

# アルゴリズム的ランダムネスと学習可能性(3)

宮部賢志(明治大学)

2024年7月9日(火) -- 12日(金)

RIMS共同研究 (公開型)

数理論理学の最近の進展

Symposium on Advances in Mathematical Logic

1. ランダムネスの理論の概要・歴史: (1)前半
2. Martin-Löfランダム性: (1)後半
3. マルチンゲール: (2)前半
4. Kolmogorov複雑性: (2)後半
5. Solovay還元: (3)前半
6. 学習可能性: (3)後半

# Martin-Löfランダム性

定義(Martin-Löf 1966)

**Martin-Löf検定**(ML検定): 一様c.e.開集合の列 $(U_n)_{n \in \omega}$ で, すべての $n \in \omega$ で $\mu(U_n) \leq 2^{-n}$ となるもの.

$X \in 2^\omega$ とML検定 $(U_n)_n$ に対して,  $X \notin \bigcap_n U_n$ となるとき,  $X$ はML検定 $(U_n)_n$ に**合格する**(pass)という.

$X \in 2^\omega$ がすべてのML検定に合格するとき,  $X$ は**MLランダム**であるという.

# Solovay還元

# left-c.e. MLランダム

実数 $x$ がleft-c.e.であるとは，単調増加な計算可能な有理数列 $(a_n)_n$ で $\lim_n a_n = x$ となるものが存在すること．

テーマ：left-c.e. MLランダム，みんな同じ性質を持つ．

- Turing次数が $0'$
- 停止確率として書ける
- Solovay完全
- 複雑性が定数しか変わらない
- 収束速度はすべて同じ

## 定義

万能非接頭機械 $U$ に対し, その**停止確率**(halting probability)を,

$$\Omega = \sum_{\sigma \in \text{dom}(U)} 2^{-|\sigma|}$$

として定義する.

Chaitinの $\Omega$ と呼ばれることもある.

停止確率は機械 $U$ に依存するため,  $\Omega_U$ と書くこともある.

省略した場合は, 万能非接頭機械であれば成り立つ性質を議論する.

# 停止確率の性質

Kraftの不等式から $\Omega \leq 1$ が分かる

また左c.e.実数(left-c.e. real)であることも分かる。

## 命題

停止確率は停止問題とTuring同値である，つまり， $\Omega \equiv_T \emptyset'$

## 証明

$\Omega$ が与えられたら， $\Omega_s \upharpoonright n = \Omega \upharpoonright n$ となる $s$ まで待つことで，長さ $n$ 以下の文字列で停止するか判定できる。

逆に各 $r \in \mathbb{Q}$ に対し $\exists s. \Omega_s > r$ ならば止まる，そうでなければ止まらないプログラムを考えることで， $\Omega$ を計算できる。

# 停止確率の性質

**定理** (Chaitin)

$\Omega$ はMLランダムである。

**証明**

$\Omega$ は停止問題とTuring同値なので有理数ではない。

よって、すべての $n$ に対して $s$ が存在して $\Omega_s \upharpoonright n = \Omega \upharpoonright n$ となる。

十分大きい $c \in \omega$ を使って、以下のように機械 $M$ を定義する。

入力 $\tau \in 2^{<\omega}$ に対して、

$$U(\tau)[s] = \Omega_s \upharpoonright n, \quad |\tau| < n - c$$

(これは $K(\Omega_s \upharpoonright n)[s] < n - c$ を意味している)ならば、

$\mu \notin \text{rng}U[s]$ となる $\mu \in 2^{<\omega}$ を見つけ,  $M(\tau) = \mu$ とする.  
 $c, M$ の情報を持つ長さ $c$ 以下の文字列を $\rho$ とする.

$$U(\rho\tau) = \mu, U(\rho\tau)[s] \uparrow$$

が成り立っていると思って良い.

$$\Omega - \Omega_s \geq 2^{-(c+|\tau|)} > 2^{-n}$$

であり,  $\Omega \upharpoonright n \neq \Omega_s \upharpoonright n$ .

すなわち $|\tau| < n - c$ ならば $U(\tau) \neq \Omega \upharpoonright n$ なので,  $K(\Omega \upharpoonright n) \geq n - c$

証明終

特別な機械 $M$ を作ることによって、 $U$ がそれを自動で追いかけてくれるというのが面白い。

$\Omega$ は、停止問題を計算することができるような情報をMLランダムという圧縮した形で持っている。

後に逆も成り立つことを紹介する。

left-c.e.実数がMLランダムあることは収束がととても遅いことを意味する.

## 定義 (Solovay)

$\alpha \leq_S \beta$ とは, 部分計算可能な関数  $f : \subseteq \mathbb{Q} \rightarrow \mathbb{Q}$  と  $c \in \omega$  が存在して,

$$q \in \mathbb{Q} \text{ かつ } q < \beta \Rightarrow f(q) \downarrow < \alpha \text{ かつ } \alpha - f(q) < c(\beta - q)$$

$\beta$ の下からの近似有理数 $q$ が与えられたら,  $\alpha$ のよりよい近似有理数 $f(q)$ を与えることができる.

つまり,  $\beta$ の方が下から近似しにくい.

定理

$$\alpha \leq_S \beta \Rightarrow \alpha \leq_T \beta$$

定理

$$\alpha \leq_S \beta \Rightarrow \alpha \leq_K \beta$$

ここで,

$$\alpha \leq_K \beta \iff K(\alpha \upharpoonright n) < K(\beta \upharpoonright n) + O(1)$$

# Solovay還元の特徴づけ

**定理** (Downey, Hirschfeldt, and Nies 2002)

$\alpha, \beta$ をleft-c.e.実数とする.

$\alpha \leq_S \beta$ であることと以下は同値：ある $c \in \omega$ とleft-c.e.実数 $\gamma$ が存在して、

$$c\beta = \alpha + \gamma$$

気持ち： $\alpha$ がある一定量変化したら、 $\beta$ もその後でそれと同じぐらい変化する。

left-c.e.実数 $\beta$ が**Solovay完全**(Solovay complete)とは、任意のleft-c.e.実数 $\alpha$ に対して、 $\alpha \leq_s \beta$ となること。

left-c.e.なMLランダム実数が存在するから、Solovay完全なleft-c.e.実数はMLランダム。

# Kučera-Slamanの定理

**定理** (Kučera-Slaman 2001)

$\alpha$ をMLランダムなleft-c.e.実数とすると,  $\alpha$ はSolovay完全.

**証明**

$\beta$ をleft-c.e.実数として,  $\beta \leq_S \alpha$ を示す.

近似列 $(\alpha_s), (\beta_s)$ を固定する.

ML検定 $(U_n)_n$ を以下のように構成する.

stage  $s$ において,  $\alpha_s \in U_n[s]$ であれば何もしない.

そうでなければ, 最後に $U_n$ が変化したstage(なければ0)を $t$ とし,

$(\alpha_s, \alpha_s + 2^{-n}(\beta_s - \beta_t))$ を $U_n$ に入れる.

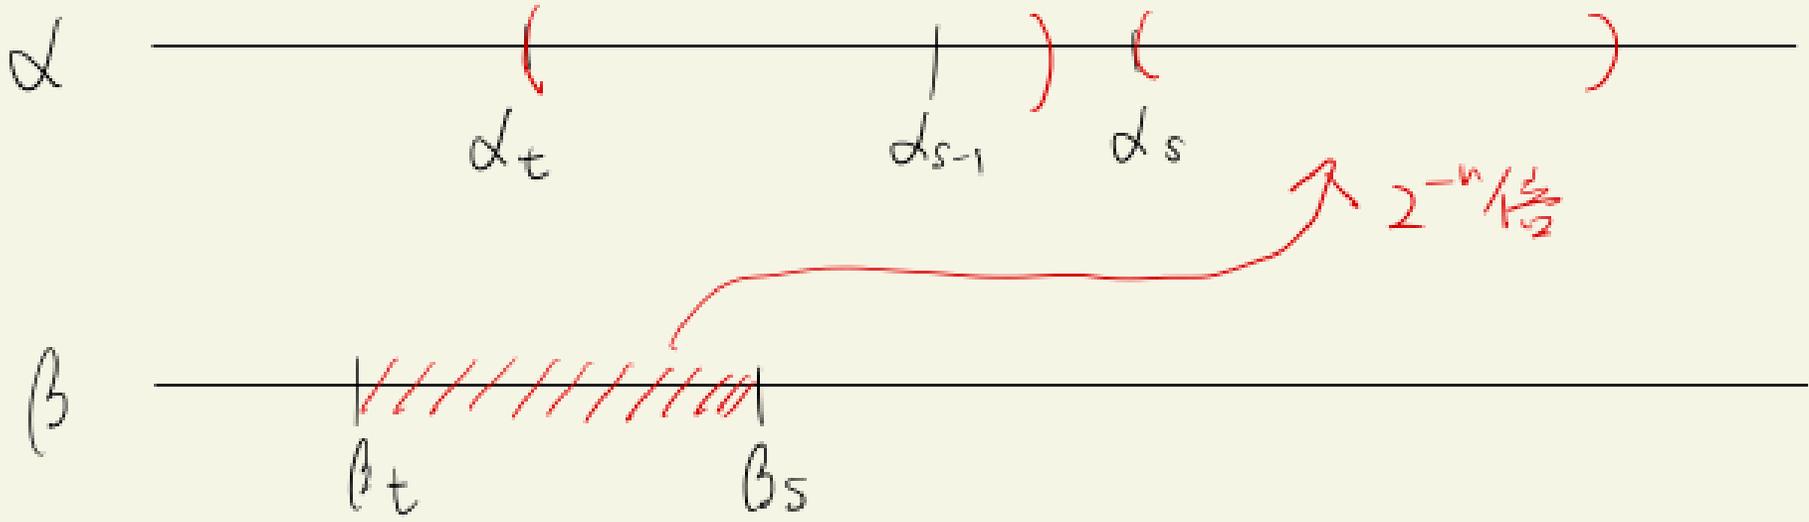
## Kučera-Slamanの定理(続き)

明らかに $\mu(U_n) \leq 2^{-n}\beta$ で、 $(U_n)_n$ はML検定。  
 $\alpha$ はMLランダムなので、ある $n \in \omega$ で $\alpha \notin U_n$ .

$U_n$ が変化したstageを $s_0, s_1, \dots$ とすると、

$$\alpha_{s_{i+1}} - \alpha_{s_i} \geq 2^{-n}(\beta_{s_i} - \beta_{s_{i-1}})$$

これは、 $\beta \leq_S \alpha$ を示している。



**定理** (Calude, Hertling, Khoussainov, and Wang 1998)

$\alpha$ がSolovay完全なleft-c.e.実数ならば，ある万能非接頭機械 $U$ が存在して， $\Omega_U = \alpha$ となる．

つまり，left-c.e.実数に対しては，MLランダム性，Solovay完全性，停止確率となることはすべて同値．

Solovay還元は $K$ 還元を導くことから，すべてのMLランダムleft-c.e.実数はその非接頭Kolmogorov複雑性は定数を除いて一致する．

**定理** (Barnmpalias and Lewis-Pye 2017)

$\Omega$ をMLランダムなleft-c.e.実数とし，その近似列 $(\Omega_s)_s$ を固定する． $\alpha$ をleft-c.e.実数とし， $(a_s)_s$ をその近似列とする．

- $\alpha$ がMLランダムならば， $\lim_s \frac{\alpha - \alpha_s}{\Omega - \Omega_s}$ が正の値として存在する．
- $\alpha$ がMLランダムでなければ， $\lim_s \frac{\alpha - \alpha_s}{\Omega - \Omega_s} = 0$

MLランダムな列はどのような計算可能な近似列をとったとしても，同じように収束が遅い．

## c.a.実数

left-c.e.以外の実数に対するSolovay還元を考えたい。

$x \in \mathbb{R}$ が**弱計算可能**(weakly computable)とは、計算可能な有理数列  $(a_n)_n$  で  $\sum_n |a_{n+1} - a_n| < \infty$  となるものが存在して、 $\lim_n a_n = x$  となること。

2つのleft-c.e.実数の差になることと同値。

left-c.e.を含む最小の実閉体。

$x \in \mathbb{R}$ が**計算近似可能**(computably approximable, c.a.)とは、計算可能な有理数列  $(a_n)_n$  が存在して  $\lim_n a_n = x$  となること。

実数を2進展開と同一視したとき、 $x \leq_T \emptyset'$  と同値。

**定義** (Zheng and Rettinger 2004)

$\alpha, \beta$ をc.a.実数とする.

$\alpha \leq_s \beta$ とは, ある計算可能な近似列 $(a_n)_n, (b_n)_n$ と $c \in \omega$ が存在して, すべての $n \in \omega$ で,

$$|\alpha - a_n| < c(|\beta - b_n| + 2^{-n})$$

となること.

注意: left-c.e.実数に対しては, もとのSolovay還元と同値になる.

# Solovay還元の性質

**定理** (Rettinger and Zheng 2005)

$\alpha$ を弱計算可能実数とする。

もし $\alpha$ がMLランダムならば、 $\alpha$ はleft-c.e.かright-c.e.

## 証明

$\alpha$ の計算可能近似列 $(a_n)_n$ で有界変動 $\sum_n |a_{n+1} - a_n| < \infty$ を固定

$\alpha < a_n$ となる $n$ が有限個であれば、 $\alpha$ はleft-c.e.である。

$\alpha > a_n$ となる $n$ が有限個であれば、 $\alpha$ はright-c.e.である。

$(a_n)_n$ が $\alpha$ を無限回跨ぐとする。有界変動であることから、 $m$ 回以上跨ぐ部分は全体の長さの $1/m$ 以下である。

このことから、 $\alpha$ を覆うML検定を作ることができる。

# Solovay還元の性質

**定理** (Rettinger and Zheng 2005)

$\alpha$ をc.a.実数とする.

$$S(\alpha) = \{\beta \in \mathbf{CA} : \beta \leq_s \alpha\}$$

は体(field)をなす.

**観察** (隈部・宮部・鈴木 to appear)

上記の集合は実閉体にもなる.

# Solovay還元の特徴づけ

**定理** (隈部・宮部・鈴木 to appear)

$\alpha, \beta$ をc.a.実数とする.

$\alpha \leq_S \beta$ と以下は同値:ある計算可能な $\alpha, \beta$ の近似列 $(a_n)_n, (b_n)_n$ と $c \in \omega$ が存在して,

$$(\forall n, k)[k < n \Rightarrow |a_n - a_k| < c(|b_n - b_k| + 2^{-k})]$$

考える差が数列同士なので使いやすい.

# Solovay還元の性質

**定理** (Rettinger and Zheng 2005)

$\alpha$ をc.a.実数とする.

$\alpha \leq_S \Omega$ と $\alpha$ が弱計算可能であることは同値.

**証明**

$S(\Omega)$ はすべてのleft-c.e.を含む体である.

弱計算可能実数の集合はleft-c.e.を含む最小の体なので,  $S(\Omega)$ に含まれる.

逆は上記の定理を使うと楽に示せる.

# Solovay還元の性質

$\alpha \leq_S \Omega$ として、 $\alpha$ が弱計算可能であることを示す。

仮定より $\alpha, \Omega$ の近似列 $(a_n)_n, (b_n)_n$ と $c \in \omega$ が存在して、

$$(\forall n, k)[k < n \Rightarrow |a_n - a_k| < c(|b_n - b_k| + 2^{-k})]$$

ここで、 $(a_n)_n, (b_n)_n$ は有界変動ではないかもしれない。

$b_n \rightarrow \Omega$ で、 $\Omega$ には単調増加の近似列 $(\Omega_s)_s$ が存在するので、

$$|b_{n_i} - \Omega_{n_i}| < 2^{-i}$$

となる計算可能な部分列 $(n_i)_i$ が取れる。

# Solovay還元の性質

ここで、 $(a_{n_i})_i$ は $\alpha$ に収束する計算可能な列である。また、

$$\begin{aligned} |a_{n_{i+1}} - a_{n_i}| &< c(|b_{n_{i+1}} - b_{n_i}| + 2^{-n_i}) \\ &< c(|\Omega_{n_{i+1}} - \Omega_{n_i}| + 2^{-i-1} + 2^{-i} + 2^{-n_i}) \end{aligned}$$

右辺の和は有限であるから、 $(a_{n_i})_i$ は有界変動。

# Solovay次数の構造

left-c.e.実数についてはSolovay次数の構造もよく知られている。

## 命題

left-c.e.実数 $\alpha, \beta$ に対し、 $\alpha + \beta$ は $\alpha, \beta$ のSolovay次数における最小上界を与える。

## 証明

$\alpha, \beta \leq_S \alpha + \beta$ はDowneyらの特徴づけから明らか。

$\alpha, \beta \leq_S \gamma$ とすれば、 $\gamma$ の近似から $\alpha, \beta$ の近似を作ることができるので、 $\alpha + \beta$ の近似も作ることができる。

# Solovay次数の構造

**定理** (Downey, Hirschfeldt, and Nies 2002)

MLランダムでないleft-c.e.実数 $\alpha$ に対し, あるleft-c.e.実数 $\beta, \gamma$ が存在して,  $\beta, \gamma <_S \alpha$ かつ $\alpha = \beta + \gamma$ となる.

MLランダムでないleft-c.e.実数 $\alpha$ に対し, あるleft-c.e.実数 $\beta$ が存在して,  $\alpha <_S \beta <_S \Omega$ となる.

## 問題

弱計算可能実数に対するSolovay次数の構造はどうなっているか？

最小上界は常に存在するか？稠密か？

c.a.次数ではどうか？

# 學習可能性

# 学習とは

機械学習とはデータから規則を抽出する技術。  
理論的な解析のためには設定を定める必要がある。  
ここではSolomonoffの枠組みを用いる。

$2^\omega$ 上の未知の確率測度 $\mu$ からランダムな列 $X \in 2^\omega$ が最初から順に与えられるとする。

$\sigma = X \upharpoonright n$ を見て次のビット $X(n)$ の確率を推定する。

真の確率は

$$k \mapsto \mu(k|\sigma) = \frac{\mu(\sigma k)}{\mu(\sigma)}$$

である。

### 定義

$\xi : 2^{<\omega} \rightarrow [0, 1]$ が**半測度**(semimeasure)とは,  $\lambda$ を空文字とし, 任意の  $\sigma \in 2^{<\omega}$ に対し,

$$\xi(\lambda) \leq 1, \xi(\sigma 0) + \xi(\sigma 1) \leq \xi(\sigma)$$

を満たすこと.

半測度がc.e.であるとは, 関数として下側半計算可能(lower semicomputable)であること.

c.e.半測度が**万能**(universal)とは, 任意のc.e.半測度 $\nu$ に対し, ある $c \in \omega$ が存在して, すべての $\sigma \in 2^{<\omega}$ に対し, 以下を満たすこと.

$$\nu(\sigma) \leq c\xi(\sigma)$$

**定理** (Solomonoff 1964)

$\mu$ : 計算可能な確率測度

$\xi$ : 万能c.e.半測度

$k \in \{0, 1\}$ に対し,  $\mu$ -確率1で, 以下が成立する.

$$|\mu(k|X_{<n}) - \xi(k|X_{<n})| \rightarrow 0 \quad (n \rightarrow \infty)$$

$\xi$ は $\mu$ の事前知識はないが,  $X$ の情報から $\mu$ を推定可能.

Solomonoffはこの $\xi(\cdot|\cdot)$ を**アルゴリズム的確率**と呼んだ.

これで人工知能の研究終わり. . . というわけにはいかない.

## 従来の見解

Marcus Hutter's beautiful (and in some respects beautifully ugly) theory of Universal AI, building on the earlier theory of Solomonoff induction, is the paradigm case of the theory-first approach. (BEN GOERTZELのblogより 2021)

These answers are useless if they cannot be approximated in practice, i.e., by a regular Turing machine. (Leike and Hutter 2018)

One might worry that for this reason, Solomonoff prediction is completely useless as a practical guide for assigning prior probabilities. (A Dilemma for Solomonoff Prediction, Neth 2023)

その他, impracticalとも言われる。

- 計算不可能なpriorを如何に近似するか？
  - 近似は難しい
- 収束に必要なランダム性は？
  - MLランダム性では不十分

# 学習理論の違い

- 古典的統計的学習理論
  - 過学習，損失関数は凸，1対1対応
- 深層学習，KAN
  - 二重降下，損失関数は非凸，1対1対応しない
- 万能推論
  - すべての計算可能な確率分布を考える，自然数でパラメタ化される
  - 非連続，損失関数は非凸，1対1対応しない

ニューラルネットワークとTuring機械というモデルに差はあるが，似たことを考えている．

## 汎用的な予測とは

計算可能な確率分布に万能なものは存在しない。

dominateにより半順序を入れれば「より汎用的な予測」の概念は定義できる。

### 定義

十分汎用的な計算可能な予測確率に対して性質 $P$ が成り立つとは、ある計算可能な予測確率 $\nu$ が存在して、 $\nu$ をdominateするすべての計算可能な予測確率 $\xi$ に対し、 $\xi$ が性質 $P$ を持つことを意味する。

# KL-divergence

離散分布において、 $\mu$ の $\xi$ に対するKL-divergenceは、

$$D(\mu||\xi) = \sum_{\sigma \in \{0,1\}} \mu(\sigma) \log \frac{\mu(\sigma)}{\xi(\sigma)}$$

- $d_\sigma(\mu||\xi) = d(\mu(\cdot|\sigma)||\xi(\cdot|\sigma))$
- $D_n(\mu||\xi) = \sum_{k=1}^n E_\mu[d_{X_{<k}}(\mu||\xi)]$
- $D_\infty(\mu||\xi) = \lim_{n \rightarrow \infty} D_n(\mu||\xi)$

$\mu$ と $\xi$ が計算可能ならば、 $D_\infty(\mu||\xi)$ は左c.e.実数か無限大

## 定理 (M.)

$\mu$ : 計算可能な確率測度

十分汎用的な予測測度  $\xi$  に対し,  $D_\infty(\mu \parallel \xi)$  は有限で, MLランダムな左 c.e.実数となる.

## 直感的な説明

$\xi$  は十分汎用的なので,  $\mu$  と  $\mu$  に似た分布両方を dominate する必要がある.

その違いがいくらでも遅く起こるので, その誤差の収束は最も遅く, MLランダムである必要がある.

また十分汎用的であれば, どんな  $\xi$  でもほぼ同じ速さで収束する.

# まとめ

- ランダムネスの理論は確率の公理化，データの計算論的な理解などを目指して始まった
- ランダム性は典型性(検定)，予測不可能性(マルチンゲール)，圧縮不可能性(複雑性)などにより特徴づけられる．(積分検定などもある．)
- MLランダムな左c.e.実数は，停止確率，Solovay完全性など多くの性質を持つ面白い実数のクラス．近似の収束が遅い実数．
- MLランダムな左c.e.実数は，学習の文脈で誤差の和として現れる．おそらくそのような例は他にもあると思われる．