

应用随机过程 笔记

1. 概率论基础知识

1.1. 概率

- 样本空间 Ω , 其元素称为样本点 ω , 子集称为事件 A ;
- Ω 的一些子集构成集类 \mathcal{F} 。 \mathcal{F} 若对于补和可列并封闭, 则称为 σ 代数, (Ω, \mathcal{F}) 称为可测空间;
- 概率 P 是 \mathcal{F} 上满足非负性、归一性、可列可加性的函数。 (Ω, \mathcal{F}, P) 称为概率空间。

1.2. 随机变量

- $X : \Omega \rightarrow \mathbb{R}$, 满足 $\forall a \in \mathbb{R}, \{\omega | X(\omega) < a\} \in \mathcal{F}$ 。
- 分布函数 $F(x) = P[X \leq x]$, 其中 $\{X < x\}$ 的意思是 $\{\omega | X(\omega) < x\}$ 。

给定随机变量 X 可以生成 Ω 上的 σ 代数, 即包含所有形如 $\{X \leq a\}, a \in \mathbb{R}$ 的最小 σ 代数, 记作 $\sigma(X)$ 。同样可以定义 $\sigma(X_1, \dots, X_n)$ 。生成的 σ 代数表示由 X_1, \dots, X_n 完全决定的事件, 在后面的停时中会用到。

1.3. Riemann-Stieltjes 积分

设 $F(x)$ 在 \mathbb{R} 上单调不减、右连续, $g(x)$ 连续, 则 $g(x)$ 关于 $F(x)$ 在 $[a, b]$ 上的 R-S 积分为 (分割、取点、求极限的定义方式和黎曼积分相同)

$$\int_a^b g(x) dF(x) = \lim_{\lambda \rightarrow 0} \sum_i g(u_i) \Delta F(x_i)$$

R-S 积分满足区间可加性、线性性 (对 f 和 g 都线性)。

若 $F(x)$ 在 $[a, b]$ 上可导, 则 $\int_a^b g(x) dF(x) = \int_a^b g(x) f(x) dx$ 。

1.4. 随机变量的数字特征

- 数学期望: 若 $\int_{\mathbb{R}} |x| dF(x)$ 存在, 则

$$E(X) = \int_{\mathbb{R}} x dF(x)$$

- 方差: $Var(X) = E(X - EX)^2$, 协方差: $Cov(X, Y) = E[(X - EX)(Y - EY)]$
 - $Var(aX + bY) = a^2 Var(X) + b^2 Var(Y) + abVar(X)Var(Y)$ 。
 - $|E(XY)|^2 \leq E(X)^2 E(Y)^2$ 。
- k 阶矩: 原点矩 $E(X^k)$, 中心矩 $E((X - EX)^k)$ 。

1.5. 重要函数和变换

- 矩母函数

$$\psi(t) = E(e^{tX}) = \int_{\mathbb{R}} e^{tX} dF_X(x)$$

矩母函数的重要性质是: 若 X 的 k 阶矩存在, 则 $E(X^k) = \psi^{(k)}(0)$ 。

- 特征函数

$$\phi(t) = E(e^{itX}) = \int_{\mathbb{R}} e^{itX} dF_X(x)$$

若分布函数 $f(x)$ 存在, 则 $\phi(x)$ 就是 $f(x)$ 的傅立叶变换。

1.6. 收敛性

对于随机变量序列 $\{X_n\}$ 及其分布函数 $\{F_n(x)\}$, 定义以下收敛方式

- 几乎必然收敛: $P[\lim_{n \rightarrow \infty} X_n = X] = 1$, 记作 $X_n \xrightarrow{\text{a.s.}} X$;
- 依概率收敛: $\forall \epsilon, \lim_{n \rightarrow \infty} P[|X_n - X| < \epsilon] = 1$, 记作 $X_n \xrightarrow{P} X$;
- r 阶矩收敛: $\lim_{n \rightarrow \infty} \mathbb{E}(|X_n - X|^r) = 0$, 记作 $X_n \xrightarrow{L^r} X$; $r = 2$ 时称为均方收敛;
- 依分布收敛 (弱收敛) : $\lim_{n \rightarrow \infty} F_n(x) = F(x)$, 记作 $X_n \xrightarrow{d} X$.

四种收敛的关系:

$$\begin{array}{ccccccc} \xrightarrow{L^s} & \xrightarrow[s > r \geq 1]{\Rightarrow} & \xrightarrow{L^r} & & & & \\ & & & \Downarrow & & & \\ \xrightarrow{\text{a.s.}} & \xrightarrow{\Rightarrow} & \xrightarrow{P} & \xrightarrow{d} & \xrightarrow{\rightarrow} & & \end{array}$$

2. 随机过程

2.1. 随机过程的定义

随机过程是概率空间 (Ω, \mathcal{F}, P) 上的一族随机变量 $\{X(t, \omega), t \in T\}$ 。

$X(t, \omega)$ 也可写成 $X_t(\omega)$ 、 $X(t)$ 或 X_t , 其所有取值构成状态空间 \mathcal{S} 。

2.2. 随机过程的数字特征

- 协方差函数 $\gamma(s, t) = \text{Cov}(X(s), X(t))$ 和自相关函数 $R_X(s, t) = \mathbb{E}(X(s)X(t))$
二者满足 $R_X(s, t) = \gamma(s, t) + \mu_X(s)\mu_X(t)$
- 同样也可以定义互协方差函数 $\gamma_{XY}(s, t) = \text{Cov}(X(s), Y(t))$ 和互相关函数 $R_{XY}(s, t) = \mathbb{E}(X(s)Y(t))$

2.3. 常见类型的随机过程

- 独立增量过程: 对任意 $t_1 < t_2 < \dots < t_n$, 有 $X(t_i) - X(t_{i-1})$ 相互独立。若 $X(t_i) - X(t_{i-1})$ 只与 $t_i - t_{i-1}$ 有关, 则称有平稳增量。
- 马尔可夫过程: 将来的状态只与现在有关, 而与过去无关 (条件独立)。
- 二阶矩过程: 方差函数永远存在。
- 平稳过程:
 - 宽平稳过程: 均值不变, 协方差 $\text{Cov}(X_t, X_s)$ 只与 $t - s$ 有关。
 - 严平稳过程: $(X(t_1), X(t_2), \dots, X(t_n))$ 与 $(X(t_1 + h), X(t_2 + h), \dots, X(t_n + h))$ 有相同的分布。
- 鞅: $\mathbb{E}(X(t_{n+1})|X(t_1), X(t_2), \dots, X(t_n)) = X(t_n)$ 。
- 更新过程: X_k 独立同分布, $S_n = \sum_{k=1}^n X_k$, 则 $N(t) = \max\{n|n \geq 0, S_n \leq t\}$ 为更新过程。
- 点过程 (计数过程): $\{N(A), A \subset T\}$ 取值非负整数, $N(\emptyset) = 0$, 当 $A_1 \cap A_2 = \emptyset$ 时有 $N(A_1 \cup A_2) = N(A_1) + N(A_2)$ 。

2.4. σ 代数流

对于概率空间 (Ω, \mathcal{F}, P) , $\{\mathcal{F}_t\}$ 代表 \mathcal{F} 的一系列子 σ 代数, 且满足 $\{\mathcal{F}_t\}$ 非降, 即对于 $\forall t_1 \leq t_2$ 有 $\mathcal{F}_{t_1} \subseteq \mathcal{F}_{t_2}$, 则称 $\{\mathcal{F}_t\}$ 为一个 σ 代数流。有时 $\{\mathcal{F}_t\}$ 也指对应的随机过程生成的 σ 代数流, 即 $\mathcal{F}_t = \sigma(X(s), 0 \leq s \leq t)$ 。

σ 代数流 $\{\mathcal{F}_t\}$ 代表了随机过程截至时间 t 所积累的信息, 即是一个信息流。若一个随机变量 X 是 \mathcal{F}_t 可测的, 是指对于 Borel 集的元素 $A \in \mathcal{B}$, 有 $\{\omega \in \Omega | X(\omega) \in A\} \in \mathcal{F}_t$ 。这表示 X 完全由 t 时间及以前的信息所决定。

3. 泊松过程

3.1. (时齐) 泊松过程的定义

泊松过程 $N(t)$ 指时间 t 以内发生事件的个数, 发生的速率为 λ 。

泊松过程是具有独立增量和平稳增量的计数过程, 定义为满足:

1. 计数过程, 且 $N(0) = 0$;
2. 独立增量;
3. $N(t+s) - N(s)$ 服从参数为 λt 的泊松分布。

等价定义:

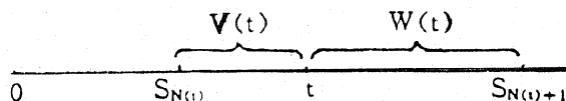
1. 计数过程, 且 $N(0) = 0$;
2. 独立平稳增量;
3. 对 $\forall t > 0$ 和充分小的 Δt 有 $P[N(t + \Delta t) - N(t) = 1] = \lambda \Delta t + o(\Delta t)$,
 $P[N(t + \Delta t) - N(t) \geq 2] = o(\Delta t)$ 。

3.2. 泊松过程的重要性质

定义 S_n 是第 n 个事件的到达时间, $X_n = S_n - S_{n-1}$ 是时间间隔, 则有

- $\{X_n\}$ 独立同服从参数为 λ 的指数分布;
- $\{S_n\}$ 服从 $\Gamma(n, \lambda)$ 。

定义年龄 $V(t)$ 和剩余寿命 $W(t)$, 则有



- $W(t)$ 与 X_n 同分布, 即满足参数为 λ 的指数分布 (无记忆性) ;
- $V(t)$ 满足“截尾”指数分布, 即

$$P[V(t) \leq x] = \begin{cases} 1 - e^{\lambda x}, & x \in [0, t) \\ 1, & x \in [t, +\infty) \end{cases}$$

到达时间 S_n 的条件分布

- 若已知事件在 $[0, t]$ 内只发生一次, 则该事件的到达时间是 $[0, t]$ 上的均匀分布 (平稳独立增量) 。
- 若发生了 n 次, 则到达时间的次序统计量的联合密度函数为

$$f(t_1, t_2, \dots, t_n) = \frac{n!}{t^n}, \quad 0 < t_1 < t_2 < \dots < t_n$$

注: 对于 n 个独立同分布的密度函数为 $f(y)$ 的统计量 Y_k , 其次序统计量的联合密度函数为

$$f(y_1, y_2, \dots, y_n) = n! \prod_{k=1}^n f(y_k), \quad 0 < y_1 < y_2 < \dots < y_n$$

以上除 $V(t)$ 的性质外都可以作为泊松分布的充要条件。

3.3. 泊松过程的检验与估计

泊松过程可以通过以下之一进行检验：

1. $\{X_n\}$ 独立同指数分布；
2. $W(t)$ 与 X_n 同分布；
3. $\forall t > 0$ 且 $N(t) = 1$ 时, S_1 满足 $[0, t]$ 上的均匀分布；
4. 给定 $t > 0$ 且 $N(t) = n$ 时, S_1, \dots, S_n 与 $[0, t]$ 上的独立均匀分布的次序统计量分布相同。

参数 λ 的估计

- 极大似然估计: $\hat{\lambda} = n/T$;
- 区间估计: 置信度为 $1 - \alpha$ 的区间为

$$\left[\frac{\chi_{\alpha/2}^2(2n)}{2S_n}, \frac{\chi_{1-\alpha/2}^2(2n)}{2S_n} \right]$$

3.4. 泊松过程的推广

非时齐泊松过程

非时齐泊松过程的定义与时齐泊松过程类似, 但不要求平稳增量, 强度 $\lambda(t)$ 随时间变化。

定义均值函数

$$m(t) = \int_0^t \lambda(s) ds$$

则 $N(t+s) - N(t)$ 服从参数为 $m(t+s) - m(t)$ 的泊松分布。

非时齐泊松过程可以转化为时齐泊松过程: $M(t) = N(m^{-1}(t))$ 是强度为 1 的泊松过程。

复合泊松过程

设 $\{Y_i\}$ 独立同分布, $N(t)$ 为泊松过程, 且二者独立, 则

$$X(t) = \sum_{i=1}^{N(t)} Y_i$$

称为复合泊松过程。复合泊松过程的意思是: 若某种事件的发生复合泊松过程, Y_i 表示每个事件的某种随机的广延量, 则 $X(t)$ 表示时间 t 内所有事件的该参量的总量。

复合泊松过程的性质:

- $X(t)$ 有独立增量;
- $$E(X(t)) = \lambda t E(Y), \quad \text{Var}(X(t)) = \lambda t E(Y^2).$$

条件泊松过程

若泊松过程的速率变成一个随机变量 Λ , 对于给定的 $\Lambda = \lambda$ 时, $N(t)$ 是参数为 λ 的泊松过程, 则 $N(t)$ 称为条件泊松过程。

条件泊松过程的全概率公式: 若 Λ 的分布是 G , 则长度为 t 的时间区间内发生 n 次事件的概率是

$$P[N(t+s) - N(s) = n] = \int_0^{+\infty} e^{-\lambda t} \frac{(\lambda t)^n}{n!} dG(\lambda)$$

条件泊松过程的性质:

$$E(N(t)) = tE(\Lambda), \quad \text{Var}(N(t)) = t^2 \text{Var}(\Lambda) + tE(\Lambda)$$

4. 更新过程

4.1. 更新过程的定义

更新过程是指时间间隔 $\{X_n\}$ 独立同分布的计数过程。即 $S_n = \sum_{k=1}^n X_k$, $N(t) = \sup\{n | S_n < t\}$ 。

4.2. 更新过程的重要性质

到达时间 S_n 的分布

- 若 $\{X_n\}$ 的分布为 $F(t)$, S_n 的分布为 $F_n(t)$, 则有

$$\begin{aligned} F_1(t) &= F(t), \\ F_n(t) &= \int_0^t F_{n-1}(t-s)dF(s), \quad n \geq 2 \end{aligned}$$

即 $F_n(t)$ 是 $F(t)$ 的 n 重卷积, 记为 $F_n = F_{n-1} * F$ 。

- $P[N(t) = n] = F_n(t) - F_{n-1}(t)$
- $E(X_n)$ 记为 μ , 有 $S_n/n \xrightarrow{\text{a.s.}} \mu$

平均事件数目

- 更新函数定义为 $M(t) = E(N(t))$, 则有

$$M(t) = \sum_{n=1}^{\infty} F_n(t) < \infty$$

- $M(t)$ 满足更新方程

$$M(t) = F(t) + \int_0^t M(t-s)dF(s)$$

- $m(t) = M'(t)$ 称为更新密度, 满足更新方程

$$m(t) = f(t) + \int_0^t m(t-s)f(s)ds$$

4.3. 更新方程

对于已知函数 $a(t)$ 和已知的分布函数 $F(t)$, 关于未知函数 $A(t)$ 的更新方程是指

$$A(t) = a(t) + \int_0^t A(t-u)dF(u)$$

若 $a(t)$ 有界, 则更新方程的解唯一, 为

$$A(t) = a(t) + \int_0^t a(t-u)dM(u)$$

其中

$$M(t) = \sum_{n=1}^{\infty} F_n(t), \quad F_n = F_{n-1} * F$$

4.4. 更新定理

- 更新过程下的 Wald 等式

$$E(S_{N(t)+1}) = \mu(M(t) + 1)$$

- Feller 基本更新定理

$$\lim_{t \rightarrow +\infty} \frac{M(t)}{t} = \frac{1}{\mu}$$

定义格点分布：对于非负随机变量 X ，若 $\exists d \geq 0$ ，使得 $\sum_{n=0}^{\infty} P[X = nd] = 1$ ，其中满足此式的最大 d 称为 X 的周期，称 X 的分布函数 F 是格点的。

- Blackwell 更新定理

F 是非负的分布函数， F_n 是 F 的 n 重卷积， $M(t) = \sum_{n=1}^{\infty} F_n(t)$ ，则

- 若 F 不是格点的，则对 $\forall a \geq 0$ ，

$$\lim_{t \rightarrow +\infty} [M(t+a) - M(t)] = \frac{a}{\mu}$$

- 若 F 是格点的，周期为 d ，则

$$\lim_{n \rightarrow \infty} [M((n+1)d) - M(nd)] = \frac{d}{\mu}$$

- 关键更新定理（与 Blackwell 更新定理等价）

若 F 是均值为 μ 的非负随机变量的分布函数， $a(t)$ 单调且绝对可积。对于更新方程

$$A(t) = a(t) + \int_0^t A(t-u) dF(u)$$

$A(t)$ 是其解，则

- 若 F 是非格点的，则

$$\lim_{t \rightarrow +\infty} A(t) = \begin{cases} \frac{1}{\mu} \int_0^{+\infty} a(t) dt, & \mu < +\infty \\ 0, & \mu = +\infty \end{cases}$$

- 若 F 是以 d 为周期的格点的，则对于 $\forall c > 0$ ，有

$$\lim_{t \rightarrow +\infty} A(t) = \begin{cases} \frac{d}{\mu} \sum_{n=0}^{\infty} a(c+nd), & \mu < +\infty \\ 0, & \mu = +\infty \end{cases}$$

4.5. 更新过程的推广

延迟更新过程

延迟更新过程是指 X_1 服从与其他 X 不同的分布 G 。此情况下，更新函数变为

$$M(t) = \sum_{n=1}^{\infty} G(t) * F^{(n-1)*}(t)$$

此更新函数仍然遵循更新定理。

更新回报过程

假设每次更新的时候都伴随随机的回报 R_n ，其中随机向量 (X_n, R_n) 独立同分布，但 R_n 可以依赖 X_n 。则更新回报过程是指

$$R(t) = \sum_{i=1}^{N(t)} R_i$$

更新回报定理指出，若更新间隔 X_i 满足 $E(X) < \infty$ ，每次更新的期望回报 $E(R_i) < \infty$ ，则有

$$\begin{aligned} \frac{R(t)}{t} &\xrightarrow{\text{a.s.}} \frac{E(R)}{E(X)} \\ \lim_{t \rightarrow \infty} \frac{E(R(t))}{t} &= \frac{E(R)}{E(X)} \end{aligned}$$

交错更新过程

一个系统有“开”(1) 和“关”(0) 两种状态, 假设系统最初为“开”, 且在 Z_1 时间后变为“关”, 再在 Y_1 时间后变为开, Z_2 时间后变为关, 如此往复。设 (Z_n, Y_n) 独立同分布, 即 $\{Z_n\}$ 之间、 $\{Y_n\}$ 之间独立同分布, 但 Z_i 和 Y_j 在 $i = j$ 时可以相关。则系统的状态 $\zeta(t)$ 称为交错更新过程。

交错更新定理指出, 若 $E(Z_n + Y_n) < \infty$, 且 $Z_n + Y_n$ 不是格点的, 则

$$\lim_{t \rightarrow +\infty} P[\zeta(t) = 1] = \frac{E(Z)}{E(Z) + E(Y)}$$

$$\lim_{t \rightarrow +\infty} P[\zeta(t) = 0] = \frac{E(Y)}{E(Z) + E(Y)}$$

5. 马尔可夫链

5.1. 马尔可夫链的定义

马尔可夫性是指未来只与现在有关, 与过去无关。即对任意的状态 i_0, i_1, \dots, i_n, j , 有

$$P[X_{n+1} = j | X_0 = i_0, X_1 = i_1, \dots, X_n = i_n] = P[X_{n+1} = j | X_n = i_n]$$

若马尔可夫链的初始状态 $P[X_0 = i_0]$ 给定, 则其统计特性完全由条件概率 $p_{ij} = P[X_{n+1} = j | X_n = i_n]$ 决定。

一个非常有用的结论是: 若随机过程 $\{X_n\}$ 满足 $X_n = f(X_{n-1}, \xi_n)$, 其中 $\{\xi_n\}$ 为取值在 \mathcal{S} 上的独立同分布随机变量, 且 X_0 与 $\{\xi_n\}$ 相互独立, 则 $\{X_n\}$ 是马尔可夫链, 且 $p_{ij} = P[f(i, \xi) = j]$ 。

5.2. 转移概率

定义一步转移概率 $p_{ij} = P[X_{n+1} = j | X_n = i_n]$ 和 m 步转移概率 $p_{ij}^{(m)} = P[X_{n+m} = j | X_n = i_n]$ 。

定义转移概率矩阵 $\mathbf{P} = (p_{ij})$, $\mathbf{P}^{(m)} = (p_{ij}^{(m)})$, 即

$$\mathbf{P} = (p_{ij}) = \begin{bmatrix} p_{00} & p_{01} & \dots \\ p_{10} & p_{11} & \dots \\ \vdots & \vdots & \ddots \end{bmatrix}$$

则有 Chapman-Kolmogorov 方程

$$p_{ij}^{(m+n)} = \sum_{k \in \mathcal{S}} p_{ik}^{(m)} p_{kj}^{(n)}$$

或

$$\mathbf{P}^{(n)} = \mathbf{P}^n$$

若系统在时刻 n 的分布为 $\pi(n)$ (行向量), 则 $n+1$ 时刻的分布为 $\pi(n)\mathbf{P}$ 。

5.3. 停时与强马尔可夫性

设 $\{X_n, n \in T\}$ 是一个随机过程, τ 是一个取值于 $T \cup \{+\infty\}$ 的随机变量。若对于 $\forall n \in T$, 事件 $\{\tau = n\}$ 完全取决于 X_1, X_2, \dots, X_n , 即 $\{\tau = n\} \in \mathcal{F}_n = \sigma(X_0, X_1, \dots, X_n)$, 则称 τ 是一个停时。停时的直观意义是, 一个过程是否停止完全取决于该时刻前的信息。

强马尔可夫性是将马尔可夫性中确定的现在时刻 n 变为随机的停时 τ , 仍然保持“未来与过去无关”的性质。即对于停时 τ , 有

$$P[X_{\tau+1} = j | X_0 = i_0, X_1 = i_1, \dots, X_\tau = i_\tau] = P[X_{\tau+1} = j | X_n = i_\tau]$$

可以证明, 任何离散时间的马尔可夫链都具有强马尔可夫性。

5.4. 状态的分类

- 状态 i 可达状态 j ($i \rightarrow j$) : $\exists n \geq 0$ 使得 $p_{ij}^{(n)} > 0$; 互相可达称为互通, 记为 $i \leftrightarrow j$;
可以将根据是否互通将马尔可夫链分为多个类。只存在一个类的马尔可夫链称为不可约的。
- 定义周期 $d = \text{gcd}(\{n \geq 1 | p_{ii}^{(n)} > 0\})$, 若 $d = 0$ 称为非周期的, $d > 0$ 称为周期的。属于同一个类的状态的周期相同。
- 常返: 记 $f_{ij}^{(n)}$ 为从 i 经过 n 步后首次到达 j 的概率, $f_{ij} = \sum_{n=1}^{\infty} f_{ij}^{(n)}$ 。 $f_{ii} = 1$ 称为常返的。
 - $f_{ii}^{(1)} = 1$ 称为吸收的。

两个常返态 i 、 j 之间满足 $f_{ij} = 1$ 。

对于常返态 i , 定义 $\mu_i = \sum_{n=1}^{\infty} n f_{ii}^{(n)}$ 为返回的平均步数。

- 若 $\mu_i < \infty$ 称为正常返, $\mu_i = \infty$ 称为零常返;
- 正常返 \wedge 非周期 = 遍历。

常返、非常返、正常返、零常返都是类性质。

从状态 i 进入 j 次数的期望

$$E\left(\sum_{n=0}^{\infty} \mathbb{I}(X_n = j) \mid X_0 = i\right) = \sum_{n=0}^{\infty} p_{ij}^{(n)}$$

返回次数的期望: 对于常返态为 $+\infty$, 对于非常返态为有限, 且等于 $1/(1 - f_{ii})$ 。

对于两个常返态 i 、 j , 从 i 进入 j 的次数的期望也为 $+\infty$ 。

状态空间分解定理: 可以将状态空间 \mathcal{S} 分解为有限个或可列个互不相交的子集

$$\mathcal{S} = \left(\bigcup_n C_n \right) \cup D$$

其中:

每个 C_n 是常返态构成的不可约闭集 (从内部无法到达外部), 称为基本常返闭集;

每个 C_n 的状态同属正常返态或零常返态, 具有相同周期, 且 $f_{ij} = 1$;

D 由全体非常返态构成, 从 C_n 中无法进入 D 。

若 \mathcal{S} 为有限集, 则 D 一定为非闭集, 即系统最终一定进入常返闭集。

5.5. 极限分布

转移概率的极限

基本极限定理: 若 i 是周期为 d 的常返态, 则 ($\mu_i = \infty$ 时为 0)

$$\lim_{n \rightarrow \infty} p_{ii}^{(nd)} = \frac{d}{\mu_i}$$

对于两个状态之间的转移概率, 若 j 为非常返态或零常返态, 则对任意的 $i \in \mathcal{S}$ 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = 0$$

若 j 正常返, 该极限不一定存在。但对给定的 i 和 $0 \leq r \leq d - 1$, 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(nd+r)} = \frac{d}{\mu_j} \sum_{m=0}^{\infty} f_{ij}^{(md+r)}$$

或者可以考虑其 Cesaro 平均收敛性

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{ij}^{(k)} = \begin{cases} 0, & j \text{ transient or null recurrent} \\ f_{ij}/\mu_j, & j \text{ positive recurrent} \end{cases}$$

平稳分布和极限分布

平稳分布 π 是指满足

$$\pi = \pi \mathbf{P}$$

极限分布是指 (若与 i 无关的极限存在)

$$\pi_j^* = \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \frac{1}{\mu_j}$$

对于不可约遍历链, 极限分布就是平稳分布, 且唯一。而对于非常返或零常返的不可约链, 平稳分布不存在。

对于不可约遍历链, $\{\pi_i = 1/\mu_i\}$ 是下面方程组的唯一解。

$$x_j = \sum_{i \in \mathcal{S}} x_i p_{ij}, \quad x > 0, \quad \sum_{i \in \mathcal{S}} x_i = 1$$

对于一般的马尔可夫链, 用 C_+ 表示全体正常返态的集合, 则平稳分布存在的充要条件是 C_+ 非空, 平稳分布唯一存在的充要条件为 C_+ 只包括一个基本常返闭集。

5.6. 马尔可夫链蒙特卡洛方法 (MCMC)

对于一个随机向量 \mathbf{X} , 我们常常想要求其某个函数的期望 $\theta = \mathbb{E}(h(\mathbf{X}))$ 。蒙特卡洛方法是生成独立同分布的随机向量序列 $\{\mathbf{X}_n\}$, 并依照强大数定律导出

$$\sum_{k=1}^n \frac{h(\mathbf{X}_k)}{n} \xrightarrow{\text{a.s.}} \theta$$

但生成特定概率分布的随机向量并不简单 (例如归一化因子难以计算, 或维度之间相关等)。MCMC 试图生成以 $P(\mathbf{X} = \mathbf{x}_i)$ 为平稳概率的马尔科夫链。当 $n \rightarrow \infty$ 时, \mathbf{X}_n 的分布接近 π , 从而以上面相同的方式估计 θ 。

6. 时间连续马尔可夫链

6.1. 时间连续马尔可夫链

时间连续马尔可夫链的指标集为 $T = [0, +\infty)$, 但其状态空间 \mathcal{S} 仍然是离散的。时间连续马尔可夫链对于任意 $0 \leq t_0 \leq t_1 \leq \dots \leq t_n \leq t_{n+1}$, 有

$$P[X(t_{n+1}) = i_{n+1} | X(t_0) = i_0, X(t_1) = i_1, \dots, X(t_n) = i_n] = P[X(t_{n+1}) = i_{n+1} | X(t_n) = i_n]$$

记转移概率为

$$p_{ij}(s, t) = P[X(t+s) = j | X(s) = i]$$

若 $p_{ij}(s, t)$ 与 s 无关, 称该马尔可夫链是时齐的, 记转移概率为 $p_{ij}(t)$ 。本处只讨论时齐的连续时间马尔可夫链。

时间连续马尔可夫链的一条轨道是: X 在某个状态停留一段时间后, 跳到另一个状态, 再停留一段时间后再跳向第三个状态, 如此进行下去。时间连续马尔可夫链具有无记忆性, 即在每个状态停留的概率满足指数分布。

6.2. 转移概率与转移速率

时间连续马尔可夫链也有 C-K 方程

$$p_{ij}(s+t) = \sum_{k \in \mathcal{S}} p_{ik}(s) p_{kj}(t)$$

或矩阵形式

$$\mathbf{P}(s+t) = \mathbf{P}(s) \mathbf{P}(t)$$

转移矩阵满足 $\mathbf{P}(0) = \mathbf{I}$ 且 $\mathbf{P}(t)$ 对于 t 一致连续。

为了得到与时间间隔无关的描述转移概率的量, 定义转移速率矩阵

$$\mathbf{Q} = \mathbf{P}'(0) = \lim_{t \rightarrow 0} \frac{\mathbf{P}(t) - \mathbf{I}}{t}$$

\mathbf{Q} 的对角元可以是 $-\infty$ 。当没有无穷时, 称 \mathbf{Q} 是保守的。当状态空间 \mathcal{S} 有限时, \mathbf{Q} 必保守。

其中 q_{ij} 是从状态 i 转移至状态 j 的速率。定义 $q_i = -q_{ii}$ 表示从状态 i 跳出的速率。

Kolmogorov 向前向后微分方程 (第二条为向前方程, 在状态有限或生灭过程中成立)

$$\begin{aligned} p'_{ij}(t) &= \sum_{k \neq i} q_{ik} p_{kj}(t) - q_{ii} p_{ij}(t) \\ p'_{ij}(t) &= \sum_{k \neq i} q_{kj} p_{ik}(t) - q_{jj} p_{ij}(t) \end{aligned}$$

或写成矩阵形式

$$\begin{aligned} \mathbf{P}'(t) &= \mathbf{P}(t) \mathbf{Q} \\ \mathbf{P}'(t) &= \mathbf{Q} \mathbf{P}(t) \end{aligned}$$

7. 鞍

7.1. 鞍的定义

鞍的概念来源于公平赌博, 即资金期望不变化。随机过程 $\{X_n\}$ 满足以下条件则称为鞍

1. $E(|X_n|) < \infty$;
2. $E(X_{n+1} | X_0, X_1, \dots, X_n) = X_n$, a.s..

如果有另一随机过程 $\{Y_n\}$ (例如代表每场赌博的输赢), X_n 是 Y_0, \dots, Y_n 的函数, 则 $\{X_n\}$ 满足以下条件称为关于 $\{Y_n\}$ 是鞍

1. $E(|X_n|) < \infty$;
2. $E(X_{n+1} | Y_0, Y_1, \dots, Y_n) = X_n$, a.s..

有时引入记号 $\mathcal{F}_n = \sigma(Y_0, Y_1, \dots, Y_n)$, 则也会说 $\{X_n\}$ 关于 $\{\mathcal{F}_n\}$ 是鞍。

对于鞍, $E(X_{n+1}) = E(E(X_{n+1} | Y_0, Y_1, \dots, Y_n)) = E(X_n)$, 所以其期望在任何时刻均相等。

7.2. 上鞍/下鞍及分解定理

对于随机过程 $\{X_n\}$ 和 $\{Y_n\}$, $\{X_n\}$ 是 $\{Y_n\}$ 的函数, 则 $\{X_n\}$ 满足以下条件称为关于 $\{Y_n\}$ 是上(下)鞍

1. $E(\min(x, 0)) > -\infty$ ($E(\max(x, 0)) < +\infty$);
2. $E(X_{n+1} | Y_0, Y_1, \dots, Y_n) \leq X_n$ ($E(X_{n+1} | Y_0, Y_1, \dots, Y_n) \geq X_n$).

上 (下) 鞍描述的是不利 (有利) 的非公平赌博。

下 (上) 鞍分解定理: 下 (上) 鞍一定可以唯一地分解为一个鞍和一个增 (减) 过程之和。即对于任意一个 $\{X_n\}$ 关于 $\{Y_n\}$ 是下 (上) 鞍, 则必存在唯一的分解 $X_n = M_n + Z_n$ 使得

1. $\{M_n\}$ 关于 $\{Y_n\}$ 是鞍;
2. Z_n 是 Y_1, \dots, Y_{n-1} 的函数, 且 $Z_1 = 0$, Z_n 不减 (增), 且期望存在。

7.3. 停时定理

设 $\{M_n\}$ 关于 $\{X_n\}$ 是鞍, T 是停时且满足

1. $P[T < \infty] = 1$;
2. $E(|M_T|) < \infty$;
3. $\lim_{n \rightarrow \infty} E(|M_n| \mathbb{I}_{\{t > n\}}) = 0$,

则有 $E(M_T) = E(M_0)$ 。

停时定理的意义是: 在公平赌博中, 无论你按照何种策略根据前面的结果决定停止时间, (在满足一定条件下) 你都不可能赢。由于现实中赌博不可能无限进行下去, 即停时是有界的, 因此该条件自然满足。

7.4. 鞍收敛定理

设 $\{M_n\}$ 关于 $\{X_n\}$ 是 (上/下) 鞍, 并且 $\sup E(|M_n|) < \infty$, 则存在随机变量 M_∞ 使得

$$M_n \xrightarrow{\text{a.s.}} M_\infty$$

即: 有上界的下鞍收敛, 有下界的上鞍收敛。

7.5. 连续鞍

定义在相同概率空间上的随机过程 $\{X(t)\}$ 若满足以下条件, 则称 $\{X(t)\}$ 关于 $\{\mathcal{F}_t\}$ 是鞍

1. $\forall t, E(|X(t)|) < \infty$;
2. $\forall s, t, E(X(t+s)|\mathcal{F}_t) = X(t)$, a.s.;
3. $\forall t, X(t)$ 关于 \mathcal{F} 是可测的。

同样可以定义连续时间的上鞍和下鞍。

连续鞍也满足上面的重要定理

- 期望不变: $E(X(t)) = E(X(0))$;
- 停时定理: 若 τ 是有界停时, 则 $E(X(\tau)) = E(X(0))$;
- 鞍收敛定理: 若 $\sup E(|X_n|) < \infty$, 则存在 X_∞ 使得 $X_n \xrightarrow{\text{a.s.}} X_\infty$ 。

8. 布朗运动

8.1. 布朗运动的定义

Brown 运动又称为 Wiener 过程, 是对称随机游走的连续化。其定义为

1. $\{B(t)\}$ 有独立增量;
2. 对每个 $t > 0$, $B(t) - B(0)$ 服从正态分布 $\mathcal{N}(0, \sigma^2 t)$ 。

一个等价定义是

1. 正态增量: $B(t+s) - B(t) \sim \mathcal{N}(0, \sigma^2 s)$;
2. 独立增量: $B(t) - B(s)$ 独立于过去的 $B(u), u \leq s$;
3. 连续性: $B(t)$ 是 t 的连续函数。

当 $B(0) = 0$ 且 $\sigma = 1$ 时, 称为标准布朗运动。

8.2. 布朗运动的基本性质

- 布朗运动的马尔可夫性

布朗运动不但具有马尔可夫性, 还具有强马尔可夫性。

- 布朗运动的鞅性

布朗运动 $\{B(t)\}$ 是鞅, $\{B^2(t) - t\}$ 也是鞅。

- 布朗运动的路径性质

对于一个布朗运动, 其几乎所有路径 $b(t)$ 都满足

1. 在任何区间都不单调;

2. 在任何点都不可微;

3. 在任何区间上都不是有界变差的, 即对任意一个区间分割 $t_0 < t_1 < \dots < t_n$ 有

$$\lim_{\lambda \rightarrow 0} \sum_i |b(t_i) - b(t_{i-1})| = \infty$$

4. 对于任何 t , 路径在 $[0, t]$ 上的二次变差为 t , 即对任意一个分割 $0 = t_0 < \dots < t_n = t$ 有

$$\lim_{\lambda \rightarrow 0} \sum_i |b(t_i) - b(t_{i-1})|^2 = t$$

- 布朗运动的正态性

正态过程 (Gauss 过程) 是指任意有限维分布都是正态分布的随机过程。

布朗运动是期望 $E(B(t)) = 0$ 、协方差 $\gamma(t, s) = \min(t, s)$ 的正态过程。

8.3. 首中时与零点

首中时

以 T_x 表示布朗运动首次击中 x 的时间, 即 $T_x = \inf\{t | B(t) = x\}$ 。那么有

$$P[T_x \leq t] = 2 - 2\Phi\left(\frac{|x|}{\sqrt{t}}\right)$$

T_x 的两条重要性质是, 对于 $\forall x$, 有 $P[T_x < \infty] = 1$, 但 $E(T_x) = \infty$ 。

零点

布朗运动的反正弦律是指, $B(t)$ 在 (t_1, t_2) 上没有零点的概率是

$$P[B(t) \neq 0, t_1 < t < t_2] = \frac{2}{\pi} \arcsin \sqrt{\frac{t_1}{t_2}}$$

这是一个很有趣的结论, 即在 (t_1, t_2) 上有没有零点的概率与 $t_2 - t_1$ 无关, 与 t_2/t_1 有关。

8.4. 布朗运动的推广

布朗桥

布朗桥是给定 $B(0) = B(1) = 0$ 的 $t \in [0, 1]$ 的布朗运动。其定义为

$$B^*(t) = B(t) - tB(1), \quad 0 \leq t \leq 1$$

布朗桥的分布与给定 $B(1) = 0$ 的布朗运动的条件分布相同。

有吸收值的布朗运动

若 x 处的首中时为 T_x , 则在 x 处被吸收的布朗运动是指

$$Z(t) = \begin{cases} B(t), & t < T_x \\ x, & t \geq T_x \end{cases}$$

其概率分布为

$$\begin{cases} P[Z(t) = x] = \frac{2}{\sqrt{2\pi t}} \int_x^{+\infty} \exp(-\frac{u^2}{2t}) du, \\ P[Z(t) \leq y] = \frac{1}{\sqrt{2\pi t}} \int_{y-2x}^y \exp(-\frac{u^2}{2t}) du, \quad y < x \end{cases}$$

在原点反射的布朗运动

定义为 $Y(t) = |B(t)|$ 。其分布函数非常简单，即 $P[Y(t) \leq y] = P[-y \leq B(t) \leq y]$ 。

几何布朗运动

定义为 $X(t) = e^{B(t)}$ 。几何布朗运动描述的是相对变化为独立同分布的模型。例如，若随机变量 $X(t)$ 满足 $\frac{X(n\Delta t)}{X((n+1)\Delta t)}$ 独立同分布，则当 $\Delta t \rightarrow 0$ 时， $X(t)$ 可以描述为几何布朗运动。

几何布朗运动满足 $E(X(t)) = e^{t/2}$ ， $\text{Var}(X(t)) = e^{2t} - e^t$ 。

漂移布朗运动

$\{B(t) + \mu t\}$ 称为漂移系数为 μ 的布朗运动。它是不对称随机游走的连续化。

在漂移布朗运动中，很有用的一个量是，起始于 x ，先击中 a 再击中 $-b$ 的概率 ($a, b > 0$)

$$P[T_a < T_{-b} < \infty | X(0) = x] = \frac{e^{2\mu b} - e^{-2\mu x}}{e^{2\mu b} - e^{-2\mu a}}$$

9. 随机微积分

9.1. L^2 空间上的分析

定义所有二阶矩存在的随机变量构成的集合为 L^2 空间。其上内积定义为 $(X, Y) = E(XY)$ (复数则定义为 $(X, Y) = E(X\bar{Y})$)。从而可以定义范数 $\|X\| = \sqrt{(X, X)}$ 和距离 $d(X, Y) = \|X - Y\|$ 。

在此基础上，可以定义分析学的概念。对于随机变量序列 $\{X_n\}$ ，若 $d(X_n, X) \rightarrow 0, n \rightarrow \infty$ ，则称 X 是序列 $\{X_n\}$ 的均方极限，记作 $\lim_{n \rightarrow \infty} X_n \stackrel{L^2}{=} X$ 。 L^2 空间的柯西序列必收敛，因此 L^2 空间是一个完备的欧氏空间。

连续的二阶矩过程 (即 $\forall t, X(t) \in L^2$ 的过程) 相当于 L^2 空间中的一条曲线。我们可以对随机过程定义分析学性质。

- 均方连续

$$\lim_{t \rightarrow t_0} X(t) \stackrel{L^2}{=} X(t_0)$$

$\{X(t)\}$ 在 t_0 处均方连续的充要条件是自相关函数 $R_X(s, t) = (X(s), X(t))$ 在 (t_0, t_0) 处连续。

- 均方导数

$$\lim_{h \rightarrow 0} \frac{X(t_0 + h) - X(t_0)}{h} \stackrel{L^2}{=} X'(t_0)$$

均方可导的充要条件是 $R_X(s, t)$ 在 (t_0, t_0) 处广义二次可微，即下式的极限存在

$$\lim_{\substack{h \rightarrow 0 \\ l \rightarrow 0}} \frac{R_X(t_0 + h, t_0 + l) - R_X(t_0 + h, t_0) - R_X(t_0, t_0 + l) + R(t_0, t_0)}{h \cdot l}$$

- 均方积分：若 $f(t)$ 是 T 上的函数， $X(t)$ 是 T 上的二阶矩过程，则与黎曼积分进行相同的分割、取点、最大长度趋于 0 的过程，若极限存在，则称为黎曼均方积分

$$\lim_{\lambda \rightarrow 0} \sum_k f(u_k) X(u_k) \Delta t_k \stackrel{L^2}{=} \int_a^b f(t) X(t) dt$$

均方可积的一个充分条件是 $\int_a^b \int_a^b f(s) f(t) R_X(s, t) ds dt$ 存在。

这些均方分析性质与普通函数的分析学性质有很多类似之处。

- 均方导数的性质:

1. 可导则连续;
2. 导数具有线性性;
3. $(f(t)X(t))' = f'(t)X(t) + f(t)X'(t)$;
4. $E(X'(t)) = (E(X(t)))'$;
5. $E(X'(s), X'(t)) = \frac{\partial^2}{\partial s \partial t} R_X(s, t)$ 。

- 均方积分的性质:

1. 线性性和区间可加性;
2. 闭区间上 $X(t)$ 均方连续则均方可积;
3. 若 $Y(t) = \int_a^t X(u) du$, 则 Y 均方可导, 且 $Y'(t) = X(t)$;
 $X(t)$ 均方可导, $X'(t)$ 均方连续, 则 $X(b) - X(a) = \int_a^b X'(t) dt$;
4. $E\left(\int_a^b f(t)X(t) dt\right) = \int_a^b f(t)E(X(t)) dt$ 。

9.2. Itô 积分

在概率空间 (Ω, \mathcal{F}, P) 上, 我们希望定义一个随机过程的函数 $f(t, \omega)$ 关于布朗运动 $B(t, \omega)$ 的积分。当 $f(t, \omega)$ 满足以下条件时, 这种积分是可以恰当定义的。满足这些条件的集合记作 $L^2(T)$ 。

1. $f(t, \omega)$ 关于 $\mathcal{B}(T) \times \mathcal{F}$ 可测, 即对 $\forall t, \forall A \in \mathcal{B}(T)$, 有 $\{\omega \in \Omega | f(t, \omega) \in A\} \in \mathcal{F}$;
2. $\forall t$, 有 $f(t, \cdot)$ 关于 \mathcal{F}_t 可测, 其中 $\{\mathcal{F}_t\}$ 是 σ 代数流, 即 $f(t, \cdot)$ 完全由 t 时间及之前的状态决定;
3. $E\left(\int_T f(t, \omega)^2 dt\right) < \infty$ 。

$L^2(T)$ 上的随机过程都可以由简单过程进行二阶矩逼近。对于简单过程 (ξ_i 是随机变量)

$$\phi(t) = \xi_0 \mathbb{I}_0(t) + \sum_{i=0}^{n-1} \xi_i \mathbb{I}_{(t_i, t_{i+1}]}(t)$$

此时 Itô 积分定义为 (注意结果是一个随机变量)

$$\int_0^T \phi(t) dB(t) = \sum_{i=1}^{n-1} \xi_i (B(t_{i+1}) - B(t_i))$$

若随机过程 $f(t)$ 可以由一个简单过程序列 $\{\phi_n(t)\}$ 二阶矩逼近, 即

$$\lim_{n \rightarrow \infty} \int_0^T E(\phi_n(t) - f(t))^2 dt = 0$$

则 $f(t)$ 的 Itô 积分定义为简单过程的积分在均方收敛意义下的极限

$$\lim_{n \rightarrow \infty} \int_0^T \phi_n(t) dB(t) \stackrel{L^2}{=} \int_0^T f(t) dB(t)$$

9.3. Itô 积分的性质

Itô 积分的基本性质

- 线性性与区间可加性 (与 R-S 积分相同)
- 零期望

$$\mathbb{E} \left(\int_0^T f(t) dB(t) \right) = 0$$

- 方差

$$\text{Var} \left(\int_0^T f(t) dB(t) \right) = \int_0^T \mathbb{E}(f^2(t)) dt$$

Itô 积分过程

Itô 积分的变上限积分定义了一个随机过程

$$Y(t) = \int_0^t X(s) dB(s)$$

其重要性质包括

- $\{Y(t)\}$ 是零均值的连续鞅;
- 鞅表示定理 (上面一条的逆命题) : 若 $\{Y(t)\}$ 是鞅, $Y(t) \in L^2(T)$, 则必存在唯一的过程 $X(t) \in L^2(T)$ 使得, 对任意 $t_1, t_2 \in T$, 有

$$Y(t_2) - Y(t_1) = \int_{t_1}^{t_2} X(s) dB(s)$$

- 若 X 是非随机的 t 的函数, 且 $\int_0^T X^2(s) ds < \infty$, 则 $\{Y(t)\}$ 是高斯过程。
- $Y(t)$ 在 $[0, t]$ 上的二次变差为

$$[Y, Y](t) = \int_0^t X^2(s) ds$$

9.4. Itô 公式

Itô 公式相当于随机分析中的链式求导法则: 若 f 是二次连续可微的函数, 则对于任意 t 有

$$df(B(t)) = f'(B(t)) dB(t) + \frac{1}{2} f''(B(t)) dt$$

或积分形式

$$f(B(t)) = f(0) + \int_0^t f'(B(s)) dB(s) + \frac{1}{2} \int_0^t f''(B(s)) ds$$

更一般地, 如果我们定义 Itô 过程 (即漂移-扩散过程), 其中随机过程 $\sqrt{\mu(t)}, \sigma(t) \in L^2(T)$

$$dX(t) = \mu(t) dt + \sigma(t) dB(t)$$

而若想要求 t 和 $X(t)$ 的函数 $f(t, x)$, 则 f 仍然是 Itô 过程, 且有

$$df = \left(\frac{\partial f}{\partial t} + \mu \frac{\partial f}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 f}{\partial x^2} \right) dt + \sigma \frac{\partial f}{\partial x} dB$$

Itô 公式可以用于计算与布朗运动有关的积分式。

9.5. 随机微分方程

形如

$$dX(t) = \mu(t, X(t)) dt + \sigma(t, X(t)) dB(t)$$

的方程称为随机微分方程 (SDE)。

解的存在唯一性定理

若 $\mu(t, x), \sigma(t, x) : [0, T] \times \mathbb{R} \rightarrow \mathbb{R}$ 满足

1. 可测性: $\mu, \sigma \in L^2([0, T] \times \mathbb{R})$;
2. Lipschitz 条件: 存在常数 $M > 0$ 使得对 $\forall t \in [0, T], \forall x, y \in \mathbb{R}$, 有

$$|\mu(t, x) - \mu(t, y)| + |\sigma(t, x) - \sigma(t, y)| < M|x - y|$$

3. 线性增长有界: 存在常数 $K > 0$ 使得对 $\forall t \in [0, T], x \in \mathbb{R}$ 有

$$|\mu(t, x)| + |\sigma(t, x)| \leq K(t + |x|)$$

4. 初始条件: $X(t_0)$ 关于 \mathcal{F}_{t_0} 可测, 且 $E(X(t_0)^2) < \infty$

则存在唯一的连续路径随机过程 $\{X(t), t \geq t_0\}$ 满足该方程, 且 $\{X(t)\} \in L^2(t_0, T)$ 。

9.6. SDE 应用举例

- Ornstein-Uhlenbeck (OU) 过程

OU 过程在包括计算神经科学内的许多领域中都很常用。其方程为

$$dX(t) = -\mu X(t)dt + \sigma dB(t)$$

由于布朗运动的变差是白噪音, 因此该方程可以化做以下形式, 称为 Langevin 方程。其中 ξ 是白噪音。

$$\frac{dX(t)}{dt} = -\mu X(t) + \sigma \xi(t)$$

其密度函数 $P(x, t)$ 满足 Fokker-Planck 方程

$$\frac{\partial P}{\partial t} = \mu \frac{\partial(xP)}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 P}{\partial x^2}$$

OU 过程是一个平稳的马尔可夫过程, 同时也是高斯过程。其解为

$$X(t) = X(0)e^{-\mu t} + \frac{\sigma}{\sqrt{2\mu}} e^{-\mu t} B(e^{2\mu t} - 1)$$

- Black-Scholes 期权定价公式

金融中的 Black-Scholes 期权定价公式非常有名。设股票的价格为随机过程 S_t , 期望收益率为 b , 波动率为 σ , 则 S_t 应满足 SDE

$$dS_t = bS_t dt + \sigma S_t dB_t$$

给定初始变量 S_0 时, 此方程的解为带有漂移项的几何布朗运动 (但后面不直接用这个解)

$$S_t = S_0 \exp\left(\left(b - \frac{\sigma^2}{2}\right)t + \sigma B_t\right)$$

若期权价格为时间和股票价格的函数 $V(t, S_t)$, 根据 Itô 公式展开

$$dV = \left(\frac{\partial V}{\partial t} + bS_t \frac{\partial V}{\partial S_t} + \frac{\sigma^2}{2} S_t^2 \frac{\partial^2 V}{\partial S_t^2} \right) dt + \sigma S_t \frac{\partial V}{\partial S_t} dB_t$$

若卖出方在 t 时刻每卖出 1 份期权就买入 δ 份股票进行对冲, 即投资组合 $\Pi_t = \delta S_t - V(t, S_t)$, 则其价值增量应为

$$\begin{aligned} d\Pi_t &= \delta dS_t - dV(t, S_t) \\ &= \left(-\frac{\partial V}{\partial t} + bS_t \left(\delta - \frac{\partial V}{\partial S_t} \right) - \frac{\sigma^2}{2} S_t^2 \frac{\partial^2 V}{\partial S_t^2} \right) dt + \sigma S_t \left(\delta - \frac{\partial V}{\partial S_t} \right) dB_t \end{aligned}$$

要求收益是无风险的, 即 dB_t 项应为 0, 所以 $\delta = \partial V / \partial S_t$, 带入可得

$$d\Pi_t = \left(-\frac{\partial V}{\partial t} - \frac{\sigma^2}{2} S_t^2 \frac{\partial^2 V}{\partial S_t^2} \right) dt$$

无风险时, 收益必等于无风险利率 r 所造成的收益, 即 $d\Pi_t = r\Pi_t dt$, 将此带入上式, 同时带入无风险的 Π_t , 即可得到最终的 Black-Scholes 方程

$$\frac{\partial V}{\partial t} + rS_t \frac{\partial V}{\partial S_t} + \frac{\sigma^2}{2} S_t^2 \frac{\partial^2 V}{\partial S_t^2} - rV = 0$$

这个结果很有趣的是，它与 b 和 σ 都无关。在一些经典的期权中该方程有解析解，即为 Black-Scholes 期权定价公式。