

書評

「データ科学入門Ⅲ」

モデルの候補が複数あるときの意思決定



松嶋敏泰 監修
早稲田大学データ科学教育
チーム 著
サイエンス社 (2024 年)
A5 判, 176 ページ,
定価 2,090 円
ISBN : 978-4-7819-1598-2

データ科学を支える専門分野として統計学と(機械学習を中心とした)情報科学がある。それぞれ、異なるコミュニティがあり独立して発展しつつも、互いに大きな影響を与えている。

データ科学において、「モデル」の定義は重要である。単回帰の「モデル」 $y=a+bx$ において、パラメータ a と b を求めることは単純な計算である。しかし、多項式の「モデル」の集合を考えると、適切な次数を決定することは簡単な問題ではない。古典的な統計学では、変数選択法を含む「アルゴリズム」が提案されてきた。特に、AIC は、標準的な情報量規準として広く使われている。また、BIC も情報量基準として広く使われている。ここで、「基準」と「規準」と書き分けているのは、小西 (2019) [1] が参考になる。

本書では、漢字の使い分けはしていないが、「構造推定の問題」として BIC、「予測の問題」として AIC を説明しており、これにより、AIC と BIC が、単に第 2 項が $2 \times$ (自由パラメータ数) と $\log n \times$ (自由パラメータ数) のどちらであるかという形式的な違いではないことが分かる。これらの体系化により、必要に応じて、WBIC などを勉強するための道標となる。統計学を含めた初学者にとってレベルが高いが、広い意味での「回帰」をモデルの立場から体系的に示している。

第 1 章は、本書の立場の外観を与えている。この章に目を通すことで、著者の立場が分かると思う。ただし、多くの読者にとって、この章だけを独立して理解することは困難である。その場合、軽く目を通して、第 2 章以降に進む方が良いと思われる。この章は、全体を読んだから、または、より学習が進んでから、時間をかけてじっくりと味わうことをお勧めする。

第 2 章は、回帰における基礎事項を分かり易く扱っている。多項式回帰や重回帰分析から始めて、リッジ回帰、lasso 回帰など縮小推定まで紹介している。かなり詳細な内容を含んでいる。

第 3 章は、「モデル」の扱いについての中心的な章である。分野や研究者によって「モデル」の定義が異なるので、著者の「モデル」の定義を正確に把握することが望まれる。「モデルが既知」と「モデルが未知」の違いを丁寧に解説したうえで、後者における扱いの基礎を扱っている。ところどころ、ベイズアプローチにもふれている。BIC, AIC の違いを理解されたい。変数増加法・変数減少法などのモデルの探索アルゴリズムも紹介している。

第 4 章では、(本書における)同質性を仮定した場合の予測について扱っており、クロスバリデーションのいくつかの手法、データ科学において基本的な事項である正則化の枠組みでリッジ回帰、lasso 回帰などを簡潔に紹介している。

第 5 章では、ニューラルネットワークの基本を説明したのち、CNN やディープニューラルネットワークまで丁寧に扱っている。深層学習を応用する際、単にパッケージを利用するだけのエンドユーザ以上の理解が可能になる。

付録も、深層学習などを学ぶための数理として有用である。

参考文献では、数理的な立場から統計学を学ぶための良書がそろっている。

この分野の進展は急激である。データ科学は、まさに変容・進化しており、新しい手法や理論が次々と登場している。本書でも少しだけ紹介している生成 AI が、社会において大きな影響を与えている。また深層学習などで登場する Double descent (二重降下) は、表面的には、Bias-Variance Trade-off と反することである。このような時代におけるデータ科学の学習においては、統計学・情報学を含めた基本的な概念の学習が求められている。そのような意味で、統計学と機械学習の架け橋となる本書は、名著だと考える。

参考文献

- [1] 小西貞則 (2019) : 情報量規準 AIC の統計科学に果たしてきた役割「5. 赤池ベイズ情報量規準 ABIC とベイズ型モデル評価基準 BIC」, 統計数理, 第 67 卷第 2 号, pp. 193-214 <https://www.ism.ac.jp/editsec/toukei/pdf/67-2-193.pdf>

(統計数理研究所 水田 正弘)