

哲学研究

第六百六号

統計学はなぜ哲学の問題になるのか

大塚 淳

一 はじめに

あらゆる事柄に関するデータが収集され「ビッグデータ」として活用される今日の高度情報化社会において、統計学はますます重要な地位を占めてきている。20世紀において、統計学は科学的方法論の中枢を担ってきた。また21世紀に入り急速に発展してきた機械学習技術は、音声・画像認識、購買履歴に基づいたレコメンドシステム、認証技術や自動運転などを通じて、我々の生活の隅々にまで浸透しようとしている。

こうした統計学および機械学習の急速な発展は、もちろん人文系の学者にとつても無関係なものではない。現に、AIやコンピュータが人間に替わり判断を行う、あるいは特定の判断に繋がりやすい情報を選択的に提示することの法的小よび倫理的含意については、様々な仕方で議論が呼び起こされている。しかし社会的影響についての議論を別として、統計学や機械学習の手法や考え方自体の哲学的含意を分析する論考は、少なくとも本邦において

はあまり現れてこなかったというのが実情であろう。⁽¹⁾これは、哲学・統計学の双方にとつて非常に不幸なことであると思われる。というのも、統計学には、哲学者が伝統的に論じてきた問題や、それを考える上での具体的なヒントが様々な形で表れ出ているからであり、また逆に、哲学的な議論を参照することによつて、統計学の考え方やそれが直面する問題がクリアに把握されることもあるからである。本稿ではこうした観点から、昨⁽²⁾年上梓した小著の内容を部分的に紹介する形で、統計学と哲学の双方向的関係性について考察してみたい。

統計学の重要性は、それが現代における標準的な帰納推論の枠組みを与える点にある。かいつまんでいえば、統計学とは与えられたデータから未観測の事象について推論する手立てを与える数理理論である。一方ヒューム以来、哲学者は帰納推論の可能性とその条件について長らく論じてきた。現代数理統計学は、ヒュームの懐疑論に肯定的な答えを与えるわけではない。しかしながらそれは、一定の数理的仮定を置くことによつて、その枠組みの範囲内で、帰納推論を定式化し、その精度を評価することを可能にする。統計学を具体的問題に適用するとき、科学者は世界や対象をそうした数理的仮定に従うものとして、つまりそうした数学的構造を有するものとして捉えている。これは世界に対するある種の存在論的態度と言えよう。であれば、それがどのような存在論なのか、つまり種々の統計学的手法はどのような存在論的要請を持つのかということが第一の哲学的問題になる。

統計学は、そうした存在論的前提を確率論の用語によつて定式化する。しかしそれは数学的構造であり、現実の対象ではない。ここから、前者を後者によつて解釈する意味論的問題が生じる。具体的には、確率とは何を意味するか、因果関係とは何か、あるいは統計的検定において広く用いられている「p値」とは何か、というような問題群は、この意味論的関心に基づく。

最後に、統計学の本丸は、そのように措定され、解釈された数学的構造をデータから推論することに存する。この推論は帰納的であり、推論対象についての確実な答えを与えてくれるわけではない。そうでありながらも、我々

は統計的手法がいずれかの仮説をデータから正当化してくれることを期待している。では、それらの手法はどのような意味で対象についての知識を我々に与え、また仮説を正当化してくれるのだろうか。こうした問題は、プラトン以来の認識論の伝統的課題である。ここに、統計学が持つ三つ目の哲学的側面、すなわち認識論的側面が現れる。前述の拙著では、ベイズ統計や古典統計、予測理論、機械学習、因果推論などの様々な統計学的理論に対し、この存在論的・意味論的・認識論的という三つの哲学的側面から分析を加えた。しかしここでは紙幅の都合上、存在論と認識論という側面を絞った上で、上掲書での議論を部分的に紹介したい。

二 統計学における存在論的問題

ヒュームが喝破したように、帰納推論を行うためには、与えられた現象／データ以上のものを世界の側に仮定しなければならない。自然の斉一性は、そうした存在論的仮定の最たるものである。しかしそれだけではない。統計学では帰納推論を行うために、斉一性としての確率モデルに加え、さらなる仮定を加えるのが一般的であり、そうした存在論的仮定の強弱によって、扱える推論の幅が決まってくる。この節では、統計学で導入される種々の存在論的前提と、その評価基準について考察しよう。

二・一 自然の斉一性としての確率モデル

治験結果を元に薬効の有無を判断する／気象データから明日の天気を予測する／出口調査から選挙結果を判断する等々、我々の社会における多くの判断は統計的推論に基づいている。このように与えられたデータから未観測の事象を推測する統計的枠組みを、推測統計 (inferential statistics) と呼ぶ。推測統計は基本的に帰納推論の枠組みであり、よってそこにはヒュームが指摘した困難が直接当てはまる。ヒュームは、帰納推論を行うためには、現象の

背後に自然の斉一性 (uniformity of nature) を想定しなければならぬと指摘したのであった (Hume, 1739)。推測統計においてこの斉一性の役割を果たすのが、確率モデル (probability model) である。確率モデルは、観測されるデータが引き出される (サンプルされる) もととなる空間 (標本空間 sample space) を、確率論の用語によって定式化したものである。よってそこには観察されたデータだけでなく、将来観測されるであろう、あるいは決して観測されずに留まるかもしれない可能性もすべて含まれている。重要なのは、複数のサンプリングを通して、この確率モデル自体は同一に留まるという想定である。この斉一性の仮定を置くことによって、得られたデータを用いてこのモデルの内実を推論することを通じて未だ見ぬ事象を推測する、という推測統計の戦略が正当化される (図1)。

もう少しこの確率モデルの内実に分け入ってみよう。確率モデルは標本空間およびその上の確率関数から構成される。⁽³⁾ 標本空間は、我々が「事象」と呼ぶものを部分集合として含む集合である。例えば「サイコロを1回投げて偶数の目が出る」という事象は {1, 2, 3, 4, 5, 6} からなる標本空間の部分集合 {2, 4, 6} として表せる。確率 P とはこのような部分集合としての事象にその「大きさ」を 0 から 1 までの範囲で与える、つまりその大きさを「測る」関数である。よく知られた

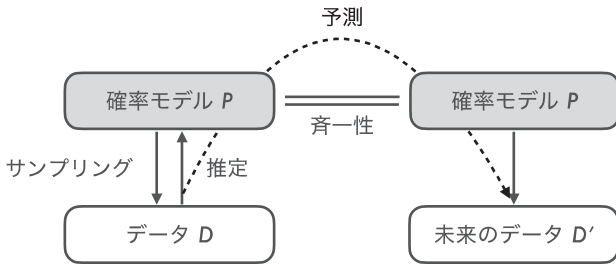


図1：推測統計において、データは確率モデルからの部分的抽出として扱われる。確率モデルは直接は観察されず、データから帰納的に推論されるのみである。この確率モデルが斉一的に留まるという仮定を置くことで、既知のデータから未知のデータへの予測が根拠付けられる。

確率の公理とは、この関数が「大きさ」のメジャー（測度）になつてゐるために最低限満たしておいてほしい条件をまとめたものだとして理解できる。

こうした確率モデルは、ヒューム以来の哲学者が「自然の斉一性」という名で呼び表してきたものを、確率論の用語を用いて数学的にモデル化したものだと言えよう。よつて統計学者が帰納推論を行うとき、彼女らもまたこの意味において、自然の斉一性がデータの背後に存在すると想定してゐることになる。これは一般に「真のモデル」と呼ばれる。

自然の斉一性を確率の用語によつて書き表すことで、そこから様々な帰結を導くことができる。有名どころとしては、コインを無限に投げ続けたときの表の相対頻度はその「真なる確率」に漸近していくという大数の法則や、どのような試行であれ平均をとると、その分布は正規分布に近づくという中心極限定理などが挙げられよう。これは、単に斉一性が成立してゐる（考察対象が一つの不変的な確率モデルとして記述できる）という想定のみから導かれる理論的結果である。「のみ」といふのは、こうした結果に必要なのは単に確率モデルがあるということだけであり、それがどのようなものであるかについて（つまり「真のモデル」がどのようなものであるかについて）我々が知っている必要はないということだ。実際のところ、我々は確率モデルの全貌を観測することはできず、「真のモデル」は我々には常に隠されてゐる。しかしその内実について全く情報を欠いていたとしても、単に斉一性が成立しているという存在論的前提のみから、帰納推論についての一定の保証を与えることができる。このことを上の法則や定理は示してゐる。

二・二 自然種としての統計モデル

しかしながら、斉一性が保証してくれる漸近定理が有効になるのは、基本的には大標本のみであり、それほど多

くのサンプルを取れない科学的推論においては現実的な解たりえないことが多い。その場合、統計学者はさらに踏み込んで、斉一性の内実自体に仮定を立てる。この仮定は統計モデル (statistical model) と呼ばれ、斉一性として立てた確率関数を、有限個のパラメータを持つ関数として明示的に書き下すことで得られる。例えば有名な正規分布は、平均 μ と分散 σ^2 という二つのパラメータによって定まる関数として、次のように書き下せる…

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

パラメータ μ, σ を定めてやった上で、上式の x に様々な値を代入すると、その確率 $p(x)$ が得られ、それをプロットするとお馴染みの釣り鐘型のグラフが出来上がる。先に述べたように、斉一性/確率モデルを想定したからといって、その確率関数が実際にどのような形なのかは誰にもわからない。そうであっても、その関数はだいたいどのような関数形で書けるだろうとアタリをつけるのが、統計モデルの役割である。

統計モデルとして仮定される関数には、上述した正規分布の他、ベルヌーイ分布、二項分布、ウィッシュヤート分布等、様々な形がありうる。こうした関数形の様々な種類を、分布族 (families of distribution) と呼ぶ。またこのように名前が定まった分布族の他、変数間の関係を方程式によって表す回帰モデルなども統計モデルの重要な事例である。

確率モデルの想定に加え、それをさらに統計モデルを用いてモデル化することの利点はどこにあるのか。最大の利点は、それによって隠された斉一性のあり方について、より踏み込んだ推論ができるようになることである。確率関数が有限数のパラメータを持つ関数の形で書けると想定することで、確率モデルについての推論を、パラメータの具体的な値についての推論に落とし込むことができる。例えば、対象が正規分布に従うと仮定できるのであれば、その平均と分散を推定するだけで確率モデルを同定できることになる。つまり自然の斉一性についての統計的

仮説が、数個のパラメータの値に関する仮説に還元される。これをもとに、データからパラメータを推定することによって、自然の斉一性のあり方を推定し、かつそれを元にして未観測事象を予測する、という方法が開けるのである。こうした推測統計の方法を、パラメトリック統計と呼ぶ。

統計モデルとは、それ自体は複雑で捉えどころのない「真の確率」を、明示的な名と数式によって切り出すものだと言える。その意味においてこれは、哲学の文脈で「自然種 (natural kind)」と呼ばれてきたものに近い。例えば我々は「金属」という自然種(化学種)によって、混沌とした現実世界の内のいくつかの部分(つまり、我々が普段「金属」という語によって指し示す対象)を切り出す。その時我々は、その金属とされるものが共通して持つ何らかの特徴を念頭におき、それによって事物を分類している。さらに金属は複数のパラメータを持ち、それを同定することで、対象となる物質を(例えば「金」や「鉄」などとして)一意的に同定することもできる。こうすることで、単に対象を同定するだけでなく、その対象がどのようにふるまうのか(例えば磁石を近づけたら、王水に入れたら、どうなるのか)を帰納的に予測することができる。

統計モデルは、まさにこうした自然種と同様の役割を統計的推論において果たす。つまりそれは様々な帰納問題を類別する「種 (kinds)」として機能する。例えばコイン投げのように二つの結果を持つ試行であれば、ベルヌーイ分布によるモデル化が適切だろう。他の事象、例えば身長などであれば、正規分布が適切かもしれない。化学者が試薬を分子式によって識別するように、統計学者は帰納問題を統計モデル(分布族)によって分類する。また化学者がそのように同定された分子式から試薬の反応を予測するように、統計学者は推定された分布から将来サンプルされるであろう事象を予測する。このように統計モデルは、統計学における自然種、いわば確率種 (probabilistic kind)としての役割を担っている。これは、単に自然の斉一性を想定するだけでなく、それを特定の離散的な種類へと分類・還元するという意味で、より強い存在論的前提を体现している。パラメトリック統計は、こうしたより

強い存在論的想定を立てることによって、よりきめの細かい推論を可能にするのである。

二・三 確率種の良さとリアルパターン

では上述したような存在論的前提の「良さ」はどのようにして評価されるのだろうか。それは我々が自然種に何を期待するかによって決まってくる。自然種に対する最も一般的な期待は、それが世界の真のあり方を忠実に反映している、ということだろう。実際、化学者が金と銀を分けるとき、それは物質世界の客観的な区別を反映していると我々は期待する。統計学においても同様に、仮定された自然の斉一性の性質をできるだけ正しく捉えることは重要であるように思われる。なんとすれば、図1で示したように、我々はそうした斉一性の把握を通じてのみ観測の事象に対する予測を立てることができるからである。

もしそうだとすると、対象をできるだけ精緻に記述できるような詳細な統計モデルこそが「良い」確率種である、という還元主義的な結論が導かれるように思われる。モデルの詳細さの代表的な指標として、パラメータの数がある。例えばある一つの性質(例えば年収)を予測するために、他の一つの性質(年齢)のみを用いる線形モデルと、それに加えて学歴も考慮するモデルでは、後者の方が一つ余計にパラメータを持ち、その分粒度が高い。これを敷衍すれば、できるだけ多くの性質を詰め込んだモデルの方が年収についてのより良い予測を提供してくれるだろうと結論したくなるかもしれない。

しかしながら、実際には必ずしもそうではない。赤池弘次が示した情報量規準(AIC; Akaike Information Criterion)の観点からは、多すぎるパラメータはかえってモデルの予測性能(汎化性能)に対するペナルティとして働く(Akaike, 1974; 赤池ほか, 2007)。詳細は省くが、詳細すぎるモデルは、柔軟すぎるがゆえに、データに含まれるノイズを拾ってしまい、手持ちのデータに過剰適合(overfit)してしまうのである。したがってこの観点からは、適

度に粒度を落とした荒いモデルの方が、より予測性能が高い、「良い」モデルでありうるという可能性が示唆されるのである。

赤池の理論は、自然種に対して我々が期待するもう一つのあり方を反映している。すなわちそれは、自然種は現象の予測に役立つものでなければならぬ、という期待である。例えば我々が日常においてカラスを一つの生物種として捉え、それを単なる原子や細胞の集積物として見ないのは、前者の捉え方のほうがより豊かな予測を我々に与えてくれるからである。デネットは、我々の予測関心に基づいて切り出されるこのようなまとまりを、リアル・パターンと呼んだ(Dennett, 1991)。例えば、「カラス」は物理学的には随分と曖昧で不正確な一般化かもしれないが、我々の日々の予測関心に良く合致する限りにおいて、十分リアルな存在である。ここで含意されているのは、我々の存在論が予測というプラグマティックな関心に基づいて編成されているという考え方である。AICを始めとしたモデルの汎化性能を重視したモデル選択規準は、こうしたリアル・パターンとしての自然種の「良さ」を計るものだと考えることができるだろう。

二・四 機械学習の存在論

プラグマティズム的存在論が含意するのは、存在の区分(何が良い自然種と認められるか)が我々の予測関心と認識的制約によって決まり得るということである。ラプラスの悪魔のような存在であれば、「カラス」などという概念に頼らずとも、物理的状态のみから任意の精度で将来を予測することができるかもしれない。つまり何が「自然種」として認められるかは認識者に相対的にのみ定まるといふことになる。

近年急速に研究が進んでいる深層学習(deep learning)は、このことの可能性をより鮮やかに示唆する。深層学習で扱われるモデルは極めて巨大であり、そのパラメータの数は多いもので数千億個に達する。前述のように、こ

のように複雑なモデルは通常そのままでは過剰適合を起こし、大した汎化性能を期待できない。その問題を、モデルの構造上の工夫、学習手法の改良、そしてとりわけ大量のデータによる学習などによって解決したのが、近年の深層学習モデルである。そのような大量のデータによって裏付けられた深層モデルは、我々の理解を遙かに超えた粒度で自然の斉一性を捉えていると言えよう。深層モデルに対してしばしば向けられる「ブラックボックス」という批判は、こうした点に起因している。つまり我々は自然種に対して、ある種の「扱いやすさ」や法則性を期待している。例えばメンデレーエフの周期表は、単に様々な化学種を分類するだけでなく、その分類の規則性を開示するという点でも我々の理解に寄与している。一方、深層学習によって得られるモデルは、仮に現象の斉一性を高い精度で捉えていたとしても、我々にこうした理解を与えてくれない。つまり、そのモデルのどの部分が対象の何に対応し、どのパラメータを変えると何が帰結するのかということについて、明示的な解を与えてくれないのである。こうして深層学習は、予測力と理解可能性のトレードオフを我々に突きつける。伝統的な科学観においては、両者は常に一体であった。しかし深層学習は、その強力な予測力と引き換えに理解可能性の放棄を我々に迫っているように思える。そのように理解可能性を欠いたかたまりをそれでもなお一つの「自然種」という存在論的単位として認めるのかどうかということは、哲学的に吟味されるべき問題であろう。

またこれに加え、深層学習はもう一つの興味深い存在論的問題を提起する。それは、深層学習モデル自体が、データの中から一つのパターン、ないしは独自の「自然種」を発見する認識者として考えられるという可能性である。例えば画像認識モデルは、与えられたデータから「猫」や「自動車」などといった対象を学習し、判別することができるようになる。あるいは近年囲碁において世界トップ棋士を打ち負かしたAlpha Go⁶、人間の棋士には未だ理解できないような囲碁の「型」を見出しているのかもしれない。実際、モデルが入力データから適切に対象を切り分け認識しているということは、例えば自動運転技術などの実用化にとつて、必要不可欠な前提である。

よって当然、深層モデルがデータからどのような「存在論」を構築しているのかということは、単に学術的関心のみならずその実践・応用の観点からも問われるべき問題である。

この点で興味深い問題として、敵対的事例 (adversarial example) と呼ばれる現象がある。これは元画像 (例えばパンダ) に、我々の目には全く違いが見いだせないようなノイズを乗せることによって、モデルが誤った判断をしてしまう (例えばそれをテナガザルだと認識する) という事例である。より深刻な事例としては、道路標識にステッカーを貼ることで、特定の自動運転システムに誤動作を引き起こさせるような可能性が指摘されている。こうした敵対的事例の存在が示唆しているのは、一見我々と同じように判断しているかに見える深層モデルが、実は我々とは全く異なった存在論を構築している、という可能性である。つまり我々が「パンダ」という概念で抜き出しているパターンと、深層学習モデルがそう判断するパターンは、たとえそれがこれまでのデータにおいて完全に一致していたとしても、実は全く異なるものかもしれない。これはクリプキが論じた、いわゆる「ウイトゲンシュタインの足し算のパラドクス」の実際例に他ならない (飯田, 2016)。敵対的事例は、この哲学的パラドクスが単に原理的な可能性ではなく実際に起こりうる問題であること、そしてその解決は深層モデルの社会的応用にとっても重要な課題であることを示している。

これはもちろん、足し算のパラドクスが解決されない限り深層モデルの社会応用を認めるべきではない、ということではない。しかしそうした現象が生ずる可能性を認めた上で、それが起こることを防ぐ手立ては考えられるべきであろう。つまり我々は、深層モデルの存在論を読み解き、我々のそれとすり合わせる必要がある。しかしそもそも、深層モデルが異なる自然種概念を用いているかどうかということを、我々が知る手立てはあるのだろうか。これはまさに、クワインが翻訳の不確定性として提示した問題に他ならない (Quine, 1960)。実際、モデルの評価はある種の根底的翻訳を内包しているといえる。モデルが「猫」とラベル付けするものは、我々がその概念によつ

て理解しているあの動物と同一だろうか？実はそれは単に猫に特徴的な性質や背景の組み合わせに反応しているだけかもしれない(Xiao et al., 2020)、あるいはより複雑に「猫性がそこに顕在化している」と考えているのかもしれない。クワインが翻訳の不確定性の議論によって示唆するのは、このような可能性のうちどれが「正しい」かは一意的には定まらない、あるいはそもそも唯一の正解のようなものは存在しない、という可能性である。であるとすれば、深層モデルの判断根拠を説明しようとする「理解可能なAI (Explainable AI: XAI)」の試み(原, 2018)も、同様に答えの無い探求ということになるだろう。

しかし仮にそうであったとしても、そうした探求を無用として片付けてしまうのは、赤子を産湯とともに流すような行いである。なんととなれば、存在論は、我々の他者理解の根底にあるからである。我々は全く存在論を共有しないもののふるまいを予測することができない。人間だけでなく、他の生物、例えば低空飛行で向かってくるカラスが次に何をするかを予測するのにも、そもそもカラスがどのようなモノを認識しているのかについての理解が不可欠である。同様に、自動運転技術に用いられる動体認識モデルがどのようなモノを存在として認めているのかがある程度知られない限り、我々はそれに自らの生命を預ける気にはならないだろう。そのような意味で、機械学習にまつわる存在論的問題は、哲学的関心を惹くだけでなく、その社会的応用にとっても重要な含意を持つのである。

三 統計学における認識論的問題

続いて、統計学における認識論的側面に少し目を向けてみたい。統計学と認識論の組み合わせは、それほど突飛なものとしては映らないであろう。実際、両者はともに、科学的仮説や信念を正当化するという共通の役割ないし動機を有している。古くはプラトンが『メノン』において示したように、知識とは単に正しい信念ではない。同様

に、単に正しいと判明した仮説と科学的知識を同一視するわけにはいかない。科学的な知見とみなされるためには、仮説は然るべき方法で正当化されていなければならない。それゆえ多くの科学論文は「材料と方法 (materials and methods、いわゆる「マテメソ）」に一節を割き、当該論文で示された結果を正当化するための手段を明示するのである。

統計学は、この科学的知見の正当化プロセスのうち、特に得られたデータから結論を導くその過程において、特権的な役割を担っている。全ての科学的仮説は蓋然的であり、論理的必然性をもって結果を保証するものではない。したがって仮説に有利な結果が観察されたときでも、それが仮説によって想定されている事態とは全く関係なく単に偶然によって生じたという可能性を排除できない。そのような「まぐれ当たり」を排除し、観察や実験結果が真に仮説をサポートするものかどうかを判断するために、統計的方法が必要とされるのである。

では、そうした正当化はどのようになされるのであろうか。実のところ、統計学的方法論は一枚岩ではない。有名なところでは、仮説検定に代表される古典的統計理論や、ベイズ定理に根ざすベイズ統計など、様々な流派が存在している。それぞれの流派は、核とされる数理的方法論のみならず、どのような意味においてそうした数理理論が経験的仮説の確証や反証になるのかという、いわばその正当化概念においても考え方を異にしている。前掲の拙著では、そうした違いが、ちょうど哲学的認識論における二つの対立的立場、すなわち内在主義と外在主義に対応すると論じた。以下ではそれをかいつまんで説明することで、統計学と認識論の間の並行関係を素描してみたい。

三・一 内在主義認識論としてのベイズ統計

ベイズ統計は、仮説の検証プロセスを、仮説の確率を証拠に基づいてアップデートしていく過程として捉える。

ここで「仮説の確率」とは何かという意味論的問題は本稿では割愛するが、一般的には、ある認識者、例えば探求

主体である科学者が当該仮説に対して持つ「信念の度合い」として解釈されることが多い。アップデートの手引に用いられるのが、ベイズの定理である。この定理は、証拠を得る前の仮説の確率（事前確率：prior probability）と、仮説を仮定したときの証拠の得られやすさ（尤度：likelihood）から、証拠を得た後の仮説の確率（事後確率：posterior probability）を導く。前二者が大きい仮説の方が事後確率が大きくなり、よって良く支持されるということになる。

実のところ、この事後確率の計算過程自体には帰納的なところは一つもない。むしろベイズ定理は確率論から帰結する数学的定理であり、それを用いた事後確率の計算はれっきとした演繹推論である。ではなぜ、そうした演繹推論によって経験的仮説を確証ないし反証できるのであろうか。

この背景にあるのが、ベイズ統計の認識論的な想定である。上の素描に従えば、ベイズ的な推論とは、事前確率と尤度という前提から、事後確率という結論をベイズ定理という推論規則によって導く過程であると捉えられる。つまりベイズの正当化とは、仮説についての確率評価を手持ちの前提と証拠から整合的に導くことである。これは、一般に内在主義的（internalist）と言われる認識論的立場の正当化概念と類似している。内在主義によれば、主体の信念が正当化されるのは、本人がその信念の理由ないし証拠をしっかりと把握しており、そうした根拠から当該の信念が適切な推論過程を経て導かれるときだとされる（戸田山、2002）。例えばもし私が「邪馬台国の都は九州にあったことを知っている」と主張するのだとしたら、何らかの証拠となる状況を私が把握しており、かつ私がその証拠から九州説を引き出すために用いた推論が適切であることが期待されるだろう。また逆に、適切な推論関係を有した根拠を有しているのであれば、主体の信念は正当化される、と内在主義者は考える。そうだとすれば同様に、科学者が適切な前提（事前確率および尤度）からベイズ推論という適切な推論規則を用いて仮説の事後確率を評価するとき、その評価（すなわち仮説がもつともらしいか、あるいはそうでないかという判断）は、内在主義的

な意味で正当化されている、と考えることができるだろう。

ここでさまざま問題になるのは、ではそもそも適切な前提とは何か、ということである。例えば私が邪馬台国九州説の根拠として挙げるものがいかかわしいオカルト雑誌の記事だけだったとしたら、たとえその記事内容自体は九州説を示唆するものだったとしても、私の仮説は正当化されているとは到底言えないだろう。同様に、ベイズ推論によって事後確率を「正当化」しても、前提となる事前確率や尤度が適切でなかったとしたら、それは正真正当化とは認められないだろう。

これに対しすぐ思いつく手立ては、推論の前提はそれ自体正当化されていなければならない、という条件を付けることである。しかしこれはすぐさま正当化の遡行問題 (regress problem) を引き起こす。つまり、ある結論を正当化するためにはまずその前提を正当化せねばならず、そのためにはさらにその前提を……というように無限の正当化の過程が要請されることになってしまうのである。一部の内在主義者は、こうした遡行を防ぐために、それ以上の正当化を必要としない基礎的信念の存在を認めてきた。基礎的信念の候補としては、数学的真理やコギトなど、それ自体において十分明証であるような信念や、「私には今黒い点が見えている」といった直接知覚経験が挙げられてきた。前者はアプリアリ、後者はアポステリオリな方法だと言えよう。こうした基礎的信念によって遡行問題を防ごうとする立場は、基礎付け主義 (foundationalism) と呼ばれる。

ベイズ統計にも、似たような考え方が認められる。ベイズ推論の前提のうち、とりわけ問題視されてきたのは事前確率である。というのも、もう一方の尤度は前節で述べた統計モデル／確率種の想定であり、他の統計的手法でも一般的に要請されるものであるのに対し、事前確率はベイズ特有の前提だからである。よってこの事前確率をどのように正当化するかということは、ベイズ統計の正当性をめぐる議論においても焦眉の課題であった。

基礎付け主義的認識論において二種類の基礎的信念が見られたように、事前確率の正当化にも二つの戦略が考え

られる。一つはアプリオリな戦略であり、いかなる仮説についての臆見も反映しないよう、全く無情報となるような仕方です。事前確率を定めるものである。これを無情報事前分布と呼ぶ。もう一つの戦略はアポステリオリなものであり、何らかのデータがあったとき、このデータに合わせる形で事前確率を定めるものである。例えば、私がある疾患にかかっている確率はどれくらいであろうか。もしこれを無情報として（かかっているかかかっていないかはどちらも二つに一つなのだから）0.5としてしまったら、検査結果から大いに誇張された決断を引き出すことになってしまっただろう。もしその疾患が稀であると分かっているのであれば、事前確率も相応の低さに設定すべきである。このように、経験的データに合わせて事前確率やモデルを設定する手法を、経験ベイズと呼ぶ。これは哲学的に見れば、何らかのデータをそれ以上来歴を問わない「所与 (given)」とみなして、それを前提の根拠に据えるということにほかならない。これは一見まっとうに思えるが、しかしそもそも事前確率をデータに合わせるとはどのようなことか、またなぜそのような手続きが正当化されるのか、ということを問い始めると、一筋縄ではない問題群に直面する。そしてそれは、認識論の文脈においてセラーズ (Sellars, 1997) が批判した「所与の神話」とちょうど同様の問題構造を持つのである。

三・二 外在的認識論としての古典統計

ベイズ統計では仮説の確率を考え、証拠に基づきそれをアップデートする。一方、古典統計においては、仮説の確率というものは考えない。仮説とは世界のあり方を示すものである限り、それは成り立っているか否かどちらかなのであり、その「度合い」のようなものを想定するのはナンセンスだと考えるのが古典統計の立場である。古典統計において確率が割り当てられるのはデータである。ある仮説を仮定したときに、どのような結果が得られやすいか。その仮定のもとであまりにもありそうにない、稀なデータが得られたとしたら、もともとの仮説に何かおか

しいところがあるに違いない。そのように考えて仮説の成否を検証するのが、古典統計の要をなす仮説検定の考え方である。

これは一見したところ、ポパーの反証主義の考え方に似ている。反証主義においては、仮説 H_0 からある予測 H_1 が含意されるとき、その予測が失敗 $\neg H_1$ すれば仮説が反証されるとする。ただしこの推論が妥当であるためには、仮説 H_0 を完全に含意しなければならぬ。それがあくまで蓋然にとどまる場合、 $\neg H_1$ は H_0 を含意しないし、また H_0 の確率が低い、つまり $P(H_0|\neg H_1)$ が低いということも導かれぬ(Sober, 2008)⁽⁵⁾。よって反証主義の考え方はそのままでは統計的仮説の検定として用いることができない。

統計的検定理論では、これを回避するために帰無仮説と対立仮説という、二つの相反する仮説を考える。例えば新薬開発において、新薬に効果がない(新薬を投与した群と対照群の間で差がない)という仮説を帰無仮説 H_0 、効果がある(二群に差が見られる)という仮説を対立仮説 H_1 としよう。このときデータに基づいて帰無仮説を棄却することができるか、というのが我々の関心である。常識的には、観測された差が大きいほど、 H_0 を退ける根拠になりそうである。しかし結果は蓋然的であるので、こうした判断には常に間違いの可能性がつきまとう。一つは、実際には効果がない(H_0 が真である)のに効果があると誤って判断してしまう(H_0 を棄却してしまう)第一種の誤り(type I error)であり、もう一つは実際に効果がある(H_1 が真である)のにも関わらず効果無しと判定してしまう(H_0 を棄却できない)第二種の誤り(type II error)である。検定の要は、この二つの誤りの確率をできるだけ下げないように判断基準を設定することにある。特に第一種の誤りを犯す確率は有意水準(significance level)と呼ばれ、これを低く(例えば5%等)抑えることが重要視される。これはすなわち、偶然に帰無仮説 H_0 を棄却してしまうことなるべく防ぐということである。よってそうした検定を用いてもなお帰無仮説が棄却されるとしたら、それは偶然ではない確率が高く、その結果も信頼できるとみなせるだろう。こうした考え方により、検定理論

は仮説の棄却という判断を正当化するのである。

しかしながら、こうした手続はどのような意味で「この薬には効果がある」という仮説を正当化するのだろうか。古典統計の正当化の根拠は、仮説判定装置としての検定の信頼性に求められる。検定とは、つまるところデータを入力したときに結論（帰無仮説の棄却／非棄却）を返す装置（関数）として考えられる。この装置は、一定の偽陽性（第一種の誤り）率と偽陰性（第二種の誤り）率を持つ。その中でも、両誤り率が低い検定装置は、偽陽性率と偽陰性率が低い医療検査器具が信頼に足ると我々が考えるように、高い信頼性を持っていると言えるだろう。そして古典統計においては、こうした信頼性が高い検定によって得られた結論が、正当化されるのであった。これは認識論においては、外在主義、とりわけ信頼性主義（reliabilism）と呼ばれる立場に呼応する（Goldman & Beddor, 2016; 戸田山, 2002）。外在主義は、内在主義とは異なり、認識主体はその根拠や用いた推論規則をすべて内に有していなければならぬ、という要件を課さない。主体がたとえ根拠の正当性について無知であったとしても、実際問題としてその根拠が正当なのであれば、それをもって正当化は成立する、と考えるのである。ところで検定は、認識主体たる科学者がその推論において用いる主要な根拠の一つであろう。そして古典統計理論は、その手続きが実際のところどの程度信頼できるのかということを、二つの誤り確率という形で評価する。そしてその誤り確率が低い、つまり信頼性が高いとき、それを用いて得られた結論は、外在主義的な意味で正当化されていると言っているのである。

検定理論のこうした外在主義的な正当化概念を、我々はどう評価すべきだろうか。外在主義に対して向けられる懸念は、認識主体がその結論に対し無責任に過ぎないか、ということである。つまり根拠を外界に「丸投げ」してしまうことよって、外在主義者はその結論が実際に正しいものであるのかについての責任も放棄してしまっているのではないか。これと同様の批判が、近年、検定理論に対しても向けられている。検定理論は20世紀以来、科学

的推論の標準的方法としての地位を保ってきた。その過程において手続きは規格化・パッケージ化され、現在ではデータを入力するだけで簡単に仮説検定を行えるようなソフトも一般化されている。また科学コミュニティにおいても、そうした検定において一定の基準を満たした（ p 値が低い）結論は正しいものとして、無批判的に学術誌に掲載され、受け入れられてきた。しかしこうした検定プロセスの無批判的な使用は、誤用や誤った解釈を生み、結果として再現性の無い研究結果が量産されることにつながったという懸念が指摘されている。こうした「 p 値問題」および「再現性の危機」は近年科学コミュニティの間でも大きな問題となっており、アメリカ統計学会も検定の使用についての注意喚起を行うなど（Massestein & Lazar, 2016）、長らく科学的推論においてヘゲモニーを握ってきた古典統計理論自体の信頼性を問い直す動きが広まっている。

哲学的観点からは、こうした懸念は古典統計の外在的性格に起因するものだと捉えることができる。前述のように、検定理論による正当化は判断に用いられる検定の信頼性に起因する。古典統計理論はこの信頼性を確率的に見積もるのだが、その見積もりは空から降ってくるわけではなく、様々な前提に基づいている。そうした前提には、「確率種」（二・二節）として統計モデルの想定や、実験結果の正しい取り扱いなどが含まれる。もしこれらの前提が成り立っていないならば、当然、そこから導かれる信頼性の見積もりも机上の空論でしかない。しかしながら、単に得られたデータを統計ソフトに入力して結論を導くような「推論過程」では、こうした前提はすべて外的なものとして扱われ、批判的な検討を免れてしまう。上述の再現性問題の一端は、このような前提の吟味を外部に押し付け、あるいは有耶無耶にするような無責任な検定の使用に求められるだろう。これが示唆するのは、統計的検定の使用は、それによって正しい判断に至るためには（つまりその正当化概念が真理促進的 truth-conducive であるためには）、その前提について完全に外的であってはならないということだ。そしてこれは、外在主義に対して向けられる批判と軌を一にしている。つまり仮に正当化の源泉が認識／検定プロセスの信頼性にあるとしても、我々はそ

れを完全に外的なものとして吟味の対象から外してしまうことはできないのである。

三・三 認識論と統計学

以上、我々は現代統計学における主要な立場であるベイズ統計と古典統計を、認識論的内在主義と外在主義という観点から分析してきた。そこで明らかになったのは、正当化概念、すなわち仮説を科学的知見として受けいれるためにはどのような手続きを踏むべきかということに関する、両者の見解の相違である。20世紀において繰り広げられてきた両者の間の激しい論争の一部は、こうした哲学的相違に起因している。確かに、20世紀後半からのよりプラグマティックな統計手法（二・三節）の興隆および現代の機械学習（二・四節）の発展により、近年ではこうした議論は徐々に下火になりつつあり、またその意義も見えにくくなっている。しかしだからといって、それを現在の立場から時代遅れのドグマとして一方的に断罪するのはホイッグ史観の誹りを免れないだろう。今日に至る統計学の源流を築き、またその流れを發展させてきた議論の内実を理解し、公正に評価するためにも、その背景に控える哲学的前提に留意することが重要なのである。

またそもそもこうした哲学的議論は、現代統計学においてその意義が失われたわけでは決してない。確かに、数学的理論としての現代統計学は、20世紀から飛躍的な進歩を遂げてきた。しかし統計学は、単に数学の内に閉じるわけではない。なぜ演繹的体系である数理統計学が、現実の対象に適用され、未知の事柄について推論する手引きを与えてくれるのか。数学自体はこうした哲学的問いに答えを与えてくれない以上、そこには「泥臭い」哲学的思索や前提がどうしても必要になってくるのである。もし統計学がこの哲学的前提への反省を放棄するとしたら、それこそ一つのドグマを盲信する愚を犯すことになるだろう。

そうした反省の必要性は、数学的に高度に發展した現代統計学において、少なくなるところか、より一層増して

いるように思える。例えば、二・四節で紹介した機械学習理論の急速な発展は、伝統的統計学のそれとは異なる、新しい正当化概念を要請する。我々はいかにして、我々の知性では到底把握しきれない複雑さを持つ機械が大量のデータを用いて生成する結論を、「正当化」されたものとして扱うことができるのだろうか。またそのような結論を土台にして科学が作られるとき、我々の科学観はどのように変化していくのだろうか。これらは認識的問題であるが、今後機械学習技術が社会に応用されていくにつれ、法的・倫理的な問題も不可避的に伴う。例えば現在、医薬品が承認されるためには統計的検定の実施が義務付けられているが、これは承認の正当性が（一部のせよ）前節で紹介した統計的検定の正当化概念に基礎づけられているということを意味している。このように、統計的正当化は我々の社会における様々な正当化、この場合では法的正当化に浸透している。であるとすれば、今後の統計的手法の発展に伴い、その正当化概念を反省していくことは、その社会的応用にとっても重要な含意を持つだろう。例えば自動運転技術が認められるべきかどうかは、自動運転システムの判断がどの程度正当化されているかによる。ではそれはどのような正当化なのだろうか。単にシミュレーションの成績などといった外在的なもので良いのか、あるいはシステムの判断根拠についてのより立ち入った、内在的な正当化が必要なのか。機械学習技術が市民生活に真に受け入れられ、また我々がそれを（単に押し付けられるのではなく）正しく用いるためにも、こうした認識論的考察を避けて通ることはできないのである。

また逆に、統計学の認識論的側面を学ぶことは、哲学的関心にとっても有益な視座をもたらすだろう。そもそも認識論とは、^{エピステーメー}「知識とは何か、我々はそれをどう獲得するか」というプラトン以来の関心に根ざす。だとすれば、現代において知識の代表格とされている科学、そしてその主要な方法論である統計学を無視することはできないはずである。実際のところ、上で述べてきたように、種々の統計学的手法は哲学的認識論のモデルとして機能している。こうしたモデルの役割は（およそあらゆる科学的モデルに共通するように）、哲学理論の精巧なレプリカを科

学的方法論の文脈に見出すことにあるのではない。むしろそれを適度に捨象・抽象化して定式化すること、そしてまた現実への適用を通じてそうした考え方の問題点を探り、洗練していくことにこそ、モデルの意義がある。認識論が現実社会を営む人間の知の解明であらんとする限り、哲学者の直観に根ざしたアプリアリオリな議論に閉じるのではなく、今日の社会において実際に知識を生み出している科学的方法論に照らし合わせて理論を洗練させていく試みは、有益かつ必要不可欠なことだと筆者は信じる。

これは決して、クワイン (Quine, 1969) が示唆したような認識論の科学への還元を意味するわけではない。そもそも、そのように哲学と科学を分けて考えること自体が恣意的区分であるように思われる。古代ギリシアを見ても、近世ヨーロッパを見ても、すでに哲学の内には科学的な部分があり、科学の内には哲学的な部分がある。それは「科学」という名称が独り立ちし、高度に分業化が進んだ現代においても同様である。そうだとすれば、哲学者は、哲学における科学的部分、および科学における哲学的部分の双方に目を向けるべきであろう。本稿で示そうとしたように、メタ科学的な方法論としての統計学は、そうした横断的思索にとつての沃野を提供するのである。

四 結び

以上本稿では、統計学と哲学の間の関連性を、主にその存在論的および認識論的側面に絞りを、足早に論じてきた。ここで紹介した話題はほんの一部であり、例えば意味論的側面や、また因果推論のように哲学者にとつても馴染みの深い問題に対する統計学的手法については紙幅の都合上割愛した。それらの話題、また上で扱った議論のより詳細な内容については、前掲書を参照されたい。また言うまでもなく、そこで扱えた議論として、統計学という巨大な氷山のほんの一角でしかない。21世紀に入り、計算機科学との融合という新たな局面を迎え急速に発展する統計学の哲学的含意の解明は、まだほとんど手つかずと言つて良いだろう。また比較対象として取り上げた哲学的

手法も主に英米系分析・科学哲学に限られたが、ここにもまた、歴史的、法哲学的、倫理学的観点、あるいは「ポストモダン」的手法など、さまざまな切り口がありうることだろう。こうした多様な可能性を含め、今後、哲学と統計学の間のより実り多き分析がなされることを期待しつつ、本稿の結びとしたい。

参考文献

- Akaike, H. (1974) A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723.
- Childers, T. (2013) *Philosophy and Probability*. Oxford University Press. (宮部賢治監訳 (2020) 『確率と哲学』九夏社)
- Demett, D. C. (1991) Real Patterns. *The Journal of Philosophy*, 88(1), 27–51.
- Gillies, D. (2000) *Philosophical Theories of Probability*. Routledge. (中山智香子訳 (2004) 『確率の哲学理論』日本経済評論社)
- Goldman, A., & Beddor, B. (2016) Reliabilist Epistemology. In E. N. Zalta (Ed.), *The Stanford Encyclopedia of Philosophy* (Winter 2016). Metaphysics Research Lab, Stanford University. <https://plato.stanford.edu/archives/win2016/entries/reliabilism/>
- Hume, D. (1739) *A Treatise on Human Nature*. (木曾好能訳 (1995) 『人間本性論 第一巻：知性について』法政大学出版局)
- Quine, W. V. O. (1960) *Word and Object*. The MIT Press. (大出晃・宮館恵訳 (1984) 『ワードと対象』勁草書房)
- Quine, W. V. O. (1969) Epistemology Naturalized. In *Ontological Relativity and Other Essays* (pp. 69–90) Columbia University Press.
- Rowbottom, D. P. (2015) *Probability*. Polity Press. (佐竹祐介 (2019) 『現代哲学のキーワード』：確率』岩波書店)
- Sellars, W. (1997) *Empiricism and the Philosophy of Mind* (Robert Brandom (ed.)). Harvard University Press. (神野慧一郎・土屋純一・中才敏郎抄訳 (2006) 『経験論と心の哲学』勁草書房)
- Sober, E. (2008) Evidence and Evolution. *Cambridge University Press*. (松王政浩抄訳 (2012) 『科学と証拠—統計学の哲学入門—』名古屋大学出版会)
- Wasserstein, R. L., & Lazar, N. A. (2016) The ASA's Statement on p-Values: Context, Process, and Purpose. *The American Statistician*, 70(2), 129–133.
- Xiao, K., Engstrom, L., Ilyas, A., & Madry, A. (2020) Noise or Signal: The Role of Image Backgrounds in Object Recognition. In *arXiv [cs.CV]*. arXiv: <http://arxiv.org/abs/2006.09994>

- 赤池弘次 (1980) 「統計的推論のパラダイムの変遷について」。『統計数理研究所報』 27(1)。
- 赤池弘次、甘利俊一、北川源四郎、樺島祥介、下平英寿 (2007) 『赤池情報量規準 AIC—モデリング・予測・知識発見』。共立出版。
- 飯田 隆 (2016) 『規則と意味のパラドックス』。筑摩書房。
- 上枝美典 (2020) 『現代認識論入門—ゲテティア問題から徳認識論まで—』。勁草書房。
- 大塚 淳 (2020) 『統計学を哲学する』。名古屋大学出版会。
- 大出 晃 (1977) 『確率と統計の周辺』。『理想』 528, 173-198。
- 田口 茂、大塚 淳、西郷甲矢人 (2020) 「現象学的明証論と統計学—経験の基本的構造を求めて—」。『哲学論叢』 47, 20-34。
- 出口康夫 (1998) 「統計学から見たクワインの科学論」。『アルケー』 6, 60-70。
- 戸山和久 (2002) 『知識の哲学』。産業図書。
- 原 聡 (2018) 「機械学習における解釈性 (Interpretability in Machine Learning)」。人工知能学会。
https://www.ai-gakkaï.org/jp/my-bookmark_vol33-no3/
- 林知己夫 (1960) 「統計的方法の基礎について」。『科学基礎論研究』 5(1), 1-16。

註

- (1) もちろん、そうした研究は皆無であるわけではない。例えば (林, 1960; 大出, 1977; 赤池, 1980; 出口, 1998; 田口ほか, 2020) などを参照。
- (2) 大塚 (2020)、『統計学を哲学する』名古屋大学出版会。
- (3) 正確を期すならば、さらにどのような部分集合が「事象」として認められるべきかを定める代数的構造 (シグマ代数) が必要なのだが、ここでは割愛する。
- (4) 詳しくは拙著「一章一節、ないし (Chidlers, 2013; Gillies, 2000; Rowbottom, 2015) などを参照。
- (5) 前述のように古典統計では「仮説の確率」というものを考えないので、これはあくまでベイズ的な立場で考えた話である。ただしそれにせよ、予測の失敗のみから蓋然的仮説の成否を論理的に導くことはできない。

THE OUTLINES OF THE MAIN ARTICLES IN THIS ISSUE

Why does statistics matter to philosophy?

by

Jun OTSUKA

Associate Professor,
Graduate School of Letters,
Kyoto University

This article explores the intersection of philosophy and statistics by examining philosophical assumptions underlying modern mathematical statistics from ontological and epistemological perspectives. Statistics is of interest to philosophers because its mathematical apparatus serves as “models” of philosophical ideas. For instance, much-discussed concepts of the uniformity of nature and natural kinds each correspond to the probability models and statistical models, which are the bread and butter of most statistical methods. Dennett’s real pattern is similar in spirit to information criteria (such as AIC) used to determine the level of complexity that maximizes a model’s predictive ability. In addition, the recent development in machine learning (e.g. deep learning) models implies that these machines have their own “ontology,” which is far more complicated and possibly efficient in understanding the world than ours. This gives rise to a Quinian problem of radical translation between our and machines’ ontologies, which, I suggest, is a key to the application of AI technologies to our society.

From the epistemological perspective, the article compares the Bayesian and classical statistics with the internalist and externalist epistemology, respectively. The comparison elucidates how and in what sense the statistical methods adopted in each camp are considered to justify scientific hypotheses, and also sheds light on their epistemic problems. I conclude with a plea for more studies and interdisciplinary dialogues between statistics and the philosophy of various traditions.