

AI における学習の力学・生物学的考察

石塚 隆男

亜細亜大学経営学部

1. 緒言

2000 年代後半に機械学習の手法のひとつとしてディープラーニングが開発されたのを機に第 3 次 AI ブームが始まり、AI は汎用性と人間を超える情報処理能力を獲得し実用段階に入ったと言われている。今泉 (2021) は、深層学習がしていることを「コンピュータ上で“関数”を構成している」と表現している[3]。関数を構成するしくみは、線形の積和と活性化関数といういたってシンプルである。

深層学習は強力な手法である一方、統計モデルと異なり、結果を導出した根拠が見えず解釈が困難であることが指摘されており、説明可能な AI の実現を目指した研究も行われている。現代の AI は多層ニューラルネットワーク (DNN) を前提としており、従来の統計モデルの常識では理解が困難である。

今日、AI が一応の成功を呈しているのは人間にとって世話なしであるとともに、AI の学習アルゴリズムそのものに何らかの合理性があると見なすことができる。

そこで、本研究では合理性の根拠を物理学や生物学などの自然科学の原理や法則に求め、考察を行うことを目的とする。

もしも AI の学習アルゴリズムが自然法則にしたがっているならば、AI が導き出した結果も自然法則の帰結と考えることができる。

今回、力学における最小作用の原理に注目し、考察した結果、いくつかの知見が得られたので報告する。

2. 最小作用の原理の含意[1]

最小作用の原理とは、「運動はラグランジアンと呼ばれるエネルギーの汎関数の値が最小になるような軌道をとる」とするものであり、ここから運動方程式、電磁気学におけるマクスウェルの方程式、相対性理論におけるアインシュタイン方程式、量子力学におけるシュレーディンガー方程式、場の理論におけるクライン・ゴルドン方程式、等を導け、矛盾なく解釈できることから動力学の基本原則と呼ばれている。

最小作用の原理は数学の変分原理に基づくもので最小値ではなく、極小値を与える停留点を得られるので正確には「停留作用の原理」であるが、「最小作用の原理」と呼ばれ現在に至っている。

最小作用とは、大まかに要約すれば、物体が 2 時点間を移動する場合、手持ちの運動エネルギーとポテンシャルエネルギー (位置エネルギー) を用い、最も作用が少なくて済む軌道を自動的に選択することを意味する。

物体は最小作用の原理にしたがい、各時点における運動エネルギー-ポテンシャルエネルギー (=ラグランジアン) の積分=作用 (Action) を最小化するようにふるまうが、なぜ、2 つのエネルギーの差を用いるのかについて解析力学の多くの文献は十分答えているとは言い難い。

生きものを含む物体は、運動エネルギーの源となるポテンシャルをもっている。ポテンシャルは環境からの影響を受けるとともに運動エネルギーの結果も記憶される。始点と終点の境界条件のもとで、ラグランジアンの積分=作用を最小にするためには無駄な運動エネルギーを消費しないこととポテンシャルを大きくすることである。

数学の世界では、最小作用の原理の例として挙げられる最速降下曲線の軌道は一意に決まるが、一般の世界では最小作用の原理を満たす経路は前提により変わる。

3. 方法

AI の学習アルゴリズムと最適化のアルゴリズムを取り上げ、最小作用の原理による解釈を試みる。

4. 結果

1) ハードモデル vs. 原始ネットワークモデル

ハードモデルとは柔軟性に乏しく用途が限定されるモデルであり、原始ネットワークモデルとは単純であるがゆえに柔軟性が高く繰り返しにより正解に近づくことができるモデルである。

深層学習が生まれるまでは、汎用性や柔軟性に欠けるハードモデルが中心であった。たとえば、ワープロはワープロ専用機であり、統計モデルは最小 AIC を満たすモデルが選択された。当時はこれが最小作用であった。その後、PC の

性能が上がり、ワープロはソフトで実行する時代となり、問題ごとに統計モデルをつくる必要がなくなり、1台〇役もこなせる汎用性が高まった。このように、何が最小作用かは前提や時代により変わりうる。汎用性を高めるためにメタヒューリスティクスによるチューニングが必要になっている。

2) 「近傍」探索による最小作用の実現

タブーサーチは、改善されるまで近傍探索を行い、既に探索したところは探索候補から外すことでループに陥るのを防ぐ学習アルゴリズムである。遠方をランダムに探索するのではないため、運動エネルギーは小さく抑えられ、運動履歴をポテンシャルに記憶することで無駄な動きをしない最小作用を実現している。焼きなまし法もエネルギー最小の状態に近づくために現在の状態の近傍を探索する点で最小作用をねらったアルゴリズムである。

3) 進化論と遺伝的アルゴリズム

ダーウィンの進化論によれば、地球上の大半の生きものは環境の変化に雌雄の生殖により適応してきた。地球環境の大きな変化を生き抜くための最小作用の源となるポテンシャルが雌雄の存在であると考えられる。遺伝的アルゴリズム (GA) は個体の内部表現を特徴の候補の組合せにより遺伝子型として表現している。伊庭 (2015) は進化計算と深層学習を接続するニューロエボリューションの可能性を論じている [2]。GA のデータは解の候補である個体であるが、ニューラルネットワークでは局所的なニューロンが個体に相当し、ニューロン間のつながりが GA の交叉に相当する。GA は遺伝子型の構造により最適解に達する特徴が抽出されない可能性があるが、ニューラルネットワークは普遍性近似定理によりいくらでも解の精度を上げることができる [5]。

5. 考察

第3次 AI ブームの中で XAI (eXplainable AI; 説明可能な AI) が話題となっているが、ロボットにおける「不気味の谷」になぞらえることができる。人間は日々さまざまな意思決定を行うが、なぜ、それを選んだのかについて説明できないことの方が多い。多くの場合、説明は後付けであり、決定結果が妥当であるように意識的に脚色される。人間の判断や意思決定には、説明不可能な潜在意識が働いており、絶えず揺らいでいると考えられる。潜在意識の位置をとらえようとすれば、ハイゼンベルクの不確定性原理により、意識の運動量 (ベクトルの方向) は不確定になると考えられ、後付けの説明はリア

ルの説明にはなりえないが、それでも人間は因果関係がわかると安心するのである。

機械学習やディープラーニングがチューニング次第では非常に高性能な働きをする現在、AI による卓見がなぜそうなのかを明らかにしたいというニーズがあるのは AI に不気味さを感じている背景がある。

従来の多変量解析では変数を増やせば係数パラメータも増え、推定に用いるデータ量も増やす必要があり、さらに変数間の多重共線性の問題も出てくるのでオッカムの剃刀やケチの原理にしたがうのがよいとされてきた [4]。AIC や MDL はそうした発想に基づく産物である。

機械学習ではビッグデータが利用可能になったことで膨大なパラメータ数でも推定でき、さらに多重共線性も特に問題にはなっていない [6]。機械学習には統計モデルのオーバーフィッティングに相当する過学習の問題があるが、入力データにより汎化することで対応可能である。

6. 結びにかえて

本研究では AI における学習アルゴリズムについて最小作用の原理により解釈を試みた。ニューラルネットワークを用いた深層学習は現状では極小作用の停留点といえると思われる。最小作用の原理と普遍性近似定理の存在は AI による結果の解釈に大きな意味をもつと考えられる。

参考文献

- [1] 石塚隆男 (2021) 「最小作用の原理のビジネスへの応用に関する考察」『日本経営工学会 2021 年秋季大会予稿集』 pp107-108
- [2] 伊庭斉志 (2015) 『進化計算と深層学習』オーム社
- [3] 今泉允聡 (2021) 『深層学習の原理に迫る』岩波書店
- [4] 紺野大地, 池谷裕二 (2022) 『脳と人工知能をつないだら、人間の能力はどこまで拡張できるか 脳 AI 融合の最前線』講談社
- [5] Michael Nielsen (「ニューラルネットワークと深層学習」 翻訳プロジェクト訳) (2014) 「CHAPTER 4 ニューラルネットワークが任意の関数を表現できることの視覚的証明」 http://nnadl-ja.github.io/nnadl_site_ja/chap4.html, 2022 年 1 月 7 日確認
- [6] 「統計学と機械学習におけるマルチコ (多重共線性) に対する考えの相違」 <https://yolo-kiyoshi.com/2019/05/27/post-1160/>, 2022 年 1 月 7 日確認