

# tieli/notes/appl\_stoch/lect\*.pdf 部分习题参考答案

吴大维

1582 年 10 月 10 日

## 1 Lecture 2

5. 为了计算  $\mathbb{E}(X_1 \cdots X_k)$ , 只需求出矩母函数  $M(t)$  在原点处对  $t_1, \dots, t_k$  的混合偏导数

$$\left. \frac{\partial^k M(t)}{\partial t_1 \partial t_2 \cdots \partial t_k} \right|_{t=0}.$$

又因为对于正态变量  $X \sim \mathcal{N}(0, \Sigma)$  而言,  $M(t) = \exp\left(\frac{1}{2}t^T \Sigma t\right)$  是解析的, 所以又只需求出它在原点 Taylor 展开式中  $t_1 \cdots t_k$  项系数的  $1!1! \cdots 1! = 1$  倍.

用  $e^x$  在原点的 Taylor 展开, 得到

$$M(t) = \sum_{k=0}^{\infty} \frac{1}{k!} \left( \frac{1}{2} \sum_{i,j=1}^n \sigma_{ij} t_i t_j \right)^k.$$

显然展开式中只有偶数次项, 所以  $k$  为奇数时  $\mathbb{E}(X_1 \cdots X_k) = 0$ .

$k$  为偶数时,  $t_1 \cdots t_k$  一项只可能来自和式中的  $\frac{k}{2}$  次项

$$\frac{1}{(k/2)!} \left( \frac{1}{2} \sum_{i=1}^n \sigma_{ii} t_i^2 + \sum_{i < j} \sigma_{ij} t_i t_j \right)^{\frac{k}{2}}.$$

又因为  $t_1, \dots, t_k$  是两两不同的变元, 所以  $t_1 \cdots t_k$  这一项只可能由交叉项  $\sigma_{ij} t_i t_j$  ( $i \neq j$ ) 产生, 而且每个括号提供两个因子. 任何一种  $\{1, 2, \dots, k\}$  的分划  $\{i_1, i_2\}, \{i_3, i_4\}, \dots, \{i_{k-1}, i_k\}$ , 对应了一种由每个括号提供因子的方式 (即第  $j$  个括号提供  $t_{i_{2j-1}}, t_{i_{2j}}$  的因子); 对于同一种分划方式, 它的  $\frac{k}{2}$  个因子的二元组有  $\left(\frac{k}{2}\right)!$  种不同的排列方式, 所以它产生的系数为  $\left(\frac{k}{2}\right)! \sigma_{i_1 i_2} \cdots \sigma_{i_{k-1} i_k}$ . 因此求和后该项的系数为

$$\frac{1}{(k/2)!} \cdot \sum_{\text{pairing}} (k/2)! \prod \sigma_{ij} = \sum_{\text{pairing}} \prod \sigma_{ij}.$$

而根据二阶矩的性质,  $\mathbb{E}(X_i X_j) = \sigma_{ij}$ , 证明完毕.

## 2 Lecture 3


2. 首先,  $\mathbb{S}^2$  指的是三维空间中的二维球面.

$$\mathbb{S}^2 = \{(x, y, z) \in \mathbb{R}^3 : x^2 + y^2 + z^2 = 1\}.$$

其次, 很多同学选择如下的方法生成球面均匀分布.

取  $\theta \sim \mathcal{U}(0, \pi)$ ,  $\varphi \sim \mathcal{U}(0, 2\pi)$ , 则  $(\sin \theta \cos \varphi, \sin \theta \sin \varphi, \cos \theta) \sim \mathcal{U}(\mathbb{S}^2)$ .

部分同学生成的分布如下图所示.



可以明显看到这些样本点在两极较为集中, 这是因为球面上纬度角  $\theta$  并非均匀分布. 球面上的面元等于  $\sin \theta d\theta d\varphi$ , 所以  $\theta$  的分布的密度函数正比于  $\sin \theta$ , 或者说  $\cos \theta$  是均匀分布. (亦可通过“球冠面积正比于高度”的事实推出) 因此, 若采用球坐标方式生成, 生成  $\theta$  的方式应为

$$U \sim \mathcal{U}[-1, 1],$$

$$\theta \sim \arccos(U).$$

4. 题中算法的第 2、3 步的总效果是在  $U < \frac{p(X)}{Mg_m(X)}$  时接受, 所以和算法 2.6 等价 (在算法 2.6 中, 把  $f(x)$  换成  $Mg_m(x)$ ,  $A$  换成  $M$ ), 是正确的采样算法.

该算法的优势在于, 第 2 步计算的函数  $g_l(x)$  非常简单, 所以有一定概率减少计算  $f(x)$  的次数, 从而减少计算复杂度.

$$\mathbb{P}(\text{不用计算 } f(x)) = \int g_m(x) \frac{g_l(x)}{Mg_m(x)} dx = \frac{1}{M} \int g_l(x) dx.$$

### 3 Lecture 4

1. 我们证明对任何单调增函数  $f, g$ , 都有  $\text{Cov}(f(X)g(X)) \geq 0$ .

$$\begin{aligned} \text{Cov}(f(X)g(X)) &= \mathbb{E}(f(X)g(X)) - \mathbb{E}f(X)\mathbb{E}g(X) \\ &= \frac{1}{2} \left[ \int_0^1 (f(x)g(x) + f(y)g(y)) dx - \int_0^1 f(x) dx \int_0^1 g(y) dy - \int_0^1 g(x) dx \int_0^1 f(y) dy \right] \\ &= \frac{1}{2} \int_{[0,1]^2} [f(x)g(x) + f(y)g(y) - f(x)g(y) - f(y)g(x)] dx dy \\ &= \frac{1}{2} \int_{[0,1]^2} [f(x) - f(y)][g(x) - g(y)] dx dy. \end{aligned}$$

由于  $f, g$  单调性相同, 括号内恒非负, 所以积分恒非负. 证明完毕.

3. 由熟知结论  $\log x \leq x - 1, \forall x > 0$ . 所以

$$D(f||g) = - \int f(x) \log \frac{g(x)}{f(x)} dx \geq - \int f(x) \left( \frac{g(x)}{f(x)} - 1 \right) dx = \int [f(x) - g(x)] dx = 0.$$

等号成立当且仅当  $\frac{g(x)}{f(x)} = 1$  处处成立, 即  $f \equiv g$ .

## 4 Lecture 5

2. (a) 注意到

$$Z_{2n} = \frac{Z_n + \tilde{Z}_n}{\sqrt{2}},$$

其中  $\tilde{Z}_n$  是与  $Z_n$  独立同分布的随机变量. 记  $Z_n$  的特征函数为  $f_n$ , 则根据特征函数的性质,

$$f_{2n}(t) = f_n^2\left(\frac{t}{\sqrt{2}}\right).$$

令  $n \rightarrow \infty$ , 那么根据假设  $f_n \rightarrow f$ , 所以

$$f(t) = f^2\left(\frac{t}{\sqrt{2}}\right).$$

(b) 由递推式可知

$$f(t) = \left[f(2^{-\frac{n}{2}}t)\right]^{2^n}.$$

因为  $f \in C^2$ , 所以在原点处有二阶 Taylor 展开 (条件  $\mathbb{E}X_n = 0 \Rightarrow f'(0) = 0$ )

$$f(x) = 1 + \frac{1}{2}f''(0)x^2 + o(x^2).$$

所以

$$f(t) = \left[1 + \frac{1}{2}f''(0)2^{-n}t^2 + o(2^{-n})\right]^{2^n}.$$

令  $n \rightarrow \infty$ , 即得

$$f(t) = e^{\frac{1}{2}f''(0)t^2},$$

就是 Gauss 函数的特征函数.

(c) 一般地, 此时成立

$$Z_{m+n} = \frac{mZ_m + n\tilde{Z}_n}{m+n},$$

从而

$$f_{m+n}(t) = f_m\left(\frac{m}{m+n}t\right)f_n\left(\frac{n}{m+n}t\right).$$

对任意  $s, t \in \mathbb{R}_+$ , 令  $m, n \rightarrow \infty$  并且  $\frac{m}{n} \rightarrow \frac{s}{t}$ , 可得

$$f(s+t) = f(s)f(t).$$

由  $|f| \leq 1$  以及连续性, 根据 Cauchy 方程的性质, 必有  $f(t) = e^{-kt}, t \geq 0, (k \geq 0)$ . 同理  $t \leq 0$  时有  $f(t) = e^{k't} (k' \geq 0)$ .

若加上对称性假设  $f(t) = f(-t)$ , 则有  $k = k'$ , 所以  $f(t) = e^{-k|t|}$ .  $k = 0$  时, 这是单点分布的特征函数;  $k > 0$  时, 这是 Cauchy 分布的特征函数.

(d) 用 (c) 中的类似推导可以得到此时  $f(t)$  满足的函数方程

$$f(t) = f(p^\alpha t)f((1-p)^\alpha t), \quad \forall t \in \mathbb{R}, p \in (0, 1).$$

$t \geq 0$  时, 换元  $t = s^\alpha, g(s) = f(t)$ , 可得

$$g(s) = g(ps)g((1-p)s),$$

所以由 Cauchy 方程的性质,  $g(s) = e^{-ks}, \forall s \geq 0$ . 同理可对  $t < 0$  讨论, 再由对称性  $f(t) = f(-t)$  得

$$f(t) = \exp(-k|t|^{\alpha-1}), \forall t \in \mathbb{R}.$$

由 Durrett 的例 3.3.23 (Durrett, R. Probability: Theory and Examples, 5th ed., pp. 138–139) 即得  $\alpha$  的范围为

$$0 < \alpha^{-1} \leq 2 \Leftrightarrow \alpha \geq \frac{1}{2}.$$

4. (单边 Laplace 引理) 首先不妨设  $h(0) = 0$ , 否则考虑  $h(x) - h(0)$ . 根据题意,  $h(x)$  在  $x = 0$  处可微, 所以对任意  $\varepsilon > 0$ , 存在  $\delta > 0$  使得  $0 < x < \delta$  时,

$$|h(x) - h'(0)x| < \varepsilon x.$$

我们将积分分为  $(0, \delta)$  和  $(\delta, \infty)$  两段.

$$I(t) = \left( \int_0^\delta + \int_\delta^\infty \right) e^{-th(x)} dx = I_1 + I_2.$$

首先,

$$\frac{1 - e^{-\delta(-h'(0)+\varepsilon)t}}{(-h'(0)+\varepsilon)t} < \int_0^\delta e^{t(h'(0)-\varepsilon)x} dx < I_1 < \int_0^\delta e^{t(h'(0)+\varepsilon)x} dx = \frac{1 - e^{-\delta(-h'(0)-\varepsilon)t}}{(-h'(0)-\varepsilon)t}.$$

不妨假设  $\varepsilon < |h'(0)|$ , 那么上式取极限  $t \rightarrow \infty$  可得

$$\frac{1}{-h'(0)+\varepsilon} \leq \liminf_{t \rightarrow \infty} tI_1 \leq \limsup_{t \rightarrow \infty} tI_1 \leq \frac{1}{-h'(0)-\varepsilon}$$

然后,

$$I_2 \leq e^{(t-1)\eta} \int_\delta^\infty e^{h(x)} dx = O(e^{\eta t}),$$

其中  $\eta = \sup_{x>\delta} h(x) < 0$ . 因为  $e^{\eta t} \ll t^{-1}$ , 所以  $t \rightarrow \infty$  时将两式相加可得

$$\frac{1}{-h'(0)+\varepsilon} \leq \liminf_{t \rightarrow \infty} tI(t) \leq \limsup_{t \rightarrow \infty} tI(t) \leq \frac{1}{-h'(0)-\varepsilon}.$$

由  $\varepsilon$  的任意性即得结论.

## 5 Lecture 6

3. 考虑 Q 过程 (转移速率矩阵  $\mathbf{Q} = ((q_{ij}))$ ), 则有

$$\begin{aligned} h_i(t + \Delta t) &= \mathbb{E}(f(X_{t+\Delta t}); X_0 = i) \\ &= \mathbb{E}[\mathbb{E}(f(X_{t+\Delta t}) | X_{\Delta t}); X_0 = i] \\ &= \sum_j p_{ij}(\Delta t) h_j(t). \end{aligned} \quad (\text{根据独立增量性})$$

所以有

$$\begin{aligned} \frac{h_i(t + \Delta t) - h_i(t)}{\Delta t} &= \frac{p_{ii}(\Delta t) - 1}{\Delta t} h_i(t) + \sum_{j \neq i} \frac{p_{ij}(\Delta t)}{\Delta t} h_j(t) \\ &\rightarrow q_{ii} h_i(t) + \sum_{j \neq i} q_{ij} h_j(t), \quad \Delta t \rightarrow 0. \end{aligned}$$

若将  $\{h_i(t)\}$  写作一个向量  $\mathbf{h}(t)$ , 那么它满足的方程为

$$\mathbf{h}'(t) = \mathbf{Q}\mathbf{h}(t),$$

称为后向方程. 注意我们在推导过程中先走  $\Delta t$  的时间步再走  $t$  的时间步, 即时间增量是向后的. 另一种理解方式为: 概率转移矩阵  $\mathbf{P}(t)$  满足

$$\mathbf{P}(t) = e^{t\mathbf{Q}} \Rightarrow \mathbf{P}' = \mathbf{Q}\mathbf{P} = \mathbf{P}\mathbf{Q},$$

所以

$$\mathbf{h}(t) = \mathbf{P}\mathbf{f} \Rightarrow \mathbf{h}'(t) = \mathbf{Q}\mathbf{P}\mathbf{f} = \mathbf{Q}\mathbf{h}.$$

5. (1) 当转移速率  $\lambda(t)$  不是常数时, 记  $p_m(t)$  为  $t$  时刻的分布, 则由 Poisson 过程条件 (4),

$$p_m(t+h) = p_m(t)(1 - \lambda(t)h) + p_{m-1}(t)\lambda(t)h + o(h).$$

移项并取微分得到

$$p'_m(t) = -\lambda(t)p_m(t) + \lambda(t)p_{m-1}(t),$$

以及初值条件

$$p_m(0) = \delta_{m0} = \begin{cases} 1, & m = 0, \\ 0, & m \geq 1. \end{cases}$$

记  $\Lambda(t) = \int_0^t \lambda(s)ds$ , 则经过变换, 可得

$$[e^{\Lambda(t)}p_m(t)]' = \lambda(t)e^{\Lambda(t)}p_{m-1}(t),$$

所以

$$p_m(t) = e^{-\Lambda(t)} \int_0^t \lambda(s)e^{\Lambda(s)}p_{m-1}(s)ds, \quad m \geq 1.$$

$m = 0$  时有解 ( $p_{-1}(t) \equiv 0$ )

$$p_0(t) = e^{-\Lambda(t)},$$

代入递推可得

$$p_m(t) = e^{-\Lambda(t)} \int_0^t \lambda(s) \frac{(\Lambda(s))^{m-1}}{(m-1)!} ds = e^{-\Lambda(t)} \frac{(\Lambda(t))^m}{m!}, \quad \forall m,$$

即  $X_t \sim \mathcal{D}(\Lambda(t))$ . 也可通过对时间  $t$  进行重参数化  $s = \Lambda(t)$  来解释.

(2) 记  $T_t$  为所求的等待时. 由独立增量性, 从  $t$  时刻开始的算起的轨道  $\{X_{t+s} - X_t\}_{s \geq 0}$  和以  $\lambda(t+s)$  为转移速率的过程同分布.  $T_t > s$  的概率就是过程  $\{X_{t+s} - X_t\}$  时刻该过程仍然在 0 位置的概率, 即上面小题中的  $p_m(0)$ , 故直接代入可得

$$\mathbb{P}(T_t > s) = \exp\left(-\int_0^s \lambda(t+s)ds\right).$$

## 6 Lecture 7

2. 因为  $Q(\sigma \rightarrow \sigma') = Q(\sigma' \rightarrow \sigma)$ , 所以为了验证细致平衡条件, 只需验证

$$\pi(\sigma)A(\sigma \rightarrow \sigma') = \pi(\sigma')A(\sigma' \rightarrow \sigma),$$

对于所有只有一个位点不同的  $\sigma, \sigma'$ .

若采用 Metropolis 算法, 左边等于

$$\frac{1}{Z} e^{-\beta H(\sigma)} \min\{1, e^{-\beta(H(\sigma')-H(\sigma))}\} = \frac{1}{Z} \min\{e^{-\beta H(\sigma)}, e^{-\beta H(\sigma')}\},$$

由对称性, 右边显然也等于这个值, 所以结论成立.

若采用 Glauber 算法, 左边等于

$$\frac{1}{Z} e^{-\beta H(\sigma)} \frac{1}{1 + e^{\beta(H(\sigma')-H(\sigma))}} = \frac{1}{Z} \frac{1}{e^{\beta H(\sigma)} + e^{\beta H(\sigma')}},$$

由对称性, 右边显然也等于这个值, 所以结论成立.

## 7 Lecture 9

解决此题时我们需要考虑到  $V(x)$  极小点处可能存在的不同的阶数. 记  $V(x)$  全局极小点的集合为  $M$ . 假设  $M$  有限且  $V(x)$  光滑, 且不妨设  $\min V(x) = 0$ , 那么在其中一点  $x_i \in M$  附近  $V(x)$  的 Taylor 展开必定为

$$V(x) = \frac{V^{(2k)}(x_i)}{(2k)!} (x - x_i)^{2k} + O((x - x_i)^{2k+1}),$$

这是因为极小值点处最低阶的一个非零导数不可能为奇数阶. 在上述  $x_i$  的一个邻域内, 可以仿照 Laplace 渐近公式的证法证明

$$\int_{x_i-\varepsilon}^{x_i+\varepsilon} e^{-\beta V(x)} dx = [C_k + o(1)] (\beta V^{(2k)}(x_i))^{-1/2k}, \quad \beta \rightarrow \infty,$$

其中  $C_k$  是由  $k$  决定的常数.

考虑  $M$  中所有点的  $\varepsilon$  邻域, 其中  $\varepsilon$  取得充分小使得它们两两不交, 则  $e^{-\beta V(x)}$  在这些邻域之并以外的积分指数下降; 在  $x_i$  点, 若阶数为  $k_i$ , 那么  $\int_{B_\varepsilon(x_i)} e^{-\beta V(x)}$  的衰减阶数为  $O(\beta^{-1/2k_i})$ , 所以那些最大的  $k_i$  附近的那些概率是主导项. 记这些点组成的集合为  $M^* \subset M, k^* = \max_i k_i$ , 用渐近展开公式可以决定这些主导项之间的比例关系, 再归一化得到

$$\begin{aligned} \Pi_\beta \left( \bigcup_{x \in M^*} B_\varepsilon(x) \right) &\rightarrow 1, \\ \Pi_\beta(B_\varepsilon(x_i)) &\rightarrow \frac{[V^{(2k^*)}(x_i)]^{-1/2k^*}}{\sum_{x \in M^*} [V^{(2k^*)}(x)]^{-1/2k^*}}. \end{aligned}$$

由  $\varepsilon$  的任意性,  $\Pi_\beta$  的极限为

$$\frac{\sum_{x \in M^*} [V^{(2k^*)}(x)]^{-1/2k^*} \delta_x}{\sum_{x \in M^*} [V^{(2k^*)}(x)]^{-1/2k^*}}.$$

## 8 Lecture 10

4. Arcsine Law 有两种形式, 分别关于最后一个零点和大于 0 的时长. 以下两个定理是来自 Durrett 的 Thm. 4.9.5 和 Thm. 4.9.6 (pp. 261–267), 请参考那里获取证明。

**Theorem** (关于最后一个零点的反正弦律). 设  $\{S_n\}$  是  $\mathbb{Z}$  上的对称随机游走, 令

$$L_{2n} = \sup\{m \leq 2n : S_m = 0\},$$

则

$$\lim_{n \rightarrow \infty} \mathbb{P} \left( a \leq \frac{L_{2n}}{2n} \leq b \right) = \int_a^b \frac{1}{\pi \sqrt{x(1-x)}} dx = \frac{2}{\pi} (\arcsin \sqrt{b} - \arcsin \sqrt{a}).$$

**Theorem** (关于大于 0 时长的反正弦律). 设  $\{S_n\}$  是  $\mathbb{Z}$  上的对称随机游走, 令  $\pi_{2n}$  为  $[0, 2n]$  上  $x$  轴上方的线段  $(k-1, S_{k-1}) \rightarrow (k, S_k)$  的数目, 并且令  $u_m = \mathbb{P}(S_m = 0)$ , 则

$$\mathbb{P}(\pi_{2n} = 2k) = u_{2k}u_{2n-2k},$$

从而

$$\lim_{n \rightarrow \infty} \mathbb{P}\left(a \leq \frac{\pi_{2n}}{2n} \leq b\right) = \int_a^b \frac{1}{\pi\sqrt{x(1-x)}} dx = \frac{2}{\pi}(\arcsin \sqrt{b} - \arcsin \sqrt{a}).$$

还有结论  $\pi_{2n} \stackrel{d}{=} L_{2n}$ .

## 9 Lecture 12

1. 根据上一讲的等价定义, 为说明某个随机过程是 **Brownian motion**, 只需说明:

- (i) 它是 **Gauss** 过程.
- (ii) 均值  $m(t) = 0$ , 协方差  $K(s, t) = s \wedge t$ .
- (iii) 轨道 a.s. 连续.

对于本题的三个过程, 前两点都是容易验证的, 但很多人忘了验证第三点.

$X_t = tW_{1/t}$  在  $t = 0$  处的轨道连续性是不那么平凡的, 需要说明

$$\lim_{t \rightarrow \infty} \frac{W_t}{t} = 0, \quad \text{a.s.}$$

用下述关于轨道最大值点的结论.

$$\mathbb{P}\left(\max_{[0, t]} W_t \geq a\right) = \mathbb{P}(\tau_a \leq t) = 2\mathbb{P}(W_t > a), \quad \forall a > 0.$$

用这个更强的上界限制  $W_t/t$  的取值.

$$\begin{aligned} \mathbb{P}\left(\sup_{t \in [T, 2T]} \frac{|W_t|}{t} \geq \varepsilon\right) &\leq \mathbb{P}\left(\max_{t \in [0, 2T]} |W_t| \geq 2\varepsilon T\right) \\ &\leq 4\mathbb{P}(W_{2T} > 2\varepsilon T) \\ &= C \frac{e^{-\varepsilon^2 T}}{\sqrt{T}}. \end{aligned}$$

上式对  $T_n = 2^n T$  求和后收敛, 由 **Borel-Cantelli** 引理, a.s. 只出现有限次, 所以 a.s. 成立

$$\lim_{t \rightarrow \infty} \frac{|W_t|}{t} \leq \varepsilon.$$

因此  $W_t/t \rightarrow 0$ , a.s.. 事实上有更强的结论 (**Law of the Iterated Logarithm**):

$$\limsup_{t \rightarrow \infty} \frac{W_t}{\sqrt{2t \log \log t}} = 1, \quad \text{a.s.}$$

2. 序列  $Y_n(t, \omega)$  不是一个 IID 序列的部分和, 因为  $Y_{n+1}$  的前  $2^n$  项并非来自  $Y_n$ , 而只是同分布. 但还是可以通过 **Borel-Cantelli** 引理证明其 a.s. 收敛性.

$$\begin{aligned} \mathbb{P}(|Y_n(t, \omega) - t| \geq \varepsilon) &\leq \varepsilon^{-2} \text{Var}(Y_n(t, \omega)) = \frac{t^2}{2^n \varepsilon^2}, \\ &\Rightarrow \sum_n \mathbb{P}(|Y_n(t, \omega) - t| \geq \varepsilon) < \infty, \\ &\Rightarrow \mathbb{P}(\{|Y_n(t, \omega) - t| \geq \varepsilon\} \text{ i.o.}) = 0, \\ &\Rightarrow Y_n(t, \omega) \rightarrow t, \text{ a.s.} \end{aligned}$$

$Y_n$  似乎并不是单调的, 因为  $(a+b)^2 \leq a^2 + b^2$  并不总是对任意  $a, b \in \mathbb{R}$  成立.

## 10 Lecture 13

1. 右端点积分可直接用二次变差的性质推出. 中点积分会遇到形如

$$\sum_{j=0}^{N-1} (W_{t_{j+1/2}} - W_{t_j})^2$$

的项, 可用证明二次变差等于  $T/2$  的相同方法证明其极限为  $T/4$ .

2. (a) 考虑函数  $f(x, u) = \varphi(x - u) = \exp\left(\frac{1}{2}(x - u)^2\right)$ , 它是两变量的解析函数. 在  $(x, 0)$  点对  $u$  进行 Taylor 展开, 得到

$$f(x, u) = \sum_{n=0}^{\infty} \frac{u^n}{n!} \frac{\partial^n f}{\partial u^n} \Big|_{(x,0)}.$$

另一方面, 根据  $f(x, u) = \varphi(x - u)$  的形式可知,

$$\frac{\partial^n f}{\partial u^n} \Big|_{(x,0)} = (-1)^n \frac{\partial^n f}{\partial x^n} \Big|_{(x,0)} = (-1)^n \frac{\partial^n (e^{-x^2/2})}{\partial x^n} \Big|_{(x,0)} = e^{-x^2/2} h_n(x).$$

两边乘  $e^{-x^2/2}$  即得结论.

$a > 0$  时, 作变量替换  $u \leftarrow a^{\frac{1}{2}}u, x \leftarrow a^{-\frac{1}{2}}x$ , 第二个关系式是显然的.  $a \rightarrow 0$  时,  $H_n(x, a) \rightarrow H_n(x, 0)$ , 所以取极限可以得到对  $a = 0$  也成立 (或者直接验证).

(b) (a) 中第二个式子对  $x$  求二阶导数, 得到

$$\sum_{n=0}^{\infty} \frac{u^n}{n!} \partial_x^2 H_n(x, a) = u^2 e^{ux - \frac{au^2}{2}}.$$

对  $a$  求一阶导数, 得到

$$\sum_{n=0}^{\infty} \frac{u^n}{n!} \partial_a H_n(x, a) = -\frac{u^2}{2} e^{ux - \frac{au^2}{2}}.$$

相加得到

$$\sum_{n=0}^{\infty} \frac{u^n}{n!} \left( \frac{1}{2} \partial_x^2 + \partial_a \right) H_n(x, a) = 0.$$

由于该式对任意  $u$  都成立, 所以左边级数中的每一项系数都是 0, 即第一个结论成立.

对  $x$  求一阶导数, 得到

$$\sum_{n=0}^{\infty} \frac{u^n}{n!} \partial_x H_n(x, a) = u e^{ux - \frac{au^2}{2}} = u \sum_{n=0}^{\infty} \frac{u^n}{n!} H_n(x, a).$$

对比两边对应项系数, 即得第二个结论.

(c) 对  $n$  归纳.  $n = 1$  时,  $h_1(x) = x$ , 所以

$$W_t = \int_0^t dW_{t_1} = \frac{1}{1!} t^{\frac{1}{2}} \frac{W_t}{t^{\frac{1}{2}}},$$

结论成立.

假定对  $n - 1$  成立, 则只需证明

$$\frac{1}{n!} H_n(W_t, t) = \int_0^t \frac{1}{(n-1)!} H_{n-1}(W_s, s) dW_s.$$



由 Itô 公式和前两小问的结论,

$$\begin{aligned} dH_n(W_t, t) &= \partial_x H_n(W_t, t) dW_t + \underbrace{\frac{1}{2} \partial_x^2 H_n(W_t, t) dt + \partial_a H_n(W_t, t) dt}_{(b) \text{ 结论 1}} \\ &= \partial_x H_n(W_t, t) dW_t = n H_{n-1}(W_t, t) dW_t. \end{aligned}$$

4. 根据 ODE 的熟知结论,  $(e^{tA})' = Ae^{tA} = e^{tA}A$ , 所以根据 Itô 公式,

$$d(e^{-tA} X_t) = -e^{-tA} A X_t dt + e^{-tA} dX_t = e^{-tA} (-A X_t dt + dX_t),$$

其中因为函数关于  $X_t$  线性所以二阶导为零. 代入原方程可得

$$d(e^{-tA} X_t) = e^{-tA} \sigma dW_t,$$

所以它的显式解可以写成

$$X_t = e^{tA} X_0 + \int_0^t e^{(t-s)A} \sigma dW_s.$$

假设  $\lambda(A) < 0$ , 那么上面的分布在  $t \rightarrow \infty$  时有极限, 也就是稳态分布. 它同分布于

$$\int_0^\infty e^{tA} \sigma dW_t.$$

均值显然为零, 协方差用 Itô 等距性计算.

$$\begin{aligned} \mathbb{E}_\pi(X X^T) &= \int_0^\infty (e^{tA} \sigma)(e^{tA} \sigma)^T dt \\ &= \int_0^\infty e^{tA} \sigma \sigma^T e^{tA^T} dt. \end{aligned}$$

5. 我们形式地把右端点的函数值写成

$$\sigma(X_{t+\Delta t}, t + \Delta t) = \sigma(X_t, t) + \sigma_x \Delta X_t + \sigma_t \Delta t.$$

展开右端点 SDE. 根据 Itô 公式, 把  $dW_t$  看成  $(dt)^{\frac{1}{2}}$ , 且省去所有  $\frac{3}{2}$  阶以上的项.

$$dX_t = b(X_t, t) dt + [\sigma(X_t, t) + \sigma_x dX_t] dW_t.$$

扩散项中多出的  $dX_t dW_t$  中, 只有  $\sigma(X_t, t) dW_t dW_t$  的部分非零, 所以最后剩下几项为

$$dX_t = [b(X_t, t) + \sigma \sigma_x(X_t, t)] dt + \sigma(X_t, t) dW_t.$$

## 11 Lecture 14

1. 使用 Einstein's summation. 首先根据上一章形式展开成 Itô 的 SDE.

$$dX_t = b dt + \sigma dW_t + \frac{1}{2} (\nabla \sigma \cdot dX_t) dW_t.$$

写成指标形式.

$$dX_t^j = b^j dt + \sigma^{jk} dW_t^k + \frac{1}{2} \partial_i \sigma^{jk} dX_t^i dW_t^k.$$

对于最后一项, 我们递归地展开  $dX_t^i$ , 并只保留  $(dW_t^k)^2$  的项, 得到

$$\begin{aligned} \partial_i \sigma^{jk} dX_t^i dW_t^k &= \partial_i \sigma^{jk} (b^i dt + \sigma^{il} dW_t^l) dW_t^k \\ &= \partial_i \sigma^{jk} \sigma^{ik} dt. \end{aligned}$$

然后我们就得到了 Itô 形式的 SDE, 可以由此写出前后向算子

$$\begin{aligned} dX_t^j &= b^j dt + \frac{1}{2} \partial_i \sigma^{jk} \sigma^{ik} dt + \sigma^{jk} dW_t^k \\ \mathcal{L}u &= b^j \partial_j u + \frac{1}{2} \partial_i \sigma^{jk} \sigma^{ik} \partial^i u + \frac{1}{2} \sigma^{ik} \sigma^{jk} \partial_{ij} u \\ &= b^j \partial_j u + \frac{1}{2} \sigma^{ik} \partial_i (\sigma^{jk} \partial_j u) \\ \mathcal{L}^*p &= -\partial_j (b^j p) + \frac{1}{2} \partial_j [\sigma^{jk} \partial_i (\sigma^{ik} p)] \end{aligned}$$

再写成矩阵向量形式, 得 Fokker-Planck 方程.

$$p_t = \mathcal{L}^*p = -\nabla \cdot (p\mathbf{b}) + \frac{1}{2} \nabla \cdot (\sigma \nabla \cdot (p\sigma^T)),$$

其中矩阵的散度按行求. 右端点积分的推导是类似的.

## 12 Lecture 15

每个强连续压缩半群  $S(t)$  对应到一个无界算子  $L$ , 称为它的生成元, 满足:

1.  $L$  是稠定闭算子.
2. 以  $\mathcal{D}(L)$  内的点为起点, 算子半群的轨道  $S(t)x$  连续可微, 而且满足

$$\frac{dS(t)x}{dt} = LS(t)x = S(t)Lx.$$

(a) 由  $\|S(t)\| \leq 1$  知  $\|P\| \leq 1$ , 是压缩算子. 由半群性质,  $S(t)S(t) = S(2t)$ . 令  $t \rightarrow \infty$ , 由  $S(t)$  的压缩性质, 左边算子复合可以取强极限, 得  $P^2 = P$ , 所以是投影.

(b) 由半群性质,  $S(s+t) = S(s)S(t) = S(t)S(s)$ . 令  $s \rightarrow \infty$  得到  $P = S(t)P = PS(t)$ .

由此得到  $P$  和  $L$  可交换. 此即对任意  $x \in \mathcal{D}(L)$ ,  $0 = PLx = LPx$ . 这是因为

$$0 = \frac{d}{dt}[S(t)Px] = \frac{d}{dt}[PS(t)x] = PLx,$$

从而可推出  $Px \in \mathcal{D}(L)$  且  $LPx = 0$ .

(c) 当  $x \in \mathcal{N}(L)$  时,  $Lx = 0$ , 所以根据生成元的性质,  $\frac{d}{dt}(S(t)x) = S(t)Lx = 0$ , 所以  $S(t)x \equiv x, \forall t > 0$ . 令  $t \rightarrow \infty$  可得  $Px = x$ , 故  $x \in \mathcal{R}(P)$ .

当  $x \in \mathcal{R}(P)$  时, 由  $L$  的稠定性, 用  $y \in \mathcal{D}(L)$  逼近  $x$ , 则  $P_y \rightarrow Px = x$ . 由 (b) 的额外结论,  $LP_y = 0$ . 再由  $L$  的闭性可知  $x \in \mathcal{D}(L)$  且  $Lx = 0$ , 即  $x \in \mathcal{N}(L)$ .

(d) 当  $x \in \mathcal{R}(L)$  时, 设  $x = Ly, y \in \mathcal{D}(L)$ , 那么由 (b) 的额外结论,  $Px = PLy = 0$ , 故  $x \in \mathcal{N}(P)$ .

当  $x \in \mathcal{N}(P)$  时, 假设  $x \notin \mathcal{R}(L)$ , 则由 Hahn-Banach 定理, 存在连续线性泛函  $f \in \mathcal{B}^*$ , 使得  $f|_{\overline{\mathcal{R}(L)}} = 0, \langle f, x \rangle \neq 0$ . 考察从  $x$  出发的轨道, 则  $S(t)x \rightarrow Px = 0$ , 所以  $\langle f, S(t)x \rangle \rightarrow 0$ . 任取  $y \in \mathcal{D}(L)$ , 有

$$\frac{d}{dt} \langle f, S(t)y \rangle = \frac{d}{dt} \langle f, LS(t)y \rangle = 0.$$

这说明  $\langle f, S(t)y \rangle = \langle f, S(0)y \rangle = \langle f, y \rangle$ , 对  $y \in \mathcal{D}(L)$ . 因为  $L$  稠定, 所以  $S^*(t)f = f$ , 对任意  $t > 0$ , 进而  $\langle f, S(t)x \rangle \equiv \langle f, x \rangle \neq 0$ , 矛盾!

## 13 Lecture 16

1. We notice that the variables are jointly Gaussian, so we only need to compute their mean and covariance. W.l.o.g., we let  $t_n = 0$ , and then the three variables become

$$\Delta W_n = W_{\Delta t} = \int_0^{\Delta t} dW_\tau, \Delta Z_1 = \int_0^{\Delta t} \tau dW_\tau, \Delta Z_2 = \int_0^{\Delta t} W_\tau d\tau.$$

We also recall that by the Itô integral

$$tW_t = \int_0^t W_s ds + s dW_s,$$

the three quantities are correlated, i.e.  $\Delta Z_2 = \Delta t \Delta W_n - \Delta Z_1$ . We only need to generate  $(\Delta W_n, \Delta Z_1)$ .

Obviously, their means are both zero. Their variances and covariances equal

$$\begin{aligned} \mathbb{E}(\Delta W_n)^2 &= \Delta t, \\ \mathbb{E}(\Delta Z_1)^2 &= \int_0^{\Delta t} \tau^2 d\tau = \frac{1}{3}(\Delta t)^3, \\ \mathbb{E}(\Delta W_n \Delta Z_1) &= \int_0^{\Delta t} \tau d\tau = \frac{1}{2}(\Delta t)^3. \end{aligned}$$

Therefore, we only need to generate the two-dimensional Gaussian variable subject to mean 0 and covariance matrix

$$\mathbf{A} = \begin{bmatrix} \Delta t & \frac{1}{2}(\Delta t)^2 \\ \frac{1}{2}(\Delta t)^2 & \frac{1}{3}(\Delta t)^3 \end{bmatrix}.$$

2. Consider the diffusion process

$$dX_t = b(X_t)dt + dW_t,$$

i.e. the process with *constant additive noise*. Use  $\{X_n^h\}$  to denote the numerical solution, and  $\{X_t\}$  the exact one. We are going to prove that the Euler-Maruyama scheme

$$X_{n+1}^h = X_n^h + b(X_n^h)h + \Delta W_n^h$$

is actually of order 1 strong convergence. Here the assumption on  $b$  must be very strong, and we will show them during our proof. The goal is to prove that the  $L^2$  error of the  $n$ -th step with  $nh \leq T$  is of order  $O(h^2)$ , which requires the truncation error at each step to be  $O(h^3)$ .

As is usually done in numerical ODEs, we separate the error of each step into *propagation and accumulation*.

$$X_{n+1}^h - X_{(n+1)h} = (X_{n+1}^h - \bar{X}_{n+1}) + (\bar{X}_{n+1} - X_{(n+1)h}),$$

where  $\bar{X}_{n+1}$  denotes the solution obtained by taking one forward time step from the exact solution  $X_{nh}$ .

Suppose  $b$  is Lipschitz with constant  $L$ , and then we have

$$|X_{n+1}^h - \bar{X}_{n+1}| = |(X_n^h - X_{nh}) + h(b(X_n^h) - b(X_{nh}))| \leq (1 + Lh)|X_n^h - X_{nh}|.$$

This is because we use the *same Wiener trajectory* no matter what our precision is. Next, the propagation error at the  $n$ -th step caused by discretization.

$$\begin{aligned} \bar{X}_{n+1} - X_{(n+1)h} &= \int_{nh}^{(n+1)h} [b(X_t) - b(X_{nh})] dt \\ &= \int_{nh}^{(n+1)h} dt \int_{nh}^t b'(X_s) [b(X_s) ds + dW_s] + b''(X_s) ds \\ &\triangleq Y_n + Z_n, \end{aligned}$$

where we used Itô's formula, and denoted by

$$Y_n := \int_{nh}^{(n+1)h} dt \int_{nh}^t (bb' + b'')|_{X_s} ds,$$

$$Z_n := \int_{nh}^{(n+1)h} dt \int_{nh}^t b'(X_s) dW_s.$$

By estimating their orders we find that  $\mathbb{E}(Y_n^2) = O(h^4)$ , and that  $\mathbb{E}Z_n^2 = O(h^3)$ .

Take the conditional expectation with respect to the  $n$ -th step.

$$\begin{aligned} & \mathbb{E}[(X_{n+1}^h - X_{(n+1)h})^2 | X_n^h, X_{nh}] = \mathbb{E}[(X_{n+1}^h - \bar{X}_{n+1} + Y_n + Z_n)^2 | X_n^h, X_{nh}] \\ & \leq \mathbb{E}[(1 + \varepsilon)(X_{n+1}^h - \bar{X}_{n+1} + Z_n)^2 + (1 + \varepsilon^{-1})Y_n^2 | X_n^h, X_{nh}] \\ & \leq \mathbb{E}[(1 + \varepsilon)(X_{n+1}^h - \bar{X}_{n+1} + Z_n)^2 | X_n^h, X_{nh}] + (1 + \varepsilon^{-1})C_1 h^4. \end{aligned}$$

Now comes the critical part. Notice that

$$X_{n+1}^h - \bar{X}_{n+1} = [b(X_n^h) - b(X_{nh})]h$$

is determined by  $X_n^h$  and  $X_{nh}$ , which is considered constant in the conditional expectation. Meanwhile,  $Z_n$  is an Itô integral over  $W_t$  on  $(nh, (n+1)h]$ , so it has conditional expectation 0 given  $X_{nh}, X_n^h$  because of the Markovian property. Therefore, we can break down the first quadratic term  $(X_{n+1}^h - \bar{X}_{n+1} + Z_n)^2$  and eliminate the crossing term in between. The overall estimate then becomes

$$\begin{aligned} & \mathbb{E}[(X_{n+1}^h - X_{(n+1)h})^2 | X_n^h, X_{nh}] \\ & \leq (1 + \varepsilon)(X_{n+1}^h - \bar{X}_{n+1})^2 + (1 + \varepsilon)\mathbb{E}[Z_n^2 | X_n^h, X_{nh}] + (1 + \varepsilon^{-1})C_1 h^4 \\ & \leq \underbrace{(1 + \varepsilon)(1 + Lh)|X_n^h - X_{nh}|^2}_{\text{propagation}} + \underbrace{(1 + \varepsilon)C_2 h^3 + (1 + \varepsilon)^{-1}C_1 h^4}_{\text{truncation}}. \end{aligned}$$

Choosing  $\varepsilon = h$  makes the propagation factor

$$(1 + h)(1 + Lh) = 1 + O(h) = O(1),$$

and truncation error

$$C_2(1 + h)h^3 + C_1 \left(1 + \frac{1}{h}\right)h^4 = O(h^3),$$

so the final estimate of  $\mathbb{E}|X_{nh} - X_n^h|^2$  is  $O(h^2)$  as desired.

## 14 Lecture 18

1. Discretizing the problem into finite case, we get

$$\mathbb{E} \exp\left(i \sum_j \zeta(t_j) \Delta W_{t_j}\right) = \exp\left(\frac{1}{2} \sum_j (t_j - t_{j-1}) \zeta^2(t_j)\right)$$

since  $W_t$  has independent increments and  $\mathbb{E}(\Delta W_{t_j})^2 = t_j - t_{j-1}$ . Taking the formal limit  $\max_j \Delta t_j \rightarrow 0$  gives us the desired result.