

# アルゴリズム的情報理論

## Algorithmic Information Theory

宮部賢志 (明治大学工学部数学科)

2025年3月11日(火)

# 自己紹介

- 宮部賢志(みやべけんし)
- 岐阜市出身
- 京都大学理学部・理学研究科 (学部・修士・博士・ポスドク)
- 現在：明治大学理工学部数学科
- 専門：計算論・確率論
- 興味：確率の哲学, 予測の限界

- アルゴリズム的情報理論(Algorithmic Information Theory, AIT)
- Algorithmic randomnessやKolmogorov complexityとも呼ばれる
- ランダム性や情報量, 予測限界などの概念を計算の概念を用いて定式化し, その性質を調べる

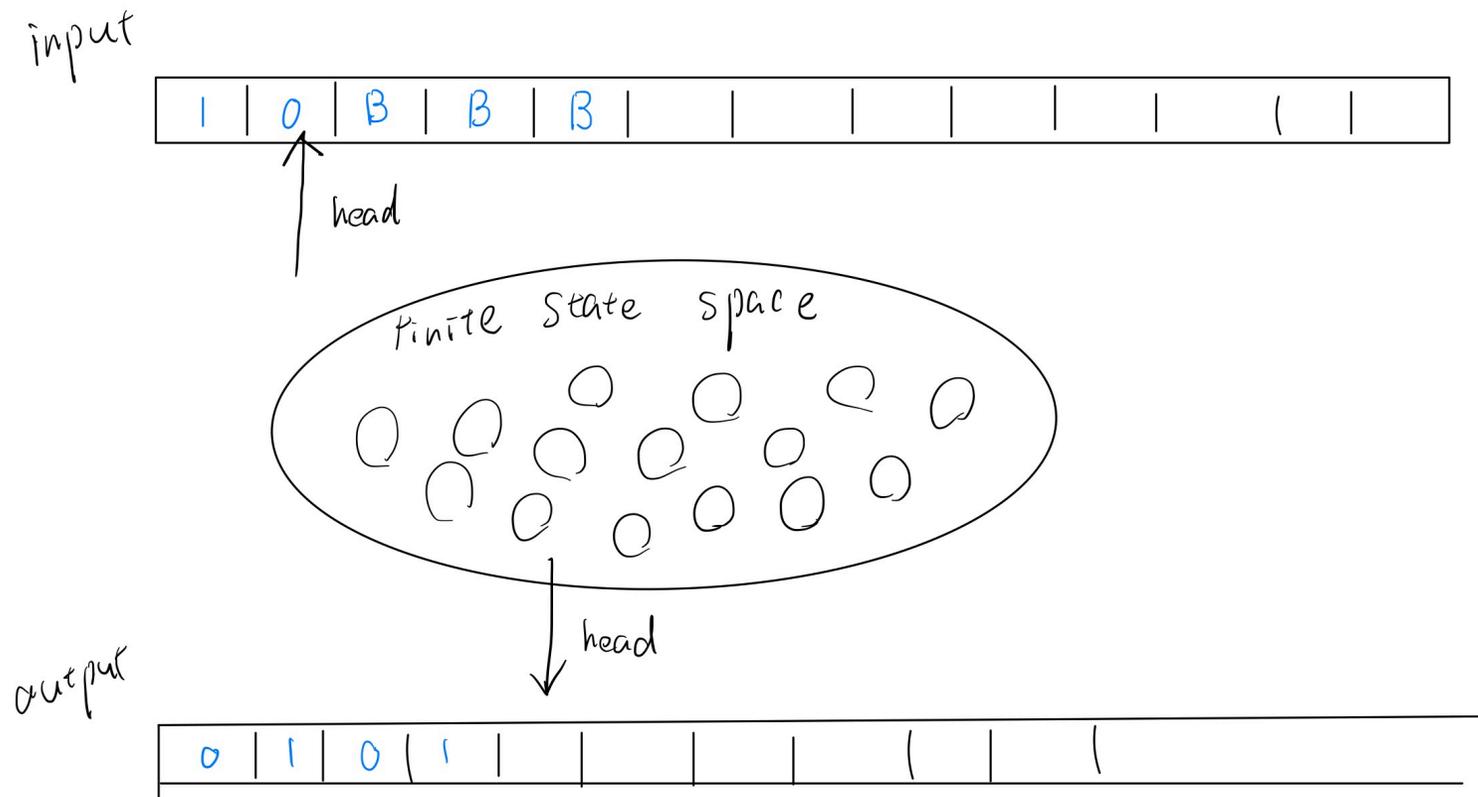
- 1900年：Hilbertの23の問題のうち第6問題『物理学の諸公理の数学的扱い』の中で、確率の公理的基礎を求める
- 1919～: von Misesによる頻度主義による確率論の提案, collectiveと呼ばれるランダムな列の概念の提案, Villeの構成などにより不十分であることが認識される
- 1970年代：Kolmogorov, Solomonoff, Chaitinらにより、「文字列の複雑性」の概念が提案され, ランダム性について数学的に議論できるようになった
- 2010年前後～：計算可能解析学(computable analysis)の手法により, 通常の数学的対象のランダム性を議論できるようになった

# 計算論入門

## 計算論の基本的な知識の確認

- Hilbertの第2問題「算術の公理間の整合性」や第10問題「ディオファントス方程式の可解性の決定問題」などの提起
- 1930年代に、ラムダ計算、再帰関数、Turing機械などが提案され、その計算可能性が等価であることが示される
- Church-Turingのテーゼ：「計算可能な関数とは、Turing機械により計算できる関数のこと」

# Turing機械



## Turing機械の性質

入力と出力は有限アルファベットで、読み書きできる  
各ステップは有限状態に従って決定的に定まる  
機械の動きは有限情報で記述できる

### 定理

計算可能関数は可算である

プログラムが文法的に正しいかどうかは計算可能に判定可能.  
計算が停止しないときには未定義とする. 一般には部分関数となる.

## 定義

$\Phi_e : \subseteq 2^{<\omega} \rightarrow 2^{<\omega}$  を  $e$  番目の機械とする.

## 定理

以下を満たす**万能機械**(universal machine) $U$ が存在する. 任意の機械 $M$ に対し, ある $\sigma \in 2^{<\omega}$ が存在して, すべての $\tau \in 2^{<\omega}$ で $U(\sigma\tau) \simeq M(\tau)$ .

## 定理 (停止問題の計算不可能性)

$H = \{\langle e, k \rangle \mid \Phi_e(k) \downarrow\}$  を停止問題(Halting problem)と呼ぶ。停止問題 $H$ は計算不可能

## 系

部分計算可能関数は計算可能に数え上げられるが、全域計算可能関数は計算可能に数え上げることができない。

# 万能推論入門

- 主な貢献者はRay Solomonoff(1926-2009)
- 1964年に発表された"A Formal Theory of Inductive Inference"のPart I, IIがよく引用される
- 2000年代にはMarcus HutterらによるAIXIへの拡張もある
- 万能推論(Universal induction)と呼ばれる.
- Solomonoff自身は, 確率概念の計算論的な再定義という意味で, Algorithmic Probabilityと呼んでいる.

# 設定1

カントール空間: 2進無限列 $\{0, 1\}^{\mathbb{N}}$

$\mu$ : カントール空間上の計算可能測度(未知のモデルを表す)

$X$ :  $\mu$ に対してランダムな列

$X \in \{0, 1\}^{\mathbb{N}}$ が順に与えられるとする. つまり,

$$X = X_1 X_2 X_3 \cdots$$

は $\mu$ の情報を持っており,

$$X_{\leq n} = X_1 X_2 \cdots X_n$$

として,  $X_{\leq n}$ から $X_{n+1}$ の分布を予測する問題を考える.

真の分布は

$$\mu(k | X_{\leq n}) = \frac{\mu(X_{\leq n} k)}{\mu(X_{\leq n})}$$

である. 予測もまた測度 $\xi$ により,

$$\xi(k | X_{\leq n}) = \frac{\xi(X_{\leq n} k)}{\xi(X_{\leq n})}$$

と表される. すなわち,  $\xi$ はベイズ予測における事前分布で,  $\xi(\cdot | \cdot)$ は事後分布である.

モデル測度 $\mu$ は何らかの積測度になっているとは一般には仮定しない。  
つまり、独立同分布性は仮定しない。

そのかわり、モデル測度 $\mu$ は計算論の意味で計算可能であると仮定している。  
また、予測測度 $\xi$ にも弱い計算可能性を仮定する。

## ゴール

多くの未知測度 $\mu$ に対して,  $\xi(\cdot|\cdot)$ が $\mu(\cdot|\cdot)$ に近いような事前分布 $\xi$ を作る.

未知測度 $\mu$ は様々なタスク(教師あり学習)に対応する. 例えば, 分類, 回帰, 画像認識, 音声認識, 自然言語処理, 金融予測などなど.

予測測度 $\xi$ はデータから学習するモデルに対応する.

Solomonoffの主定理を述べるのに必要な言葉を準備する.

測度 $\xi$ が測度 $\nu$ を**優越する**(dominate)とは, ある定数 $c \in \mathbb{N}$ があってすべての $\sigma \in \{0, 1\}^*$ で $\nu(\sigma) \leq c \cdot \xi(\sigma)$ となることをいう. ここで,  $[\sigma] = \{X \in \{0, 1\}^{\mathbb{N}} \mid \sigma < X\}$ とし,  $\nu(\sigma)$ は $\nu([\sigma])$ を意味する.

## 定理

任意のc.e.半測度を優越するようなc.e.半測度は**最適**(optimal)と呼ばれる. 最適なc.e.半測度は存在する.

このことは, 万能Turing機械が存在することと同様に示すことができる.

## 定理 (Solomonoff 1964)

$\mu$ を計算可能な測度,  $\xi$ を最適なc.e.半測度とする. このとき,  $\mu$ -確率1で,

$$\lim_{n \rightarrow \infty} |\xi(\cdot | X_{\leq n}) - \mu(\cdot | X_{\leq n})| = 0$$

この予測 $\xi(\cdot | \cdot)$ は万能であることを意味する.

Solomonoffはこの $\xi(\cdot | \cdot)$ を**アルゴリズム的確率**(algorithmic probability)と呼んでいる.

- $\xi(\cdot | \cdot)$ は計算可能ではなく, 近似可能だがその困難度も高い.
- $\xi(\cdot | \cdot)$ の $\mu(\cdot | \cdot)$ への収束は計算可能に抑えることができない.
- "completely useless"と表現する人もある...

注意: No Free Lunch定理とは矛盾しない.

# Kolmogorov complexity 入門

- ここまではSolomonoffの結果を最短距離で紹介した.
- 万能な予測の哲学的議論を行う前に, 複雑性の概念を紹介して, その関係も議論できるようにしておきたい.
- モデルの複雑さを定量的に表現することで, 「単純なモデルほど可能性が高い」と考えるモデルが良いモデルになることを主張する.

# モデル選択

モデル選択：観察データに合致する複数のモデルからどのモデルを選ぶか？

2つの大きな異なる考え方がある。

- Epiculusの多説明原理

If more than one theory is consistent with the observations, keep all theories.  
(Principle of Multiple Explanations)

- オッカムの剃刀(Occam's razor)

『オッカムのかみそり: 最節約性と統計学の哲学』 エリオット・ソーバー  
(著), 森元 良太 (翻訳), 勁草書房(2021)

## アイデア

単純なモデルは可能性が高く、複雑なモデルは可能性が低いとして、確率を足し合わせよう。

この意味で、Epiculusの多説明原理とオッカムの剃刀のいいところ取りをする。  
ではモデルの複雑性をどう定量化するか？

## 定義 (Kolmogorov complexity)

文字列  $\sigma \in 2^{<math>\omega</math>$  の plain Kolmogorov complexity  $C(\sigma)$  を,

$$C(\sigma) = \min\{|p| \mid U(p) = \sigma\}$$

と定義する。ただし、 $U$  は万能機械である。

ここで、 $|p|$  はプログラム  $p \in 2^{<math>\omega</math>$  の長さ。単純なほど小さく、複雑なほど大きくなる。例えば、ほとんどのランダムな列  $\sigma \in 2^n$  に対して、 $C(\sigma) \approx n$  となる。

## 定義 (Solomonoff's prior)

$$M(\sigma) = \sum_{p:U(p)=\sigma^*} 2^{-|p|}$$

ここで、 $U$ は万能単調機械(universal monotone machine)で、 $U(p) = \sigma^*$ は出力が $\sigma$ から始まることを意味する。

$M(\sigma)$ は $\sigma$ が単純であれば大きくなる。

## 定理

上記で定義した  $M$  は、最適な c.e. 半測度となる。

複雑性から作られた事前分布が最適な予測を与えることが分かる。

# 確率の哲学

## 疑問

アルゴリズム的確率(Algorithmic Probability, AP)は確率の哲学の文脈ではどう評価されるのか？

- APは主観説か？デュエム-クワイン問題を解決しているか？クロムウェルの規則に従っているか？
- APは頻度説や傾向説と解釈できるか？
- APはaleatoryかepistemicか？
- No Free Lunch定理との関係は？(議論済み)
- Nicod's criterionに従うか？(議論済み)
- Pure inductive logicでの公理はどうか？
- 機械学習における更新とベイズ更新との関係は？

APは主観説と客観説の両面を併せ持つ。

- 枠組みは主観説であり，観察が少ないときは，確率の値が万能機械の取り方に依存する。
- 一方，観察が多いときは，万能機械の取り方に依らずに，真の分布に近づく。
- すべての計算可能な測度に対して収束するので，「主観的すぎる」という批判は当たらず，クロムウェルの規則に弱い意味で従う。

- 事前分布に主観的な要素は入らないので、デュエム-クワイン問題についても自動的に解決される。
- Grueのパラドックスについても、複雑性の観点から説明できる。
- ただし、考察する空間や言語にどう依存するかについては、議論が進んでいない。
- 観察から学習するという意味でepistemicな確率だと思うが、複雑さを考察する中で構造やパターンを見つけ、aleatory的な要素が加味される。ここについても議論が必要。

- Rathmanner, S., & Hutter, M. (2011). A Philosophical Treatise of Universal Induction. *Entropy*, 13 (6), 1076–1136.  
<https://doi.org/10.3390/e13061076>