

「AI を監査する…」
～ビジネスに AI を活用する ITC への提言～



2020年3月31日
企業内 ITC・IT ガバナンス研究会

序

デジタル化の進展に依って、ITが業務に組み込まれ日常の仕事がそれなしでは回らない時代になって久しい。ことに「DX」という言葉がもてはやされ、「いかに早く実用に供するかたちで導入するか…」が、当然の如く語られる時代にある。

主役になるのは、AI、RPA、IoTなどであるが、ただ単に導入すればことが進むと云う単純なものでないことは明らかである。

私共「企業内ITC・ITガバナンス研究会」としては、これらの信頼性を検証・担保する監査プロセスのすべてを研究テーマとして網羅すべきとも思われるが、些か荷が重すぎるのと、それは本分でもないと考えているので、今年度はその一連のプロセスの一部に特化して、ITコーディネータとしても関心の深いであろうところ、「AI監査」の部分を深堀して、論述したいと考えている。

「AI監査」を行うに、実際にあたっては、データを投入して結果を見ることから始めなければならないか…とも思われるが、私共は新しい技術特有のリスク要素に感度を上げて、50数年前初めてのコンピュータシステムの信頼性を担保するために監査を行った時と同等のアウトプットを導き、変化に向き合って新しい技術に臨むべきと考え、これを今年度の研究会成果物とさせて頂く。

2020年3月

執筆者 一同

執筆メンバー ITガバナンス研究会

久住 昭之(元ITコーディネータ)

坂本 徳明(0064952006C)

瀬戸 昭彦(0065252006C)

滝沢 康(0012552001C)

千枝 和行(0029302004C)

古川 正紀(0005462001C)

牧田 一雄(元ITコーディネータ)

山崎 直和(0035252003C)

(注)本記載内容は、ITコーディネータ個人としての見解を述べたものであって、個人が所属する企業・団体としての見解を述べたもので無いことをお断りします。

また、本書において使用しているシステム名や製品名などで各メーカー等の登録商標を使用している部分がありますが、文中においてはTM、コピーライト表記はしておりません。

1. はじめに

序にも書かせて頂いたが、デジタル化の進展に依って、ITが業務に組み込まれ日常の仕事がそれなしでは回らない時代になって久しい。ことに「DX」という言葉がもてはやされ、「いかに早く実用に供するかたちで導入するか…」が、当然の如く語られる時代にある。

主役になるのは、AI、RPA、IoTなどであるが、ただ単に導入すればことが進むと云う単純なものでないことは明らかである。

昨年経産省は「システム監査基準」及び「システム管理基準」の改訂を行い、今年度はFISC(金融情報システムセンター)が、「金融機関等のシステム監査基準」の改定を行い、ともにその中で「ISO/IEC38500」を意識した「組織の力」としての「ITガバナンス」について触れて居り、「監査でITガバナンスをどう審査するか…」について述べられている。

詰まるところは、「意思決定プロセスを監査する…」とされているが、先に記述した「DX」等の新しい技術を業務に取り込むと云う事は、それを所管する部署がどう企画して、承認を受けて、導入実施して、結果の実績をきちんと確認されているかという部分を監査することになる。新しい技術の場合は、仕組み・体制・プロセスを綿密に見て行かねばならないからである。

私共「企業内ITC・ITガバナンス研究会」としては、この監査プロセスのすべてを研究テーマとして網羅すべきではあるが、些か荷が重すぎるのと本分でもないと考えているので、今年度はその一連のプロセスの一部に特化して、ITコーディネータとしても関心の深いであろうところを深堀して、論述したいと考えている。

前述のような前提のもと、今年度の課題は「AI(システム)監査」と云う事にさせて頂く。通常、新規技術の導入を考える場合、PoC (Proof of Concept : 概念実証) の手法を活用する。AIの導入に於いても多くが、このPOC手法を用いて小規模な実証検査をした上で、かつそのリスク分析を実施した上で、導入に問題なしと判断できたところで、次のステップに進むと云うプロセスを踏襲するはずである。

実際のAIシステムの導入は現時点では、かなりのスピードで浸透している。例えば某生保ではIBM社のWatsonを導入して、保険金の支払業務にAIを活用されている。その詳細ロジックに関してはうかがい知れないが、綿密なシステム監査が実施されたことと推察する。また、何社かの企業で採用面接にAIを使用していると云う事例が在る。

ある企業では、面接の結果を過去の大量の面接データと照合して、採用可否判断に使用されたりしているが、別の企業ではAI搭載のロボット面接官が集団面接の場に於いて、発言の少ない応募者に発言を促したり、他の応募者の発言に対して矛盾点を指摘したり、反対意見を促すような事例も既にあると云う。

このような事例を見聞きするにつれ、その判断をするAIの信頼性に対して、大きなリスクを意識するのは当然のことと考える。

AI監査に於いて、現時点ではその監査基準に明確なものは示されていない。有識者の幾人かの講演資料に意見として見受けられる程度であり、今はいろいろな研究機関で体系的な取りまとめを実施していると云う旨を伺っている。

私たちの研究会もそれに倣って意見を出し、少しの検証結果をまとめたいと考える。

AIシステムと言っても、システムであるからには、システムとしての定義、内部ロジックは当然のことながら存在する。そこにAIシステム特有の判断基準の見落とし、統計推論の信ぴょう性が大きな潜在リスクとなるので、少しでもそのリスクを見つけ出すべを導き出したいと考えている。

実際にデータを投入して結果を見ることから始めなければならないか…とも思われるが、私共は新しい技術特有のリスク要素に感度を上げて、50数年前初めてのコンピュータシステムの信頼性を担保するために監査を行った時と同等のアウトプットを導き、変化に向き合って新しい技術に臨むべきと考える。

AIに関しては、未だに法的な部分で不透明なところが多い。著作権は人に与えられるものであるから、AIの成果物は著作権として認められないとか、実しやかに主張される方も居られる。このような過程の段階で「AI監査」の領域に一石を投じる意義は高いと考える。

2. AI が活躍する環境

まずは本章において、改めて「AIが活躍する環境」について再確認してみたい。と言っても、そもそもAIという概念自体がいつまでたっても曖昧であるため、本章では再認識の意味も込めて「AIとは何か」、「現在のAIができること」、「AIが活躍する環境」の3ステップで考察することとしたい。

2-1. AIとは何か

AIの定義は難しい。略さずに英語表記すれば「Artificial Intelligence」であり、日本語に直訳すると「人工知能」となるが、そもそも「人工知能」というのが何だか分かりにくい。そこで本章においては、便宜的に「人工知能」＝「自律性と適用性を兼ね備えたもの」と読み替えて考えていくこととしたい。

「自律性」とは、「人間が指示することなく自動的に作業等を行える能力」であり、単純なロボットでも具備している能力である。それに対して「適用性」というのは、学習や経験を積むことでパフォーマンスを向上させる能力のことであり、まさにこの「適用性」こそがAIのミソと言える。

ちなみに、総務省が公表している「情報通信白書（令和元年版）」においても、AIの定義については明確に示されておらず、

『あえていえば、「AI」とは、人間の思考プロセスと同じような形で動作するプログラム、あるいは人間が知的と感じる情報処理・技術といった広い概念で理解されている。』

との記載にとどめられている。さらに、「AI」、「機械学習」、「深層学習（ディープラーニング）」の関係性については図2-1のように整理されている。

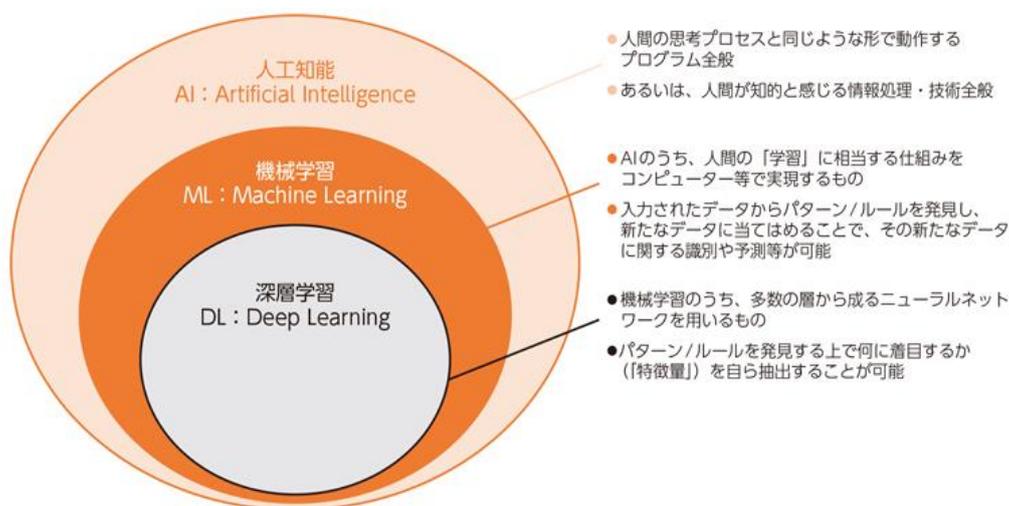


図2-1 「AI」、「機械学習」、「深層学習（ディープラーニング）」の関係性

また、AIにも様々な種類がある。よく「強いAI（汎用型AI）」と「弱いAI（特化型

AI)」といった言葉を耳にするが、前述した「適用性」の差がその違いになっている。具体的には、人間と同じように様々な作業を行うことができるものが一般体に「強いAI」と呼ばれ、特定用途のためだけに作られたもの（例えば将棋のAIソフトや音声認識等）が「弱いAI」と呼ばれている。

一方で、人工知能のレベルによって分類する場合もある。例えば、レベル1を家電等に組み込まれた機械を制御するプログラムレベルと定義し、レベル4を深層学習（ディープラーニング）するプログラムレベルと定義する方法である。

このようにAIという言葉自体が示すスコープは広範囲かつ曖昧であり、どこをスコープに考えるかによって論ずる内容も微妙に変わってしまうので本稿のようなAIについて考察する文献については特に注意が必要である。よく多くの会社等の中でAIについて議論していると、すぐに話が噛み合わなくなるのはこのせいではないだろうか。

以上のことを踏まえ、AIという言葉を幅広く考えてしまうと以降の論点がぼやける危険性があるため、本章では「強いAI（汎用型AI）」を念頭に考えていくこととしたい。

2-2. 現在のAIで出来ること

次に、現在のAIで具体的に何かできるようになり、どのようなことに使われているかについて改めて考えてみることにしたい。

現在のAIで出来ることを分類すると概ね表2-1のように整理出来ると考えている。

表2-1 現在のAIで出来ること

| | 主な実現内容 | 補足説明 |
|---|--------|--|
| 1 | 音声の認識 | AIが音声を学習し、言葉を理解&活用できるようになる。 |
| 2 | 言語の認識 | AIが文字を学習し、文章を理解&活用できるようになる。 |
| 3 | 画像の認識 | AIが図形を学習し、画像を理解&活用できるようになる。 |
| 4 | 機械の制御 | 上記3つの認識により、機械（自動車等）を最適に動作させることが可能になる。 |
| 5 | 将来の予測 | 機械の制御が可能になることにより、INPUTとOUTPUTの結果を学習出来るようになり、INPUT情報から将来のOUTPUT結果を予測することが可能になる。 |

【道路情報の認識を色分する例（Full-Resolution Residual Networks (FRRNs)より)】



【道路情報の認識を囲う例（SSD MobileNet V2より)】



【唇の動きから文字に変換する例（Lip Reading Sentences in the Wildより)】



2-3. AIが活躍する環境

前節までの考察を踏まえ、本章の最後である本節では「AIが活躍する環境」、すなわち、具体的にどのような分野や業態でAIが活躍しているかについて、再確認してみることとしたい。

まず、総務省が「ICTの現状に関する調査研究（平成30年）」の結果として取り纏めた図2-2を参照していただきたい。「活用技術」（＝AIで出来ること）と「活用空間」（＝AIによって分析された結果等を活用する環境）の視点で分類されているが、AIが具体的にどのような環境で活用されているかが良く分かる。

| 活用空間 \ 活用技術 | サイバー空間 | リアル空間 |
|-------------|--|--|
| 機械学習 | <ul style="list-style-type: none"> 最適提案 レコメンド FAQ | <ul style="list-style-type: none"> 農作物の生育状況管理 混雑予測 サービス・商品の需要予測 与信審査 設備の稼働状況管理 |
| 画像認識 | <ul style="list-style-type: none"> 不正等の検知 不正送金 迷惑メール 悪質案件 不正出品物 | <ul style="list-style-type: none"> 不良品の検出 高齢者の見守り 顧客属性推定 自動運転 健康管理 監視 |
| 音声認識 | <ul style="list-style-type: none"> デジタル化 手書き文字 音声 | <ul style="list-style-type: none"> 音声翻訳 知識支援 FAQ候補の提示 コミュニケーション 娯楽 介護 英会話 商品案内 |
| 自然言語処理 | <ul style="list-style-type: none"> 注文対応 質問回答 | <ul style="list-style-type: none"> 口コミ分析 |

図2-2 AI・IoTサービスマッピング

サイバー空間では、過去のデータ等、デジタルデータが豊富に蓄積されているため、それらの分析結果に基づくレコメンドや不正検知等で多く活用されている。一方、リアル空間では、蓄えられたデータを分析して結果を出すというよりも、リアルタイムで変化する情報をもとに稼働状況を管理する、混雑情報を予測する、自動運転を制御する等、状況把握等にAIを活用しているのが特徴と言える。

参考資料：

1. 「情報通信白書（令和元年版）」（総務省）
2. 「ICTの現状に関する調査研究（平成30年）」（総務省）

3. AIを利用することによる効果（経営的な視点から）

AI技術はスキル不足や人手による作業を補完する手段のひとつとして様々なビジネスシーンで実用化が進みつつあるが、その背景にはインターネットやクラウド等の大量データの高速伝送や蓄積、コンピュータ処理能力の向上があり、IoTによるデータの見える化、人の行動や生活に密着したモバイルデバイスの実現といったことがある。現時点においては、画像認識や動画認識、顔認証、文字認識といった画像処理系での利用が先行しているが、今後は更に感情認識や音声認識、医者や弁護士など膨大な情報を取り扱う専門家のサポートといった、「ヒトの活動・判断支援」の分野で利用されていくことが想定できる。

3.1 AIにより可能となっていくこと

AI技術によって、従来の能力がより拡張されていくものと考えられる。拡張可能な能力としては、

- ① 事象を把握するための知覚・認識能力
- ② 知識の継承や経験の補完などといったナレッジ
- ③ 意思決定支援のための判断材料や予測結果の提示

といったことが考えられ、それぞれの事例としては次のようなものがある

- ④ 知覚・認識：カメラによる製品の外観検査の自動化
- ⑤ ナレッジ：過去のデータから類似事例を提示することで、経験が少ない者でも高度な査定や評価といった業務が行える
- ⑥ 判断：製造業のプロセスデータから製品品質の悪化やプロセス上のボトルネックの予兆を検出する

これらを組み合わせた具体的な利用例は次のとおりである。

(1) ヘルプデスク支援（①+②）

- ・蓄積された回答シナリオを基に、問い合わせ内容をリアルタイムに分析して回答に必要な情報をオペレータに提示する
- ・お客様の声の調子からお客様の感情を読み取り、適切な対応アドバイスを提示する

(2) 障害検知対応の自動化（②+③）

- ・運用管理システムからのイベント通知に応じて、蓄積された対応事例の中から想定されるトラブル内容とアクション選択を自動化する

(3) 脅威検知・分析 (②+③)

- ・ 公的機関の情報や論文集、専門家コメントなどといった各種情報を収集することで、セキュリティ脅威に関する知識を自動収集・習得し、それをもとにしてセキュリティアセスメントを行ったり、インシデント発生時の深刻度をアドバイスするなど担当者を支援する

3.2 AI利用の経営的観点からの意義

経営的な観点から言えば「AIを利用することによる効果」とは、大きく分けて2通りが考えられる。

一つは、コスト削減／パフォーマンス向上効果であり、どこにAIを活用すれば自社に最も効果的であるのかを整理すること＝AIの活用できる業務とそうでない業務を仕分ける（細分化して可視化する）ことと言える。

もう一つは新たな収益獲得効果であり、「画像が何なのか認識が出来る」ということではなく、どんなことが認識できるのか、それがどのようにビジネスの中で役立つのか、あるいはそれによりどんな新しいビジネスが創出できるのかということだと言える。

(1) コスト削減/パフォーマンス向上効果

現在行っている業務を、AI技術を適用して効率的に行うことでコスト削減を図ることが可能となる。その際にはAI技術で代替しやすい定型業務、人間が必要な業務、その中間のグレーゾーンなど業務を分析し、どのようなことが代替できるかをきちんと仕分けすることが必要である。

- ・ 人手不足を代替（＝ヒトがやるべきこととAIに代替させることを分け）
- ・ コストパフォーマンス向上（＝より多くの作業を正確かつスピーディーに）

ヒトが単純作業として行っていたことは、マンマシンインタフェースを効率化することで機械に行わせることができるようになる。

- ・ マンマシンインタフェースの効率化

音声による入力や指示（ヒトは、書くことは大変だが、しゃべることは簡単）

- ・ 経営判断材料の提供

判断時の要検討項目についての不足（抜けモレ）チェック等による効率的な判断

例えば、売上予測、生産計画、仕入管理、在庫管理、リソースマネジメント、人事管理・・・などなど、各業務プロセスへの導入、あるいは各業務プロセス間での最適な連携まで、どこに導入することで有効かを考える必要がある。

なお、定型業務ではRPA (Robotic Process Automation) やコストの低いアウトソースで費用対効果が十分に出ることもあるため、重要なのは人間が本当にやる

べき仕事を再定義し、それに集中するための選択肢を考えることである。(AI前提ではない)

(2) 新たな収益獲得効果

AI技術によりこれまでできなかったことができるようになることで、新しいサービスや製品の提供による事業拡大が可能となる。

AIを利用することで、試行錯誤の支援（ある程度の絞り込み）が行えるが、レコメンドはあっても、AIシステムのアウトプット結果（判断）でヒトが動くことはなく、その内容を必ずヒトが採用可否判断することが必要となる。

例：ヒトの表情から感情を推測し、対応の仕方をガイドする/変える

収益機会がどこにあるのかを見つける手助けをする

AI導入は、ヒトに考える時間を創り出すことを可能としてくれる。この時間をビジネス創造に振り向けていくことが重要であり、それこそがAIを利用することによる効果であると言える。

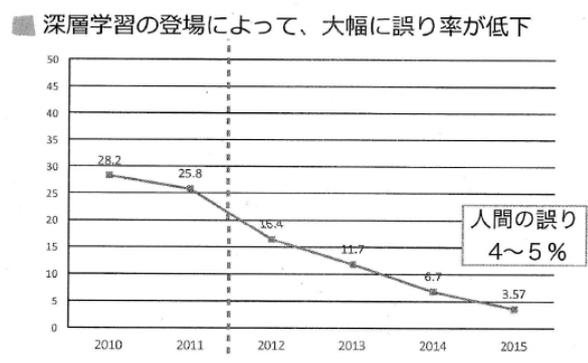
4. AI処理の信頼性とは (AIの処理結果をそんなに簡単に信用していいものか)

Googleが深層学習で写真の識別レベルを飛躍的に向上させて以来、深層学習を利用した画像識別・音声認識・構文解析技術の向上などにより、X線フィルム・MRI等の画像による病気診断、車に搭載したカメラによる自動運転の可能性、コールセンターの案内や翻訳など、AIの可能性を示す技術が次々に登場し、世の中を変えていく可能性を与えてくれている。

良い事ばかりが宣伝される一方で、そのような処理をした出力結果の信頼性については、一部の研究者以外にその信頼性に言及している例は少ない。特に企業がAI サービスを行うにあたって、どのくらいの過ちを犯すものなのかについては、表向きは一切言及されていない。

【岐阜大 速水教授の講義より引用】

2010年からの誤り率の推移



利用者はAI処理の結果について、どのくらい信頼したらいいのか。つまり、誤診だったり、人違いだったり、誤操作だったり、誤った回答だったりをした場合の確率や、その影響についてどのように考え、対応したらいいのだろうか。この章ではその事について考えてみたい。

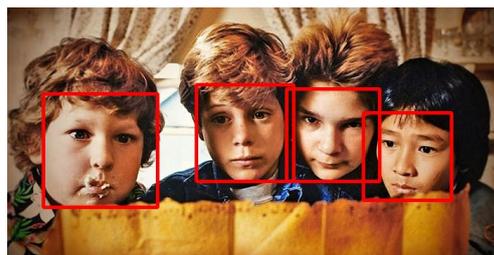
4-1. AIと言えどコンピュータのアプリケーションプログラムに過ぎない

Googleは写真に撮影されている特定物、例えば猫・犬・鳩・カラスなどを極めて高い精度で識別する技術を公表した。更には、人間の顔やランドマークなどを写真上から区別して認識する技術を提供した。

【下の写真で顔認証をしてマークする例】



【顔認証後の写真】



これら技術を応用して、例えば車に搭載したカメラで運転中の道路を撮影し、撮影されている被写体がなんであるのかの識別を、コンピュータ処理として可能に

した。実際のところ、Googleは地図上に「ストリートビュー」をはめ込むために、車のルーフ上に四方が撮影できるカメラを搭載して、世界中の道路を撮影しまくり、地図からストリートビューが閲覧できるようにした。この膨大なビッグデータを元に、人・生物・信号・道路・ランドマーク等を識別し、運転者が適切な運転をできるような支援技術を可能にした。

人間のドライバーが注意を怠っても、コンピュータで処理された画像を元に、ブレーキやハンドル操作などを運転者に変わって操作できるよう制御する集積回路を搭載し、人間に変わって適切な操作が可能となった。これは、従来からあった車の制御技術に、新たに画像処理とAI技術を組み合わせることで、実現可能である。

【画像（上半分）を識別して、認識を色分け（下半分）する例（SegNetより）】



車は今や、動く情報処理センターとでもいうべき方向に進んでいる。単に運転だけではなく、インターネットを通じた情報入手、スマホなどの携帯端末との連携による情報処理、情報発信が可能で、移動しながら情報処理センター化が可能である。これらは全てITと通信技術がもたらすもので、コンピュータによるアプリケーションプログラムがもたらす情報処理の一形態である。オフィス上では以前からあった技術もあるが一段と進歩しており、工場内や一般家庭内、航空機・船舶などでも同様の技術がもたらされつつある。この流れはだれにも止められず、認識しない間に利用するような環境がもたらされつつある。

4-2. AIに置ける主要な処理機能

AIで使われている技術はいったい何なのか。

大きくは2つの技術である。一つは分類・識別技術であり、もう一つは因果関係を明確化する技術である。以下に主な技術を例示する。

ここでは、これらの手法の詳細な解説は行わないので、それぞれの専門書にて学習願いたい。

分類や因果関係を調べる技術は以前から存在していて、それらは主に統計学として広く利用さ

- a) 分類機能
 - 数値データの分類
 - テキストの分類
 - 写真の識別
 - 音声の識別
- b) 回帰と因果関係の機能
 - 重回帰分析

れてきた。また、数値以外のテキストデータなどは、テキストマイニングとして利用されてきている。統計学による分類は関数モデルにより行われているので、線形モデルでの当てはめが成立しなかったり、データに重複があったり、境界線があいまいな場合、上手く適用できない。また、処理しても例外が多く発生したりして、信頼性に欠ける場合がある。

ところが、AI技術の中のパーセプトロンやニューラルネットワークは、同様にモデルを設定して内部で関数処理を行いながらも、曖昧なデータでも識別を可能とした。このため、応用範囲が広がったのである。

◇統計解析と機械学習（AI）の相違点

| 項目 | 統計解析 | 機械学習（AI） |
|----------|-----------------------|-----------------|
| 処理方法 | バッチ処理中心 | オンライン処理中心 |
| 処理のタイミング | データが集約できた時点 | デイリーで常時発生 |
| データ量 | 数百～数百万？ | 数百万～数千万 |
| 前処理 | 対象データの構造化 | 事前集約処理が必要 |
| 解析対象の統制 | 必ず統制が必要 | 必ずしも統制は必要なし |
| 解析方法 | パラ・ノンパラ両方 | パラ・ノンパラ両方 |
| 求めているもの | 調査対象の構造化 （どうなっている） | モデル作成 （自動処理） |
| データの性質 | 数量化できるものが中心 | 数量化に依存せず適用 |
| 計算パラメータ | パラメータは固定化 | パラメータは常時変化 |
| 結果の保証 | 結果に対する保証が必要 | 保証に関しては不明 |
| 適用 | 将来の事象に指針を付与 | モデルに適用し継続利用 |

統計処理とAI処理は共にモデルを設定し、当てはまりの良いもの、つまり誤差が最小になるものを選択して未来の現象に当てはめて活用する。

では、統計処理とAI処理の大きな違いは何か。処理の仕方が違うのは勿論であるが、誤差の取り扱い方が大きく異なるのである。統計処理の場合、観測された誤差は全体的にプールされ、計算された統計量に意味が有るのか無いのかを、誤差の統計量を基準にして判断される。

それに対して、AIの場合は損失関数や勾配降下法等を使って誤差をコントロールする。教師有りの場合、結果が目標値からずれた場合、出力側から入力側に遡るようにして誤差を割り振り、より想定した結果に近づける様にチューニングを行う。従って、より良いモデル設定と損失関数等の選び方が性能を分けてしまう。

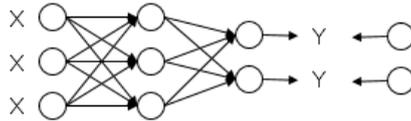
ただ、ここでお断りしておくが、現在統計パッケージを販売している会社や、BIツール（ビジネスインテリジェンスツール）を販売している会社では、既にこのようなAI処理の特性を取り入れており、その境界線は曖昧になりつつあるのが現状である。

関数を特定するパラメータを特性値と呼ぶが、統計計算の場合人間が判断し、AI（深層学習）の場合はAI自身が判断する。従って、なぜそのような結果になる

のかを説明できない場合が存在する。答えはあるが、プロセスを証明できないのである。

◇誤差逆伝播法(バックプロパゲーション)

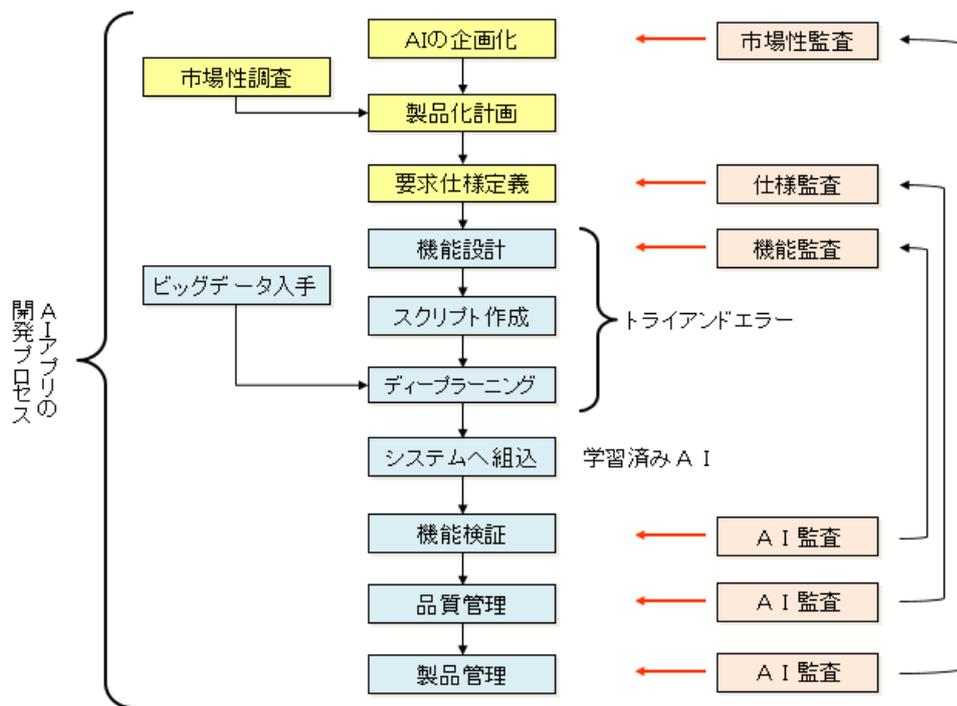
階層型ニューラルネットワークで使用される計算方法で、誤差関数Eを設定して、入力Xから得られた出力Yと正解データTとの誤差を計算して、Eの値が小さくなるように学習するアルゴリズム。
何層にもわたってユニットが存在することから、出力層から入力層に向かってパラメータの調整量が伝わっていく方法。



4-3. AI開発のプロセス

AI開発のプロセスと監査のポイントを下図に例示する。

AI開発のプロセスと監査のポイント



一応、説明の便宜上開発フローらしきものを例示してあるが、AI開発はウォーターフォール開発の様に一定方式があるわけではなく、アジャイル開発の様にトライアンドエラーの性質が強い。特に、マン・マシンインターフェイスの部分はともかくとして、中心となるAIに学習させる部分は今のところ開発者による手作りに依存している。

AI監査を行う場合は、その辺の事情を意識する必要がある。

4-4. AIの信頼性と処理上の誤差の取り扱い方法

AI処理と言っても種々あり、そこで取り扱われている誤差（損失関数）の処理方法も複数存在し、画一的に表現できない。良し悪しではなく、種類が存在して技術者がそれを使い分けて利用している。損失関数の取り扱いが適切に行われているかどうかは、基本的にはAI機能の設計方針に依存することになる。処理は機械学習・深層学習とあるが、少しずつ異なる。

今回はAIを監査の視点で論じているので、誤差の取り扱いはその結果の品質に影響する重要なファクターとなる。それはそのまま、AI処理の信頼性にもつながる。

1) AI（推論エンジン）開発での手順

AI処理の設計をしてから、最適解でのAI推論エンジンの完成に至るまでの中心的な開発手順を、以下に例示してみる。

- ① 事業上の解決すべき問題点の明確化
- ② AI処理方式の決定
- ③ 出力ラベルの用意（教師有り学習）
- ④ 深層学習する層（何層にするか）の選択
- ⑤ 活性化関数の選択
- ⑥ 機械学習
- ⑦ 実行結果のラベルの比較で損失関数から誤差を計算
- ⑧ 勾配降下法の選択又は最適化の適用による最適化
- ⑨ 事業としての処理の評価

監査の観点で見た時、これらの記録を点検し、方法論の選択とその結果につき、監査を進める事がポイントになる。

尚、AI推論エンジンがパッケージで提供されているものを利用している場合、上記の手順は利用者から見るとブラックボックス化されており、開発者がその内容を開示しない限り、内容の監査は出来ず、入力と結果の照合によるテストデータ法的な監査しかできない。それは汎用の統計パッケージなどと同様の扱いにならざるを得ない。

2) 画像における境界の識別

画像の識別と言えば、例えば猫の画像であれば「猫」というラベルを付ける事である。画像をクラス識別するということ、どこかに境界線があるということである。

画像を識別する場合は、それらの要素を配列空間に展開するのである。8×8の画素なら64画素であり、63次元の空間になる。つまり63次元の特徴量という事になるわけである。この入力データの内積を計算し、損失関数を用いて損失が少なくなるように識別境界の角度を調整していく。機械学習でも境界線が引けるが、問題は精度なのである。機械学習で引いた境界線では誤差が多く実用に耐えられないのである。この機械学習の欠点を補うために、畳み込みニューラルネットワークが考案されたのである。

ニューラルネットワーク上では入力された信号を、論理演算を行って次のノードに送るよう設計されている。この層をいくつか重ねることにより、識別が可能となる。

3) 様々な活性化関数

ニューラルネットワークにシグモイド関数を使用したのは、歴史的な背景があり、脳の神経細胞の信号伝達をモデル化したものであるからである。

活性化関数をいくつか紹介する・

- ・双曲線正接 (hyperbolic tangent)
- ・ランプ関数 (rectified linear function)
- ・ステップ関数 (step function)
- ・ソフトマックス関数 (softmax function)

4) 識別における誤差の取り扱い

損失関数はラベルと出力の誤差を計算する関数になる。ニューラルネットワークモデルは教師データとニューラルネットワークの出力間の差を小さくする様に、学習が行われる。損失関数はその「差」の測り方を与える役割があり、問題に対して適切に損失関数を選ぶことが重要になる。

a) 分類問題に適用される損失関数

- ・交差エントロピー誤差 (cross entropy error)

$$E = - \sum_k t_k \log y_k$$

t_k は実際のカテゴリを0,1を用いて表す(正解であれば1、不正解に対しては0)。 y_k は予測確率。

b) 回帰問題に適用される損失関数

- ・平均二乗誤差 (Mean Squared Error)

$$MSE(y_i, \hat{y}_i) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

y_i は実値、 \hat{y}_i は予測値を指す。

- 平均絶対誤差 (Mean Absolute Error)

$$MAE(y_i, \hat{y}_i) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

y_i は実値、 \hat{y}_i は予測値を指す。

- 平均二乗対数誤差 (Mean Squared Logarithmic Error)

$$MSLE(y_i, \hat{y}_i) = \frac{1}{n} \sum_{i=1}^n \{\log(1 + y_i) - \log(1 + \hat{y}_i)\}^2$$

y_i は実値、 \hat{y}_i は予測値を指す。

c) ニューラルネットワークにおける活性化関数と損失関数

パーセプトロンやニューラルネットワークでは、色々な値が入力される。それを整理して、0～1の数値出力に整理して判定する。そのようなルール決めをしないと、出力してくる数値がシステムによってばらばらになり、評価できないからである。すべての出力を0～1に統一する。その場合、2値分類(クロスエントロピー)の場合にシグモイド関数を使用し、多値分類ではソフトマックス関数を使用する。ソフトマックス関数の特徴は、クラス数がいくつあっても合計が1になるように調整することである。

ニューラルネットワークで2値もしくは多値で入力されたデータは、ネットワークノード上の活性化関数で変換され、最終的に0～1にデータとなって出力される。活性化関数を適用することにより、2つのクラスを識別する境界線を引くことが出来る。解決すべき問題によって、活性化関数や損失関数を適切に選択する必要がある。場合によっては、設計者自身が関数定義をする必要が出てくる。

ニューラルネットワークを使って推論した結果と、あらかじめ用意したラベルデータを突き合わせてみる。この推論値とラベル値の差が損失として認識されるのである。

d) 誤差の最小化を図る様々な勾配降下法

交差エントロピー誤差や平均二乗誤差以外にも、損失を減らす方法としていくつかの方法が提案されている。

- 最急降下法 (gradient descent)
損失関数の勾配から、傾きの方向に最小値を探索する方法。
- バッチ勾配降下法 (batch gradient descent)
訓練データ全体に対して、損失関数の勾配を計算する方法。
- 確率的勾配降下法 (stochastic gradient decent)
データ一つ一つの勾配を見て都度パラメータを更新する方法。
- ミニバッチ勾配降下法 (mini-batch gradient decent)
先の2つを組み合わせたようなもの。

勾配降下法を適用して処理すると、誤差が必ず減っていくというわけではない。場合によっては、段階的に下がってきたのに、ある時点から急に誤差が拡大するようなケースもあり、何が起きているのか分からず当惑するような場面に遭遇することも有り得る。トライアンドエラーで改善策を積み重ねるしかない場合も出てくる。

e) 最適化の手法

学習によるパラメータの更新は、損失が最小になるよう、パラメータの最適化を行うことである。いくつかの方法を掲載する。

- **SDG**
現在位置で勾配の最も急な方向へパラメータを更新する方法。
- **Adagrad**
学習率を固定ではなく徐々に減衰させる手法で、1つ1つのパラメータに対して、学習効率を調整する方法。
- **RMSprop**
一律に勾配の2乗を足すのではなく、減衰率を過去の勾配に乗算することで過去の勾配を更新する方法。
- **Adam**
RMSpropにモーメンタムの考えを追加したような方法。

どの方法論が一番いいというのではなく、これらの方法のうち、目的に沿ったものを比較しながら選択していく事になる。

4-5. 適用するデータの処理に対する要件定義と検証

前項では、損失関数（誤差）の取り扱い方をいくつか紹介した。AIの、特に深層学習の場合には、関数の取り扱い以外にもチェックしなければならない点はいくつかあるので、それにふれてみたい。

1) AI処理の対象となるデータと頑健性 (Robustness)

AI処理に限らず、一般の統計処理でも第1に考えておかなければならないことは、処理の対象となるデータの塊をどの様に考え捉えているか、という事である。統計学ではこれを「母集団」と呼んでいる。処理する対象がどのような特性を備え、どの程度の規模を想定しているかを処理の設計として明確に定義されていなくてはならない。想定していた母集団から少しずつれたり、異なる特性を備えているデータだったりすると、処理の結果が少しずつれてしまうことがある。ある特定の統計処理手法に、適正ではないデータを当てはめて処理した結果について、それをどの程度信頼したらよいかを表す指標を「頑健性」と呼ぶ。AIでも同様に処理機能に対してデータ特性が適正でない場合を想定しなくてはならず、その場合に処理結果をどの程度信用したらよいかという、頑健性を問題にしなくてはならないし、機械学習の段階で確認されている必要がある。AIシステムとしてテスト結果の評価を行う場合に、この頑健性のチェックがなされていたかどうかの裏付け資料も、監査のポイントとなる。

2) 機械学習データと本番データの識別

AIに処理を学習させるために事前に機械学習を行うわけであるが、この推論エンジン作成のためのデータが本番データと明確に区別されているかどうかも重要なチェックポイントである。機械学習用のデータは、想定されるデータ群のほとんどをカバーしているのでなければ、前項の様な問題が発生することを防止できない。

3) オンライン連続処理の機械学習データの適正

POSのようなデータや工場内における機械の連続稼働データは、デイリー処理で連続的に入力され、連続的に処理されていく。この様なシステムへの適用を考えたAIに機械学習を行う際には、バッチ処理での確認では不適正で、本番データと同様にデータを連続的に投入して処理する環境で学習されたAI推論エンジンでなければ、適正な処理は期待できない。これらの記録も監査上の重要なチェックポイントとなる。

4-6. 個人の技量 (技術・経験) に依存するAIモジュール開発の信頼性

AI処理には種々の手法が存在し、又、現に今ある手元の問題を解決する為に新たな関数が生み出されたりしている等、技術開発が頻繁に起こる非常に流動的な分野である。従って、AI推論エンジンの開発には日々の開発行為と同時に、新たなAI研究に着目して、常に新しい情報を収集する必要がある。個人的な経験と同時に、

情報収集・理解力も問われるので、その開発結果は個人の技術や技量に大きく依存せざるを得ない。監査の視点で見た場合、担当者、特にリーダークラスの開発経験や教育・研修記録を入念にチェックする必要がある。

それと同時に、リーダー以上に開発元のベンダーそのものが、AIシステム開発のために品質基準を制定することにどれくらいエネルギーを注いでいるか、という事も重要なチェックポイントになる。各開発プロジェクトのリーダーが、品質基準を元にプロジェクトの品質チェックポイントを定め、成果物に対して品質基準に基づくレビューがなされ、そのエビデンスが残っていることが品質チェックのポイントとなる。

4-7. AIの品質を保証するためのエビデンスはどれだけ集めたか

AIでも、通常のシステム開発と同様に、まずAIモジュール単体での機能テストを行い、実際に稼働させるシステム上に組み込んで、同様に機能するかどうかの結合テストを行う。

各々の作業フェーズでは、機械学習をさせるデータを読み込ませて学習を行い、その後、本番を想定した実データを当てはめて、想定通りの結果が得られるかどうかの検証を行う。AIの場合、結果の妥当性は想定しているデータ群（母集団）の想定と、実際に集められたデータ（サンプル）に対し、処理を当てはめて生まれる結果が想定と同じかずれが生じているかが判断基準となる。その信頼性は、集められたデータが処理に必要な性質を保有しているかどうかの品質に依存している。

製品として公開・利用してもらおう段階で、想定通りの結果が得られるかどうかは、同様にテスト段階で適用した結果に依存する。AIの特性として、新たな性質を保有したデータが投入された場合、AIが持つ特性値が少しずつ変化していく性質を持っている。この「変化」に対して、どのように対応していくかの定義を開発者側が予め定めてあるかどうかをチェックすることも、監査の視点としては重要となる。

4-8. 設計思想とプロセスの評価方法

「4-3 AI開発のプロセス」に於いて、凡その開発の流れを示した。AI処理結果の信頼性やその範囲については、2つの論点がある。一つは、トライアンドエラー処理に於いてどの様な方法論でどの程度の確認処理を繰り返したかが重要であるが、パッケージとして提供されているモジュールをそのまま利用している場合は内容がブラックボックス化されており、個別にその精度を確認することは開発ベンダーがその内容を公開しない限り困難である、という点である。

もう一つの論点であるが、AI処理に於いて適正な出力であるかどうかは、あらかじめ用意した学習用データと目標値との照合で確認できる（教師有り学習）。し

かし、実際に運用を始めてみて入力データの性質が少しずつ変化し始めると、出力も変化し始める。これが、AIによる深層学習の特性である。

利用者側に立った監査の視点でも、2つの論点がある。1つは、既に論じたとおり、AIシステムを大きなくくりで定義する、「製品コンセプト」の定義がどの様にされているか、という点である。もう一つが、AI処理結果が変化した場合の、サービス提供者としてのベンダー側の利用者に対するフォロー機能である。この点をチェックすることが、監査側にとって重要となる。

AI監査では、上流工程である製品コンセプトをどのように定義し、製品の精度をどのように設定したか、さらにはフォローを前項のチェックポイントと考え方を元に監査すれば、精度の高い監査が期待できる。

参考資料：

データ分析のための機械学習入門（橋本泰一著、SBクリエイティブ(株)）

Deep Learning Javaプログラミング（巢籠悠輔著、(株)インプレス）

Google Cloud Platform（吉川隼人著、(株)リックテレコム）

5. AIの開発を委託される企業が留意すべきリスク

AI 技術¹の基本技術思想は、データから結論を推論する帰納的なものであり、従来型の演繹的なソフトウェアの基本技術思想と根本的に異なっている。AI技術を使ったソフトウェア（以下「AIソフトウェア」という）の開発手法は、従来型のソフトウェア開発手法とは異なる。よって、AIソフトウェアの開発を依頼する者（以下「ユーザ」という。）、およびAIソフトウェアの開発を受ける者（以下「ベンダ」という。）の双方は、この違いを十分認識しておく必要がある。

本章では、AIソフトウェアの開発を請け負うベンダが認識しておくべき基本設計思想の違いによるリスクを、AIソフトウェアが出力する結果の信頼性に焦点を当てて述べる。

5-1. AIの開発におけるリスクとは

総務省は、同省管轄の情報通信政策研究所が主催した有識者会議「AIネットワーク社会推進会議」がまとめた「AI開発ガイドライン案」を公表している。まずは、このガイドライン案を使って、AI開発のリスクを概観する。

このガイドライン案の目的は、AIネットワーク化の健全な進展を通じてAIシステム²の便益の増進とリスクの抑制を図ることにより、利用者の利益を保護するとともにリスクの波及を抑止し、人間中心の智連社会を実現することであり、つぎの9つの開発原則で構成されている。

（主にAIネットワーク化の健全な進展及びAIシステムの便益の増進に関する原則）

① 連携の原則

開発者³は、AIシステムの相互接続性と相互運用性に留意する。

（主にAIシステムのリスクの抑制に関する原則）

② 透明性の原則

開発者は、AIシステムの入出力の検証可能性及び判断結果の説明可能性に留意する。

③ 制御可能性の原則

開発者は、AIシステムの制御可能性に留意する。

④ 安全の原則

¹ 「AI 技術」とは、人間の行い得る知的活動をコンピュータ等に行わせる一連のソフトウェア技術の総称である。

² 「AI システム」とは、AI ソフトを構成要素として含むシステムをいう。

³ 「開発者」とは、AI システムの研究開発（AI システムを利用しながら 行う研究開発を含む。）を行う者（自らが開発した AI システムを用いて AI ネットワークサービスを他者に提供するプロバイダを含む。）をいう。

開発者は、AIシステムがアクチュエータ等を通じて利用者及び第三者の生命・身体・財産に危害を及ぼすことがないように配慮する。

⑤ セキュリティの原則

開発者は、AIシステムのセキュリティに留意する。

⑥ プライバシーの原則

開発者は、AIシステムにより利用者及び第三者のプライバシーが侵害されないよう配慮する。

⑦ 倫理の原則

開発者は、AIシステムの開発において、人間の尊厳と個人の自律を尊重する。

(主に利用者等の受容性の向上に関する原則)

⑧ 利用者支援の原則

開発者は、AIシステムが利用者を支援し、利用者を選択の機会を適切に提供することが可能となるよう配慮する。

⑨ アカウンタビリティの原則

開発者は、利用者を含むステークホルダに対しアカウンタビリティを果たすよう努める。

このガイドライン案は、AI開発に倫理規定が必要との声が世界で強まる中、国際会議の場で「日本発の叩き台」として提案する狙いがあり、複数のAIが連携する「AIのネットワーク化」を前提にしている。そのため、AI自体が制御不能になったり、AI同士が相互連携したりした結果、予期しない問題を引き起こす恐れや、AIシステムが国境を越えて利用され、その影響範囲が国内に留まらない、などのリスクを想定している。そのためビジネスでの活用を考えると些か現実離れしている。凄まじい勢いで進歩を遂げるAIではあるが、今のところビジネスに導入されるAIは、ネットワーク化されたAIではなく単体のAIであろう。その観点から上記9つの原則をみると、AIの開発を委託されるベンダが注目すべき原則は、「② 透明性の原則」および「⑨ アカウンタビリティの原則」であろう。

5-2. なぜAIの開発に「透明性」と「アカウンタビリティ」が求められるのか

AI開発に「透明性」と「アカウンタビリティ」が求められると考える理由は二つある。ひとつは「AIのブラックボックス性」であり、もう一つは「AIの信頼性」である。

5-2-1. AIのブラックボックス性

企業は以前から、金融市場やその他のステークホルダのために、監査済みの

財務諸表を発行することが義務づけられている。これは、社外の人間には社内の経営が「ブラックボックス」に見えるからであり、会計情報がルールを遵守して作成され、そこに不備や虚偽がないかを「監査」する過程を経る必要があるからである。

コンピュータも同様である。コンピュータの仕組みが分からない部外者にとっては、コンピュータがどのようにしてアウトプット(結果)を出したのか分からないため「ブラックボックス」に見える。コンピュータが単なる科学的な研究対象から、企業活動の幅広い分野で利用されるようになり、コンピュータが処理して得られた結果をもとに意思決定を行うようになり、それが正しいことを担保するためにコンピュータを監査する必要がでてきた。

ではAIはどうか。かつてコンピュータがたどった道をAIも辿るのではないかとみている。AIのしくみが分からない人にとっては、コンピュータ同様、AIはブラックボックスである。これまで2度、AIが話題になったことがあるが、いずれも科学的な関心ごとであり、ビジネス分野での利用には至らなかった。しかし、昨今のAIはビジネス分野への利用が現実のものとなり、しかも意思決定に深く関与し始めようとしている。AIが出した結果をもとに意思決定するのであれば、それが正しいことを担保するために、AI開発における透明性とアカウントビリティが求められるのは必然ではないだろうか。

5-2-2. AIの信頼性

「コンピュータは正確だが人間はミスをする」というのはよく知られたコンピュータの特徴である。AIはどうか。AIは正確かというところではない。なぜならAIは「人間の知能を真似した機械」だからである。人間と同じようにAIもミスをする可能性があるのだ。AIをビジネスに活用する際に、この認識は重要なポイントとなる。

コンピュータの特徴を生かせる業務にAIを用いるのは間違った選択である。例えば、入出金明細データから自動仕訳を行うような業務に、仕訳パターンの学習効果があるとか、起票漏れを防止するなどの理由でAIを導入しようとしても、そのような業務はAIよりもコンピュータで処理した方がずっと速くて正確である。AIは判断結果に信頼度が付く。逆に言えば、常に100%の信頼度が得られるとは考えずに利用すべきものである。自動仕訳のような、間違っては困る業務に使うのは、現時点では不適切と言える。逆に、CT画像を見て癌の可能性を発見してくれるように、人間を補佐してくれるものと考えて業務への適用を考えるべきである。

なぜなら、従来のコンピュータが処理するのは構造化されたデータであり、AIが処理するのは非構造化データであるからだ。よってAIが出力する結果の信

頼性に対する透明性とアカウントビリティが求められることは容易に想像できるであろう。コンピュータと同じ考え方でAI開発のリスクアセスメントを行うことはできないのである。

5-3. 基本的なAIのしくみ

AI開発において透明性やアカウントビリティに影響を与えるリスクを評価するためには、AIの基本的な仕組みを理解しておかなければならない。最近注目を浴びている機械学習とは、データから規則性や判断基準を学習し、それに基づき未知のものを予測、判断などを実現する学習方法のひとつである。つまり、機械学習はAIを実現させる手法であり、機械に学習させて人間のような認識、判断を行わせるものである。機械学習では最初に学習データを用いて機械に学習させ（学習段階）、できた学習済みモデルを使って未知のデータを判断・推定する（利用段階）。つまりAIのしくみは、知能を発達させる「学習段階」と発達した知能を利用する「利用段階」で構成されている。

機械学習の学習段階では学習データを使ってトレーニングを行い、上達ぶりをチェックしてパラメータ調整を行うことを繰り返すことによって、“さっきまでは分からなかったけれど、今なら分かるよ”と学習済みモデルが賢くなっていき、これ以上の上達が望めなくなるまで繰り返し学習を行う。

よって、利用段階でAIが出力する結果の信頼性は学習段階に依拠する。ベンダに委託されるAIソフトウェア開発のほとんどは、機械を学習させて学習済みモデルをつくる学習段階であろう。したがって、ベンダにはAIが出力する結果の信頼性について説明責任が生じる。AIの開発を委託されるベンダは、説明責任を果たすために、AIの出力の信頼性に影響をおよぼす学習段階のリスクについて熟知し、それを管理・統制する仕組みをつくり、それを監査する必要があると考える。

5-3-1. AIソフトウェアの開発工程である「学習段階」のながれ

「学習段階」はセンサやカメラ等何らかの方法により収集・蓄積された「生データ」から、最終的成果物としての「学習済みモデル」を生成することを目的とする。その過程は、「学習用データセットの生成段階」と「学習済みモデルの生成段階」の二つに分けることができる。

機械学習の手法により学習を行う場合、生データから学習済みモデルを生成するための第一段階として、学習を行うのに適した学習用データセットを生データから生成する過程を経ることが必要となる。これが「学習用データセットの生成段階」である。

また、第二段階として、学習用データセットの中から一定の規則を見出し、

その規則を表現するモデルを生成するためのアルゴリズムを実行する「学習用プログラム」と、一定の目的のために機械的に調整された「学習済みパラメータ」をプログラムに実装することで、ソフトウェアとしての「学習済みモデル」を得ることができる。これが「学習済みモデルの生成段階」である。

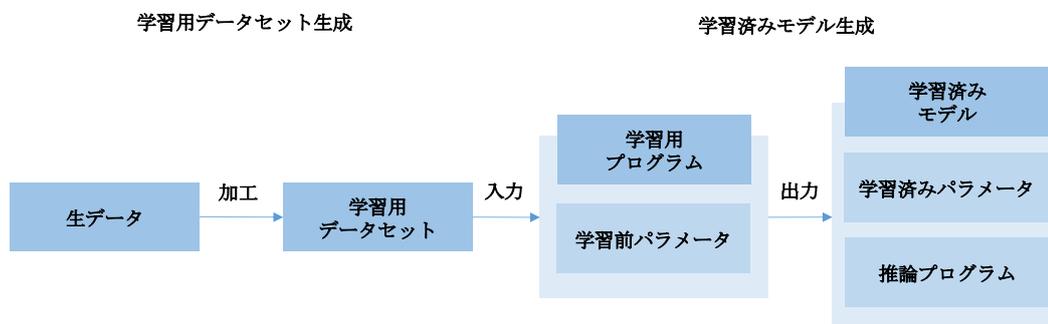


図5-1

5-3-2. 「学習段階」を構成する要素

学習段階は、「生データ」「学習用データセット」「学習用プログラム」「学習済みモデル」で構成される。

「生データ」は、ユーザやベンダ、その他の事業者や研究機関等により一次的に取得されたデータであって、欠測値や外れ値を含む等、そのままでは学習を行うのに適していないものであることが多い。そのため、生データは、生成される学習済みモデルの内容・品質に大きな影響を及ぼす。

「学習用データセット」は、生データに対して、欠測値や外れ値の除去等の前処理や、ラベル情報（正解データ）等の別個のデータの付加等、変換・加工処理を施すことによって、対象とする学習の手法による解析を容易にするために生成された二次的な加工データである。

「学習用プログラム」は、学習用データセットの中から一定の規則を見出し、その規則を表現するモデルを生成するためのアルゴリズムを実行するプログラムである。

アルゴリズムとは、問題を解くための手順を定式化した形で表現したものであり、正しく解を得るための具体的な手順および根拠を与える。コンピュータを使って問題を解くために、コンピュータでアルゴリズムを実装したものがプログラムである。AIのアルゴリズムは、コンピュータ・ソフトウェアを用いて人間の考え方や能力を模擬するために数学的に表現された手順である。

「学習済みモデル」は、「学習済みパラメータ」が組み込まれた「推論プログラム」である。「学習済みパラメータ」は、学習用データセットを学習用プログラムに対して入力することで、一定の目的のために機械的に調整される係数で

あり、「推論プログラム」は、「学習済みパラメータ」を適用することで、入力に対して一定の結果を出力することを可能にするプログラムである。データの中から一定の規則を見出すアルゴリズムと学習パラメータは出力される結果の品質に影響を与える。アルゴリズムが間違っていると正しい結果が得られないのは従来型のプログラムと同じである。与えられたデータからユーザが期待(要求)する結果を得るために最適なアルゴリズムでなければならない。

5-4. 「学習用データセット生成段階」におけるリスク

従来型のソフトウェア開発の場合、その基本的な作業は、一般的に、「入力値の処理手順を一定のルールとして記述し、その記述をコード化する」という演繹的なものである。あらかじめ開発対象物が特定されており、かつ、その動作原理も直感的に把握しやすいことが多い。他方、学習済みモデル生成の場合、学習用データセットという限られたデータのみから未知の様々な状況における法則を推測するという帰納的な性質上、AI 技術に習熟した技術者であっても、推測対象となる未知のあらゆる事象を予測して学習を行うのは極めて困難であるため、学習済みモデルの内容・性能等は学習用データセットによって左右されるのである。

学習済みモデルの生成は、学習用データセットの統計的な性質を利用して行われるという性質上、学習済みモデルの性能は、学習用データセットの品質に依存する。すなわち、学習済みモデルが学習用データセットの統計的性質を反映して生成されることから、学習用プログラムの仕様に問題がないような場合であっても、ユーザの満足のいく性能の学習済みモデルが生成できないという事態も十分に想定される。たとえば、学習用データセットに含まれるデータに本来の統計的性質を反映していないデータ（外れ値）が混入していた場合や、学習用データセットのデータに大きな統計的なバイアスが含まれていた場合等には、精度の高い学習済みモデルを生成することはできないことが多い。また、特定の学習データで何回も学習すると、その特定の学習データにだけ強い学習モデルになってしまい、その他の汎用データに対する信頼性が落ちる、いわゆる過学習（Over Fitting）に陥りやすい。

このように、学習済みモデルの出力結果には本質的に誤差が含まれるのである。それ故、出力結果には論理性が求められる。それがベンダに課せられた課題であり、出力結果の誤差について説明責任がある。

よって、ベンダは学習用データセット生成段階において、透明性を確保できるよう学習用データの選定に対して明確な基準を策定し、データ自体の偏りの評価方法やその許容範囲の決定方法など、学習の偏りに伴うリスクを抑制する仕組みを検討する必要がある。また、それらの基準や仕組みが有効に機能するよう統制し、説明責任が果たせるようエビデンスを残すべきであろう。その場合、監査の観点から、次のようなことに留意する必要があると思われる。

- ① 学習用データの量は十分か。
学習済みモデルの精度を十分に確保できる量の生データが必要である。
- ② 学習用データに偏りが無いか。
特定の学習データで何回も訓練を行うとその特定の学習データにだけ強い学習モデルになってしまいその他の汎用データに対する信頼性が落ちる。
- ③ 人間でも判定に困るデータが混入していないか。
たとえば、人間でも判定できないような画像はAIでもうまく特徴点を見つけれない。そのようなデータで学習させると悪い影響を与える。
- ④ AIを導入する目的にあっていないデータが混入していないか。
例えば、顔認証させているつもりなのに、AIは背景にある時計を対象にするようなことは起こりうる。目的に合った対象を検出しているかチェックする必要がある。
- ⑤ 間違ったラベル付けをしていないか。
教師あり機械学習では、教師データとしてラベル情報をデータに付加する。間違ったことを教えれば当然AIは間違っただけで学習する。データにラベルを付けるのは人間である。誤ったラベルを付けるミスは起こりうる。
- ⑥ 間違われやすいデータも学習させているか。
AやBがよくXに間違われるという場合、AやBの学習よりもXを正しく学習させる方が効果的な場合は、AやBのデータだけでなくXの学習データも十分確保する必要がある。

5-5. 「学習済みモデル生成段階」におけるリスク

学習済みモデル生成段階におけるリスクを考えるには学習の手法に関する知識が必要になる。学習の手法によって結果の信頼性に影響を与えるリスクが異なるからである。機械学習とは、あるデータの中から一定の規則を発見し、その規則に基づいて未知のデータに対する推測・予測等を実現する学習手法の一つである。機械学習は、真実のデータや人間による判別から得られた正解に相当する「教師データ」の与えられ方によって「教師あり学習」「教師なし学習」「強化学習」の3つに分類することができる。

教師あり学習は「入力と出力の関係」を学習する。そのため、正しい答えである「教師データ」が与えられる。教師なし学習は「データの構造」を学習するため「教師データ」は与えられない。強化学習は試行錯誤を通じて「価値を最大化するような行動」を学習する。そのため正しい答え自体は与えられないが、報酬（評価）が与えられる。

また、分析手法の観点では、「教師あり学習」と「教師なし学習」は統計学に基づいた「統計的機械学習」が一般的であり、「教師あり学習」では回帰分析や決定

木、「教師なし学習」ではk平均法やアソシエーション分析などがもちいられる。

「強化学習」は概ね統計学とは無関係であり、コンピュータサイエンス分野におけるアルゴリズムのひとつである動的計画法やモンテカルロ法などがもちいられる。

これに加えて、より基礎的で広範囲な機械学習の手法であるニューラルネットワークという分析手法を拡張し、高精度の分析を可能にした「深層学習」がある。「深層学習」は機械学習に包含される。

機械学習の選択は、AIを用いる目的によって選択され、目的と用意できる学習データ量に応じて、機械学習に最適なアルゴリズムが選択される。

AI開発では、その性質上、中身がブラックボックスとなってしまうことがあることは述べた。そのため、AIの判断が「何故その判断に至ったのか」を検証したり、説明したりすることが難しくなる。特にディープラーニングにおいては、判断結果の説明が困難となる。判断にどのようなデータやアルゴリズムを使ったかなどの情報開示を可能とし、AIの開発が論理的に行われていることを説明できるようにしておくことが求められる。また、万が一問題が発生した場合には、原因究明・再発防止策が求められることになるため、AIの判断の検証可能性を確保できるように、記録・保管する対象データやログの範囲を十分に検討し、それを管理する仕組みも構築する必要がある。その場合、監査の観点から、次のようなことに留意する必要があると思われる。

- ① 機械学習とアルゴリズムは、開発を依頼されたAIの利用目的に合っているか。
AIの利用目的によって機械学習とアルゴリズムは異なる。
- ② 「学習用データセット」は保存されているか。
AIの判断結果の妥当性を検証するためには、機械学習で使用した「学習用データセット」が必要になる。
- ③ 機械学習の過程は記録され保存されているか。
AIの判断結果の妥当性を検証するためには、機械学習が適切かつ十分に行われたことを明らかにする必要がある。

5-6. 従来型のソフトウェア開発との違いによるリスク

AIソフトウェアの開発は、従来型のソフトウェア開発とは異なり、開発当初に明確な要件定義を行うことが難しく、また事後的な検証も困難である。そのため、その開発過程は必然的に試行錯誤を何度も重ねる必要がある。このような状況では、後戻りが不可避免的に発生することから、ウォーターフォール型の開発は必ずしも実態にそぐわない場合が多く、アジャイル開発などの非ウォーターフォール型の開発が適している。非ウォーターフォール型の開発においては、常に結果（成果物）が導入意図に沿うものか、効果が期待できるものか等の評価を繰り返しながら開発することとなる。よって、この繰り返し行われる評価の質もAIの出力結果の信頼性に影

響を与える。特に、ウォーターフォール型の開発を得意としてきたベンダは、このことに留意してAIソフトウェア開発を行う必要がある。

参考資料：

国際的な議論のためのAI開発ガイドライン案（AIネットワーク社会推進会議）

AI・データの利用に関する契約ガイドライン - AI 編 - （経済産業省）

ICTスキル総合習得教材 - データ分析 - （総務省）

6. ITCによるAIの信頼性へのアプローチ

本章では、中小企業がAIを活用するための信頼性の視点について考えてみたい。

なぜ、いきなりAI導入の作業に取り掛かれないのか。それは、既に説明してきた通り、AIが従来のアプリケーションとは異なる特徴を持ち、異なる長所を持ち、異なる短所を持っているからである。

従って、まずITC自身がAI処理というものを理解し、その後、導入を希望する顧客企業に「AI処理とはどういうものなのか」を理解した上で、導入作業に入らなくてはならない。

6-1. まずITC自身がAIを業務に適用するとはどういうことなのかをよく考えてみる

最先端ともいうべきAIは深層学習（ディープラーニング）を使用したものであるが、以下の様な特徴を持っているのでまずその事を理解することが大切である。

1) 処理機能

- ①人間の認識力では到達できないような、量・速さの処理が出来る。
(画像処理、音声認識、翻訳、文書分類などには目をみはる処理が可能)
- ②人間の判断よりも速く、間違いが少ない。(見落としが無いのは強み)
- ③自分に無い知識や判断でも、学習済みAIを使えば他人の知識や判断をそのまま利用できる。
- ④様々なアプリと連携すると、使い方のバリエーションが増える。
- ⑤機能の付加や処理のバリエーションはアイデア次第で広がってくる。

2) 開発過程

- ①処理機能が学習したデータに依存している
(入力されていない範疇のデータ入力では処理できない)
- ②活性化関数と損失関数のチューニングが適切でないと、動作が安定しない。
(開発者の経験が浅いと難しい)
- ③AI処理の精度を良くしようと思ったらニューラルネットワークの階層を増やす必要があるが、階層を増やすと別のトラブルに見舞われやすいので、開発者がそのことを理解している必要がある。
- ④アプリの作り方にもよるが、誤動作をしても停止せずに何とか動く様に設計されていないといけない。
(開発者の経験が浅いと難しい)

3) 利用環境

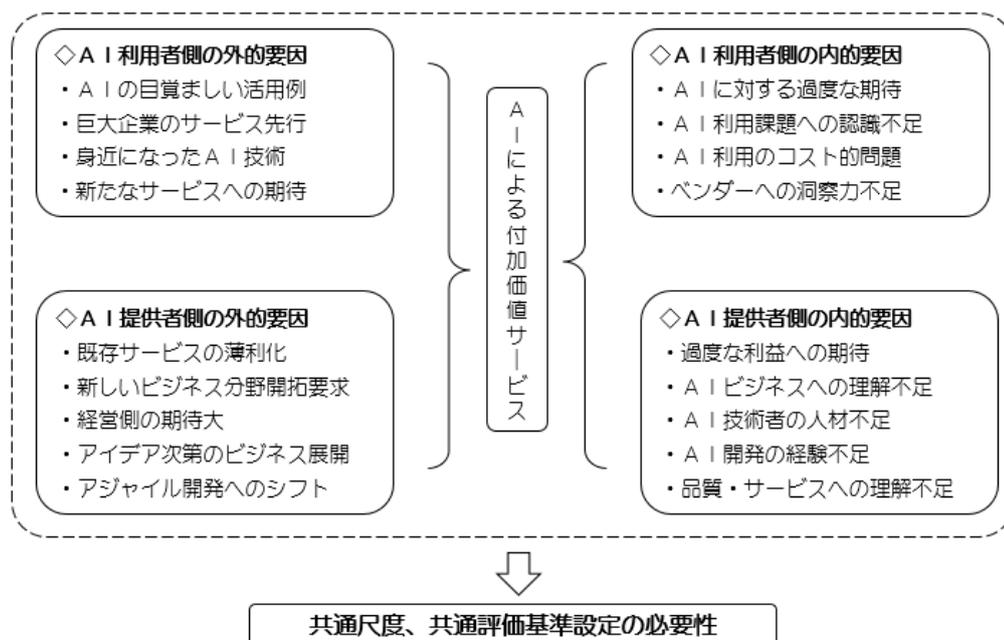
- ①AI処理はPCのCPUリソースを大量に消費するので、それなりの投資が必要になる、若しくはクラウド上での利用になる。
(CPUでは処理できなくて、複数のGPUが必要になる)

4) 提供ベンダー

- ① サービスを提供する会社が小規模だったり、経験不足だったりすると、処理結果が思わしくなくなる可能性がある。

6-2. 顧客にAIとは何なのかをよく理解してもらう

6.1で理解した事柄を顧客に伝え、過度な期待を持たないように説明しておく必要がある。【図6-1 AIプロダクト品質保証ガイドライン作成の背景：意識】



6-3. 利用者側が何の目的で使うかを明確にする

通常のシステム導入と同様に、導入目的と適用範囲の明文化を行う。

現行の課題を抽出した上でAIの導入目的と適用範囲を導き出す。

その際、ITCプロセスガイドラインを念頭に、IT戦略や経営戦略を参照することを忘れないことが大切である。

6-4. AIを利用するとはどういうことなのかを理解してもらう

通常の業務分析と要件定義と同様に、AI処理の定義を行う。

導入目的によって選定するパッケージ、形態（オンプレミス/クラウド）および体制（社内、委託先など）が異なってきますので、導入目的を明文化してプロジェクトオーナー及び主要メンバーに周知することが重要となる。

また、レスポンスや操作性、保守性、移行性などの非機能要件も忘れずに検討

しておく必要がある、

6-5. 利用者の業務環境を確認し、適用性を判断する

通常のシステム導入分析と同様に、利用者の業務環境の確認を行う。

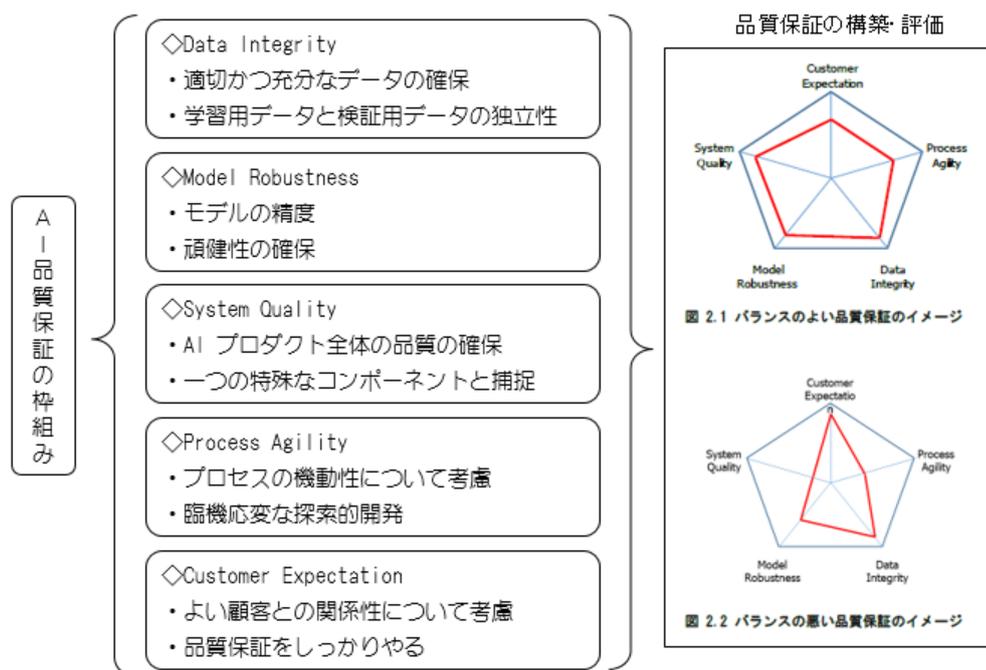
業務環境に合わせたシステムを納期どおりにリリースできても導入が成功したと言えない。あらかじめ決められたKPIが目標値以上になってKGIを達成できることをモニタリングする仕組みが必要である。

6-6. 市販の汎用性AIを利用する場合

市販の汎用性AIシステムを利用する場合の注意点を列挙する。

- ①機能や長所・短所をよく確認する。
- ②AI利用環境や利用制限事項を確認する。
- ③適用できるデータの種類を確認する。
- ④機械学習を適用して、処理結果と期待値を比較し、評価する。
- ⑤本論文や「AIプロダクト品質保証ガイドライン」の5つの評価を適用する。

【図6-2 AIプロダクト品質保証ガイドライン 品質保証の枠組み】



- ⑥AI機能のみならず、採用の是非を判断する。

6-7. 社内システム内にAI処理機能を組み込んで利用する場合

既存の社内システムにAI処理システム組み込んで利用する場合の注意点を列挙する。

- ①AI処理を行う目的を明確にする。
- ②AI処理を行う業務の要件定義をする。
- ③利用するAIの機能の要件定義をする。
- ④AIのプロトタイプを作成してみる。
- ⑤AIに機械学習をしてみる。
- ⑥本番環境の模擬システムでテスト運用をしてみる。
- ⑦本論文や「AIプロダクト品質保証ガイドライン」の5つの評価を適用する。
- ⑧AI機能のみならず、採用の是非を判断する。

6-8. 契約による現段階での信頼性担保

ここで言うAIは、5章で述べられた「AIシステム」(AIソフトを構成要素として含むシステム)と定義して話を進めてみたい。尚ここでは 信頼性(信頼性性能)を「アイテムが与えられた条件の下で、与えられた期間、要求された機能を遂行できる能力」と定義しておく。

AIシステムもソフトウェアとして考えると、

- ① 信頼性を計る指標
 - ② 信頼性を確保する仕組み
- が信頼性を担保する仕組みと考えられる

① 信頼性を計る指標を定義する

ソフトウェアの信頼性を測るための指標としては、

1) MTBF (平均故障時間: Mean Time Between Failure)

ハードウェアだけでなくソフトウェアの場合も、正常な状態でどのくらいの時間稼働できるかという数値なので、この数値が大きければ大きいほどそのソフトウェアは信頼性が高いと思われる。

2) MTTR (平均修理時間: Mean Time To Repair)

MTBFの時と同様にソフトウェアに障害が発生してから修復が完了するまでの時間の平均値です。従って、この数値が小さければ小さいほど、短い時間で障害が復旧できる。

3) システム稼働率 ($MTBF \div (MTBF + MTTR)$)

MTBFとMTTRから求められる、ソフトウェアの実際の稼働率です。

② 信頼性を確保する仕組みを整える

設計書や仕様書を作成する段階からチェックし、外部から調達した ものも対象にする。また、形式や手法に合わせた検査・検証ツールを用いてプログラムの動作を検査・検証することも重要。ソフトウェアの信頼性を確保するには、ソフトウェアテストの存在が必須になることになると思わ

れる。

但し、現状ではAIシステムについては、ユーザだけでなく、開発者にも「ブラックボックス」に見える為、いわゆる「システム監査」的なものが整備されていない

ここ数年の現実的な対応としては、AIシステムの開発契約・利用契約を

- ・知的財産権等
- ・権利貴族・利用条件の設定
- ・債務不履行の有無
- ・帰責性・因果関係の有無
- ・優越的地位の濫用（下請法）
- ・排他条件付取引・拘束条件付取引（独禁法）

といった様な点に注意しながら契約で種々のリスクをヘッジするのがITCとして現実的な信頼性を担保する手段と思われる。

特にデータの学習や学習済データの扱いには留意する必要がある。

今後の対応として、サイバー保険の様に当初は全く対応していなかったが、数年たつとあたりまえの様に広告を見かける様になるであろう“AIに対応した保険”の活用も併せて検討しておくが良い。

6-9. 第三者による信頼性担保

IPAが2015年に公開した製品・システムにおけるソフトウェアの信頼性・安全性等に関する品質説明力強化のための制度構築ガイドライン（通称：「ソフトウェア品質説明のための制度ガイドライン」）から、AIに沿った制度が出てくることを今後期待したい。

社会全体を支えるITに対して利用者が安全・安心に使えるようにする為、利用者視点に立ったソフトウェア信頼性の見える化を促進しています。

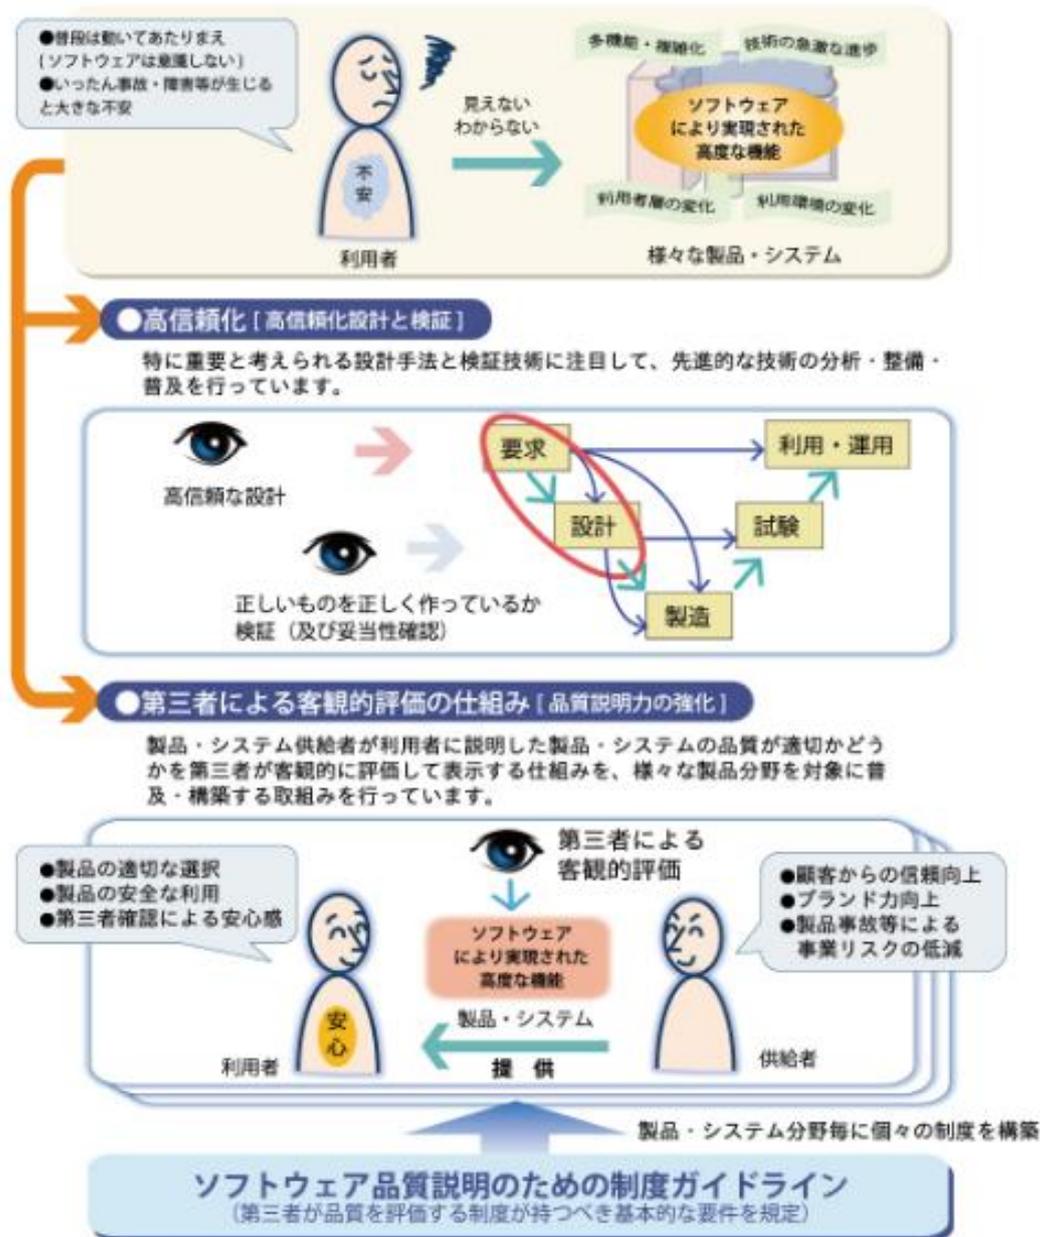
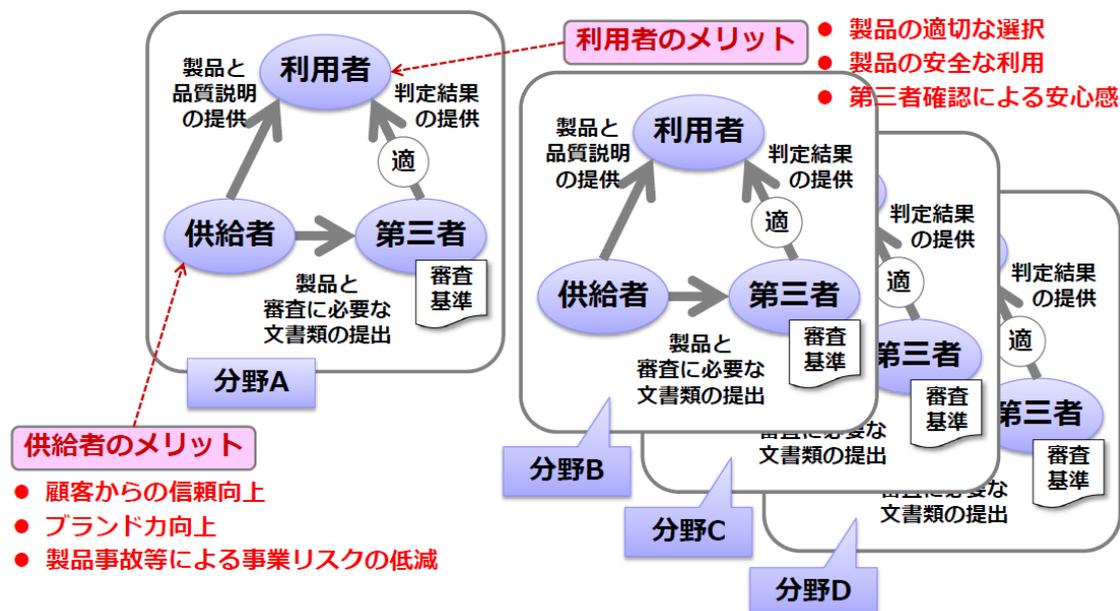


図6-1：ソフトウェア信頼性の見える化
<https://www.ipa.go.jp/sec/software/index.html>

AIがいつでも安心して利用できるためには、それらが人や財産に被害を与えずに動作するための「安全性」や、要求された機能や動作を安定して実行するための「信頼性」、また、外部からの侵入・改ざんや情報漏えいを起こさないための「セキュリティ」などの要素がしっかりと確保されている必要がある。

製品・システムの分野毎に制度ガイドラインに基づく枠組みが構築される



制度ガイドラインが想定する制度の枠組み

このような、利用者が安心して製品やシステムを利用し続けるために必要な要素を総合して『ディペンダビリティ (Dependability)』と呼び、さまざまなモノ同士がつながるIoT時代の製品やシステムにおいては、このディペンダビリティの確保が重要な課題となっている。

一般団法人 ディペンダビリティ技術推進協会（以下、DEOS協会）より、本ガイドラインに準拠して構築された制度として、ディペンダビリティ技術の認証制度である「DEOS認証制度」の運用が開始されている。

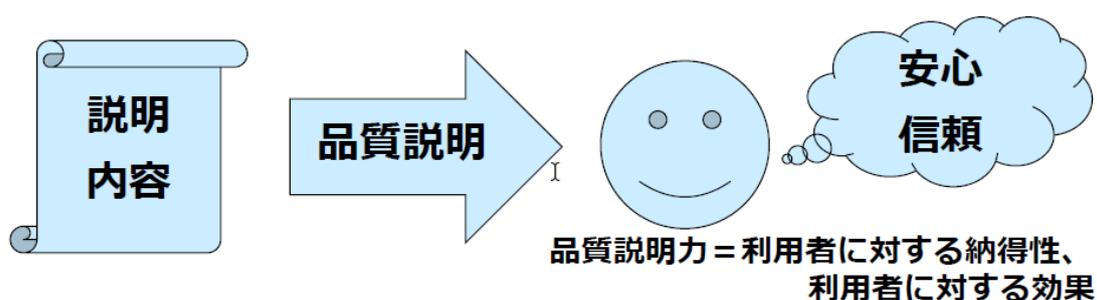
今後DEOS協会やその他の団体でAIの信頼性の担保が可能になると思われるので 早くITCがこの様な制度を活用できることを強く希望する。

参考資料：

- AI・データの利用に関する契約ガイドライン - AI 編 - (経済産業省)
- AIプロダクト品質保証ガイドライン (QA4AI コンソーシアム編)
- ソフトウェア品質説明のための制度ガイドライン (IPA)

[参考] なぜ第三者による客観的な評価の裏付けが必要なのか

- ・グローバル市場においては当事者企業の主張だけでは不十分で、第三者による客観的な評価の裏付けが必要である。
- ・IT融合システムの市場の拡大には利用者の理解と安心感が不可欠であり、利用者に対する品質説明が重要である。
- ・利用者自らが、製品・サービスやシステムを選択し、組み合わせて使用する時代。しかし、技術的に詳細な説明は利用者には困難第三者が品質を客観的に確認して利用者にはわかりやすく示す仕組みが求められている。



ソフトウェア品質説明（力の強化）

ソフトウェアが重要な役割を果たす製品・システムにおいて以下の事項を根拠や事実に基づいて説明すること。

- ・想定する利用者、利用目的、利用状況、制約事項
- ・利用する上で必要なソフトウェアの品質とその目標
- ・品質目標を達成するための設計・実装・運用および保守
- ・品質目標を達成したことの検証・監査

技術的側面：供給者が製品・システムを開発・運用する過程において、要求される品質を確保するための開発・運用技術ex. モデルベース開発、形式手法、トレーサビリティ、検証技術など。

管理的側面；製品・システムのライフサイクル全般にわたる組織的な品質マネジメント

制度的側面：供給者による品質説明の適切性を第三者が確認し、利用者提供する仕組み（制度）の構築公正かつ専門的な観点での評価により利用者の安心感を醸成

<注意>ソフトウェアに関する説明を行えば、その製品・システムの品質の説明になるということを意図するものではない

7. おわりに

AIは、飛躍的な進化を続け、非常に幅広い領域で利用されるようになり、今後はビジネスに欠かせない経営資源の1つになると考えられる。

中堅中小企業においてもAIの導入が進み、積極的な検討、試行、導入が行われており、AIの機能の高度化に合わせて、ビジネスモデル全体に適用され始めている。

これまで述べてきたように、進化し続けるAIについては、可監査性と追跡可能性を困難にする恐れがあり、この進化の速度は非常に短い時間内に、大規模なエラーを発生させる可能性が潜在する。

依って、適用する領域や機能、特性に合わせたリスクを抽出・評価し、リスク対応を行う必要があることになる。

つまりAI活用で効果を上げるためには、リスクをコントロールすることが重要であり、ビジネス貢献には、リスクマネジメントの巧拙が左右するとも言えるわけである。

前章までに、AIを利用した業務処理の正確性を担保するに必要な事柄を、監査と言う視点において述べさせて頂いた。

この視点において、ITコーディネータとしてユーザ支援を行う上で、AIを適用する領域や機能、特性により、信頼性を損なう事象の影響度や発生可能性を見極め、対応策を検討、実施することを十分に理解し、今後も継続したテクノロジーの進化と新サービスへの適用に対応した管理を浸透させることが、重要な役割となるであろう。

最後に、本論文が読者諸兄の役に立てれば幸いである。

以上

別紙 I

ITC 自身の AI に対する理解のポイントと同時に、顧客への説明ポイント

| 深層学習（ディープラーニング）を使用した AI 利用上の注意点 |
|---|
| <p>1) 利用メリット・デメリット</p> <ul style="list-style-type: none">✓ 人間の認識力では到達できないような、量・速さの処理が出来る。✓ 人間の判断よりも速く、間違いが少ない。✓ 特に、画像処理と言語処理は新しい技術を生み出し続ける。✓ 自分に無い知識や判断でも、学習済みAIを使えば他人の知識や判断をそのまま利用できるの、処理の幅が広がる（初心者や障害者にとってメリットが大きい）。✓ 様々なアプリと連携すると、使い方のバリエーションが増える。✓ 機能の付加や処理のバリエーションはアイデア次第で広がってくる。✓ ニューラスネットワークの処理層がブラックボックスになっているので、処理結果の理由付けが困難になる（エビデンスの必要な処理には、別に検証行為が必要になる）。✓ AIを何でもできるものと勘違いする人がいる。現実のAIは単機能のものを組み合わせていろいろなことが出来る様に見せているだけである。従って、類似製品でも、想定する利用方法で使える製品と使えない製品があることを理解しなければならない。✓ AIを処理から見ると、実は単純作業を気が遠くなるほど反復処理をしているだけなので、CPU、いやGPU機能を大量に消費するものである。有名なアルファ碁はサーバーを1000台余り使用していたことを連想すれば、今のAIの特徴がお分かりいただけるはず。✓ 気が利くAIは様々な機能を組み合わせているので意外と高価である。癒しロボットではCPUを20個ほど使っているが、CPU1個1万円としても、20個だとCPUだけで20万円、システム全体で50万円前後になってしまう。 |
| <p>2) 開発過程</p> <ul style="list-style-type: none">✓ 処理機能が学習したデータに依存している。 (学習されていない範疇のデータ入力では、処理結果に保証ができない)✓ 活性化関数と損失関数のチューニングが適切でないと、動作が安定しない。✓ 開発はトライアンドエラーの連続で、結構コストや労力がかかる。✓ 開発者に統計学や解析学の知識が必要になり、誰でもできる訳ではない。✓ AI処理の精度を良くしようと思ったらニューラルネットワークの階層を増やす必要があるが、階層を増やすと別のトラブルに見舞われやすいので、泥沼にハマらないためには、開発者がそのことを理解している必要がある。 |

- ✓アプリの作り方にもよるが、誤動作をしても停止せずに何とか動く様に設計されていなくてはならない。(特に自動運転や工場の生産システムなど)
- ✓学習の程度をどの程度にすればいいのかの基準があるわけではないので、学習が足りなかったり過学習になってりするので、開発者自身が明確な基準や経験を持ち合わせていないと難しい。
- ✓学習済みAIは、必ずフィールドで実データを使った確認が必要になる。(中国は広東省などで大規模な社会実験を行って、データの蓄積を図っている、AIの最先端国家である)。

3) 利用環境

- ✓AI処理はPCのCPUリソースを大量に消費するので、それなりの投資が必要になる、若しくはクラウド上での利用になる(今のAIはムーアの法則に依存したもので、多数のGPUが必要になる)。

4) サービス提供者

- ✓サービスを提供する会社が経験不足だったりすると、処理結果が思わしくなくなる可能性がある。
- ✓AIの動作が思わしくない場合、最後はサポート力が勝負になるが、企業体力や組織の整備力がものを言う。
- ✓サービス提供者が著作権に抵触する製品を提供した場合、利用に影響が出る可能性がある。

5) もっと大きな根本的な問題

- ✓AIに使われている中心的モジュールの多くは、ソフトビッグ企業によって開発されている(その代表が、Googleが開発したTensorFlow)。他の企業では、もはや高機能モジュール開発は困難であると言われている。ソフトビッグ企業による支配が潜在的に拭い去れない。

別紙Ⅱ

A I 監査のチェックリスト (例示)

| | |
|--------------|---|
| 1. 企業概要 | |
| 1.1 事業ポリシー | ✓事業ポリシーは制定されているか |
| 1.2 企業規模 | ✓事業継続上の企業規模は十分か |
| 1.3 事業分野 | ✓事業分野継続上のリソースは有るか |
| 1.4 事業継続性 | ✓事業継続の十分なプランがあるか |
| 1.5 シェア | ✓事業継続のためのシェアはあるか ✓シェア拡大の可能性は有るか |
| 1.6 コンプライアンス | ✓コンプライアンス基準は制定されているか ✓コンプライアンスの教育は実施されているか |
| 1.7 企業情報公開 | ✓企業情報を確認する方法はあるか |
| 2. 業務統制 | |
| 2.1 組織 | ✓組織を確認する書類は制定されているか |
| 2.2 責任体制 | ✓責任体制は明確になっているか |
| 2.3 法令順守 | ✓法令を遵守する体制は取られているか |
| 2.4 要員規模 | ✓事業に必要な要因は確保されているか |
| 2.5 品質管理体制 | ✓品質管理体制は確立されているか ✓品質管理のための基準書は制定されているか ✓品質管理のための教育は実施されているか |
| 2.6 情報収集力 | ✓情報収集手段は情報の質は十分確保されているか |
| 2.7 マネジメント能力 | ✓管理者は必要な能力を身に付けているか ✓管理者の業務経歴は記録されているか |
| 2.8 教育訓練体制 | ✓教育訓練体制は整えられているか |
| 2.9 監査体制 | ✓業務監査・機能監査の技術と体制は確保されているか |

| | |
|-------------|--------------------------------------|
| 3. 製品化の根拠 | |
| 3.1 商品化の狙い | ✓商品の市場性・ターゲット顧客・自社のポジションなどが明確になっているか |
| 3.2 事業性の判断 | ✓事業性について、十分な検討が行われているか |
| 3.3 業務知識の獲得 | ✓商品化・事業展開に必要な業務知識は確保されているか |
| 3.4 法規制の知識 | ✓事業分野に対する法規制は調査されているか |
| 3.5 業界慣習の知識 | ✓製品化する上での業界慣習は調査されているか |
| 3.6 ターゲット顧客 | ✓ターゲットになる顧客は明確になっているか |

| | |
|----------------------|--|
| 4. システム開発プロセス | |
| 4.1 システム開発プロセス | <ul style="list-style-type: none"> ✓システム開発プロセスは明確になっているか ✓AI 処理の目的は明確になっているか ✓AI 機能が利用される市場性は調査されているか ✓市場のターゲティングは明確になっているか ✓製品化計画のドキュメントは明確に定義されているか ✓リーダーの経歴はAI 開発で十分な経験を持っているか ✓開発組織は、遂行に必要な経験やリソースの割り当てが行われているか ✓開発メンバーの教育・研修の記録は明確になっているか ✓要件定義は、AI にとって必要な項目が盛り込まれているか ✓AI 機能の定義が明確になっているか ✓機能は、AI 業務機能を生かすように漏れなく定義されているか ✓機能を実現するデータの種類や量は明確に定義されているか ✓機能が満たされない場合の動作について、明確に定義されているか ✓AI 処理がバッチ処理と連続処理の違いが明確に定義されているか ✓機能の限界が明確に定義され、範疇を越えた場合の動作が明確化されている ✓使用されているスクリプトは明確になっているか ✓スクリプトの動作が生かされるような記述がなされているか ✓対象となるデータは明確になっているか ✓機能検証に必要なデータは網羅的に集められているか |
| 1) AI の企画 | |
| 2) 市場性調査 | |
| 3) 製品化計画 | |
| 4) 開発チームは明確に定義されているか | |
| 5) 要求仕様定義 | |
| 6) 機能設計 | |
| 7) スクリプト作成 | |
| 8) ビッグデータ入手 | |

| | |
|--------------|--|
| | <ul style="list-style-type: none"> ✓機能検証に必要なデータ量は確保されているか ✓入手したデータの信頼性や著作権等の問題は調整済みであるか |
| 9) 深層学習 | <ul style="list-style-type: none"> ✓深層学習が実行可能なリソースは十分確保されているか |
| 10) システムへの組込 | <ul style="list-style-type: none"> ✓深層学習を行う階層などは十分考慮されているか ✓テスト結果を本番環境で実行できる条件は十分検討されているか |
| 11) 機能検証 | <ul style="list-style-type: none"> ✓システムとのデータ受け渡しや整合性は十分検討されているか ✓問題が発生した場合の対処法は検討されているか |
| 12) 品質チェック | <ul style="list-style-type: none"> ✓テスト環境は十分な機能が確保されているか ✓テストケースは十分網羅されているか ✓テストに必要なデータ量・データ範囲は十分確保されているか ✓テスト環境は本番環境と明確に分離されているか ✓テスト用のデータと本番用のデータは明確に区別されているか |
| 13) 製品チェック | <ul style="list-style-type: none"> ✓AI 機能を確認する品質基準は確保されているか ✓チェックするメンバーの教育研修は十分確保されているか ✓製品が設計と相違ないかどうかを判定する基準は明確になっているか ✓納品された製品が契約通りであるかどうかをチェックする基準は明確になっているか |

| | |
|---------------|--------------------------------------|
| 5. 支援機能 | |
| 5.1 セキュリティ管理 | ✓管理基準にのっとったセキュリティ体制・基準・教育訓練は整えられているか |
| 5.2 下請け管理 | ✓下請け管理の基準・体制は有るか |
| 5.3 コミュニケーション | ✓コミュニケーション体制は取られているか |
| 5.4 記録管理 | ✓業務推進上の記録を取る基準・体制はあるか |
| 5.5 情報管理 | ✓情報管理の基準・体制は有るか |
| 5.6 製品バージョン管理 | ✓製品のバージョン管理をする技術・体制は有るか |

| | |
|------------|-------------------------|
| 6. 顧客管理 | |
| 6.1 顧客との契約 | ✓顧客と締結すべき契約内容が明確になっているか |
| 6.2 サービス体制 | ✓顧客に対するサービス体制は確立されているか |
| 6.3 サポート力 | ✓サポートする技術・要員は有るか |
| 6.4 情報管理 | ✓情報管理機能は有るか |
| 6.5 クレーム対応 | ✓クレームに対するサポート体制は有るか |

6 項目の企業評価をスコアリングし、レーダーチャートにグラフ化してみる

