

Day 6. Large Deviations - Theory & Practice.

Large Deviations in a Mitchell.

大偏差理论主要研究独立同分布的随机变量的序列的样本均值的大偏差的渐近理论。我们考虑一个在时间上的序列：一个城市每天以 μ 的概率降雨。现在进行了 T 天的观察 ($T \rightarrow \infty$)。问观察到 T 天内下雨的次数 $f = \frac{f_T}{T}$ 的分布是什么样子的？(我们可以将 T 称为“尺度”，而将 f 称为“强度”)。 f 的分布收敛于 μ 的分布：

$P(f_T) = C_T \cdot \mu^f (1-\mu)^{T-f}$ 。这里 C_T 是归一化常数。所以根据中心极限定理，当 T 相当大时，这一分布可由正态近似描述：

$p(f, T) = \sqrt{\frac{T}{2\pi T(1-\mu)}} \exp(-T \frac{(f-\mu)^2}{2\mu(1-\mu)})$ 。数值计算表明，在 $f \approx \mu$ 处这一近似是相当好的。但在 f 远离 μ 的地方，这样的逼近就不适用了。我们希望对这些稀有事件有一个更好的逼近。

例如，我们介绍一个例子，一个简单系统的逼近是 $\lim_{T \rightarrow \infty} \frac{1}{T} \ln p(f, T) = -I(f)$ 。当 $T \rightarrow \infty$ 时， $p(f, T) \approx \exp(-T I(f))$ 。对于 μ 分布， $I(\mu)$ 称为 KL Divergence。

即 $I(\mu) = f \ln \frac{\mu}{1-\mu} + (1-f) \ln \frac{1-\mu}{\mu}$ 。从 $p(f, T) = \exp(-T I(f))$ 这样的形式，我们可以看出事件发生的频率随着系统尺度的增加而增大的关系，都被称为大偏差原理。 $I(f)$ 称为 rate function。

一般说来，rate function 有以下性质：1. 非负，即 $f = \mu$ 处 $I(f) = 0$ 。2. 对称性原理，在 $f < \mu$ 处通常与 $f > \mu$ 处对称 (根据中心极限定理)。而在 $f \rightarrow \mu$ 处， $I(f)$ 得到好的逼近。

从表面上看，对称性原理就是放大那些原来稀有的事件。所以你可以认为对称性原理是中心极限定理的推广。例如 $I(f)$ 的渐近展开 (泰勒展开)，则它收敛回到中心极限定理的 $I(f) = \frac{(f-\mu)^2}{2\sigma^2}$ 。

其中 $\sigma^2 = \lim_{T \rightarrow \infty} T \phi(f)$ 。我们希望给出 $I(f)$ 的具体形式。这需要 cumulant generating function。 $\psi(q; T) = \ln(\exp(T \phi(q))) = T \ln \phi(q)$ 。不妨以 μ 为例，这很容易得到 $I(\mu)$ 的表达式。所以，我们研究 scaled CGF。

$\psi(q) = \lim_{T \rightarrow \infty} \frac{1}{T} \ln \langle \exp(T \phi(q)) \rangle$ 。不难证明 scaled CGF 可得随机变量的一些信息。eg. $\psi'(q) = \phi$ 。 $\psi''(q) = \sigma^2$ 。

Gärtner-Ellis Theorem 指出， $I(f)$ 与 $\psi(q)$ 的 Legendre 变换有关： $I(f) = \sup_q [f q - \psi(q)]$ 。这有一个简单的证明。

$\psi(q) = \lim_{T \rightarrow \infty} \frac{1}{T} \ln \int_{-\infty}^{\infty} df \cdot p(f, T) \exp(T q f)$
 $= \lim_{T \rightarrow \infty} \frac{1}{T} \ln \int_{-\infty}^{\infty} df \cdot \exp[-T(I(f) - q f)] = \sup_f [q f - I(f)]$
 (当 $q = \psi'(q)$ 时， $I(f)$ 有极值)

Currents, Traffic and Other Observables.

在这里，我们介绍几个主要的可观测测量： $w(x)$, $q(x)$, $st(x)$ 。它们都与从某种信号而来的大偏差原理研究它们有联系。这些原理，我们介绍给读者。现在我们的研究可观测测量：一类称为 static observables。 $I(f)$ 的 SO 可以表示为：

$A(x) = \sum_i q_i x_i$ 。其中 T_i 是粒子位置的时间。 $q_i(x) = \int_{-T_i}^{T_i} dt \cdot S_{q_i}(x)$ 。被称为“流”。

另一类称为 Dynamic observables。它与系统一起随时间演化。即 $J(x) = \sum_{i=1}^N \ln \frac{p_i(x)}{p_i(x)}$ 。 $\ln \frac{p_i(x)}{p_i(x)}$ 。

与 $\ln \frac{p_i(x)}{p_i(x)}$ 的这样的可观测测量它们的时间反演是不变的。典型的例子如热力学熵： $(d_{xx} = k_B \ln \frac{k_{xx}}{k_{xx}})$ ，或整个系统的熵 T_B 。

$(d_{xx} = k_B \ln [\frac{k_{xx} p_i}{k_{xx} p_i}])$

在 各个部分保持的前提下, 可以有 $\tau(A) = \beta \text{Lap } \beta + \tau(A)$. 从而我们有: $\text{Lap} = \frac{\partial^2 \psi}{\partial q \partial \beta} \Big|_{q=0, \beta=0}$. 利用上面的对称性, 我们有:

$$\frac{\partial^2 \psi}{\partial q \partial \beta} \Big|_{q, \beta} = \frac{\partial^2 \psi}{\partial q \partial \beta} \Big|_{-q, -\beta/\tau(A)}.$$

$$= \frac{1}{\tau(A)} \frac{\partial^2 \psi}{\partial q \partial \beta} \Big|_{\tilde{q} = -q - \beta/\tau(A)} - \frac{\partial^2 \psi}{\partial q \partial \beta} \Big|_{-q, -\beta/\tau(A)}.$$

取 $q=0$, 我们得到了一个“路上的”微分方程: $\text{Lap} = \frac{1}{2\beta} \Big|_{q=0} \frac{\partial^2 \psi}{\partial q \partial \beta} \Big|_{q, \beta=0} = \beta \alpha$.

→ Tiltting.

例如像以前, 一个 Markov 链的 Scaled CGF 有非常重要的信息. 但很多时候, Scaled CGF 并不直接够用. 此时我们考虑将一种称作 Tiltting 的根下. 给定一个生成函数:

$\phi_x^{(1)}(q, t) = \left\{ \exp(q \cdot T, j) \mid x_t = x \right\} = \int p_x \cdot p_x \cdot \sum_{k_{x,t-1}} \exp(q \cdot j_{k,t-1})$ 原始的 CGF. $\phi_x^{(1)}(q, t) = \sum_x \phi_x^{(1)}(q, t)$. 我们在此展开, 有:

$$\phi_x^{(1)}(q, t) = \int p_x \cdot \sum_{k_{x,t-1}} \exp(q \cdot x_{t-1}^{out} \cdot d_{x,t-1}) \cdot k_{x,t-1} \cdot \exp(-k_{x,t-1}^{out} \cdot (t-t_{n-1})) \cdots \exp(-k_{x,0}^{out} \cdot (t-t_0)) \cdot p_{x,0}(t_0).$$

$$= \int 0 \cdot \sum_{k_{x,t-1}} \exp(-k_{x,t-1}^{out} \cdot (t-t_{n-1})) \cdot (k_{x,t-1} \cdot \exp(q \cdot d_{x,t-1})) \cdots (k_{x,0} \cdot \exp(q \cdot d_{x,0})) \exp(-k_{x,0}^{out} \cdot (t-t_0)) \cdot p_{x,0}(t_0).$$

所以, 由此可得, $\phi_x^{(1)}(q, t)$ 可以拆成或一个路径概率的积分. x 是沿这个路径中一个状态转移给出的:

$\frac{d}{dt} \phi_x^{(1)}(q, t) = \sum_{x'} L_{xx'}(q) \phi_{x'}^{(1)}(q, t)$ 其中 $L_{xx'}$ 为生成函数生成 $L_{xx}(q) = \int \frac{k_{xx} \exp(q \cdot d_{xx})}{-k_{xx}^{out} \cdot x} \cdot x dx$. 显然, L_{xx} 并不一定满足 $L_{xx}(q) = 0$. 即使 $\phi_x^{(1)}(q, t)$ 并非归一化的.

在 L_{xx} 不变的情况下, 生成函数的解为: $\phi_x^{(1)}(q, t) = \sum_{x'} \left[\exp((t-t_0) \cdot L(q)) \right]_{xx'} p_{x'}(t_0)$. 从而 $\phi_x^{(1)}(q, t)$ 的演化与初始条件 L_{xx} 的最大本征值控制. 从而我们得到:

$\phi_x^{(1)}(q, t) = \exp((t-t_0) \cdot \lambda_{\max}(q)) = \psi(t, q) = \lambda_{\max}(q)$. 从而, 上面方程解的生成函数或本征值, 就可以计算 $\psi(t, q)$. 对于状态为 x 的增量, 我们还可以通过 L_{xx} 直接对初始条件.

而在生成函数中, 还有互信息的计算. 记 L 的本征值为 $\det(L(q) - \lambda I) = \sum_{\lambda} a_{\lambda}(q) \lambda^n = 0$. 由于对于 $q=0$ 时生成函数的 L 回到初始条件的解, 所以, 必然有 $\lambda_{\max}(q=0) = 0$.

有假设, $g_{\lambda}(q) = \sum_{\lambda} a_{\lambda}(q) \cdot \lambda^q = 0$. 它对于所有 q 恒成立. 从而有:

$$\begin{cases} \frac{d}{dq} g_{\lambda}(q, q) = \frac{\partial g}{\partial \lambda} \cdot \frac{\partial \lambda}{\partial q} + \frac{\partial g}{\partial q} = 0 \\ \frac{\partial g}{\partial \lambda} \cdot g_{\lambda}(q, q) = \frac{\partial g}{\partial \lambda} \cdot \left(\frac{\partial g}{\partial \lambda} \right) + \frac{\partial g}{\partial \lambda} \cdot \frac{\partial g}{\partial \lambda} + \frac{\partial g}{\partial \lambda} \cdot \frac{\partial g}{\partial \lambda} + \frac{\partial g}{\partial \lambda} = 0. \end{cases}$$

利用它们, 我们得到生成函数变量的一阶 = 阶信息.

另外个以记是使用以值来计算. $\lambda_{\max}(q)$. 定义 $\tilde{x}_{x,t} = \sum_{x'} S_{xx'} + \alpha + L_{xx}$. α 与 α 作用的结果. 从而 $\tilde{x}_{x,t}$ 没有关联. 则 $\tilde{x}_{x,t}$ 的最大本征值为 $\text{tr}(\alpha + \lambda_{\max}(q)) = \tilde{\lambda}_{\max}(q)$.

将 α 作用在生成函数的变量 $\phi_x^{(1)}$ 上. 从而, 对于很大的 n , 我们有: $\tilde{x}^n \cdot \phi^{(1)} \sim (\tilde{\lambda}_{\max})^n \cdot \phi_{\max}$.

→ Example: Michaelis-Menten Reaction Scheme.

我们考虑一个催化反应的催化速度是恒定的. $A + E \xrightleftharpoons[k_r]{k_f} E \cdot A \xrightleftharpoons[k_{-1}]{k_1} B + E$. E 是酶, $E \cdot A$ 是反应物与酶的复合物. 这是最简单的情况, 每个反应物, 所有反应度的不变, 且酶有一个.

这跟导数 $\frac{d}{dt} \ln \frac{P_{n+1}}{P_n} = \exp \left(\frac{1}{P_n} (-q + \mu + \mu_n) \right) = \exp(-\mu_n \Delta t)$. 因为一个分子与一个A分子之间的碰撞。为了写出出生率。我们设定 $\begin{cases} k_1^+ = w_1 \exp((\mu_1 - \delta)/2\Delta t) > k_1^- = w_1 \exp(\delta^2/2\Delta t) \\ k_2^+ = w_2 \exp(-\delta^2/2\Delta t) > k_2^- = w_2 \exp((\mu_2 + \delta)/2\Delta t) \end{cases}$

单位速率 = 反应速率 μ . 且 $w_2 \ll w_1$. 我们用两个变量描述这个系统。一个从当前酶有没有被结合的0/1变量。另一个是反应开始以来。生成的B分子数 n . (所以 n 可以变大). 系统方程为:

记酶被结合的方程 $P = P_n \cdot P_{n+1}$. 从而有 $\frac{dP}{dt} = \frac{d}{dn} \left(k_1^+ P_n + k_2^- P_{n+1} - (k_1^- + w_2) P_n \right) \Rightarrow \frac{dP}{dt} = (k_1^+ + k_2^-) \cdot (1-P) - (k_1^- + w_2) P$

同时出生率 $P_{n+1} = \left(1 + \frac{k_1^+ + k_2^-}{k_1^- + k_2^-} \right)^{-1} \approx \frac{\exp(\frac{1}{2}(\mu_1 - \delta))}{1 + \exp(\frac{1}{2}(\mu_1 - \delta))}$ 且 μ_1 为酶的出生率: $\langle \dot{n} \rangle = k_1^+ P_{n+1} - k_2^- P_{n+1} \rightarrow \frac{P_{n+1} - P_{n+1}}{P_{n+1} - P_{n+1}}$ 的差分为 k_2^- .

$\frac{dP_n}{dt} = k_1^+ P_n P_{n+1} + k_2^- P_{n+1} - (k_1^- + k_2^-) P_n$

如果我们用大偏差理论。首先在 CGF. 我们对于出生与酶结合的0/1变量条件取得条件CGF. 具体而言, 取 $\phi(q, t) = \sum_{n=-\infty}^{\infty} \exp(g(n, \Delta t)) \cdot P_{n,n(t)}$.

我们可以把这两个部分一个具有两个不同的新current. 从而将 CGF 中的均值路径展开。但这是直接从 Master Eq. 下可以知道.

$\frac{d \left(\sum \exp(q(n, \Delta t)) \cdot P_n \right)}{dt} = k_1^+ \sum \left(\exp(q(n+1/2)) \exp(q/2) P_n \right) + k_2^- \sum \left(\exp(q(n-1/2)) \exp(q/2) P_n \right)$. 那么方程内部, 我们可以给出 $\phi(q, t)$ 的演化:

$\frac{d \phi(q)}{dt} = 2 \sin \left(\frac{\phi}{2} \right)$. $\delta_{12} = \begin{pmatrix} -(k_1^+ + k_2^-) & \delta^2 k_1^- + 2 k_2^+ \\ 2 k_1^+ + 2 k_2^- & -(k_1^+ + k_2^-) \end{pmatrix}$. $\phi = \exp(q/2)$. 一步给出 scaled CGF, 从而得到 L 的本征值. 不被改动的量 $\lambda^2 = \frac{k_1^+ k_2^-}{k_1^- k_2^+}$ (或 $q \rightarrow q' = \frac{\phi}{\delta t} - q$).

上式的特征值不变. 下式 n 的 CGF:

$\phi^{(n)}(q, t) = \sum \exp(qn) \cdot [P_{0,n(t)} + P_{1,n(t)}] = \sum \exp(qn) \cdot P_{n,t} = \phi(q) + \exp(-q/2) \phi(q) = \exp(L \max(q))$. 定义 $n = N/t$. 那么 $\phi(q) = \lambda \max(q)$. 并且有 $\lambda \max(q) = \lambda \max \left(\frac{\phi}{k_1^-} - q \right)$.

利用 $\lambda \max(q)$ 的近似函数 $\lambda \max(q) = \int \frac{\sqrt{k_1^+ k_2^-} \cdot \exp(q/2)}{\sqrt{k_1^- k_2^+} \cdot \exp(q/2)} \cdot q \cdot t \cdot \omega$. 你可以将所有的统计量, 例如 $\langle n \rangle = d \lambda \max / dq |_{q=0}$ 与 δt 无关. $J(\lambda) = 2 \sin \left(\frac{J}{\sqrt{k_1^- k_2^+}} \right)$.

→ Example 2: Fluctuation Relations in a model of kinesin.

→ Cloning.

估计并模拟一个过程的轨迹是困难的. 但研究大偏差于任何时间 t — 不确定性. 你会不断延长采样时间, 以期让这些稀有事件出现. 但根据大偏差, 这些稀有事件的概率会随 t 的上升而指数级地减少. 从而你永远不会得到这样的稀有事件. 所以从另一条路走, 估计并模拟的生成 L 的每次平均值并非非常. 所以可以尝试直接模拟 $P(q, t)$ 满足的“微扰主方程”. 对于概率密度 P 的方程, 模拟方程的必需生成 P 以所必需等待时间. 单位以 P 为间隔而计算. 但 $\phi(q, t)$ 满足的主方程的概率密度并不守恒. 所以如何对 P 进行模拟是个问题. 一种用了解决问题的最好称为 cloning. 其做法是重复以下操作 — 我们同时复制 N 个. 为此, 我们模拟 N 个:

- 估计斜率 $K_{\text{est}}(q) = K_{\text{est}} \exp(q \Delta x)$. • 估计斜率 $K_{\text{est}}(q) = \mathbb{E}[\Delta x]$. $K_{\text{est}}(q)$.
- 估计斜率的时间序: $P_x(t, q) = K_{\text{est}}(q) \cdot \exp(-K_{\text{est}}(q) \cdot t)$. • 权重/heights: $Y_x(t, q) = \exp \left[(K_{\text{est}}(q) - K_{\text{est}}(q)) \cdot t \right]$.

利用这些新信息 $\phi^{(N)}(q, t) = \int P_x \cdot \delta^{K_{\text{est}}(q)} \cdot \frac{K_{\text{est}}(q)}{K_{\text{est}}(q)} \cdot P_{n_1}(t-t_1, q) \cdot Y_{n_1}(t-t_1, q) \cdot \dots \cdot \frac{K_{\text{est}}(q)}{K_{\text{est}}(q)} \cdot P_{n_N}(t-t_N, q) \cdot Y_{n_N}(t-t_N, q)$.

• $\frac{K_{\text{est}}(q)}{K_{\text{est}}(q)} \cdot P_{n_1}(t-t_1, q) \cdot P_{n_2}(t-t_2, q)$.

我们需要对每个粒子进行克隆。为此，我们要选取合适的 N 个 clone。 $N \gg 1$ 。在时刻 t 时，第 α 个粒子的状态由 x^α 表征。它下一次跳跃的时间由 τ^α 表征。
 在初始时，每个粒子的状态 $x^\alpha(0)$ 是从初始分布 $p(x|t=0)$ 中随机抽取的。而两次跳跃的时间 τ^α 也是从分布 $p_\tau(\tau|t)$ 中抽取的。在抽取后，设置 $t = t + \tau^\alpha$ ，进行如下迭代：

- 对粒子编号进行跳跃的标记编号 α^* ，即 τ^{α^*} 为所有 τ^α 中最小者
- 将 α^* 标记为 τ^{α^*} 。
- 更新 x^{α^*} 的坐标 x 。它是从分布 $p(x|x^{\alpha^*}) = \frac{K(x^{\alpha^*}, x) p(x)}{K(x^{\alpha^*}, x^{\alpha^*})}$ 中随机抽取的。
- 将 α^* 标记为下一粒子的时间设置 $\tau^{\alpha^*} = t + \Delta t$ 。 Δt 服从 $p_\tau(\Delta t, t)$ 中随机抽取的。
- 计算一段时间内的概率 $K(x, t) = \exp[-(K(x, t) - K(x^{\alpha^*}, t)) \Delta t]$
- 根据权重调整 clone。具体而言，应计算 $y = L[K(x, t) + \epsilon]$ 。 $\epsilon \sim U(0, 1)$
- 将 clone 的数目调整至 N
- 设置一个 rescaling factor $x = N / (N + y - 1)$ 。

$\begin{cases} \text{若 } y=0, & \text{则直接将该 clone 删除。} \\ \text{若 } y=1, & \text{不做任何操作} \\ \text{若 } y>1, & \text{则把剩余的粒子标记为 } y-1 \text{ 倍。} \end{cases}$

以上算法的正确性证明可解释为入然的，但最值得注意的是，你可以认为 y 是 x 在时间 t 时，路径对于所有有作业权的权重。

对于 $C(t)$ 的表达式为 $p(x|t, y) = (x_1, x_2, \dots, x_N)^T$ 。 N 个 scaled $C(t)$ 为 $y(t) = -\frac{1}{N} \sum_{i=1}^N \ln C(x_i, \dots, x_N)$ 。

Losses of Large Deviation

总体而言，我们利用大偏差理论研究随机系统 (static 和 dynamic)。但有些时候我们处理的是多尺度的过程，这时，我们常常引入不同尺度上的大偏差理论。

- level 1 针对瞬时状态的随机的大偏差理论。e.g. 粒子的位置 $x(t)$ 。
- level 2 描述一些路径的可测量 (与系统所经历的时间有关)。主要与 empirical vector 有关： $f = (f_1, \dots, f_N)$ 为 x 上的路径统计。
- level 3 则处理路径上的统计。即 $\mathcal{P} = (x_1, x_2, \dots, x_N)$ 上的可测量。

为了处理不同尺度上的大偏差理论，我们需要引入所谓 Contraction principle。粗略地说：当我们固定和变量 x 的 rate function 为 $I^0(x)$ ， x, y 间有函数关系 $y = f(x)$ ，则 y 的 rate function 为：
 $I^1(y) = \inf_{x: f(x)=y} I^0(x)$ 。每次改变 y 的速率函数 $I^1(y)$ 在点 x 的值由 x 对应的“最可能事件”决定。

对于马尔可夫过程可以取 x 为 “Level 2.5”，即 empirical vector $f = f(x)$ 与 empirical jump frequency $r_{x,1} = \frac{N_{x,1}(x)}{T}$ 的集合。对于由马尔可夫过程生成的系统，Level 2.5 很重要，因为一些主要可测量 e.g. 熵产生，的大偏差理论可以从这里导出。因此我们推导 Level 2.5 的 rate function。

这要求系统处于稳态。若在时间段 $[0, T]$ ，为平稳过程，我们做 empirical stationary 假设。即 $r_{x,1} = \frac{1}{T} \sum_{i=1}^T r_{x,i}$ 。

随着 T 的增大， $f_x \rightarrow P^{\text{st}}$ ， $r_{x,1} \rightarrow K_{\text{st}} P^{\text{st}}$ 。我们需引入一个辅助的近似过程。这个过程中的 jump rate 满足 $r_{x,1} = K_{\text{st}} f_x$ (对应于 $r_{x,1} = K_{\text{st}} P^{\text{st}}(x)$)。

相当于我们用路径的 $r_{x,1}$ 和 f_x 定下了这个过程的 K_{st} 。这个过程的跃迁速率 $K_{\text{st}} = \sum_x \tilde{K}_{x,1}$ 。

那么, 对于任意路径 ω , 它在高度 P 的概率与在高度 P^* 下的概率之比 (或者说, 两个高度下的 P -期望) 为:

$$\frac{P_A}{P_A^*} = \left(\prod_{i=1}^n \frac{P_{X_i, X_{i-1}}}{P_{X_i^*, X_{i-1}^*}} \right) \left(\prod_{i=1}^n \exp \left(-(\tilde{k}_{X_i} - \tilde{k}_{X_{i-1}})(t_{i-1} - t_i) \right) \right) \quad (t_{i-1} = t_i^*)$$

$$= \exp \left[-T \cdot \tilde{E} \left(\tilde{k}_{X_i} \ln \frac{\tilde{k}_{X_i}}{\tilde{k}_{X_i^*}} - \tilde{k}_{X_i} + \tilde{k}_{X_i^*} \right) f_i \right].$$

从而, 我们有: $P(f, \tilde{k}, \tau) = \underbrace{P^*(f, \tilde{k}, \tau)}_{\substack{\text{这仅用经验建立的 jump rate} \\ \text{因此 } T = \tau \text{ 时, 这一项的值即为 } 1}} \cdot \left\langle \frac{P_A}{P_A^*} \right\rangle = \frac{P_A}{P_A^*} = \exp \left[-T \cdot \tilde{E}(f, \tilde{k}) \cdot f_i \right]$, 其中 $\tilde{E}(f, \tilde{k}) = \sum_{X_i} \left(\tilde{k}_{X_i} \ln \frac{\tilde{k}_{X_i}}{\tilde{k}_{X_i^*}} - \tilde{k}_{X_i} + \tilde{k}_{X_i^*} \right) f_i$.

到前面的章节及这里, 我们可得到: $P(f, \tau) = \exp \left[-T \cdot \tilde{E}(f, \tau) \right]$, $\tilde{E}(f, \tau) = \inf_{\tilde{k}} \tilde{E}(f, \tilde{k})$.

而在 current $J_{X_i} = \tilde{k}_{X_i} f_i - \tilde{k}_{X_i^*} f_i$, 它对应的 rate function 可用乘积给出. 具体而言, 存在一个自对称参数, $\lambda_{X_i} = -\lambda_{X_i^*}$, 我们有了的 rate function.

$\phi(\tilde{k}_i, k_i, \lambda) = \sum_i \left[\tilde{E}(f, \tilde{k}_i) + \frac{1}{2} \lambda_{X_i} (\tilde{k}_{X_i} f_i - \tilde{k}_{X_i^*} f_i - J_{X_i}) \right]$. 通过求导可得到: $\tilde{E}(f, \tau) = \tilde{E}(f, \tilde{k}^*)$, $\tilde{k}_{X_i}^* = \tilde{k}_{X_i} \cdot \exp(\pm \lambda_{X_i})$.