

持続可能な社会と企業経営

—AI活用の視点から—

足立 光生

論文要旨

現代ビジネスにおいてAIが重要な地位を占めるようになって久しい。AI関連技術の近年の著しい進化を受け、企業にもAIを現場レベルで活用するだけでなく、経営判断という企業経営の核心部分で活用する可能性が高まっている。ただし、たとえ「AIを活用した経営判断」で日々の局所的最適解を導けたとしても、中長期における大局的最適解を導けるとは限らない。大局的最適解を解くためには企業がたとえば企業倫理を重視して社会のサステナビリティを追求する等の方策が必要である。

本稿では第1に、日々の「AIを活用した経営判断」の適切な最適解の導出について論じる。近年のクラウドコンピューティングならびにIoTの発展とともにビッグデータの取得が容易になり、AI活用は拡充されてきた。ただし、企業がAIを経営判断へ導入する場合には経営のオリジナリティを重視する必要がある。

第2に、社会のサステナビリティを視野に入れた「AIを活用した経営判断」について論じる。それに関する一つ目としては、深層学習を使ったモデルはブラックボックス化しており、説明は困難であるため、経営者とステイクホルダーの間で長期的なストーリー共有が必要であり、経営者とステイクホルダーの間で少なくとも使用モデルの特徴を情報として共有しておく必要がある。二つ目としては、さらに企業経営が社会のサステナビリティを重視するものへの方策である。AIが学習結果として反倫理的なソリューションを返してしまい、それが検証な

きまま実行される危険性への対策としては、前処理の活用等が一般的であるが、現実には手回りのかかる作業である。そこで、ESGへの取り組みを評価として反映した株価収益率を教師信号として、深層学習等の学習モデルを活用することについて論じる。

はじめに¹

2015年9月末に国連が提唱したSDGs (Sustainable Development Goals、持続可能な開発目標)は持続可能な社会を実現するために17のGoalから構成されている。いうまでもなく企業において17のGoalはすべて重要であり、これらを念頭に置きながら企業経営を継続していく必要がある。ただし、企業にとって17のGoalのうち真っ先に目がいくのはGoal9と考えられる。特にGoal9の9.1には「質が高く、信頼でき、持続可能かつレジリエントなインフラ (quality, reliable, sustainable and resilient infrastructure)」(UN (2015))と提示されている。では、このようなインフラとは何を指しているのだろうか。

実際のところGoal9の9.1が示唆する「インフラ」はあまりにも漠然としており、その捉え方は、思想や生活環境によって大きく異なるようにみえる。昔からあるインフラの一般的なイメージとしては港湾、道路、鉄道などであろうし、ITが発展している現在において無形のネットワーク等も確かにインフラであろう。ただし、近年の社会における急激な技術発展を考えた場

¹ 本研究について、日本学術振興会・科学研究費助成事業(学術研究助成基金助成金・基盤研究(C)、課題番号20K01896「持続可能な社会を真に実現するESG経営—新たな評価フレームワークの構築と提言—」)の助成を受けた。

合、それ以外の「世の中を支える基盤技術」はどうだろうか。たとえばビジネス界で現在脚光を浴びているブロックチェーン（Blockchain）は、Goal 9 の 9.1 のインフラに該当するのだろうか²。

ブロックチェーンは当初、暗号資産（crypto asset）である Bitcoin を生み出すための基盤として誕生した。現在も世界中で Bitcoin は盛んに取引が行われているし、様々な議論をよびながらも Bitcoin を支えるシステムは頑健に維持されている。Bitcoin 以外の他の暗号資産についても、ブロックチェーンを基盤として生み出されているものが多い。さらに、管理者をおかずに参加者全員が台帳を管理していくブロックチェーンの画期的な仕組みは暗号資産だけではなく、他分野への応用を積極的に誘引している。特に Vitalik Buterin がイーサリアム（Ethereum）を構築して以降、契約（Contract）を自動執行可能とするスマートコントラクト（Smart Contract）についてブロックチェーンで講じていく試みも始まっている。スマートコントラクトはビジネスの幅広い分野に応用可能なため、ブロックチェーンは今後ビジネスにおいて欠かせない基盤となることが予想される。

ただし、このような状況であるにせよ、現時点では様々な企業やコンソーシアムがブロックチェーンの活用を模索している途中過程にあり、ブロックチェーンをインフラと定義づけるには拙速であることは否めない。ブロックチェーンを「質が高く、信頼でき、持続可能かつレジリエントなインフラ」に位置づけるには、もう少し今後の展開を待つ必要があるようだ。同様のことは他の現在開発中の基盤技術にもいえ、たとえば量子コンピューティング（Quantum Computing）も同様の部類になると考えられる。

そのように考えていけば、現時点で SDGs における Goal 9 の 9.1 のインフラに最も近い基盤技術は何ととっても深層学習（Deep Learning）等によって支えられている AI（Artificial Intelligence）ではないだろうか。

AI は現在、企業活動の様々な側面において幅広く活用されており、現代のビジネスを展開

するうえで欠かせない基盤技術となっている。生産現場、倉庫管理、物流等、応用の範囲は枚挙に暇なく、活用はビジネスの多方面にわたっている。このような急激な進展のなかで AI が「質が高く、信頼でき、持続可能かつレジリエントなインフラ」として認知されるための最終地点は、人間が従来行ってきた最終的判断を AI にすべて委ねるということであろう。たとえばビジネスについていえば、AI をビジネスの現場レベルで活用するだけでなく、「経営判断」という企業経営の核心部分で活用することにある。

いうまでもなく現時点において、それは実現していない。現在のところは AI の学習結果を経営判断に補完的（augmented）に取りいれているのが関の山である。ただし AI 関連技術が指数関数的に発展していることを考えれば将来的に、（生身の経営者が経営判断を行うのではなく）AI が企業の経営判断を行う「ロボット経営」が採用されていく可能性もあり得る。そして AI の現在の活躍を鑑みれば「特異点」到達に関わりなく、もっと早い時点で「ロボット経営」が実現する可能性も否定できない。ただし、そこには 2 つの疑問がある。

第 1 に、今後 AI の技術が大幅に発展したとしても「ロボット経営で的確な経営を行うことは可能か」という単純な疑問である。それは経営に必要な総合的判断能力をロボットが獲得できるか、という疑問である。かりに工場で用いられる産業用ロボットならば、学習対象は閉じた空間内の出来事であり、既存データを学習することによって最適な解（例えば産業用ロボットのアームの動き）を導出できる可能性がある。ただし、産業用ロボットの場合、学習対象は限定されているのが通常であろう。経営判断においては社会で起きている様々な現象を、現在進行形のものを含めて学習していく必要があり、学習対象を限定しているわけではない。そのような広範囲な学習は実際のところ可能かという疑問である。

第 2 に、企業経営の目標として、「持続可能な経営（Sustainable Management）」に努めること、すなわち社会のサステナビリティ（sustainability、

² ただし、ブロックチェーンは様々な技術をつなぎあわせて構築されたものであることにも留意する必要がある。たとえば、ブロックチェーンを構成している技術の一つが暗号技術であり、Bitcoin では公開鍵暗号手法（Public-key cryptography）が的確に活用されている。

持続可能性)を追求することは当然求められる。企業経営は目先の利益にとらわれず企業の倫理的責任(Carroll(1991))を追求することが大前提であるが、人間の援助をなくして、AIのみでどこまで「持続可能な経営」を目指すことが可能かという疑問である。

本稿はこのような2つの疑問をふまえ、「AIを活用した経営判断」のあり方を論じる。第1章では、企業経営において従来AIに何が期待されていたかについて、その経緯を簡単に整理する。企業の現場から生み出されるデータを経営判断に活かす試みがかなり以前より行われてきたことに触れ、近年の企業が扱うデータの変化と、近年登場してきた深層学習の特徴について簡単に概観する。第2章では、日々の経営戦略という局所的視点から考える。AI活用において先行する他業界からの技術移行の可能性について言及するものの、その応用における問題点について示唆する。第3章ではより大局的視点から、企業の倫理的責任をはじめとして社会のサステナビリティという視点から考えていく。「AIを活用した経営判断」では、その判断根拠がブラックボックス化してしまう可能性が非常に高いため、様々なステイクホルダーを見据えた明確な説明責任の必要性について言及する。また、AIの判断結果が「持続可能な経営」を反映したものとなるように、学習モデル構築における株式市場のデータ活用について論じる。

1. 経営判断におけるデータ活用と深層学習活用の概要

旧来、経営判断は経営者の熟練した経験や勘所に依拠するものと考えられてきた。ただし、生身の人間の判断には当然間違いもある。かりに十分なインテリジェンスを持って経営を行うロボットが今後誕生したとして、そうしたロボットが、旧来型の「経営者の直観」や「経営者の勘所」を用いた経営を目の当たりにすれば、まさに「経営者の暴走」ととらえるだろう。

経営判断に科学的根拠を持たせることの重要性についてはかなり以前より意識されていた。特にビジネスの現場から生み出されるデータをもとに経営判断を行うこと(いわゆる data-driven 型経営)の重要性はかなり以前から構想されていた。本章では最初にそうした経営判断の従来の試みについて整理する。次に2000年代における深層学習の進展を整理し、深層学習の活用を裏で支えることになったデータ量の変化について示唆する。

1.1 旧来の試みと変化

企業における data-driven 型経営は1960年代には既に構想されており、大企業はその時期、様々な情報の活用を志向するようになった。ただし、その当時では大型コンピュータを導入できる機関も限定されており、たとえそのような大型コンピュータの導入に至っても、1960年代の情報処理能力では実際の経営判断に実用化するには程遠かった。

1970年代には、蓄積された知識や経験則から演繹的に解を導出するエキスパート・システム(Expert System)が注目を浴びた。エキスパート・システムはまさに「AIを活用した経営判断」の試みそのものであったといえよう。ただし、エキスパート・システムは膨大な知識データベースを必要として多大な開発コストを誘引する結果となった。さらに1970年代当時の情報処理能力の限界も重なり、エキスパート・システムを経営判断に実用することは困難なことであった³。

その後1980年代になるとビジネスの様々なシーンにおいてたとえばPOS(Point of Sale)データの活用が積極的に推進された。システム開発もそれに応じて盛んになっていく⁴。

1990年代になるとインターネット環境の普及が広く普及し、エンドユーザのPCにおけるCPU(Central Processing Unit)の性能が向上するなか、企業経営者にとって情報活用の門戸が大きく広がった。企業の間では情報が企業価値に貢献するというコンセンサスが幅広く得られた。

³ エキスパート・システムの実質的な失敗は、その後の「AIを活用した経営判断」をデザインするための貴重な経験則となったものと考えられる。

⁴ ただし、この時期、企業毎に仕様の異なるシステムの氾濫を招いたともいえる。

ところでこの時期以降に企業が主に扱ってきたデータは POS データ（あるいは ID-POS データ）、経理データ、顧客データ等をはじめとする構造化データであった。構造化データを活用するメリットとしては、何よりもデータ処理の簡単な点が挙げられる。さらに、外部のステイクホルダーに対して経営指針を説明する場合にも、構造化データを基盤としている場合、説明は簡潔かつ明瞭となる。ただし、構造化データにはデータ整理に膨大な時間を要するというデメリットも存在する。また、表形式に整理されなかった有用な情報を活用できない可能性も高い。そうした弱点を克服するのが、非構造化データといえよう。

2000 年代になり、次節でのべるように深層学習が発展したことから、非構造化データの活用に注目が集まった。社内における営業記録のようなテキストデータはもちろん、社外の SNS におけるテキストデータなどの非構造化データが data-driven 型経営に積極的に活用されるようになる。非構造化データの持つ情報は、構造化データの持つ情報量をはるかに大きいことから、企業経営においてはデータ活用が近年特に重要になっている。そこで現代の企業においては CDO (Chief Data Officer、最高データ責任者)⁵ の重要性も高くなっている。

1.2 深層学習の登場と発展

AI の基盤となった深層学習について最初に整理しておきたい。

深層学習は、従来からあったニューラルネットワーク (Neural Network) に大幅な改良を重ねた発展形といえよう。ニューラルネットワークは生物の脳のなかにある神経細胞ニューロン (Neuron) をヒントに得た数理モデルであり、k 近傍法や決定木などとともに機械学習 (Machine Learning) の一種に分類される。

ニューラルネットワークの出発点は、McCulloch & Pitts (1943) のモデルに遡る。McCulloch &

Pitts (1943) が提示したモデルでは、複数の入力値から一つの出力値を得るために、入力値に重みをかけて足し合わせる。そして、その際、その足し合わされた数値が閾値を超える必要がある。こうした McCulloch & Pitts (1943) の発想は現代まで続く技術の大きな礎となっている。その後、Rosenblatt (1958) はニューロンの重みを任意に決めるのではなく、教師を設定して学習の結果とりだすためのモデルとしてパーセプトロン (Perceptron) を開発した。

その後、ニューラルネットワークは一つの体系化されたモデルとして開発されていく。複数のニューロンを利用し、層を基盤としてつなぎあわせて作り上げたニューラルネットワーク上で Back Propagation⁶ によって学習を行わせる。そして最適なパラメータを持つ学習モデルを構築して、様々な現実の課題に応用する。このようなニューラルネットワークについては自然科学だけではなく社会科学からも注目され、実に様々な研究が展開された⁷。ただし、ニューラルネットワークが持つ学習能力や予測精度には限界があり、現実社会への適用には大幅な改良が必要とされていた。

そこに登場したのが深層学習である。2006 年に Hinton 等がニューラルネットワークに対して大きな改良を加えた深層学習を考案する (Hinton et al. (2006) 等)。深層学習はニューラルネットワークの中間層をより多層化する。さらこの時期に生まれたオートエンコーダ (auto encoder) (Hinton & Salakhutdinov (2006)) では、対象の特徴量を識別する点において大きな進展がみられた。オートエンコーダは、入力値と出力値を同値とすることで、情報をネットワークのなかに圧縮する。さらに、情報を圧縮した層をかりに順次スタックしていけば、より有意な学習モデルを構築できることが一般的に想定される。ただし、現実にはそれぞれの層を最適化しても総体のバランスは最適とならない可能性がある。そのため、オートエンコーダは現在、深層学習の先導役としての位置付けにあるとはいえない⁸。ただし、オートエンコーダの概念として、

⁵ CDO は、Chief Digital Officer (最高デジタル責任者) の意味として使われる場合もある。

⁶ たとえば Rumelhart et al. (1986) 等を参照せよ。

⁷ ニューラルネットワークを現実のソリューションに用いる研究はあまりにも多様で膨大な研究である。たとえば拙著 adachi (2004) では、株式市場のローソク足をニューラルネットワークに学習させて株価予測を試みている。

⁸ 現在、オートエンコーダ活用の一つの方向性としてあげられるのが VAE (Variational Autoencoder) である。VAE は Goodfellow et al. (2014) が提示した GAN (Generative Adversarial Networks) と同様に、学習対象と同様のものの生成を試みるモデルとして位置づけられる。

いかに学習対象を正確に把握していくか、そのために何を精緻に改良していくべきか、というコンセプトが従来のニューラルネットから深層学習(Deep Learning)への劇的發展につながったと思われる。

現在、深層学習については画像認識等に活用されるCNN(Convolutional Neural Network)⁹、時系列データを扱うことから言語処理に強みを発揮するRNN(Recurrent Neural Network)等の開発が注目されている。さらに、深層強化学習(Deep Reinforcement Learning)は対象の価値を計測するためのモデルとして、脚光を浴びている。

深層強化学習は、言葉のとおり、深層学習に強化学習(Reinforcement Learning)を導入したのである。旧来、強化学習は、Watkins & Dayan(1992)のQ学習に代表されるように、エージェント自身が将来的な報酬を最大化するために自律的に学習していくものとして開発されていた。そもそも強化学習は機械学習の一類型として確立しており、ニューラルネットとは別の流をくむものであった。すなわち強化学習は(ニューラルネットの進化バージョンとして登場した)深層学習とは別の類型にあるといえよう。ただし、強化学習にCNN等の深層学習が組み合わされることで新しい深層強化学習となり、産業用ロボット等の自律的な学習に活用されている¹⁰。

1.3 深層学習の発展と周囲の環境

ところで、深層学習による学習には相応のデータ量を必要とする。それに対して、近年におけるデータ量の爆発的な増加がその発展を後押しした。産業界ではIoT(Internet of Things)の発展に伴って得られる膨大なデータ、日常生活ではSNSに書き込まれる大量のテキストデータや投稿される大量の画像等、いわゆるビッグデータの取得が容易になり、深層学習の現実応用に大きく寄与した。

さらに、同時並行でGPU(Graphics Processing Unit)の性能向上が、深層学習の膨大な演算処理を実用化する一助となった。当初、深層学習のビジネス活用は、オンプレミス型のネットワーク構築によって志向された。ただし、クラウドコンピューティングの精度も急激な発展から、オンプレミス型ネットワーク構築からクラウド利用に替わってきており、一からの開発コストを捻出することの難しい企業にもその利用は活発になってきている。そのため、世の中の関心はいわゆるGAFAM¹¹をはじめとする大手プラットフォームフォーマーが開発する新しい技術に移っている。

また、経営戦略とは少し離れるが、ビジネスにおける深層学習の発展は、IoTの発展とともにエッジコンピューティングへも応用されていることも注目すべきであろう。すなわち、工場や倉庫等の様々な設備から発せられる様々な情報をセンサで取得し、それを現場レベルで解釈する方向性である。ここではセンサと安価に手に入るボードコンピュータとつなぎ、その場で深層学習を実践させるものである。このような場面で使われる簡易なコンピュータでは、そのコンピュータで作動させるためのよりコンパクトなネットワークを開発する必要がある。そこには大規模ネットワークで作成された出力層を、簡易なネットワークに学習させるDistilling(Hinton et al. (2015))が有効と考えられる。今後ローカルかつコンパクトな深層学習モデルが社会で大いに活躍することは必至であろう。

2. AIの経営判断への活用(1)

一日々の経営判断という視点から—

企業においては日々、様々な判断に迫られる。かりに企業がAIを日々の経営判断へ活用するとすれば、具体的にどのような場面であろうか。企業の経営判断といってもあまりにも多様である。業種や業界は様々であり、一様に定義でき

⁹ 畳み込み層をニューラルネットに応用する方法であり、その発想はLeCun et al. (1989)等を起源とする。

¹⁰ 一例としてQ学習では、ある状態(state)とある行動(action)の関数として、Q値という価値を表として定義する。ただし、表はもっと幅広い状態空間で定義することも可能である。そこでニューラルネット上で表を学習によって類似的に構築しようとしたのがQ-Networkである。さらに、(ニューラルネットの発展版である)深層学習を使ってその実現を試みたのがDeep Q-Network(Mnih et al. (2015))である。

¹¹ Google, Apple, Facebook, Amazonの4社。また、これらの企業にNetflixを含めてFAANGとよばれる場合もある。

るものでは決してないが、あえてイメージ的に集約するとすれば、たとえば、(1) 新規事業への参画の決定、(2) 新しいサービス商品に関する最終価格決定、(3) 企業資源の適切なアセットアロケーションの決定、(4) 業務の提携先の決定、(5) 主要な人事の決定 といった具合であろう。

これらの日々の経営判断では深層学習を用いた確かな経営判断を講じていくことは可能か。たとえば、AIによって解を導けたとしてもその解はそもそも適切か。本章では第1に現代の経営に何が求められているかについて、第2に他の業界から学習モデルを転移する場合の課題について、第3に深層学習の特徴とデータに関する一般的課題について概観する。

2.1 企業経営に求められているサステナビリティ

企業経営が社会から要望されている課題は大きい。たとえ日々の経営判断とはいえ、現在では経営者に対しても様々な姿勢が求められており、その点は特に投資家から規律付けされる可能性もある。それは2006年のPRI (Principles for Responsible Investment、責任投資原則) を起源とする。

2006年にUNEP FI (United Nations Environment Programme Finance Initiative、国連環境計画金融イニシアティブ) とグローバルコンパクト (Global Compact) のもとでPRIが提唱されて以降は、ESG (Environment, Social, Governance) 投資が証券投資の世界で大きな潮流をしめる。投資家においてのもっぱらの関心事は現在、該当企業がどれだけESG要因を遵守しているかということに間違いはない。特にSDGsのGOALに向けてESG投資は、持続可能な投資 (sustainable investment) の重要な課題として定義づけられている。たとえばGSIA (Global Sustainable Investment Alliance) は、「持続可能な投資」を7つの分類の中で定義している¹²が、そこにはESG投資の重要性がうかがえる。このような

投資の潮流は、経営にきわめて影響を及ぼすため、企業が「AIを使った経営判断」を日々行っていく際にもこの傾向は踏襲する必要がある。

2.2 AI導入における課題

あらゆる企業において経営判断から免れることはできない。一方、AIを活用した経営判断を志向する全ての企業がAIシステムを自前で構築できるとは限らない。その場合には前述したようにクラウドが提供する様々なサービスを利用することが一般的となりつつある。また、AIソリューション関連の業者に依頼し、自社のニーズに応じた形で適切なシステムを構築してもらうことも想像される。ただし、ソリューションを提供する業者もそもそも限定されており、依頼してくる業界も似通ってくる。そこで、別の企業に導入した学習済みモデルを初期値として導入する転移学習 (Transfer Learning) が適用されることも想像される。

ところで、転移学習を活用する場合には、経営判断と多くの類似のソリューションが、既に金融・証券業界に導入されている点に注意する必要がある。金融・証券業界によるAI導入の試みは古く、たとえば(1)については投資行動における意思決定法¹³ときわめて類似している。投資の世界ではAIによる資産運用アドバイスは普遍的な広がりを見せており、人知のみでは達成の難しいハイパフォーマンスが期待されている。金融・証券業界での学習済みモデルは、証券投資における様々な事象を学習したものであり、同じく幅広い事象を対象とする経営判断に転用することは果たして可能か。

金融・証券業界で使われている手法を経営判断に応用すること考えた場合、何よりも注意しなければならないのは、企業経営と投資の意思決定における根本的な差異にある。投資の場合は「長いものにまかれる」的な思想が根本にあるため、転移学習によって投資判断が画一化してしまうことは一般的に違和感がない¹⁴。ただし、経営の場合には画一化したモデルを様々な

¹² GSIA (2018) を参照せよ。

¹³ このような意思決定法については、ファイナンス理論においてはNPV法で論じられてきたが、1990年代になるとリアルオプション (Real Options) のフレームワークで論じられるようになった。

¹⁴ あまりにも多くの投資家が同じモデルを使用してしまえば、市場の方向性を著しく誘導することによって、2010年に起きたフラッシュクラッシュ (Flash Crash) のような急激な価格変化を招く恐れもある。

企業で使用することは、経営判断が画一化してしまい、経営の独自性を壊していく可能性がある。その企業の存在価値は、他の企業には真似できないオリジナリティの筈である。

さらに説明責任の違いについても考えてみたい。企業経営、投資いずれについてもその主体者においても厳しい責任が問われていることはいうまでもない。企業経営においては様々なステイクホルダーに対する説明責任が備わるし、投資においては受託者責任が存在する場合もある。ただし、説明責任の所在については以下の点で、その様相が根本的に異なっている。

最初に企業経営においては、組織や株主をはじめとするステイクホルダーを納得させるためには経営判断への説明責任が要求されていく場合が多い。そこで、経営者はステイクホルダーへの説明責任のため、その行動を掘り下げて説明する必要が生まれる。一方、投資においてはその注文一つひとつに対して、(よほど巨額で超長期の投資ならともかく)説明する必要に常に迫られていくとは想像しにくい¹⁵。特に、2010年代に東証のアローヘッド導入を境に、わが国でも勃興したHFT(High Frequency Trading)に代表されるように、投資には高頻度で取引が行われている世界もある。これらの高頻度で執行される投資において、いちいちの投資行動の背景の説明をたとえ求められたとしても実際には無理がある。

このように投資と経営とは異なるため、投資の判断に使われる学習モデルをそのまま経営判断に転移することは難しいであろう。

ただし、転移学習は難しいにせよ、経営の巧拙を判断しているのは通常の場合、株式市場における株価となっていることには十分留意する必要がある。すなわち(上述のように転移学習を活用することには無理があるものの)株価収益率を教師信号として学習ネットワークに活用できる可能性が存在する。この点については第3章であらためて論じる。

2.3 深層学習の特徴とデータに関する一般的課題

深層学習が発展を遂げた一因としては(前章で述べたオートエンコーダだけでなく)学習モデルにおける中間層が多層化したことも挙げられる。中間層の多層化によって、学習過程はより厳密なものになり、それまでの機械学習に比して予測精度の精緻化にも貢献した。ただし、一般的に中間層が多層化することは、学習モデルの学習時間の増加につながる。そもそも学習時間がかかることは、瞬時的な経営判断を迫られるときに致命的である。特に、本来ならば一般的な常識レベルで結論が下せる判断にしても、データを用意して学習を行ってから判断ということになれば本末転倒であろう。すなわち、現状において「AIを活用した経営判断」には判断までのタイムラグを考慮し、場合に応じて臨機応変に対応することが求められる。また、学習の対象であるデータ量について考えてみた場合、データ量が学習モデルの規模に比して多い場合にも同様の所要時間に関する問題が考えられる。

一方、データ量が少ない場合はどうか。データ量が少ない場合、一般的に問題となるのは「過学習(Over Learning)」である。学習モデルが少ないデータに適合してしまうあまり、本来ならば一般的でない事象が重視されてしまう恐れがある。過学習を避ける手段としては、過学習が認識されると速やかに学習を打ち切るという方法もあるし、ニューロンをランダムに消去するDropout(Srivastava et al. (2014)等)や、ニューロン同士の結合の重みをゼロにするDropconnect(Wan et al. (2013)等)を活用することも検討する必要がある。ただし、それとは逆に、企業の特異な内部環境から採取されるデータであれば、学習モデルに比して絶対的にデータ量が足りない場合もある。そのようなデータ不足による過学習を避けるために、自然科学の分野では、Data Extension¹⁶と呼ばれる人工的なデータの増強が行われる場合がある(Autio et al. (2007)等)。ただし、これは一

¹⁵ たとえば株式市場では板の上に投資家の相場観を反映した注文を置くことで取引を行うが、投資家自体はアバター化したものであり、匿名性が担保される。

¹⁶ Data Augmentationともよばれる。

般的には画像処理への対応であり、経営判断において同様の措置を適用することは難しいことが想定される。

3. AIの経営判断への活用(2) 一企業のサステナビリティという視点から

2020年のパンデミックによって現代社会はこれまでに経験しなかった困難に直面した。不確実な困難に立ち向かうためには「AIを活用した経営判断」がブレイクスルーとなる可能性も確かに存在する。ただし、前章で指摘したように「AIを活用した経営判断」においては様々なステークホルダーを同時に満足させる判断でなければならない。

また、かりに日々の経営判断における局所的最適解が一時的に適切なものであっても、「合成の誤謬 (fallacy of composition)」が示唆するように、それを積み重ねたところで大局的最適解になるとは限らない。この点はAIが行うか人間が行うかに関わらず、経営判断の核心部分であり、そのためにも経営判断にサステナビリティ要素をより強く意識する施策が必要である。

3.1 深層学習を使った経営判断—ブラックボックスからの脱却

深層学習による結果が誰にも予想できなかったアウトプットであった場合、人知を超えた「知」として経営判断に大きく寄与する場合もあろう。また、そうした結果に価値が認められて経営者が日々の経営判断にAIを使うことになっても、経営者がステークホルダーに「なぜこのような判断となったか」を説明しようとするればいっきにハードルが上がる。

従来の構造化データを使って、線形的な構造に焼き直して解説することは、一般的に「わかりやすさ」を担保することが可能であったものの、深層学習を使ったモデルはモデル自体がブラックボックス化しており、結果の説明は極めて困難である。モデル自体はネットワークとし

て構成されるものである。そこでマイクロレベルでノード間の結合重みを一つひとつ検証しても、新たな解釈は生み出せないことが通常である。また、マクロレベルでみた場合、深層学習が導出するアウトプットは、あくまでも「AIが対象の本質を十分理解して導出した」ものではない。AIが描いた画像等がよく話題になるが、これらをみればAIの学習過程の奇怪さに気づかされる。AIの学習過程は、人間が通常行うような学習過程ではなく、AI自身が解釈しやすいような独特の当てはめ方をしていると考えるべきであろう。人間は自らが創り出したAIの行動を、逆に理解する必要に迫られている。

それでは打開策はどこにあるのか。近年では深層学習のアウトプットをブラックボックス化せずに、きちんと解釈しようとする研究が進んでいる。例えばCNNにおける学習過程でどこに力点がおかれて学習したかを明らかにする取り組みとしてはGrad-CAM (Gradient-weighted Class Activation Mapping)¹⁷が挙げられる。このような取り組みは、様々なステークホルダーへの説明責任の多い企業にとって特に重宝されるであろう。ただし、こうしたアプローチの成果については未知数である。

現時点における最低限の対策として、経営者と(株主をはじめとする)ステークホルダーの間で「ストーリーを共有すること」が重要である。「経営判断にAIを活用するというコンセンサスを得る」ことも出発点として当然必要であるが、経営者とステークホルダーの間でより深い知識共有が必要な場合は、少なくとも使用する学習モデルの特徴をお互いに共有する必要がある。深層学習と一言でいっても様々なモデルがあり、それぞれに特性があるからだ。万が一不備な事態等が生じた場合、学習モデルの特性を経営者とステークホルダーの間で共有しておくことで対応できる部分も大きい。明らかに誤ったソリューションへの予防線として、経営者とステークホルダーで「使用モデルはどのような状況において、判断を間違えやすいか」を知識共有していることが経営を進めるうえでの大前提と考えられる。

¹⁷ Grad-CAMについてはSelvaraju et al. (2017)等を参照せよ。

3.2 「持続可能な経営」と深層学習

企業の経営判断の拠り所は、企業収益のみを単純に追求することではない。より重要なのは「持続可能な経営」を担保しながら企業収益を追求する姿勢にある。特に、経済的価値に加えて社会的価値を生み出すCSV¹⁸(Porter & Kramer (2006), Porter & Kramer (2011))の概念が普及したことにより、企業に対して経済的価値の増加と社会的価値の増加を同時に追求することが要求されるようになってきている。このような潮流はSDGsが採択されて以降、世界的な取り組みとなりつつある。また、わが国においても近年になって企業の急激なガバナンス改革もその後押しをしている¹⁹。

企業が持続可能な経営を維持するためには、たとえば企業倫理を固く維持しなければならない。それを文字通り解釈すれば、「ロボット経営」の実現を目指す場合、企業倫理の学習モデルを構築するということになる。ただし、企業の倫理的側面をAIが学習することは簡単なことであろうか。いうまでもなくAIは、人間のように、幼い時から社会生活を送るなかで倫理的判断を要求されてきたわけではないので、人間にとって簡単に出来る倫理判断がAIにとっては簡単とは限らない。企業倫理を学習する場合、一から適切な学習を積み重ねていく必要がある。

そして倫理判断を行うとともに、企業収益の最大化を目指すための経営判断をしていかなければならない。後者が優先される学習モデルであれば、企業が収益をあげるために適切な経営判断とした場合、反倫理的なアウトプットをソリューションとして返す可能性もある。たとえば前章で提示した(4)提携先の決定についても原材料のサプライヤーを決定する際に、その価格設定や納入の迅速さ等を学習して結論を下すことが出来ても、サプライヤーが反社会的な行為をしている場合に、市場に蔓延する噂等を加味した上で判断することは難しい。今後起こりうる反倫理的な問題にはどのように対処するか。

現時点においてこうした対応は、学習データ

に対する前処理に転化される。すなわち反倫理的な結論を防ぐためには、前処理を行い、最初に倫理上不適切なデータを取り除く。ただし、現実には前処理は手間のかかる作業であり、さらに前処理の段階で恣意的な干渉を入れ過ぎてしまった場合、AI導入の目的が失われてしまうことは必至である。

そこで、経営判断のネットワークを構築する際、サステナビリティ要素をネットワークに併合させる必要がある。これらを実装する学習モデルを構築して、前処理をなるべく減じる必要がある。

結局のところ以上を解釈するならば、学習モデルを構築する際に、ネットワークにサステナビリティ要素も併せて学習させることが考えられる。たとえば、一例を挙げれば深層学習において多用されるアンサンブル学習(Ensemble learning)の活用も選択肢と考えられる。アンサンブル学習を上手に活用し、「経営判断に関する学習」「サステナビリティ要素に関する学習」を複合的にバランスよく組み合わせた学習を行うことが一つの解決策となる可能性は高い。ただし、このような考えは理論的に問題がなくでも、現実にはかなり難しいことが想定される。

3.3 教師データとしての株式市場の活用

先に、深層学習等による学習モデルを構築する際に、経営判断に必要な事項とサステナビリティ要素をそれぞれ学習してアンサンブルをとる方法を述べたが、以降ではアンサンブルをとらずに、それらを同時に学習する簡易なアプローチについて考えてみたい。そして、そのようなモデルについてはオーソドックスな機械学習でも可能であるが、2006年以降の理論の発展を考えれば、深層学習モデルを構築することが望ましい。

単純に、構築する学習モデルの一例として、入力層には経営に関する各種要素に関して、その状態をインプットするため素子を複数並べる。そして、出力層の素子に「企業のサステナ

¹⁸ Creating Shared Value. 共有価値の創造。

¹⁹ 2014年2月に、金融庁は日本版スチュワードシップ・コードを発表した。また、2015年6月に金融庁と東京証券取引所によってコーポレートガバナンス・コードの適用が開始された。

ビリティの向上に向けた取り組みを価値として評価するもの」を置くべきであろう。

それでは出力層におく「企業のサステナビリティの向上に向けた取り組みを価値として評価するもの」とは何か。それは経営の成果に関する価値、すなわち株式市場における該当株の収益率とするアプローチはどうだろうか²⁰。株価収益率の利点としてはどのような事態においても営業日には必ず採取出来るという継続性を有する²¹。また、日々の終値に基づく日次収益率だけでなく、1分足終値における収益率、1秒足終値における収益率等、時系列の間隔にはかなりのバリエーションがあるため、様々な場面での応用も考えられる。

それでは、そもそもなぜ企業がサステナビリティ要素を考慮にいった結果が、該当企業の株価収益率として考えることが可能か。それについては、これまで企業の財務パフォーマンスの向上と投資家から要求される ESG 項目の関連を論じた各種の研究から示唆できる。

企業の財務パフォーマンスの向上と投資家から要求される ESG 項目の関連性は、2006 年に UNEP FI 等によって PRI が提唱される以前から散見される。たとえば、1990 年代から企業の ESG の取り組みといった社会的パフォーマンスが CFP (Corporate Financial Performance, 財務パフォーマンス) に良好な影響を与えることが研究のなかで指摘されている。古いものとしては 1990 年代前半を対象とした Griffin & Mahon (1997) や、主に 1990 年代後半を対象とした Tsoutsoura (2004) によってもその結果は同様である。2000 年代になっても検証結果の基本的な流れに変わりはない (Lenssen et al. (2005) 等)。

また、2006 年に PRI が提唱されて以降も同種の検証は盛んに行われ、現時点において世界中で莫大な研究成果となっている。そのなかには肯定的な結果も否定的結果もあるが、それらの集約的な研究としては Friede et al. (2015) がある。たとえば Friede et al. (2015) によれば、社会的パフォーマンスが財務パフォーマンスに与える影響に関して 2000 を超える研究結果

を集約した結果、ESG と CFP のノンネガティブな関係を総括している。さらに同研究結果は CFP に対する ESG のプラスの影響が長期にわたって安定していることも示唆している。

このような研究の結果から、ESG が CFP に対しプラスの影響を与えることが一般的に想定される。そして CFP において、株式市場を通じて表現する一つの方法を挙げるならば株価収益率ということになる。すなわち、企業経営のなかで ESG への取り組みが的確なものであれば該当企業の株価収益を向上させることにつながり、逆も然りという発想は否定できない。言葉を変えれば、「ESG への企業経営の取り組みは、結果的に市場から株価収益率という報酬を得る」と定義づけた学習モデルによって学習を簡易にすることは可能と考えられる。

また、われわれの住んでいる世界はパンデミックや震災等、予期せぬショックによって、状態は極端に遷移する。実は、そのような状況変化は状態空間の多様な次元数を考慮していかなければならないが、それを株価収益率という (収益率と時間の) 2次元において集約的に表現可能な点は大変有為とも考えられる。

さらに、状態空間に何らかの変化が生じれば株式市場での株価は市場水準の Jump という形で対応する。Jump が起きた後の株価水準について水準の調整することで、それまでの学習モデルでも的確な学習を継続することが可能と考えられる。

以上のアプローチは、あくまでもサステナビリティ要素を考慮に入れた「AI を使った経営判断」を簡易に行うためであることを再度留意してほしい。

おわりに

AI を経営判断に活用していく試みとして、前章では 2 つの提案を行った。一つは、(AI の学習過程がブラックボックスの構造を持つため説明を省力することが多いものの) ステイクホルダーに対して経営判断の明確な説明を行う施

²⁰ ただし、該当企業が上場していることが前提となる。

²¹ ただし、取引所のシステムトラブル等によってその事が担保できないことも起こりえる。2020 年 10 月 1 日朝、東京証券取引所でアローヘッドの不具合等からシステム障害が起り、すべての銘柄で取引が終日中止される等の異常事態となった。

策である。もう一つは、「社会のサステナビリティに関する学習」と「経営判断に関する学習」を組み合わせた方法である。単純に考えれば「社会のサステナビリティに関する学習」と「経営判断に関する学習」のアンサンブル学習ということになるが、それよりも各種の深層学習のなかで、該当企業の株価収益率を教師データとして採用することで簡易に対応可能とも考えられる。これまでの様々な研究結果から、該当企業の株価収益率こそ企業のサステナビリティ要素に対する市場からの評価であるからだ。

いずれにせよ、学習モデル構築にサステナビリティ要素は絶対に必要であり、サステナビリティの考慮が欠けていたとすれば、たとえ日々の経営判断において局所的最適解を解けても、大局的に持続可能な経営を行うことはロボット経営には難しいだろう。

本論の最後に、今後、経営者をはじめ様々なステークホルダーの意識変革について触れたい。重要なのは、これらから共生を図っていくAIに対するより深い理解、すなわち愛着ではないだろうか。本論でも述べたように学習構造が通常ブラックボックス化しているAIは、人間にとって気味の悪いものとして見えがちである。だからこそ、愛情をもってAIを理解しようとする姿勢が逆に必要ではないか。ビジネスに関わる人間以外のもの、たとえば原材料等に用いられる自然資本に対して愛着を感じることは従来からビジネスの世界では広く見受けられた。自然資本と同様に、AIを理解して愛着を持つとする姿勢は、一朝一夕では難しい。AIの構想は古くからあったものの、長い試行錯誤を経た結果、ようやく的確な学習を始めたばかりである。また、われわれが時間をかけて愛情を育むべき対象は、「AIを活用した経営判断」を志す企業に対しても同様である。該当企業の経営者(あるいはステークホルダー)の意思についても社会全体で時間をかけて見守っていく必要があるのではないか。持続可能な世界に向かって、われわれが準備すべき課題はまだまだ多いようである。

参考文献

- Adachi, M. (2004). Applying Neural Networks to the Extraction of Available Investment Information from the Previous Day's Stock Market. *NUCB Journal of Economics and Information Science* (『名古屋商科大学総合経営・経営情報論集』), 48(2), 13-22.
- Autio, L., Juhola, M., & Laurikkala, J. (2007). On the neural network classification of medical data and an endeavour to balance non-uniform data sets with artificial data extension. *Computers in Biology and Medicine*, 37(3), 388-397.
- Carroll, A. B. (1991). The pyramid of corporate social responsibility: Toward the moral management of organizational stakeholders. *Business Horizons*, 34(4), 39-49.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative adversarial nets. In *Advances in Neural Information Processing Systems*, 2672-2680.
- Friede, G., Busch, T., & Bassen, A. (2015). ESG and financial performance: aggregated evidence from more than 2000 empirical studies. *Journal of Sustainable Finance & Investment*, 5(4), 210-233.
- Griffin, J. J., & Mahon, J. F. (1997). The corporate social performance and corporate financial performance debate: Twenty-five years of incomparable research. *Business & Society*, 36(1), 5-31.
- GSIA (2018) GLOBAL SUSTAINABLE INVESTMENT REVIEW 2018 (2020年3月1日閲覧)
<http://www.gsi-alliance.org/wp-content/uploads/2019/03/GSIR-cover-thumbnail1.jpg>
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507.
- Hinton, G., Vinyals, O., & Dean, J. (2015). Distilling the knowledge in a neural network. arXiv preprint arXiv:1503.02531.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1(4), 541-551.
- Lensen, G., van den Bergh, L., Louche, C., Van de Velde, E., Vermeir, W., & Corten, F. (2005) *Corporate Governance: The International Journal of Business in Society*.
- McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J., & Barton, D. (2012). Big data: the management revolution. *Harvard Business Review*, 90(10), 60-68.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., et al. (2015). Human-level control through deep reinforcement learning. *nature*, 518(7540), 529-53
- Porter, M., & Kramer, M. R. (2006). Strategy & Society. *Harvard Business Review: Collection*, 2, 1-17.
- Porter, M., & Kramer, M. R. (2011). Creating shared value. *Harvard Business Review*, 89, 62-77.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological*

- Review*, 65(6), 386.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 618-626).
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.
- Tsoutsoura, M. (2004). Corporate social responsibility and financial performance.
- UN.(2015). Transforming our world: the 2030 Agenda for Sustainable Development. *Division for Sustainable Development Goals: New York, NY, USA*.
- Watkins, C. J., & Dayan, P. (1992). Q-learning. *Machine Learning*, 8 (3-4), 279-292.
- Wan, L., Zeiler, M., Zhang, S., Le Cun, Y., & Fergus, R. (2013). Regularization of neural networks using dropconnect. In *International Conference on Machine Learning*, 1058-1066.