

Geometric Ergodicity of Hamiltonian Monte Carlo

竹田航太

2022年11月6日

概要

MCMC などのアルゴリズムにおいて生成される estimator の有効性を考える上で Markov Chain の収束について考えることは重要である。収束性は (Geometric) Ergodicity という概念で表現されるが、何らかのノルムによる定常分布への収束性を指すものである。ここでは主に HMC に関する収束定理についてまとめる。確率微分方程式やマルコフ連鎖、凸最適化に関する知識が求められる。

1 ノルム

収束定理において使われる測度空間のノルムを整理する。現在確認しているものは以下

(1) total variation:

$$d_{TV}(\nu_1, \nu_2) = \|\nu_1 - \nu_2\|_{TV} = \sup_{A \in \mathcal{F}} (\nu_1(A) - \nu_2(A)) = \int_A \left| \frac{d\nu_1}{d\nu_2} - 1 \right| d\nu_2$$

(2) χ^2 -距離:(これは距離ではない)

$$\|\nu_1 - \nu_2\|_{\chi^2} = \int_A \left| \frac{d\nu_1}{d\nu_2} - 1 \right|^2 d\nu_2$$

(3) Wasserstein-k 距離:

$$d_{W_k}(\nu_1, \nu_2)^k = W_k(\nu_1, \nu_2)^k = \inf_{(X, Y) \in \mathcal{C}(\nu_1, \nu_2)} \mathbb{E}[\|X - Y\|^k]$$

1.1 ノルム間の不等式

ノルム間に成り立つ関係については次を参照 [1, ON CHOOSING AND BOUNDING PROBABILITY]

例えば

$$d_{min} \cdot d_{TV} \leq W_1 \leq \text{diam}(\Omega) \cdot d_{TV}$$

2 証明にあたっての仮定

HMC の収束性を証明するためによく仮定される条件をまとめる。分布を $\pi = e^{-U}$ と表し、ポテンシャル U について条件を課す。典型的なものは log-concave と gradient-Lipschitz である。

2.1 Log-Concave

HMC の収束において density の log-concave 性 (もしくはポテンシャルの convex 性) が必要とされる。この背景には convex optimization の理論がある。しかし、応用上は non-convex な最適化を必要とする場合があり、HMC の non-concave density への適用の需要も高まっている。

2.2 Gradient-Lipschitz

後述の通り、gradient-Lipschitz 性から density から誘導される確率微分方程式の解の存在が示される。

2.3 Bounded

状態空間がコンパクトでポテンシャルが有界な時、Log-concave 性を使わず簡単に HMC の収束を示すことができる。

3 SDE との関係

一般に MCMC に対する収束定理は対応する SDE の離散化解のノルム収束評価として捉えることができる。

3.1 Langevin diffusion

HMC の簡易版のアルゴリズムとして Langevin Monte Carlo がある。これは π から定められる Langevin 方程式と呼ばれる以下の確率微分方程式を離散化 (Euler scheme) したアルゴリズムである。

$$dY_t = -\nabla U(Y_t)dt + \sqrt{2}dB_t \quad (3.1)$$

[2, Durmus] によると U に関する convex 性や gradient-Lipschitz 性の仮定の元で π に対する log-Sobolev 不等式や Y_t に対する状態空間の次元に依存しない指数収束性が示される。また、[Karatzas, Shreve]^{*1} の Chapter5, Thm2.5 によると gradient-Lipschitz 性から (3.1) と 2 次モー

^{*1} <https://link.springer.com/content/pdf/>

メントをもつ初期分布 μ_0 に対する一意な強解の存在を示せる。さらに Thm2.9 によれば (3.1) から定まる半群^{*2} P_t は π と可逆になり、 π を不変測度としてもつ。^{*3}

3.1.1 SDE の知識

以下などを参考にして SDE に関する知識をつける必要がある。

Karatzas, Shreve; <https://link.springer.com/content/pdf/>

Ergodicity for SDEs; <https://www.sciencedirect.com/science/article/pii/S0304414902001503>

Exponential convergence for LD; <https://projecteuclid.org/journals/bernoulli/volume-2/issue-4/Exponential-convergence-of-Langevin-distributions-and-their-discrete-approximations/bj/1178291835.full>

4 収束・Ergodicity

Markov kernel の定義は Markov Chain に譲る。

4.1 Markov kernel の表現

$(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ 上の Markov Chain $(X_n)_{n \geq 0}$ を考える。この Markov kernel を定式化を行う。 $(\Theta, \mathcal{B}_\Theta)$ 上の r.v. θ を考え、これにより Chain を生成する際のランダム性を表現する。

Definition 4.1. $f_\theta : \mathbb{R}^d \rightarrow \mathbb{R}^d$ に対して、次の形の Markov kernel を考える。

$$P(x, A) = \int 1_A(f_\theta(x)) \gamma(d\theta) \quad x \in \mathbb{R}^d, A \in \mathcal{B}(\mathbb{R}^d)$$

今、分布 π への chain を Metropolis-Hasting Algorithm によって構成するので f_θ の形は以下のようなになる。

$$f_\theta(x) = \begin{cases} g_\xi(x) & (u < a(x, g_\xi(x))) \\ x & \text{other} \end{cases}$$

ここで $\theta = (\xi, u)$ $u \sim U[0, 1]$ であり、 $\xi \sim \mu \in \mathcal{M}_1(\mathbb{R}^d)$ として、 g_ξ は candidate(proposal) map と呼ばれる。

g_ξ を用いて proposal kernel $Q : \mathbb{R} \times \mathcal{B}(\mathbb{R}^d) \rightarrow [0, 1]$ は次で与えられる。

$$Q(x, A) = \int 1_A(g_\xi(x)) \mu(d\xi) \quad x \in \mathbb{R}^d, A \in \mathcal{B}(\mathbb{R}^d)$$

^{*2} transition kernel とも呼ばれる

^{*3} マルコフ連鎖については https://litharge3141.github.io/blog_pdf/markov_chain/markovchain.pdf なども参照

さらに, $\pi, Q(x, dy)$ にそれぞれ density $q(x, y), \pi(x)$ の存在を仮定すると, acceptance probability $a(x, y)$ は次のようにかける

$$a(x, y) = 1 \wedge \frac{\pi(y)q(y, x)}{\pi(x)q(x, y)} 1_S$$

(ただし, $S = \{\pi(x)q(x, y) > 0\}$) 特に $\pi(x)q(x, y) = 0$ の場合は $a(x, y) = 1$ となる.

Definition 4.2 (MH-type kernel). Markov kernel P が Metropolis-Hasting type (MH-type) であるとは以下を満たすこと.

$$P(x, A) = a(x, y)Q(x, dy) + r(x)\delta_x(dy)$$

ただし, $r(x) = 1 - \int a(x, y)Q(x, dy)$

Lemma 4.3 (MH-type の導出). 上で f_θ から定義した P は MH-type となる.

4.2 Exmample

g_ξ の例を典型的なアルゴリズムで紹介する.

表1 g_ξ の例

Algorithm	$g_\xi(x)$	$\xi \sim$
RWM	$x + \xi$	mean zero symmetric measure on \mathbb{R}^d
MALA	$x + \frac{h}{2}\nabla \log(\pi(x)) + \sqrt{h}\xi$	$N(0, I)$
HMC	$\text{Pr}_x \circ \phi_T(x, p)$	$\xi = (p, T); p \sim N(0, M), T \sim \text{measure on } \mathbb{N}$

Remark 4.4. MALA は以下の Langevin diffusion の Euler-Maruyama scheme による離散化.

$$dX_t = \nabla \log(\pi(X_t))dt + \sqrt{2}dW_t$$

ただし, W_t は Brawnian Montion.

4.3 Conditions

目的の定常分布 π に収束するための Markov kernel P に対する条件を考える.

4.3.1 定常分布と可逆性

まず, 定常分布の定義について.

Definition 4.5 (Markov 遷移核の作用). $\mu \in \mathcal{M}_1(\mathbb{R}^d)$ に対して, $\mu P \in \mathcal{M}_1(\mathbb{R}^d)$ を次で定める.

$$\mu P(\cdot) := \int_{\mathbb{R}^d} \mu(dx) P(x, \cdot)$$

$f: \mathbb{R}^d \rightarrow \mathbb{R}$ s.t. 有界, $\mathcal{B}(\mathbb{R}^d)$ -可測に対して, $Tf: \mathbb{R}^d \rightarrow \mathbb{R}$ を次で定める.

$$Pf(\cdot) = \int_{\mathbb{R}^d} f(y) P(\cdot, dy)$$

また, m -step Markov 遷移核 P^m ($m \geq 2$) を再帰的に以下で定義する.

$$P^m(x, A) := (P(x, \cdot) P^{m-1})(A) = \int_{\mathbb{R}^d} P(x, dy) P^{m-1}(y, A) \quad (4.1)$$

Definition 4.6 (定常分布と可逆性). $\pi \in \mathcal{M}(\mathbb{R}^d)$ が P -stationary(invariant) とは以下が成り立つこと

$$\pi P = \pi$$

また, π と P が reversible とは以下が成り立つこと

$$\pi(x) P(x, dy) = \pi(dy) P(y, dx)$$

Lemma 4.7. Markov kernel P が π に対して reversible のとき π は P -invariant となる.

Proof.

$$\int_{x \in \mathcal{X}} \pi(dx) P(x, dy) = \int_{x \in \mathcal{X}} \pi(dy) P(y, dx) = \pi(dy) \int_{x \in \mathcal{X}} P(y, dx) = \pi(dy)$$

□

Lemma 4.8. π に対して定義した MH-type kernel は π に reversible な chain を作る.

4.3.2 定常分布への収束

次に一意的な定常分布への収束を保証するための条件を考える.

Definition 4.9 (ϕ -irriducible). Markov kernel P が $\exists \phi: \sigma$ -finite measure on \mathcal{X} に対して, ϕ -irriducible(既約)

$\stackrel{\text{def}}{\Leftrightarrow}$ 任意の $x \in \mathcal{X}$ と $\phi(A) > 0$ となる $A \in \mathcal{B}(\mathcal{X})$ に対し, ある $n = n(x, A) \in \mathbb{N}$ s.t. $P^n(x, A) > 0$

Example 4.1 (Running Example). $\pi \in \mathcal{M}(\mathbb{R}^d)$ の density を同様に π と書き, π に対する MH-type Algorithm を考える. proposal density $q(x, y)$ は $\mathbb{R}^d \times \mathbb{R}^d$ 上正值, 連続とし, π は至

る所有限とする.

このとき, このアルゴリズムは π -irriducible となる.

確かに, $\forall x \in \mathbb{R}^d$ と $\pi(A) > 0$ となる A に対して, $\exists R > 0$ s.t. $\pi(A_R) > 0$ (ただし, $A_R = A \cap B_R(0)$). 次に連続性から, $\exists \epsilon$ s.t. $\forall x \in \mathbb{R}^d, \inf_{y \in \mathbb{R}^d} \min\{q(x, y), q(y, x)\} \geq \epsilon$ $\pi(x) > 0$ として, *4

$$\begin{aligned} P(x, A) &\geq P(x, A_R) \geq \int_{A_R} q(x, y) \min \left[1, \frac{\pi(y)q(y, x)}{\pi(x)q(x, y)} \right] dy \\ &\geq \epsilon \int_{A_R} \frac{\pi(y)}{\pi(x)} dy \\ &\geq \epsilon |\{y \in A_R; \pi(y) \geq \pi(x)\}| + \frac{\epsilon}{\pi(x)} \pi(\{y \in A_R; \pi(y) < \pi(x)\}) \end{aligned}$$

π は Lebesgue 測度に対して絶対連続なので $|A_R| > 0$ であり, そのため最右辺は同時に 0 にならない. 以上から $P(x, A) > 0$ となり, P は π -irriducible である.

Definition 4.10 (aperiodic). P with 定常分布 π が *aperiodic* とは次を満たす $d \geq 2$ が存在しないこと. disjoint $A_1, \dots, A_d \in \mathcal{B}(\mathbb{R}^d)$ s.t.

$$P(x, A_{i+1}) = 1 \text{ if } x \in A_i \text{ and } P(x, A_1) = 1 \text{ if } x \in A_d \text{ and } \pi(A_1) > 0$$

Example 4.2 (Running Example 続き). 追加の過程なしで *aperiodic* が成り立つ. 背理法により示す. disjoint な $\mathcal{X}_1, \mathcal{X}_2 \subset \mathcal{X}$ s.t. $\pi(\mathcal{X}_1), \pi(\mathcal{X}_2) > 0$ かつ $P(x, \mathcal{X}_2) = 1 \forall x \in \mathcal{X}_1$ を考える. π の絶対連続性から $|\mathcal{X}_1| > 0$ となるので,

$$P(x, \mathcal{X}_1) \geq \int_{y \in \mathcal{X}_1} q(x, y) a(x, y) dy > 0$$

次に asymptotic convergence theorem を述べる. 状態空間には可算生成な σ 代数を仮定するが $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ はこれを満たす. 定理の証明は [3] に譲る.

Theorem 4.11 (定常分布への収束). Markov 連鎖 (T, δ_x) は ϕ -irriducible, aperiodic で定常分布 $\pi \in \mathcal{M}_1(\mathcal{X})$ をもつとする. このとき π a.e. $x \in \mathcal{X}$ で

$$\lim_{m \rightarrow \infty} \|P^m(x, \cdot) - \pi(\cdot)\|_{TV} = 0$$

Remark 4.12. Theorem 4.11 は P に ϕ -irriducible と aperiodic を要請するが, π が定常分布となるアルゴリズム (MH-type など) を使えば大きな問題ではなくなる.

4.4 Geometric Ergodicity

次は定常分布への収束の速さを評価したい. べき的 (geometric) な収束を保証するのが (Geometric)Ergodicity である.

*4 そうでない場合は $a(x, y) = 1$ となり, 直ちに $P(x, A)$ が従う.

Definition 4.13 (Geometric Ergodicity). *Markov Chain P with stationary π が Geometrically Ergodic とは以下を満たすこと.*

$\exists \rho < 1, \exists M : \mathbb{R}^d \rightarrow [0, 1]; \pi$ -a.e. finite s.t.

$$\|P^n(x, \cdot) - \pi(\cdot)\|_{TV} \leq M(x)\rho^n$$

Definition 4.14 (Lyapunov function, Drift condition). *Markov kernel P に対して, Lyapunov function V が存在する (もしくは Drift condition を満たす)*

$\stackrel{\text{def}}{\Leftrightarrow} V : \mathbb{R}^d \rightarrow [1, \infty]$ s.t. $\exists 0 < \lambda < 1, \exists b < \infty, \exists \omega < \infty$

$$PV(x) \leq \lambda V(x) + b1_{C_\omega}(x) \quad (4.2)$$

ただし, $C_\omega = \{x; V(x) \leq \omega\}$

Theorem 4.15 (Geometrically Ergodic Theorem). $x \in \mathbb{R}^d$ を初期値として Markov kernel P により生成される Chain が π -irreducible, aperiodic であり, Lyapunov function V をもつとする. このとき P は Geometrically Ergodic である. i.e.

$\exists \rho < 1, \exists M : \mathbb{R}^d \rightarrow [0, 1]; \pi$ -a.e. finite s.t.

$$\|P^n(x, \cdot) - \pi(\cdot)\|_{TV} \leq M(x)\rho^n$$

Example 4.3 (not irreducible chain). $U(x) = x, L = 2, \epsilon = \sqrt{2}$ の時, $\phi(x_0, p_0) = x_0$ となり chain は not irreducible.

Remark 4.16 ([4]). *MH-type* について, $\text{ess sup } r(x) = 1$ のとき, *geometric ergodicity* は成り立たない.

Example 4.4 ([4]). 以下の形の目的分布に対して, *Random Walk Metropolis* は not geometrically ergodic.

$$\pi(x, y) \propto \exp -(x^2 + x^2y^2 + y^2).$$

参考文献

- [1] Alison L. Gibbs and Francis Edward Su. On choosing and bounding probability metrics. *International Statistical Review / Revue Internationale de Statistique*, 70(3):419–435, 2002.
- [2] Alain Durmus and Éric Moulines. Sampling from a strongly log-concave distribution with the Unadjusted Langevin Algorithm. Preliminary version, April 2016.
- [3] Gareth O. Roberts and Jeffrey S. Rosenthal. General state space markov chains and mcmc algorithms. *Probability Surveys*, 1(none), Jan 2004.

- [4] GO Roberts and RL Tweedie. Geometric convergence and central limit theorems for multidimensional hastings and metropolis algorithms. *BIOMETRIKA*, 83(1):95–110, MAR 1996.
- [5] Samuel Livingstone, Michael Betancourt, Simon Byrne, and Mark Girolami. On the geometric ergodicity of hamiltonian monte carlo, 2018.
- [6] Oren Mangoubi and Aaron Smith. Rapid mixing of hamiltonian monte carlo on strongly log-concave distributions, 2017.
- [7] Arnak S. Dalalyan. Theoretical guarantees for approximate sampling from smooth and log-concave densities, 2016.
- [8] Gareth O. Roberts and Richard L. Tweedie. Exponential convergence of Langevin distributions and their discrete approximations. *Bernoulli*, 2(4):341 – 363, 1996.