

ICT・AI 技術の税務行政における 活用可能性について

— (データ分析及びその体制論を含む) —

浦 東 聡 介

〔 税 務 大 学 校 〕
〔 研 究 部 研 究 員 〕

論文の内容については、すべて執筆者の個人的見解であり、税務大学校、国税庁あるいは国税不服審判所等の公式見解を示すものではありません。

要 約

1 研究の目的

本研究は、国税庁において ICT・AI 技術を効果的に利活用するための論点整理並びに各論点についての留意点及び方向性の考察を目的とする。近年、税務行政を取り巻く環境は ICT や AI が著しく発展するとともに、新たに社会保障・税番号制度やマイナポータルが導入されるなど大きく変化している。このような中、国税庁では、内国税の適正かつ公平な賦課及び徴収の実現という国税庁の任務を十分に果たしていくため、納税者の利便性向上や税務行政の効率化等の観点から、業務・システムの見直しに取り組んでいる。こうした見直しを円滑かつ効率的に実施するためには、ICT・AI 技術によるデータ活用を業務の中核に据え、それらを活用して何ができるのかを中心に検討し、業務改革を実施する必要がある。しかしながら、AI 技術は近年急速に発展した分野であり、その技術の本質や AI の利点を十分に引き出すための体制などについて十分な知見が蓄積されていない。そこで、本稿では、国税庁が取り扱う典型データである損益計算書を対象としたプロトタイプの子測モデル作成や官民の AI 利活用に関する動向調査などを通じて、国税庁が保有するデータの特性を踏まえた AI 利活用における留意点や、継続的な AI 利活用が可能となる AI 人材の確保・育成戦略や組織体制等について検討する。

2 研究の概要

(1) AI の概要

AI に関する研究は、ヒトの知能そのものを持つ機械を作ろうとする伝統的立場と、ヒトが知能を使ってすることを機械にさせようとする立場が存在する⁽¹⁾。このような立場の違いや「知能」のとらえ方の違いなどから、AI の統一的定義は存在しない。本稿では、データを利用してコンピュータ

(1) 人工知能学会「What's AI」(<https://www.ai-gakkai.or.jp/whatsai/AIwhats.html>) (令和 5 年 5 月 8 日最終閲覧)。

に何らかの推定を行わせる試みである機械学習を⁽²⁾AI に含める近年の傾向に従い、深層学習を含む機械学習を AI と定義する。

機械学習は、教師あり学習、教師なし学習、強化学習に大別される。これらのうち、本稿では教師あり学習に焦点を当て損益計算書を対象としたプロトタイプモデルを作成して考察する。教師あり学習とは、正解値などのラベルが付与された学習用のデータを利用して学習済みモデルを作成し、推論時にラベルのない新たなデータに対して分類や予測を行う手法⁽³⁾で、ロジスティック回帰、サポートベクターマシン、決定木及びランダムフォレスト等が例として挙げられる。AI で解決すべき具体的な課題が与えられた際には、これらの手法から最も適切な手法を選択する必要があるが、絶対的な選択基準は存在しない。そのため、利用できる機器の性能や求められる説明性及び解釈性を勘案し、選択肢を限定した上で、複数の機械学習手法でモデルを構築し、予測精度の高いモデルを選択することが望ましい。

(2) データ分析

イ 利用データの概観及びスケーリング

調査・徴収の効率化・高度化に向けて、損益計算書データを用いたプロトタイプの予測モデルを作成し、その過程及び結果を考察した。予測モデルの作成は、データ概要把握、前処理例としてスケーリング、予測モデル作成の順で実施した。

データ概要把握において、損益計算書に記載される値は、相関係数及び分散拡大係数 (VIF) が高くなることが認められた。スケーリングでは、ミニマックススケーリング、標準化、ロバストスケーリングに加えて業務知識に基づく方法として各データを売上額で除算する方法及びミニマックススケーリングを行方向に行う方法を実施した。スケーリングを実施しない場合、ミニマックススケーリングを実施する場合、各デ

(2) 独立行政法人情報処理推進機構 AI 白書編集委員会『AI 白書 2020 [第 1 版]』88 頁 (KADOKAWA, 2020)。

(3) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)46 頁。

ータを売上額で除算する場合で散布図を比較したところ、各データを売上額で除算する場合は散布図の形状が大きく異なることを確認した。このことは、業務知識に基づく前処理が予測モデルの精度に大きな影響を与える可能性があることを示唆している。そのため、予測モデルを作成する際には、エンジニアのみならず業務知識豊富な担当者の参画が重要となる。

ロ 予測モデル作成

損益計算書データのうちランダムに選択した半数に対して売上額を 10%削減し、疑似的に誤りのある損益計算書を作成した。同様の方法で、売上額を 5%、2.5%削減したデータセット及び仕入額を 10%、5%、2.5%増加させたデータセットの合計 6 種類のデータセットを作成した。当該データセットに対して、6 種類のスケールング手法及び 5 種類の機械学習手法（ロジスティック回帰、サポートベクターマシン、決定木、ランダムフォレスト及び深層学習）を組み合わせることで予測モデルを構築し、その予測精度を比較した。

6 種類のデータセットに対する予測精度の最高値の達成状況は、サポートベクターマシン 2 回、ランダムフォレスト 2 回、決定木 1 回であった。しかしながら、6 種類のデータセットと 6 種類のスケールング方法の組み合わせである 36 のケースにおける予測精度について、機械学習ごとに平均値を算出すると、深層学習以外は全て 68%台であり、大きな差は認められなかった。このことは、サポートベクターマシン及びランダムフォレストは高精度を示すことが多いものの、安定性を欠いたことを示唆している。同一の損益計算書から作成したデータセットであっても、売上額や仕入額の削減・増加割合の違いとスケールング手法の違いによって最も高い予測精度を達成するアルゴリズムが異なったことが示すように、最適な機械学習手法を事前を選択することは困難である。そのため、実務において予測モデルを作成する際には、利用可能な機器の性能、求められる説明性及び解釈性を勘案した上で、複数のモデルを

並行作成しつつ、過学習のリスクなど各機械学習手法の特徴及び利用予定の業務の特性を踏まえて、最適なモデルを選択することが望ましい。

(3) AI の説明性及び解釈性

AI が出した予測結果について、その理由や根拠が不明瞭だと AI に求められる社会的要請である公平性、透明性及び説明責任の確保が困難となるため、AI の説明性及び解釈性が重要となる。本稿では、説明性を「予測結果又は予測モデルを数学的に説明可能であり、その説明をヒトが理解できる形式で提示できること」、解釈性を「AI の予測結果や予測モデルに対する数学的説明について、ヒトが予測結果と結び付けて理解できること。」と定義した。

AI のブラックボックス化は、予測結果の理解及び予測モデルの理解という 2 つの観点において、説明性及び解釈性を損ない公平性、透明性のある意思決定及びその結果に対する説明責任の適切な確保に向けた阻害要因となる。一方で、ロジスティック回帰や決定木に代表されるホワイトボックス型とされる AI は、予測結果の理解及び予測モデルの理解という 2 つの観点において数学的な説明が明確であるため説明性に優れている。しかしながら、ホワイトボックス型 AI の数学的説明でも、具体的な誤り箇所を提示できないことや、判断過程が専門家と異なる等の理由から、予測結果に対する数学的説明と予測結果を結び付けて理解することが困難であり解釈性に欠ける場合がある。そのため、ホワイトボックス型の AI であっても、その AI を選択するのみでは説明責任を十分に確保できない可能性があることに留意する必要がある。

AI の説明性及び解釈性の向上に向けては、近年注目される XAI 技術の活用が有効であると考えられる。また、それに加えて、誤りの有無という 2 値分類ではなく、具体的な誤り内容を判定対象とする多クラス分類の予測モデル作成といったモデル作成者における工夫及び AI とは別にヒトの観点から予測結果を確認するといった AI 利用者の態度も AI を有効に活用するためには重要である。

さらに、AI の公平性、透明性及び説明責任の確保に向けては、このような AI 作成者及び利用者の工夫に加え、AI を利用する一連の業務における判断過程、判断理由、判断に対する責任の所在を明確にするための事務運営体制及び事務処理手順の整備が重要である。

(4) AI を活用するための組織体制について

AI を有効に活用するためには、単に AI を技術として導入するのみではなく人材及びデータ活用環境の双方の充実が重要である。特に人材に関しては、AI サイエンティスト、AI エンジニア及び AI プランナーといった AI 専門家が長期的に不足することが予測されるため、計画的な確保が必要である。この点について、民間企業の 6 割以上が不足する AI 人材を自社育成する方針を示している⁽⁴⁾。このことは、AI の利活用に当たっては、業務知識が必要であると判断されたことが一因と考えられる。そのため、国税庁においても AI の有効活用に向けて計画的な人材育成が重要である。

人材育成で目標とすべき具体的レベルの設定においては、予測モデルなどを作成する AI 専門家レベルと予測モデルの利活用部署レベルに大別される。AI 専門家レベルでは、予測モデルを作成するための知識及び作成した予測モデルの妥当性を評価するための統計及び数理基礎知識の習得が必要と考える。利活用部署レベルでは、四分位偏差、分散及び標準偏差などのデータの散らばりや、散布図や相関係数などのデータの相関性に関する知識を全職員が持つことが望ましい。また、利活用部署レベルにおける上位レベル（組織全体としての標準的レベル）としては、AI に関する基礎知識、データの可視化技術、データの集計、ツールによるデータ解析技術等を習得することが望まれる。

(4) 独立行政法人情報処理推進機構『IT 人材白書 2019 [第 1 版]』99 頁（独立行政法人情報処理推進機構、2019）。

目 次

はじめに	385
第 1 章 AI の概要	387
第 1 節 AI とは	387
1 AI の概念	387
2 本稿における AI の範囲	388
3 小括	389
第 2 節 AI の数学的理解	390
1 線形回帰問題	390
2 線形分類問題	392
3 説明変数の数	394
4 深層学習	396
5 小括	399
第 3 節 機械学習の概要	400
1 機械学習の学習手法	400
2 主な教師あり学習	402
3 主な教師なし学習	404
4 手法の選択	404
5 小括	407
第 2 章 データ分析	408
第 1 節 利用データの概観及びスケーリング	408
1 利用データ	409
2 損益計算書データの特徴	409
3 損益計算書データのスケーリング	411
4 小括	419
第 2 節 予測モデル作成	420
1 データ作成	421

2	スケーリング	421
3	学習結果	422
4	全体考察	429
5	機械学習の手法別考察	434
6	小括	446
第 3 章	AI の説明性及び解釈可能性	447
第 1 節	AI に対する社会的要請	447
1	AI に求められる公平性	447
2	AI に求められる透明性	448
3	AI に求められる説明責任	448
4	小括	449
第 2 節	AI の説明性及び解釈可能性	449
1	AI の説明性及び解釈可能性	449
2	AI のブラックボックス化	450
3	ホワイトボックス型 AI の説明力	456
4	小括	473
第 3 節	AI の説明性及び解釈可能性を踏まえた 社会的要請への対応	473
1	ブラックボックス型 AI の「モデルの理解」及び「予測結果の理解」の改善	474
2	AI の予測結果に対する納得感の獲得	475
3	AI に対する社会的要請を踏まえた AI の利用方法	476
4	小括	480
第 4 章	AI を活用するための組織体制について	481
第 1 節	民間企業における取組状況等	481
1	民間企業の AI 活用に向けた体制づくり	481
2	AI 活用に必要な能力	483
3	小括	489
第 2 節	国税庁において AI 活用するために必要な体制	490

1 全職員が備えるべき知識	491
2 標準的知識	491
3 専門的知識（ミドルレベル）	492
4 専門的知識（エキスパートレベル）	494
5 小括	494
結びにかえて	495

はじめに

近年、税務行政を取り巻く環境は ICT や AI が著しく発展するとともに、新たに社会保障・税番号制度やマイナポータルが導入されるなど、大きく変化していく中、国税庁では、内国税の適正かつ公平な賦課及び徴収の実現という国税庁の任務を十分に果たしていくため、納税者の利便性向上や税務行政の効率化等の観点から、業務・システムの見直しに取り組んでいる。こうした見直しを円滑かつ効率的に実施するためには、現状の業務プロセスを前提とした業務の効率化といった観点にとどまらず、ICT・データ活用を業務の中核に据え、それらを活用して何ができるのかを中心に検討し、業務改革を実施する必要がある。

国税庁においては、このような方針を取りまとめ、平成 29 年 6 月に「税務行政の将来像」を公表し、ICT の活用による「納税者の利便性の向上」及び「課税・徴収の効率化・高度化」を柱とした「スマート税務行政」への進化を掲げた。更に、令和 3 年 6 月には、デジタルの活用によりサービスや仕事の在り方を変革する、デジタル・トランスフォーメーションを推進する動きが社会全体で広まったことを受け、「税務行政のデジタル・トランスフォーメーションー税務行政の将来像 2.0ー」を公表、課税・徴収におけるデータ分析の活用等の取組を加速させることとした。

また、この間には令和元年 6 月に内閣府から「AI 戦略 2019～人・産業・地域・政府全てに AI ～」が公表されるなど、政府全体としても AI 利活用に向けた取り組みが加速されているため、国税庁における ICT 技術を活用したデータ分析の取り組みについても AI 技術の活用が大きく期待されている。

しかしながら、AI 技術は近年急速に発展した分野であり、その技術の本質や AI の利点を十分に引き出すための体制などについて十分な知見が蓄積されていない。ICT・AI 技術を活用し、ICT・AI 技術からの恩恵を最大限享受するためには、国税庁が保有するデータの特性を踏まえた手法の検討や、継続的な AI 活用が可能となる AI 人材の確保・育成戦略や組織体制についての検討が必要

である。

そこで、本稿ではこれらを明らかにするため、国税庁が取り扱う典型データである損益計算書を対象としたプロトタイプの予測モデル作成や官民の AI 利活用に関する動向調査などを通じて「AI・機械学習の概要」、「AI を用いたデータ分析の概要及び留意点」、「AI に求められる説明性及び解釈性」及び「データ活用推進体制」について論点整理並びに各論点についての留意点及び方向性を考察する。

第 1 章 AI の概要

第 1 節 AI とは

本稿では、税務行政における ICT、取り分け AI について考察する。しかし、AI という言葉の定義は専門家の間でも定まっていない⁽⁵⁾。そのため、本節では AI に関する考察の出発点として、本稿における AI を定義する。

1 AI の概念

AI とは、Artificial Intelligence の略語で一般的に人工知能と訳される。AI という言葉は、1956 年にアメリカのダートマス大学で開催されたワークショップ（ダートマス会議）の提案書⁽⁶⁾において用いられたものが世界初とされている。この提案書では、抽象化、概念形成、自身の改善を行う機械を AI としていることから、当初の AI は人工的に作られるヒトと同等の知能を意図したものと考えられる。このヒトと同等の知能を人工的に作成する試みは、様々な角度からアプローチが試みられているものの現在まで実用化には至っていない。

しかしながら、この試みの過程では、ヒトと同等の知能の作成には至らずとも、目的を特定した場合には、ヒトの知的な活動を代替し得る手法が数多く考案された。現在、AI として使用されているシステムの多くは、このような手法の応用事例と考えられる。

このように、AI は、ヒトの知能そのものを持つ機械を作ろうとする立場と、ヒトが知能を使つてすることを機械にさせようとする立場があり、実際の研究の多くは後者の立場に立っている⁽⁷⁾。本稿でも、後者の立場に立ち、人間

(5) 松尾豊『人工知能は人間を超えるか〔初版〕』44 頁(KADOKAWA、2015)。

(6) A Proposal for the Dartmouth Summer research Project on Artificial Intelligence (www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html) (令和 5 年 2 月 8 日最終閲覧日)。

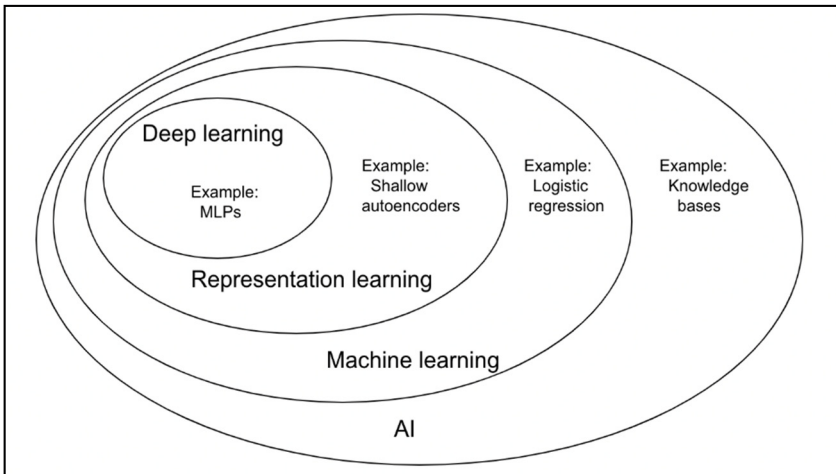
(7) 人工知能学会・前掲注(1)。

が知能を使ってすることを代替する機械を AI として議論を進めることとする。そのため、本稿では前者の立場に関する問いである「知能とは何か」、「意識とは何か」、「生命とは何か。」等の哲学的な議論には言及せず、AI を統計的・数学的理論に立脚した ICT 技術として捉えることとする。

2 本稿における AI の範囲

2012 年画像認識コンペティションである ImageNet Large Scale Visual Recognition Challenge において、トロント大学ジェフリー・ヒントンのチームが深層学習を用いた AI を利用し、それまでの記録を大幅に更新して注目を集めた。それ以降、深層学習が AI 技術の中心的役割を担っているが、ヒトが知能を使ってすることを機械にさせようとする技術は深層学習に限ったものではなく、下図 1-1 「深層学習が機械学習の一種であることを示すベン図」に示すとおり他の技術も AI として認知されている。

【図 1-1】深層学習が機械学習の一種であることを示すベン図



(出典：Ian Goodfellow et al.(2016) “Deep Learning” MIT Press. p.9 (<https://www.deeplearningbook.org>) (令和 5 年 2 月 8 日最終閲覧日))

このように、深層学習 (Deep learning) は機械学習 (Machine learning) の一種であると整理される。機械学習とは、データを利用してコンピュータに何らかの推定を行わせる試みである⁽⁸⁾。深層学習を含む表現学習 (Representation learning) 以外の機械学習は、学習過程において予測に有効な特徴をエンジニアが与えることに対して、深層学習を含む表現学習では大量のデータからモデルが特徴を自力で抽出する点に両者の違いがある⁽⁹⁾。

また、深層学習を含む機械学習がデータから知識を得る手法であることに對して、エキスパートシステムをはじめとする知識ベース (Knowledge bases) のアプローチは、専門家の知見をルールとして蓄積し、推論の手法を用いて問題を解決する手法である。エキスパートシステムは、1980 年代に AI 技術の中心的役割を果たした技術であり、近年はエキスパートシステムという言葉が使われる機会も少ないことから⁽¹⁰⁾、本稿で検討する AI は、知識ベースの AI を含めず、深層学習を含む機械学習と定義する。

3 小括

AI は、ヒトの知能そのものを持つ機械を作ろうとする伝統的立場と、ヒトが知能を使つてすることを機械にさせようとする立場が存在する⁽¹¹⁾。このような立場の違いや、「知能」のとらえ方の違いなどから、専門家の間でも AI の統一的定義は存在しない。2012 年以降、深層学習が AI の中心的技術であるが、図 1-1 「深層学習が機械学習の一種であることを示すベン図」に示すとおり、知識ベースアプローチまでを AI の範囲であると定義する考え方

(8) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)88 頁。

(9) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)187 頁。

(10) 寺野隆雄「エキスパートシステムはどうなったのか？」計測と制御 第 42 巻 第 6 号 454 頁 (計測自動制御学会 2003 年)。

エキスパートシステムは、使われなくなったのではなく、技術として定着したことで AI として注目されなくなったものと考えられる。エキスパートシステムの国税業務における利活用は期待されるが、機械学習とは開発手法が異なることから、本稿で検討する AI には含めない。

(11) 人工知能学会・前掲注(1)。

も存在する。本稿では、データを利用してコンピュータに何らかの推定を行わせる試みである機械学習⁽¹²⁾（深層学習を含む。）を AI と定義し、開発手法が機械学習と異なるエキスパートシステムは AI の定義に含めないこととする。

第 2 節 AI の数学的理解

本稿における AI は、深層学習を含む機械学習である。深層学習を含む機械学習は、最適化、確率、統計、線形代数、微分積分等の数学的理論や手法に基づき設計、実装されている。そのため、AI の本質を理解するためには数学的に理解することが必要不可欠である。

そこで、本節では線形問題及び深層学習を例に AI の数学的仕組みについて概要を確認し、次節以降の導入とする。併せて、深層学習を含む機械学習を予測に利用する場合、「知能」、「意識」及び「生命」等の哲学的な問いとは切り離して、予測モデルの作成及び実行が可能であることを確認する。

1 線形回帰問題

線形回帰問題は、目的変数と説明変数⁽¹³⁾の関係を明らかにする問題（回帰問題）⁽¹⁴⁾について、両者の関係を線形で近似しようとするものである⁽¹⁵⁾。回

(12) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)88 頁。

(13) 「二変数 x と y の間に一方 x が他方 y を左右ないしは決定する関係があるとき、 x を独立変数、 y を従属変数と言う。」(松原望『統計学入門〔初版〕』58 頁(東京大学出版会、1991))。また、「統計、パターン認識分野では『独立変数』を『説明変数』、『従属変数』を『目的変数』とすることが多い。」(橋本洋志『データサイエンス教本〔初版〕』16 頁(オーム社、2018))とされている。本稿では、これらの用語は「説明変数」及び「目的変数」として統一して使用する。

(14) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)56 頁。

(15) $f(x)+f(y)=f(x+y)$ かつ $f(cx)=cf(x)$ が成り立つとき、 $f(x)$ を「線形」という。ここでは、線形回帰問題の説明にあたり、典型例である説明変数と目的変数の関係を 1 つの直線で近似する単回帰を例とした。本稿では簡単化のため、直線で近似するものを「線形問題」、曲線で近似するものを「非線形問題」として解説する。なお、数式(1)は、厳密には平行移動を伴う線形写像であるため、アフィン写像である。

帰問題の例として、「気温(説明変数)から来場者数(目的変数)を予測する」、「部屋の広さ(説明変数)から家賃(目的変数)を予測する」などが挙げられる。両者の関係を線形で近似するとは、説明変数が 1 つの場合は、以下の数式(1)において目的変数と説明変数の関係に最もよく当てはまる係数「 a 」及び切片「 b 」を推定することが典型である。

(注) 説明変数が 1 つのものを単回帰、2 つ以上のものを重回帰という。

$$\hat{y} = ax + b \cdots \text{数式(1)}$$

部屋の広さから家賃を予測する場合、数式(1)では、部屋の広さを x 、家賃の予測値(数式(1)の x に部屋の広さを代入して得られる値)を \hat{y} として、学習に利用できるデータ全体を考慮した際に \hat{y} と家賃の正解値 y との誤差が最も小さくなるような係数「 a 」及び切片「 b 」を推定する。最小化すべき誤差を数式で表すと以下の数式(2)のとおり。

$$E(a, b) = \frac{1}{N} \sum_{n=1}^N (\hat{y}(x_n) - y_n)^2 \cdots \text{数式(2)}^{(16)}$$

この数式(2)を誤差関数といい、係数「 a 」及び切片「 b 」の値を変化させながら誤差関数の値(E)を最小化⁽¹⁷⁾することが「AIの学習」である。

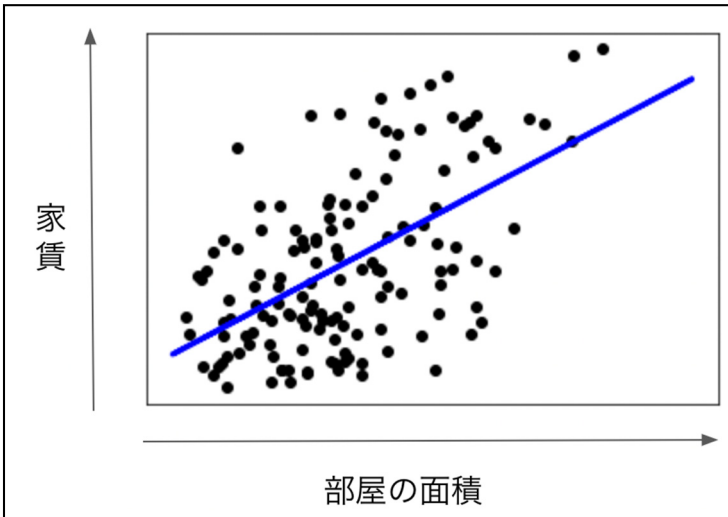
このようにして、具体的な係数及び切片(例えば「 $a=0.7$ 」「 $b=1$ 」など)が得られると、AIの学習は終了し、得られた数式(1)'(「 $y=0.7x+1$ 」など)を用いることで、未知のデータ(x)が与えられた際に予測値を得ることができる。

学習に用いたデータの散布図と学習済み数式(1)'のイメージを下図 1-2「データの散布図と学習済み数式(1)''に示す。

(16) 誤差関数の例として平均二乗誤差(MSE)の数式を記載した。この他にも平均絶対値誤差(MAE)、MSEのルートをとったRootMSEなど様々なものがある。

(17) 誤差関数を最小化するためには、別途計算が必要となるが本稿では省略する。

【図 1-2】データの散布図と学習済み数式(1)'



(出典：筆者作成)

以上のように、AI の学習は、

- ① 予測に用いる数式を選択
- ② 予測値と正解値の誤差を表す誤差関数の選択
- ③ 誤差関数から求められる数値（誤差）の最小化

という三段階の手順に分けることができ、線形回帰問題に限らず多くの AI の学習に共通する手順である。

2 線形分類問題

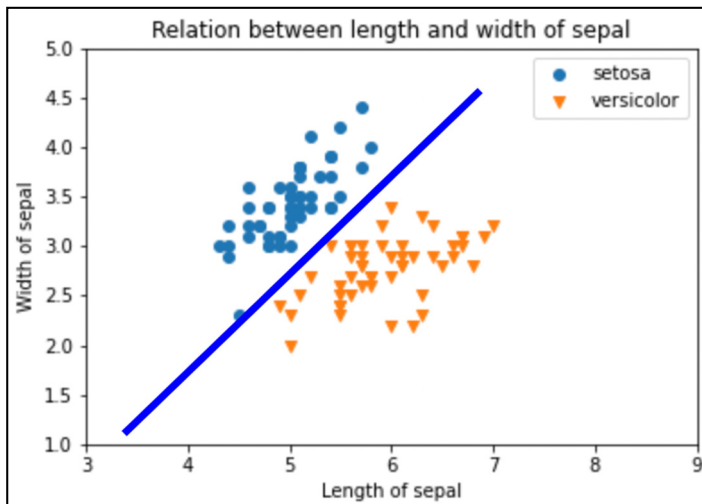
事前に与えられたクラスに基づいて、与えられたデータをそれらのクラスに割り当てる問題を分類問題という⁽¹⁸⁾。「与えられた画像を犬の画像又は猫の画像に分類する」、「気温と湿度から 1 時間後に雨が降るか降らないか」を

(18) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)56 頁。

予測する問題などが分類問題の例として挙げられる。このような問題のうち、「予測に用いる数式」に線形の数式を用いるもの（与えられたデータを線形の数式で分離するもの）を線形分類問題という。

下図 1-3 「アヤメの品種分類」は、がく片の幅と長さからアヤメの品種を「setosa」又は「versicolor」に分類する問題である⁽¹⁹⁾。「setosa」と「versicolor」の間に描写した直線は学習済みの「予測に用いる数式」で、分類問題では「決定境界」と呼ばれている。回帰問題が「予測に用いる数式」における線上の座標を予測値としたことに対し、分類問題では決定境界を境にデータがどのクラスに属するのかを予測している。

【図 1-3】アヤメの品種分類



(出典：筆者作成)


(19) scikit-learn(<https://scikit-learn.org/stable/index.html>)からデータを取得(データ取得令和5年2月8日)。

3 説明変数の数

線形回帰問題の例では、「部屋の面積」という一つの説明変数から、「家賃」を予測した。また、線形分類問題の例では、「がく片の幅」と「がく片の長さ」という二つの説明変数からアヤメの品種を分類した。

アヤメの品種分類において、「がく片の幅」のみを 1 次元（数直線上）に描写すると下図 1-4 「がく片の幅又は長さによるアヤメの分類」左に示すとおり、概ね 2.7~3.5 の区間で「setosa」と「versicolor」が重複する。同様に「がく片の長さ」のみでアヤメの分類を行う場合は、下図 1-4 「がく片の幅又は長さによるアヤメの分類」右に示すとおり、概ね 5.0~6.0 の区間で「setosa」と「versicolor」が重複する。そのため、今回用いたアヤメの品種分類データでは説明変数が一つの場合は、両者を完全に切り分けることができない。このような場合に、「がく片の幅」及び「がく片の長さ」という 2 つの説明変数を同時に用いることで図 1-3 「アヤメの品種分類」のようにデータを二次元空間に描写して、アヤメの種類を 2 分する直線を描写することが可能となる。

【図 1-4】 がく片の幅又は長さによるアヤメの分類



(出典：筆者作成)

このように予測対象の特徴をよく表現した説明変数を追加することで分類精度の向上が期待できる。

参考として、前述のアヤメの品種分類問題に目的変数⁽²⁰⁾ (virginica) 及び説明変数 (花びらの長さ、花びらの幅) を追加した上で作成した予測モデルの精度を表 1-1 「アヤメの品種分類問題における説明変数と正解率」に示す。

【表 1-1】アヤメの品種分類問題における説明変数と正解率⁽²¹⁾

	説明変数			
	がく片の長さ	がく片の長さ がく片の幅	がく片の長さ がく片の幅 花びらの長さ	がく片の長さ がく片の幅 花びらの長さ 花びらの幅
訓練データ 正解率	77.1%	82.9%	96.2%	98.1%
テストデータ 正解率	68.9%	82.2%	95.6%	97.8%

(出典：筆者作成)

例として説明変数を 1 つ (「がく片の長さ」のみ) から 4 つ (「がく片の長さ」、「がく片の幅」、「花びらの長さ」及び「花びらの幅」) まで増加させながら予測精度を観察した。このように予測モデルの学習においては追加する説明変数の種類数に上限はなく、視覚的に捉えることは不可能であるものの、3次元の立体空間を超えた高次元を扱うことが多い⁽²²⁾。ただし、説明変数のむやみな追加は、学習に必要なデータ量や時間の増加を招き学習の難易度を上げることが知られているため(一般に「次元の呪い」と言われている。)、説明変数を追加することによる効果とコストを適切に見極める必要がある。

(20) 2 値分類では問題が容易であり、説明変数を 2 以上用いた場合の予測精度に差が認められなかった。そのため、目的変数を追加することで問題を複雑化した上で、説明変数の追加と予測精度の関係を確認した。


(21) sklearn.linear_model の LogisticRegression (random_state=0) の場合の結果。

(22) 説明変数が 1 次元の場合の決定境界は点、説明変数が 2 次元の場合は線、説明変数が 3 次元の場合は面となり、4 次元以上の説明変数の次元数を P とした場合、決定境界は P-1 次元の超平面となる。

4 深層学習

深層学習は、「神経細胞（ニューロン）を模擬した処理を深く多層に重ねたネットワークをモデルとし、学習させるアプローチ⁽²³⁾」である。深層学習の典型的モデル構造である全結合層のみのモデルは、下図 1-5 「ニューラルネットワーク⁽²⁴⁾の構造」に示すような層構造である。ニューラルネットワークは入力層（値を入力する層）から出力層へ向けて計算を繰り返し、最終的に目的とする予測値を算出する。

【図 1-5】ニューラルネットワークの構造



(出典：独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2) 90 頁)


また、図中の円は「ノード」と呼ばれ、各ノードに接続する線にはそれぞれ重み w が割り当てられる。ニューラルネットワークにおける計算は、下図 1-6「ニューラルネットワークにおける各ノードの入出力」に示すとおり、

(23) 独立行政法人情報処理推進機構 AI 白書編集委員会「AI 白書 2022」50 頁 (KADOKAWA, 2022)。

(24) 本稿では、モデル構造を指す場合に「ニューラルネットワーク」、モデルの学習及び学習済みモデルを指す場合に「深層学習」と表現する。

直前のノードから出力された値 x_i に重み w_i （添字 i は i 番目を表す。）を乗じた値が次のノードへの入力となる。入力を受けたノードでは、それぞれの入力値を合計の上（下図 1-6 「ニューラルネットワークにおける各ノードの入出力」における u を計算）、活性化関数を用いて値を変換し出力値とする（下図 1-6 「ニューラルネットワークにおける各ノードの入出力」における z ）。

【図 1-6】ニューラルネットワークにおける各ノードの入出力



（出典：筆者作成）

以上のように、深層学習では、活性化関数で変換する u を求めるために第 1 章第 2 節 1 「線形回帰問題」における重回帰と同様の計算（数式(3)参照）を行っている。

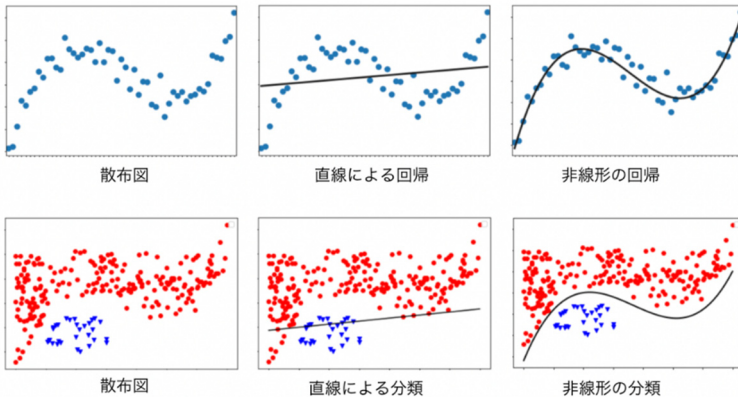
$$u = w_1x_1 + w_2x_2 + \dots + w_nx_n \dots \text{数式(3)}$$

活性化関数の代表的なものとしては、シグモイド関数（値(図中の u)を 0 から 1 までの間の値へ変換）や、正規化線形関数（値(図中の u)が 0 以下の場合には 0、それ以外の場合は u をそのまま出力とする関数）が挙げられる。深層学

習は、活性化関数を使用することで非線形化⁽²⁵⁾し、線形では正確に近似できない予測にも対応可能としている。すなわち、深層学習とは、活性化関数を使って非線形性を入れた、多層に構成した関数を使った誤差関数の最小化⁽²⁶⁾である。

非線形化の利点は、回帰問題において下図 1-7 「非線形な分布に対する回帰及び分類」上段のように直線上に並んでいない点（数値）を予測できることや、分類問題において下図 1-7 「非線形な分布に対する回帰及び分類」下段のように直線で切り分けることができない点を分離することが可能になることである。

【図 1-7】非線形な分布に対する回帰及び分類



(出典：筆者作成)

図 1-7 「非線形な分布に対する回帰及び分類」における非線形の回帰曲線又は決定境界の形状は、「予測に用いる数式」に依存するため、数式の選

(25) 非線形とは線形でないものをいい、線形とは $f(x)+f(y)=f(x+y)$ かつ $f(cx)=cf(x)$ が成り立つときの $f(x)$ をいう。

(26) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23)35 頁。

括は予測精度に直結する。「予測に用いる数式」に深層学習を採用する場合、十分に大きなネットワークを構築することで、理論上はどのような曲線であっても近似できるため、高精度な予測が期待できる（「万能近似定理⁽²⁷⁾」として数学的に証明されている。）。

ただし、高精度な予測が期待される深層学習であっても、目的変数と説明変数に何らかの関連性が認められないものについては、正しく予測することができないことに留意する必要がある。

5 小括

AI の学習は①予測に用いる数式の選択、②予測値と正解値の誤差を表す誤差関数の選択及び③誤差関数から求められる数値（誤差）の最小化という 3 つの数学的ステップで捉えることができる。このうち、①予測に用いる数式の選択は、予測対象のデータへの当てはまりに大きな影響を与えることとなる。予測対象のデータが線形に分布することを仮定した数式では、非線形なデータの分布へ適合することが困難である。深層学習は、多層構造を持つニューラルネットワークにおいて、活性化関数を用いることで非線形なデータの分布に対応できるため、高い性能が期待される。

予測対象のデータが線形に分布することを仮定した単純な数式は元より、深層学習のモデル構造であるニューラルネットワークであっても、機械学習の学習ステップ①②③は数学的に計算されるため、税務行政における AI の利活用に当たっては、「意識」、「知能」及び「生命」等の議論には言及しない。

(27) 万能近似定理(universal approximators theorem)とは、ネットワークが十分な数の隠れユニットを持つ場合、線形の出力層と活性化関数を持つ隠れ層を少なくとも1つ持つ順伝搬型ネットワークは、どんなボレル可測関数でも任意の精度で近似できるという定理。「Hornik Kurt et al.(1989) “Multilayer Feedforward Networks are Universal Approximators” Neural Networks.vol.2. Pergamon Press. pp.359-366」において示された。

第 3 節 機械学習の概要

本稿では、「第 2 章データ分析」において、損益計算書を分析対象に複数の機械学習手法を用いて予測モデルを構築した結果を考察する。第 3 節ではその導入として、代表的な機械学習手法を紹介する。

1 機械学習の学習手法

機械学習の学習手法は、表 1-2 「学習手法の 3 分類」のとおり「教師あり学習」、「教師なし学習」及び「強化学習」の 3 種類に大別される。

【表 1-2】学習手法の 3 分類⁽²⁸⁾

学習手法	概要
教師あり学習	正解値などのラベルが付与された学習用のデータを利用して学習済みモデルを作成し、推論時にラベルのない新たなデータに対して分類や予測を行う。
教師なし学習	ラベルが付与されていないデータから、隠されている構造や規則性を記述するための特徴を学習する。
強化学習	ゴールや目的を仮定せず、学習を行う「エージェント」が状態を観察し、環境からの報酬を最大化するように試行錯誤しながら行動を選択することで学習を行う。あらかじめ報酬を最大化する条件などを定義する必要がなく、システム自身に試行を繰り返させることで学習が進む。

教師あり学習の利点は、正解データと予測結果の差を計測しながら学習を進めるため、予測精度を参考にしてモデルの導入可否を判断できる点である。

(28) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)46 頁。

これに対して、教師なし学習は、学習対象データが持つ構造や規則性の分析を目的とするため、学習後のモデルから出力される結果を解釈し、次の行動にどのように活用するのかを検討する必要がある。

例えば、確定申告書を入力として税務調査で確認すべき事項の有無を判断する教師あり学習の AI を利用する場合、AI から出力されるのは、誤りが想定される確定申告書であるか否かといった 2 択や誤りが想定される確率である。職員はこの結果を基に、確定申告書の審査業務において、「税務調査の必要度が高そうな確定申告書はベテラン職員が確認する」又は「特定の職員に税務調査の必要度が高そうな確定申告書の確認が集中しないようにバランスよく確定申告書の審査を配分する」などの判断に活用することができる。

一方で、教師なし学習の場合、クラスタリングを例にすると、確定申告書の入力に対して AI が出力するのは確定申告書のグループ分けである。このグループは、税務調査で確認すべき事項の有無で分けられているものではなく、確定申告書に記載された各数値から判断された確定申告書ごとの類似性で分けられる。そのため、それぞれのグループにどのような意味があり、それをどのように扱うべきであるのかは示されておらず、職員が別途検討する必要がある。

もっとも、クラスタリングは教師なし学習の一例であり、オートエンコーダのように異常検知に利用できる教師なし学習も存在するため、税務調査で確認すべき事項の有無を判断するために学習手法を検討する場合であっても、教師なし学習全てを選択肢から除外することなく、目的と利用できるデータに応じて適切な手法を選択する必要がある。

強化学習については電力システム運用などで社会実装に向けた応用研究が進められているものの⁽²⁹⁾、現状では社会実装の適用範囲は限定的であるため本稿においては以後言及しない。

(29) 高山聡志 “Application of reinforcement learning to power system operation”
IEEE Transactions on Power and Energy Vol.141 No.10 pp.608-611 (2021) .

2 主な教師あり学習

主な教師あり学習は表 1-3 「主な教師あり学習」のとおり。

【表 1-3】主な教師あり学習

名称	概要
線形回帰	<p>目的変数と説明変数の関係を明らかにする問題（回帰問題）⁽³⁰⁾について、両者の関係を線形で近似しようとするもの。</p> <p>回帰問題に用いられる。</p>
ロジスティック回帰	<p>A か B のどちらかしか起こらない場合などに、事象がどちらに分類できるかの確率を計算する⁽³¹⁾。</p> <p>※線形回帰モデルと同様に説明変数と目的変数の関係を線形で近似し、そこから得られる値を関数によって確率に変換するもの。</p> <p>分類問題に用いられる。</p>
サポートベクターマシン (SVM)	<p>データを何らかの特徴に基づき 2 分類する際、双方のデータ群を等しい距離（マージン）で区切る平面を機械学習により発見する手法⁽³²⁾。</p> <p>回帰問題及び分類問題に利用可能。</p>

(30) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2)56 頁。

(31) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23)50 頁。

(32) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23)50 頁。

<p>決定木</p>	<p>一連の説明変数の中から、1つの適切な説明変数を選択して、データセットをより均質な傾向を持つサブセットに分割することを繰り返して、目的変数に強く関連している説明変数や注目したいサブグループを発見することを目的とする手法⁽³³⁾。</p> <p>回帰問題及び分類問題に利用可能。</p>
<p>ランダムフォレスト</p>	<p>ランダムに選んだ学習データと説明変数を用いて決定木を作成し、その多数決や平均値を結果として出力するもの。決定木よりも精度が高くなる傾向がある⁽³⁴⁾。</p> <p>回帰問題及び分類問題に利用可能。</p>
<p>深層学習 (深層ニューラルネットワーク)</p>	<p>神経細胞(ニューロン)を模倣した処理を深く多層に重ねたネットワークをモデルとし、学習させるアプローチ⁽³⁵⁾。</p> <p>回帰問題及び分類問題に利用可能。</p>

(33) 奥喜正ほか「データマイニングにおける二価データ解析：決定木とロジスティック回帰分析」物流問題研究 44 号 2 頁(2004)。

(34) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23) 50 頁。

(35) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23) 50 頁。

3 主な教師なし学習

主な教師なし学習は、表 1-4 「主な教師なし学習」のとおり。

【表 1-4】主な教師なし学習

名称	概要
主成分分析	多次元のデータに対して正味に効果のあるより少ない成分を抽出（次元の削減）する手法 ⁽³⁶⁾ 。
k-means	データ点の所属するクラスを、各データ点からクラスタ重心への距離が最も近いものから選択する手法 ⁽³⁷⁾ 。

4 手法の選択

表 1-3 「主な教師あり学習」及び表 1-4 「主な教師なし学習」において示したとおり、機械学習にはさまざまな手法が存在する。これらの手法については、明確な選択基準は存在しない。そのため、どの手法が最良か、もしくはより良いかを、事前に予測できることはほとんどないと考えられている⁽³⁸⁾。しかし、経験則から一定の基準は示されており、機械学習でよく利用されるライブラリである `scikit-learn` の「`scikit-learn algorithm cheat-sheet`⁽³⁹⁾」（図 1-8）や「色々な学習法の特徴」表（1-5）がその例として挙げられる。

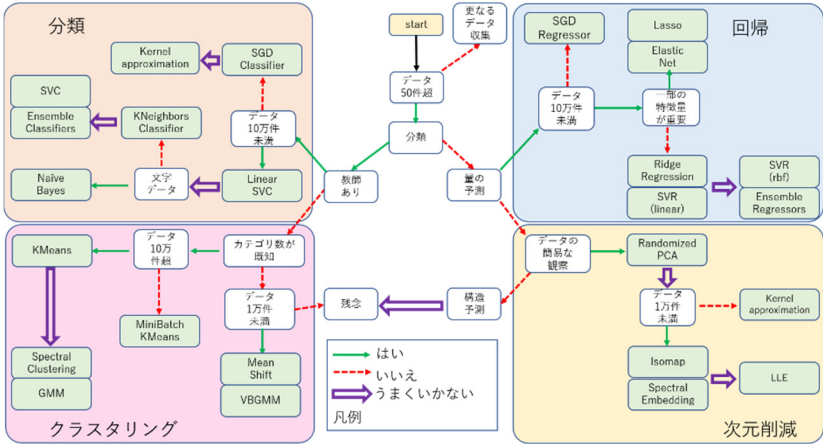
(36) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23) 50 頁。

(37) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(23) 50 頁。

(38) Trevor Hastie 他（杉山将他訳）『統計的学習の基礎-データマイニング・推論・予測』401 頁（共立出版、2014）。

(39) https://scikit-learn.org/stable/tutorial/machine_learning_map/(令和 5 年 2 月 8 日最終閲覧日)。`scikit-learn` で対応している手法のみを対象としていることには留意が必要。

【図 1-8】 scikit-learn algorithm cheat-sheet



(出典: scikit-learn algorithm cheat-sheet・前掲注(39)を筆者翻訳の上、一部修正)

【表 1-5】 色々な学習法の特徴 (○: 良い、△: 普通、×悪い)

特徴	NN	SVM	決定木	MARS	KNN
異種データの「混在」の自然な扱い	×	×	○	○	×
欠損データの扱い	×	×	○	○	○
入力空間での外れ値に対するロバスト性	×	×	○	×	○
入力の単調変換に対するロバスト性	×	×	○	×	×
計算機的拡張性 (N が大きいとき)	×	×	○	○	×
相互関連性がない入力を扱う能力	×	×	○	○	×
特徴量の線形結合を抽出する能力	○	○	×	×	△
説明性	×	×	△	○	×
予測能力	○	○	×	△	○

(注) NN: 深層学習、MARS: 多変量適応的回帰スプライン、KNN: K-近傍法を表す。

(出典: Trevor Hastie 他・前掲注(38)401 頁を一部修正。)

「scikit-learn algorithm cheat-sheet」(図 1-8)は「データ数が一定数以上であるか」や「分類問題か」など 2 択の質問に回答することでフローチャートに従い機械学習手法を決定するもので予測能力に重きを置いた判定と考えられる。

一方で、表 1-5 「色々な学習法の特徴」からは、機械学習の手法選択において考慮すべき 3 つの要素を読み取ることができる。1 つ目の要素は、予測能力に関する項目である。具体的には、「予測能力」と予測能力に影響を与えるであろう項目として「異種データの『混在』の自然な扱い」、「欠損データの扱い」、「入力空間での外れ値に対するロバスト性」、「入力の単調変換に対するロバスト性」、「相互関連性がない入力を扱う能力」及び「特徴量の線形結合を抽出する能力」が挙げられる。2 つ目の要素は計算コストである。具体的項目として、「計算機的拡張性 (N が大きいとき)」が挙げられる。計算コストが大きなアルゴリズムを利用する場合、その計算コストに見合った機器の使用が求められる。そのため、利用見込みのデータ量を基に学習に要する時間と予測に要する時間の 2 点を考慮し、利用予定の機器で運用可能であることを確認する必要がある。3 つ目の要素は、説明性及び解釈性である。具体的項目としては「説明性」が挙げられる。説明性とは予測結果又は予測モデルを数学的に説明可能であり、その説明をヒトが理解できる形式で提示できることである。また、解釈性とは AI の予測結果や予測モデルに対する数学的説明について、ヒトが予測結果と結び付けて理解できることである(説明性及び解釈性については、本稿第 3 章第 2 節「AI の説明性及び解釈可能性」において詳細を述べる。)

これら 3 つの要素のうち、計算コスト並びに説明性及び解釈性の要求レベルはモデルの候補を限定するための強い制約条件となる。そのため、これら 2 つの要素について要求レベルを決定し、利用できないアルゴリズムを選択肢から除外した上で、複数の機械学習モデルを並行して作成し、予測精度のよい機械学習手法を選択することが望ましい。

5 小括

機械学習は、教師あり学習、教師なし学習及び強化学習に大別される。本稿では、次章以降で教師あり学習を用いて予測モデルを構築する。教師あり学習とは、正解値などのラベルが付与された学習用のデータを利用して学習済みモデルを作成し、推論時にラベルのない新たなデータに対して分類や予測を行うもので⁽⁴⁰⁾、線形回帰、ロジスティック回帰、SVM、決定木、ランダムフォレスト及び深層学習等が例として挙げられる。AI で解決すべき具体的な課題が与えられた際には、このような手法から最も適切な手法を選択する必要があるが、明確な選択基準は存在しない。そのため、利用できる機器の性能や求められる説明性及び解釈性を勘案し、選択肢を限定した上で、複数の機械学習手法でモデルを構築し、予測精度の高いモデルを選択することが望ましい。

(40) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2) 46 頁。

第 2 章 データ分析

第 1 節 利用データの概観及びスケーリング

国税庁では、調査・徴収の効率化・高度化に向けて、申告書及び決算書等の分析による申告誤りの判定を目指している⁽⁴¹⁾。そこで、本章では公開情報から抽出した損益計算書の簡易データに対して「第 1 章 AI の概要」で述べた機械学習手法によって予測モデルを構築する過程を通じて、損益計算書データの特徴、損益計算書データに対するスケーリング、機械学習手法ごとの特徴等を考察する。

第 1 節では、予測モデル作成前に実施すべきデータの概要把握及びスケーリングについて概要を述べる。データの概要把握とは最大値、最小値及び平均値等の基本統計量の取得、欠損データの含有程度の確認並びに相関係数の取得等を通じてデータの特徴を把握することである。これらの状況を把握することで、外れ値の処理、欠損データの補完及び説明変数の選択等の次に実施すべき作業の計画を立案する。本稿では、データの概要把握のうち、損益計算書データを取り扱う際に重要となる相関係数の確認についての概要を述べる。

スケーリングとは、学習の円滑な収束及び性質の異なるデータの結果への影響度合いを調整するため、入力値や出力値の範囲を特定のルールに基づき変換する手法である。機械学習では、説明変数をモデルの学習に適した形式にするため、外れ値の処理、欠損データの補完、説明変数の選択・抽出・生成・変換等を実施する。この作業は、特徴量エンジニアリングと呼ばれ、予測モデルの学習前に実施する重要な工程とされている。特徴量エンジニアリングのうち、変換の代表例がスケーリングで、予測モデル作成に当たっては多くの場合に実施されている。本稿では、特徴量エンジニアリングの例としてスケーリングを

(41) 国税庁「税務行政のデジタル・トランスフォーメーションー 税務行政の将来像 2.0 ー」20 頁 (https://www.nta.go.jp/about/introduction/torikumi/digitaltransformation/pdf/syouraizo2_r0306.pdf) (令和 5 年 2 月 21 日最終閲覧)。

取り上げ、その概要を述べる。

1 利用データ

経済情報プラットフォーム **SPEEDA** を利用して日本の上場企業のうち 3,066 社の令和 3 年度決算損益計算書（通貨は米ドル、単位は百万）データを取得した。このうち、記載率が高い売上（以下、勘定科目を表す場合は「売上」と表記し、具体的金額を表す場合は「売上額」と表記する。）、仕入（以下、勘定科目を表す場合は「仕入」と表記し、具体的金額を表す場合は「仕入額」と表記する。）、売上総利益、一般管理費、営業外収益、営業外費用、福利厚生費、研究開発費、減価償却費、経常利益及び税引前利益率⁽⁴²⁾を分析対象の勘定科目とした。これら 11 の勘定科目に欠損値がない企業を抽出したところ 1,026 社が該当した（1,026 社の損益計算書データを以下「本件サンプルデータ」という。）。本章以降、本件サンプルデータを対象として分析を実施する。

なお、本稿で利用する勘定科目は記載率によって選定したが、実務においては後述する相関関係等を参考に予測モデルの精度向上に資する勘定科目を適切に選定する必要がある。また、本稿では欠損値がない企業のみを分析対象としたが、実務においては欠損値を含むデータについても平均値、中央値等で補完するなど適切な対応が必要となる。

2 損益計算書データの特徴

損益計算書は、企業の経営成績を明らかにするため、一会計期間に属する全ての収益とこれに対応するすべての費用とを記載して経常利益を表示し、これに特別損益に属する項目を加減して当期純利益を表示する。通常多くの収益を計上するには、収益に対応する原価や諸経費も多く必要となるため、損益計算書に記載される各金額には相関関係が生じることとなる。統計的な

(42) 税引前利益率は損益計算書に記載された勘定科目ではなく、経済情報プラットフォーム **SPEEDA** が分析用に追加した項目。

分析を行う場合には、取り扱うデータ相互に相関関係が複数認められる場合（多重共線性がある場合）には、目的変数に有意に影響を与える説明変数を見逃す恐れがあるなどの問題が生じる。そのため、選択する機械学習手法によっては説明変数間の多重共線性を軽減する処理を行う必要がある。

本件サンプルデータについて、売上と他の科目とのピアソンの積率相関係数を測定した結果は表 2-1 「売上と他の科目との相関係数」のとおり。営業外費用（0.20）及び税引前利益率（0.03）を除き高い相関が認められる。

【表 2-1】売上と他の科目との相関係数

	仕入	売上 総利益	一般 管理費	営業外 収益	営業外 費用	福利 厚生費	研究 開発費	減価 償却費	経常 利益	税引前 利益率
相関係数	0.99	0.91	0.46	0.69	0.20	0.88	0.87	0.93	0.55	0.03

(出典：筆者作成)

また、多重共線性の深さを定量化した分散拡大係数（VIF）⁽⁴³⁾は、表 2-2 「売上と他の科目との分散拡大係数」のとおり。多くの勘定科目で分散拡大係数が高い値を示すことから多重共線性が認められるものと判断できる。

【表 2-2】売上と他の科目との分散拡大係数

	仕入	売上 総利益	一般 管理費	営業外 収益	営業外 費用	福利 厚生費	研究 開発費	減価 償却費	経常 利益	税引前 利益率
VIF	6.9e+12	5.0e+11	7.1e+10	2.0e+9	1.5e+10	7.2e+0	7.3e+0	2.8e+1	5.8e+10	1.2e+0

(注) e は 10 のべき乗を表す。そのため、例えば e+12 は 10^{12} を表す。

(出典：筆者作成)

以上のとおり、相関係数及び分散拡大係数（VIF）が高い値を示すことから、本件サンプルデータを用いた分析では、目的変数に有意に影響を与える

(43) 分散拡大係数がどの程度であれば多重共線性の問題が生じるのかについて、明確な基準はないものの概ね 5 から 10 を基準とするものが多い。

説明変数を見落とすリスク、不必要な説明変数が含まれるリスク等があることを念頭に分析する必要がある。

3 損益計算書データのスケーリング

(1) スケーリングの概要

機械学習では、学習の円滑な収束及び性質の異なるデータの結果への影響度合いを調整するため、分析対象のデータをスケーリングすることが多い。例えば、気温と湿度を説明変数にする場合に、気温 30 度と湿度 30% では数値として同じ「30」であったとしても意味は異なる。東京都を基準にすると気温 30 度は気温としては相対的に高く、湿度 30%は相対的に低い。また、説明変数に 24 時間降水量を加える場合は、その数値は 100 mm を超えることも多く、気温及び湿度の 30 に対して数倍の大きな数値を入力することとなる。機械学習では、説明変数の単位は考慮せず数値のみを入力として取り扱うため、相対的に高いはずの気温 30 度と相対的に低いはずの湿度 30%は同じ 30 として扱われ、降水量の 100 mm は 100 として扱われる。このように異なる性質の情報を取り扱う際には、スケーリングを実施することで、それぞれの説明変数における各データの相対的な位置関係を維持しつつ、各説明変数の数値を概ね同じ区間に配置することができる。このことで、機械学習の予測精度の向上やモデルの解釈性の向上が期待できる。

スケーリングの例としては、特徴量の範囲を 0 から 1 までの数値に変換する「ミニマックススケーリング」(数式 (4) 参照)、特徴量を平均 0、分散 1 の分布に変換する「標準化」(数式 (5) 参照) 等が挙げられる。

$$x'_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad \dots \text{数式(4)}$$

$$x'_i = \frac{x_i - \bar{x}}{\sigma} \quad \dots \text{数式(5)}$$

(i = 1, 2, \dots n)

ここで、 $\min(x)$ は説明変数 x の最小値、 $\max(x)$ は説明変数 x の最大値、 \bar{x} は説明変数 x の平均値、 σ は説明変数 x の標準偏差を表す。

一方で、損益計算書データの場合、そこに記載される数値は金額であり、原則として円やドルなど通貨の単位も統一されている。このような場合に、スケーリングを実施すると有用な情報が失われる可能性もあるためスケーリング実施要否の判断は慎重に行う必要がある。下表 2-3 「スケーリングなし」は簡易な損益計算書を疑似的に作成したものであり、表 2-4 「ミニマックススケーリング（列方向）」は当該損益計算書に対してミニマックススケーリングを列方向に実施したものである。

【表 2-3】スケーリングなし

	売 上	仕 入	売上総利益	一般管理費	営業利益
A	150	135	15	12	3
B	300	240	60	40	20
C	450	315	135	125	10
D	500	475	25	10	15

(出典：筆者作成)

【表 2-4】ミニマックススケーリング（列方向）

	売 上	仕 入	売上総利益	一般管理費	営業利益
A	0.00	0.00	0.00	0.02	0.00
B	0.43	0.31	0.38	0.26	1.00
C	0.86	0.53	1.00	1.00	0.41
D	1.00	1.00	0.08	0.00	0.71

(出典：筆者作成)

表 2-4 「ミニマックススケーリング (列方向)」のとおり、ミニマックススケーリング (列方向) を実施することで全ての数値が 0 から 1 の間の値へ変換される。数式 (4) を用いた変換計算は、勘定科目ごと (列ごと) に行われるため、同一行内の各勘定科目の大小関係や比率等の情報は失われる。例えば、A はスケーリングをしない場合 (表 2-3) は売上 150、仕入 135 であることから原価率 0.9 (135/150) であるが、ミニマックススケーリング (列方向) の後 (表 2-4) では、売上 0、仕入 0 であるため原価率 0 (0/0) である。このような行方向の情報の喪失は、必ずしも予測モデルの精度低下に直結するものではないが、利用するアルゴリズムによっては、原価率のような説明変数相互間の関係性を学習可能なものも存在するため、影響を慎重に見極める必要がある。

また、行の情報を保持するために、表 2-5 「ミニマックススケーリング (行方向)」のように行方向に数式 (4) を適用してスケーリングすることも考えられる⁽⁴⁴⁾。この場合、行内の最大値及び最小値を用いて変換するため、同一行内の各勘定科目の大小関係は保持されるが、比率⁽⁴⁵⁾や列に対する情報は失われる。例えば、スケーリングをしない場合 (表 2-3) は A と B の売上を比較すると A が B の 0.5 倍 (150/300) であることに對して、ミニマックススケーリング (行方向) の後 (表 2-5) では、1.0 倍 (1.0/1.0) となる。また、A における一般管理費の売上に対する割合は、スケーリングをしない場合 (表 2-3) は 0.08 (12/150) であることに對して、ミニマックススケーリング (行方向) の後 (表 2-5) では 0.06 (0.06/1.00) となる。

(44) スケーリングは列方向の情報を用いて数値変換することが一般的である。また、行方向の情報を用いた変換は列方向の各データの位置関係を変更することから、スケーリング以外の特徴量エンジニアリングと定義することも考えられるが、本稿で取り扱うミニマックススケーリング (行方向) 及び対売上比率化は損益計算書の各数値を概ね 0 から 1 までの値に変換するためスケーリングと定義した。

(45) 比率の情報が失われるのは、数式 (4) において分子から $\min(x)$ を控除することによる。そのため、 $\min(x)$ が 0 の場合又は $\min(x)$ を控除しても影響を受けない程度の大きさを持つ x_i 間では実質的に比率の情報は保持される。

【表 2-5】ミニマックススケーリング（行方向）

	売 上	仕 入	売上総利益	一般管理費	営業利益
A	1.00	0.90	0.08	0.06	0.00
B	1.00	0.79	0.14	0.07	0.00
C	1.00	0.69	0.28	0.26	0.00
D	1.00	0.95	0.03	0.00	0.01

(出典：筆者作成)

このようなミニマックススケーリングの他に、経験則から分析に有効であると考えられる情報がある場合には、経験則に沿ったスケーリングを実施することも検討する。例えば、専門家が行う損益計算書分析では、売上高総利益率、売上高営業利益率及び売上高当期純利益率のように利益を売上額で除算することで得られる数値がよく用いられる。このように経験則から対売上比率が分析に有効であることが期待される場合には、表 2-6 「対売上比率」のとおり各勘定科目の値を売上額で除算することで対売上比率に変換することが考えられる。対売上比率化は、ミニマックススケーリング（行方向）と同様に、行方向の情報保持に有効であり同一行内の各勘定科目の大小関係及び各勘定科目の比率が保持される。一方でどのデータも売上が 1 になるなど、列方向の情報は失われることとなる。

【表 2-6】対売上比率

	売 上	仕 入	売上総利益	一般管理費	営業利益
A	1.00	0.90	0.10	0.08	0.02
B	1.00	0.80	0.20	0.13	0.07
C	1.00	0.70	0.30	0.28	0.02
D	1.00	0.95	0.05	0.02	0.03

(出典：筆者作成)

以上のように、スケーリングは、実施しないことも含めて様々な選択肢が挙げられるが、機械学習の手法の選択と同様にいずれの選択肢を採用すべきであるのかを事前に予測することは困難である。そのため、複数のスケーリング手法を試行しながら予測精度を比較することが望ましい。

また、予測モデルの作成においては、スケーリング以外にも、仕入額を売上額で除算して原価率を算出し、説明変数として新たに追加するなど、データの分析や加工作業が予測精度に大きく影響する。これらの作業は業務知識に基づいて行うことで効果的かつ効率的に進めることができるため、予測モデルの作成には、エンジニアのみならず業務知識豊富な担当者の参画が重要となる。


(2) 本件サンプルデータへの適用

本件サンプルデータに対してスケーリングを実施の上、売上及び仕入について他の勘定科目との散布図⁽⁴⁶⁾を作成した。

イ スケーリングをしていないデータ

スケーリングを実施しない場合の売上及び仕入について他の勘定科目との散布図は図 2-1 「スケーリングを実施しない場合の散布図」のとおり。

【図 2-1】スケーリングを実施しない場合の散布図



(注) 上段：売上、下段：仕入


(出典：筆者作成)

(46) 散布図の視認性を確保する観点から外れ値データを削除した。

ロ ミニマックススケーリング

ミニマックススケーリング（列方向）（数式（4））を実施した場合の売上及び仕入について他の勘定科目との散布図は図 2-2 「ミニマックススケーリング（列方向）実施後の散布図」のとおり。

【図 2-2】ミニマックススケーリング（列方向）実施後の散布図



（注）上段：売上、下段：仕入

（出典：筆者作成）

ミニマックススケーリング（列方向）を実施した散布図の概形は、スケーリングしていない散布図の概形から大きな変化が認められない。これは、ミニマックススケーリング（列方向）が列方向の位置関係を保持したまま値を圧縮する手法であることに起因する。

第 1 章第 2 節 2 「線形分類問題」で述べたように分類問題を解くためには、このように散布図として描写された各点に対して、分類対象のデータを区分できるような境界を作成する必要がある。ミニマックススケーリング（列方向）は、散布図の概形に変更を加えないため、スケーリング前に分類できなかった点を再配置して分類のための境界作成を容易にするよりも、主に学習の収束に貢献するものと考えられる。このことは、同時にスケーリング前に分類できていた点が分類できなくなると


というような変更を加えるものではないことを意味する⁽⁴⁷⁾。ミニマックススケーリング（列方向）においては、スケーリング前に存在した売上と仕入の関係といった行方向の情報は失われる。しかしながら、このような情報が失われても、予測性能の低下に直結するような影響（散布図の形状変化）は見られない。このことは、スケーリングを実施しない場合、売上と仕入の関係といった経験則上重要な情報は、保有されるものの、そのままでは有効に活用されていない可能性が高いことを示唆している。

ただし、このことは機械学習全般に当てはまるものではなく、例えば畳み込み層を持つニューラルネットワークを利用することで、行方向のデータの規則性から情報を取得することが期待されるため、売上と仕入の関係性といった情報を活用できる可能性がある。

ハ 売上額で全科目を除算したデータ

売上額で全科目を除算した場合の売上及び仕入について他の勘定科目との散布図は図 2-3 「売上額で全科目を除算した後の散布図」のとおり。

【図 2-3】売上額で全科目を除算した後の散布図



(注) 上段：売上、下段：仕入

(出典：筆者作成)

(47) 厳密には、ミニマックススケーリングによって点の密集度が変化するため、スケーリング前後で個別の点について分類結果が異なる可能性はある。しかし、散布図の概形に変化がないことから、大半のデータ点の分類結果に影響を与えない。

ミニマックススケーリング（列方向）と異なり、各データ点が再配置され散布図の形状が大きく変化した。そのため、売上額で除算する前後で適切な決定境界が変化し、その結果として各データ点の分類結果が改善することが期待される。このようなスケーリング手法を利用することで、畳み込み層を持つニューラルネットワークのように行方向のデータの並び順から情報を取得する機械学習手法に限らず、説明変数の各項目を単独で利用するような機械学習の手法でも、行方向の情報に基づき正確に分類対象のデータを区分できるような境界が作成可能となる可能性が示された。

ただし、図 2-3 「売上額で全科目を除算した後の散布図」上段のデータが y 軸方向への広がりを失ったことが示すとおり、売上額で全科目を除算する場合、売上はどのデータも 1 になり、売上の項目自体の情報は失われることとなる。

散布図の形状が大きく変化したことから、再度相関係数を測定する。

なお、売上が全て 1 に変換されたため、売上と他の科目との相関係数ではなく、仕入と他の科目の相関係数を測定し、スケーリング前と比較する。

【表 2-7】仕入と他の科目との相関係数

処理	売上	売上 総利益	一般 管理費	営業外 収益	営業外 費用	福利 厚生費	研究 開発費	減価 償却費	経常 利益	税引前 利益率
前	0.99	0.85	0.49	0.65	0.13	0.85	0.85	0.91	0.49	0.00
後	-	1	-0.81	-0.13	-0.04	-0.48	-0.36	-0.06	-0.46	-0.41

(注) 「処理」欄が「前」はスケーリング前、「後」はスケーリング後を表す。

(出典：筆者作成)

売上と仕入を除く、9 個の勘定科目のうち、6 個の科目で相関係数の絶対値が減少していることが確認できる。さらに、分散拡大係数 (VIF) についても表 2-8 のとおり改善していることが確認できる。

【表 2-8】仕入と他の科目との分散拡大係数

処理	売上	売上 総利益	一般 管理費	営業外 収益	営業外 費用	福利 厚生費	研究 開発費	減価 償却費	経常 利益	税引前 利益率
前	1.1e+13	5.0e+11	7.1e+10	2.0e+9	1.5e+10	7.2	7.3	2.8e+1	5.8e+10	1.2
後	-	6.3e+6	3.6e+6	8.2e+4	5.4e+4	1.6	1.5	1.1	1.4e+6	8.9

(注) 「処理」欄が「前」はスケーリング前、「後」はスケーリング後を表す。

(出典：筆者作成)

このように、売上額で全科目を除算することで散布図の形状を大きく変化させ、分散拡大係数 (VIF) の数値を大幅に改善することができた。

ただし、分散拡大係数 (VIF) が大幅に減少した後であっても、なお高い数値を示していることから、多重共線性の問題には留意する必要がある。

4 小括

経済情報プラットフォーム SPEEDA を利用して日本の上場企業の損益計算書データを取得した。損益計算書データは、勘定科目間の相関係数が高く、分散拡大係数 (VIF) も高い。そのため、損益計算書データを対象とした予測モデル作成では、利用する機械学習手法によっては多重共線性への注意が必要となる。

機械学習で一般的に実施されるスケーリングは、エンジニア及び業務知識豊富な担当者の協力の下実施することで、データが持つ情報を効果的に利用することが期待される。機械学習では、学習の円滑な収束及び性質の異なるデータの結果への影響度合いを調整するため、入力値や出力値の範囲を特定のルールに基づき変換するスケーリングがよく行われる。スケーリングの例としては、ミニマックススケーリングが挙げられる。ミニマックススケーリングは、最小値及び最大値を用いて入力値を 0 から 1 までの値に変換する手法である。ミニマックススケーリングは、列方向にも、行方向にも作用させ

ることができるが、列方向に作用させた場合には行方向の値が持っていた関係性が失われ、行方向に作用させた場合には列方向の値が持っていた関係性が失われる。一般的にミニマックススケーリングは列方向に作用させる。ミニマックススケーリングを列方向に作用させた場合、散布図の概形は変化せず、2値分類における決定境界の概形も変化しない。そのため、行方向の値が持っていた関係性が失われても、予測性能の低下に直結するような影響を与えない。このことは、経験則上重要であると考えられる原価率などの行方向の値が持っている関係性が情報として利用できていない可能性を示唆している。

原価率など行方向の情報が経験則上重要と考えられる場合には、その経験則に沿ったスケーリングが有効に機能することが期待される。具体的には、売上額で各勘定科目の値を除算することで各勘定科目の値を概ね0から1の間に変換することができる。そのため、この手法は行方向に作用するスケーリングと考えることができる。行方向に作用するスケーリングは列方向の値が持っていた関係性が失われ再構成される。このことは、散布図の各データ点を再配置することを意味するため、散布図の概形が変化する。その結果、各データ点の分類結果が改善することが期待される。ただし、散布図の概形の変化は必ずしも予測精度の向上をもたらすものではなく、スケーリングによって変換した説明変数と目的変数との間に何らかの関連性が認められる場合に効果が発揮される。効果的に説明変数を変換するためには、業務知識に基づくことが有効であると考えられるため、予測モデルの作成には、エンジニアのみならず業務知識豊富な担当者の参画が重要となる。

第2節 予測モデル作成

第2節では、本件サンプルデータに対して「第1章 AI の概要」で述べた機械学習手法を用いて分類問題の予測を行い、その結果を考察する。予測モデルの作成は、検出対象となる疑似データ（誤りのあるデータ）の作成、スケーリン

グ、モデル学習の順で実施する。疑似データは、本件サンプルデータの半数に対して売上額を削減又は仕入額を増加させることで作成した。スケーリングは、①スケーリング実施なし、②ミニマックススケーリング（列方向）、③標準化、④ロバストスケーリング、⑤売上額で全科目を除算、⑥ミニマックススケーリング（行方向）の 6 種類を実施し、それぞれのデータを利用して予測モデルを作成することで予測精度を比較した。機械学習手法は、①ロジスティック回帰、②決定木、③ランダムフォレスト、④SVM、⑤深層学習の 5 つの手法を利用して予測モデルを作成することで予測精度を比較した。

1 データ作成

疑似的に誤りのあるデータを作成するために本件サンプルデータの半数をランダムに抽出し、売上額を 10%削減した。併せて、売上額が減少することで影響を受ける売上総利益などの金額も売上額の減少と整合性が取れるように調整した。これら売上額を削減したデータを検出対象である陽性とし、売上額を削減していない残り半数のデータと合わせてデータセットを作成した。

同様に売上額を 5%、2.5%削減したデータ及び仕入額を 10%、5%、2.5%増加させたデータも作成した。これらの疑似的に作成した誤りデータ 6 種類は、それぞれを組み合わせることなく、6 種類のデータセットとして利用した。

各データセットを訓練データ 821 件（約 8 割）及びテストデータ 205 件（約 2 割）に分割した。

2 スケーリング

機械学習での学習前に、ミニマックススケーリング、標準化、ロバストスケーリング及び売上額で全科目を除算する方法によりスケーリングを実施した。このうち、ミニマックススケーリングについては、列方向及び行方向の 2 つのパターンで実施した。

なお、ロバストスケーリングとは次の数式（6）で行うスケーリングをい

う。

$$x'_i = \frac{x_i - Q_1(x)}{Q_3(x) - Q_1(x)} \quad \dots \text{数式(6)}$$

(i = 1, 2, \dots, n)

ここで、 Q_1 は説明変数 x の第1四分位数、 Q_3 は説明変数 x の第3四分位数を表す。

3 学習結果

(1) 売上額削減データ

イ 売上額 10%削減データ

売上額を 10%削減したデータに対する正解率は表 2-9「売上額 10%削減データに対する予測精度（正解率）」のとおり。

【表 2-9】売上額 10%削減データに対する予測精度（正解率）

	L R	D T	R F	S V M	D L
スケーリングなし	85.9%	83.0%	86.4%	82.5%	83.5%
MM スケーリング (列方向)	85.4%	83.0%	86.4%	87.9%	82.5%
標準化	85.9%	83.0%	86.4%	85.4%	85.4%
ロバストスケーリング	85.4%	83.0%	86.4%	85.4%	83.5%
売上除算	86.9%	84.5%	86.4%	87.9%	87.4%
MM スケーリング (行方向)	86.9%	84.5%	86.4%	87.4%	81.1%
平均	86.1%	83.5%	86.4%	86.1%	83.9%
最高	86.9%	84.5%	86.4%	87.9%	87.4%
最低	85.4%	83.0%	86.4%	82.5%	81.1%
高低差	1.5%	1.5%	0.0%	5.3%	6.3%
標準偏差	0.007	0.008	0.000	0.021	0.022

(注 1) LR はロジスティック回帰、DT は決定木、RF はランダムフォレスト、SVM はサポートベクターマシン、DL は深層学習を表す (以下同じ)。

(注 2) MM スケーリングはミニマックススケーリングを表す (以下同じ)。

(注 3) 表中の太文字は最高精度を表す (以下同じ)。

(注 4) 高低差は最高と最低の差を表す (以下同じ)。

(出典：筆者作成)

全体的に予測精度は良好であり、いずれの機械学習手法、スケーリング手法においても正解率が 80%を超えている。最も正解率が高かったのは、売上額で全科目を除算したデータで学習した SVM で、正解率は 87.9%であった。スケーリング手法別に最高精度を達成した機械学習手法を確認すると、ランダムフォレスト及び SVM がそれぞれ 3 つのスケーリング手法で最高精度を達成した。機械学習手法ごとに正解率の平均値を算出すると、86.4%のランダムフォレストが最も高精度であった。ランダムフォレストはスケーリング手法を問わず、正解率が一定であることに対して、SVM はスケーリングしない場合には、正解率が 82.5%と低くスケーリングの実施有無によって正解率に大きな差が認められた。また、深層学習も正解率に大きなばらつきが認められた。

ロ 売上額 5%削減データ

売上額を 5%削減したデータに対する正解率は表 2-10「売上 5%削減データに対する予測精度 (正解率)」のとおり。

【表 2-10】売上額 5%削減データに対する予測精度（正解率）

	L R	D T	R F	S V M	D L
スケーリングなし	69.4%	69.4%	69.9%	61.2%	58.3%
MM スケーリング（列方向）	67.5%	69.4%	69.9%	69.9%	62.6%
標準化	69.9%	69.4%	69.9%	70.9%	65.5%
ロバストスケーリング	69.4%	69.4%	69.9%	70.9%	66.5%
売上除算	70.4%	68.5%	70.9%	71.8%	67.0%
MM スケーリング（行方向）	71.4%	69.4%	70.4%	71.8%	62.6%
平均	69.7%	69.3%	70.1%	69.4%	63.8%
最高	71.4%	69.4%	70.9%	71.8%	67.0%
最低	67.5%	68.5%	69.9%	61.2%	58.3%
高低差	3.9%	1.0%	1.0%	10.7%	8.7%
標準偏差	0.013	0.004	0.004	0.041	0.033

（出典：筆者作成）

全体傾向として正解率が売上額 10%削減データに比して概ね 15%ポイント程度悪化した。最も正解率が高かったのは、売上額で全科目を除算したデータ又はミニマックススケーリング（行方向）を実施したデータで学習した SVM で、正解率は 71.8%であった。スケーリング手法別に最高精度を達成した機械学習手法を確認すると、SVM が 5つのスケーリング手法で、ランダムフォレストが 2つのスケーリング手法で最高精度を達成した。機械学習手法ごとに正解率の平均値を算出すると、売上額を 10%削減したデータに対する予測同様にランダムフォレストが最も精度が高く、70.1%であった。

以上から、売上額を 10%又は 5%削減した場合は、高精度が期待されるスケーリング手法、機械学習手法は同じような傾向を示しているものと考えられる。

ハ 売上額 2.5%削減データ

売上額を 2.5%削減したデータに対する正解率は表 2-11 「売上額 2.5%削減データに対する予測精度（正解率）」のとおり。

【表 2-11】売上額 2.5%削減データに対する予測精度（正解率）

	L R	D T	R F	S V M	D L
スケーリングなし	55.3%	62.6%	55.8%	55.3%	54.4%
MM スケーリング（列方向）	57.8%	62.6%	57.3%	59.7%	54.4%
標準化	58.7%	62.6%	55.8%	58.7%	58.7%
ロバストスケーリング	58.3%	62.6%	55.8%	57.3%	58.7%
売上除算	59.7%	58.7%	60.2%	61.2%	54.9%
MM スケーリング（行方向）	59.7%	60.7%	58.7%	54.9%	59.2%
平均	58.3%	61.7%	57.3%	57.8%	56.7%
最高	59.7%	62.6%	60.2%	61.2%	59.2%
最低	55.3%	58.7%	55.8%	54.9%	54.4%
高低差	4.4%	3.9%	4.4%	6.3%	4.9%
標準偏差	0.016	0.016	0.018	0.025	0.024

（出典：筆者作成）

正解率は、売上額を 5%削減したデータに対する正解率よりも更に 15%ポイント程度悪化した。売上額削減前のデータにおいて原価率の標準偏差が 0.16（16%）程度であることを考慮すると、売上額 2.5%の削減はデータの一般的なばらつきの範囲内に収まり、損益計算書に与える影響が小さいため、予測難易度の高い問題であったと考えられる。

最も正解率が高かったのは、スケーリングなし、ミニマックススケーリング（列方向）、標準化又はロバストスケーリングでスケーリングしたデータで学習した決定木で、正解率は 62.6%であった。スケーリング手法別に最高精度を達成した機械学習手法を確認すると、決定木が 5つ、

SVM が 1 つのスケーリング手法で最高精度を達成した。機械学習手法ごとに正解率の平均値を算出すると、61.7%の決定木が最も高精度であった。

(2) 仕入額増加データ

イ 仕入額 10%増加データ

仕入額を 10%増加させたデータに対する正解率は表 2-12 「仕入額 10%増加データに対する予測精度 (正解率)」のとおり。

【表 2-12】仕入額 10%増加データに対する予測精度 (正解率)

	L R	D T	R F	S V M	D L
スケーリングなし	76.2%	77.7%	78.6%	51.9%	77.7%
MM スケーリング (列方向)	75.7%	78.6%	78.6%	78.2%	58.7%
標準化	76.7%	77.7%	78.6%	79.6%	75.2%
ロバストスケーリング	77.7%	77.7%	78.6%	82.5%	76.7%
売上除算	75.7%	79.1%	83.5%	82.0%	74.8%
MM スケーリング (行方向)	79.1%	81.1%	81.6%	81.6%	80.1%
平均	76.9%	78.6%	79.9%	76.0%	73.9%
最高	79.1%	81.1%	83.5%	82.5%	80.1%
最低	75.7%	77.7%	78.6%	51.9%	58.7%
高低差	3.4%	3.4%	4.9%	30.6%	21.4%
標準偏差	0.013	0.013	0.021	0.119	0.077

(出典：筆者作成)

正解率は概ね 70%台後半程度であった。最も精度が高かったのは、売上額で全科目を除算したデータで学習したランダムフォレストで正解率は 83.5%であった。スケーリング手法別に最高精度を達成した機械学習手法を確認すると、ランダムフォレスト及び SVM がそれぞれ 3 つのスケーリング手法で最高精度を達成した。機械学習手法ごとに正解率の平均値を算出すると、79.9%のランダムフォレストが最も高精度であっ

た。SVM はスケーリングしない場合には、正解率が 51.9%と極端に低くスケーリング手法の違いによって正解率に大きなバラつきが認められた。また、深層学習も正解率に大きなバラつきが認められた。

ロ 仕入額 5%増加データ

仕入額を 5%増加させたデータに対する正解率は表 2-13「仕入額 5%増加データに対する予測精度（正解率）」のとおり。

【表 2-13】仕入額 5%増加データに対する予測精度（正解率）

	L R	D T	R F	S V M	D L
スケーリングなし	63.6%	60.2%	60.2%	43.7%	65.1%
MM スケーリング（列方向）	65.1%	60.2%	59.7%	66.5%	59.7%
標準化	66.0%	60.2%	60.2%	66.0%	61.2%
ロバストスケーリング	63.6%	60.2%	60.2%	64.6%	61.7%
売上除算	67.0%	64.1%	68.9%	67.0%	57.8%
MM スケーリング（行方向）	65.1%	64.1%	66.0%	66.0%	64.1%
平均	65.0%	61.5%	62.5%	62.3%	61.6%
最高	67.0%	64.1%	68.9%	67.0%	65.1%
最低	63.6%	60.2%	59.7%	43.7%	57.8%
高低差	3.4%	3.9%	9.2%	23.3%	7.3%
標準偏差	0.013	0.020	0.039	0.092	0.027

（出典：筆者作成）

正解率は、仕入額を 10%増加させたデータに対する正解率に比して概ね 15%ポイント程度悪化している。最も正解率が高かったのは、売上額で全科目を除算したデータで学習したランダムフォレストで正解率は 68.9%であった。スケーリング手法別に最高精度を達成した機械学習手法を確認すると、SVM が 4つのスケーリング手法で、ランダムフォレストが 2つのスケーリング手法で最高精度を達成した。機械学習手法ごと

に正解率の平均値を算出すると、65.0%のロジスティック回帰が最も高精度であった。

また、SVM はスケーリングしない場合には正解率が 43.7%であり、ランダムに選択した場合の期待値 (50.0%) を下回ることから、学習が適切に進まなかったことが確認できる。

ハ 仕入額 2.5%増加データ

仕入額を 2.5%増加させたデータに対する正解率は表 2-14 「仕入額 2.5%増加データに対する予測精度 (正解率)」のとおり。

【表 2-14】仕入額 2.5%増加データに対する予測精度 (正解率)

	L R	D T	R F	S V M	D L
スケーリングなし	53.4%	56.8%	52.9%	52.4%	47.1%
MM スケーリング (列方向)	54.9%	56.8%	52.4%	56.8%	52.9%
標準化	55.3%	56.8%	52.9%	56.8%	58.7%
ロバストスケーリング	55.3%	56.8%	52.9%	55.3%	60.7%
売上除算	58.7%	56.8%	55.3%	61.2%	53.4%
MM スケーリング (行方向)	57.8%	56.8%	57.3%	59.2%	53.4%
平均	55.9%	56.8%	54.0%	57.0%	54.4%
最高	58.7%	56.8%	57.3%	61.2%	60.7%
最低	53.4%	56.8%	52.4%	52.4%	47.1%
高低差	5.3%	0.0%	4.9%	8.7%	13.6%
標準偏差	0.020	0.000	0.019	0.030	0.048

(出典：筆者作成)

仕入額を 2.5%増加させたデータに対する正解率は、仕入額を 5%増加させたデータに対する正解率に比して概ね 10%ポイント程度悪化した。売上額を 2.5%削減させたデータと同様に予測難易度が高い問題であったと考えられる。最も予測精度が高かったのは、売上額で全科目を除算

したデータで学習した SVM で正解率は 61.2%であった。スケーリング手法別に最高精度を達成した機械学習手法を確認すると、決定木、SVM 及び深層学習がそれぞれ 2 つのスケーリング手法で最高精度を達成した。機械学習手法ごとに正解率の平均値を算出すると、57.0%の SVM が最も高精度であった。

4 全体考察

(1) スケーリング手法

スケーリング手法ごとの予測精度は表 2-15「スケーリング手法ごとの予測精度（平均正解率）」のとおり。

【表 2-15】スケーリング手法ごとの予測精度（平均正解率）

	売上削減			仕入増加			平均
	10%	5%	2.5%	10%	5%	2.5%	
スケーリングなし	84.3%	65.6%	56.7%	72.4%	58.5%	52.5%	65.0%
MM スケーリング (列方向)	85.0%	67.9%	58.4%	74.0%	62.2%	54.8%	67.0%
標準化	85.2%	69.1%	58.9%	77.6%	62.7%	56.1%	68.3%
ロバストスケーリング	84.8%	69.2%	58.5%	78.6%	62.0%	56.2%	68.2%
売上除算	86.6%	69.7%	58.9%	79.0%	65.0%	57.1%	69.4%
MM スケーリング (行方向)	85.2%	69.1%	58.6%	80.7%	65.1%	56.9%	69.3%

(出典：筆者作成)

スケーリング手法ごとの予測精度の平均値を比較すると、最も予測精度が高かったのは、売上額で全科目を除算する手法で平均正解率が 69.4%、次にミニマックススケーリング（行方向）で 69.3%であり、いずれも行方向に対する変換であった。機械学習でよく使用されるライブラリである scikit-learn ではスケーリングの初期設定が列方向のスケーリングである

など、機械学習一般にはスケーリングは列方向に行うことが多いが、本件サンプルデータに対しては、異なる損益計算書の同一勘定科目の数値を用いる列方向のスケーリングではなく、同じ損益計算書内の数値を用いてスケーリングする方がその後の機械学習でより良い結果を得られることが確認できた。これは、損益計算書を分析する際に、売上額等の多寡を企業間で単純比較するのではなく、原価率など収益と費用のバランスを重視した分析を行うことに相当するため、専門家が行う損益計算書分析の手法と整合する。

次に列方向の数値を用いるミニマックススケーリング（列方向）、標準化及びロバストスケーリングを比較すると、ミニマックススケーリング（列方向）が他の2手法に比較して1%ポイント以上精度が低かった。これは、本件サンプルデータに外れ値が存在し、データの偏りも大きい（歪度 18.15、尖度 467.90）ことが要因として考えられる。

最も予測精度が低かったのは、スケーリングを行わない場合で、ミニマックススケーリング（列方向）よりも正解率が更に2%ポイント低かった。特に SVM において、スケーリングを実施しない場合の予測精度低下は顕著であった。

以上から、今回用いた機械学習手法の全体傾向としては、損益計算書データに対してスケーリングすることが有効であり、スケーリングの方向は列方向よりも行方向に実施することが予測精度の向上に寄与すると考えられる。

(2) 機械学習手法

機械学習手法別の最高精度獲得状況は表 2-16「機械学習手法別の最高精度獲得状況」のとおり。

【表 2-16】 機械学習手法別の最高精度獲得状況

	L R	D T	R F	S V M	D L
売上 10%削減				○	
売上 5%削減				○	
売上 2.5%削減		○			
仕入 10%増加			○		
仕入 5%増加			○		
仕入 2.5%増加				○	

(出典：筆者作成)

最高精度を最も多く達成したのは、SVM の 3 回で、次にランダムフォレストの 2 回であった。

機械学習手法別の予測精度平均値の最高精度獲得状況は表 2-17「機械学習手法別の予測精度平均値の最高精度獲得状況」のとおり。

【表 2-17】 機械学習手法別の予測精度平均値の最高精度獲得状況

	L R	D T	R F	S V M	D L
売上 10%削減			○		
売上 5%削減			○		
売上 2.5%削減		○			
仕入 10%増加			○		
仕入 5%増加	○				
仕入 2.5%増加				○	

(出典：筆者作成)

機械学習手法ごとの正解率の平均値で最高精度を最も多く達成したのは、ランダムフォレストの 3 回で、次にロジスティック回帰、決定木及び SVM の 1 回であった。ランダムフォレスト及び決定木は列方向のスケーリングの影響を受けない手法であるため、予測精度が安定していたことが要因として考えられる。

学習データ 6 種類及びスケーリング手法 6 種類の組み合わせ全 36 パターン別に予測精度の順位を集計した結果は表 2-18「機械学習手法ごとの順位回数」のとおり。

【表 2-18】機械学習手法ごとの順位獲得回数 (回)

	L	R	D	T	R	F	SVM	D	L
1 位獲得回数		1		8		11		19	3
2 位獲得回数		16		4		8		6	4
3 位獲得回数		12		9		5		4	5
4 位獲得回数		6		12		7		3	5
5 位獲得回数		1		3		5		4	19

(出典：筆者作成)

最高精度を最も多く達成したのは、SVM の 19 回、次にランダムフォレストの 11 回であった。表 2-16「機械学習手法別の最高精度獲得状況」及び表 2-18「機械学習手法ごとの順位回数」の結果から、損益計算書を用いた予測タスクで高い精度を求める場合、SVM 及びランダムフォレストが有効である可能性が示唆される。

データの種類別に各機械学習手法の平均正解率を算出した結果は表 2-19「6 種類のスケーリング手法に対する予測精度の平均値 (正解率)」のとおり。

【表 2-19】 6 種類のスケーリング手法に対する予測精度の平均値（正解率）

	L R	D T	R F	S V M	D L
売上額 10%削減	86.1%	83.5%	86.4%	86.1%	83.9%
売上額 5%削減	69.7%	69.3%	70.1%	69.4%	63.8%
売上額 2.5%削減	58.3%	61.7%	57.3%	57.8%	56.7%
仕入額 10%増加	76.9%	78.6%	79.9%	76.0%	73.9%
仕入額 5%増加	65.0%	61.5%	62.5%	62.3%	61.6%
仕入額 2.5%増加	55.9%	56.8%	54.0%	57.0%	54.4%
平均	68.6%	68.6%	68.4%	68.1%	65.7%
標準偏差平均	0.014	0.010	0.017	0.055	0.038

（出典：筆者作成）

深層学習以外は、「平均」が 68%台であり、大きな差は認められなかった。また、表 2-18「機械学習手法ごとの順位回数」において 1 位を多く獲得した SVM 及びランダムフォレストよりもロジスティック回帰及び決定木の方が予測精度の平均値で高い値を示した。このことは、SVM 及びランダムフォレストは高精度を示すことが多いものの、安定性を欠いていることを示唆している。

本稿の検証結果は、同じ損益計算書を基に売上又は仕入の数値を変更したデータであっても最高精度を達成する手法は一つに定まらず、前述（第 1 章第 3 節 4「手法の選択」）のとおり、事前にどの手法が最良であるのかを予測することが難しいとされていることを確認する結果となった。このことから、高い予測精度を期待する場合は事前に学習手法を特定することなく、幅広く予測モデルを作成した上で、実運用すべきモデルを選定することが望ましい。また、その際にはモデルの予測精度や安定性等の判断基準を利用予定の業務特性に応じて定め、これらを踏まえてモデルを選定することが望ましい。

5 機械学習の手法別考察

(1) ロジスティック回帰

ロジスティック回帰の学習では、`scikit-learn` を使用し、パラメータは指定せず初期値で学習した。


ロジスティック回帰は、学習データ別（表 2-16）では最高精度の達成は一度もなく、学習データ及びスケーリング手法の組み合わせ別（表 2-18）に確認した場合に最高精度を 1 度達成したのみであった。しかし、表 2-18 「機械学習手法ごとの順位回数」に示すとおり、正解率が 2 位又は 3 位となることが多く、検証した 5 つの機械学習の手法の中では中間的な予測精度のモデルであった。

パラメータの調整をすることなく初期値であっても安定的な予測精度を記録している点や、学習後には係数を取得して予測結果に対する各説明変数の貢献度を確認できる点から、他のモデルの比較対象となるベースラインモデルとしても利用価値がある機械学習手法であると考えられる。

決定境界の形状を確認するため、売上及び仕入データのみを取得し、可視化用に別途学習させた。可視化結果は図 2-4 「ロジスティック回帰の決定境界」のとおり。

なお、当該モデルは決定境界を可視化するためのモデルであり、本章で予測精度を考察したモデルとは別モデルである（以下、決定境界に対する考察において同じ。）。

【図 2-4】ロジスティック回帰の決定境界



(出典：筆者作成)

図 2-4 「ロジスティック回帰の決定境界」は、売上を横軸 (x 軸)、仕入を縦軸 (y 軸) としており、丸印 (●) が陽性データ (売上額を 10%削減させたデータ)、下三角印 (▼) が陰性データ (正常データ) である (以下、決定境界の図において同じ)。

本件サンプルデータでは、売上と仕入の相関係数が 0.99 と極めて高い正の相関を示しており、一方が増加すると他方も増加する関係にある。どの企業も原価率が等しいと仮定すると各データ点は傾きを正とする一直線に並ぶこととなるが、実際は企業ごとに原価率が異なることから、仮定した直線上から離れた位置に下三角印が付されている。更に、丸印のデータは、売上額を実際よりも 10%削減されているため、本来プロットされる位置よりも x 軸と平行に負の方向に移動している。

ロジスティック回帰は、このようにデータをプロットした空間に直線を

引くことで、丸印と下三角印を分離する手法であり、図 2-4 「ロジスティック回帰の決定境界」では網掛け部分に付された点を正常データと判断している。ロジスティック回帰はこのように 1 本の直線でシンプルな決定境界を作成するため、本章で検証した他の学習手法に比べると過学習⁽⁴⁸⁾に強い手法といえる。

(2) 決定木

決定木の学習では、`scikit-learn` を使用し、パラメータは `max_depth` (決定木の深さ) のみ設定した (`max_depth=5`)。

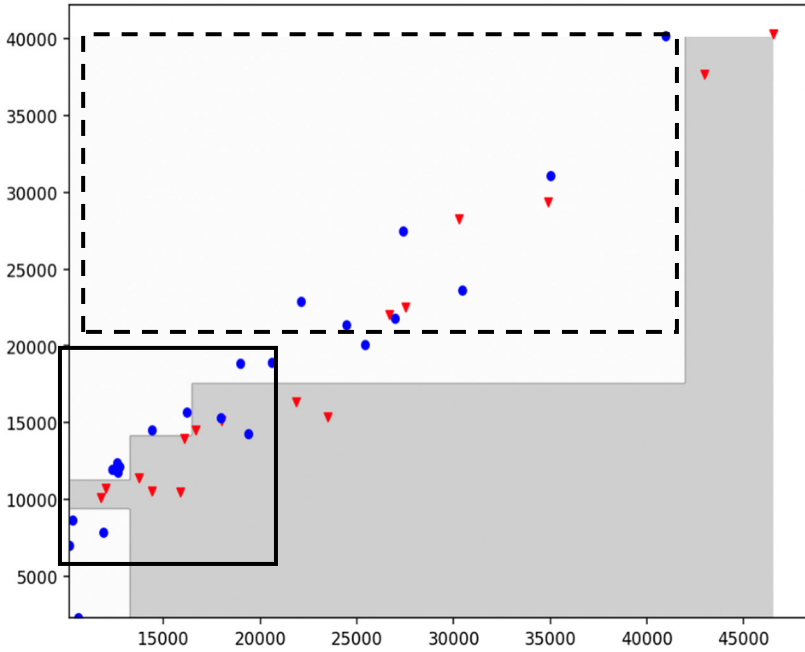
決定木は、学習データ別 (表 2-16) では最高精度の達成が売上額 2.5% 削減に対する 1 度のみであった。当該学習データを使用した場合は、売上額で全科目を除算する手法を除き他の学習手法よりも優れていた (表 2-11 「売上額 2.5%削減データに対する予測精度 (正解率)」参照。)。しかしながら、表 2-18 「機械学習手法ごとの順位回数」に示すとおり、正解率の順位は 4 位の獲得回数が 12 回と最も多く、今回の検証においては相対的に精度が低い学習手法であった。

列方向のスケーリングに対しては、仕入額を 10%増加させたデータで学習した場合におけるミニマックススケーリング (列方向) を除き、正解率に変化が認められなかった。一般的に決定木は、スケーリングによる予測精度の変化が見込まれないことから、スケーリング不要の手法として知られているが、本稿における検証結果もこのことと整合する。一方で、行方向に対するスケーリングを実施した場合には、予測精度の向上が認められた。これは、行方向にスケーリングすることで散布図の形状 (データの列方向に対する位置関係) が変化したことに起因すると考えられる。

決定木の決定境界は下図 2-5 「決定木の決定境界 (`max_depth=5`)」のとおり。

(48) 訓練データに対してモデルが過剰に適合し、汎化性能が低下する現象。

【図 2-5】決定木の決定境界 (max_depth=5)




(出典：筆者作成)

決定木は x 軸、y 軸に対して垂直な直線を組み合わせて決定境界を作成するため、本件サンプルデータのように斜めに分布する(相関関係がある)データに対して、分岐が少ない木では決定境界を散布図の形状に適合させることが困難である。分岐を増やすことで、斜め方向に階段状に決定境界を作成することは可能であるが、その場合は決定木の利点である説明性を犠牲にすることとなる。このことから、予測精度と説明性のバランスを見極めながら木の深さなどのパラメータを調整する必要がある。

図 2-5「決定木の決定境界 (max_depth=5)」では、実線四角部分はデータ分布への適合が期待できるものの、破線四角部分では全てのデータを誤りのある損益計算書と予測するため適切に学習していないことが確認で

きる。訓練データに更に適合させるため、木の深さについての制限を解除し再度学習させたところ下図 2-6「決定木の決定境界(木の深さ無制限)」の決定境界を得た。

【図 2-6】決定木の決定境界（木の深さ無制限）



(出典：筆者作成)

破線部分に大きな切れ込みが入り、過学習していることが確認できる。このように決定木は、過学習が生じやすい傾向にあるため、パラメータ調整は慎重に行う必要がある。

(3) ランダムフォレスト

ランダムフォレストの学習では、`scikit-learn` を使用し、パラメータは `max_depth` (決定木の深さ) のみ設定した (`max_depth=5`)。

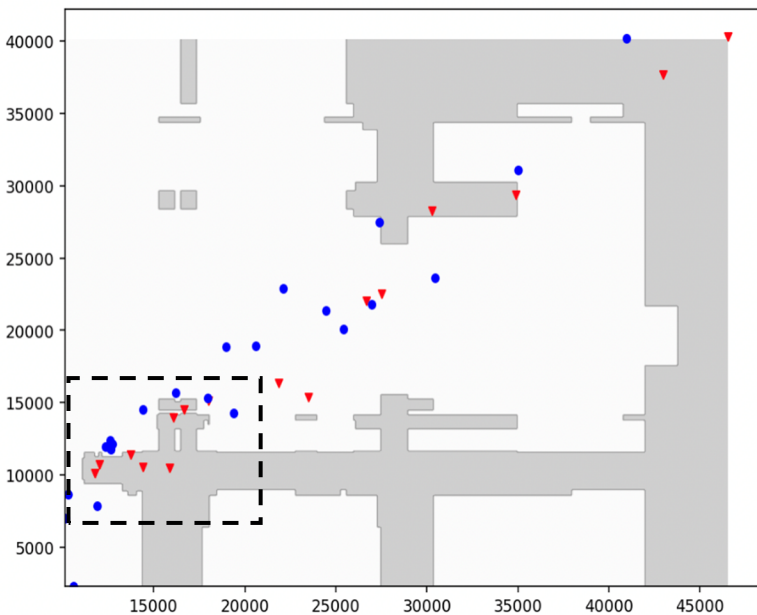
ランダムフォレストは、学習データ別 (表 2-16) では最高精度を 2 回記録し、学習データ及びスケーリング手法の組み合わせ別 (表 2-18) で

も最高精度を 11 回記録しており、今回の検証においては相対的に高精度な学習手法であった。列方向のスケーリングに対しては、売上額を 2.5%削減したデータにおけるミニマックススケーリング（列方向）及び仕入額を 5%増加させたデータにおけるミニマックススケーリング（列方向）を除き、正解率に変化が認められなかった。

一方で、行方向に対するスケーリングでは精度の向上が確認できた。ランダムフォレストは、決定木を組み合わせた手法であるため、決定木の特徴と同様の特徴を示したことが確認された。

ランダムフォレストの決定境界は下図 2-7 「ランダムフォレストの決定境界（max_depth=5）」のとおり。

【図 2-7】ランダムフォレストの決定境界（max_depth=5）



(出典：筆者作成)

ランダムフォレストも決定木同様に x 軸、 y 軸に対して垂直な直線を組み合わせて決定境界を作成する。決定木に比べて複雑な決定境界を作成する傾向にあるため、より細やかな分類が可能となる。しかしながら、破線部分の決定境界は陽性データ（丸印）を避けるような極端な形状が認められ過学習していることが確認できる。ランダムフォレストは、今回の検証において優れた予測精度を発揮したが、過学習させないようパラメータの調整は慎重に実施する必要がある。

(4) SVM

SVM の学習では、scikit-learn を使用し、パラメータは kernel（カーネル）のみ調整した。具体的には、linear、rbf、poly、sigmoid の 4 種類のカーネルについて学習させ、最高精度のモデルの正解率を SVM の正解率として採用した。

SVM は、学習データ別（表 2-16）では最高精度を 3 回記録し、学習データ及びスケーリング手法の組み合わせ別（表 2-18）でも最高精度を 19 回記録するなど、今回の検証においては最も高精度な学習手法であった。

しかし、表 2-20 「6 種類の学習データに対する予測精度の平均値」のとおり、スケーリング手法別に予測精度の平均値を算出すると、SVM はスケーリングを実施しない場合に予測精度が大きく低下していることが確認できる。このことから、SVM を利用する場合には、スケーリングが極めて重要であると考えられる。


【表 2-20】 6 種類の学習データに対する予測精度の平均値

	L R	D T	R F	S V M	D L
スケーリングなし	67.3%	68.3%	67.3%	57.8%	64.3%
MM スケーリング (列方向)	67.7%	68.4%	67.4%	69.8%	61.8%
標準化	68.8%	68.3%	67.3%	69.6%	67.5%
ロバストスケーリング	68.3%	68.3%	67.3%	69.3%	68.0%
売上除算	69.7%	68.6%	70.9%	71.8%	65.9%
MM スケーリング (行方向)	70.0%	69.4%	70.1%	70.1%	66.7%

(出典：筆者作成)

SVM の決定境界は下図 2-8 「SVM の決定境界」 のとおり。

【図 2-8】 SVM の決定境界



(出典：筆者作成)

左は linear カーネル、右は poly カーネルを使用したもの。poly カーネルは曲線の決定境界を作成できるため、直線の決定境界よりもデータの分布状況により適合することが期待される。

(5) 深層学習

深層学習は、TensorFlow Keras を使用した。TensorFlow Keras では、ニューラルネットワークの層の数や幅の広さなどを利用する機器のリソースが対応可能な範囲で任意に組み合わせることができる。そのため、モデルデザインの自由度が高くモデル作成者の熟練度により予測精度に大きな差が生じる。本稿で利用したモデルのアーキテクチャは表 2-21 「ニューラルネットワークアーキテクチャ」のとおり。

【表 2-21】ニューラルネットワークアーキテクチャ

Layer	Output Shape	Param
Dense	(None,32)	384
Dense	(None,64)	2,112
batch normalization	(None,64)	256
Dense	(None,128)	8,320
batch normalization	(None,128)	512
Dense	(None,64)	8,256
Dense	(None,1)	65

Total params:19,905

Trainable params:19,521

Non-trainable params:384

(出典：筆者作成)

深層学習は、学習データ別（表 2-16）では最高精度の記録はなく、学習データ及びスケーリング手法の組み合わせ別（表 2-18）で最高精度を 3 回、最下位を 19 回記録するなど、今回の検証では精度が最も悪かった。しかし、深層学習は予測精度が偶然性の影響を受けやすいため、再度新たに学習することで予測精度が変化することが考えられる。これは、単純な学習手法であるロジスティック回帰の学習パラメータ数が 12（説明変数の数及び切片）であることに対して、表 2-21 「ニューラルネットワークア

「アーキテクチャ」に示したニューラルネットワークは学習パラメータ数が 19,521 と極端に多く、これらの学習パラメータへランダムに割り当てられる初期値が学習後の予測精度に影響を与えるためである。

学習パラメータの初期値のランダム性がもたらす予測精度への影響を確認するため、売上 10%削減データに対してスケーリング手法ごとにパラメータの初期値を 100 パターン作成してそれぞれ学習させた。結果は表 2-22 「深層学習 100 回試行予測精度」のとおり。

【表 2-22】深層学習 100 回試行予測精度

	スケーリングなし	MM スケーリング (列方向)	標準化	ロバストスケーリング	売除 上算	MM スケーリング (行方向)
平均	84.6%	85.3%	83.6%	84.2%	85.9%	84.1%
標準偏差	0.024	0.016	0.023	0.030	0.018	0.030
最小値	75.2%	76.7%	76.2%	70.9%	78.2%	69.4%
第 1 四分位	83.0%	85.0%	82.5%	83.0%	85.3%	83.0%
第 2 四分位	85.0%	85.4%	84.0%	85.0%	86.4%	84.5%
第 3 四分位	86.4%	86.0%	85.0%	86.0%	86.9%	86.4%
最大値	88.3%	87.9%	86.9%	89.3%	88.3%	87.9%

(出典：筆者作成)

【表 2-23】スケーリング手法別最高予測精度


	スケーリングなし	MM スケーリング (列方向)	標準化	ロバストスケーリング	売除 上算	MM スケーリング (行方向)
最高精度	86.4%	87.9%	86.4%	86.4%	87.9%	87.4%
学習手法	R F	SVM	R F	R F	SVM	SVM

100 パターン作成したうち最も正解率が高かったモデル（表 2-22 「深層学習 100 回試行予測精度」における「最大値」）の値は、表 2-23 「ス

「スケーリング手法別最高予測精度」に示す他の学習手法が記録した最も高い正解率の値以上であることが確認できる。

また、スケーリング手法別の予測精度のヒストグラムは図 2-9 「スケーリング手法別予測精度ヒストグラム」のとおり。

【図 2-9】スケーリング手法別予測精度ヒストグラム




(出典：筆者作成)

全てのスケーリング手法で最高精度と最低精度に 10%ポイント以上の差があること、ミニマックススケーラ (列方向) 及び売上額で全科目除算したデータを用いて学習したモデルの予測精度が安定している (ばらつきが少ない) ことが確認できる。

このように、深層学習では初期値によって学習後の予測精度に差が生じることが知られている。そのため、予測モデルの精度を高めるためにどのような分布から初期値をランダムサンプリングすべきかについての研究が行われてきた。本稿では、学習パラメータへの初期値の割り当てに Xavier

の初期化⁽⁴⁹⁾を利用したが、この他に He の初期化⁽⁵⁰⁾も多く利用される。
 深層学習の決定境界は下図 2-10 「深層学習の決定境界」のとおり。

【図 2-10】 深層学習の決定境界



(出典：筆者作成)

深層学習の決定境界は複雑な形状を学習可能であるが、図 2-10 「深層学習の決定境界」ではシンプルな決定境界が示されている。これは、学習

-
- (49) Xavier Glorot et al(2010) "Understanding the difficulty of training deep feedforward neural networks." Proceedings of the thirteenth international conference on artificial intelligence and statistics. JMLR Workshop and Conference Proceedings, 2010. <http://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf> (令和 5 年 3 月 4 日最終閲覧日)。
- (50) He, Kaiming, et al(2015) . "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification." Proceedings of the IEEE international conference on computer vision.2015. https://openaccess.thecvf.com/content_iccv_2015/html/He_Delving_Deep_into_ICCV_2015_paper.html(令和 5 年 3 月 4 日最終閲覧日)。

に利用した売上と仕入の相関係数が 0.99 と極めて高い正の相関を示しており、概ね直線状に分布していること、データの可視化のために学習に利用する説明変数を 2 変数に限定したことなどが原因として考えられる。

6 小括

最適な機械学習手法を事前に選択することは困難であることから、予測モデルを作成する際には、複数の予測モデルを並行して作成した上で、最適な予測モデルを選択することが望ましい。本検証では、本件サンプルデータから 6 種類のデータセットを作成し、6 種類のスケーリング手法及び 5 種類の機械学習手法を組み合わせることで予測モデルを構築し、その予測精度を比較した。その結果、SVM 及びランダムフォレストは最高精度の達成頻度が高く、ロジスティック回帰は安定して中間的な予測精度を記録し、決定木及び深層学習は予測精度が下位になる傾向があることが確認された。しかしながら、機械学習の手法ごとに予測精度の平均値を算出すると、深層学習以外はすべて 68% 台であり、大きな差が認められなかった（表 2-19 「6 種類のスケーリング手法に対する予測精度の平均値（正解率）」参照）。このことは、SVM 及びランダムフォレストは高精度を示すことが多いものの、安定性を欠いていることを示唆している。また、深層学習は、学習パラメータが多く、ランダムに割り当てられる初期値の影響によって予測性能が安定しないものの、初期値の値によっては他の機械学習手法よりも高精度を記録した。以上のように、同じ損益計算書データを利用した予測モデルであっても、条件をわずかに変更するだけで最高精度を記録する機械学習手法が異なることから、最適な機械学習手法を事前に選択することは困難である。そのため、実務において予測モデルを作成する際には、第 1 章で述べた計算コスト並びに説明性及び解釈性の要求レベルを考慮の上、複数のモデルを並行作成しつつ、過学習のリスクなど各機械学習手法の特徴及び利用予定の業務に応じた判断基準を踏まえて、最適なモデルを選択することが望ましい。

第 3 章 AI の説明性及び解釈可能性

第 1 節 AI に対する社会的要請

近年 AI は、自動車産業における自動運転、医療分野における画像診断、金融業における審査業務など、ヒトの生命、身体、財産に影響を及ぼす分野においても導入や導入に向けた検討が進められている。このような背景から、AI に対して公平性及び透明性のある意思決定とその結果に対する説明責任（アカウンタビリティ）の適切な確保が求められている⁽⁵¹⁾。第 3 章では、これらの社会的要請に留意しつつ、AI の予測結果を利用する部署にとって受け入れられやすい AI を開発するために留意すべき点について考察する。

第 1 節では、AI に対する社会的要請である公平性、透明性及び説明責任の内容を確認する。AI が出した予測結果について、その理由や根拠が不明瞭だとこのような社会的要請に応えることが困難となるため、AI の説明性及び解釈性が重要となる。そこで、第 2 節では、ブラックボックス型 AI 及びホワイトボックス型 AI それぞれの説明性及び解釈性について考察する。第 3 節では、AI の予測結果を利用者が受け入れやすくなるように、ブラックボックス型 AI 及びホワイトボックス型 AI の説明性及び解釈性の改善策を提案する。併せて、AI に求められる社会的要請である公平性、透明性及び説明責任の確保に向けた具体策を提案する。

1 AI に求められる公平性

AI の公平性とは、AI 利活用ガイドラインによるとバイアスによって個人及び集団が不当に差別されないこと⁽⁵²⁾を指すものと考えられる。また、ここ

(51) 統合イノベーション戦略推進会議平成 31 年 3 月 29 日「人間中心の AI 社会原則」11 頁。

(52) AI ネットワーク社会推進会議令和元年 8 月 9 日「AI 利活用ガイドライン～AI 利活用のためのプラクティカルリファレンス～」10 頁。

でいうバイアスとは、サンプリングバイアス、認知バイアス及び感情バイアス等を総称したもの⁽⁵³⁾を指す。人間中心の AI 社会原則では、バイアスの例として人種、性別、国籍、年齢、政治的信条、宗教⁽⁵⁴⁾が挙げられており、このようなバックグラウンドを理由に AI によって不当な差別を受けることなく人々が公平に扱われることを求めている。

2 AI に求められる透明性

AI の透明性とは、入出力データに関する検証可能性及び判断結果の説明可能性を確保⁽⁵⁵⁾することを要請するものと考えられる。AI 利活用ガイドラインでは、透明性に関して AI の入出力ログの記録保存という技術的な要請に加え、利用者の納得感や安心感の獲得という解釈性の確保及び AI の動作に対する証拠の提示等を目的とする判断結果の説明性確保が必要であることを述べている。更に行政機関が AI を利用する場合には、法の支配、行政の透明性確保、適正手続の要請も踏まえた説明性の確保を要請している。

3 AI に求められる説明責任

説明責任とは、Accountability の訳語である。Accountability という単語の解釈については、学術論文でも諸説論じられ、必ずしも統一された解釈は示されていないが、本稿では AI の出力に対する責任の所在を明確にし、AI の使用や出力結果に対して説明を求められた際に適切に説明することを要請するものと定義する。AI 利活用ガイドラインでは、AI の判断が直接に消費者的利用者や第三者に対して影響を及ぼす態様により AI を利活用する場合には、消費者的利用者や第三者が AI の利活用について適切に認識することができるよう AI に関する利用方針を作成・公表することを求めている⁽⁵⁶⁾。

(53) AI ネットワーク社会推進会議・前掲注(52)23 頁。

(54) 統合イノベーション戦略推進会議・前掲注(51)11 頁。

(55) AI ネットワーク社会推進会議・前掲注(52)10 頁。

(56) AI ネットワーク社会推進会議・前掲注(52)25 頁。

4 小括

AI の利用に当たっては、公平性、透明性及び説明責任の確保が求められる。公平性とは、バイアスによる不当な差別を行わないことである。透明性の確保とは、入出力データに関する検証可能性及び判断結果の説明可能性を確保することである。説明責任の確保とは、AI の使用や出力結果に対して説明を求められた際に適切に説明することを要請するものである。

第 2 節 AI の説明性及び解釈可能性

AI が出した予測結果について、その理由や根拠が不明瞭だと AI に求められる社会的要請である公平性、透明性及び説明責任の確保が困難となるため、AI の説明性及び解釈性が重要となる。第 2 節では、AI のブラックボックス化が説明性及び解釈性の阻害要因となることを、予測結果の理解及びモデルの理解という 2 つの観点から考察する。併せて、ホワイトボックス型とされる AI が持つ説明性及び解釈性を考察した上で、その限界を指摘する。

1 AI の説明性及び解釈可能性

AI に求められる社会的要請を果たすためには、説明性及び解釈性が重要となる。AI の説明性及び解釈性については、統一的な定義は存在しない。本稿では、説明性は予測結果又は予測モデルを数学的に説明可能であり、その説明をヒトが理解できる形式で提示できることと定義する。

また、AI を数学的に理解できる場合であっても、その数学的理解が予測結果に納得感を与えるとは限らない。例えば、売上と仕入を用いて損益計算書の誤りを判定する AI で、売上額と仕入額の積が偶数になる場合に、「当該損益計算書は誤りである。」と判定する AI を提示された場合、計算方法、計算結果及び判定基準は数学的に明確であり、ヒトにとって理解可能である。しかし、その計算式及び計算結果と判定結果を結び付けて理解することはできない。売上額と仕入額の積が偶数になることと、損益計算書に誤りがあるこ

とは無関係と考えられることから、この AI では納得感が得られない。このように、AI の計算過程が数学的に明確であることと、予測結果に納得感を得られることは別の問題である。本稿では、AI の予測結果や予測モデルに対する数学的説明について、ヒトが予測結果と結び付けて理解可能であることを解釈性と定義する。


2 AI のブラックボックス化

機械学習では、内部の計算方式が複雑であるほど、入力に対する表現力を高めることができるため、より複雑な推論処理を模倣できる。しかし、内部の計算方式を複雑にすると、その表現を人間が理解することが困難になり、AI の解釈可能性が低くなるとされている⁽⁵⁷⁾。このことから、AI のブラックボックス化は AI に対する社会的要請である「公平性」、「透明性」及び「説明責任」の確保への阻害要因となるものと考えられる。ここでは、AI の説明性及び解釈性を考察するに当たり、予測結果の理解及びモデルの理解という 2 つの観点を導入する。その上で、これら 2 つの観点に沿ってブラックボックス型 AI の典型例である深層学習を考察し、AI がブラックボックス化することの問題点を指摘する。

機械学習の種類と対応可能な問題の複雑さの関係は概ね下図 3-1 「機械学習の種類と対応可能な問題の複雑さの関係」のようなイメージとなる。

(57) 坪直樹ほか『XAI (説明可能な AI) その時人工知能はどう考えたのか? [初版]』18 頁 (リックテレコム、2021 年)。

【図 3-1】機械学習の種類と対応可能な問題の複雑さの関係



(出典：坪直樹ほか・前掲注(57)18頁。)

図 3-1 「機械学習の種類と対応可能な問題の複雑さの関係」に示すとおり、ブラックボックスとされる機械学習手法の代表例は、深層学習（ディープラーニング）であるが、深層学習は機械学習である以上、人工的な「思考」や「感情」などに基づき判断するものではなく、数式により定義及び計算される。そのため、各ニューロンに入力される値や各ニューロンから出力される値の一つ一つは確認することができる。しかしながら、そういった個々の計算の確認を重ねて予測結果の出力値まで追ったとしても、なぜそのような計算を重ねることで正しい予測結果が出力されるのかということは理解できない。この点に機械学習におけるブラックボックスの本質があると考えられる。そして、この個々の計算の積み重ねを観察することでそのモデルを理解できないということは、次の 2 点においてモデルを利用する障壁となる。

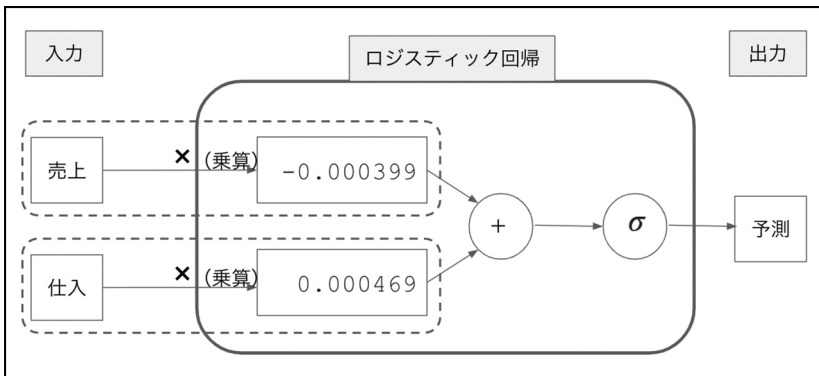
一つ目は、「予測結果の理解」が困難という点である。これは、モデルに入力した説明変数のうち、どの説明変数がどのように結果に影響を与えたのかを理解することが困難であることを指し、個々の予測結果が理解の対象となる。

二つ目は、「モデルの理解」が困難という点である。これは、モデルの全体的な予測傾向を理解することが困難であるということであり、モデルの内部構造が理解の対象となる。これら二つの理解について以下で具体的な数値を挙げて考察する。

(1) 予測結果の理解

予測結果の理解は、予測の基となる個々の入力値を用いて予測結果を理解しようとするものである。このような予測結果の理解を目的になされる説明を「局所説明」という。下図 3-2 「ロジスティック回帰のモデルイメージ」は、第 2 章第 2 節 5 「機械学習の手法別考察」において、示した決定境界の形状を確認するために作成したロジスティック回帰のモデルイメージである。ただし、簡略化のため切片は省略する。

【図 3-2】ロジスティック回帰のモデルイメージ



(出典：筆者作成)

このロジスティック回帰のモデルは、入力値として受け取った売上額に係数「-0.000399」を乗じるとともに、仕入額に「0.000469」を乗じ、それぞれを加算した上でシグモイド関数により 0～1 までの値（確率）に変換して予測値とする。仮に売上額が「10,000」、仕入額「9,000」の場合、係

数をそれぞれ乗じると売上については約「-4.0」、仕入については約「4.2」となり、これらを加算すると「0.2」、シグモイド関数による変換で約「0.56」となる。今回用いたロジスティック回帰の設定では出力値が 0.5 を超えるものは陽性判定（誤りのある損益計算書であるという判定。）するため、「0.56」という計算結果は陽性となる。

この結果に対する局所説明の例は、「10,000 の売上額は結果を陰性方向に約-4.0 引き下げることに貢献し、9,000 の仕入額は結果を陽性方向に約 4.2 押し上げることに貢献した（いずれもシグモイド関数による変換前の値。）」である。これは、陰性（誤りのない損益計算書）と判定するには「売上額が少ない」又は「仕入額が多い」のいずれかであるということを表している。このように局所説明は、個々の予測結果とその予測の基となる入力値に対して行われる。そのため、予測結果を利用するユーザー部署において特に重要視される説明である。

（2）モデルの理解

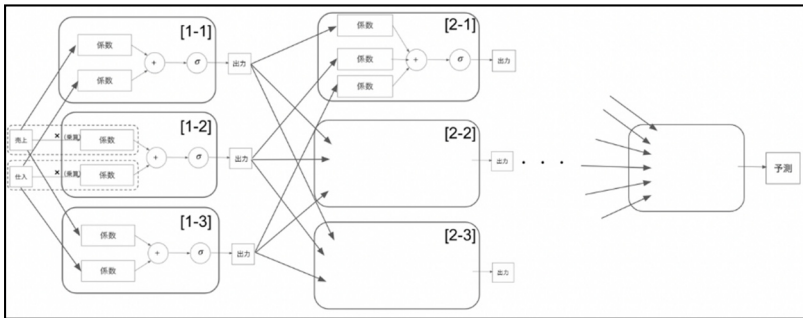
モデルの理解とは、モデルの内部構造を理解することで、モデルの予測傾向を把握することである。図 3-2 「ロジスティック回帰のモデルイメージ」におけるロジスティック回帰では、売上額に乘じる係数は「-0.000399」、仕入額に乘じる係数は「0.000469」である。このことから、このロジスティック回帰のモデルは入力される売上額が増加すると負の値を大きくするため陰性（誤りのない損益計算書）と判断する傾向が強くなり、仕入額が増加すると正の値を大きくするため陽性（誤りのある損益計算書）と判断する傾向が強くなることが理解できる。また、売上額と仕入額に同じ数値が入力された場合には、僅かに仕入額の反応が大きくなる。

このようにモデルの全体的な理解をするための説明を「大域説明」という。モデルの内部を理解することで、モデルの精度改善、不適切なバイアスの検知などが可能となるため、大域説明はモデルの開発者やモデルの利用可否を判断する管理者にとって有用な説明である。

(3) 深層学習における予測結果の理解及びモデルの理解の困難性

深層学習においてもロジスティック回帰と同様に、入力値に対して係数を乗じた値をそれぞれ加算した上でシグモイド関数などの活性化関数で変換して出力値とする。下図 3-3 「深層学習のモデルイメージ」は深層学習のモデルを簡略化したイメージである（切片は省略する。）。

【図 3-3】 深層学習のモデルイメージ



(出典：筆者作成)

この図では、売上額は「1-1」、「1-2」及び「1-3」のそれぞれの箱に伝達され、そこで係数が乗じられる。この係数はそれぞれ独立した値である（係数は学習により獲得するもので、複数の係数が偶然一致することを妨げないが、通常異なる値である）。売上額の値を受け取った「1-1」、「1-2」及び「1-3」のそれぞれの箱では、ロジスティック回帰同様に売上額に係数を乗じた値を、仕入額に係数を乗じた値に加算し、活性化関数で変換して出力値を算出する。そして、この出力値を次の「2-1」、「2-2」及び「2-3」へ伝達する。前の層の出力値を受け取った「2-1」、「2-2」及び「2-3」では、受け取った値に係数を乗じて加算した上で活性化関数による変換を行い出力値とする。深層学習では、この過程を何度か繰り返した後に予測値を出力する。このように深層学習においても、

個別の入力値と係数の乗算やノード内での加算は具体的な数値を観察できる。しかしながら、「1-1」、「1-2」及び「1-3」において売上額に乗じる係数の正負が異なるような場合に、この層だけをみても売上が結果に対して陽性方向（誤りのある損益計算書）へ貢献するのか陰性方向（誤りのない損益計算書）へ貢献するのかを判断できない。また、仮にこの層では、売上額に対する係数が全て正の値であったとしても、次の層で負の係数を乗じることになると評価は逆転する。更に、一度箱を通過すると（2層目以降では）売上額と仕入額それぞれに係数を乗じて加算した上で活性化関数によって変換した値が出力値となるため、次層以降のノードで前層から受け取った数値に乗じる係数を観察したところで、当初受け取った売上額、仕入額をどのように評価しているのかを数学的にヒトが理解できるように提示することは困難となる。そのため、深層学習は「予測結果の理解」の観点から、説明性が乏しい機械学習手法といえる。

また、モデル内の各係数を観察した場合、係数が膨大であり、かつ層が深くなるとその層で受け取る値自体の意味を理解できないことから、各係数が入力層で受け取った売上額及び仕入額をどのように評価しているのかを数学的に理解できない。このことから、深層学習は「モデルの理解」の観点からも説明性が乏しい機械学習手法といえる。

このように、深層学習は予測結果及びモデルを数学的に理解することが困難である。また、予測結果及びモデルに対する数学的説明を理解できない以上、それらを予測結果と結び付けて理解することも困難である。そのため、深層学習は、説明性及び解釈性に乏しい典型的なブラックボックス型 AI である。

（4）AI のブラックボックス化の問題点

AI のブラックボックス化は、説明性及び解釈性を損ない公平性及び透明性のある意思決定とその結果に対する説明責任の適切な確保に向けた阻害要因となる。ブラックボックス型 AI は予測結果及びモデルともに、数学的に理解することが困難であることから、説明性に乏しい。また、数学的

理解が困難である AI は、AI から出力される数学的説明を予測結果と結び付けて理解することも困難であることから、解釈性に乏しい。AI の説明性が乏しく、予測結果を数学的に理解できないという特性は、予測結果の説明が求められる透明性確保の阻害要因になると考えられる。また、AI の説明性が乏しく、モデルの理解が困難であるという特性は、AI がバイアスの影響を受け差別を助長するような基準によって予測する傾向を持った場合であっても、そのことを検知できないという問題につながり公平性の阻害要因になると考えられる。更に、AI の解釈性が乏しく、ヒトに納得感を与える予測結果を出力できないという特性は、AI の使用や出力結果に対して説明を求められた際に適切に説明することができないという結果を招き、説明責任の適切な確保の阻害要因となる。以上から、AI のブラックボックス化は、AI に対する社会的要請である公平性、透明性及び説明責任の確保に向けて阻害要因となる。

3 ホワイトボックス型 AI の説明力


図 3-1 「機械学習の種類と対応可能な問題の複雑さの関係」で示されるとおり、ロジスティック回帰及び決定木は一般にホワイトボックス型 AI とされている。ここでは、第 2 章第 2 節「予測モデル作成」において作成したロジスティック回帰及び決定木について、予測結果の理解及びモデルの理解の観点から説明性及び解釈性を考察する。

(1) ロジスティック回帰

図 3-2 「ロジスティック回帰のモデルイメージ」では、説明の簡略化のため第 2 章第 2 節 5 「機械学習の手法別考察」において示した決定境界の形状を確認するためのロジスティック回帰を例にした。このモデルは、売上及び仕入の 2 つの項目から損益計算書の誤り有無を判断したが、実務で使用するモデルではより多くの説明変数を利用することが見込まれるため、ここでは第 2 章第 2 節「予測モデル作成」において予測精度比較に利用したロジスティック回帰を使用して考察する。

下図 3-4 「ロジスティック回帰の係数 (売上額 10%削減データ)」は売上額を 10%削減したデータを予測対象としたロジスティック回帰の係数である。

【図 3-4】ロジスティック回帰の係数 (売上額 10%削減データ)



(出典：筆者作成)

税引前利益率の値が突出していることが確認できる。このことから、一見このモデルは税引前利益率を重視するモデルであるかのようにも考えられる。しかし、分析対象の損益計算書について科目ごとの傾向を把握するため中央値及び平均値を算出すると、税引前利益率は表 3-1 「損益計算書データの中央値及び平均値」のとおり、平均値 2.4、中央値 2.4 と他の科目に比べて絶対値の小さな値が入力値として与えられる傾向にある。

【表 3-1】損益計算書データの中央値及び平均値


科 目	中 央 値	平 均 値
売 上	484.4	2496.8
仕 入	361.7	2068.0
売上総利益	91.7	428.9
一般管理費	85.7	421.9
営業外収益	4.2	29.1
営業外費用	1.6	13.6
福利厚生費	34.1	221.2
研究開発費	5.4	73.0
減価償却費	15.3	117.7
経 常 利 益	6.5	22.5
税引前利益率	2.4	2.4

(出典：筆者作成)

モデルの全体傾向を把握するためには、各項目にどのような値が入力される傾向にあるのかを加味して判断する必要がある⁽⁵⁸⁾。そこで、代表値として中央値をこのモデルの各係数に乗じると下図 3-5 「ロジスティック回帰の係数(売上額 10%削減データ)と損益計算書データの中央値の乗算結果」の結果が得られる。

(58) スケーリング実施済のデータで学習したロジスティック回帰の場合は、代表値を乗算せずに係数比較が可能。

【図 3-5】ロジスティック回帰の係数（売上額 10%削減データ）と損益計算書データの中央値の乗算結果



(出典：筆者作成)

売上及び仕入の値が高くなり、税引前利益率の値が結果に与える影響は全体の中で中間的な影響度であることが確認できる。このモデルから出力される値は、傾向として売上から最も影響を受ける。売上の値は、係数が負であることから出力結果の合計値を引き下げる（誤りのない損益計算書と判断する）効果がある。このように、図 3-5 「ロジスティック回帰の係数（売上額 10%削減データ）と損益計算書データの中央値の乗算結果」はモデルの全体的な予測傾向として捉えることができるため、このモデルに対する大域説明である。当該大域説明に必要な数学的計算は積の算出のみであり理解が容易であることから、ロジスティック回帰はモデルの理解の観点において説明性の高い機械学習手法である。

また、利益を過少に計上する損益計算書を検出する場合、売上額が多いことが陰性（誤りのない方向）へ、仕入額が多いことが陽性（誤りのある

方向)へつながることは論理的に整合している。その他の科目に関しても、結果に大きな影響を与える科目に関する係数の正負は、専門家の経験則と概ね一致することが確認できる。このように数学的なモデルの説明と予測結果を結び付けて理解可能であることから、ロジスティック回帰はモデルの理解の観点において解釈性の高い機械学習手法である。

ロジスティック回帰の大域説明がモデル理解の観点で説明性及び解釈性に優れていることは、モデルに大きな誤りがないか、バイアスが含まれないか等を確認する必要があるモデル開発者及びモデルの使用可否を判断する管理者にとって有用な情報を提供する。

一方で、このモデルからの出力結果を使用する場面では、モデルの全体傾向が経験則と整合したとしても、まさに使用しようとしている個別の予測結果がどのような根拠で導かれたものかを示されない限り安心して予測結果を活用することは難しい。

そこで、次にこのモデルの予測結果の理解を促す局所説明の説明力を考察するため、科目ごとの値が全損益計算書の平均値であるデータが存在すると仮定して、当該データを使用して予測を実施する。ロジスティック回帰の係数に科目ごとの平均値を乗じた結果は表 3-2 「ロジスティック回帰の係数(売上額 10%削減データ)と科目ごとの平均値の乗算結果」のとおり。

【表 3-2】ロジスティック回帰の係数（売上額 10%削減データ）と科目ごとの平均値の乗算結果

科 目	ロジスティック回帰の係数と科目ごとの平均値の乗算結果
売 上	-6.264608
仕 入	4.932963
売上総利益	-2.099033
一般管理費	3.450069
営業外収益	0.544687
営業外費用	0.022824
福利厚生費	-0.097191
研究開発費	0.149164
減価償却費	-0.437829
経常利益	0.088505
税引前利益率	-0.429084

(出典：筆者作成)

これは、予測の基となる個々の入力値が予測結果に対してどの程度影響を与えたのかを表す数値であるため、局所説明である。この事例では、各数値の合計は約-0.14 となり、シグモイド関数での変換を経て誤りのない損益計算書と判断される。科目ごとの値を観察すると、売上の値が約-6.3 であり全体の中で最も数値が大きい。しかし、この損益計算書に誤りがあるか否かという予測は、売上単独で判定するものではなく、他の科目との合計値によって算出される。そのため、売上が結果に対して貢献度が大きいことは確認できるが、「売上が原因で誤りのない損益計算書に分類された」と結論づけることはできない。

次に科目ごとの値が平均値であるデータの売上のみを 0.9 倍して擬似的

に誤りのある損益計算書を作成し、ロジスティック回帰の係数を乗じた。計算結果は表 3-3「ロジスティック回帰の係数(売上額 10%削減データ)と科目ごとの平均値(誤りデータ)の乗算結果」のとおり。

【表 3-3】ロジスティック回帰の係数(売上額 10%削減データ)と科目ごとの平均値(誤りデータ)の乗算結果

科 目	ロジスティック回帰の係数と科目ごとの平均値(誤りデータ)の乗算結果
売 上	-5.638147
仕 入	4.932693
売上総利益	-2.099033
一般管理費	3.450069
営業外収益	0.544687
営業外費用	0.022824
福利厚生費	-0.097191
研究開発費	0.149164
減価償却費	-0.437829
経 常 利 益	0.088505
税引前利益率	-0.429084


(出典：筆者作成)

売上の値が約 0.6 増加していることが確認できる。この増加の影響で予測結果は誤りのある損益計算書と判断された。表 3-3「ロジスティック回帰の係数(売上額 10%削減データ)と科目ごとの平均値(誤りデータ)の乗算結果」においても表 3-2「ロジスティック回帰の係数(売上額 10%削減データ)と科目ごとの平均値の乗算結果」同様に売上の絶対値が最も大きく、このことが結果に最も影響している。しかし、表 3-3「ロジス

ティック回帰の係数（売上額 10%削減データ）と科目ごとの平均値（誤りデータ）の乗算結果」の売上は表 3-2 「ロジスティック回帰の係数（売上額 10%削減データ）と科目ごとの平均値の乗算結果」の値よりも絶対値が約 0.6 小さくなり、他の科目との差は小さくなっている。このように売上の絶対値が小さくなったことで、各数値の合計は約 0.49 となり、誤りのある損益計算書と判断される。以上のように、入力値からモデル内での計算を示し、局所説明を得ることができた。大域説明同様に、積及び和の算出が中心であり数学的に理解が容易であることから、ロジスティック回帰の局所説明は予測結果の理解の観点から説明性に優れている。しかし、ロジスティック回帰から読み取れる数学的説明を予測結果と結び付けて理解しようとする、個々の数値の意味や具体的に誤りがある箇所が分からないため、そこから納得感を得ることは難しいのではないかと。

予測結果の理解の観点から、解釈性に対する考察を深めるため、仕入額を 10%増加させた損益計算書を予測対象としたロジスティック回帰の係数を確認する。代表値として中央値をこのモデルの各係数に乗じると下図 3-6 「ロジスティック回帰の係数（仕入額 10%増加データ）と科目ごとの中央値の乗算結果」の結果が得られる。

【図 3-6】ロジスティック回帰の係数（仕入額 10%増加データ）と科目ごとの中央値の乗算結果



(出典：筆者作成)

また、図 3-6 「ロジスティック回帰の係数（仕入額 10%増加データ）と科目ごとの中央値の乗算結果」の具体的な値を、図 3-5 「ロジスティック回帰の係数（売上額 10%削減データ）と損益計算書データの中央値の乗算結果」の具体的な値とともに表 3-4 「図 3-5 及び図 3-6 の具体的な値」に示す。

【表 3-4】図 3-5 及び図 3-6 の具体的値

科 目	ロジスティック回帰の係数と 科目ごとの中央値の乗算結果	
	10%仕入増加	10%売上削減
売 上	-0.886659	-1.215273
仕 入	0.651100	0.862815
売上総利益	-0.332293	-0.449064
一般管理費	0.495769	0.701064
営業外収益	0.055705	0.077777
営業外費用	0.002951	0.002704
福利厚生費	-0.001825	-0.014976
研究開発費	0.006641	0.010975
減価償却費	-0.048991	-0.057039
経常利益	0.027132	0.025539
税引前利益率	-0.351731	-0.428817

(出典：筆者作成)

仕入額を 10%増加させたデータを予測対象としたロジスティック回帰の係数に科目ごとの中央値を乗じた値は、売上額を 10%削減したデータを予測対象としたロジスティック回帰の係数に科目ごとの中央値を乗じた値と同様の傾向であった。具体的には、係数の正負は一致しており、絶対値の大きさで降順に並び替えた場合の並び順も概ね同じ並び順となる。いずれのモデルにおいても、売上の係数が最も絶対値が大きく、予測結果に最も影響力があることを確認できる。

次に科目ごとの値が平均値である損益計算書データの仕入額のみを 1.1 倍して擬似的に誤りのある損益計算書データを作成し、ロジスティック回帰の係数に乘じた。計算結果を表 3-5 「ロジスティック回帰の係数（仕

入額 10%増加データ)と科目ごとの平均値(誤りデータ)の乗算結果」に示す。

【表 3-5】ロジスティック回帰の係数(仕入額 10%増加データ)と科目ごとの平均値(誤りデータ)の乗算結果

科 目	ロジスティック回帰の係数と科目ごとの平均値(正常データ)の乗算結果	ロジスティック回帰の係数と科目ごとの平均値(誤りデータ)の乗算結果
売 上	-4.570211	-4.570211
仕 入	3.722629	4.094892
売上総利益	-1.554204	-1.554204
一般管理費	2.440664	2.440664
営業外収益	0.385956	0.385956
営業外費用	0.025084	0.025084
福利厚生費	-0.011838	-0.011838
研究開発費	0.089776	0.089776
減価償却費	-0.376878	-0.376878
経 常 利 益	0.093918	0.093918
税引前利益率	-0.351731	-0.351731

(出典：筆者作成)

仕入の値が約 0.37 増加したことが確認できる。この増加の影響で予測結果は誤りのある損益計算書と判断された。仕入の値を増加させることで擬似的に誤りのある損益計算書を作成したにもかかわらず、依然として結果に最も大きな影響を与えているのは(最も絶対値が大きいのは)売上である。このように、ロジスティック回帰は学習済みモデルの係数を利用して各科目がどの程度予測結果に影響を与えているのかを確認可能であるが、最も予測結果に影響を与えた科目が誤りのある科目であることは保証され

ていない。

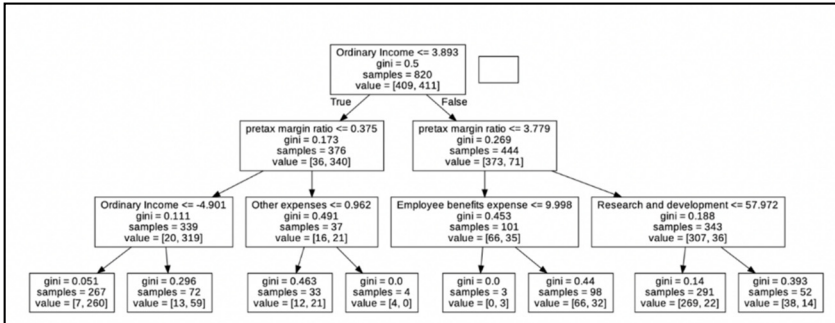
以上のように、ロジスティック回帰の大域説明はモデル理解の観点で説明性及び解釈性に優れたモデルである。また、局所説明についても高い説明性を有する。このことから、ロジスティック回帰は、AI の公平性及び透明性の観点において優れた機械学習手法であると考えられる。しかしながら、局所説明は説明性が高いものの、個別の予測結果に対する説明を見ただけではどの科目に誤りがあるのかを示すことはできず、予測結果を利用するヒトに次の行動を示唆するような情報を与えることができていない。そのため、ロジスティック回帰の局所説明は、予測結果に対する数学的説明と予測結果を結び付けて理解することが困難であり、予測結果の理解の観点において解釈性が不十分であることから、説明責任については十分に果たせない場合があることに留意する必要がある。

(2) 決定木

次にロジスティック回帰同様にホワイトボックス型として知られる決定木について、予測結果の理解及びモデルの理解の観点から説明性及び解釈性を考察する。決定木は一連の説明変数の中から、1つの適切な説明変数を選択して、データセットをより均質な傾向を持つサブセットに分割することを繰り返して、目的変数に強く関連している説明変数や注目したいサブグループを発見することを目的とする手法である⁽⁵⁹⁾。そのため、各分岐の条件を確認することでモデルの傾向を把握し大域説明を得ることができる。また、個々の予測結果が決定木の各分岐でどのような経路をたどったのかを確認することで、その結果の基となった入力値が予測結果に与えた影響を確認し、局所説明を得ることができる。以下、第2章第2節「予測モデル作成」において予測精度比較に利用した決定木の分岐条件を可視化した下図3-7「決定木の分岐条件図」を使用して考察する。

(59) 奥喜正ほか・前掲注(33)2頁。

【図 3-7】決定木の分岐条件図



(出典：筆者作成)

第一階層（最も上にある箱）では、経常利益の値が 3.893 以下であれば左、3.893 超であれば右に分岐する。同様に第二階層、第三階層の分岐を経て第四階層へ到達する。第四階層の value は、モデルの学習に用いたデータについて、その箱に到達した誤りのない損益計算書（左）と誤りのある損益計算書（右）の数を表し、この値の多数決によりこの箱の属性（誤りのある損益計算書又は誤りの無い損益計算書）が決定する。例えば、第四階層左端の箱は誤りの無い損益計算書 7 件、誤りのある損益計算書 260 件であり、誤りのある損益計算書の数が誤りのない損益計算書の数よりも多いので、「誤りのある損益計算書と予測する箱」となる。予測時に分岐を繰り返してこの箱にたどり着いた場合は、誤りのある損益計算書として分類される。このように、決定木は各分岐においてどの項目（科目）をどのような条件で分類するのかを確認することでモデル傾向を把握可能であり、そのことに必要な数学的要素は数値の大小比較のみであることから、モデルの理解の観点において説明性が高い手法である。決定木は、分岐に使用される項目や分岐の条件を取得することで、バイアスなどによる不適切な判断や経験則と大きく異なるような条件が当該モデルに含まれないことを確認可能である。そのため、予測精度の改善案の検討を行うモデル開発者

やモデルの使用可否を判断する管理者にとって受け入れられやすい機械学習手法である。また、個々の予測結果についても、入力データを分岐条件の順で大小比較することで算出可能であることから、予測結果理解の観点からも決定木は説明性の高い機械学習手法である。

一方で、決定木の予測は、専門家による損益計算書分析の手法と整合するような判断過程とは異なるため、予測に対する数学的説明を予測結果と結び付けて理解することが困難であり、納得感に欠ける機械学習手法と考えられる⁽⁶⁰⁾。損益計算書分析において決定木の判断が専門家と異なる点は 2 点挙げられる。

1 点目は専門家が損益計算書の各科目間の関係性である比率を重視することに対し、決定木は単独の数値に対する判断を繰り返す点にある。具体的には、専門家が損益計算書进行分析する際には各科目の比率を重要視するため、売上が 100 万円計上された損益計算書を示されたとしても、そのみでは売上の適正性は判断できない。売上額に対する原価が示されることで、「売上額に比して原価が多いため、売上額の過少計上又は原価の過大計上が想定される」等の分析が可能となる。これは、専門家が行う損益計算書分析において、業種に対する一般的な利益率が経験則として蓄積され、そのような経験則と比較することで分析対象の損益計算書の適正性を検証するためである。

これに対して、決定木は各分岐において 1 つの科目を一定の基準で分割する。そのため、モデルの構造上他の科目との比率の比較が困難となる。例えば、「売上 100 万円」を分岐条件に使用する場合、その分岐では売上が 100 万円以上であるかどうかのみで判断する。売上 100 万円の適正性を確認するためには、仕入等の他の科目を勘案する必要があるが、単独の分岐ではこのような情報は勘案されない。後続の分岐で仕入が条件に利用される場合もあるが、このように専門家の経験則と合致するような分岐が与

(60) 決定木の普遍的な特徴ではなく、本稿の損益計算書を用いた分析における特徴。

えられることは保証されない。

また、仮に「仕入 80 万円以上」が「売上 100 万円以上」という分岐条件の後続の分岐条件に与えられた場合、「売上 100 万円以上」かつ「仕入 80 万円以上」という分岐経路において、「売上 100 万円かつ仕入 80 万円（原価率 80%）」は、「売上 200 万円かつ仕入 80 万円（原価率 40%）」と同じ分岐をたどり、「売上 50 万円かつ仕入 40 万円（原価率 80%）」とは異なる分岐をたどる。このように決定木は一定額を基準にデータを分割するため、損益計算書のように比率が重要となる分析を苦手とする傾向がある。このような傾向は、経験則から導かれる各科目の比率を基にした判断基準を持つ専門家に違和感を与える要因となる。

もっとも、分析に比率が重要であることが事前に判明している場合には、入力データを事前に比率化した上で予測モデルを構築することで決定木の弱点を補うことができる。

2 点目は、一度分岐で使用した科目を再度使用する可能性があることである。図 3-7 「決定木の分岐条件図」では、第一階層で経常利益 (3.893 以下)、第二階層左で税引前利益率 (0.375 以下)、第三階層左で再び経常利益 (-4.901 以下) を分岐条件に使用している。これは、この順で分岐することが必要であり、モデルの予測精度を維持するためには、経常利益に関する条件をまとめて、第一階層で税引前利益率 (0.375 以下)、第二階層左で経常利益 (-4.901 以下) とすることはできない。このように同じ科目を条件分岐に繰り返すことは、専門家の判断過程とは異なりモデルの直感的な理解の妨げとなる。

第 2 章第 1 節 2 「損益計算書データの特徴」でも確認したとおり、損益計算書に記載される各科目の値は強い相関を持つ傾向にあり、散布図を作成した場合に斜め方向に直線状に並ぶことが想定されるところ、決定木によってこのような形状にある点を分離するためには、階段状の決定境界の作成が必要となる。階段状の決定境界を作成するためには、同一科目を繰り返して分岐条件に利用することとなるため、直感的な解釈が困難となる。

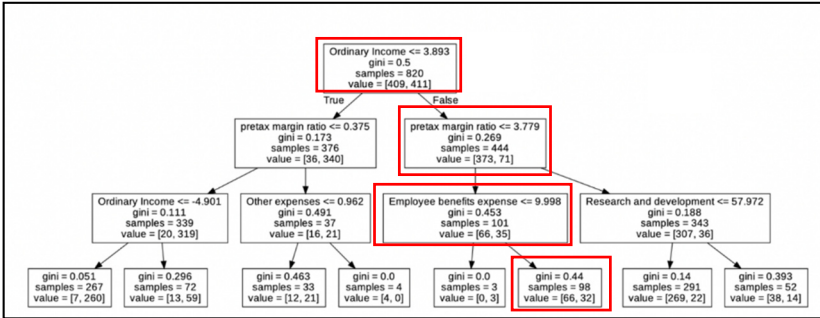
次に、ロジスティック回帰同様に予測結果の理解を促す局所説明の説明力を具体的に考察するため、科目ごとの値が平均値であるデータが存在すると仮定して、当該データを使用して予測を実施する。入力データは表 3-6 「科目ごとの平均値」のとおり。

【表 3-6】科目ごとの平均値

科 目	平 均 値
売 上	2496.815723
仕 入	2067.957470
売上総利益	428.858253
一般管理費	421.923504
営業外収益	29.181511
営業外費用	13.567189
福利厚生費	221.232240
研究開発費	73.035965
減価償却費	117.734622
経常利益	22.546981
税引前利益率	2.434780

図 3-7 「決定木の分岐条件図」に従い分岐すると下図 3-8 「科目ごとの平均値がたどる分岐条件」の経路をたどり、誤りの無い損益計算書に分類された。

【図 3-8】科目ごとの平均値がたどる分岐条件



(出典：筆者作成)

この結果は、表 3-6 「科目ごとの平均値」に示すデータが「経常利益が 3.893 超かつ、税引前利益率が 3.779 以下かつ、福利厚生費 9.998 超であることから誤りの無い損益計算書と判断した。」と局所説明をすることができる。この局所説明は、差別につながる不適切なバイアスによって判断されたものではないことは確認できる。しかし、損益計算書の分析指標として有効であると考えられるような経験則と整合するものではない。また、どの科目に誤りがあるのかを示すものでもない。そのため、このモデルの判断にヒトが共感したり、納得することは困難である。

以上のように、決定木はモデルの理解及び予測結果の理解の観点で数学的な理解が容易であることから説明性に優れた手法である。このような特徴によって、決定木はバイアスの検知や入出力データに関する検証可能性の確保が可能である。このことから決定木は、AI の公平性及び透明性の確保の観点において優れた機械学習手法であると考えられる。ただし、決定木の予測は専門家による損益計算書分析の手法と整合するような判断過程とは異なるため、予測に対する数学的説明を予測結果と結び付けて理解することが困難であり、モデルの理解及び予測結果の理解の両観点において解釈性が不十分であると考えられる。そのため、説明責任については、十

分に果たせない場合があることに留意が必要である。

4 小括

AI が出した予測結果について、その理由や根拠が不明瞭だと AI に求められる社会的要請である公平性、透明性及び説明責任の確保が困難となるため、AI の説明性及び解釈性が重要となる。説明性とは予測結果又は予測モデルを数学的に説明可能であり、その説明をヒトが理解できる形式で提示できることである。また、解釈性とは AI の予測結果や予測モデルに対する数学的説明について、ヒトが予測結果と結び付けて理解できることである。

AI のブラックボックス化は、予測結果の理解及びモデルの理解という 2 つの観点において、説明性及び解釈性を損ない公平性、透明性のある意思決定及びその結果に対する説明責任の適切な確保に向けた阻害要因となる。

ホワイトボックス型の AI であるロジスティック回帰及び決定木は、予測結果及び予測モデルを数学的に理解可能である。そのため、バイアスの検知や入力データに関する検証が可能であり、AI の公平性及び透明性の確保に優れている。一方で、予測結果の理解については、AI の予測結果に対する数学的説明では、具体的な誤りの箇所を検知できない、判断過程が専門家と異なる等の理由から、予測結果に対する数学的説明と予測結果を結び付けて理解することが困難であり解釈性に欠ける場合がある。そのため、ホワイトボックス型の AI であっても、その AI を選択するのみでは説明責任を十分に果たせない可能性があることに留意する必要がある。

第 3 節 AI の説明性及び解釈可能性を踏まえた 社会的要請への対応

ブラックボックス型の AI は入力に対する表現力が高く、高精度が期待できる一方で、予測結果の理解及びモデルの理解という 2 つの観点において、説明性及び解釈性の確保が困難である。また、ホワイトボックス型の AI は、予測結

果の理解及びモデルの理解の観点において説明性は高いものの、解釈性が乏しく、予測結果の理解からもたらされる情報は AI の予測結果を使用するユーザが期待するものと一致せず、納得感を得るための説明力が不十分な場合がある。これらを踏まえ、AI に対する社会的要請を満たすとともに、AI の予測結果を利用するユーザが AI の予測結果を受け入れ、有効活用するために考慮すべき事項を考察する。

1 ブラックボックス型 AI の「モデルの理解」及び「予測結果の理解」の改善

近年機械学習モデルの予測根拠を説明する XAI (eXplainable AI) 技術の研究が急速に進み、多種多様な技術へと発展している⁽⁶¹⁾。そのため、これら XAI 技術の活用がモデルの理解及び予測結果の理解が困難というブラックボックス型 AI の問題点の対応案として考えられる。XAI 技術の多くは、ブラックボックス型の AI とは別の独立した技術で、説明対象のブラックボックス型 AI から情報を引き出し、開発者や予測結果の利用者に対して説明を与える通訳的存在である。

モデルの理解を促す大域説明を目的とした XAI の分類として「局所説明を多数集めて統計分析し、モデルの判断傾向を説明するモデル検査型」、「人が解釈できる簡易モデルに大域的に近似・射影して説明するモデル説明型」⁽⁶²⁾がある。モデル検査型の例としては ELI 5⁽⁶³⁾、モデル説明型の例としては Skater⁽⁶⁴⁾が挙げられる。

また、予測結果の理解を促す局所説明を目的とした XAI として「予測において、モデルが各特徴量をどの程度重視したかを説明する因子型」、「予測において、モデルが類似すると考える教師データを提示する事例型」、「予測に

(61) 恵木正史「XAI(eXplainable AI)技術の研究動向」日本セキュリティ・マネジメント学会誌 Vol.34, No.1 21 頁 (日本セキュリティ・マネジメント学会、2020)。

(62) 恵木正史・前掲注(61)21 頁。

(63) 「ELI 5 Documentation」
(<https://eli5.readthedocs.io/en/latest/index.html>) (令和 5 年 2 月 18 日最終閲覧)。

(64) 「skater Overview」(<https://oracle.github.io/Skater/overview.html>) (令和 5 年 2 月 18 日最終閲覧)

において、専門家が重要と考える概念を、モデルがどの程度重視しているかを説明する知識型、「予測の結果を変えたいとき、入力データの各特徴量のうちどれを変更すれば良いかを説明する反実型⁽⁶⁵⁾」が挙げられる。モデル因子型の例として LIME⁽⁶⁶⁾、事例型の例として Influence Boosting⁽⁶⁷⁾、知識型の例として TCAV⁽⁶⁸⁾、反実型の例として Counterfactual Explanation⁽⁶⁹⁾等が挙げられる⁽⁷⁰⁾。

これら XAI の多くは、ブラックボックス型 AI の説明を目的に作成されたものであることから、その説明はホワイトボックス型 AI よりもヒトにとって理解しやすいことも多い。一方で、XAI の説明は、その説明が理解しやすいように情報の省略が行われたり、説明対象の AI の振る舞いをまねた全く別の AI に説明を肩代わりさせる等が行われることもあるため、その利用に当たっては技術内容を理解した上で利用する必要がある。

2 AI の予測結果に対する納得感の獲得

第 3 章第 2 節 3 「ホワイトボックス型 AI の説明力」において、ホワイトボックス型の AI であっても、予測結果の理解については解釈性を欠き納得感を得られない場合があることを指摘した。納得感は情報の受け手の能力に左右されると共に主観的な要素が強い。損益計算書の誤り有無を判定する場合を例にすると、会計及び機械学習の両方の知識を有する場合と、会計又は

(65) 恵木正史・前掲注(61)21 頁。

(66) Marco Tulio Ribeiro et al.(2016) “Why should i trust you?: Explaining the predictions of any classifier,” In Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, pp. 1135-1144.

(67) Boris Sharchilev et al.(2018) “Finding influential training samples for gradient boosted decision trees,” International Conference on Machine Learning.PMLR, 2018.p.4577-4585.

(68) Been Kim et al.(2018) “Interpretability beyond feature attribution: Quantitative testing with concept activation vectors (tcav),” International Conference on Machine Learning.PMLR,2018.p.2668-2677.

(69) Sandra Wachter et al.(2018) “Counterfactual explanations without opening the black box: Automated decisions and theGDPR” Harv. JL & Tech., Vol. 31, p. 841, 2017.

(70) 恵木正史・前掲注(61)21 頁。

機械学習のいずれかの知識のみを有する場合とでは局所説明に対する理解度も異なることから、そこから得られる納得感も異なる。

このような理由から、万人が理解可能で納得感を得られる局所説明をすることは現実的ではない。このような状況で、AI の予測結果を有効に活用するためには、AI とヒトの協調、すなわち AI 開発者と AI 利用者であるヒトの双方の歩み寄りが重要である。AI 開発者側の歩み寄りとしては、XAI 技術の活用、更には予測結果の詳細化が挙げられる。予測結果の詳細化とは、損益計算書の誤り有無判定を例にすると、予測対象を誤りの有無という 2 値分類とせず、売上誤り、仕入誤り等と多クラス分類問題にすること等が挙げられる⁽⁷¹⁾。この予測結果を受けたヒトは、具体的に想定される誤り箇所が提示されることで、例えば売上に誤りがあるという前提に立って AI から与えられる局所説明の理解に努めると共に損益計算書を確認することが可能となる。この際には、売上に誤りがある場合の損益計算書の特徴を念頭に自身の知識と経験則に照らし、ヒトの観点から損益計算書を確認する。このように AI の予測結果の理解に努めようとする態度と、AI とは別にヒトの観点からの予測結果の確認をすることがヒトの歩み寄りである。AI を利用した課題の解決は、AI から予測を出力することや、その予測結果を理解することが目的ではなく、本来設定した課題の解決こそが目的であることから、AI とヒトが協調して本来の課題を解決することが望まれる。

3 AI に対する社会的要請を踏まえた AI の利用方法

AI に求められる社会的要請である「公平性」、「透明性」のある意思決定及びその結果に対する「説明責任」の確保に対して本章での考察を踏まえ対応策を提案する。

(1) 公平性の確保

公平性の確保に向けては、予測結果の理解、モデルの理解及び学習デー

(71) 多クラス分類とすることで予測モデルの精度が低下する可能性があることには留意が必要である。

タの選択を適切に組み合わせることが重要である。公平性の確保は、バイアスに基づく AI の判断で不当な差別をしないことを要請するものである。AI の判断からバイアスによる影響を除去するためには、予測結果の理解による個別データの確認及びモデルの理解によるモデルの判断傾向の確認が有効である。例えば、画像データを予測対象とする AI を利用する場合、予測対象となった画像のどの部分を根拠に AI が判断したのか、AI はどのような判断傾向を持つのかを確認しなければ AI の判断根拠にバイアスが含まれないことを確認することは困難である。

一方で、表形式のデータを取り扱う場合には、説明変数に利用する項目を事前に確認することができる。特に行政機関が保有する表形式データは法令に基づき取得されたデータが多く、これらは適切に管理されている。このようなデータは、AI の学習に用いる前にどのようなデータが含まれるのかを事前に把握することが可能である。そのため、表形式のデータを取り扱う際には、説明変数となる項目を事前に確認して学習データを適切に選択することで、不当な差別を引き起こす恐れがあるデータ項目を事前に除外し、より確実に公平性を確保することが望ましい。

以上のように、取り扱うデータ形式の特性に応じて、予測結果の理解、モデルの理解及び学習データの選択を適切に組み合わせ、公平性を確保することが重要である。

(2) 「透明性」及び「説明責任」の確保

透明性及び説明責任の確保に向けては、AI を利用する一連の業務において判断過程、判断理由、判断に対する責任の所在を明確にすることが必要である。透明性の確保とは、AI の入出力データに関する検証可能性及び判断結果の説明可能性を確保⁽⁷²⁾することを要請するものである。また、説明責任の確保は AI の出力に対する責任の所在を明確にし、AI の使用や出力結果に対して説明を求められた際に適切に説明することを要請するもので

(72) AI ネットワーク社会推進会議・前掲注(52)24 頁。

ある。これらの要請に応えるためには、AI を利用する業務における判断過程を明確にする必要がある。判断過程とは、①AI がどのようなデータで学習し、②どのようなデータに基づき予測結果を出力したのかという AI の予測過程及び③AI の予測を誰が作成し、④その予測を誰がどのように解釈し、⑤その解釈を基に誰がどのように判断し、⑥その判断を誰が承認したのかという一連の事務処理プロセスである。

これらの一連の事務処理プロセスのうち、AI の予測結果の解釈(上記④)及び当該解釈を基にした判断(上記⑤)の理由を明確にすることが判断理由の明確化である。判断理由の明確化では、判断の承認者や当該判断の影響を受ける者が納得できるように判断に対する理由をヒトの言葉で説明する必要がある。そのため、単にホワイトボックス型の AI を利用するのみではこの要請には応えられない。例えば、損益計算書の誤りを検出するロジスティック回帰モデルの AI を利用する際に、売上の値に大きな影響を受けて「誤りのある損益計算書」という予測結果が出力されたことに対して、「売上の値が大きいと誤りがある損益計算書に分類された」という分析は AI の予測結果の説明である。このような AI の予測結果の説明は、ホワイトボックス型 AI を利用すると比較的容易に行える。しかし、判断理由の明確化では、このような AI の予測結果の説明を基に最終的な判断を行った理由を根拠となる数値とともに示すことが望まれる。具体的には、AI の予測結果の説明に基づき、仕入など他の科目の値と売上の値との比率、業種、事業規模等を勘案し、「この業種における一般的な原価率を踏まえると売上額が過少であることが想定される⁽⁷³⁾。」といったヒトの言葉で解釈を加えることが判断理由の明確化である。

判断理由の明確化において重要な点は、AI の予測結果を基に他の情報を総合勘案した上でヒトが判断し、その判断理由を説明できることである。

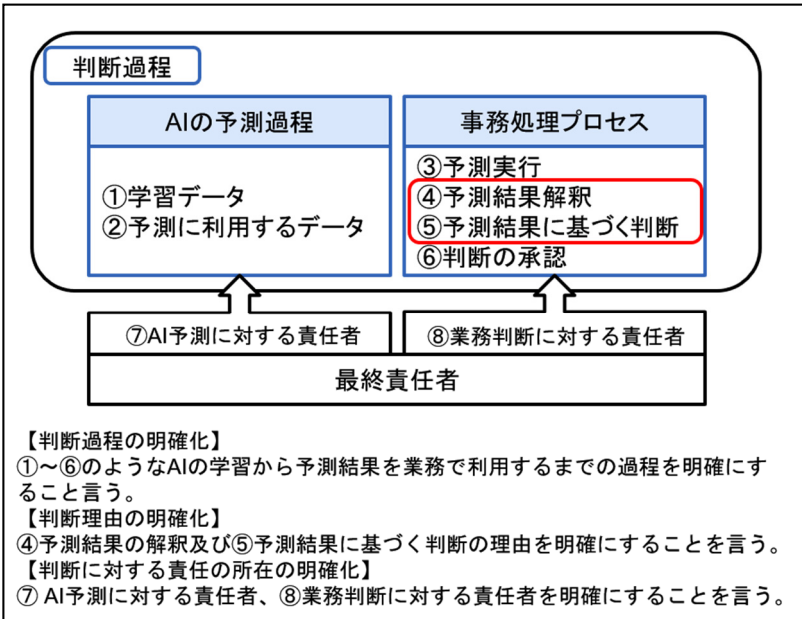
(73) 第3章第2節3「ホワイトボックス型 AI の説明力」で示したロジスティック回帰では、売上の係数が負であった。そのため、売上の値に大きな影響を受ける(期待される売上の値よりも小さな値の入力を受けると)、係数との乗算結果は大きくなる。

ここでは、判断主体がヒトである。そのため、ブラックボックス型 AI を利用した場合であっても、AI の予測結果を参考にヒトが判断し、当該判断理由を明確化することで、AI に求められる社会的要請は果たされるものと考えられる。

責任の所在の明確化とは、⑦AI を利用する業務における最終責任者に加え、⑧AI の予測に対する責任者及び具体的業務における判断の責任者を明確にすることである。想定外の挙動など AI の予測に誤りがある場合と AI の予測に基づきヒトが誤った判断をした場合とでは説明すべき内容が異なる。そのため、状況に応じて適切な説明を行えるよう AI を利用する判断過程に沿って責任者を明確にする必要がある。

以上をイメージ化した図は図 3-9「判断過程及び判断理由の明確化のイメージ」のとおり。

【図 3-9】判断過程及び判断理由の明確化のイメージ



(出典：筆者作成)

なお、判断理由の明確化は AI 利活用の透明性及び説明責任の確保に向けて特に留意が必要である④及び⑤を対象としたが、他の判断過程についても、適切な意思決定手続の履行に留意する必要がある。

4 小括

ブラックボックス型の AI は、予測結果の理解及びモデルの理解において、説明性及び解釈性の確保が困難である。一方で、ホワイトボックス型の AI は、予測結果の理解及びモデルの理解の観点において、説明性に優れている。しかし、解釈性には乏しく予測結果の理解からもたらされる情報は AI の予測結果を使用するユーザが期待するものと一致せず、納得感を得られない場合がある。

ブラックボックス型 AI の説明性及び解釈性向上に向けては、近年注目される XAI 技術の活用が有効であると考えられる。また、ホワイトボックス型 AI も含めて AI の納得感向上に向けては、AI 開発者の歩み寄り及び AI 利用者の歩み寄りが必要である。AI 開発者の歩み寄りとしては、XAI 技術の活用、予測結果の詳細化等が挙げられる。AI 利用者の歩み寄りとしては AI の予測結果の理解に努めようとする態度を持つこと、AI とは別にヒトの観点から予測結果を確認すること等が挙げられる。

AI に求められる社会的要請である公平性の確保に向けては、予測結果の理解、モデルの理解及び学習データの選択を適切に組み合わせることが重要である。また、透明性及び説明責任の確保に向けては、AI を利用する一連の業務において判断過程、判断理由、判断に対する責任の所在を明確にすることが必要である。

第 4 章 AI を活用するための組織体制について

第 1 節 民間企業における取組状況等

第 4 章では、AI を有効活用するための組織体制及び知識レベルについて考察する。第 1 節では、民間企業における AI 活用に向けた体制作りを確認する。併せて政府の AI 活用に向けた教育改革の内容を確認することで、AI 活用に有効な組織体制及び知識レベルを考察する。第 2 節では、第 1 節の内容を踏まえ、国税庁において AI を有効活用するための体制及び役割に応じて求められる具体的な知識レベルを考察する。

1 民間企業の AI 活用に向けた体制づくり

平成 31 年 2 月一般社団法人日本経済団体連合会（経団連）は「AI 活用戦略～AI-Ready な社会の実現に向けて～⁽⁷⁴⁾」を公表した。ここでは、AI の産業展開には、製品・サービスや業務プロセス、ひいては企業組織や産業、社会自体の変革が必要であることを述べた上で、そのためには、「AI を活用するための準備（AI-Ready 化）を行うことが必要」としている。また、AI-Ready な企業、更にその先にある AI-Powered な企業に向けた行動指針「AI-Ready な企業に向けたガイドライン⁽⁷⁵⁾」では、AI-Ready な状況を「経営・マネジメント層、専門家及び従業員」という人材の観点並びに「システムレベル・データ」というデータ活用環境整備の観点という 2 つの観点で評価し AI を活用するための段階を 5 つのレベルに区分している。

このことから、AI を有効に活用するためには、単に AI を技術として導入するのみではなく、組織内の「人材」及び「データ活用環境」の双方の充実

(74) 一般社団法人日本経済団体連合会平成 31 年 2 月 19 日「AI 活用戦略～AI-Ready な社会の実現に向けて～」

(https://www.keidanren.or.jp/policy/2019/013_honbun.pdf) (令和 5 年 2 月 19 日最終閲覧)。

(75) 一般社団法人日本経済団体連合会・前掲注(74) 19 頁。

が重要であると考えられる。このうち、特に AI サイエнтиスト、AI エンジニア及び AI プランナーといった AI 専門家人材については「IT 人材受給に関する調査⁽⁷⁶⁾」において、長期的に不足することが予測されており、今後の対応が検討されている。この点については、「IT 人材白書 2019⁽⁷⁷⁾」によると、不足する AI 専門家人材の確保策について「社内の人材を育成して確保する」とした企業が最も多く「外部委託で確保する」とした企業を大きく上回っている⁽⁷⁸⁾。これは、AI を活用した製品やサービスで利益を生むには、自社の特性や強みといった業務知識を持つことが必要であると判断されたことが一因と考えられる。このように AI 専門家に業務知識というビジネス現場での能力が求められるのは、下図 4-1 「データサイエンティストに求められるスキルセット⁽⁷⁹⁾」において、データサイエンティストに必要な知識の一つとして「ビジネス力」が挙げられることと整合的である。

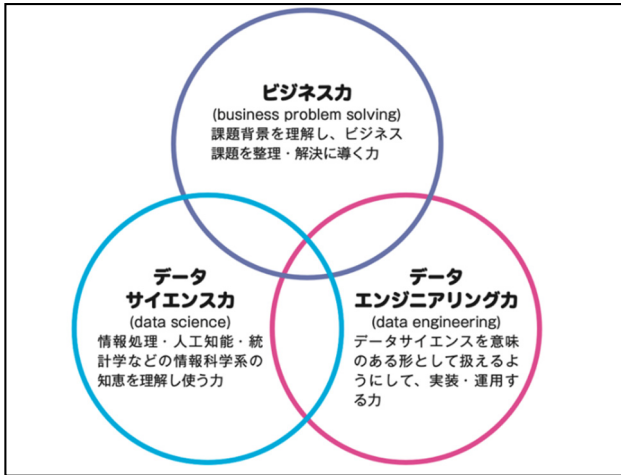
(76) みずほ情報総研株式会社経済産業省受託授業平成 31 年 3 月 1 日「平成 30 年 IT 人材受給に関する調査」58 頁 (https://www.meti.go.jp/policy/it_policy/jinzai/houkokusyo.pdf) (令和 5 年 2 月 19 日最終閲覧)。

(77) 独立行政法人情報処理推進機構・前掲注(4) 99 頁。

(78) 「社内の人材を育成して確保する」と回答した割合は、IT 企業以外の一般企業においては「AI 人材はいる」企業 (N=54) で 63.0%、「AI 人材はいないが、獲得・確保を検討している」企業 (N=119) で 65.5%、「外部委託で確保する」と回答した企業は、「AI 人材はいる」企業 (N=54) で 44.4%、「AI 人材はいないが、獲得・確保を検討している」企業 (N=119) で 46.2%であった。IT 企業では、「社内の人材を育成して確保する」割合は更に高い。独立行政法人情報処理推進機構・前掲注(4) 99 頁。

(79) 一般社団法人データサイエンティスト協会及び独立行政法人情報処理推進機構共同作成 <https://www.ipa.go.jp/files/000083733.pdf> (令和 5 年 2 月 21 日最終閲覧)。

【図 4-1】 データサイエンティストに求められるスキルセット



(出典：一般社団法人データサイエンティスト協会・独立行政法人情報処理推進機構「データサイエンティストのためのスキルチェックリスト/タスクリスト概説」14頁 (<https://www.ipa.go.jp/files/000083733.pdf>) (令和 5 年 2 月 21 日最終閲覧。))

このような AI 専門家人材に加え、AI の産業展開を目指す AI-Ready な企業では、従業員にも AI ツールでデータ分析を行い、自社の事業に生かすことや、現場の知見と基礎的 AI 知識を持ち、自社への AI 導入を推進すること⁽⁸⁰⁾に関する知識及び技術を求めている。

2 AI 活用に必要な能力

内閣府が公表した「AI 戦略 2019⁽⁸¹⁾」では、デジタル社会の基礎知識であ

(80) 独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2) 513 頁。

(81) 統合イノベーション戦略推進会議令和元年 6 月 11 日「AI 戦略 2019 ～人・産業・地域・政府全てに AI～」本戦略の目的は、Society 5.0 の実現を通じて世界規模の課題の解決に貢献するとともに、我が国自身の社会課題も克服するために、今後の AI の利活用の環境整備・方策を示すこととされている。

(<https://www8.cao.go.jp/cstp/ai/aistratagy2019.pdf>) (令和 5 年 2 月 19 日最終閲覧。)

る「数理・データサイエンス・AI」に関する知識・技能、新たな社会の在り方や製品・サービスをデザインするために必要な基礎力など、持続可能な社会の創り手として必要な力を全ての国民が育み、社会のあらゆる分野で人材が活躍することを目指して①全ての高等学校卒業生が、「理数・データサイエンス・AI」に関する基礎的なリテラシーを習得、②データサイエンス・AIを理解し、各専門分野で応用できる人材を育成（約 25 万人/年）、③データサイエンス・AI を駆使してイノベーションを創出し、世界で活躍できるレベルの人材の発掘・育成（約 2,000 人/年、そのうちトップクラス約 100 人/年）などが掲げられた。また、これらに加えて具体的目標として④文理を問わず、全ての大学・高専生（約 50 万人卒/年）が、課程にて初級レベルの数理・データサイエンス・AI を習得することが掲げられた⁽⁸²⁾。

このことを受け、数理・データサイエンス・AI 教育強化拠点コンソーシアムでは、リテラシーレベル（前述の①及び④を対象とするもの）のモデルカリキュラム（以下「リテラシーレベルカリキュラム」という。）及び応用基礎レベル（前述の②を対象とするもの）のモデルカリキュラム（以下「応用基礎レベルカリキュラム」という。）を作成、公表した。モデルカリキュラムの主な内容は表 4-1 「主なリテラシーレベルカリキュラム（抜粋）」、表 4-2 「主なリテラシーレベルカリキュラム（オプション）（抜粋）」及び表 4-3 「主な応用基礎レベルカリキュラム（抜粋）」のとおり。

(82) 統合イノベーション戦略推進会議・前掲注(81)8頁。

【表 4-1】主なリテラシーレベルカリキュラム（抜粋）⁽⁸³⁾

データリテラシー	キーワード（知識・スキル）
2-1. データを読む	<ul style="list-style-type: none"> データの種類(量的変数、質的変数) データの分布(ヒストグラム)と代表値(平均値、中央値、最頻値) 代表値の性質の違い(実社会では平均値=最頻値でないことが多い) データのばらつき(分散、標準偏差、偏差値) 観測データに含まれる誤差の扱い 打ち切りや脱落を含むデータ、層別の必要なデータ 相関と因果(相関係数、擬似相関、交絡) 母集団と標本抽出(国勢調査、アンケート調査、全数調査、単純無作為抽出、層別抽出、多段抽出) クロス集計表、分割表、相関係数行列、散布図行列 統計情報の正しい理解(誇張表現に惑わされない)
2-2. データを説明する	<ul style="list-style-type: none"> データ表現(棒グラフ、折線グラフ、散布図、ヒートマップ) データの図表表現(チャート化) データの比較(条件をそろえた比較、処理の前後での比較、A/B テスト) 不適切なグラフ表現(チャートジャンク、不必要な視覚的要素) 優れた可視化事例の紹介(可視化することによって新たな気づきがあった事例など)
2-3. データを扱う	<ul style="list-style-type: none"> データの集計(和、平均) データの並び替え、ランキング データ解析ツール(スプレッドシート) 表形式のデータ(csv)

【表 4-2】主なリテラシーレベルカリキュラム（オプション）（抜粋）⁽⁸⁴⁾

オプション	キーワード（知識・スキル）
4-1. 統計および数理基礎	<ul style="list-style-type: none"> 確率、順列、組み合わせ 線形代数(ベクトル、ベクトルの基本的な演算、ノルム、行列とベクトルの積、行列の積、内積) 1 変数関数の微分と積分 指数関数、対数関数 集合、ベン図

(83) 数理・データサイエンス・AI 教育強化拠点コンソーシアム令和 2 年 4 月「数理・データサイエンス・AI(リテラシーレベル)モデルカリキュラム～データ思考の涵養～」12 頁 (www.mi.u-tokyo.ac.jp/consortium/pdf/model_literacy.pdf) (令和 5 年 2 月 19 日最終閲覧)。リテラシーレベルモデルカリキュラムは導入・基礎・心得・選択から構成される。このうち、モデルカリキュラムの活用イメージにおいてもっとも多くの時間が割り当てられた「基礎」を「主なリテラシーレベルカリキュラム」として抜粋した。

(84) 数理・データサイエンス・AI 教育強化拠点コンソーシアム・前掲注(83)16 頁。

<p>4-2. アルゴリズム基礎</p>	<ul style="list-style-type: none"> ・アルゴリズムの表現 (フローチャート、アクティビティ図) ・並び替え(ソート) ・探索(サーチ)
<p>4-3. データ構造とプログラミング基礎</p>	<ul style="list-style-type: none"> ・数と表現、計算誤差、データ量の単位、文字コード、配列 ・変数、代入、繰り返し、場合に応じた処理
<p>4-4. 時系列データ解析</p>	<ul style="list-style-type: none"> ・時系列データ(トレンド、周期、ノイズ) ・季節調整、移動平均
<p>4-5. テキスト解析</p>	<ul style="list-style-type: none"> ・形態素解析、単語分割、ユーザ定義辞書、n-gram、文章間類似度 ・かな漢字変換の概要
<p>4-6. 画像解析</p>	<ul style="list-style-type: none"> ・画像データの処理 ・画像認識、画像分類、物体検出
<p>4-7. データハンドリング</p>	<ul style="list-style-type: none"> ・データベース(リレーショナルデータベース、SQL) ・プログラミング(Python、R 等) ・データクレンジング:外れ値、異常値、欠損値の処理 ・データの抽出 ・データの結合 ・名寄せ
<p>4-8. データ活用実践(教師あり学習)</p>	<ul style="list-style-type: none"> ・教師あり学習による予測 例)売上予測、罹患予測、成約予測、離反予測など ・データの収集(分析に必要なデータの確認、対象となるデータの収集) ・データの加工(データクレンジング、サンプリング、簡単な説明変数の作成) ・データの分析(単回帰分析、重回帰分析、ロジスティック回帰分析、モデルの評価) ・データ分析結果の共有、課題解決に向けた提案
<p>4-9. データ活用実践(教師なし学習)</p>	<ul style="list-style-type: none"> ・教師なし学習によるグルーピング 例)顧客セグメンテーション、店舗クラスタリング ・データの収集(分析に必要なデータの確認、対象となるデータの収集) ・データの加工(データクレンジング、サンプリング、簡単な説明変数の作成) ・データの分析(階層クラスタリング 非階層クラスタリング) ・データ分析結果の共有、課題解決に向けた提案

【表 4-3】主な応用基礎レベルカリキュラム（抜粋）⁽⁸⁵⁾

学修項目	キーワード（知識・スキル）
1-2. 分析設計	<ul style="list-style-type: none"> ・データ分析の進め方、仮説検証サイクル ・分析目的の設定 ・様々なデータ分析手法（回帰、分類、クラスタリングなど） ・様々なデータ可視化手法（比較、構成、分布、変化など） ・データの収集、加工、分割/統合
1-3. データ観察	<ul style="list-style-type: none"> ・データの集計、比較対象の設定、クロス集計表 ・データのバラツキ、ヒストグラム、散布図 ・データの特異点、相違性、傾向性、関連性
1-4. データ分析	<ul style="list-style-type: none"> ・単回帰分析、重回帰分析、最小二乗法 ・ロジスティック回帰分析、最尤法 ・時系列データ、時系列グラフ、周期性、移動平均 ・クラスター分析、デンドログラム ・パターン発見、アソシエーション分析、リフト値
1-5. データ可視化	<ul style="list-style-type: none"> ・可視化目的（比較、構成、分布、変化など）に応じた図表化 ・1～3次元の図表化（棒グラフ、折線グラフ、散布図、積み上げ縦棒グラフ、箱ひげ図、散布図行列、ヒートマップなど） ・適切な縦軸、横軸候補の洗い出し ・不必要な誇張表現、強調表現がもたらす影響
2-5. データ加工	<ul style="list-style-type: none"> ・集計処理、四則演算処理 ・ソート処理、サンプリング処理 ・クレンジング処理（外れ値、異常値、欠損値）
3-3. 機械学習の基礎と展望	<ul style="list-style-type: none"> ・実世界で進む機械学習の応用と発展（需要予測、異常検知、商品推薦など） ・機械学習、教師あり学習、教師なし学習、強化学習 ・学習データと検証データ ・ホールドアウト法、交差検証法 ・過学習、バイアス
3-4. 深層学習の基礎と展望	<ul style="list-style-type: none"> ・実世界で進む深層学習の応用と革新（画像認識、自然言語処理、音声生成など） ・ニューラルネットワークの原理 ・ディープニューラルネットワーク（DNN） ・学習用データと学習済みモデル
3-5. 認識	<ul style="list-style-type: none"> ・認識技術の活用事例 ・パターン認識、特徴抽出、識別 ・数字認識、文字認識 ・画像認識、音声認識

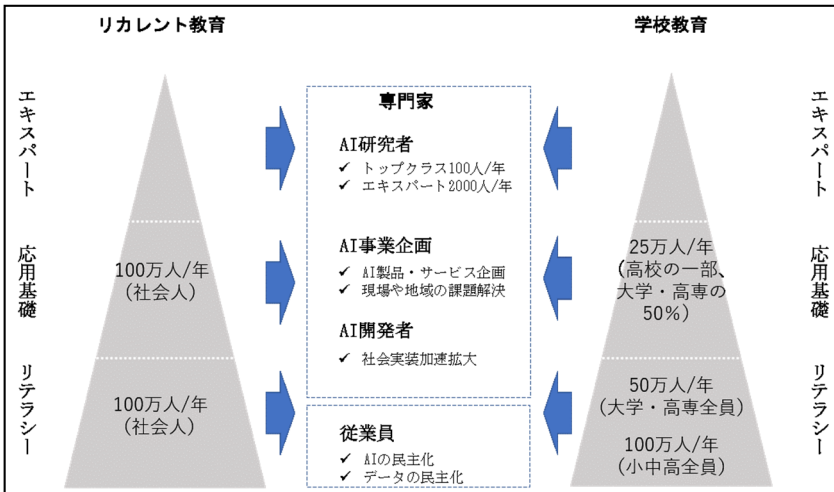
(85) 数理・データサイエンス・AI 教育強化拠点コンソーシアム令和 3 年 3 月「数理・データサイエンス・AI（応用基礎）モデルカリキュラム～AI×データ活用の実践～」12 頁（www.mi.u-tokyo.ac.jp/consortium/pdf/model_ouyoukiso.pdf）（令和 5 年 2 月 19 日最終閲覧）。応用基礎レベルモデルカリキュラムはデータサイエンス基礎、データエンジニアリング基礎・AI 基礎から構成される。これらのなかから、予測モデルの作成に特に関連が高いと考えられる項目を「主な応用基礎レベルカリキュラム」として抜粋した。

<p>3-6. 予測・判断</p>	<ul style="list-style-type: none"> ・予測技術の活用事例 ・決定木 (Decision Tree) ・混同行列、Accuracy、Precision、Recall ・MSE (Mean Square Error) ・ROC 曲線、AUC (Area Under the Curve) 《オプションレベル》 ・ランダムフォレスト ・サポートベクターマシン (SVM)
<p>3-7. 言語・知識</p>	<ul style="list-style-type: none"> ・自然言語処理の活用事例 ・形態素解析、単語分割、係り受け解析 ・ユーザ定義辞書 ・かな漢字変換

また、高等学校においては平成 20・21 年の学習指導要領改定において数学 I に「データの分析」が取り入れられ、「分散、標準偏差、散布図及び相関係数」などデータ分析に必要な知識の習得を目指した授業が行われている。これに加え、令和 4 年度からは情報科において共通必修科目「情報 I」が新設され、全ての生徒がプログラミングのほか、ネットワーク（情報セキュリティを含む）やデータベースの基礎等について学習することとされた。

以上のように、我が国における AI 戦略である「AI 戦略 2019」を受けたモデルカリキュラム及び高等学校数学の学習指導要領を確認することで、AI 活用が必要と考えられるおおよその具体的能力を知ることができる。また、各教育レベルと企業内部での役割の関連付けのイメージは下図 4-2 「AI 戦略 2019 による教育改革のイメージ」のとおり。

【図 4-2】 AI 戦略 2019 による教育改革のイメージ



(出典：独立行政法人情報処理推進機構 AI 白書編集委員会・前掲注(2) 521 頁を一部修正。)

リテラシーレベルの AI 知識を持つ場合、主に従業員として現場から AI の民主化及びデータの民主化を進めることが期待される。また、応用基礎レベルの知識を持つ場合は AI 専門家として AI 事業企画及び AI 開発者としての活躍が期待される。

3 小括

経団連が公表した「AI 活用戦略～AI-Ready な社会の実現に向けて～⁽⁸⁶⁾」によると、AI を有効に活用するためには、単に AI を技術として導入するのみではなく、組織内の人材及びデータ活用環境の双方の充実が重要であると考えられる。特に人材に関しては、AI サイエнтиスト、AI エンジニア及び AI プランナーといった AI 専門家が長期的に不足することが予測されるた

(86) 一般社団法人日本経済団体連合会・前掲注(74)19 頁。

め、計画的な確保が必要である。この点について、民間企業の 6 割以上が不足する AI 人材を自社育成する方針を示している。このことは、AI の利活用にあたっては、業務知識が必要であると判断されたことが一因と考えられる。

AI 人材の育成において、目標とする技術レベルを検討する際には、数理・データサイエンス・AI 教育強化拠点コンソーシアムによるモデルカリキュラムが参考になる。具体的には、AI の民主化及びデータの民主化を進めることが期待される従業員については、グラフ化、ヒートマップ化、チャート化等のデータの可視化技術、データの集計及びツールによるデータ解析技術等のリテラシーレベルの知識が求められる。また、AI 事業企画、AI 開発が期待される専門家は、外れ値の処理などを含むデータのクレンジング処理、サポートベクターマシン及び深層学習等の高度な予測モデルの構築等の応用基礎レベルの知識が求められる。

第 2 節 国税庁において AI 活用するために必要な体制

国税庁において AI を有効活用するためには、民間企業同様に人材育成及びデータ活用環境整備の両面の充実が求められる。これら両面の充実に向けては、「税務行政のデジタル・トランスフォーメーション-税務行政の将来像 2.0-」において、人材育成としてデータリテラシーのレベルに応じた研修体系の整備、システムの高度化として「①書面中心からデータ中心の事務へ移行、②税目別データベース等の見直し、③オープンシステム化」をコンセプトとする次世代システムの開発が掲げられ⁽⁸⁷⁾、AI 活用に適した状況の整備が進められている。本稿では、「AI 戦略 2019」を受けたモデルカリキュラム等の内容を踏まえ、国税庁における人材育成について組織内の役割別に習得すべきデータリテラシーのレベルを考察する。

なお、以下の 1 から 4 までのうち、1 及び 2 はデータの利活用部署、3 及び

(87) 国税庁・前掲注(41)26 頁 (令和 5 年 2 月 21 日最終閲覧)。

4 は予測モデル作成などを行う部署で必要となる知識を想定している。

1 全職員が備えるべき知識

「AI 戦略 2019」の教育改革における大目標に「全ての高等学校卒業生が、『理数・データサイエンス・AI』に関する基礎的なリテラシーを習得」することが掲げられていることから、AI の利活用を推進し、AI からもたらされる便益を享受するためには組織内の AI 専門家のみならず、AI 専門家以外の職員全体が AI に関連するリテラシーを習得することが肝要である。今後、高等学校教育において基礎的な統計知識等を含む「データの分析」を履修した職員の割合が増加することが期待されるものの、「データの分析」が指導内容とされる以前に高等学校を卒業した職員も多く在籍する。そのため、高等学校数学における「データの分析」程度を全職員が備えるべき知識レベルの目標として設定し、必要に応じて研修などを実施することで知識を習得させ、組織における基礎的な AI リテラシーの普及を図ることが望ましいと考える。具体的内容としては、四分位偏差、分散及び標準偏差などのデータの散らばりや、散布図や相関係数などのデータの相関把握が挙げられる。これらの知識を習得することで、データの散らばりや相関等の基本的統計知識に基づいた分析が可能になることや、AI が出力する予測に対して職員各自が自分自身の判断基準に照らしてその当否を適切に判断できるようになること等が期待される。

2 標準的知識

AI 戦略 2019 では、数理・データサイエンス・AI 教育強化拠点コンソーシアムによるリテラシーレベルカリキュラム程度の知識を、文理を問わず、全ての大学・高専生（約 50 万人卒/年）が習得することを目標としている。そのため、今後は新規採用者の中に一定数の数理・データサイエンス・AI に関するリテラシーレベルの知識及び技術を保有する者が存在することが期待される。一方で、高等学校数学における「データの分析」同様に、多数の在職

者はこのようなカリキュラムによる学習機会を得られなかったことが想定される。そのため、必要に応じてリテラシーレベルカリキュラムに相当する研修を実施することで AI 利活用の効果の拡大が期待される。研修の具体的レベルとしては、リテラシーレベルカリキュラムを参考にすると、AI に関する基礎知識、グラフ化、ヒートマップ化、チャート化等のデータの可視化技術、データの集計、ツールによるデータ解析技術等を習得できるレベルが望ましい。これらの知識を習得することで、国税局（所）におけるデータ活用業務への従事や、税務署の調査・徴収部門等におけるデータ活用に関する中心的な役割を担うことが期待される。


3 専門的知識（ミドルレベル）

図 4-2 「AI 戦略 2019 による教育改革のイメージ」において示されるとおり、組織内部で AI 専門家として活躍するためには、リテラシーレベルカリキュラムのうち、高度な知識として位置付けられる「オプション」レベル以上の知識及び技術を習得していることが期待される。国税庁又は国税局において AI 専門家として予測モデルの作成などに従事することを想定した場合、外れ値の処理などを含むデータクレンジング技術及び重回帰分析、ロジスティック回帰分析、クラスタリング等の予測モデル作成関連技術の習得を範囲としたリテラシーレベルカリキュラムにおける「オプション」レベルの知識が必要であると考えられる。

また、リテラシーレベルカリキュラムにおける「オプション」レベルでは、予測モデル作成関連技術の習得に加え、統計及び数理基礎知識の習得が含まれる。統計及び数理基礎知識は、作成した予測モデルの特性を理解し、予測モデルの妥当性を評価するために求められる知識である。下図 4-3 「THE DATA SCIENCE VENN DIAGRAM」に示すとおりデータサイエンス分野では、分析者自身が結論に至る経緯を理解しない場合であっても、尤もらしい分析を作成することが可能であり、このような分析は「危険 (Danger Zone)」と考えられている。そのため、国税庁又は国税局において AI 専門家として

予測モデルの作成などに従事する場合には、統計及び数理基礎知識を習得する必要があると考える。

【図 4-3】 THE DATA SCIENCE VENN DIAGRAM



(出典：Drew Conway 「THE DATA SCIENCE VENN DIAGRAM(2010-09-30) by Drew Conway」 (<http://drewconway.com/zia/2013/3/26/the-data-science-venn-diagram>) (令和 5 年 2 月 21 日最終閲覧。))

以上のように、国税庁又は国税局において AI 専門家として従事するためには、予測モデル作成技術の習得及び統計・数理基礎知識を範囲としたリテラシーレベルカリキュラムにおける「オプション」レベルの知識の習得が必要であることから、研修などを通じて計画的かつ着実に担当者を育成することが望ましい。

なお、リテラシーレベルカリキュラムにおける「オプション」レベルで扱う予測モデルは、概ね BA ツール⁽⁸⁸⁾で作成可能であることが見込まれるため、専門的知識（ミドルレベル）では、プログラミング技術は習得が望ましいものの、必須ではないと考えられる。

(88) ビジネス アナリティクス(Business Analytics)ツールの略称で、画面からの直感的操作でデータ加工や予測モデルの作成が行えるもの。

4 専門的知識（エキスパートレベル）

「3 専門的知識（ミドルレベル）」では、原則として BA ツールによる予測モデル作成を前提とした。BA ツールはユーザインターフェースからの直感的操作によって短期間で予測モデルを構築することができるが、パラメータ調整などは既定の範囲内に限定されるなどの制約が存在することも多い。そのため、より詳細な予測モデルの調整又は画像認識若しくは自然言語処理などの高度な技術が必要な分析には対応できないことも想定される。このような高度な予測モデル作成に対応するため、国税庁や一部の国税局では応用基礎レベルカリキュラムに相当する技術の習得が望まれる。このレベルでは、Python 等のプログラミング言語を活用し、大規模なデータに対して外れ値の処理などのクレンジング処理及び標準化、サポートベクターマシン、深層学習等の高度な予測モデルの構築が期待される。専門的知識（ミドルレベル）同様に統計及び数理基礎知識が必要であること、プログラミング技術の習得には期間を要することから、専門的知識（ミドルレベル）習得者に対して必要な研修を計画的かつ着実に実施することが望まれる。

5 小括

国税庁の人材育成において目指すべきレベルとしては、予測モデルなどを作成する AI 専門家レベルと予測モデルの利活用部署レベルに大別される。AI 専門家レベルでは、予測モデルを作成するための知識及び作成した予測モデルの妥当性を評価するための統計及び数理基礎知識の習得が必要と考える。利活用部署レベルでは、四分位偏差、分散及び標準偏差などのデータの散らばりや、散布図や相関係数などのデータの相関把握に関する知識を全職員が備えるべき知識と位置付けることが望ましい。また、利活用部署レベルにおける上位レベル（組織全体としての標準的レベル）としては、数理・データサイエンス・AI 教育強化拠点コンソーシアムによるリテラシーレベルカリキュラムに相当するレベルが望ましいと考える。

結びにかえて

本研究は、国税庁において ICT・AI 技術を効果的に利活用するための論点整理並びに各論点についての留意点及び方向性の考察を目的に、AI の概要、データ分析、AI の説明性及び解釈性、AI を活用するための組織体制について検討した。第 1 章では、AI はヒトの知能そのものを持つ機械を作ろうとする立場と、ヒトが知能を使ってすることを機械にさせようとする立場があり、実際の研究の多くは後者の立場に立っている⁽⁸⁹⁾ことを述べた上で、本研究においても後者の立場に立って AI を深層学習を含む機械学習と定義した。しかし、2023 年 3 月に GPT-4 (Generative Pre-trained Transformer 4)⁽⁹⁰⁾の公開によって注目を集めた OpenAI 社が、全人類に汎用人工知能の利益がもたらされることを確保することを使命として掲げている⁽⁹¹⁾ように、ヒトの知能そのものを持つ機械を作ろうとする研究も続けられている。何を AI と定義するのかは、立場によって異なるものの、いずれの立場からも有用な研究成果は発表され得るため、本稿における AI の定義に関わらず、広く ICT・AI 技術の動向を注視する必要がある。

また、本稿では紙幅の都合上、教師あり学習を中心に検討を進めた。しかし、教師なし学習も国税業務において活用用途は十分に存在する。例えば、特定の教師あり学習モデルのみを使い続けた場合、当該モデルによって選ばれたデータが、更に教師データとして利用されるといった繰り返しが起こり、モデルに強いバイアスが生じることが考えられる。このような事態を防止するために、教師なし学習によって分析することで、教師あり学習とは異なる特徴を発見したり、教師あり学習によって引き起こされたバイアスを検知できたりすることが期待される。このような教師なし学習の国税業務における活用可能性の検討

(89) 人工知能学会・前掲注(1)。

(90) (<https://openai.com>) (令和 5 年 5 月 24 日最終閲覧)。

(91) OpenAI 社ホームページ (<https://openai.com/about>) (令和 5 年 5 月 20 日最終閲覧)。

は今後の研究に委ねたい。

以上のように、本稿で取り上げた AI 技術は AI 技術全体の一部であり、更に日々新たな AI 技術が生み出される。新たな AI 技術の導入を検討する際には、技術的な本質を理解し、その技術を適切に評価することが肝要である。そのために必要な能力については第 4 章第 2 節において考察したところである。また、技術的な本質の理解に加え、公平性、透明性を確保し説明責任を果たすため、AI を利用する一連の業務において判断過程、判断理由、判断に対する責任の所在を明確にすることが求められる。このような、知識の習得及び蓄積と組織体制の整備を通じて、AI 技術を有効に利活用する組織の基礎が構築される。

AI 技術の導入は、納税者の利便性向上や税務行政の効率化等の観点から革新的な変化をもたらす可能性を秘めている。本稿が国税組織における AI 技術の導入及び有効活用の一助となることを希望する。

謝辞

本論文の記載に当たり、立教大学大学院人工知能科学研究科瀧雅人准教授から多大なご助言、ご協力をいただきました。ここに深謝の意を表します。