

Ewens分布を不変にする2つのMarkov連鎖

半田賢司（佐賀大学）

題材

遺伝子変換モデル

- ・ 各個体のタイプが世代交代に伴い変化（ランダムサンプリング／突然変異）
- ・ 同じタイプの個体からなるグループサイズの時間発展を記述

凝結・分裂モデル

- ・ 2つのクラスターが合体／1つのクラスターが2つのクラスターに分裂
- ・ クラスターサイズの時間発展を記述

内容

- 2つのモデル共に **Ewens分布** を定常分布として持つ.
- それらの連続版：無限個 **アレルモデル** と区間の **split-merge過程**
- 連続版は共に **Poisson-Dirichlet分布** を定常分布として持つ.

整数分割と Ewens 分布

N : 自然数, \mathcal{P}_N : N の分割全体

記法 $\mathcal{P}_N \ni \lambda = (1^{\lambda_1} 2^{\lambda_2} \dots)$

$$\begin{aligned} \longleftrightarrow N &= \overbrace{1 + \dots + 1}^{\lambda_1} + \overbrace{2 + \dots + 2}^{\lambda_2} + \dots + \overbrace{N}^{\lambda_N} = \sum i \lambda_i \\ &=: n_1 + \dots + n_k \quad (n_1 \geq \dots \geq n_k) \quad \text{ただし } k = \sum \lambda_i =: |\lambda| \end{aligned}$$

$$\longleftrightarrow \underline{n} = (n_1, \dots, n_k, 0, 0, \dots) \in \mathbf{Z}_+^\infty$$

Ewens 分布 μ_θ on \mathcal{P}_N ($\theta > 0$: パラメータ)

$$\mu_\theta(\lambda) = \frac{N!}{(\theta)_N} \prod_{i=1}^N \left(\binom{\theta}{i}^{\lambda_i} \frac{1}{\lambda_i!} \right) = \frac{\theta^{|\lambda|}}{(\theta)_N} \prod_{i=1}^N \frac{i^{\lambda_i}}{i^{\lambda_i} \lambda_i!}$$

ただし, $(\theta)_N = \theta(\theta + 1) \cdots (\theta + N - 1)$

注意 $\theta \rightarrow \infty$ のとき $\mu_\theta \rightarrow \delta_{(1^N 2^0 \dots)}$, $\theta \downarrow 0$ のとき $\mu_\theta \rightarrow \delta_{(1^0 \dots (N-1)^0 N^1)}$.

Ewens分布とサイクル長

$\mathcal{S}_N : \{1, \dots, N\}$ の置換全体

$\mathcal{S}_N \ni \sigma$ は, 互いに排反な「台」を持つ巡回置換の積で表せる:

$$\sigma = \tau_1 \circ \dots \circ \tau_k \quad (k =: |\sigma|)$$

τ_i の「台 (support)」の大きさ (不動点は大きさ 1) に着目:

$$N = \#\text{supp}(\tau_1) + \dots + \#\text{supp}(\tau_k) \longrightarrow \lambda \in \mathcal{P}_N$$

(結局) 「ランダム置換 σ はランダム分割 λ を導く。」

定理 [Cauchy, 18??] (for $\theta = 1$)

$\theta > 0$ に対し, \mathcal{S}_N 上の分布 m_θ を $m_\theta(\sigma) \propto \theta^{|\sigma|}$ で定めるとき,

$$\sigma \sim m_\theta \implies \lambda \sim \mu_\theta$$

遺伝子変換モデル

状態空間 \mathcal{P}_N

- ・ 個体数 N の集団において、個体の ‘タイプ’ に基づくグループ分け
- ・ グループサイズに着目 $\rightarrow \lambda \in \mathcal{P}_N$

(結局) 「ランダムなタイプ変化はランダム分割の時間発展を導く。」

タイプの時間発展 (概要) (Wight-Fisher型) cf. 清水昭信『確率過程論』

(1) random sampling

各個体が独立に、 N 個体から当確率で選んだ個体と同じタイプになる。

(2) mutation

一定の率で、これまでに存在しなかった新たなタイプへと変化する。

連続時間 Markov 過程としての定式化 (1)

$\theta > 0$: パラメータ (突然変異率)

$\lambda \in \mathcal{P}_N$ からの推移先と推移率 (rate) : $i, j \in \{1, \dots, N\}$

(1) random sampling

• $i \neq j$ に対し, $\lambda \mapsto \lambda^{i \rightarrow j}$;

「大きさ i のグループの **1** 個体が大きさ j のグループへ移動」 rate $i\lambda_i j\lambda_j$

• 各 i に対し, $\lambda \mapsto \lambda^{i \rightarrow i}$;

「大きさ i のグループの **1** 個体が大きさ i の 別の グループへ移動」 rate $i\lambda_i i(\lambda_i - 1)$

(2) mutation

各 i に対し, $\lambda \mapsto \lambda^{i \rightarrow *}$;

「大きさ i のグループの **1** 個体が大きさ **1** のグループを形成」 rate $\theta i \lambda_i$

記号 $\text{rate}_{WF}(\lambda \mapsto \lambda')$: 「 $\lambda \in \mathcal{P}_N$ から $\lambda' \in \mathcal{P}_N$ への推移率」

例) $\text{rate}_{WF}(\lambda \mapsto \lambda^{i \rightarrow *}) = \theta i \lambda_i$

Ewens分布の不変性 – 遺伝子変換モデルの場合

生成作用素

$$G_N f(\lambda) = \sum_{\lambda'} \text{rate}_{WF}(\lambda \mapsto \lambda') [f(\lambda') - f(\lambda)]$$

定理 パラメータ θ の遺伝子変換モデルは、Ewens分布 μ_θ を唯一の定常分布として持つ。実際、次の詳細釣り合い条件 (DBC) が満たされる：

$$\text{rate}_{WF}(\lambda \mapsto \lambda') \mu_\theta(\lambda) = \text{rate}_{WF}(\lambda' \mapsto \lambda) \mu_\theta(\lambda'), \quad \forall \lambda, \lambda' \in \mathcal{P}_N$$

すなわち、 μ_θ は（もっと強く）可逆分布である。

（略証）DBC から次が示される。

$$\sum_{\lambda} G_N f(\lambda) g(\lambda) \mu_\theta(\lambda) = \sum_{\lambda} f(\lambda) G_N g(\lambda) \mu_\theta(\lambda).$$

凝結分裂モデル

状態空間 \mathcal{P}_N

- ・ N 個の粒子がいくつかのクラスターを成す.
- ・ クラスターサイズに着目 $\rightarrow \lambda \in \mathcal{P}_N$

(結局) 「クラスターのランダムな合体・分裂はランダム分割の時間発展を導く。」

クラスター群の時間発展 (概要)

cf. **[Diaconis, Mayer-Wolf, Zeitouni, Zerner, 2004]**

(0) N 粒子から 2 粒子を非復元抽出

(1) **coagulation**

2 粒子が異なるクラスターに属する場合, 2 つのクラスターが合体

(2) **fragmentation**

2 粒子が同じクラスターに属する場合, クラスターが無作為の大きさに 2 つに分裂

[e.g. 大きさ 10 のクラスターの分裂でできる小クラスターサイズ $\in \{1, 2, \dots, 9\}$]

連続時間 Markov 過程としての定式化 (2)

$\hat{\beta} > 0$: 凝結率, $\check{\beta} > 0$: 分裂率

$\lambda \in \mathcal{P}_N$ からの推移先と推移率 (rate) : $i, j \in \{1, \dots, N-1\}$

(1) coagulation

• $i \neq j$ に対し, $\lambda \mapsto \mathbf{Coag}_{i,j}\lambda$;

「大きさ i のクラスター 1 個と大きさ j のクラスター 1 個が合体」 rate $\hat{\beta} \frac{i\lambda_i j\lambda_j}{N(N-1)}$

• 各 i に対し, $\lambda \mapsto \mathbf{Coag}_{i,i}\lambda$;

「大きさ i の 2 つの異なるクラスター同士が合体」 rate $\hat{\beta} \frac{i\lambda_i i(\lambda_i-1)}{N(N-1)}$

(2) fragmentation

i, j に対し, $\lambda \mapsto \mathbf{Frag}_{i,j}\lambda$;

「大きさ $i+j$ のクラスターが大きさ i, j の 2 つのクラスターに分裂」

$$\text{rate } \check{\beta} \frac{(i+j)\lambda_{i+j}}{N(N-1)} = \check{\beta} \frac{i+j}{N} \cdot \frac{i+j-1}{N-1} \cdot \frac{1}{i+j-1} \cdot \lambda_{i+j}$$

Ewens分布の不変性 – 凝結分裂モデルの場合

生成作用素

$$L_N f(\lambda) = \sum_{\lambda'} \text{rate}_{CF}(\lambda \mapsto \lambda') [f(\lambda') - f(\lambda)]$$

定理 凝結率 $\hat{\beta}$, 分裂率 $\check{\beta}$ の凝結分裂モデルは, パラメータ $\theta = \check{\beta}/\hat{\beta}$ の **Ewens** 分布 μ_θ を唯一の定常分布として持つ. 実際, 次の 詳細釣合条件 (DBC) が満たされる:

$$\text{rate}_{CF}(\lambda \mapsto \lambda') \mu_\theta(\lambda) = \text{rate}_{CF}(\lambda' \mapsto \lambda) \mu_\theta(\lambda'), \quad \forall \lambda, \lambda' \in \mathcal{P}_N$$

すなわち, μ_θ は (もっと強く) 可逆分布である.

(略証) **DBC** から次が示される.

$$\sum_{\lambda} L_N f(\lambda) g(\lambda) \mu_\theta(\lambda) = \sum_{\lambda} f(\lambda) L_N g(\lambda) \mu_\theta(\lambda).$$

注意 $\check{\beta} = \hat{\beta} = 1$ のとき, $\text{rate}_{CF}(\lambda \mapsto \cdot)$ は \mathcal{P}_N 上の推移確率でもあり, 「**ランダム互換 (transposition) モデル**」が導く推移確率と同じ.

連続極限 as $N \rightarrow \infty$ (定式化)

$$\mathcal{P}_N \ni \lambda \longleftrightarrow N = n_1 + \dots + n_k \quad (n_1 \geq \dots \geq n_k > 0)$$

$$\longleftrightarrow \underline{n} = (n_1, \dots, n_k, 0, 0, \dots) \text{ を正規化 :}$$

$$\frac{1}{N} \underline{n} = \left(\frac{n_1}{N}, \dots, \frac{n_k}{N}, 0, 0, \dots \right) \in \nabla_\infty$$

新たな状態空間は

$$\nabla_\infty = \left\{ \underline{p} = (p_1, p_2, \dots) : p_1 \geq p_2 \geq \dots \geq 0, \sum_{i=1}^{\infty} p_i = 1 \right\}$$

テスト関数 $\phi(\underline{p}) = \prod_{i=1}^{\infty} f(p_i)$

ただし, $f \geq 0$, $f - 1 \in C_c^\infty(\mathbf{R}_+)$, $\text{supp}(f - 1) \subset (0, \infty)$.

注意 このとき, $f(0) = 1$ であり, $\prod_{i=1}^{\infty} f(p_i)$ は有限積.

連続極限 – 遺伝子変換モデルの場合

- $\phi(\underline{p}) = \prod_{i=1}^{\infty} f(p_i)$ に対して, $\phi_N(\underline{n}) = \prod_{i=1}^{\infty} f\left(\frac{n_i}{N}\right)$ とおくと,

$$G_N \phi_N(\underline{n}) = \sum_{i \neq j} n_i n_j \left[f\left(\frac{n_i - 1}{N}\right) f\left(\frac{n_j + 1}{N}\right) - f\left(\frac{n_i}{N}\right) f\left(\frac{n_j}{N}\right) \right] \prod_{l \neq i, j} f\left(\frac{n_l}{N}\right) \\ + \theta \sum_i n_i \left[f\left(\frac{n_i - 1}{N}\right) f\left(\frac{1}{N}\right) - f\left(\frac{n_i}{N}\right) \right] \prod_{l \neq i} f\left(\frac{n_l}{N}\right).$$

- $N \rightarrow \infty$ のとき $N^{-1} \underline{n}^{(N)} \rightarrow \underline{p}$ (i.e., $N^{-1} n_i^{(N)} \rightarrow p_i$ ($\forall i \in \mathbf{N}$)) ならば,

$$G_N \phi_N(\underline{n}^{(N)}) \rightarrow \sum_{i, j=1}^{\infty} p_i (\delta_{ij} - p_j) \frac{\partial^2 \phi}{\partial p_i \partial p_j}(\underline{p}) - \theta \sum_{i=1}^{\infty} p_i \frac{\partial \phi}{\partial p_i}(\underline{p}) \\ =: \mathcal{G} \phi(\underline{p}) \quad \text{「無限個アレルモデル」の生成作用素}$$

cf. [Shimizu, 1987] 「n-locusモデル」の場合 ($i, j \in \mathcal{P}_n?$)

連続極限 – 凝結分裂モデルの場合

- $\phi(\underline{p}) = \prod_{i=1}^{\infty} f(p_i)$ に対して, $\phi_N(\underline{n}) = \prod_{i=1}^{\infty} f\left(\frac{n_i}{N}\right)$ とおくと,

$$L_N \phi_N(\underline{n}) = \hat{\beta} \sum_{i \neq j} \frac{n_i n_j}{N(N-1)} \left[f\left(\frac{n_i + n_j}{N}\right) - f\left(\frac{n_i}{N}\right) f\left(\frac{n_j}{N}\right) \right] \prod_{l \neq i, j} f\left(\frac{n_l}{N}\right) \\ + \check{\beta} \sum_i \frac{n_i}{N(N-1)} \sum_{m=1}^{n_i-1} \left[f\left(\frac{m}{N}\right) f\left(\frac{n_i - m}{N}\right) - f\left(\frac{n_i}{N}\right) \right] \prod_{l \neq i} f\left(\frac{n_l}{N}\right).$$

- $N \rightarrow \infty$ のとき $N^{-1} \underline{n}^{(N)} \rightarrow \underline{p}$ (i.e., $N^{-1} n_i^{(N)} \rightarrow p_i$ ($\forall i \in \mathbf{N}$)) ならば,

$$L_N \phi_N(\underline{n}^{(N)}) \rightarrow \hat{\beta} \sum_{i \neq j} p_i p_j \left[f(p_i + p_j) - f(p_i) f(p_j) \right] \prod_{l \neq i, j} f(p_l) \\ + \check{\beta} \sum_i p_i^2 \int_0^1 du \left[f(up_i) f((1-u)p_i) - f(p_i) \right] \prod_{l \neq i} f(p_l) \\ =: \mathcal{L} \phi(\underline{p}) \quad \text{「区間の split-merge 過程」の生成作用素}$$

cf. [Mayer-Wolf, Zeitouni, Zerner, 2002]

Poisson-Dirichlet 分布 (定義)

$\sum \delta_{Z_i}$: $(0, \infty)$ 上の **Poisson** 点過程で, 平均測度 $\theta z^{-1} e^{-z} dz$

定義

$Z_{(1)} \geq Z_{(2)} \geq \dots$: Z_1, Z_2, \dots を大きい順に並べたもの

$Z := Z_1 + Z_2 + \dots (< \infty \text{ a.s.})$

このとき, 正規化された無限列 $(Z_{(1)}/Z, Z_{(2)}/Z, \dots)$ が導く

$$\nabla_\infty = \left\{ (p_1, p_2, \dots) : p_1 \geq p_2 \geq \dots \geq 0, \sum_{i=1}^{\infty} p_i = 1 \right\}$$

上の分布をパラメータ θ の **Poisson-Dirichlet 分布** とよぶ.

記号 **PD**(θ)

Ewens分布とPoisson-Dirichlet分布

事実 (1) 各 $\lambda \in \mathcal{P}_N$ に対して

$$\mu_\theta(\lambda) = \frac{N!}{\prod_{i=1}^N ((i!)^{\lambda_i} \lambda_i!)} E^{\text{PD}(\theta)} \left[\sum_{\substack{i_1, \dots, i_k \\ \text{distinct}}} P_{i_1}^{n_1} \dots P_{i_k}^{n_k} \right]$$

ただし, $\underline{n} = (n_1, \dots, n_k, 0, 0, \dots)$ は λ から定まるものとする.

(2) ランダム分割 $\lambda^{(N)} \in \mathcal{P}_N$ は Ewens 分布 $\mu_\theta = \mu_\theta^{(N)}$ に従うとする.

$\lambda^{(N)}$ から定まる $\underline{n}^{(N)} = (n_1^{(N)}, \dots, n_k^{(N)}, 0, 0, \dots)$ について, $N \rightarrow \infty$ のとき

$$\frac{1}{N} \underline{n}^{(N)} \Rightarrow (P_1, P_2, \dots) \sim \text{PD}(\theta) \quad (\text{法則収束})$$

定常分布としてのPoisson-Dirichlet分布

— 無限個アレルモデルの場合

定理 [Ethier-Kurtz, 1981]

$\text{PD}(\theta)$ は, 生成作用素

$$\mathcal{G}\phi(\underline{p}) = \sum_{i,j=1}^{\infty} p_i(\delta_{ij} - p_j) \frac{\partial^2 \phi}{\partial p_i \partial p_j}(\underline{p}) - \theta \sum_{i=1}^{\infty} p_i \frac{\partial \phi}{\partial p_i}(\underline{p})$$

に付随する ∇_{∞} 上の Markov 過程の一意的な定常分布である. また, 可逆分布でもある.

注意 $t \rightarrow \infty$ のときの定常分布への収束の速さについては, ある意味で指数的であることが知られている. (2パラメータ版も含めて [Petrov, 2009])

定常分布としての Poisson-Dirichlet 分布

– 区間の split-merge 過程の場合

定理 [Mayer-Wolf, Zeitouni, Zerner, 2002]

$\theta = \check{\beta}/\hat{\beta}$ とおく. $\mathbf{PD}(\theta)$ は, 生成作用素

$$\begin{aligned} \mathcal{L}\phi(\underline{p}) &= \hat{\beta} \sum_{i \neq j} p_i p_j \left[f(p_i + p_j) - f(p_i) f(p_j) \right] \prod_{l \neq i, j} f(p_l) \\ &\quad + \check{\beta} \sum_i p_i^2 \int_0^1 du \left[f(up_i) f((1-u)p_i) - f(p_i) \right] \prod_{l \neq i} f(p_l) \end{aligned}$$

に付随する ∇_∞ 上の Markov 過程の可逆定常分布である.

注意 (1) 定常分布は一意的であろうとの予想があるが, 今の所, $\theta = 1$ の場合のみが示されている. [Diaconis, Mayer-Wolf, Zeitouni, Zerner, 2004]

(2) $t \rightarrow \infty$ のときの定常分布への収束の速さについては, 指数的でないことが示せる.