \int_0^t \mathbb{P}(A_{t-s})dF(s) \end{aligned}$$

注意到 $\int_t^\infty \mathbb{P}(U_1 > t|W_1=s)dF(s) = \mathbb{P}(U_1 > t, W_1 > t) = \mathbb{P}(U_1 > t)$, 因此

$$f(t) = \mathbb{P}(U_1 > t) + \int_0^t f(t-s)dF(s).$$

由关键更新定理,

$$\lim_{t \rightarrow \infty} f(t) = \frac{\int_0^\infty \mathbb{P}(U_1 > t)dt}{1/\lambda + 1/\mu} = \frac{\mu}{\lambda + \mu}. \quad \square$$

练习题

17.1 两台机器独立不间断地加工零件, 若其中一台加工零件的时间服从参数为 $1/2$ 的指数分布, 另外一台服从 $(0, 4)$ 上的均匀分布, 求到时间 $t = 100$ 时两台机器一起至少加工 90 个零件的概率估计.

17.2 设 N 是等待时间分布为连续分布的更新过程, 平均等待时间为 μ , $A(t)$ 表示在时刻 t 的年龄, 对任意 $c > 0$, 问长时间后事件 $\{A(t) < c\}$ 发生的概率.

17.3 令 $L(t)$ 表示时刻 t 更新过程的总寿命, 若平均等待时间 $\mu < \infty$, 证明 $\lim_{t \rightarrow \infty} L(t)/t = 0$ 几乎必然成立.

17.4 设更新过程 N 的等待时间分布 F 连续且均值 μ 与方差 σ^2 都有限, 证明 $\lim_{t \rightarrow \infty} (m(t) - t/\mu) = (\sigma^2 - \mu^2)/2\mu^2$.

17.5 设更新过程 N 的等待时间分布 F 连续且均值 μ 与方差 σ^2 都有限. $A(t)$ 是 N 在时刻 t 的年龄, 求 $\lim_{t \rightarrow \infty} \mathbb{E}(A(t))$.

17.6 设 $g(t)$ 是积分方程 $G(t) = e^{-t} + \int_0^t G(t-s)e^{-2s}ds$ 的最小非负解, 求 $\lim_{t \rightarrow \infty} g(t)$. ([提示] 注意关键更新定理条件)

17.7* 设 F 是步长为 d 的格子点分布, 数学期望为 μ , $m(t)$ 是以 F 为等待时间分布的更新函数, 证明

$$\lim_{n \rightarrow \infty} [m(nd) - m((n-1)d)] = d/\mu.$$

5.3 两类广义更新过程

更新过程可做很多推广, 本节简要介绍有偿更新过程与可终止更新过程.

5.3.1 有偿更新过程

定义18.1 设 $\{(W_n, Y_n), n \geq 1\}$ 为独立同分布的二维随机变量序列, $W_n \geq 0$, N 是以 $\{W_n\}$ 为等待时间序列的更新过程, 对任意 $t \geq 0$, 令

$$X(t) = \sum_{n=1}^{N(t)} Y_n,$$

称 $X = \{X(t), t \geq 0\}$ 为有偿更新过程. 若 N 为Poisson过程, $\{Y_n, n \geq 1\}$ 与 $\{W_n, n \geq 1\}$ 独立, 则称 X 为复合泊松过程.

定理18.1 设 X 为有偿更新过程, $\mathbb{E}(W_1) < \infty$, $\mathbb{E}|Y_1| < \infty$, 则

$$\lim_{t \rightarrow \infty} \frac{X(t)}{t} = \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)}, \quad \text{a.s. 而且 } \lim_{t \rightarrow \infty} \frac{\mathbb{E}(X(t))}{t} = \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)}.$$

证明 由强大数定理及 $N(t) \rightarrow \infty$, a.s. 可知

$$\frac{X(t)}{t} = \frac{\sum_{k=1}^{N(t)} Y_k}{N(t)} \frac{N(t)}{t} \rightarrow \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)}, \quad \text{a.s.}$$

定理前半部分极限成立. 对后半部分极限, 注意到

$$\begin{aligned} \mathbb{E}\left(\sum_{k=1}^{N(t)+1} Y_k\right) &= \sum_{k=1}^{\infty} \mathbb{E}\left(\sum_{i=1}^k Y_i \mathbf{1}_{\{N(t)+1=k\}}\right) = \sum_{k=1}^{\infty} \sum_{i=1}^k \mathbb{E}\left(Y_i \mathbf{1}_{\{\sum_{n=1}^{k-1} W_n \leq t, \sum_{n=1}^k W_n > t\}}\right) \\ &= \sum_{i=1}^{\infty} \sum_{k=i}^{\infty} \mathbb{E}\left(Y_i \mathbf{1}_{\{\sum_{n=1}^{k-1} W_n \leq t, \sum_{n=1}^k W_n > t\}}\right) \\ &= \sum_{i=1}^{\infty} \mathbb{E}\left(Y_i - Y_i \sum_{k=1}^{i-1} \mathbf{1}_{\{\sum_{n=1}^{k-1} W_n \leq t, \sum_{n=1}^k W_n > t\}}\right). \end{aligned}$$

由 $\{(W_n, Y_n), n \geq 1\}$ 的独立同分布性可得

$$\begin{aligned} \mathbb{E}\left(\sum_{k=1}^{N(t)+1} Y_k\right) &= \sum_{i=1}^{\infty} \mathbb{E}(Y_i) \left(1 - \sum_{k=1}^{i-1} \mathbb{P}\left(\sum_{n=1}^{k-1} W_n \leq t, \sum_{n=1}^k W_n > t\right)\right) \\ &= \sum_{i=1}^{\infty} \mathbb{E}(Y_i) (1 - \mathbb{P}(N(t) + 1 \leq i - 1)) = \sum_{i=1}^{\infty} \mathbb{E}(Y_i) \mathbb{P}(N(t) + 1 \geq i) \\ &= \mathbb{E}(Y_1) \sum_{i=1}^{\infty} \mathbb{P}(N(t) + 1 \geq i) = \mathbb{E}(Y_1)(1 + m(t)). \end{aligned} \tag{5.3.1}$$

进而

$$\lim_{t \rightarrow \infty} \frac{1}{t} \mathbb{E}\left(\sum_{i=1}^{N(t)+1} Y_i\right) = \lim_{t \rightarrow \infty} \frac{g(t)}{t} = \mathbb{E}(Y_1) \lim_{t \rightarrow \infty} \frac{1 + m(t)}{t} = \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)}.$$

另一方面,

$$\begin{aligned}\mathbb{E}(Y_{N(t)+1}) &= \int_0^\infty \mathbb{E}(Y_{N(t)+1}|T_1=s)dF(s) \\ &= \int_t^\infty \mathbb{E}(Y_1|W_1=s)dF(s) + \int_0^t \mathbb{E}(Y_{N(t-s)+1})dF(s).\end{aligned}$$

记 $B(t) = \mathbb{E}(Y_{N(t)+1})$, $b(t) = \int_t^\infty \mathbb{E}(Y_1|W_1=s)dF(s)$, 则

$$B(t) = b(t) + \int_0^t B(t-s)dF(s).$$

由 $|b(t)| \leq \int_0^\infty \mathbb{E}(|Y_1||W_1=s)dF(s) = \mathbb{E}(|Y_1|) < \infty$ 可知 $b(t)$ 为局部有界函数, 且由(5.3.1)易知 $B(t)$ 也是局部有界函数, 因此

$$B(t) = b(t) + \int_0^t b(t-s)dm(s).$$

又由 $t \rightarrow \infty$ 时 $b(t) \rightarrow 0$ 可知, 对任意 $\varepsilon > 0$, 存在 T , 当 $t > T$ 时, $|b(t)| \leq \varepsilon$. 所以

$$\begin{aligned}0 \leq \frac{1}{t} \int_0^t |b(t-s)|dm(s) &= \frac{1}{t} \left[\int_0^{t-T} + \int_{t-T}^t \right] |b(t-s)|dm(s) \\ &\leq \varepsilon \frac{m(t-T)}{t} + \mathbb{E}(|Y_1|) \frac{m(t) - m(t-T)}{t}.\end{aligned}$$

先令 $t \rightarrow \infty$ 再令 $\varepsilon \rightarrow 0$, 由推论17.4可得

$$\lim_{t \rightarrow \infty} \frac{B(t)}{t} = 0.$$

最后注意到 $\mathbb{E}(X(t)) = \mathbb{E}\left(\sum_{i=1}^{N(t)+1} Y_i\right) - \mathbb{E}(Y_{N(t)+1})$, 综合以上结果可得

$$\lim_{t \rightarrow \infty} \frac{\mathbb{E}(X(t))}{t} = \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)}. \quad \square$$

例18.1 设手机寿命为 Z 年, Z 服从连续分布 H . 某人使用手机, 若原来手机用了 T 年还没坏则花 C 元换一部新手机, 若在 T 年前损坏, 则用 D 元换新手机. 问长时间后, 此人平均每年多少钱用于手机更换?

解 可用有偿更新过程来描述这一问题, 令 $W_n = Z_n \wedge T = \min\{Z_n, T\}$, 其中 Z_n 表示第 n 部手机的寿命, N 为以 $\{W_n\}$ 为更新时间的更新过程,

$$Y_n = C\mathbf{1}_{\{W_n=T\}} + D\mathbf{1}_{\{W_n < T\}}$$

为第 n 次手机更新的费用, 那么在时刻 t 之前总的手机更新费用为

$$X(t) = \sum_{i=1}^{N(t)} Y_i$$

平均费用为

$$\lim_{t \rightarrow \infty} \frac{X(t)}{t} = \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)} = \frac{C + (D - C)H(T-)}{\int_0^T \bar{H}(x)dx},$$

其中 $H(T-) = \mathbb{P}(W_n < T)$. \square

例18.2 设顾客按强度为 λ 的泊松过程来到某个只有一个服务窗口的服务台, 设服务台服务每

个顾客所需时间是独立同分布的随机变量, 分布为 G , 期望为 $1/\mu$, $\mu > \lambda$, 不论顾客到达后是否需要等待, 顾客都在接受服务后才离开. 问长时间后顾客到达即可接受服务的平均概率.

解 可用有偿更新过程来描述所讨论问题. 假定系统从第一个顾客到达开始, 显然服务台按“工作”和“空闲”两种状态更新循环运行. 以 X_i 表示第*i*次系统忙的时长, Y_i 表示第*i*次系统闲的时长, 那么 $W_i = X_i + Y_i$ 就是系统一个服务周期的时长. 按假定, (X_i, Y_i) 为独立同分布的二维随机变量. 特别 Y_i 为第*i*个忙期结束到下一个顾客到达的时间, 由题设, 服从参数为 λ 的指数分布. 在 $[0, t]$ 时段内, 顾客到达即能接受服务的时长为

$$T(t) = \sum_{k=1}^{N(t)} Y_k + (t - T_{N(t)} - X_{N(t)+1}) \mathbf{1}_{\{t > T_{N(t)} + X_{N(t)+1}\}}$$

其中 N 为以 $\{W_i\}$ 为更新时间的更新过程, 上式右边后一项表示第 $N(t) + 1$ 个服务周期中在*t*之前的空闲时间. 显然

$$\sum_{i=1}^{N(t)} Y_i \leq T(t) \leq \sum_{i=1}^{N(t)+1} Y_i.$$

因此所求平均概率总有

$$\lim_{t \rightarrow \infty} \frac{T(t)}{t} = \frac{\mathbb{E}(Y_1)}{\mathbb{E}(W_1)} = \frac{1/\lambda}{\mathbb{E}(X_1) + 1/\lambda}.$$

以 U 表示服务第一个顾客的时间, V 表示服务第一个顾客时到达的顾客数. 显然 U 服从 G 分布, 而 V 为强度为 λ 的泊松过程在 $[0, U]$ 时间内粒子到达数. 所以

$$\mathbb{E}(U) = \frac{1}{\mu}, \quad \mathbb{E}(V) = \int_0^\infty \lambda u dG(u) = \frac{\lambda}{\mu}.$$

由于服务顾客是独立同分布的, $\mathbb{E}(X_1|U, V) = U + V\mathbb{E}(X_1)$, 进而

$$\mathbb{E}(X_1) = \mathbb{E}(U) + \mathbb{E}(X_1)\mathbb{E}(V) = \frac{1}{\mu} + \mathbb{E}(X_1)\frac{\lambda}{\mu}.$$

由此可得 $\mathbb{E}(X_1) = 1/(\mu - \lambda)$. 所以

$$\lim_{t \rightarrow \infty} \frac{T(t)}{t} = 1 - \frac{\lambda}{\mu}. \quad \square$$

例18.3 设保险公司理赔事件发生服从强度为 λ 的Poisson过程, 每次理赔金额 Y_i 服从参数为 μ 的指数分布且相互独立. 设公司初始资本为 x , 单位时间内的保费收入为 c . 问该公司永不破产的概率?(公司破产就是指公司净值产为负). 假定 $c > \lambda/\mu$.

解 在时间区间 $[0, t]$ 内, 公司需支付的理赔费用为 $\sum_{i=1}^{N(t)} Y_i$, 从而*t*时刻公司资产为

$$W(t) = x + ct - \sum_{i=1}^{N(t)} Y_i.$$

公司永不破产的概率

$$B(x) = \mathbb{P}(W(t) \geq 0, t \geq 0) = \mathbb{P}(x + ct - \sum_{i=1}^{N(t)} Y_i \geq 0, t \geq 0),$$

并约定 $B(x) = 0, x < 0$. 那么由全概率公式

$$B(x) = \int \mathbb{P}(W(t) \geq 0, t \geq 0 | W_1 = s, Y_1 = y) dH(s, y),$$

其中 $H(s, y)$ 为 (W_1, Y_1) 的联合分布. 显然

$$\mathbb{P}(W(t) \geq 0, t \geq 0 | W_1 = s, Y_1 = y) = \begin{cases} 0, & y > x + cs, \\ B(x + cs - y), & y \leq x + cs. \end{cases}$$

由假设 $dH(s, y) = \lambda e^{-\lambda s} \mu e^{-\mu y} ds dy$, 因此

$$\begin{aligned} B(x) &= \int_0^\infty \lambda e^{-\lambda s} ds \int_0^{x+cs} B(x + cs - y) \mu e^{-\mu y} dy \\ &= \int_x^\infty \frac{\lambda}{c} e^{-\frac{\lambda}{c}(u-x)} du \int_0^u B(u - y) \mu e^{-\mu y} dy. \end{aligned}$$

两边关于 x 求导得

$$B'(x) = \frac{\lambda}{c} B(x) - \frac{\lambda}{c} \int_0^x B(y) \mu e^{-\mu(x-y)} dy, \quad (5.3.2)$$

进一步关于 x 求导, 整理得 $(\frac{\lambda}{c} - \mu) B'(x) = B''(x)$. 由此可得

$$B(x) = b + \frac{a}{\frac{\lambda}{c} - \mu} e^{(\frac{\lambda}{c} - \mu)x},$$

其中 a, b 为待定常数. 由定理 14.1 可知

$$\lim_{t \rightarrow \infty} \frac{W(t)}{t} = c - \frac{\lambda}{\mu} > 0,$$

从而 $\lim_{x \rightarrow \infty} B(x) = 1$ (证明省略). 因此

$$B(x) = 1 + \frac{a}{\frac{\lambda}{c} - \mu} e^{(\frac{\lambda}{c} - \mu)x},$$

将其代入方程 (5.3.2) 得 $a = -\frac{\lambda}{c\mu} (\frac{\lambda}{c} - \mu)$. 所以

$$B(x) = 1 - \frac{\lambda}{c\mu} e^{(\frac{\lambda}{c} - \mu)x}. \quad \square$$

5.3.2 可终止更新过程

定义 18.2 若更新过程等待时间分布 F 以正概率取 $+\infty$, 那么我们称此更新过程为可终止更新过程.

为了叙述简单, 与注 16.1 一样我们仍要求等待时间分布 F 在 $[0, \infty)$ 内或者有局部有界的导函数或者是阶梯函数且跳跃点包含在形如 $\{nd, n \geq 0\}$ 的集合中. 前者类似连续分布, 后者类似格子点分布.

例 18.4 设 j 是马氏链 X 的非常返状态, $N(t)$ 表示从 j 出发的马氏链 X 到时刻 t 为止回到状态 j 的次数, 那么 $N(t)$ 就是可终止更新过程.

由定义可知可终止更新过程仍有更新性, 其更新函数 $m(t) = \mathbb{E}(N(t))$ 仍满足更新方程

$$m(t) = F(t) + \int_0^t m(t-s)dF(s),$$

并且更新方程

$$B(t) = b(t) + \int_0^t B(t-s)dF(s)$$

的局部有界解仍可表示成

$$B(t) = b(t) + \int_0^t b(t-s)dm(s).$$

但对可终止更新过程而言, 在某次事件发生后会以正概率不再有事件发生. 记这最后一次事件发生的时刻为 ξ , 即

$$\xi = \sup\{T_n; T_n < \infty, n \geq 0\}.$$

那么 $N(\infty) = N(\xi)$ 就是更新事件发生的总次数.

定理18.2 设 $p = F(\infty)$, 即 $1 - p$ 是 F 在 $+\infty$ 的概率. 对以 F 为等待时间分布的可终止更新过程 N 而言,

$$\mathbb{P}(\xi \leq t) = (1-p)(1+m(t)), \quad \mathbb{P}(N(\infty) = k) = p^k(1-p), \quad k \geq 0,$$

以及

$$\mathbb{E}(\xi) = \frac{1}{1-p} \int_0^\infty (p - F(t))dt, \quad m(\infty) = \mathbb{E}(N(\infty)) = \frac{p}{1-p}.$$

证明 记 N 的第 n 个等待时间为 W_n . 显然

$$\{N(\infty) = k\} = \{W_1 < \infty, \dots, W_k < \infty, W_{k+1} = \infty\}.$$

因此 $\mathbb{P}(N(\infty) = k) = p^k(1-p)$, 进而 $\mathbb{E}(N(\infty)) = p/(1-p)$.

注意到 $W_1 = \infty$ 时 $\xi = 0$, 因此对任意 $t \geq 0$, 由更新技巧可得

$$\begin{aligned} \mathbb{P}(\xi \leq t) &= \mathbb{E}(\mathbb{P}(\xi \leq t | W_1)) = 1 - p + \int_0^\infty \mathbb{P}(\xi \leq t | W_1 = s)dF(s) \\ &= 1 - p + \int_0^t \mathbb{P}(\xi \leq t-s)dF(s). \end{aligned}$$

因此 $\mathbb{P}(\xi \leq t) = (1-p)(1+m(t))$. 同理

$$\mathbb{E}(\xi) = \mathbb{E}(\mathbb{E}(\xi | W_1)) = \int_0^\infty (s + \mathbb{E}(\xi))dF(s) = \int_0^\infty s dF(s) + p\mathbb{E}(\xi).$$

因此

$$\mathbb{E}(\xi) = \frac{\int_0^\infty s dF(s)}{1-p} = \frac{1}{1-p} \int_0^\infty (p - F(t))dt. \quad \square$$

由于 $N(t)$ 单调不降地几乎必然收敛到 $N(\infty)$, 由单调收敛定理(定理4.14)可知, $m(t)$ 单调不降地收敛到 $m(\infty) = p/(1-p)$, 这与通常更新过程 $m(t) \rightarrow \infty$ 完全不同.

性质18.3 设 F 为非格子点分布, $p = F(\infty) < 1$ 且存在 $\lambda > 0$ 使得 $\int_0^\infty e^{\lambda t} dF(t) = 1$. 若存

在 $M > 0$ 使得 $e^{\lambda t}(p - F(t))$ 在 $t \in [M, \infty)$ 上单调不增, $m(t)$ 是以 F 为等待时间分布的更新函数, 那么

$$\lim_{t \rightarrow \infty} e^{\lambda t}[m(t) - m(\infty)] = -\frac{1}{\lambda} \left[\int_0^\infty te^{\lambda t} dF(t) \right]^{-1}.$$

证明 由 $m(t) = F(t) + \int_0^t m(t-s) dF(s)$ 以及

$$m(\infty) = \frac{p}{1-p} = \frac{p}{1-p}(1-F(t)) + \int_0^t \frac{p}{1-p} dF(s)$$

可知

$$e^{\lambda t}[m(\infty) - m(t)] = e^{\lambda t} \frac{p - F(t)}{1-p} + \int_0^t e^{\lambda(t-s)}(m(\infty) - m(t-s))e^{\lambda s} dF(s).$$

注意到

$$\int_0^\infty e^{\lambda t} \frac{p - F(t)}{1-p} dt = -\frac{1}{\lambda} \frac{p}{1-p} + \int_0^\infty \frac{1}{\lambda(1-p)} e^{\lambda t} dF(s) = \frac{1}{\lambda},$$

由关键更新定理

$$\lim_{t \rightarrow \infty} e^{\lambda t}[m(\infty) - m(t)] = \frac{1}{\int_0^\infty \lambda s e^{\lambda s} dF(s)}. \quad \square$$

例18.5 设动物穿过某一条保护区的公路时构成一个更新过程, 其更新间隔 $W_i, i \geq 1$ 的公共分布为 F , 在该保护区行驶的汽车碰到动物穿过马路时一定要停车等待, 直到前后动物间隔时间大于 τ 时才能通过. 假定某汽车恰好碰到动物穿过马路, 求它需要等待的平均时间.

解 令 $\tilde{W}_i = \begin{cases} W_i, & W_i \leq \tau \\ +\infty, & W_i > \tau \end{cases}$. \tilde{N} 是以 \tilde{W}_i 为等待时间间隔的可终止更新过程, ξ 为该可终止

更新过程的最后更新时刻, 那么所求平均时间

$$t = \mathbb{E}(\xi) + \tau = \frac{1}{1 - F(\tau)} \int_0^\tau (F(\tau) - F(t)) dt + \tau. \quad \square$$

练习题

18.1 假设当计数器接收到一个粒子后将封闭长为 τ 的时段, 若在这个期间又有粒子到来, 从粒子到达时刻起, 计数器还将封闭 τ 时段, 直至在长为 τ 的时段内没有粒子到达, 此时计数器才重新开放计算. 设粒子到达服从等待分布为 F 的更新过程, 求计数器在一个周期内被封闭的平均时长.

18.2 3个射手轮流射击一个目标, 射手1射击直到他未中, 然后射手2射击直到他未中, 然后射手3射击直到他未中, 然后又回到射手1, 如此循环. 假设三个射手射中的概率分别为 p_1, p_2, p_3 , 确定每个射手射击次数的长程比例.

18.3 设 N 是等待时间分布为 F 的更新过程, 设 F 的均值和方差都有限, 分别是 μ, σ^2 . $A(t)$ 表示 t 时刻的年龄, 求 $\lim_{t \rightarrow \infty} \int_0^t A(s) ds / t$.

18.4* 有偿更新过程 X 满足 $\mathbb{E}(W_i) < \infty$, $\mathbb{E}|Y_i| < \infty$, 其中 W_i 服从连续分布. 令 $m(t) = \mathbb{E}(X(t))$, 证明对任意 $a > 0$

$$\lim_{t \rightarrow \infty} (m(t+a) - m(t)) = \frac{a\mathbb{E}(Y_1)}{\mathbb{E}(W_1)}.$$

18.5* 已知 $X = \{X_n, n \geq 0\}$ 为状态空间 $S = \{0, 1\}$ 的时齐马氏链, 初值为0, 转移概率矩阵

$$\mathbf{P} = \begin{pmatrix} p & 1-p \\ 1-q & q \end{pmatrix}, \quad 0 < p, q < 1.$$

设 $Y_n, n \geq 1$ 为一族均值为 μ 的独立同分布随机变量且与马氏链 X 独立. 令

$$W_k = \begin{cases} Y_k, & X_k = 0; \\ 0, & X_k = 1. \end{cases}$$

证明

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n W_k = \frac{\mu(1-q)}{2-p-q}.$$

第六章 布朗运动

作为一种物理现象, 布朗运动由19世纪20年代英国植物学家Robert Brown在观察悬浮在液体表面的花粉粒子的运动轨迹时发现. 1905年Einstein给出了布朗运动的物理学解释和方程刻画, 其深层次的数学理论基础与构造则由Wiener在1923年得到. 到目前, 布朗运动已成为运动最广泛的数学模型之一, 在自然科学、金融学、社会科学等领域有大量应用.

6.1 布朗运动及其分布

6.1.1 布朗运动

利用正态分布(随机变量), 我们定义布朗运动如下:

定义19.1 称实值随机过程 $B = \{B(t); t \geq 0\}$ 为Wiener过程或布朗运动, 若

- (a) $B(0) = 0$ 且 B 具有连续轨道;
- (b) B 是独立增量过程, 即对任意 $0 \leq t_1 < t_2 < \dots < t_n, n \geq 2$, 增量

$$B(t_1), B(t_2) - B(t_1), \dots, B(t_n) - B(t_{n-1})$$

相互独立;

- (c) 正态性, 对任意 $0 \leq s < t$, $B(t) - B(s) \sim N(0, \sigma^2(t-s))$, 其中 σ^2 为正常数.

由(b),(c)可知布朗运动 B 具有平稳独立增量.

若布朗运动 B 满足 $\sigma^2 = 1$, 则称其为标准布朗运动. 显然若 B 是方差为 σ^2 的布朗运动, 那么 B/σ 为标准布朗运动.

若 $B_x(t) = x + B(t)$, 称 $B_x = \{B_x(t); t \geq 0\}$ 为从 x 出发的布朗运动.

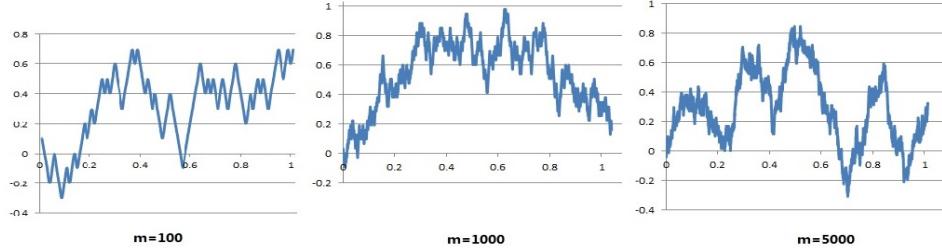
在一定意义上, 布朗运动 B 可以通过简单对称随机游动在时间和空间上采取一定方式连续化后得到. 简单对称随机游动 $S(n) = \sum_{k=1}^n X_k$ 可以用来表示每单位时间向左或向右等可能地跳一个单位的粒子的轨迹变化. 令

$$S_m(t) = \sum_{k=1}^{[mt]} \frac{1}{\sqrt{m}} X_k.$$

那么 $S_m(t)$ 记录了每 $1/m$ 单位时间向左或向右(各 $1/2$ 可能)跳 $1/\sqrt{m}$ 单位距离的粒子的轨迹变化. $m \rightarrow \infty$ 则意味着, 粒子跳跃的越来越频繁, 跳跃幅度也越来越小. 对任意固定的时刻 t , 中心极限定理保证了

$$S_m(t) = \frac{1}{\sqrt{m}} \sum_{k=1}^{[mt]} X_k = \frac{\sqrt{[mt]}}{\sqrt{m}} \frac{1}{\sqrt{[mt]}} \sum_{k=1}^{[mt]} X_k \rightarrow \sqrt{t} N(0, 1) = N(0, t).$$

更严格的数学分析表明, 随机过程 $S_m(t)$ 随着 $m \rightarrow \infty$ 会收敛到标准布朗运动 B . 下面分别是 $m = 100, 1000, 5000$ 时, $S_m(t)$ 的轨道局部($t \in [0, 1]$). 当 m 比较大时, $S_m(t)$ 可以近似看作布朗运动.



性质19.1 布朗运动 B 的均值函数 $m(t) \equiv 0$; 方差函数 $\text{Var}(B(t)) = \sigma^2 t$; 协方差函数

$$R(s, t) = \mathbb{E}(B(s)B(t)) = (s \wedge t)\sigma^2.$$

证明: 只需验证协方差函数. 不妨设 $s < t$,

$$R(s, t) = \mathbb{E}(B(s)B(t)) = \mathbb{E}(B(s)(B(t) - B(s)) + \mathbb{E}(B^2(s)) = \sigma^2 s. \quad \square$$

例19.1 设 $0 < t_1 < t_2 < t_3$, 求 $\mathbb{E}(B(t_1)B(t_2)B(t_3))$.

解 由独立增量与正态性可知

$$\begin{aligned} \mathbb{E}(B(t_1)B(t_2)B(t_3)) &= \mathbb{E}(B(t_1)(B(t_1) + B(t_2) - B(t_1))(B(t_2) + B(t_3) - B(t_2))) \\ &= \mathbb{E}(B(t_1)B(t_1)B(t_2)) + \mathbb{E}(B(t_1)(B(t_2) - B(t_1))B(t_2)) \\ &= \mathbb{E}(B^3(t_1)) + \mathbb{E}(B(t_1)(B(t_2) - B(t_1))^2) = 0. \end{aligned} \quad \square$$

定理19.2 设 $B = \{B(t); t \geq 0\}$ 为标准布朗运动, 那么下述过程也是标准布朗运动.

- (1) $\{-B(t); t \geq 0\}$;
- (2) $\{B(t+s) - B(s); t \geq 0\}$, 其中 s 为任意给定非负数;
- (3) $\{cB(t/c^2); t \geq 0\}$ 其中 c 为任意给定正数;
- (4) $\{B(u) - B(u-t); 0 \leq t \leq u\}$ 其中 u 为给定正数.

证明 按布朗运动定义, 不难验证上述结论成立. 下面以(4)为例解释如下: 令

$$X(t) = B(u) - B(u-t), \quad 0 \leq t \leq u.$$

- (a) 显然 $X(0) = 0$ 且 X 轨道连续;

(b) 对任意 $0 \leq t_1 < t_2 < \dots < t_n \leq u$,

$$\begin{aligned} & (X(t_1), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})) \\ & = (B(u) - B(u - t_1), B(u - t_1) - B(u - t_2), \dots, B(u - t_{n-1}) - B(u - t_n)), \end{aligned}$$

由布朗运动独立增量性质, 显然相互独立

(c) 对任意 $0 \leq s < t \leq u$,

$$X(t) - X(s) = B(u - s) - B(u - t) \sim N(0, t - s).$$

因此 $\{X(t), 0 \leq t \leq u\} = \{B(u) - B(u - t), 0 \leq t \leq u\}$ 为标准布朗运动. \square

注19.1 (2),(3),(4)分别表示对标准布朗运动做起点变换, 尺度变换以及时间反向变换后仍是标准布朗运动. 此外我们还可以证明 $\{tB(1/t); t \geq 0\}$ (其中 $t = 0$ 时取值为 0) 也是标准布朗运动.

6.1.2 布朗运动的分布

下面我们研究标准布朗运动的有限维分布. 为此, 总设 $B = \{B(t); t \geq 0\}$ 为标准布朗运动并记

$$\phi(x, t) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}},$$

即对任意 $a \in R, t > 0$, $\phi(x - a, t)$ 是正态分布 $N(a, t)$ 的密度函数. 容易验证

(1) 对任意 $a, b \in R, s, t > 0$,

$$\phi(x - a, s)\phi(x - b, t) = \phi(a - b, s + t)\phi(x - \frac{ta + sb}{s + t}, \frac{st}{s + t}). \quad (6.1.1)$$

(2) 对任意 $x \in R$,

$$\int_x^\infty \phi(y - a, t) dy = \int_{(x-a)/\sqrt{t}}^\infty \phi(u, 1) du = \Phi((a - x)/\sqrt{t})$$

其中 Φ 为标准正态分布函数.

定理19.3 对任意 $n \geq 1, 0 \leq t_1 < t_2 < \dots < t_n$, $(B(t_1), B(t_2), \dots, B(t_n))$ 是均值为 0, 协方差矩阵为

$$\mathbb{D} = (t_i \wedge t_j)_{i,j=1,\dots,n} = \begin{pmatrix} t_1 & t_1 & t_1 & \cdots & t_1 \\ t_1 & t_2 & t_2 & \cdots & t_2 \\ t_1 & t_2 & t_3 & \cdots & t_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ t_1 & t_2 & t_3 & \cdots & t_n \end{pmatrix}$$

的 n 维正态随机变量。因此 $(B(t_1), \dots, B(t_n))$ 的联合密度函数为

$$\rho(x_1, \dots, x_n; t_1, \dots, t_n) = \phi(x_1, t_1) \prod_{i=2}^n \phi(x_i - x_{i-1}, t_i - t_{i-1}).$$

证明 对任意 $0 \leq t_1 < t_2 < \dots < t_n, \lambda_1, \dots, \lambda_n \in \mathbb{R}$ 由布朗运动的平稳正态独立增量性质可知

$$\begin{aligned} \mathbb{E}\left(\exp\left\{\mathrm{i} \sum_{k=1}^n \lambda_k B(t_k)\right\}\right) &= \mathbb{E}\left(\exp\left\{\mathrm{i} \sum_{k=1}^n (B(t_k) - B(t_{k-1})) \sum_{j=k}^n \lambda_j\right\}\right) \\ &= \prod_{k=1}^n \mathbb{E}\left(\exp\left\{\mathrm{i}(B(t_k) - B(t_{k-1})) \sum_{j=k}^n \lambda_j\right\}\right) \\ &= \exp\left\{-\sum_{k=1}^n \frac{t_k - t_{k-1}}{2} \left(\sum_{j=k}^n \lambda_j\right)^2\right\}. \end{aligned}$$

直接验证可知

$$\begin{aligned} \sum_{k=1}^n \frac{t_k - t_{k-1}}{2} \left(\sum_{j=k}^n \lambda_j\right)^2 &= \frac{1}{2} \left[\sum_{k=1}^n t_k \left(\sum_{j=k}^n \lambda_j\right)^2 - \sum_{k=1}^{n-1} t_k \left(\sum_{j=k+1}^n \lambda_j\right)^2 \right] \\ &= \frac{1}{2} \left[\sum_{k=1}^n 2t_k \lambda_k \sum_{j=k+1}^n \lambda_j + \sum_{k=1}^n t_k \lambda_k^2 \right] \\ &= \frac{(\lambda_1, \dots, \lambda_n) \mathbb{D} (\lambda_1, \dots, \lambda_n)^T}{2}. \end{aligned}$$

因此 $(B(t_1), \dots, B(t_n))$ 服从均值为0协方差矩阵为 \mathbb{D} 的 n 维正态分布，联合密度函数

$$\rho(x_1, \dots, x_n; t_1, \dots, t_n) = \frac{1}{(2\pi)^{n/2} \sqrt{|\mathbb{D}|}} e^{-\frac{(x_1, \dots, x_n) \mathbb{D}^{-1} (x_1, \dots, x_n)^T}{2}}.$$

由矩阵求逆计算可知 \mathbb{D}^{-1} 可表示为

$$\begin{pmatrix} 1 & -1 & \cdots & 0 & 0 \\ 0 & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & -1 \\ 0 & 0 & \cdots & 0 & 1 \end{pmatrix} \begin{pmatrix} \frac{1}{t_1} & 0 & \cdots & 0 & 0 \\ 0 & \frac{1}{t_2 - t_1} & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & \frac{1}{t_{n-1} - t_{n-2}} & 0 \\ 0 & 0 & \cdots & 0 & \frac{1}{t_n - t_{n-1}} \end{pmatrix} \begin{pmatrix} 1 & 0 & \cdots & 0 & 0 \\ -1 & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & 0 \\ 0 & 0 & \cdots & -1 & 1 \end{pmatrix}$$

令 $x_0 = 0, t_0 = 0$, 将 \mathbb{D}^{-1} 的上述表达式代入联合密度函数得

$$\begin{aligned} \rho(x_1, \dots, x_n; t_1, \dots, t_n) &= \frac{1}{\prod_{i=1}^n \sqrt{2\pi(t_i - t_{i-1})}} e^{-\sum_{i=1}^n \frac{(x_i - x_{i-1})^2}{2(t_i - t_{i-1})}} \\ &= \phi(x_1, t_1) \prod_{i=2}^n \phi(x_i - x_{i-1}, t_i - t_{i-1}). \quad \square \end{aligned}$$

推论19.4 当 $B(t_k) = a$ 时, $(B(t_1), \dots, B(t_{k-1}), B(t_{k+1}), \dots, B(t_n))$ 的密度函数为

$$\varrho(x_1, \dots, x_{k-1}, x_{k+1}, \dots, x_n; t_1, \dots, t_{k-1}, t_{k+1}, \dots, t_n | a, t_k)$$

$$= \rho(x_1, \dots, x_{k-1}, a, x_{k+1}, \dots, x_n; t_1, \dots, t_n) / \phi(a, t_k).$$

特别 $\varrho(x_2, \dots, x_n; t_2, \dots, t_n | a, t_1) = \phi(x_2 - a, t_2 - t_1) \prod_{i=3}^n \phi(x_i - x_{i-1}, t_i - t_{i-1})$,

$$\varrho(x_1, \dots, x_{n-1}; \dots, t_{n-1} | a, t_n) = \frac{\phi(a - x_{n-1}, t_n - t_{n-1})}{\phi(a, t_n)} \prod_{i=1}^{n-1} \phi(x_i - x_{i-1}, t_i - t_{i-1}).$$

证明 由条件概率密度公式, 我们只需证明

$$\int_{-\infty}^{\infty} dy_1 \cdots \int_{-\infty}^{\infty} \rho(y_1, \dots, y_{k-1}, a, y_{k+1}, \dots, y_n; t_1, \dots, t_n) dy_n = \phi(a, t_k). \quad (6.1.2)$$

事实上由

$$\begin{aligned} \text{l.h.s of (6.1.2)} &= \int_{-\infty}^{\infty} \phi(y_1, t_1) dy_1 \int_{-\infty}^{\infty} \phi(y_2 - y_1, t_2 - t_1) dy_2 \\ &\times \cdots \int_{-\infty}^{\infty} \phi(y_{k-1} - y_{k-2}, t_{k-1} - t_{k-2}) \phi(a - y_{k-1}, t_k - t_{k-1}) dy_{k-1} \\ &\times \int_{-\infty}^{\infty} \phi(y_{k+1} - a, t_{k+1} - t_k) dy_{k+1} \cdots \int_{-\infty}^{\infty} \phi(y_n - y_{n-1}, t_n - t_{n-1}) dy_n \end{aligned}$$

可知

$$\begin{aligned} \text{l.h.s of (6.1.2)} &= \int_{-\infty}^{\infty} \phi(y_1, t_1) dy_1 \cdots \int_{-\infty}^{\infty} \phi(y_{k-2} - y_{k-3}, t_{k-2} - t_{k-3}) dy_{k-2} \\ &\times \int_{-\infty}^{\infty} \phi(y_{k-1} - y_{k-2}, t_{k-1} - t_{k-2}) \phi(a - y_{k-1}, t_k - t_{k-1}) dy_{k-1} \\ &= \int_{-\infty}^{\infty} \phi(y_1, t_1) dy_1 \cdots \int_{-\infty}^{\infty} \phi(y_{k-2} - y_{k-3}, t_{k-2} - t_{k-3}) \phi(a - y_{k-2}, t_k - t_{k-2}) dy_{k-2} \\ &= \cdots = \int_{-\infty}^{\infty} \phi(y_1, t_1) \phi(a - y_1, t_k - t_1) dy_1 = \text{r.h.s. of (6.1.2)}, \end{aligned}$$

其中第二个等号用了公式(6.1.1). \square

例19.2 在甲乙两人的自行车比赛中, 以 $Y(t)$ 表示当完成 $100t\%$ 的比赛路程时甲领先的时间(以秒记). 假设 $Y(t)$ 是方差为 σ^2 的布朗运动, 若甲以 σ 秒领先赢得比赛, 问甲在路程中点领先的概率是多大?

解 注意到 $B(t) = Y(t)/\sigma$ 为标准布朗运动, 所求概率为

$$p = \mathbb{P}(B(1/2) > 0 | B(1) = 1)$$

由于在 $B(1) = 1$ 条件下, $B(1/2) \sim N(1/2, 1/4)$, 因此

$$p = \mathbb{P}(N(1/2, 1/4) > 0) = \mathbb{P}(N(0, 1) > -1) = \Phi(1) \approx 0.8413,$$

其中 Φ 为标准正态分布函数. \square

在给定两个时刻取值的条件下, 我们有如下的结论, 证明省略.

推论19.5 $B(s) = x, B(t) = y$ 时, 任取 $s \leq t_1 < t_2 < \cdots < t_n \leq t$, $(B(t_1), \dots, B(t_n))$ 是均值为

$$\left(x + \frac{y-x}{t-s}(t_i - s) \right)_{1 \leq i \leq n},$$

协方差矩阵

$$\mathbb{D} = \left(\frac{(t - t_{i \vee j})(t_{i \wedge j} - s)}{t - s} \right)_{i,j=1,\dots,n}$$

的 n 维正态随机变量.

例19.3 在 $\{B(1) = 0, B(3) = u\}$ 条件下, 求事件 $\{B(2) > u, B(4) > u\}$ 发生的概率.

解 由独立增量性, 所求概率为

$$\begin{aligned} & \mathbb{P}(B(2) > u, B(4) > u | B(3) = u, B(1) = 0) \\ &= \mathbb{P}(B(2) > u | B(3) = u, B(1) = 0) \mathbb{P}(B(4) > u | B(3) = u, B(2) > u, B(1) = 0) \\ &= \mathbb{P}(B(2) > u | B(3) = u, B(1) = 0) \mathbb{P}(B(4) > u | B(3) = u). \end{aligned}$$

由推论19.5可知(对应地取 $s = 1, t = 3, t_1 = 2, x = 0, y = u$), $\{B(3) = u, B(1) = 0\}$ 条件下 $B(2) \sim N(u/2, 1/2)$. 所以

$$\begin{aligned} \mathbb{P}(B(2) > u | B(3) = u, B(1) = 0) &= \mathbb{P}(N(u/2, 1/2) > u) \\ &= \mathbb{P}(N(0, 1) > u/\sqrt{2}) = 1 - \Phi(u/\sqrt{2}). \end{aligned}$$

由推论19.4或布朗运动独立增量性可知 $\{B(3) = u\}$ 条件下, $B(4) \sim N(u, 1)$. 因此

$$\mathbb{P}(B(4) > u | B(3) = u) = 1/2.$$

因此所求概率 $p = (1 - \Phi(u/\sqrt{2}))/2$. □

6.1.3 轨道性质*

定理19.6 标准布朗运动 $B = \{B(t), t \geq 0\}$ 存在.

(Kolmogorov连续修正定理) 设 $\{X(t), t \geq 0\}$ 为实值随机过程, 若在某个参数区间 $[a, b]$ ($[a, b]$ 可以是 $[0, \infty]$) 上存在正常数 α, ε 使得对任意 $t, t+h \in [a, b]$

$$\mathbb{E}(|X(t) - X(t+h)|^\alpha) \leq \text{const} \cdot h^{1+\varepsilon},$$

那么 $\{X(t), t \in [a, b]\}$ 存在一个轨道连续的修正.

定理19.6的证明 对任意满足条件 $\sigma^2 = 1, B(0) = 0$ 的布朗运动, 我们有

$$\mathbb{E}(|B(t+h) - B(t)|^4) = 3h^2.$$

由 Kolmogorov 连续修正定理可知结论成立.

定理19.7 标准布朗运动 $B = \{B(t); t \geq 0\}$ 的几乎所有轨道处处不可微.

证明 只考虑 $t \in [0, 1]$ 的情形. 任取轨道 ω , 若 $B(\cdot, \omega)$ 在 s 可微, 则存在 $\delta \in (0, 1/2)$ 与整数 $l \geq$

1使得当 $|t - s| < \delta$ 时

$$|B(t, \omega) - B(s, \omega)| < l|t - s|.$$

对任意 $n > 4/\delta$, 令 $i = [ns] + 1 \leq n + 1$, 对 $j = i \pm 1, i \pm 2, i \pm 3$ 都应有

$$\begin{aligned} & |B(j/n, \omega) - B((j-1)/n, \omega)| \\ & \leq |B(j/n, \omega) - B(s, \omega)| + |B((j-1)/n, \omega) - B(s, \omega)| \\ & \leq l|j/n - s| + l|(j-1)/n - s| \leq 7l/n. \end{aligned} \quad (6.1.3)$$

令 $A_{n,l}^i = \{\omega; \text{对给定的 } l, i \text{ (6.1.3) 对 } j = i+1, i+2, i+3, \text{ 或对 } j = i-1, i-2, i-3 \text{ 成立}\}$.

显然随着 l 的增加, $A_{n,l}^i$ 单调不降. 特别取 $\delta = 1/m$, $m = 2, 3, \dots$, 则

$$\Omega_1 = \{\omega; \text{存在 } s \in [0, 1] \text{ 使得 } B(\cdot, \omega) \text{ 在 } s \text{ 点可微}\}$$

$$\subset \bigcup_{l \geq 1, m \geq 2} \bigcap_{n \geq 4m} \bigcup_{i \leq n+1} A_{n,l}^i.$$

但是当 $n \rightarrow \infty$ 时

$$\begin{aligned} \mathbb{P}\left(\bigcup_{i \leq n+1} A_{n,l}^i\right) & \leq (n+1) \max_{1 \leq i \leq n+1} \mathbb{P}(A_{n,l}^i) \\ & \leq 2(n+1) \left[\mathbb{P}(|B(j/n) - B((j-1)/n)| \leq 7l/n) \right]^3 \\ & = 2(n+1) \left[\int_{-7l/n}^{7l/n} \frac{1}{\sqrt{2\pi/n}} e^{-ny^2/2} dy \right]^3 \\ & \leq 2(n+1)(14l/\sqrt{2\pi n})^3 \rightarrow 0. \end{aligned}$$

因此 $\mathbb{P}(\Omega_1) \leq \lim_{l \rightarrow \infty} \lim_{n \rightarrow \infty} \mathbb{P}\left(\bigcup_{i \leq n+1} A_{n,l}^i\right) = 0$. 即对几乎必然的 ω , $B(\cdot, \omega)$ 处处不可微. \square

布朗运动轨道函数 $B(\cdot, \omega)$ 为我们提供了连续但处处不可微的函数实例.

练习题 以下总设 $B = \{B(t), t \geq 0\}$ 为标准布朗运动.

19.1 对任意 $0 \leq s < t$, 求 $B(s) + B(t)$ 的分布密度函数.

19.2 已知 $B(1) = x$, 对任意 $0 \leq s_1 < s_2 \leq s_3 < s_4 \leq 1$, 证明

- (1) $\mathbb{E}((B(s_4) - B(s_3))(B(s_2) - B(s_1))) = (s_4 - s_3)(s_2 - s_1)(x^2 - 1)$
- (2) $\mathbb{E}[(B(s_4) - B(s_1))^2] = (s_4 - s_1) + (s_4 - s_1)^2(x^2 - 1)$

19.3 在例19.2中若甲在一半赛程时领先乙 σ 秒, 问比赛结束时甲领先的概率.

19.4 令 $Y(t) = B^2(t) - t$, $R(t) = e^{cB(t)-c^2t/2}$, 其中 $c > 0$ 为常数. 证明对任意 $0 \leq t < s$,

$\mathbb{E}(Y(s)|B(t)) = Y(t)$ 以及 $\mathbb{E}(R(s)|B(t)) = R(t)$.

6.2 反射原理与极值分布

对任意 $a \in R$, 定义

$$\tau_a = \inf\{t \geq 0; B(t) = a\} = \begin{cases} \inf\{t \geq 0; B(t) \geq a\}, & a \geq 0; \\ \inf\{t \geq 0; B(t) \leq a\}, & a < 0. \end{cases}$$

称 τ_a 为 B 首次到达状态 a 的时刻, 简称为 a 的首达时.

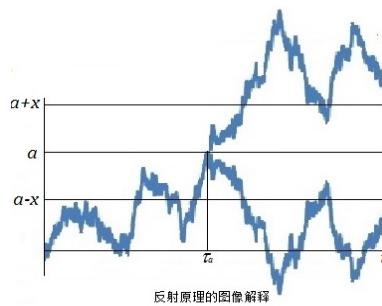
6.2.1 反射原理

利用布朗运动的对称性和独立增量性, 可得如下反射原理.

引理20.1(反射原理) 对任意 $a \in R$ 及 $x \geq 0$,

$$\mathbb{P}(B(t) \geq a + x, \tau_a \leq t) = \mathbb{P}(B(t) < a - x, \tau_a \leq t). \quad (6.2.1)$$

反射原理的直观图形解释如下,



对该直观解释不严格的数学表示如下: 设 τ_a 的分布函数为 $F(s)$, 那么

$$\begin{aligned} \mathbb{P}(B(t) \geq a + x, \tau_a \leq t) &= \mathbb{P}(B(t) > a + x, \tau_a \leq t) \\ &= \int_0^t \mathbb{P}(B(t) > a + x | \tau_a = s) dF(s) \\ &= \int_0^t \mathbb{P}(B(t) > a + x | B(s) = a, B(u) \neq a, 0 \leq u < s) dF(s) \quad (\text{轨道连续}) \\ &= \int_0^t \mathbb{P}(B(t) > a + x | B(s) = a) dF(s) \\ &= \int_0^t \int_{a+x}^{\infty} \phi(y - a, t - s) dF(s) = \int_0^t \int_{-\infty}^{a-x} \phi(y - a, t - s) dF(s) \quad (\text{对称性}) \\ &= \int_0^t \mathbb{P}(B(t) < a - x | B(s) = a) dF(s) = \mathbb{P}(B(t) < a - x, \tau_a \leq t). \end{aligned}$$

推论20.2 对任意 $a \in R$, $\mathbb{P}(B(t) \geq a | \tau_a \leq t) = 1/2$.

6.2.2 极值与首达时分布

定理20.3 记 $B^*(t) = \max_{0 \leq u \leq t} B(u)$. 对任意 $z \geq 0, x \leq z$,

$$\mathbb{P}(B^*(t) \geq z, B(t) < x) = \mathbb{P}(B(t) > 2z - x) = \int_{2z-x}^{\infty} \phi(y, t) dy.$$

因此 $(B^*(t), B(t))$ 的联合密度函数为

$$h(z, x) = 2 \frac{\partial \phi(2z - x, t)}{\partial x} = \frac{2(2z - x)}{\sqrt{2\pi t^3}} e^{-\frac{(2z-x)^2}{2t}}, \quad x \leq z, z \geq 0.$$

证明 由轨道连续性及 $B(0) = 0$ 可知, 对任意 $z \geq 0$,

$$\{B^*(t) \geq z\} = \{\tau_z \leq t\} \tag{6.2.2}$$

从而由反射原理(6.2.1)可得

$$\begin{aligned} \mathbb{P}(B^*(t) \geq z, B(t) < x) &= \mathbb{P}(\tau_z \leq t, B(t) < x) \\ &= \mathbb{P}(B(t) < z - (z - x), \tau_z \leq t) = \mathbb{P}(B(t) > z + (z - x), \tau_z \leq t) \\ &= \mathbb{P}(B(t) > 2z - x) = \int_{2z-x}^{\infty} \phi(y, t) dy. \end{aligned}$$

上式两边关于 z, x 求二阶混合偏导即得联合密度函数 $h(z, x)$. \square

例20.1 求 $\mathbb{P}(B^*(t) > x | B(t) = B^*(t))$.

解 由概率论知识可知 $\{B(t) = B^*(t)\}$ 条件下 $B^*(t)$ 的边际密度函数为

$$g(z) = \frac{h(z, z)}{\int_0^\infty h(z, z) dz} = \frac{ze^{-\frac{z^2}{2t}}}{\int_0^\infty ze^{-\frac{z^2}{2t}} dz} = \frac{z}{t} e^{-\frac{z^2}{2t}}$$

因此

$$\mathbb{P}(B^*(t) > x | B(t) = B^*(t)) = \int_x^\infty g(z) dz = e^{-\frac{x^2}{2t}}. \quad \square$$

推论20.4 对任意 $z \geq 0$,

$$\mathbb{P}(B^*(t) \geq z) = 2\mathbb{P}(B(t) \geq z) = \mathbb{P}(|B(t)| \geq z),$$

因此 $B^*(t)$ 与 $|B(t)|$ 同分布, $B^*(t)$ 的密度函数

$$g(z) = \frac{2}{\sqrt{2\pi t}} e^{-z^2/2t}.$$

证明 对任意 $z \geq 0$

$$\begin{aligned} \mathbb{P}(B^*(t) \geq z) &= \mathbb{P}(B^*(t) \geq z, B(t) \geq z) + \mathbb{P}(B^*(t) \geq z, B(t) < z) \\ &= \mathbb{P}(B(t) \geq z) + \mathbb{P}(B(t) > z) = 2\mathbb{P}(B(t) \geq z) \\ &= 2 \int_z^\infty \frac{1}{2\pi t} e^{-u^2/2t} du = \mathbb{P}(|B(t)| \geq z). \end{aligned}$$

推论得证. \square

例20.2 假定一只股票价格按标准布朗运动变化, 若你以价格 $b + c$ 买入, 而现在的价格恰好为 b , 你计划在股票价格回到 $b + c$ 元或最多再观望 T 时间后将股票抛出, 问你不能重新获得买

入价格的概率($c > 0$).

解 从现在开始看股票的价格 $S(t)$ 是一个从 b 出发的布朗运动, 即 $S(t) = b + B(t)$. 所谓不能重新获得买入价格就是指在时刻 T 之前, $S(t)$ 最大值小于 $b + c$, 即

$$B_T^* = \max_{0 \leq s \leq T} B(s) < c.$$

由推论20.4可知所求概率为

$$p = 1 - \mathbb{P}(B^*(T) \geq c) = 1 - \mathbb{P}(|B(T)| > c) = 1 - 2\Phi(-c/\sqrt{T}). \quad \square$$

推论20.5 对任意 $z > 0$, τ_z 的分布密度函数

$$p(t) = \frac{z}{\sqrt{2\pi t^3}} e^{-z^2/2t}.$$

因此 $\mathbb{P}(\tau_z < \infty) = 1$, $\mathbb{E}(\tau_z) = \infty$.

证明 对任意 $z \geq 0$, 由(6.2.2)可知

$$\mathbb{P}(\tau_z \leq t) = \mathbb{P}(B^*(t) \geq z) = 2 \int_z^\infty \frac{1}{\sqrt{2\pi t}} e^{-u^2/2t} du = \int_{z/\sqrt{t}}^\infty \frac{2}{\sqrt{2\pi}} e^{-u^2/2} du$$

两边关于 t 求导得

$$p(t) = \frac{z}{\sqrt{2\pi t^3}} e^{-z^2/2t}.$$

即

$$\mathbb{P}(\tau_z \leq t) = \int_0^t \frac{z}{\sqrt{2\pi s^3}} e^{-z^2/2s} ds.$$

因此

$$\mathbb{P}(\tau_z < \infty) = \int_0^\infty \frac{z}{\sqrt{2\pi s^3}} e^{-z^2/2s} ds = \int_0^\infty \frac{2}{\sqrt{2\pi}} e^{-u^2/2} du = 1$$

而且

$$\mathbb{E}(\tau_z) = \int_0^\infty \frac{z}{\sqrt{2\pi s}} e^{-z^2/2s} ds = \infty.$$

推论得证. \square

注意对任意 $z \geq 0$, τ_z 与 τ_{-z} 分布相同(见习题20.5), 因此对任意 $z \in R$, τ_z 的密度函数

$$p(t) = \frac{|z|}{\sqrt{2\pi t^3}} e^{-z^2/2t}.$$

因此推论20.5表明对空间 R 中任意一点 z , 布朗运动必然在有限时间内可到达这一点, 而到达这一点的平均时长为无穷.

例20.3 求例19.2中在比赛后半程甲都不落后于乙的概率.

解 依题设 $Y(t)$ 是方差为 σ 的布朗运动, 因而 $B(t) = Y(t)/\sigma$ 是标准布朗运动. 令

$$B_* = \min\{B(u); 1/2 \leq u \leq 1\}.$$

已知 $B(1) = 1$, 所求概率为

$$p = \mathbb{P}(B_* \geq 0 | B(1) = 1).$$

注意到 $W = -B$ 仍为标准布朗运动, 因此

$$p = \mathbb{P}(W^* \leq 0 | W(1) = -1),$$

其中 $W^* = \max\{W(u); 1/2 \leq u \leq 1\}$. 记 $W(1) = -1$ 下的条件概率为 \mathbb{P}_1 , 数学期望为 \mathbb{E}_1 那么

$$p = \mathbb{P}_1(W^* \leq 0) = \mathbb{E}_1(\mathbb{P}_1(W^* \leq 0 | W(1/2))).$$

由推论19.4可知, $W(1) = -1$ 条件下 $W(1/2) \sim N(-1/2, 1/4)$, 因此

$$p = \int_{-\infty}^0 \mathbb{P}_1(W^* \leq 0 | W(1/2) = x) \phi(x + 1/2, 1/4) dx.$$

注意到

$$\begin{aligned} \mathbb{P}_1(W^* \leq 0 | W(1/2) = x) &= \mathbb{P}(W^* \leq 0 | W(1/2) = x, W(1) = -1) \\ &= \mathbb{P}(\max\{U(t), 0 \leq t \leq 1/2\} \leq -x | U(0) = 0, U(1/2) = -1 - x), \end{aligned}$$

其中 $U(t) = W(t + 1/2) - W(1/2)$ 为标准布朗运动. 将其重新记作 B 得

$$\mathbb{P}_1(W^* \leq 0 | W(1/2) = x) = \mathbb{P}(B^*(1/2) \leq -x | B(1/2) = -1 - x).$$

将定理20.3中对应的 x 换成 $-1 - x$, t 换成 $1/2$ 可得 $B(1/2) = -1 - x$ 时 $B^*(1/2)$ 的边际分布密度为

$$g(z | -1 - x) = 4(2z + 1 + x)e^{-(2z+1+x)^2 + (1+x)^2}, \quad z \geq 0.$$

因此

$$\mathbb{P}_1(W^* \leq 0 | W(1/2) = x) = \int_0^{-x} 4(2z + 1 + x)e^{-(2z+1+x)^2 + (1+x)^2} dz = 1 - e^{4x}.$$

进而

$$p = \int_{-\infty}^0 (1 - e^{4x}) \frac{1}{\sqrt{\pi/2}} e^{-2(x+1/2)^2} dx = 2\Phi(1) - 1. \quad \square$$

6.2.3 零点概率*

定理20.6 从 $x \neq 0$ 出发的标准布朗运动 $B_x(s) = x + B(s)$ 在 $[0, t]$ 至少有一个零点的概率

$$p_t(x) = \frac{|x|}{\sqrt{2\pi}} \int_0^t s^{-3/2} e^{-\frac{x^2}{2s}} ds.$$

证明 先设 $x < 0$, 那么

$$p_t(x) = \mathbb{P}(\max_{0 \leq u \leq t} B(u) + x \geq 0) = \mathbb{P}(\max_{0 \leq u \leq t} B(u) \geq -x) = \mathbb{P}(\tau_{-x} \leq t)$$

$$= \mathbb{P}(\tau_{|x|} \leq t) = \frac{|x|}{\sqrt{2\pi}} \int_0^t s^{-3/2} e^{-\frac{x^2}{2s}} ds.$$

再设 $x > 0$, 此时

$$\begin{aligned} p_t(x) &= \mathbb{P}(\min_{0 \leq u \leq t} B(u) + x \leq 0) = \mathbb{P}(\min_{0 \leq u \leq t} B(u) \leq -x) \\ &= \mathbb{P}(\max_{0 \leq u \leq t} (-B(u)) \geq x) = \mathbb{P}(\tau_x \leq t) \quad (\text{因为} -B \text{也是标准布朗运动}) \\ &= \frac{x}{\sqrt{2\pi}} \int_0^t s^{-3/2} e^{-\frac{x^2}{2s}} ds. \end{aligned}$$

综合两种情况可知定理成立. \square

推论20.7 设 $0 < s < t$, B 在时间区间 (s, t) 内至少存在一个零点的概率

$$q = \frac{2}{\pi} \arccos \sqrt{\frac{s}{t}}.$$

证明 由定理20.6

$$\begin{aligned} q &= \mathbb{E}(p_{t-s}(B(s))) = 2 \int_0^\infty \phi(x, s) p_{t-s}(x) dx \\ &= 2 \int_0^{t-s} du \int_0^\infty \phi(x, s) \phi(x, u) \frac{x}{u} dx \\ &= 2 \int_0^{t-s} \frac{\phi(0, s+u)}{u} du \int_0^\infty x \phi(x, \frac{su}{s+u}) dx = \frac{1}{\pi} \int_0^{t-s} \frac{1}{s+u} \sqrt{\frac{s}{u}} du. \end{aligned}$$

积分变量代换 $v = \sqrt{u/s}$ 后得

$$\begin{aligned} q &= \frac{2}{\pi} \int_0^{\sqrt{(t-s)/s}} \frac{1}{1+v^2} dv \quad (\text{积分变换}) \\ &= \frac{2}{\pi} \arctan(\sqrt{(t-s)/s}) = \frac{2}{\pi} \arctan \sqrt{\frac{t-s}{s}} = \frac{2}{\pi} \arccos \sqrt{\frac{s}{t}}. \end{aligned}$$

推论得证. \square

例20.4 设 $c > 0$ 为常数, 求 $p = \mathbb{P}(\text{存在 } t_0 \in (1, 2) \text{ 使得 } B(t_0) = ct_0 | B(3) = 3c)$.

解 令 $W(t) = tB(1/t)$, 那么 $W(t)$ 仍为标准布朗运动, 此时

$$\{\text{存在 } t_0 \in (1, 2) \text{ 使得 } B(t_0) = ct_0\} = \{\text{存在 } t_0 \in (1/2, 1) \text{ 使得 } W(t_0) = c\}.$$

进而由推论20.7 可知

$$\begin{aligned} p &= \mathbb{P}(\text{存在 } t_0 \in (1/2, 1) \text{ 使得 } W(t_0) = c | W(1/3) = c) \\ &= \mathbb{P}(\text{存在 } t_0 \in (1/6, 2/3) \text{ 使得 } W(t_0) = 0) = \frac{2}{\pi} \arccos \sqrt{\frac{1}{4}} = 2/3. \end{aligned} \quad \square$$

定理20.8* 令 $v_t = \sup\{s; 0 \leq s \leq t, B(s) = B^*(t)\}$, 那么 v_t 的密度函数为

$$\nu(s) = \frac{1}{\pi \sqrt{s(t-s)}}, \quad 0 < s < t.$$

证明 注意到对任意 $0 < s < t$,

$$\{v_t \leq s\} = \{\max_{0 \leq u \leq s} B(u) > \max_{s < u \leq t} B(u)\}.$$

因此

$$\begin{aligned}\mathbb{P}(v_t \leq s) &= \mathbb{P}(\max_{0 \leq u \leq s} B(u) > \max_{s < u \leq t} B(u)) \\ &= \mathbb{E}(\mathbb{P}(\max_{0 \leq u \leq s} B(u) > \max_{s < u \leq t} B(u) | B^*(s), B(s))) \\ &= \mathbb{E}(\mathbb{P}(B^*(s) - B(s) > \max_{s < u \leq t} (B(u) - B(s)) | B^*(s), B(s))).\end{aligned}$$

由平稳独立增量性可得

$$\begin{aligned}\mathbb{P}(v_t \leq s) &= \mathbb{E}\left(\mathbb{P}(B^*(s) - B(s) > \max_{0 \leq u \leq t-s} W(u))\right), \\ &= \mathbb{E}\left(\int_0^{B^*(s)-B(s)} 2\phi(u, t-s)du\right)\end{aligned}$$

其中 W 表示标准布朗运动且与 B 独立. 由定理19.3,

$$\begin{aligned}\mathbb{P}(v_t \leq s) &= \int_0^\infty dz \int_0^\infty 4\phi(z+y, s) \frac{z+y}{s} dy \int_0^y \phi(u, t-s) du \\ &= \int_0^\infty dz \int_0^\infty 4\phi(z+u, s) \phi(u, t-s) du \\ &= \int_0^\infty 4\phi(z, t) dz \int_0^\infty \phi(u + \frac{t-s}{t}z, \frac{(t-s)s}{t}) du \\ &= \int_0^\infty 4\phi(z, t) dz \int_{z\sqrt{\frac{(t-s)}{ts}}}^\infty \phi(u, 1) du.\end{aligned}$$

两边求导得

$$\begin{aligned}\nu(s) &= \int_0^\infty 4\phi(z, t) \phi(z\sqrt{\frac{t-s}{ts}}, 1) \frac{\sqrt{tz}}{2\sqrt{s^3(t-s)}} dz \\ &= \int_0^\infty \frac{z}{\pi\sqrt{s^3(t-s)}} e^{-\frac{z^2}{2s}} dz = \frac{1}{\pi\sqrt{s(t-s)}}.\end{aligned}$$

定理得证. \square

练习题

20.1 求 $\mathbb{E}(B^*(t) | B(t) = x)$.

20.2 求 $\mathbb{P}(B(1) \leq x | B(u) \geq 0, 0 \leq u \leq 1)$.

20.3 股票A,B的价格比服从随机过程 $Y(t) = e^{B(t)}$ 其中 $B(t)$ 为标准布朗运动, 已知在时刻 $t = 1, t = 2$ 时价格比值分别是 $e^{0.5}$ 和 e , 试估算在 $(1, 2)$ 时间段内 B 股票价格曾超过 A 价格的概率

20.4 证明对任意 $z \geq 0$, τ_z 与 τ_{-z} 同分布.

20.5 对任意 $\lambda \geq 0$, 求 $\mathbb{E}(e^{-\lambda\tau_z})$.

20.6 当 $0 < z \rightarrow \infty$ 时, 证明 $\tau_z \rightarrow +\infty$, a.s. ([提示] τ_z 单调不降从而极限必然存在, 对任意 $t > 0$,

$$\mathbb{P}(\lim_{z \rightarrow \infty} \tau_z > t) = \lim_{z \rightarrow \infty} \mathbb{P}(\tau_z > t) = 1.)$$

20.7* 令 $\gamma_t = \sup\{s \leq t; B(s) = 0\}$, 证明

$$\mathbb{P}(\gamma_t \leq x) = \frac{2}{\pi} \arcsin \sqrt{\frac{x}{t}}, \quad x \leq t.$$

6.3 几何布朗运动与Black-Scholes公式

几何布朗运动是风险资产价格建模中被广泛运用，其中一个最著名的应用就是期权定价理论中的Black-Scholes公式。

6.3.1 几何布朗运动

定义21.1 若 $B = \{B(t), t \geq 0\}$ 为标准布朗运动， μ 和 σ 是两任意给定的常数，称由 $Y(t) = \sigma B(t) + \mu t$ 定义的若随机过程 $\{Y(t), t \geq 0\}$ 为满足漂移系数为 μ 和方差为 σ^2 的布朗运动。简称带漂移的布朗运动。

显然，对漂移系数为 μ 和方差为 σ^2 的布朗运动而言：

- (1) $Y(0) = 0$;
- (2) $\{Y(t), t \geq 0\}$ 有平稳独立增量;
- (3) $Y(t)$ 服从均值为 μt , 方差为 $\sigma^2 t$ 的正态分布.

定义21.2 若 $Y = \{Y(t), t \geq 0\}$ 为带漂移的布朗运动，那么称由 $X(t) = e^{Y(t)}$ 定义的随机过程 $X = \{X(t), t \geq 0\}$ 为几何布朗运动.

由带漂移布朗运动的独立增量性质以及正态分布性质可得，对任意 $t > u$ 以及函数 g

$$\begin{aligned}
 \mathbb{E}(g(X(t))|X(s), 0 \leq s \leq u) &= \mathbb{E}(g(e^{Y_t})|e^{Y(s)}, 0 \leq s \leq u) \\
 &= \mathbb{E}(g(e^{Y(u)}e^{Y(t)-Y(u)})|e^{Y(s)}, 0 \leq s \leq u) \\
 &= \mathbb{E}(g(e^{Y(u)}e^{Y(t)-Y(u)})|e^{Y(u)}) \\
 &= \int_{-\infty}^{+\infty} g(e^y e^x) \phi(x - \mu(t-u), \sigma^2(t-u)) dx \Big|_{y=Y(u)} \\
 &= \int_{-\infty}^{+\infty} g(X(u)e^x) \phi(x - \mu(t-u), \sigma^2(t-u)) dx,
 \end{aligned} \tag{6.3.1}$$

这里条件 $X(s), 0 \leq s \leq u$ 表示已知 u 之前所有的 $X(s)$ ，进而

$$\begin{aligned}
 \mathbb{E}(X(t)|X(s), 0 \leq s \leq u) &= X(u) \int_{-\infty}^{+\infty} e^x \phi(x - \mu(t-u), \sigma^2(t-u)) dx \\
 &= X(u)e^{(t-u)(\mu+\sigma^2/2)}.
 \end{aligned} \tag{6.3.2}$$

6.3.2 期权定价原理

对现代金融市场而言，期权无处不在。所谓期权是指一种合约，该合约赋予持有人在某一特定日期或该日之前的任何时间以固定价格购进或售出一种资产的权利。期权定义的要点如下：1、期权是一种权利。期权合约至少涉及买人和出售人两方。持有人享有权力但不承担

相应的义务。2、期权的标的物。它包括股票、政府债券等基础证券，也包括货币、股票指数、商品期货等对象。期权是这些标的物“衍生”的，因此称衍生金融工具或衍生证券。值得注意的是，期权出售人不一定拥有标的物。期权是可以“卖空”的。期权购买人也不一定真的想购买资产标的物。因此，期权到期时双方不一定进行标的物的实物交割，而只需按价差补足价款即可。3、到期日。双方约定的期权到期的那一天称为“到期日”，如果该期权只能在到期日执行，则称为欧式期权；如果该期权可以在到期日或到期日之前的任何时间执行，则称为美式期权。4、期权的执行。依据期权合约购进或售出标的资产的行为称为“执行”。在期权合约中约定的，期权持有人据以购进或售出标的资产的固定价格，称为“执行价格”或“敲定价格”。按合约购进/卖出的期权也称为看涨/看跌期权。

若期权敲定价格为 K ，期权标的物在到期日的价格为 P ，那么依据期权合约，一份看涨/看跌期权在到期日的价值分别为 $(P - K)^+$ 和 $(K - P)^+$ 。显然期权对期权合约的买入方是一项有利的经济权利，因此为了获得这份权利期权合约买入方需要给予卖出方一定的经济补偿。确定补偿的合理值就是对期权定价。通常该定价过程遵循两个原则：无套利市场假设和风险中性原理。

套利是指通过市场交易的买卖差价获取利益。所谓无套利市场，直观而言，就是市场上任何交易都不能获得无风险的套利。金融市场上实施套利行为变得非常的方便和快速。在市场有效条件下，这种套利的便捷性也使得金融市场的套利机会的存在总是暂时的，因为一旦有套利机会，投资者就会很快实施套利而使得市场又回到无套利机会的均衡中。因此，无套利市场假设被用于对金融产品进行定价。金融产品在市场的合理价格将使得市场不存在无风险套利机会，这也称为无风险套利定价原理或者简称为无套利定价原理。

在无套利市场条件下，人们进一步提出风险中性定价原理：假设经济环境是风险中性的，即处在该经济环境中的投资者总体而言对待风险的态度是中性的，投资者在投资风险资产时自己承担风险，并不要求任何的风险补偿或风险报酬。基于风险中性假设，在市场不存在任何套利可能性的条件下，风险资产的期望收益率都恰好等于无风险利率。如果衍生证券的价格依赖于可交易的基础证券，那么这个衍生证券的价格是与具体投资者的风险态度无关，而是无风险利率贴现的结果。

就数学模型而言，无套利市场和风险中性假设就是要使得用来刻画市场统计规律的概率空间 (Ω, \mathcal{F}, P) 对任何可投资的风险资产 $X(t)$ 满足：

$$\mathbb{E}(X(t+s)|\mathcal{F}_t) = X(t)e^{\lambda(t-s)},$$

其中 λ 为该市场无风险利率(按复利计算)， \mathcal{F}_t 表示 t 及 t 之前的所有市场信息；而一个在 $t + s$ 时

刻价格为 $Y(t+s)$ 的衍生证券, 在 t 时刻的价格

$$Y(t) = \mathbb{E}(e^{-\lambda s} Y(t+s)|\mathcal{F}_t).$$

如果市场只有一种风险资产 $X(t)$ 和一种无风险资产 $r(t)$, 那么 t 及 t 之前的所有市场信息就由该风险资产的信息构成. 此时

$$\mathbb{E}(X(t+s)|X(u), 0 \leq u \leq t) = X(t)e^{\lambda(t-s)}, \quad (6.3.3)$$

以该风险资产为标的物的衍生证券若 $t+s$ 时刻价格为 $Y(t+s)$, 那么在 t 时刻的价格就是

$$Y(t) = \mathbb{E}(e^{-\lambda s} Y(t+s)|X(u), 0 \leq u \leq t). \quad (6.3.4)$$

6.3.3 Black-Scholes公式

为了简单, 现在我们假定有一个无套利风险中性市场, 市场中只有一种无风险资产, 该资产的收益率为 r (按复利计算), 一种股票, 其价格变化可用过程 $X = \{X_t, t \geq 0\}$ 表示, 和一种衍生证券—以该股票为基础证券的欧式看涨期权, 期权的到期日为 T , 敲定价格为 K .

按期权合约, 期权在到期日的价值为 $(X_T - K)^+$. 因此在无套利及风险中性假设下, (6.3.4)表明该期权在 $0 \leq t \leq T$ 时的价格 C_t 为

$$C_t = \mathbb{E}(e^{-r(T-t)}(X_T - K)^+|X_s, 0 \leq s \leq t).$$

假定股价价格变化过程 X 是一个几何布朗运动 $X(t) = e^{Y(t)}$, 其中 $Y(t)$ 是一个漂移系数为 μ 、方差为 σ^2 的布朗运动. 由(6.3.1)可得

$$\begin{aligned} C_t &= e^{-r(T-t)} \mathbb{E}((X_T - K)^+|X_s, 0 \leq s \leq t) \\ &= e^{-r(T-t)} \int_{-\infty}^{+\infty} (ye^x - K)^+ \phi(x - \mu(T-t), \sigma^2(T-t)) dx \Big|_{y=X(t)} \\ &= e^{-r(T-t)} \int_{\ln(K/y)}^{+\infty} (ye^x - K) \phi(x - \mu(T-t), \sigma^2(T-t)) dx \Big|_{y=X(t)}. \end{aligned}$$

计算可得

$$\begin{aligned} &\int_{\ln(K/y)}^{+\infty} ye^x \phi(x - \mu(T-t), \sigma^2(T-t)) dx \\ &= ye^{(T-t)(\mu+\sigma^2/2)} \int_{\ln(K/y)}^{+\infty} \phi(x - (\mu + \sigma^2)(T-t), \sigma^2(T-t)) dx \\ &= ye^{(T-t)(\mu+\sigma^2/2)} \int_{[\ln(K/y) - (\mu + \sigma^2)(T-t)]/(\sigma\sqrt{T-t})}^{+\infty} \phi(u, 1) du \\ &= ye^{(T-t)(\mu+\sigma^2/2)} \left(1 - \Phi\left(\frac{\ln(K/y) - (\mu + \sigma^2)(T-t)}{\sigma\sqrt{T-t}}\right)\right) \\ &= ye^{(T-t)(\mu+\sigma^2/2)} \Phi\left(\frac{(\mu + \sigma^2)(T-t) - \ln(K/y)}{\sigma\sqrt{T-t}}\right). \end{aligned}$$

另外

$$\begin{aligned} & \int_{\ln(K/y)}^{+\infty} K\phi(x - \mu(T-t), \sigma^2(T-t))dx \\ &= K \int_{[\ln(K/y) - \mu(T-t)]/(\sigma\sqrt{T-t})}^{+\infty} \phi(u, 1)du \\ &= K\Phi\left(\frac{\mu(T-t) - \ln(K/y)}{\sigma\sqrt{T-t}}\right). \end{aligned}$$

记

$$b(K, y, T, t) = \frac{\mu(T-t) - \ln(K/y)}{\sigma\sqrt{T-t}},$$

那么

$$C_t = e^{-r(T-t)} \left[ye^{(T-t)(\mu + \frac{\sigma^2}{2})} \Phi(\sigma\sqrt{T-t} + b(K, y, T, t)) - K\Phi(b(K, y, T, t)) \right]_{y=X(t)}.$$

另一方面, 由(6.3.2)和(6.3.3)可知

$$\mathbb{E}[X(t+s)|X(u), 0 \leq u \leq t] = X(t)e^{(\mu + \sigma^2/2)s} = X(t)e^{rs}.$$

因此

$$r = \mu + \sigma^2/2.$$

将其代入到上面运算结果, 可得

$$C_t = y\Phi(\sigma\sqrt{T-t} + b(K, y, T, t)) - Ke^{-r(T-t)}\Phi(b(K, y, T, t)) \Big|_{y=X(t)}, \quad (6.3.5)$$

其中

$$b(K, y, T, t) = \frac{r(T-t) - \ln(K/y)}{\sigma\sqrt{T-t}} - \frac{\sigma\sqrt{T-t}}{2}.$$

公式(6.3.5)就是著名的欧式看涨期权的定价公式. 对看跌的欧式期权有类似的定价公式, 我们留作练习请同学自己推算.

由(6.3.5)可知, 欧式看涨期权在\$t\$时刻的价格依赖于股票在\$t\$时刻的价格\$y\$, 期权执行的时间\$T\$, 敲定价格\$K\$, 市场无风险利率\$r\$和股票价格参数\$\sigma^2\$, 并且依据定价原理, 该价格是无套利的. 在实际操作中, 容易保证\$y, T\$ 和 \$K\$都是已知的, 但参数\$\sigma^2\$往往是隐含的. 为了得到\$\sigma^2\$, 注意到以指数布朗运动为价格的股票, 对充分小的\$\Delta\$,

$$\frac{X(t+\Delta) - X(t)}{X(t)} \sim Y(t+\Delta) - Y(t) \sim \mu\Delta + \sigma^2[B(t+\Delta) - B(t)].$$

而\$\frac{X(t+\Delta) - X(t)}{X(t)}\$表示股票在\$[t, t + \Delta]\$时间内的收益率. 因此近似地看在不相交的时间区间上股票收益率是独立的, 若不相交的时间区间还是等长的, 收益率还可以看作是同分布的; \$\sigma^2\$为收益率的波动率. 因此人们常用统计方法估计该收益率的波动率并将其视为\$\sigma^2\$的值. 一种较自然地获得\$\sigma^2\$估计的方法如下: 假设获得\$n\$个时长为\$h\$的收益率数据\$x_1, \dots, x_n\$. 此时数据总体看作服从均值为\$\mu h\$和方差为\$\sigma^2 h\$的正态分布, 从而样本无偏方差为\$\sigma^2 h\$的无偏估计.

例21.1 已知某股票现价为100元, 市场无风险的年化复利率为0.15. 某公司创建一种1年后到期的欧式看涨期权, 执行价格设为120, 试给出该期权现在的每份价格. (假定股票价格服从指数布朗运动, 而且过去12个月的月收益率为0.03, 0.09, -0.06, -0.03, 0.10, 0.02, -0.07, 0.04, 0.03, -0.05, 0.02, 0.0)

解 我们先估计 σ^2 . 由12个月的收益率数据可得月收益率无偏方差为

$$\frac{1}{11} \sum_{i=1}^{12} (x_i - \bar{x})^2 = 0.003$$

其中 x_i 表示第*i*个月的收益率, \bar{x} 表示月平均收益率. 从而 $\hat{\sigma}^2 = 12 * 0.003 = 0.036$. 将 $y = 100, K = 120, T = 1, t = 0, r = 0.15, \sigma^2 = 0.036$ 代入(6.3.5)可得,

$$C_0 = 100\Phi(\sqrt{0.036} + b(120, 100, 1, 0)) - 120e^{-0.15}\Phi(b(120, 100, 1, 0))$$

其中

$$b(120, 100, 1, 0) = \frac{0.15 - \ln 1.2}{\sqrt{0.036}} - \frac{\sqrt{0.036}}{2} = -0.26522$$

因此

$$C_0 \approx 100\Phi(-0.075) - 103.285\Phi(-0.265) \approx 47 - 40.85 = 6.15.$$

所以该期权现在的每份价格为6.15元. \square

利用风险中性定价原理我们还可以给出其他类型的衍生证券的价格. 下面这个例子本质上解释了所谓回望看涨期权的定价公式.

例21.2 假设某股票的价格 $P(t) = e^{B(t)}$, 其中 $B(t)$ 为标准布朗运动. 甲乙两人围绕该股票订立合约, 规定: 乙在时刻 s 向甲支付 d 元, 而甲在 $s+T$ 时刻向乙支付 $[s, s+T]$ 时段内该股票最大价格与敲定价格 e^K 之间的价差($\max_{s \leq u \leq s+T} P(u) - e^K$)⁺. 假定无风险年复利率为1/2, 股票在 s 时刻价格为 e^x . 试利用风险中性定价原理确定 d 的值.

解 按风险中性定价原理, d 值应该为乙在 $s+T$ 时刻预期收益在 s 时按风险利率的折现, 即

$$d = e^{-T/2} \mathbb{E}((\max_{s \leq u \leq s+T} P(u) - e^K)^+ | P(s) = e^x, P(u), 0 \leq u < s).$$

计算可得

$$\begin{aligned} & \mathbb{E}((\max_{s \leq u \leq s+T} P(u) - e^K)^+ | P(s) = e^x, P(u), 0 \leq u < s) \\ &= \mathbb{E}((\max_{s \leq u \leq s+T} e^{B(s)+B(u)-B(s)} - e^K)^+ | B(s) = x) \\ &= \mathbb{E}((\max_{0 \leq u \leq T} e^{x+B(u)} - e^K)^+) = \mathbb{E}((e^{x+B^*(T)} - e^K)^+). \end{aligned}$$

由于 $B^*(T)$ 的密度函数为 $2\phi(y, T)$,

$$\mathbb{E}((e^{x+B^*(T)} - e^K)^+) = \int_{(K-x)^+}^{\infty} (e^{x+y} - e^K) 2\phi(y, T) dy$$

$$\begin{aligned}
&= 2e^x \int_{(K-x)^+}^{\infty} e^y \phi(y, T) dy - 2e^K \int_{(K-x)^+}^{\infty} \phi(y, T) dy \\
&= 2e^{x+T/2} \int_{((K-x)^+-T)/\sqrt{T}}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} dy - 2e^K \int_{(K-x)^+/\sqrt{T}}^{\infty} \phi(y, 1) dy \\
&= 2[e^{x+T/2} \Phi((T - (K - x)^+)/\sqrt{T}) - e^K \Phi(-(K - x)^+/\sqrt{T})].
\end{aligned}$$

因此 $d = 2[e^x \Phi((T - (K - x)^+)/\sqrt{T}) - e^{K-T/2} \Phi(-(K - x)^+/\sqrt{T})]$. \square

练习题

21.1 在无套利假设和风险中性原理下推导欧式看跌期权的定价公式.

6.4 高斯过程与积分布朗运动

6.4.1 高斯过程与布朗桥

定义22.1 设 $X = \{X(t); t \in T\}$ 是概率空间 $(\Omega, \mathfrak{F}, \mathbb{P})$ 上的随机过程. 称 X 为高斯过程(系), 若对任意的 $t_1, \dots, t_n \in T$,

$$(X(t_1), X(t_2), \dots, X(t_n))$$

服从正态分布(包括退化情形), 亦即存在 n 维向量 $\mu = \{\mu_1, \dots, \mu_n\}^T$ 以及 n 阶半正定或正定矩阵 \mathbf{D} 使得对任意 $\lambda = (\lambda_1, \dots, \lambda_n)^T \in R^n$,

$$\mathbb{E}(e^{i \sum_{k=1}^n \lambda_k X(t_k)}) = \exp \left\{ i \lambda^T \mu - \frac{1}{2} \lambda^T \mathbf{D} \lambda \right\}.$$

由此可知 $(X(t_1), X(t_2), \dots, X(t_n))$ 的均值向量为 μ , 协方差矩阵为 \mathbf{D} .

显然高斯过程的有限维分布由其均值(函数)和协方差(函数)唯一确定. 由定理19.2, 布朗运动 B 是一个高斯过程; 再由推论19.4, 在 $B(s), B(t)$ 给定的条件下布朗运动 $\{B(u); s < u < t\}$ 也是高斯过程.

定理22.1 $X = \{X(t); t \in T\}$ 是高斯系当且仅当其中任意有限个随机变量的线性组合都服从一元正态分布.

证明 “必要性”: 任取有限个随机变量 $X(t_1), \dots, X(t_n)$ 以及任意 $\lambda_1, \dots, \lambda_n \in \mathbb{R}$, 线性组合 $\sum_{k=1}^n \lambda_k X(t_k)$ 的特征函数

$$\mathbb{E}(e^{iu(\sum_{k=1}^n \lambda_k X(t_k))}) = \mathbb{E}(e^{i(\sum_{k=1}^n u \lambda_k X(t_k))}) = \exp \left\{ iu \lambda^T \mu - \frac{u^2}{2} \lambda^T \mathbf{D} \lambda \right\}$$

由此可知 $\sum_{k=1}^n \lambda_k X(t_k) \sim N(\lambda^T \mu, \lambda^T \mathbf{D} \lambda)$.

“充分性”: 任取 $X(t_1), \dots, X(t_n)$ 以及 $\lambda_1, \dots, \lambda_n \in \mathbb{R}$, 由于 $\sum_{k=1}^n \lambda_k X(t_k)$ 服从正态分布,

$$\begin{aligned} \mathbb{E}(e^{i \sum_{k=1}^n \lambda_k X(t_k)}) &= \exp \left\{ i \mathbb{E} \left(\sum_{k=1}^n \lambda_k X(t_k) \right) - \frac{1}{2} \text{Var} \left(\sum_{k=1}^n \lambda_k X(t_k) \right) \right\} \\ &= \exp \left\{ i \sum_{k=1}^n \lambda_k \mathbb{E}(X(t_k)) - \frac{1}{2} \sum_{k,j=1}^n \lambda_k \lambda_j \text{Cov}(X(t_k), X(t_j)) \right\} \\ &= \exp \left\{ i \lambda^T \mu - \frac{1}{2} \lambda^T \mathbf{D} \lambda \right\} \end{aligned}$$

其中 $\mu = \{\mathbb{E}(X(t_1)), \dots, \mathbb{E}(X(t_n))\}$, $\mathbf{D} = (\text{Cov}(X(t_i), X(t_j)))_{i,j}$ 正定或半正定. \square

例22.1 设 W 为标准布朗运动, 对任意 $x, y \in \mathbb{R}$, 给定 $0 \leq s < t$, 对任意 $u \in [s, t]$, 令

$$W_x^y(u) = W(u) + \left(\frac{t-u}{t-s}(x-W(s)) + \frac{u-s}{t-s}(y-W(t)) \right).$$

一般称 $\{W_x^y(u); s \leq u \leq t\}$ 为布朗桥. 任取 $s \leq u_1 < \dots < u_n \leq t$, $\lambda_1, \dots, \lambda_n \in \mathbb{R}$,

$$\sum_{k=1}^n \lambda_k W_x^y(t_k) = \sum_{k=1}^n \lambda_k \left[W(u_k) + \left(\frac{t-u}{t-s}(x-W(s)) + \frac{u-s}{t-s}(y-W(t)) \right) \right]$$

$$= \sum_{k=1}^n \lambda_k W(u_k) - \left(\sum_{k=1}^n \frac{\lambda_k(t-u_k)}{t-s} \right) W(s) - \left(\sum_{k=1}^n \frac{\lambda_k(u_k-s)}{t-s} \right) W(t) + C.$$

其中常数 $C = \sum_{k=1}^n \frac{\lambda_k(u_k-s)}{t-s}(y-x)$. 由于标准布朗运动是高斯过程, 定理22.1表明布朗桥也是高斯过程. 注意到 $W_x^y(s) \equiv x, W_x^y(t) \equiv y$,

$$\mathbb{E}(W_x^y(u)) = x + \frac{u-s}{t-s}(y-x),$$

而且直接计算可知对任意 $u \leq v \in [s, t]$,

$$\begin{aligned} & \text{Cov}(W_x^y(u), W_x^y(v)) \\ &= \text{Cov}\left(W(u) - \frac{t-u}{t-s}W(s) - \frac{u-s}{t-s}W(t), W(v) - \frac{t-v}{t-s}W(s) - \frac{v-s}{t-s}W(t)\right) \\ &= \text{Cov}\left(W(u), W(v) - \frac{t-v}{t-s}W(s) - \frac{v-s}{t-s}W(t)\right) = \frac{(t-v)(u-s)}{t-s}. \end{aligned}$$

由于高斯过程有限维分布由其均值函数和协方差函数唯一确定, 对照推论15.4, 可知

$$\{W_x^y(u); u \in [s, t]\}$$

与给定条件 $B(s) = x, B(t) = y$ 的布朗运动 $\{B(u), s \leq u \leq t\}$ 有相同的有限维分布, 从而可看作是它的一个版本. 注意在 $\{W_x^y(u)\}$ 的构造中, 我们并没有对标准布朗运动 W 设定额外的条件. \square

推论22.2 若 $\{X(t); t \in T\}$ 是高斯过程, 那么对任意 $s_k < t_k, k = 1, 2, \dots, n$,

$$\{X(t_k) - X(s_k), k = 1, 2, \dots, n\}$$

是 n 维正态随机变量.

证明 对任意 $\lambda_k \in \mathbb{R}, k = 1, 2, \dots, n$, 由定理22.1

$$\sum_{k=1}^n \lambda_k (X(t_k) - X(s_k)) = \sum_{k=1}^n \lambda_k X(t_k) + \sum_{k=1}^n (-\lambda_k) X(s_k)$$

为一维正态随机变量, 进而再用一次定理22.1可知推论成立. \square

命题22.3 轨道连续的高斯过程 $\{X(t), t \geq 0\}$ 若对任意 $0 \leq s \leq t$ 都有

$$\mathbb{E}(X(s)) = 0 \text{ 且 } \mathbb{E}(X(s)X(t)) = s,$$

那么 $X = \{X(t); t \geq 0\}$ 是标准布朗运动.

证明 只需验证布朗运动的三个条件(a),(b),(c).

(a) X 轨道连续且由条件 $\mathbb{E}(X(0)^2) = 0$ 可知 $X(0) = 0$ a.s.

(b) 对任意 $0 \leq s_1 < t_1 \leq s_2 < t_2$,

$$\mathbb{E}[(X(t_2) - X(s_2))(X(t_1) - X(s_1))]$$

$$= \mathbb{E}[X(t_2)X(t_1)] - \mathbb{E}[X(t_2)X(s_1)] - \mathbb{E}[X(s_2)X(t_1)] + \mathbb{E}[X(s_2)X(s_1)] = 0.$$

由于 $(X(t_2) - X(s_2), X(t_1) - X(s_1))$ 为二维正态随机变量, 从而独立. 因此对任意 $0 \leq t_1 <$

$t_2 < \dots < t_n$

$$X(t_1), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})$$

的协方差矩阵为对角矩阵. 这表明 $(X(t_1), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1}))$ 独立.

(c) 对任意 $0 \leq s < t$, 由 $\mathbb{E}(X(t) - X(s)) = 0$,

$$\mathbb{E}[(X(t) - X(s))^2] = \mathbb{E}[X^2(t) + X^2(s) - 2X(s)X(t)] = t - s$$

以及 $X(t) - X(s)$ 服从正态分布可知 $X(t) - X(s) \sim N(0, t - s)$. \square

命题22.4 设 $\xi_n, n \geq 1$, 是一列正态随机变量. 若 $\xi_n \xrightarrow{P} X$, 那么 X 也是正态随机变量, 而且

$$\mathbb{E}(X) = \lim_{n \rightarrow \infty} \mathbb{E}(\xi_n), \quad \text{Var}(X) = \lim_{n \rightarrow \infty} \text{Var}(\xi_n).$$

证明 由于 $\xi_n, n \geq 1$, 是一列正态随机变量, 存在 μ_n, σ_n^2 使得对任意 $\lambda \in R$

$$\mathbb{E}(e^{i\lambda\xi_n}) = \exp\left\{i\lambda\mu_n - \frac{\lambda^2}{2}\sigma_n^2\right\}.$$

由 $\xi_n \xrightarrow{P} X$ 可知 $\mathbb{P}(|X| < \infty) = 1$ 而且 $\mathbb{E}(e^{i\lambda\xi_n}) \rightarrow \mathbb{E}(e^{i\lambda\xi}) := \Psi(\lambda)$. 因此

$$|\mathbb{E}(e^{i\lambda\xi_n})| = e^{-\frac{\lambda^2}{2}\sigma_n^2} \rightarrow |\Psi(\lambda)|, \quad i\lambda\mu_n - \frac{\lambda^2}{2}\sigma_n^2 \rightarrow \ln \Psi(\lambda).$$

注意到 $\Psi(0) = 1$ 且由 $\Psi(\lambda)$ 连续可知存在 $\delta > 0$ 使得对任意 $\lambda \in (-\delta, \delta)$, $|\Psi(\lambda)| > 0$. 这表

明 $n \rightarrow \infty$ 时, σ_n^2 极限存在且有限, 记作 σ^2 . 注意到

$$\mathbb{E}(e^{i\lambda(\xi_n - \mu_n)}) = \exp\left\{-\frac{\lambda^2}{2}\sigma_n^2\right\} \rightarrow \exp\left\{-\frac{\lambda^2}{2}\sigma^2\right\}.$$

因此 $\xi_n - \mu_n \xrightarrow{d} N(0, \sigma^2)$. 记 $\liminf_{n \rightarrow \infty} \mu_n = a$, $\limsup_{n \rightarrow \infty} \mu_n = b$, 那么由 $\xi_n \xrightarrow{P} X$ 可知

$$X - a \xrightarrow{d} N(0, \sigma^2) \quad X - b \xrightarrow{d} N(0, \sigma^2)$$

因此 $a = b < \infty$. μ_n 极限也存在, 记作 μ . 从而 $X \sim N(\mu, \sigma^2)$ 为正态随机变量. \square

由命题22.4容易得到以下推论, 证明请读者自己完成.

推论22.5 设 $\{X(t); t \in T\}$ 是高斯过程, $t_l^k \in T$, ($k = 1, 2, \dots, m, l = 1, 2, \dots$). 若对任何固定的 k , $X(t_l^k)$ 依概率收敛于 $Y(k)$ 那么 $\{X(t); t \in T\} \cup \{Y_k; k = 1, 2, \dots, m\}$ 仍是高斯系, 而且 $\text{Cov}(Y_k, Y_n) = \lim_{l \rightarrow \infty} \text{Cov}(X(t_l^k), X(t_l^n))$.

6.4.2 与布朗运动有关的简单积分

在本章的最后, 我们介绍两类特殊情形下与布朗运动有关的积分.

设 B 是布朗运动, 由于 $B(t)$ 关于 t 连续, 以 $B(t)$ 为被积函数, 黎曼积分 $\int_0^t B(u)du$ 总有意义.

一般地称随机过程 $\{\int_0^t B(u)du; t \geq 0\}$ 为积分布朗运动.

更一般地设 $f(t)$ 是具有连续一阶导数的非随机函数, 对任意 $0 \leq a \leq b$, 黎曼积分

$$\int_a^b B(u) df(u) = \int_a^b B(u) f'(u) du = \lim_{\delta \rightarrow 0} \sum_{\substack{i=1 \\ \delta=\max\{t_i-t_{i-1}\}}}^n B(t_i) f'(t_i)(t_i - t_{i-1}),$$

总有意义, 其中 $a = t_0 < t_1 < \dots < t_n = b$ 为 $[a, b]$ 的任一分割. 注意上式右边极限中每个部分和都是正态随机变量, 因此由命题22.4可知 $\int_a^b B(u) df(u)$ 服从正态分布. 进一步由推论22.5还可得随机过程

$$\left\{ \int_a^t B(u) df(u); t \geq a \right\}$$

是高斯过程. 直接计算可知对任意 $s, t \geq a$,

$$\begin{aligned} \mathbb{E} \left(\int_a^t B(u) df(u) \right) &= \int_0^t \mathbb{E}(B(u)) df(u) = 0, \\ \text{Cov} \left(\int_a^t B(u) df(u), \int_a^s B(v) df(v) \right) &= \int_a^t \int_a^s \mathbb{E}(B(u)B(v)) df(u) df(v) \\ &= \int_a^s \int_a^t (s \wedge t) df(s) df(u). \end{aligned}$$

由上述分析可知, 当 B 是标准布朗运动时, 积分布朗运动 $\int_0^t B(u) du$ 是均值为0、协方差(函数)为

$$\begin{aligned} R(s, t) &= \int_0^s \int_0^t (u \wedge v) du dv = \int_0^s \int_0^s (u \wedge v) du dv + \int_0^s \int_s^t (u \wedge v) du dv \\ &= \frac{s^3}{3} + \frac{(t-s)s^2}{2} = s^2 \left(\frac{t}{2} - \frac{s}{6} \right), \quad s \leq t, \end{aligned}$$

的高斯过程, 而且 $\int_0^t B(u) du \sim N(0, t^3/3)$.

对布朗运动还可以讨论另外一种形式积分. 这里我们简单介绍 $f(t)$ 是具有连续一阶导数的非随机函数情形(对于更一般的情形请参阅[4]), 对任意 $0 \leq a \leq b$, 定义区间 $[a, b]$ 上随机积分

$$\int_a^b f(s) dB(s) = \lim_{\delta \rightarrow 0} \sum_{\substack{i=1 \\ \delta=\max\{t_i-t_{i-1}\}}}^n f(t_{i-1}) [B(t_i) - B(t_{i-1})]. \quad (6.4.1)$$

其中 $a = t_0 < t_1 < \dots < t_n = b$ 为 $[a, b]$ 的任一分割. 注意到

$$\sum_{i=1}^n \phi(t_{i-1}) [B(t_i) - B(t_{i-1})] = f(b)B(b) - \phi(a)B(a) - \sum_{i=1}^n B(t_i) (f(t_i) - f(t_{i-1}))$$

因此

$$\int_a^b f(s) dB(s) = \phi(b)B(b) - \phi(a)B(a) - \int_a^b B(s) df(s),$$

通常我们称该式为随机积分的分部积分公式. 由(6.4.1)可知, 当 $\phi(t)$ 为非随机函数时, 极限中的部分和仍为正态随机变量, 因此 $\int_a^b f(s) dB(s)$ 也是正态随机变量. 进一步由推论22.5还可知随机过程

$$\left\{ \int_a^t f(u) dB(u); t \geq a \right\}$$

也是高斯过程. 当 B 是标准布朗运动时, 对任意 $a \leq s \leq t$ 以及 $[0, t]$ 中的分割 $0 = t_0 < t_1 <$

$$\cdots < t_m = s < \cdots < t_n = t$$

$$\begin{aligned} \mathbb{E}\left(\int_a^t f(u)dB(u)\right) &= \lim_{\delta \rightarrow 0} \sum_{i=1}^n f(t_{i-1})(\mathbb{E}[B(t_i)] - \mathbb{E}[B(t_{i-1})]) \\ &= \int_a^t f(u)d\mathbb{E}(B(u)) = 0, \\ \text{Cov}\left(\int_a^t f(u)dB(u), \int_a^s f(u)dB(u)\right) &= \lim_{\delta \rightarrow 0} \mathbb{E}\left(\sum_{i=1}^n f(t_{i-1})[B(t_i) - B(t_{i-1})] \sum_{i=1}^m f(t_{i-1})[B(t_i) - B(t_{i-1})]\right) \\ &= \lim_{\delta \rightarrow 0} \mathbb{E}\left(\sum_{i=1}^m f^2(t_{i-1})[B(t_i) - B(t_{i-1})]^2\right), \quad \text{由布朗运动独立增量性} \\ &= \lim_{\delta \rightarrow 0} \sum_{i=1}^m f^2(t_{i-1})(t_i - t_{i-1}) = \int_a^s f^2(u)du. \end{aligned}$$

例22.2 设 B 是标准布朗运动, 试求出 $\int_0^1 u dB(u)$ 在 $B(1) = 1$ 条件下的分布.

解 由于 $B(1) = 1$ 条件下布朗运动仍是高斯过程, 由(6.4.1)可知, 此时 $\int_0^1 u dB(u)$ 仍是正态随机变量. 由推论19.4以及习题19.2, 仿上面的计算过程可知

$$\begin{aligned} \mathbb{E}\left(\int_0^1 u dB(u) | B(1) = 1\right) &= \int_0^1 u d\mathbb{E}(B(u) | B(1) = 1) = \int_0^1 u du = \frac{1}{2}, \\ \mathbb{E}\left[\left(\int_0^1 u dB(u)\right)^2 | B(1) = 1\right] &= \lim_{\delta \rightarrow 0} \sum_{i=1}^m t_{i-1}^2 \mathbb{E}\left([B(t_i) - B(t_{i-1})]^2 | B(1) = 1\right) \\ &= \lim_{\delta \rightarrow 0} \sum_{i=1}^m t_{i-1}^2 (t_i - t_{i-1}) = \int_0^1 t^2 dt = 1/3. \end{aligned}$$

即 $(\int_0^1 u dB(u) | B(1) = 1) \sim N(1/2, 1/3)$. □

要注意的是在随机积分表达式 $\int \phi(t)dB(t)$ 中, 虽然我们借用了微分符号 $dB(t)$, 但它并不是 $B(t)$ 的真实微分, 因为由定理19.7可知布朗运动 B 是处处不可微的. 通常我们称 $dB(t)$ 为白噪声(或将 $dB(t)$ 记作 $\dot{B}(t)dt$, 而称 $\dot{B}(t)$ 为白噪声).

练习题

22.1 设 $B = \{B(t), t \geq 0\}$ 为标准布朗运动, 试确定 $Y = \int_0^1 B(s)ds$ 的分布. 若 $B(1) = x$, 试在此条件下再确定 Y 的分布.

22.2 设 B 是标准布朗运动, 试求出 $\int_0^1 u dB(u)$ 在 $B(1) = x$ 条件下的分布.

22.3* 证明推论22.5.

第七章 离散鞅

鞅(Martingale)这个概念来自赌博策略研究, 其构词法来自法文中的首字母缩写. 鞅自Lévy和Doob等人将其引入概率论后, 目前已成为研究随机问题的一个强有力工具. 本章将简要地介绍离散时间鞅的基本理论.

7.1 鞅与停时

7.1.1 鞅的定义及举例

定义23.1 设 $X = \{X_n; n \geq 0\}$, $Y = \{Y_n; n \geq 0\}$ 是两个随机过程, 称随机过程 X 关于 Y 是鞅(下鞅, 上鞅), 若对每个 $n \geq 0$,

- (1) $\mathbb{E}(|X_n|) < \infty$,
- (2) X_n 是 X_0, Y_0, \dots, Y_n 的函数.
- (3) $\mathbb{E}(X_{n+1}|X_0, Y_0, \dots, Y_n) = X_n (\geq X_n, \leq X_n)$,

注23.1 当 X 关于 Y 是鞅时, 由条件数学期望性质, 定义中条件(2)自然成立.

从定义上看, 所谓(下, 上)鞅就是在已知 X_0, Y_0, \dots, Y_n 条件下, X_{n+1} 的条件期望与 X_n 相同(比 X_n 大, 比 X_n 小). 更形象些, 若将时刻 n 理解为现在, X_0, Y_0, \dots, Y_n 理解为的现在的信息, 那么(下, 上)鞅就是在掌握现在信息的条件下预测未来与现在相同(优于现在, 劣于现在). 若 $Y = X$ 或由上下文 Y 不言自明时, 我们也简称 $\{X_n; n \geq 0\}$ 为鞅(下鞅, 上鞅).

作为(下, 上)鞅最早的例子, 出现在赌徒问题研究中.

例23.1 假定某赌徒参与某种轮盘赌, 设赌徒初始赌本为 a , 以 X_i 表示赌徒每局赢或输的筹码, 以 Y_0 表示赌局的初始信息, Y_i 表示赌徒从第 i 个赌局中所能获得的所有信息, 令 $S_0 = a$, $S_n = S_{n-1} + X_n = a + \sum_{k=1}^n X_k$, 那么 S_n 表示第 n 局后改赌徒拥有的资本.

- (1) 若对任意 $n \geq 0$, $\mathbb{E}(X_{n+1}|S_0, Y_0, \dots, Y_n) = 0$, 那么

$$\begin{aligned}\mathbb{E}(S_{n+1}|S_0, Y_0, \dots, Y_n) &= \mathbb{E}(S_n + X_{n+1}|S_0, Y_0, \dots, Y_n) \\ &= \mathbb{E}(S_n|S_0, Y_0, \dots, Y_n) + \mathbb{E}(X_{n+1}|S_0, Y_0, \dots, Y_n) = S_n,\end{aligned}$$

即 $S = \{S_n; n \geq 0\}$ 关于 $Y = \{Y_n; n \geq 1\}$ 是鞅.

(2) 若对任意 $n \geq 0$, $\mathbb{E}(X_{n+1}|S_0, Y_0, \dots, Y_n) > 0$, 那么

$$\begin{aligned}\mathbb{E}(S_{n+1}|S_0, Y_0, \dots, Y_n) &= \mathbb{E}(S_n + X_{n+1}|S_0, Y_0, \dots, Y_n) \\ &= \mathbb{E}(S_n|S_0, Y_0, \dots, Y_n) + \mathbb{E}(X_{n+1}|S_0, Y_0, \dots, Y_n) \geq S_n\end{aligned}$$

即 S 关于 Y 是下鞅.

(3) 若对任意 $n \geq 0$, $\mathbb{E}(X_{n+1}|S_0, Y_0, \dots, Y_n) < 0$, 那么

$$\begin{aligned}\mathbb{E}(S_{n+1}|S_0, Y_0, \dots, Y_n) &= \mathbb{E}(S_n + X_{n+1}|S_0, Y_0, \dots, Y_n) \\ &= \mathbb{E}(S_n|S_0, Y_0, \dots, Y_n) + \mathbb{E}(X_{n+1}|S_0, Y_0, \dots, Y_n) \leq S_n,\end{aligned}$$

即 S 关于 Y 是上鞅. \square

直观而言, 在赌博模型中 S 为鞅表示赌局(设置)是公平的; 若 S 不是鞅, 那么赌局(设置)是不公平的, 上鞅则有利于“庄家”, 下鞅则有利于赌徒. 由赌徒模型还可以看出, 由于赌本 S_n 的变化不足以完全反映赌场信息的变化, 在鞅的定义中引进“信息”过程 Y 在有些时候是很有必要的.

下面例子表明, 鞅(现象)在随机过程中可以自然地出现.

例23.2 设 $Y = \{Y_n; n \geq 0\}$ 是状态空间 S 上时齐马氏链, 转移概率矩阵 $\mathbf{P} = (p_{i,j})$. 对 S 上任意有界函数 g , 令 $\phi(i) \triangleq \sum_{j \in S} p_{i,j}g(j)$, $i \in S$, 定义

$$X_0 = g(Y_0), \quad X_n = g(Y_n) - \sum_{k=0}^{n-1} [\phi(Y_k) - g(Y_k)], \quad n \geq 1.$$

那么由条件期望性质与马氏性, 对任意 $n \geq 1$

$$\begin{aligned}\mathbb{E}(X_{n+1}|Y_0, \dots, Y_n) &= \mathbb{E}(g(Y_{n+1})|Y_n) - \sum_{k=0}^n [\phi(Y_k) - g(Y_k)] \\ &= \sum_{j \in S} p_{i,j}g(j)|_{i=Y_n} - \sum_{k=0}^n [\phi(Y_k) - g(Y_k)] = \phi(Y_n) - \sum_{k=0}^n [\phi(Y_k) - g(Y_k)] \\ &= g(Y_n) - \sum_{k=0}^{n-1} [\phi(Y_k) - g(Y_k)] = X_n.\end{aligned}$$

这表明 $X = \{X_n; n \geq 0\}$ 关于 Y 为鞅. 特别, 若对任意 $i \in S$, $\phi(i) = (\geq, \leq)g(i)$, 那么 $X = \{g(Y_n); n \geq 0\}$ 为鞅(下鞅, 上鞅). \square

例23.3 设 $X = \{X_n; n \geq 1\}$ 为独立同分布随机变量.

- (1) 若 $\mathbb{E}(X_n) = \mu$, 令 $S_0 = 0$, $S_n = \sum_{k=1}^n X_i - n\mu$, 则 $S = \{S_n; n \geq 0\}$ 关于 X 为鞅.
- (2) 若存在 $\lambda \in R$ 使得 $\phi(\lambda) = \mathbb{E}(e^{\lambda X_n}) < \infty$, 令

$$Y_n = [\phi(\lambda)]^{-n} e^{\lambda \sum_{i=1}^n X_i}, \quad n \geq 0, \quad (\text{规定 } Y_0 = 1)$$

则 $\{Y_n; n \geq 0\}$ 为鞅. 特别, 若 $\phi(\lambda_0) = 1$, 则 $\{\exp\{\lambda_0 \sum_{i=1}^n X_i\}; n \geq 0\}$ 为鞅.

(3) 设 f_0, f_1 为两概率密度函数, 令

$$L_n = \prod_{i=1}^n \frac{f_1(X_i)}{f_0(X_i)}, \quad n \geq 0, \text{ (规定 } L_0 = 1\text{)}$$

在假设检验中以 X_n 的分布密度函数为 f_0 为原假设, 此时 $\{L_n, n \geq 0\}$ 为鞅.

解 (1) 对任意 $n \geq 0$

$$\begin{aligned} \mathbb{E}(S_{n+1}|S_0, X_1, \dots, X_n) &= \mathbb{E}(S_n + X_{n+1} - \mu|S_0, X_1, \dots, X_n) \\ &= S_n + \mathbb{E}(X_{n+1} - \mu|S_0, X_1, \dots, X_n) = S_n. \end{aligned}$$

所以 $\{S_n, n \geq 0\}$ 为鞅.

(2) 对任意 $n \geq 0$

$$\begin{aligned} \mathbb{E}(Y_{n+1}|Y_0, X_1, \dots, X_n) &= \mathbb{E}(Y_n \phi^{-1}(\lambda) e^{\lambda X_{n+1}}|Y_0, X_1, \dots, X_n) \\ &= Y_n \phi^{-1}(\lambda) \mathbb{E}(e^{\lambda X_{n+1}}) = Y_n. \end{aligned}$$

所以 $\{Y_n, n \geq 0\}$ 为鞅.

(3) 在 X_n 的概率分布密度函数为 f_0 的条件假设下, 对任意 $n \geq 0$

$$\begin{aligned} \mathbb{E}(L_{n+1}|L_0, X_1, \dots, X_n) &= \mathbb{E}\left(L_n \frac{f_1(X_{n+1})}{f_0(X_{n+1})} \middle| L_0, X_1, \dots, X_n\right) \\ &= L_n \mathbb{E}\left(\frac{f_1(X_{n+1})}{f_0(X_n)}\right) = L_n \int_{-\infty}^{\infty} f_1(x) dx = L_n. \end{aligned}$$

所以 $\{L_n, n \geq 0\}$ 为鞅. \square

例23.4 (1) 设 $N(t)$ 是强度为 λ 的泊松过程, 对任意非负递增数列 $\{t_n\}$, 令

$$M_n = N(t_n) - \lambda t_n.$$

那么由条件数学期望性质与独立增量性

$$\begin{aligned} \mathbb{E}(M_{n+1}|M_0, \dots, M_n) &= M_n + \mathbb{E}(M_{n+1} - M_n|M_0, \dots, M_n) \\ &= M_n + \mathbb{E}(N(t_{n+1}) - N(t_n) - \lambda(t_{n+1} - t_n)|N(t_0), \dots, N(t_n)) \\ &= M_n + \mathbb{E}(N(t_{n+1}) - N(t_n) - \lambda(t_{n+1} - t_n)) = M_n. \end{aligned}$$

因此 $\{N(t_n) - \lambda t_n; n \geq 0\}$ 是鞅.

(2) 设 $B(t)$ 是方差为 σ^2 的布朗运动, 对任意 $0 \leq t_0 < t_1 < \dots < t_n < \dots$, 令

$$M_n = \exp\left\{-\lambda B(t_n) - \frac{\lambda \sigma^2 t_n}{2}\right\}.$$

那么同样由条件数学期望性质, 独立增量性与正态性

$$\begin{aligned} \mathbb{E}(M_{n+1}|M_0, \dots, M_n) &= M_n \mathbb{E}\left(\exp\left\{\lambda(B(t_{n+1}) - B(t_n)) - \frac{\lambda \sigma^2 (t_{n+1} - t_n)}{2}\right\} \middle| B(t_0), \dots, B(t_n)\right) \end{aligned}$$

$$= M_n \mathbb{E}(\exp\{\lambda(B(t_{n+1}) - B(t_n)) - \frac{\lambda\sigma^2(t_{n+1} - t_n)}{2}\}) = M_n.$$

因此 $\{\exp\{\lambda B(t_n) - \frac{\lambda\sigma^2 t_n}{2}\}; n \geq 0\}$ 也是鞅.

□

7.1.2 鞅的简单性质

由定义23.1可知在给定“信息”过程条件下, $X = \{X_n; n \geq 0\}$ 为上鞅当且仅当 X 为下鞅;
 X 为鞅当且仅当 X 既是上鞅又是下鞅.

性质23.1 若随机过程 $X = \{X_n; n \geq 0\}$, $Y = \{Y_n; n \geq 0\}$ 关于 $\{Z_n; n \geq 0\}$ 都是上鞅(下鞅),
 则

- (1) $\mathbb{E}(X_n), \mathbb{E}(Y_n)$ 是非增(降)数列;
- (2) 对任意非负实数 α, β , $\{\alpha X_n + \beta Y_n; n \geq 0\}$ 是上鞅(下鞅);
- (3) $\{X_n \wedge Y_n; n \geq 0\}$ 是上鞅($\{X_n \vee Y_n; n \geq 0\}$ 是下鞅).

证明 以上鞅为例, 只证(3), 其他显然成立. 对任意 $n \geq 0$

$$\mathbb{E}(X_{n+1} \wedge Y_{n+1} | Z_0, \dots, Z_n) \leq \mathbb{E}(Y_{n+1} | Z_0, \dots, Z_n) \leq Y_n,$$

而且

$$\mathbb{E}(X_{n+1} \wedge Y_{n+1} | Z_0, \dots, Z_n) \leq \mathbb{E}(X_{n+1} | Z_0, \dots, Z_n) \leq X_n.$$

因此

$$\mathbb{E}(X_{n+1} \wedge Y_{n+1} | Z_0, \dots, Z_n) \leq \min\{X_n, Y_n\} = X_n \wedge Y_n.$$

所以 $\{X_n \wedge Y_n, n \geq 0\}$ 仍是上鞅. □

引理23.2(Jessen不等式) 设 $\psi(x)$ 是 \mathbb{R} 上凸函数, X 为随机变量,

$$\mathbb{E}(|X|) < \infty \text{ 且 } \mathbb{E}(|\psi(X)|) < \infty,$$

那么 $\psi(\mathbb{E}(X)) \leq \mathbb{E}(\psi(X))$. 进一步, 任取随机变量序列 $\{Y_n, n \geq 0\}$, 对任意 $n \geq 0$

$$\psi(\mathbb{E}(X | Y_0, \dots, Y_n)) \leq \mathbb{E}(\psi(X) | Y_0, \dots, Y_n).$$

证明 只证后一个不等式. 由于 ψ 是凸函数, 由数学分析知识可知 ψ 的左右导数都存在且对任意 $x, y \in \mathbb{R}$

$$\psi(y) - \psi(x) \geq \psi'_+(x)(y - x),$$

其中 $\psi'_+(y)$ 表示 y 的右导数. 因此

$$\psi(x) - \psi(\mathbb{E}(X | Y_0, \dots, Y_n)) \geq \psi'_+(\mathbb{E}(X | Y_0, \dots, Y_n))(X - \mathbb{E}(X | Y_0, \dots, Y_n)).$$

两边关于 Y_0, \dots, Y_n 求条件期望得

$$\begin{aligned} & \mathbb{E}(\psi(x) - \psi(\mathbb{E}(X|Y_0, \dots, Y_n))|Y_0, \dots, Y_n) \\ & \geq \psi'_+(\mathbb{E}(X|Y_0, \dots, Y_n))\mathbb{E}(X - \mathbb{E}(X|Y_0, \dots, Y_n)|Y_0, \dots, Y_n) \\ & \geq \psi'_+(\mathbb{E}(X|Y_0, \dots, Y_n))[\mathbb{E}(X|Y_0, \dots, Y_n) - \mathbb{E}(X|Y_0, \dots, Y_n)] = 0. \end{aligned}$$

因此 $\mathbb{E}(\psi(x)|Y_0, \dots, Y_n) \geq \psi(\mathbb{E}(X|Y_0, \dots, Y_n))$. \square

注意到对任意 $r > 1, x^r, x > 0$ 为凸函数, 由Jessen不等式可得 Hölder不等式:

$$\mathbb{E}(|X|^r) \geq [\mathbb{E}(|X|)]^r \text{ 即 } \mathbb{E}(|X|) \leq [\mathbb{E}(|X|^r)]^{1/r}.$$

性质23.3 设 $\{X_n\}$ 关于 $\{Y_n\}$ 为(下)鞅, $\psi(x)$ 为 \mathbb{R} 上(非降)凸函数. 若 $\mathbb{E}(|\psi(X_n)|) < \infty$ 对所有 $n \geq 0$ 都成立, 那么 $\{\psi(X_n), n \geq 0\}$ 是下鞅.

证明 由Jessen不等式, 对任意 $n \geq 0$

$$\mathbb{E}(\psi(X_{n+1})|Y_0, \dots, Y_n) \geq \psi(\mathbb{E}(X_{n+1}|Y_0, \dots, Y_n)) = \psi(X_n)(\geq \psi(X_n)).$$

因此 $\{\psi(X_n), n \geq 0\}$ 是下鞅. \square

由性质23.3我们容易构造出下鞅. 若 $\{X_n; n \geq 0\}$ 是鞅, 只要下面的随机变量序列有意义且可积, 那么

$$\{|X_n|; n \geq 0\}, \quad \{e^{X_n}; n \geq 0\}, \quad \{-\ln(X_n), n \geq 0\}$$

都是下鞅, 而当 $r \geq 1$ 时 $\{|X_n|^r; n \geq 0\}$ 也是下鞅.

性质23.4 若 $Y = \{Y_n; n \geq 0\}$ 关于 $X = \{X_n; n \geq 0\}$ 是下鞅, 那么存在一个关于 X 的鞅 $\{M_n; n \geq 0\}$ 使得

$$Y_n = M_n + N_n,$$

其中 $\{N_n; n \geq 0\}$ 是一个单调不降的随机序列, $N_0 = 0$ 且 N_n 由 Y_0, X_0, \dots, X_{n-1} 完全给定.

证明 对任意 $n \geq 1$, 令

$$N_n = \sum_{k=0}^{n-1} [\mathbb{E}(Y_{k+1}|Y_0, X_0, \dots, X_k) - Y_k].$$

由条件数学期望与下鞅定义可知 N_n 是 Y_0, X_0, \dots, X_{n-1} 的函数, 而且 $\{N_n; n \geq 1\}$ 是一个单调不降的随机序列. 再令 $M_n = Y_n - N_n$, 那么

$$\begin{aligned} & \mathbb{E}(M_{n+1}|Y_0, X_0, \dots, X_n) \\ & = \mathbb{E}(Y_{n+1}|Y_0, X_0, \dots, X_n) - \sum_{k=0}^n [\mathbb{E}(Y_{k+1}|Y_0, X_0, \dots, X_k) - Y_k] \\ & = Y_n - \sum_{k=0}^{n-1} [\mathbb{E}(Y_{k+1}|Y_0, X_0, \dots, X_k) - Y_k] = M_n. \end{aligned}$$

由此可知 M_n 为鞅进而结论成立. \square

一般地, 我们称 N_n 这种任意 n 步时的值能由 n 步以前信息 $(Y_0, X_0, \dots, X_{n-1})$ 唯一确定的随机过程为可料的(Predictable)或可容许的(Admissible).

例23.5 一个赌徒参加一种掷色子的赌博, 以 X_i 表示第 i 局该赌徒的胜负情况, 若赌徒胜则 $X_i = 1$, 否则 $X_i = -1$. 假设每一局胜负结果相互独立, 而且 $\mathbb{P}(X_i = 1) \leq 1/2$. 问该赌徒能否通过倍增策略(即首局投注1, 后面每局投注都是前一局的两倍直到该赌徒赢得一局, 然后重新执行这种投注策略)实现稳赢? (约定 $X_0 = 1$)

解 以 H_n 表示第 n 局的投注量, 显然 H_n 的可能取值为 $\{1, 2, \dots, 2^{n-1}\}$ 而且对任意 $k \leq n-1$,

$$\{H_n = 2^k\} = \{X_{n-k-1} = 1, X_{n-k} = -1, \dots, X_{n-1} = -1\}$$

因此 H_n 为 X_0, X_1, \dots, X_{n-1} 的函数, 即存在函数 $\phi_n \leq 2^n$ 使得

$$H_n = \phi_n(X_0, X_1, \dots, X_{n-1}).$$

到第 n 局, 该赌徒赢得的赌注为

$$M_n = \sum_{k=1}^n H_k X_k.$$

令 $M_0 = 0$, 由条件期望性质

$$\begin{aligned} \mathbb{E}(M_n | M_0, X_0, \dots, X_{n-1}) &= \sum_{k=1}^n \mathbb{E}(H_k X_k | M_0, X_0, \dots, X_{n-1}) \\ &= \sum_{k=1}^{n-1} H_k X_k + H_n \mathbb{E}(X_n | M_0, X_0, \dots, X_{n-1}) \leq \sum_{k=1}^{n-1} H_k X_k = M_{n-1} \end{aligned}$$

即 M_n 关于 X_n 为上鞅, 从而 $\mathbb{E}(M_n)$ 为非增序列. 这表明倍增策略不能实现稳赢. \square

7.1.3 停时及其简单性质

在第二章第一节中, 我们已给出了离散随机过程的停时定义. 我们称非负整数值的随机变量(可以取 $+\infty$) T 是随机过程 $X = \{X_n\}_{n \geq 0}$ 的停时(Stopping time), 若对任意非负整数 n , 随机事件 $\{T = n\}$ 可以通过 X_0, \dots, X_n 表示, 也即随机变量 $\mathbf{1}_{\{T=n\}}$ 可表示成 X_0, \dots, X_n 的函数. 当无需强调“信息”过程 X 时, 我们也简称 T 为停时. 直观地看, 停时定义的本质要求就是随机事件 $\{T = n\}$ 是否发生由 X_0, \dots, X_n 的信息就可判断, 不受 n 之后 X 值的影响.

例23.6 若 T 为常数, 那么 T 一定是停时, 此时事件 $\{T = n\}$ 或者为不可能事件 \emptyset 或者为必然事件 Ω .

例23.7 设 $X = \{X_n; n \geq 0\}$ 是状态空间为 S 的时齐马氏链, 对任意 $i \in S$, $\tau_i = \inf\{n \geq 1; X_n = i\}$ 为停时. 事实上, 若 $n = 0$, $\{\tau_i = 0\} = \emptyset$; 若 $n > 0$,

$$\{\tau_i = n\} = \{X_k \neq i, k = 1, \dots, n-1, X_n = i\}.$$

例23.8 设 $N(t)$ 是以 $W_i, i \geq 1$ 为等待时间序列的更新过程, T_n 为第 n 次更新发生的时间, 那么对任意 $t \geq 0$, $N(t)$ 关于 $T = \{T_n; n \geq 0\}$ 不是停时, 但 $N(t) + 1$ 关于 T 是停时. 事实上, 对任意 $n \geq 0$, 由

$$\{N(t) = n\} = \{T_n \leq t, T_{n+1} > t\}, \quad \{N(t) + 1 = n\} = \{T_n > t, T_{n-1} \leq t\}$$

可知, 判断 $\{N(t) = n\}$ 是否发生不仅需要知道 T 在 n 及之前的信息还要知道 T 在 n 之后的信息, 而判断事件 $\{N(t) + 1 = n\}$ 是否发生, 则只需要知道 T 在 n 及之前的信息.

性质23.6 若 S, T 是关于 $X = \{X_n; n \geq 0\}$ 的停时, 那么 $S + T, S \wedge T, S \vee T$ 都是停时.

证明 由于 S, T 均为停时, 对任意 $k \geq 0$, 存在 ϕ_k, ψ_k 使得

$$\mathbf{1}_{\{S=k\}} = \phi_k(X_0, \dots, X_k), \quad \mathbf{1}_{\{T=k\}} = \psi_k(X_0, \dots, X_k).$$

对任意 $n \geq 0$, 由 $\{S + T = n\} = \cup_{k=0}^n \{S = k, T = n - k\}$ 可知

$$\mathbf{1}_{\{S+T=n\}} = \sum_{k=0}^n \mathbf{1}_{\{S=k\}} \mathbf{1}_{\{T=n-k\}} = \sum_{k=0}^n \phi_k(X_0, \dots, X_k) \psi_{n-k}(X_0, \dots, X_{n-k}).$$

因此 $S + T$ 为停时. 类似, 由

$$\{S \wedge T = n\} = (\{S = n\} \cup \{T = n\}) \setminus (\{S = n, T < n\} \cup \{S < n, T = n\}),$$

可知

$$\begin{aligned} \mathbf{1}_{\{S \wedge T=n\}} &= \phi_n(X_0, \dots, X_n) + \psi_n(X_0, \dots, X_n) \\ &\quad - \sum_{k=0}^{n-1} \phi_n(X_0, \dots, X_n) \psi_k(X_0, \dots, X_k) \\ &\quad - \sum_{k=0}^n \phi_k(X_0, \dots, X_k) \psi_n(X_0, \dots, X_n) \end{aligned}$$

仍是 X_0, \dots, X_n 的函数, 因此 $S \wedge T$ 是停时. 同理可得 $S \vee T$ 也是停时, 细节请读者自己补充. \square

定理23.7(Wald等式) 设 $X = \{X_n; n \geq 1\}$ 为独立同分布随机变量序列, $\mathbb{E}(|X_1|) < \infty$, 设 T 关于 X 为停时且 $\mathbb{E}(T) < \infty$. 那么

$$\mathbb{E}\left(\sum_{i=1}^T X_i\right) = \mathbb{E}(X_1)\mathbb{E}(T). \quad (7.1.1)$$

证明 对任意 $k \geq 1$, 由于 T 为停时, 可记 $\mathbf{1}_{\{T=k\}} = \phi_k(X_1, \dots, X_k)$.

$$\begin{aligned} \mathbb{E}\left(\sum_{k=1}^T X_k\right) &= \sum_{k=1}^{\infty} \mathbb{E}\left(\sum_{i=1}^k X_i \mathbf{1}_{\{T=k\}}\right) = \sum_{i=1}^{\infty} \sum_{k=i}^{\infty} \mathbb{E}\left(X_i \mathbf{1}_{\{T=k\}}\right) \\ &= \sum_{i=1}^{\infty} \mathbb{E}\left(X_i - X_i \sum_{k=1}^{i-1} \phi_k(X_1, \dots, X_k)\right). \end{aligned}$$

利用条件数学期望性质并注意到 $\{X_n, n \geq 1\}$ 是独立同分布的,

$$\mathbb{E}\left(\sum_{k=1}^T X_k\right) = \sum_{i=1}^{\infty} \mathbb{E}\left(\mathbb{E}\left(X_i - X_i \sum_{k=1}^{i-1} \phi_k(X_1, \dots, X_k) | X_1, \dots, X_{i-1}\right)\right)$$

$$\begin{aligned}
&= \sum_{i=1}^{\infty} \mathbb{E}(X_i | X_1, \dots, X_{i-1}) \left(1 - \mathbb{E}\left(\sum_{k=1}^{i-1} \phi_k(X_1, \dots, X_k)\right) \right) \\
&= \mathbb{E}(X_1) \sum_{i=1}^{\infty} \left(1 - \mathbb{E}\left(\sum_{k=1}^{i-1} \mathbf{1}_{\{T=k\}}\right) \right) = \mathbb{E}(X_1) \sum_{i=1}^{\infty} \mathbb{P}(T \geq i).
\end{aligned}$$

注意到 $\sum_{i=1}^{\infty} \mathbb{P}(T \geq i) = \mathbb{E}(T)$, (7.1.1) 成立. \square

练习题

23.1 设 $Y = \{Y_n, n \geq 0\}$ 是状态空间 S 上时齐马氏链, 令 $X_n = g(Y_n) = f_{Y_n, j_0}$, 其中 f_{i, j_0} 表示 Y 从 i 出发有限时间内到达(回到)某个给定状态 j_0 的概率. 验证 X 关于 Y 是上鞅.

23.2 设 X_1, X_2, \dots 为独立同分布随机变量满足

$$\mathbb{P}(X_1 = 1) = p, \mathbb{P}(X = -1) = q = 1 - p.$$

对任意 $n \geq 0$ 令 $Y_0 = 1$ 以及

$$Y_n = \left(\frac{q}{p}\right)^{S_n}, \text{ 其中 } S_n = \sum_{k=1}^n X_k, \quad n \geq 1.$$

证明 $\{Y_n, n \geq 0\}$ 关于 X 为鞅.

23.3 设 X_1, X_2, \dots 为独立同分布随机变量, $\mathbb{E}(X_n) = 0, \mathbb{E}(X_n^2) = a^2$. 对任意 $n \geq 0$, 令 $Y_0 = 0$,

$$Y_n = \left(\sum_{k=1}^n X_k\right)^2 - na^2 \quad n \geq 1.$$

证明 $\{Y_n, n \geq 0\}$ 关于 X 为鞅.

23.4 设 $X = \{X_n, n \geq 0\}$ 为任一随机过程, $\tau = \min\{n \geq 0; X_n = a \text{ 或 } b\}$, $\eta = \inf\{n \geq 0; X_n \leq a\}$. 证明 τ, η 都是停时.

23.5 利用 Jessen 不等式证明 Lyapunov 不等式: 对任意随机变量 X , 若 $0 < s < t$, 则

$$(\mathbb{E}(|X|^s))^{1/s} \leq (\mathbb{E}(|X|^t))^{1/t}.$$

23.6* 请补充证明若 $\psi(x)$ 是区间 (a, b) 内凸函数, 则函数 ψ 在 (a, b) 内左右导数都存在且对任意 $x, y \in (a, b)$

$$\psi(y) - \psi(x) \geq \psi'_+(x)(y - x),$$

其中 $\psi'_+(y)$ 表示 y 的右导数.

7.2 鞅的停时定理

本节总设 $X = \{X_n; n \geq 0\}$ 关于某个信息过程 $Y = \{Y_n; n \geq 0\}$ 为(上, 下)鞅, 所有停时也以该信息过程为参考.

7.2.1 有界停时定理

引理24.1 设 $\{X_n; n \geq 0\}$ 是鞅(上鞅), T 是一个停时, 那么对任意 $0 \leq k \leq n$

$$\mathbb{E}(X_n \mathbf{1}_{\{T=k\}}) = (\leq) \mathbb{E}(X_k \mathbf{1}_{\{T=k\}}).$$

证明 由条件数学期望性质

$$\begin{aligned} \mathbb{E}(X_n \mathbf{1}_{\{T=k\}}) &= \mathbb{E}(\mathbb{E}(X_n \mathbf{1}_{\{T=k\}} | X_0, Y_0, \dots, Y_k)) \\ &= \mathbb{E}(\mathbf{1}_{\{T=k\}} \mathbb{E}(X_n | X_0, Y_0, \dots, Y_k)) = (\leq) \mathbb{E}(X_k \mathbf{1}_{\{T=k\}}). \end{aligned}$$

引理得证. \square

引理24.2 设 $\{X_n; n \geq 0\}$ 是鞅(上鞅), T 是一个有界停时, $0 \leq n \leq T \leq m$, 那么

$$\mathbb{E}(X_T | X_0, Y_0, \dots, Y_n) = (\leq) X_n.$$

证明 注意到 X_n 是 X_0, Y_1, \dots, Y_n 的函数, 由条件数学期望的平滑性,

$$\begin{aligned} \mathbb{E}(X_T | X_0, Y_0, \dots, Y_n) &= \mathbb{E}(\mathbb{E}(X_T | X_0, Y_0, \dots, Y_{m-1}) | X_0, Y_0, \dots, Y_n) \\ &= \mathbb{E}\left(\sum_{k=n}^m \mathbb{E}(X_k \mathbf{1}_{\{T=k\}} | X_0, Y_0, \dots, Y_{m-1}) | X_0, Y_0, \dots, Y_n\right) \\ &= \mathbb{E}\left(\sum_{k=n}^{m-1} X_k \mathbf{1}_{\{T=k\}} | X_0, Y_0, \dots, Y_n\right) \\ &\quad + \mathbb{E}(\mathbb{E}(X_m \mathbf{1}_{\{T=m\}} | X_0, Y_0, \dots, Y_{m-1}) | X_0, Y_0, \dots, Y_n). \end{aligned}$$

注意到

$$\mathbf{1}_{\{T=m\}} = 1 - \mathbf{1}_{\{T \leq m-1\}}$$

是 Y_0, \dots, Y_{m-1} 的函数. 由条件分布性质以及(上)鞅性质可知

$$\begin{aligned} \mathbb{E}(\mathbb{E}(X_m \mathbf{1}_{\{T=m\}} | X_0, Y_0, \dots, Y_{m-1}) | X_0, Y_0, \dots, Y_n) \\ = \mathbb{E}(\mathbf{1}_{\{T=m\}} \mathbb{E}(X_m | X_0, Y_0, \dots, Y_{m-1}) | X_0, Y_0, \dots, Y_n) \\ = (\leq) \mathbb{E}(X_{m-1} \mathbf{1}_{\{T=m\}} | X_0, Y_0, \dots, Y_n). \end{aligned}$$

因此

$$\begin{aligned} \mathbb{E}(X_T | X_0, Y_0, \dots, Y_n) &= (\leq) \mathbb{E}\left(\sum_{k=n}^{m-1} X_k \mathbf{1}_{\{T=k\}} | X_0, Y_0, \dots, Y_n\right) \\ &\quad + \mathbb{E}(X_{m-1} \mathbf{1}_{\{T=m\}} | X_0, Y_0, \dots, Y_n) \end{aligned}$$

$$= \mathbb{E}(X_{T \wedge (m-1)} | X_0, Y_0, \dots, Y_n).$$

重复上面的分析(将 $T \wedge (m-1)$ 看作新的 T 并以此类推)我们可得

$$\mathbb{E}(X_T | X_0, Y_0, \dots, Y_n) = (\leq) \mathbb{E}(X_{T \wedge n} | X_0, Y_0, \dots, Y_n) = X_n.$$

引理24.2得证. \square

定理24.3(有界停时定理) 设 $\{X_n; n \geq 0\}$ 是(上)鞅, 若 S, T 为两有界停时且 $S \leq T$ a.s. 那么

$$\mathbb{E}(X_T) = (\leq) \mathbb{E}(X_S).$$

证明 不妨设 $S, T \leq m$, 由引理24.2,

$$\begin{aligned} \mathbb{E}(X_T) &= \sum_{n=0}^m \mathbb{E}(X_T \mathbf{1}_{\{S=n\}}) = \sum_{n=0}^m \mathbb{E}(X_{T \vee n} \mathbf{1}_{\{S=n\}}) \\ &= \sum_{n=0}^m \mathbb{E}(\mathbb{E}(X_{T \vee n} \mathbf{1}_{\{S=n\}} | Y_0, \dots, Y_n)) \\ &= \sum_{n=0}^m \mathbb{E}(\mathbf{1}_{\{S=n\}} \mathbb{E}(X_{T \vee n} | Y_0, \dots, Y_n)) \\ &= (\leq) \sum_{n=0}^m \mathbb{E}(\mathbf{1}_{\{S=n\}} X_n) = \mathbb{E}(X_S). \end{aligned}$$

定理得证. \square

7.2.2 一般停时定理

引理24.4 设随机变量 W 满足 $\mathbb{E}(|W|) < \infty$, 若 T 为有限停时, 即 $\mathbb{P}(T < \infty) = 1$. 那么

$$\lim_{n \rightarrow \infty} \mathbb{E}(W \mathbf{1}_{\{T>n\}}) = 0 \text{ 且 } \lim_{n \rightarrow \infty} \mathbb{E}(W \mathbf{1}_{\{T \leq n\}}) = \mathbb{E}(W).$$

证明 由正项级数的收敛性, 当 $n \rightarrow \infty$ 时

$$\mathbb{E}(|W|) \geq \mathbb{E}(|W| \mathbf{1}_{\{T \leq n\}}) = \sum_{k=0}^n \mathbb{E}(|W| \mathbf{1}_{\{T=k\}}) \rightarrow \sum_{k=0}^{\infty} \mathbb{E}(|W| \mathbf{1}_{\{T=k\}}).$$

由于 $\mathbb{P}(T < \infty) = 1$, 由引理3.13可知

$$\mathbb{E}(|W| \mathbf{1}_{\{T \geq n+1\}}) = \sum_{k=n+1}^{\infty} \mathbb{E}(|W| \mathbf{1}_{\{T=k\}}) \rightarrow 0.$$

从而

$$0 \leq |\mathbb{E}(W) - \mathbb{E}(W \mathbf{1}_{\{T \leq n\}})| \leq |\mathbb{E}(W \mathbf{1}_{\{T \geq n+1\}})| \leq \mathbb{E}(|W| \mathbf{1}_{\{T \geq n+1\}}) \rightarrow 0.$$

由此可得引理结论. \square

定理24.5 设 $\{X_n; n \geq 0\}$ 为鞅, T 是一个有限停时, 若

$$\mathbb{E}(\sup_{n \geq 0} |X_{T \wedge n}|) < \infty,$$

那么 $\mathbb{E}(X_T) = \mathbb{E}(X_0)$.

证明 令 $W = \sup_{n \geq 0} |X_{T \wedge n}|$. 由于 $\mathbb{P}(T < \infty) = 1$,

$$X_T = \sum_{k=0}^{\infty} X_k \mathbf{1}_{\{T=k\}} = \sum_{k=0}^{\infty} X_{T \wedge k} \mathbf{1}_{\{T=k\}}.$$

从而 $|X_T| \leq W$. 因此 $\mathbb{E}(|X_T|) \leq \mathbb{E}(W) < \infty$. 此时由引理18.4

$$|\mathbb{E}(X_{T \wedge n}) - \mathbb{E}(X_T)| \leq \mathbb{E}(|X_{T \wedge n} - X_T| \mathbf{1}_{\{T \geq n\}}) \leq 2\mathbb{E}(W \mathbf{1}_{\{T \geq n\}}) \rightarrow 0.$$

所以 $\mathbb{E}(X_T) = \lim_{n \rightarrow \infty} \mathbb{E}(X_{T \wedge n}) = \mathbb{E}(X_0)$, 其中最后一个等号由有界停时定理可得. \square

推论24.6 设 $\{X_n; n \geq 0\}$ 为鞅, T 是一个有限停时, 若 $\mathbb{E}(T) < \infty$ 且存在 $K < \infty$ 使得

$$\mathbb{E}(|X_{n+1} - X_n| | X_0, Y_0, \dots, Y_n) \leq K,$$

那么 $\mathbb{E}(X_T) = \mathbb{E}(X_0)$.

证明 令 $Z_0 = |X_0|$, $Z_n = |X_n - X_{n-1}|$, $W = Z_0 + \dots + Z_T$. 则 $W \geq |X_T|$ 且

$$\mathbb{E}(W) = \sum_{n=0}^{\infty} \sum_{k=0}^n \mathbb{E}(Z_k \mathbf{1}_{\{T=n\}}) = \sum_{k=0}^{\infty} \mathbb{E}(Z_k \mathbf{1}_{\{T \geq k\}}).$$

注意到 $\mathbf{1}_{\{T \geq k\}} = 1 - \mathbf{1}_{\{T \leq k-1\}}$ 为 Y_0, \dots, Y_{k-1} 的函数, 由条件假设

$$\begin{aligned} \mathbb{E}(Z_k \mathbf{1}_{\{T \geq k\}}) &= \mathbb{E}(\mathbf{1}_{\{T \geq k\}} \mathbb{E}(Z_k | X_0, Y_0, \dots, Y_{k-1})) \\ &= \mathbb{E}(\mathbf{1}_{\{T \geq k\}} \mathbb{E}(|X_k - X_{k-1}| | X_0, Y_0, \dots, Y_{k-1})) \leq K \mathbb{P}(T \geq k) \end{aligned}$$

从而

$$\mathbb{E}(W) \leq \sum_{k=0}^{\infty} K \mathbb{P}(T \geq k) \leq K(1 + \mathbb{E}(T)) < \infty.$$

因为 $|X_{T \wedge n}| \leq W$ 对一切 n 成立, 由定理23.5 可知结论成立. \square

定理24.7 设 $\{X_n; n \geq 0\}$ 为鞅, T 是一个有限停时, 若 $\mathbb{E}(|X_T|) < \infty$ 且

$$\lim_{n \rightarrow \infty} \mathbb{E}(X_n \mathbf{1}_{\{T \geq n\}}) = 0,$$

那么 $\mathbb{E}(X_T) = \mathbb{E}(X_0)$.

证明 注意到

$$\begin{aligned} \mathbb{E}(X_T) &= \mathbb{E}(X_T \mathbf{1}_{\{T < n\}}) + \mathbb{E}(X_T \mathbf{1}_{\{T \geq n\}}) = \mathbb{E}(X_{T \wedge n} \mathbf{1}_{\{T < n\}}) + \mathbb{E}(X_T \mathbf{1}_{\{T \geq n\}}) \\ &= \mathbb{E}(X_{T \wedge n}) - \mathbb{E}(X_{T \wedge n} \mathbf{1}_{\{T \geq n\}}) + \mathbb{E}(X_T \mathbf{1}_{\{T \geq n\}}) \end{aligned}$$

由条件 $\lim_{n \rightarrow \infty} \mathbb{E}(X_{T \wedge n} \mathbf{1}_{\{T \geq n\}}) = 0$ 及引理18.4 可知 $\lim_{n \rightarrow \infty} \mathbb{E}(X_T \mathbf{1}_{\{T \geq n\}}) = 0$. 因此

$$\mathbb{E}(X_T) = \lim_{n \rightarrow \infty} \mathbb{E}(X_{T \wedge n}) = \mathbb{E}(X_0),$$

其中最后等号由有界停时定理可得. \square

定理24.8 设 $\{X_n; n \geq 0\}$ 为上鞅, T 为有限停时, 若存在随机变量 W 使得 $\mathbb{E}(|W|) < \infty$ 且对任意 $n \geq 0$, $X_{T \wedge n} \geq -W$ 成立, 那么 $\mathbb{E}(X_0) \geq \mathbb{E}(X_T)$.

证明 任意取定一个正整数 N , 令 $X_n^N = X_n \wedge N$, 那么 $\{X_n^N, n \geq 0\}$ 仍是上鞅, 从而由有界停时

定理

$$\mathbb{E}(X_0^N) \geq \mathbb{E}(X_{T \wedge n}^N).$$

由条件假设可知 $|X_{T \wedge n}^N| \leq N \vee |W| < |W| + N$. 因为 T 为有限停时,

$$X_T^N = \lim_{n \rightarrow \infty} X_{T \wedge n}^N, \quad a.s.$$

从而 $|X_T^N| \leq N + |W|$. 当 $n \rightarrow \infty$ 时, 由引理 18.4,

$$\mathbb{E}|X_{T \wedge n}^N - X_T^N| \leq \mathbb{E}(|X_{T \wedge n}^N - X_T^N| \mathbf{1}_{\{T > n\}}) \leq 2\mathbb{E}((N + W)\mathbf{1}_{\{T > n\}}) \rightarrow 0.$$

因此 $\lim_{n \rightarrow \infty} \mathbb{E}(X_{T \wedge n}^N) = \mathbb{E}(X_T^N)$. 由此可得

$$\mathbb{E}(X_0) \geq \mathbb{E}(X_0^N) \geq \mathbb{E}(X_T^N).$$

因为 $\mathbb{E}(X_T^N)$ 随着 N 的增加而单调增加,

$$\mathbb{E}(X_0) \geq \lim_{N \rightarrow \infty} \mathbb{E}(X_T^N).$$

另一方面, 由 $X_T = \lim_{n \rightarrow \infty} X_{T \wedge n}$ 及条件假设可知 $X_T \geq -W$. 所以

$$\mathbb{E}(X_T \mathbf{1}_{\{X_T \leq 0\}}) \geq \mathbb{E}(-W) > -\infty.$$

从而

$$\begin{aligned} \mathbb{E}(X_T) &= \mathbb{E}(X_T \mathbf{1}_{\{X_T \leq 0\}}) + \mathbb{E}(X_T \mathbf{1}_{\{X_T > 0\}}) \\ &= \mathbb{E}(X_T \mathbf{1}_{\{X_T \leq 0\}}) + \sum_{k=1}^{\infty} \mathbb{E}(X_T \mathbf{1}_{\{k-1 < X_T \leq k\}}) \\ &\leq \mathbb{E}(X_T \mathbf{1}_{\{X_T \leq 0\}}) + \lim_{N \rightarrow \infty} \left(\sum_{k=1}^N \mathbb{E}(X_T \mathbf{1}_{\{k-1 < X_T \leq k\}}) + N\mathbb{E}(\mathbf{1}_{\{X_T > N\}}) \right) \\ &= \lim_{N \rightarrow \infty} \mathbb{E}(X_T^N). \end{aligned}$$

综上所述可得 $\mathbb{E}(X_0) \geq \mathbb{E}(X_T)$. □

推论 24.9 若 $\{X_n\}$ 为非负上鞅, T 为有限停时, 那么 $\mathbb{E}(X_0) \geq \mathbb{E}(X_T)$.

7.2.3 停时定理应用举例

下面我们看几个应用停时定理的例子.

例 24.1 设 $a < b$ 为正整数, S_n 是从位置 a 出发的简单 (p, q) 随机游动, 定义

$$\tau_0 = \inf\{n > 0, S_n = 0\}, \quad \tau_b = \inf\{n > 0, S_n = b\} \text{ 以及 } T = \tau_0 \wedge \tau_b.$$

求 $\mathbb{E}(T)$, $\mathbb{E}(S_T)$ 以及 $\mathbb{P}(\tau_b < \tau_0)$,

解 以 $X = \{X_i, i \geq 0\}$ 表示随机游动中每步的步长, 那么 X_i 独立同分布且

$$\mathbb{P}(X_i = 1) = p, \quad \mathbb{P}(X_i = -1) = q.$$

由定义可知 T 关于 $\{S_n\}$ 为停时. 对任意 $k > b$, 设 $k = mb + r$ 其中 $m \geq 1$, $r = 0, 1, \dots, b-1$,

当事件 $\{T = k\}$ 发生时, 在 k 之前任意相邻的 b 步中游动方向 X_i 不能完全相同(否则就提前到访了0或 b). 将 k 步按每 b 步组合成

$$\{1, 2, \dots, b\}, \{b+1, \dots, 2b\}, \dots, \{(m-1)b+1, \dots, mb\}, \{mb+1, \dots, mb+r\}.$$

由 X_i 的独立同分布性可知 $\mathbb{P}(T = k) \leq (1 - p^b - q^b)^m$, 从而

$$\begin{aligned}\mathbb{E}(T) &= \sum_{m=0}^{\infty} \sum_{r=0}^{b-1} (mb+r) \mathbb{P}(T = mb+r) \\ &\leq \sum_{m=0}^{\infty} (1 - p^b)^m (m+1) b^2 = \frac{b^2}{p^{2b}} < \infty.\end{aligned}$$

令 $Y_n = S_n - n(p - q)$, 显然 $\{Y_n; n \geq 0\}$ 关于 $\{S_n\}$ 为鞅. 由

$$\mathbb{E}(|Y_{n+1} - Y_n| | S_0, \dots, S_n) = \mathbb{E}(|X_{n+1} - (p - q)| | S_0, \dots, S_n) \leq 1 + (p - q)$$

以及推论24.6可得

$$\mathbb{E}(Y_T) = \mathbb{E}(Y_0),$$

即

$$\mathbb{E}(S_T) = a + (p - q)\mathbb{E}(T). \quad (7.2.1)$$

此外, 当 $p \neq q$ 时, 令

$$M_n = \left(\frac{q}{p}\right)^{S_n}.$$

则 $\{M_n, n \geq 0\}$ 也是鞅, 而且对任意 $n \geq 0$, $M_{T \wedge n} \leq (1 \vee \frac{q}{p})^b$, 由定理24.5,

$$\mathbb{E}(M_T) = \mathbb{E}(M_0) = \left(\frac{q}{p}\right)^a.$$

即

$$\mathbb{P}(S_T = 0) + \left(\frac{q}{p}\right)^b \mathbb{P}(S_T = b) = \left(\frac{q}{p}\right)^a. \quad (7.2.2)$$

将 $\mathbb{P}(S_T = 0) = 1 - \mathbb{P}(S_T = b)$ 代入(7.2.2)解得

$$\mathbb{P}(S_T = b) = \frac{1 - \left(\frac{q}{p}\right)^a}{1 - \left(\frac{q}{p}\right)^b} = \mathbb{P}(\tau_b < \tau_0).$$

从而

$$\mathbb{E}(S_T) = b\mathbb{P}(S_T = b) = b \frac{1 - \left(\frac{q}{p}\right)^a}{1 - \left(\frac{q}{p}\right)^b}.$$

将其代入(7.2.1)得

$$\mathbb{E}(T) = \frac{b}{p-q} \frac{1 - \left(\frac{q}{p}\right)^a}{1 - \left(\frac{q}{p}\right)^b} - \frac{a}{p-q}.$$

当 $p = q = 1/2$ 时, 由(7.2.1)可知 $\mathbb{E}(S_T) = a$. 令

$$M_n = S_n^2 - n.$$

则 $\{M_n, n \geq 0\}$ 也是鞅. 对任意 $n \geq 0$, $\mathbb{E}(|M_T|) < b^2 + \mathbb{E}(T) < \infty$ 且

$$\lim_{n \rightarrow \infty} \mathbb{E}(|M_n| \mathbf{1}_{\{T \geq n\}}) \leq \lim_{n \rightarrow \infty} \mathbb{E}((b^2 + T) \mathbf{1}_{\{T \geq n\}}) = 0.$$

由定理24.7,

$$\mathbb{E}(M_T) = \mathbb{E}(M_0) = a^2. \quad (7.2.3)$$

由(7.2.1), (7.2.3)两式可得

$$\mathbb{P}(S_T = b)b = a \quad \text{以及} \quad \mathbb{P}(S_T = b)b^2 - \mathbb{E}(T) = a^2.$$

由此解得

$$\mathbb{P}(S_T = b) = \frac{a}{b} = \mathbb{P}(\tau_b < \tau_0), \quad \text{以及} \quad \mathbb{E}(T) = a(b - a). \quad \square$$

例24.2 设 $X_i, i \geq 1$ 是独立同分布的随机变量服从正态分布 $N(\mu, \sigma^2)$, $S_0 = x > 0$, $S_n = x + \sum_{k=1}^n X_k$, 令 $A = \{\text{存在 } n > 0 \text{ 使得 } S_n \leq 0\}$, 估计 $\mathbb{P}(A)$ 的上界.

解 令 $\tau = \inf\{n > 0; S_n \leq 0\}$, 那么 τ 为停时且 $A = \{\tau < \infty\}$. 由 $X_i \sim N(\mu, \sigma^2)$ 可知

$$\mathbb{E}(e^{-\lambda X_i}) = e^{-\lambda\mu + \lambda^2\sigma^2/2}.$$

取 $\lambda = 2\mu/\sigma^2 \triangleq \theta$, 由例23.3(2)可知 $W_n = \exp\{-\theta S_n\}$ 为鞅. 由有界停时定理, 对任意 $n \geq 1$

$$e^{-\theta x} = \mathbb{E}(W_0) = \mathbb{E}(W_{\tau \wedge n}) = \mathbb{E}(W_\tau \mathbf{1}_{\{\tau \leq n\}}) + \mathbb{E}(W_\tau \mathbf{1}_{\{\tau > n\}}) \geq \mathbb{P}(\tau \leq n).$$

令 $n \rightarrow \infty$ 得 $\mathbb{P}(A) \leq e^{-\theta x} = e^{-2\mu x/\sigma^2}$. \square

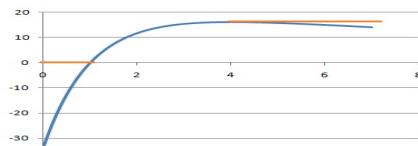
例24.3 以 Z_n 表示第 n 年开始时水库蓄水量, Y_{n+1} 表示第 n 年的净入库流量 (Y_{n+1} 为负表示净出库流量), b 表示水库的最大库容, 显然 $Z_{n+1} = (Z_n + Y_{n+1})^+ \wedge b$. 以 a 表示水库最低警戒库容, 令 $T = \min\{n, Z_n \leq a\}$, 试求 $\mathbb{E}(T)$ 的下界估计, 其中我们假定 $Z_0 = z \in (a, b)$ 以及

$$\mathbb{E}(Y_{n+1}|Z_0, Y_1, \dots, Y_n) \leq m, \quad \mathbb{E}(\exp\{-\lambda Y_{n+1}\}|Z_0, Y_1, \dots, Y_n) \leq 1.$$

解 对任意 $z \geq 0$, 令

$$g(z) = \frac{1}{m} \left(e^{\lambda(b-a)} \frac{1 - e^{-\lambda(z-a)}}{\lambda} - (z - a) \right)$$

以及 $f(z) = \begin{cases} g(z) \vee 0, & 0 \leq z \leq b, \\ g(b); & z > b. \end{cases}$ 易知当 $0 \leq z < \infty$ 时 $f(z) \geq g(z)$. (参见下图.)



而且对任意 $n \geq 0$, $f(Z_{n+1}) = f(Z_n + Y_{n+1})$. 进一步由假设条件, 对任意 $n \geq 0$, 当 $a \leq Z_n \leq b$ 时,

$$\begin{aligned} \mathbb{E}(f(Z_{n+1})|Z_0, Y_1, \dots, Y_n) &= \mathbb{E}(f(Z_n + Y_{n+1})|Z_0, Y_1, \dots, Y_n) \\ &\geq \mathbb{E}(g(Z_n + Y_{n+1})|Z_0, Y_1, \dots, Y_n) \\ &= \frac{1}{m} \mathbb{E}\left(\mathrm{e}^{\lambda(b-a)} \frac{1 - \mathrm{e}^{-\lambda(Z_n + Y_{n+1}-a)}}{\lambda} - (Z_n - a + Y_{n+1}) \Big| Z_0, Y_1, \dots, Y_n\right) \\ &\geq \frac{1}{m} \left(\mathrm{e}^{\lambda(b-a)} \frac{1 - \mathrm{e}^{-\lambda(Z_n-a)}}{\lambda} - (Z_n - a) \right) - 1 \\ &\geq f(Z_n) - 1; \end{aligned}$$

而且当 $Z_n < a$ 时, 由 $f(Z_n) = 0$, $f(Z_{n+1}) \geq 0$ 可知上式仍然成立. 因此

$$X_n = f(Z_n) + n$$

为下鞅. 由下鞅有界停时定理,

$$\mathbb{E}(f(Z_0)) = \mathbb{E}(X_0) \leq \mathbb{E}(X_{T \wedge n}) = \mathbb{E}(f(Z_{T \wedge n})) + T \wedge n.$$

即 $f(z) \leq \mathbb{E}(f(Z_{T \wedge n})) + T \wedge n$. 由于 f 为有界连续函数, 存在常数 $M > 0$ 使得

$$|\mathbb{E}(f(Z_{T \wedge n})) - \mathbb{E}(f(Z_T))| \leq \mathbb{E}(|f(Z_{T \wedge n}) - f(Z_T)|) \leq M \mathbb{P}(T > n) \rightarrow 0.$$

因此

$$\lim_{n \rightarrow \infty} \mathbb{E}(f(Z_{T \wedge n})) = \mathbb{E}(f(Z_T)) = 0.$$

又由

$$\mathbb{E}(T \wedge n) = \lim_{n \rightarrow \infty} \sum_{k=1}^{\infty} \mathbb{P}(T \wedge n \geq k) = \lim_{n \rightarrow \infty} \sum_{k=1}^n \mathbb{P}(T \geq k) = \mathbb{E}(T).$$

可得 $\mathbb{E}(T) \geq f(z)$, 即

$$\mathbb{E}(T) \geq \frac{1}{m} \left(\mathrm{e}^{\lambda(b-a)} \frac{1 - \mathrm{e}^{-\lambda(z-a)}}{\lambda} - (z - a) \right), \quad z \in (a, b).$$

练习题

24.1 试构造一个鞅 $\{X_n, n \geq 0\}$ 和停时 T 使得 $\mathbb{E}(X_T) \neq \mathbb{E}(X_0)$.

24.2 证明对任意鞅或非负下鞅 $\{X_n, n \geq 0\}$ 及停时 τ , $\mathbb{E}(|X_\tau|) \leq \lim_{n \rightarrow \infty} \mathbb{E}(|X_n|)$.

24.3 甲乙两种新药对某种疾病可能的治愈率分别假定为 p_1, p_2 . 为判定两种药物的优劣, 我们关心 p_1, p_2 间的大小关系. 为此给出如下的试验与判别准则: 每次试验治疗两病人, 一人接受甲药治疗, 一人接受乙药治疗. 观察每次治疗效果, 当一种药物的累积治愈人数超过另一种药物的累积治愈人数并达到预先给定的一个标准时, 试验就停止并判定该药比另一种药物疗效好. 问这种试验判别的失误率?

7.3 鞅不等式与极限

最后我们简单介绍几个鞅的不等式以及一个关于鞅收敛的基本定理.

7.3.1 极大不等式与Doob不等式

定理25.1 设 $\{X_n; n \geq 0\}$ 为上鞅, 则对任意 $\lambda > 0$ 有

$$\lambda \mathbb{P}(\max_{0 \leq k \leq n} X_k \geq \lambda) \leq \mathbb{E}(X_0) - \mathbb{E}(X_n \mathbf{1}_{\{\max_{0 \leq k \leq n} X_k < \lambda\}}); \quad (7.3.1)$$

$$\lambda \mathbb{P}(\min_{0 \leq k \leq n} X_k \leq -\lambda) \leq -\mathbb{E}(X_n \mathbf{1}_{\{\min_{0 \leq k \leq n} X_k < -\lambda\}}); \quad (7.3.2)$$

$$\lambda \mathbb{P}(\max_{0 \leq k \leq n} |X_k| \geq \lambda) \leq \mathbb{E}(X_0) + 2\mathbb{E}(X_n^-), \quad \text{其中 } X_n^- = (-X_n) \vee 0. \quad (7.3.3)$$

证明 (1) 令 $T = \min\{k; X_k \geq \lambda\} \wedge n$, 则 T 为有界停时. 由有界停时定理

$$\begin{aligned} \mathbb{E}(X_0) &\geq \mathbb{E}(X_T) = \mathbb{E}(X_T \mathbf{1}_{\{\max_{0 \leq k \leq n} X_k < \lambda\}}) + \mathbb{E}(X_T \mathbf{1}_{\{\max_{0 \leq k \leq n} X_k \geq \lambda\}}) \\ &\geq \lambda \mathbb{P}(\max_{0 \leq k \leq n} X_k \geq \lambda) + \mathbb{E}(X_n \mathbf{1}_{\{\max_{0 \leq k \leq n} X_k < \lambda\}}), \end{aligned}$$

移项得(7.3.1).

(2) 令 $S = \min\{k; X_k \leq -\lambda\} \wedge n$, 则 S 为有界停时, 且 $S \leq n$. 由有界停时定理

$$\begin{aligned} \mathbb{E}(X_n) &\leq \mathbb{E}(X_S) = \mathbb{E}(X_S \mathbf{1}_{\{\min_{0 \leq k \leq n} X_k \leq -\lambda\}}) + \mathbb{E}(X_S \mathbf{1}_{\{\min_{0 \leq k \leq n} X_k > -\lambda\}}) \\ &\leq -\lambda \mathbb{P}(\min_{0 \leq k \leq n} X_k \leq -\lambda) + \mathbb{E}(X_n \mathbf{1}_{\{\max_{0 \leq k \leq n} X_k > -\lambda\}}), \end{aligned}$$

移项得(7.3.2).

(3) 由(7.3.1),(7.3.2)两项直接相加可得(7.3.3). \square

注25.1 由 $\{X_n; n \geq 0\}$ 为下鞅可推出 $\{|X_n|; n \geq 0\}$ 仍是下鞅. 由(2)可得, 此时

$$\mathbb{P}(\max_{0 \leq k \leq n} |X_k| \geq \lambda) \leq \frac{1}{\lambda} \mathbb{E}(|X_n| \mathbf{1}_{\{\max_{0 \leq k \leq n} |X_k| \geq \lambda\}}).$$

引理25.2 若随机变量 ζ, η 满足 $\mathbb{E}(|\zeta|^p) < \infty, \mathbb{E}(|\eta|^q) < \infty$, 其中 $1/p + 1/q = 1$. 那么 $E|\zeta\eta| < \infty$ 且

$$\mathbb{E}(|\zeta\eta|) \leq [\mathbb{E}(|\zeta|^p)]^{1/p} [\mathbb{E}(|\eta|^q)]^{1/q}. \quad (7.3.4)$$

证明 由 $\ln x$ 为凹函数可知, 对任意 $x, y \in (0, \infty)$, $\lambda \in [0, 1]$,

$$\ln(\lambda x + (1 - \lambda)y) \geq \lambda \ln x + (1 - \lambda) \ln y.$$

从而对任意 $x, y \in (0, \infty)$,

$$x^{1/p} y^{1/q} \leq \frac{x}{p} + \frac{y}{q}.$$

显然上式对 $x, y \in [0, \infty)$ 也成立. 令 $x = |\zeta|^p / \mathbb{E}(|\zeta|^p)$, $y = |\eta|^q / \mathbb{E}(|\eta|^q)$, 那么

$$\frac{|\zeta\eta|}{\mathbb{E}(|\zeta|^p)^{1/p} (\mathbb{E}(|\eta|^q))^{1/q}} \leq \frac{1}{p} \frac{|\zeta|^p}{\mathbb{E}(|\zeta|^p)} + \frac{1}{q} \frac{|\eta|^q}{\mathbb{E}(|\eta|^q)}.$$

两边求期望得

$$\mathbb{E}\left(\frac{|\zeta\eta|}{(\mathbb{E}(|\zeta|^p))^{1/p}(\mathbb{E}(|\eta|^q))^{1/q}}\right) \leq \frac{1}{p}\mathbb{E}\left(\frac{|\zeta|^p}{\mathbb{E}(|\zeta|^p)}\right) + \frac{1}{q}\mathbb{E}\left(\frac{|\eta|^q}{\mathbb{E}(|\eta|^q)}\right) = 1.$$

移项得所需结论. \square

一般地, 我们称不等式(7.3.4)为Hölder不等式.

定理25.3 (鞅极大不等式) 设 $\{X_n; n \geq 0\}$ 为鞅或非负下鞅, $X_n^* = \max_{0 \leq k \leq n} |X_k|$. 那么

- (1) 对任意 $\lambda > 0$ 及 $r \geq 1$, $\mathbb{P}(X_n^* \geq \lambda) \leq \lambda^{-r} \mathbb{E}(|X_n|^r)$. (极大不等式)
- (2) 对任意 $r > 1$, $\mathbb{E}(|X_n^*|^r) \leq (\frac{r}{r-1})^r \mathbb{E}(|X_n|^r)$. (Doob 不等式)

证明 若 $\mathbb{E}(|X_n|^r) = +\infty$, 则结论显然成立. 下设 $\mathbb{E}(|X_n|^r) < \infty$.

由 $\{|X_n|^r, n \geq 0\}$ 为非负下鞅可得, 对任意 $k \leq n$,

$$\mathbb{E}(|X_n|^r) \geq \mathbb{E}(|X_k|^r).$$

从而令

$$Y_k = \begin{cases} |X_k|^r, & k \leq n; \\ |X_n|^r, & k > n. \end{cases}$$

那么 $\{Y_k; k \geq 0\}$ 仍为非负下鞅. 令

$$T = \min\{k, |Y_k| \geq \lambda\} \wedge n.$$

显然 T 为有界停时且 $T \leq n$,

$$\mathbb{E}(|X_n|^r) = \mathbb{E}(|Y_n|^r) \geq \mathbb{E}(|Y_T|^r) = \mathbb{E}(|X_T|^r) \geq \lambda^r \mathbb{P}(X_T \geq \lambda) = \lambda^r \mathbb{P}(X_n^* \geq \lambda).$$

由此立即可得

$$\mathbb{P}(X_n^* \geq \lambda) \leq \lambda^{-r} \mathbb{E}(|X_n|^r).$$

注意到

$$\begin{aligned} \mathbb{E}(|X_n^*|^r) &= \int_0^\infty r\lambda^{r-1} \mathbb{P}(|X_n^*| \geq \lambda) d\lambda \leq \int_0^\infty r\lambda^{r-2} \mathbb{E}(|X_n| \mathbf{1}_{\{|X_n^*| \geq \lambda\}}) d\lambda \\ &= \mathbb{E}(|X_n| \int_0^{X_n^*} r\lambda^{r-2} d\lambda) = \frac{\lambda}{\lambda-1} \mathbb{E}(|X_n| |X_n^*|^{r-1}). \end{aligned}$$

由Hölder不等式得

$$\mathbb{E}(|X_n^*|^r) \leq \left(\frac{r}{r-1}\right)^r (\mathbb{E}(|X_n|^r))^{1/r} (\mathbb{E}(|X_n^*|^r))^{1-1/r}.$$

由此可得Doob不等式成立. \square

例25.1 设 $X_n, n \geq 1$ 为独立同分布的随机变量且

$$\mathbb{E}(X_1) = 0, \quad \text{Var}(X_1) = \sigma^2.$$

则 $S_n = \sum_{k=1}^n X_k$ 为鞅, 由极大不等式可得

$$\mathbb{P}(\max_{0 \leq k \leq n} S_k \geq \lambda) \leq \frac{1}{\lambda^2} \mathbb{E}(S_n^2) = \frac{n\sigma^2}{\lambda^2}. \quad (\text{Kolomogrov 不等式})$$

以及由Doob不等式得

$$\mathbb{E}(|\max_{0 \leq k \leq n} S_k|^2) \leq 4\mathbb{E}(S_n^2) = 4n\sigma^2.$$

7.3.2 下穿不等式

对任意随机序列 $X = \{X_n; n \geq 0\}$ 以及闭区间 $[a, b]$, 令

$$T_0 = \inf\{n \geq 0, X_n \leq a\}, \quad T_1 = \inf\{n > T_0, X_n \geq b\};$$

$$T_{2j} = \inf\{n > T_{2j-1}, X_n \leq a\}, \quad T_{2j+1} = \inf\{n > T_{2j}, X_n \geq b\}, \quad j = 1, 2, \dots.$$

显然 $\{T_k, k \geq 1\}$ 为一列单调不降的关于 X_n 的停时列.

定义25.1 称 $k = \sup\{j, T_{2j-1} \leq n\}$ 为序列 $\{X_0, \dots, X_n\}$ 在时刻 n 之前上穿区间 $[a, b]$ 的次数, 记作 $U_a^b[X, n]$.

直观地理解, 时刻 n 之前的上穿次数就是序列 X 在 n 之前按时间顺序, X 的取值从区间 $[a, b]$ 的下方升到上方这种现象先后发生的次数. 按定义,

$$\{U_a^b[X, n] = j\} = \{T_{2j-1} \leq n < T_{2j+1}\}.$$

定理25.4 设 $\{X_n; n \geq 0\}$ 为上鞅, 则对任意 $n \geq 1$,

$$\mathbb{E}(U_a^b[X, n]) \leq \frac{1}{b-a} \mathbb{E}((X_n - a)^-).$$

证明 由有界停时定理, 对任意 $k \geq 0$,

$$\begin{aligned} 0 &\geq \mathbb{E}(X_{T_{2k+1} \wedge n} - X_{T_{2k} \wedge n}) \\ &= \mathbb{E}\left((X_{T_{2k+1} \wedge n} - X_{T_{2k} \wedge n})(\mathbf{1}_{\{T_{2k} \leq n < T_{2k+1}\}} + \mathbf{1}_{\{n \geq T_{2k+1}\}})\right) \\ &\geq \mathbb{E}((X_n - a)\mathbf{1}_{\{T_{2k} \leq n < T_{2k+1}\}}) + (b-a)\mathbb{P}(T_{2k+1} \leq n) \\ &\geq \mathbb{E}((X_n - a)\mathbf{1}_{\{T_{2k} \leq n < T_{2k+1}\}}) + (b-a)\mathbb{P}(U_a^b(x, n) \geq k+1). \end{aligned}$$

从而

$$\begin{aligned} \mathbb{P}(U_a^b(X, n) \geq k+1) &\leq \frac{1}{b-a} \mathbb{E}(-(X_n - a)\mathbf{1}_{\{T_{2k} \leq n < T_{2k+1}\}}) \\ &\leq \frac{1}{b-a} \mathbb{E}((X_n - a)^-\mathbf{1}_{\{T_{2k} \leq n < T_{2k+1}\}}). \end{aligned}$$

两边关于 k 求和得

$$\mathbb{E}(U_a^b(X, n)) \leq \frac{1}{b-a} \mathbb{E}((X_n - a)^-\mathbf{1}_{\{T_0 \leq n\}}) \leq \frac{1}{b-a} \mathbb{E}((X_n - a)^-).$$

定理证毕. □

7.3.3 Doob收敛定理

定理25.5 (Doob收敛定理) 设 $\{X_n; n \geq 0\}$ 为(上, 下)鞅, 若 $M = \sup_n \mathbb{E}(|X_n|) < \infty$. 则存在随机变量 X_∞ 使得当 $n \rightarrow \infty$ 时 $X_n \rightarrow X_\infty$ a.s. 且 $\mathbb{E}|X_\infty| < \infty$.

证明 由于下鞅的负过程是上鞅, 我们只讨论上鞅的情形. 令 \mathbb{Q} 表示有理数全体, 设 $a, b \in \mathbb{Q}$, $a < b$. 令 $U_a^b(X)$ 为 $\{X_n\}$ 上穿 $[a, b]$ 的次数, 即

$$U_a^b(X) = \lim_{n \rightarrow \infty} U_a^b(X, n).$$

由上穿不等式

$$\mathbb{E}(U_a^b(X)) \leq \frac{1}{b-a} \sup_n \mathbb{E}((X_n - a)^-) \leq \frac{1}{b-a} (a + \sup_n \mathbb{E}|X_n|) < \infty.$$

于是 $U_a^b(X) < \infty$, a.s. 令

$$W_{a,b} = \{\liminf_{n \rightarrow \infty} X_n < a, \limsup_{n \rightarrow \infty} X_n = b\},$$

$$W = \bigcup_{a,b \in \mathbb{Q}, a < b} W_{a,b}.$$

由 $W_{a,b} \subset \{U_a^b(X) = +\infty\}$ 可知 $\mathbb{P}(W_{a,b}) = 0$, 从而 $\mathbb{P}(W) = 0$. 显然对任意 $\omega \notin W$,

$$\liminf_{n \rightarrow \infty} X_n(\omega) = \limsup_{n \rightarrow \infty} X_n(\omega),$$

即 $\lim_{n \rightarrow \infty} X_n(\omega)$ 存在, 记作 $X_\infty(\omega)$. 若 $\omega \in W$ 则补充定义 $X_\infty(\omega) = 0$. 因此

$$X_n \rightarrow X_\infty, \text{a.s.}$$

令 $p = \mathbb{P}(|X_\infty(\omega)| = \infty)$, 那么由

$$\lim_{n \rightarrow \infty} \mathbb{P}(|X_n(\omega)| \geq c) \rightarrow \mathbb{P}(|X_\infty(\omega)| \geq c) \geq p$$

可知, 对 $c = 3M/p$ 时, 存在 N , 当 $n > N$ 时, $\mathbb{P}(|X_n| \geq c) \geq p/2$. 因此若 $p > 0$, 则

$$\mathbb{E}(|X_n|) \geq \frac{3M}{2}.$$

这与条件 $M = \sup_n \mathbb{E}(|X_n|)$ 矛盾, 因此 $p = 0$, 即 $\mathbb{P}(|X_\infty| < \infty) = 1$.

另一方面, 对任意 $c > 0, n > 0, \epsilon > 0$ 可得

$$\begin{aligned} \mathbb{E}(|X_\infty| \mathbf{1}_{\{|X_\infty| \leq c\}}) &= \mathbb{E}(|X_\infty| \mathbf{1}_{\{|X_\infty| \leq c, |X_n| \leq c\}}) + \mathbb{E}(|X_\infty| \mathbf{1}_{\{|X_\infty| \leq c, |X_n| > c\}}) \\ &\leq \mathbb{E}(|X_\infty| \mathbf{1}_{\{|X_\infty| \leq c, |X_n| \leq c\}}) + \mathbb{E}(|X_n| \mathbf{1}_{\{|X_\infty| \leq c, |X_n| > c\}}) \\ &\leq \mathbb{E}(|X_\infty - X_n| \mathbf{1}_{\{|X_\infty| \leq c, |X_n| \leq c\}}) + \mathbb{E}(|X_n| \mathbf{1}_{\{|X_\infty| \leq c\}}) \\ &\leq \epsilon \mathbb{P}(|X_\infty| \leq c, |X_n| \leq c) + 2c \mathbb{P}(|X_n - X_\infty| > \epsilon) + \mathbb{E}(|X_n|) \\ &\leq \epsilon + 2c \mathbb{P}(|X_n - X_\infty| > \epsilon) + a \end{aligned}$$

先令 $n \rightarrow \infty$ 再令 $\epsilon \rightarrow 0$ 得 $\mathbb{E}(|X_\infty| \mathbf{1}_{\{|X_\infty| \leq c\}}) \leq a$. 再令 $c \rightarrow \infty$ 得 $\mathbb{E}(|X_\infty|) \leq a$. \square

例25.2 设非负随机过程 $X = \{X_n, n \geq 0\}$ 满足

$$\mathbb{E}(X_{n+1}|X_0, \dots, X_n) = 2X_n + 1, \quad n \geq 0.$$

证明当 $n \rightarrow \infty$ 时 $X_n/2^n$ 几乎必然收敛.

证明 由条件容易验证

$$\mathbb{E}\left(\frac{X_{n+1}}{2^{n+1}}|X_0, \dots, X_n\right) = \frac{X_n}{2^n} + \frac{1}{2^n} \geq \frac{X_n}{2^n}$$

由此可知 $\{X_n/2^n\}$ 是下鞅, 而且

$$\begin{aligned} \mathbb{E}\left(\frac{X_{n+1}}{2^{n+1}}\right) &= \mathbb{E}\left(\mathbb{E}\left(\frac{X_{n+1}}{2^{n+1}}|X_0, \dots, X_n\right)\right) = \mathbb{E}\left(\frac{X_n}{2^n} + \frac{1}{2^n}\right) \\ &= \mathbb{E}(X_1/2) + \frac{1}{2} + \dots + \frac{1}{2^n} \leq \mathbb{E}(X_1/2) + 1 < +\infty. \end{aligned}$$

由定理25.5可知 $n \rightarrow \infty$ 时 $X_n/2^n$ 几乎必然收敛. \square

例25.3 设 X 是时齐的不可约常返马氏链, 转移概率矩阵 $P = (p_{ij})_{i,j \in S}$. 若 $y(i), i \in S$ 为方程组

$$u(i) = \sum_{j \in S} p_{ij} u(j), \quad i \in S,$$

的有界解, 试证明 $y(i), i \in S$, 恒为常数.

证明 令 $Y_n = y(X_n)$, 由马氏性可知

$$\begin{aligned} \mathbb{E}(Y_{n+1}|X_0, \dots, X_n) &= \mathbb{E}(y(X_{n+1})|X_0, \dots, X_n) = \mathbb{E}(y(X_{n+1})|X_n) \\ &= \sum_{j \in S} p_{X_n, j} y(j) = y(X_n) = Y_n. \end{aligned}$$

因此 $\{Y_n, n \geq 0\}$ 为鞅且有界. 由鞅收敛定理可知存在随机变量 U 使得

$$Y_n = y(X_n) \rightarrow U, \quad a.s.$$

注意到 X_n 是不可约常返马氏链, 对任意 $i, j \in S$,

$$\mathbb{P}(X_n = i, \text{i.o.}) = \mathbb{P}(X_n = j, \text{i.o.}) = 1,$$

因此存在 $\omega \in \Omega$ 使得 $Y_n(\omega) \rightarrow U(\omega)$ 且存在子列 n'_k, n''_k

$$X_{n'_k}(\omega) = i, \quad X_{n''_k}(\omega) = j.$$

这表明 $y(i) = U(\omega) = y(j)$. 因此 $y(i), i \in S$, 为恒常数. \square

练习题

25.1 设 $\{X_n, n \geq 0\}$ 为鞅, $\mathbb{E}(X_n) = 0$ 且 $\mathbb{E}(X_n^2) < \infty, n \geq 0$, 证明

$$\mathbb{P}\left(\max_{0 \leq k \leq n} X_k \geq \lambda\right) \leq \frac{\mathbb{E}(X_n^2)}{\mathbb{E}(X_n^2) + \lambda^2}.$$

25.2 给定 $\lambda > 0$, 若 X_1, X_2, \dots , 满足对任意 $n \geq 1$, $\mathbb{E}(\exp(\lambda X_{n+1})|X_1, \dots, X_n) \leq 1$, 令 $S_n =$

$X_1 + \dots + X_n, S_0 = 0$. 证明

$$\mathbb{P}(\max_{n \geq 0}(x + S_n) > l) \leq e^{-\lambda(l-x)}, \quad , x \leq l.$$

25.3 设 X_1, X_2, \dots 为独立随机变量且存在 $t > 0$ 使得对任意 $k \geq 1$,

$$\psi_k(t) = \mathbb{E}(\exp(tX_k)) < \infty.$$

若 $\Psi_n(t) = \prod_{k=1}^n \psi_k(t) \rightarrow \Psi(t) \in (0, \infty)$, 证明 $S_n = X_1 + \dots + X_n$ 几乎必然收敛.

25.4* 证明定理25.5.

参考文献

- [1] William, Feller. An introduction to probability theory and its applications (II). New York: John Wiley & Sons, 1971.
- [2] Ross, Sheldon M. Introduction to Probability Models, Tenth Edition. Singapore: Elsevier, 2010.
- [3] Karlin, Samuel and Tailor, Howard M. A First Course in Stochastic Processes. New York: Academic Press, 1975.
- [4] Karatzas, Ioannis and Shreve, Steven E. Brownian Motion and Stochastic Calculus. New York: Springer-Verlag, 1988.
- [5] Durrett, Rick. Probability: Theory and Examples. New York: Springer-Verlag, 2010.
- [6] Durrett, Rick. Essentials of Stochastic Processes. New York: Springer-Verlag, 2012.
- [7] 钱敏平, 龚光鲁. 随机过程论(第二版). 北京: 北京大学出版社, 1997.
- [8] 方兆本, 廖柏其. 随机过程(第二版). 北京: 科学出版社, 2004.
- [9] 何声武. 随机过程引论. 北京: 高等教育出版社, 1999.
- [10] 严士健, 刘秀芳. 测度与概率. 北京: 北京师范大学出版社, 2003.