

AI 事業者ガイドライン案

総務省

経済産業省

内容

はじめに.....	2
第 1 部 AI とは	8
第 2 部 AI により目指すべき社会と各主体が取り組む事項	10
A. 基本理念	10
B. 原則	11
C. 共通の指針	12
D. 高度な AI システムに係る事業者に関する共通の指針	22
E. AI ガバナンスの構築	24
第 3 部 AI 開発者に関する事項	26
第 4 部 AI 提供者に関する事項	31
第 5 部 AI 利用者に関する事項	34

はじめに

AI 関連技術は日々発展をみせ、AI の利用機会と様々な可能性は拡大の一途をたどり、産業におけるイノベーション創出や社会課題の解決に向けても活用されている。また近年台頭してきた対話型の生成 AI によって「AI の民主化」が起こり、多くの人が「対話」によって AI を様々な用途へ容易に活用できるようになった。これにより、企業ではビジネスプロセスに AI を組み込むだけでなく、AI が創出する価値を踏まえてビジネスモデル自体を再構築することも取り組まれている。また、個人においても自らの知識を AI に反映させ、自身のプロダクティビティを拡大させる取り組みが加速している。我が国では、従来から Society 5.0 として、サイバー空間とフィジカル空間を高度に融合させたシステム（CPS：サイバー・フィジカルシステム）による経済発展と社会的課題の解決を両立する人間中心の社会というコンセプトを掲げてきた。コンセプトを実現するにあたり、AI の利活用を進めていく上で誤った使い方をさせないことを目的とし 2019 年 3 月に「人間中心の AI 社会原則」が策定された。一方で、AI 技術の利用範囲やそれらの分野での利用者の拡大に伴い、リスクも増大している。特に生成 AI に関して、知的財産権の侵害や偽情報、誤情報の生成・発信等、これまでの AI ではなかったような新たな社会的リスクが生じており、AI がもたらす社会的リスクの多様化・増大が進んでいる。

そのような背景の中、本ガイドラインは、AI の安全安心な活用が促進されるよう、我が国における AI ガバナンスの統一的な指針を示す。これにより、様々な事業活動において AI を活用する者が、国際的な動向及びステークホルダーの懸念を踏まえた AI のリスクを正しく認識し、必要となる対策をライフサイクル全体で自主的に実行できるように後押しし、互いに関係者と連携しながら実践することを通してイノベーションの促進とライフサイクルにわたるリスクの緩和を両立する枠組みを積極的に共創していくことを目指す。

我が国は 2016 年 4 月の G7 香川・高松情報通信大臣会合における AI 開発原則に向けた提案を先駆けとし、G7・G20 や OECD 等の国際機関での議論をリードし、多くの貢献をしてきた。一方、AI に関する原則の具体的な実践を進めていくにあたっては、

- 少子高齢化に伴う労働力の低下等の社会課題の解決手段として、AI の活用が期待されていること
- 法律の整備・施行が AI の技術発展やその社会実装のスピード・複雑さに追いついていないこと
- 細かな行為義務を規定するルールベースの規制を行うと、イノベーションを阻害する可能性があること

等が指摘されてきた。これらを踏まえ、AI がもたらす社会的リスクの低減を図るとともに、AI のイノベーションと活用を促進していくために、関係事業者による自主的な取組を促し、非拘束的なソフトローによって目的達成に導くゴールベースの考え方で、ガイドラインを作成することとしたものである。

このような認識のもと、これまでに総務省主導で「国際的な議論のための AI 開発ガイドライン案」、「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～」、経済産業省主導で「AI 原則実践のためのガバナンス・ガイドライン Ver. 1.1」を策定・公表してきた。そして、このたび 3 つのガイドラインを参考にしながら、この数年でさらに発展した AI 技術の特徴及び国内外における AI の社会実装に係る議論を反映して、日本の事業者が AI の社会実装及びガバナンスを共に実践するための新たなガイドラインとして策定した（「図 1. 本ガイドラインの位置づけ」参照）。従来のガイドラインに代わり、本ガイドラインを参照することで、AI を活用する事業者（政府・自治体等の公的機関を含む）が安全安心な AI の活用のための望ましい行動につながる指針

（Guiding Principles）を確認できるものとしている。また、本ガイドラインは、政府が単独で主導するのではなく、教育・研究機関、一般消費者を含む市民社会、民間企業等で構成されるマルチステークホルダーとして検討を重ねることで、実効性・正当性を重視したものとして策定されている。




図 1. 本ガイドラインの位置づけ

AIの利用は、その分野とその利用形態によっては、社会に対して大きなリスクを生じさせ、そのリスクに伴う社会的な軋轢により、AIの利活用自体が阻害される可能性がある。一方で、過度な対策を講じることは、同様にAI活用自体、もしくはAI活用によって得られる便益を阻害してしまう可能性がある。このような中、予め事前に当該利用分野における利用形態に伴って生じ得るリスクの大きさ（危害の大きさとその蓋然性）を把握したうえで、その対策の程度をリスクの大きさに対応させる「リスクベースアプローチ」が重要となる。本ガイドラインでは、この「リスクベースアプローチ」に基づいて、企業における対策の方向を記載している。なお、この「リスクベースアプローチ」の考え方は、AI先進国間で広く共有されているものである。

また、AIをめぐる動向が目まぐるしく変化する中、本ガイドラインに関しては、AIガバナンスの継続的な改善に向け、アジャイル・ガバナンスの思想を参考にしながら、マルチステークホルダーの関与の下で、Living Documentとして適宜、更新を行うことを予定している（「図 2. 本ガイドラインの基本的な考え方」参照）。その更新を行うための具体的な体制については、今後検討していくこととする。




図 2. 本ガイドラインの基本的な考え方

本ガイドラインは、AI 開発・提供・利用にあたって必要な取組についての基本的な考え方を示すものである。よって、実際の AI 開発・提供・利用において、本ガイドラインを参考の一つとしながら、AI 活用に取り組む全ての事業者が自主的に具体的な取組を推進することが重要となる。同時に、AI 活用に取り組む全ての事業者は、AI が社会にもたらす影響の大きさ、人間社会をよりよいものへと発展させるために AI を活用する責務があることを認識すべきである。当該取組に対して、社会から不適切もしくは不十分と評価される場合は、自らの事業活動における機会損失が生じ、事業価値の維持が困難となる事態を招く恐れがあることへ留意することが重要となる。このような点に留意することにより、AI による便益の最大化、競争力の強化及び事業価値の維持・向上等が可能となる。なお、AI を扱う事業者以外の者、例えば、教育・研究機関に属する者や一般消費者（未成年を含む）にとっても、AI の活用にあたって参考となる情報やリスクに関する情報が盛り込まれているため、有用といえる。

本ガイドラインは、様々な事業活動において AI を活用する全ての者（政府・自治体等の公的機関を含む）を対象としている。他方で、事業活動以外で AI を活用する者又は AI を直接事業に活用せずに AI システム・サービスの便益を享受する、場合によっては損失を被る者（以下、あわせて「業務外利用者」という）については、本ガイドラインの対象には含まれない。また、AI 活用に伴い学習用等のデータが不可欠となる。それらのデータを提供する特定の法人や個人（以下、「データ提供者」という）が存在する一方で、インターネット等の公開情報等から当該データを入手することも可能である。インターネット等の公開情報等のデータ源は、本ガイドラインに沿った取組の推進を期待するものではないため、データ提供においては、提供される者、もしくは入手する者がデータを取り扱う責任を担うものとして、データ提供者に関しても本ガイドラインの対象には含まれない。以上より、本ガイドラインの対象者は、AI の事業活動を担う主体として、「AI 開発者」、「AI 提供者」、「AI 利用者」の 3 つに大別され、それぞれ以下のとおり定義される。これらの主体は事業者の組織を想定しており、AI の活用方法によっては同一の事業者が AI 開発者、AI 提供者、AI 利用者の複数を兼ねる場合もある（「図 3. 一般的な AI 活用の流れにおける主体の対応」参照）¹。

¹ 開発・提供・利用の対象に生成 AI も含まれる。AI 提供者や AI 利用者が政府・自治体等、公的機関になる場合は、民間事業者の場合とは別の考えが必要になる可能性がある。

• AI 開発者 (AI Developer)

AI システムを開発する事業者 (AI を研究開発する事業者を含む)

AI モデル・アルゴリズムの開発、データ収集 (購入を含む)、前処理、AI モデル学習、検証を通して AI モデルおよび AI モデルのシステム基盤や入出力等を含む AI システムを構築する役割を担う。

• AI 提供者 (AI Provider)

AI システムをアプリケーションや製品もしくは既存のシステムやビジネスプロセス等に組み込んだサービスとして AI 利用者 (AI Business User)、場合によっては業務外利用者に提供する事業者

AI システム検証、AI システムの他システムとの連携の実装、AI システム・サービスの提供、正常稼働のための AI システムにおける AI 利用者 (AI Business User) 側の運用サポートや AI サービスの運用自体を担う。AI サービスの提供に伴い、ステークホルダーとのコミュニケーションが求められることもある。

• AI 利用者 (AI Business User)

事業活動において、AI システム又は AI サービスを利用する事業者

AI 提供者が意図している適正な利用及び環境変化等の情報を AI 提供者と共有し正常稼働を継続する、必要に応じて提供された AI システムを運用する役割を担う。また、AI の活用において業務外利用者に何らかの影響が考えられる場合²は、当該者に対する AI による意図しない不利益の回避、AI による便益最大化の実現に努める役割を担う。




図 3. 一般的な AI 活用の流れにおける主体の対応

自らが該当する「AI 開発者」、「AI 提供者」、「AI 利用者」の立場から、「ステークホルダーからの期待を鑑みつつどのような社会を目指すのか (基本理念 = why)」を踏まえ、「AI に関しどのような取組を行うべきか (指針 = what)」を明らかにすることが重要であり、また指針を実現するために、「具体的にどのようなアプローチで取り

² 業務外利用者は、AI 利用者の指示、注意に従わない場合、何らかの被害を受ける可能性があることを留意する必要がある。

組むか（実践 = how）」を検討・決定し、実践することが AI の安全安心な活用に有用と考えられる。実際の AI サービスは目的・活用技術・データ・利用環境等によって多様なユースケースとなり、技術の発展等、外部環境の変化も踏まえつつ、AI 開発者、AI 提供者、AI 利用者が連携して最適なアプローチを検討することが重要である。本ガイドラインは読みやすさを考慮し、本編で「基本理念」と「指針」を扱い、別添（付属資料）で「実践」を扱うこととする。

「基本理念」と「指針」を扱う本ガイドラインの本編の構成を以下に記載する。

・ 第 1 部

本ガイドラインの内容に関する理解を助けるために、「用語の定義」を中心に記載する。

・ 第 2 部

AI の活用により目指すべき社会、それを実現するための基本理念（why）と各主体に共通する指針（what）を記載する。AI の活用による便益を求めめる中で、AI が社会にリスクをもたらす可能性を鑑み、共通の指針を実践するために必要となるガバナンスの構築についても触れる。第 2 部では第 3 部以降の基となる内容を解説しているため、AI を活用する全ての事業者が内容を確認し、理解することが重要である。

・ 第 3 部～第 5 部

AI を活用した事業活動を担う 3 つの主体に関し、第 2 部では触れられない主体ごとの留意点を記載する。AI を活用する事業者は自らに関する事項を理解することが重要であり、それと同時に、隣接する主体と関係する事項が多く存在するため、当該主体以外に関する事項も理解することが重要である（「図 4. 本ガイドラインの構成」参照）。

本編（why, what）			別添（付属資料）（how）	
主体 共通	第1部	AIとは	1. 第1部関連 [AIについて]	A. AIに関する前提 B. AIによる便益/リスク
	第2部	AIにより 目指すべき社会と 各主体が取り組む 事項 A.「基本理念」 B.「原則」 C.「共通の指針」 D.「高度なAIシステムに関する 事業者共通の指針」 E.「AIガバナンスの構築」	2. 第2部関連 [E.AIガバナンスの構築]	A. 経営層によるAIガバナンスの構築・ モニタリング B. AIガバナンスの事業者取組事例
	第3部	AI開発者に 関する事項	3. 第3部関連 [AI開発者向け]	A. 「第3部 AI開発者に関する事項」の解説 B. 「第2部」の「共通の指針」の解説 C. 高度なAIシステムの開発にあたって遵守 すべき事項
	第4部	AI提供者に 関する事項	4. 第4部関連 [AI提供者向け]	A. 「第4部 AI提供者に関する事項」の解説 B. 「第2部」の「共通の指針」の解説
	第5部	AI利用者に 関する事項	5. 第5部関連 [AI利用者向け]	A. 「第5部 AI利用者に関する事項」の解説 B. 「第2部」の「共通の指針」の解説
主体別			6. 「AI・データの利用に関する契約ガイドライン」を参照 する際の主な留意事項について	
			7. チェックリスト（上記2.-6.に対応）	
			8. 主体横断的な仮想事例	
			9. 海外ガイドラインとの比較表	
その他 参考資料				

図 4. 本ガイドラインの構成

「AI 開発者」、「AI 提供者」、「AI 利用者」においては、第 1 部、第 2 部に加えて、第 3 部以降の当該部及び別添（付属資料）を確認することで、AI を活用する際のリスクやその対応方針の基本的な考え方を把握することが可能となる。特に具体的な取組が決まっていない事業者にとっては、別添の記載例が参考となるため、別添の関連箇所を中心とした確認が重要となる。なお、経営者を含む事業執行責任者³は、その職務を全うするために、本ガイドラインにおける基本理念（why）と指針（what）を踏まえて、事業戦略と一体で AI を活用する際のリスク対策を検討・実践し、AI の安全安心な活用を推進することが重要である。

AI をめぐる環境はグローバル規模で日進月歩の進化を続けていることから、AI を活用する事業者は、国際的な動向にも注意を払うことが重要である。我が国においても、こうした現状を踏まえ、広島 AI プロセス⁴を通じて、AI に関する国際的な共通理解、指針の策定を主導しており、2023 年 12 月には広島 AI プロセス包括的政策枠組み等を取りまとめた。本ガイドラインも同プロセスへの貢献を意図するとともに、同プロセスを含む国際的な議論を踏まえながら検討したものである。一方で、AI をめぐる考え方や法令は国・地域で異なることから、特に、国境を越えた活動を行う事業者は、現地の法令やステークホルダーの期待に応じた対応をすべきである。

³ 事業執行責任者は、政府・自治体等の公的機関の事業執行責任者も含む。

⁴ 2023 年 5 月の G7 広島サミットの結果を受けて、生成 AI に関する国際的なルールの検討を行うため、「広島 AI プロセス」を立ち上げた。その後、同年 9 月の「広島 AI プロセス閣僚級会合」や 10 月の京都 IGF での「マルチステークホルダーハイレベル会合」等を経て発出された「AI に関する G7 首脳声明」を踏まえ、同年 12 月に「G7 デジタル・技術大臣会合」を開催し、同年の成果として、「広島 AI プロセス包括的政策枠組み」及び「広島 AI プロセス推進作業計画」を取りまとめた。

第 1 部 AI とは

AI は Artificial Intelligence（人工知能）を意味し、1956 年にダートマス会議で初めて使用された言葉である。AI は未だ確立された定義は存在しないが、「人工」・「知能」とあるように、人間の思考プロセスと同じような形で動作するコンピュータープログラムや、コンピューター上で知的判断を下せるシステム等を指す。機械学習を行わない、専門家の知識を大量にインプットすることで知識に基づく推論を行うエキスパートシステムと呼ばれるものも、元々は AI の一種とされていた。しかし、2000 年代以降、ディープラーニングの登場により、機械学習を行うことで、「画像認識」、「自然言語処理（翻訳等）」、「音声認識」が可能となり、特定の分野に特化し、予測や提案、決定を行うことができるシステムを AI と指すようになってきた。また、2021 年以降、基盤モデル⁵の台頭により、特定の分野のみに特化した AI ではない、汎用的な AI の開発が進んでいる。その結果、「予測」、「提案」、「決定」にとどまらず、全く新しい画像や文章を生成する「生成 AI」が普及するようになり、注目を集めている。このように、ひとくりに「AI」と言っても、その種類は多岐にわたり、今後の AI 技術の在り方については専門家であっても予測することは困難である。

このような状況を踏まえつつ、本ガイドラインにおける関連する用語を以下のとおり定義する。

関連する用語

- **AI**

現時点で確立された定義はなく（統合イノベーション戦略推進会議決定「人間中心の AI 社会原則」（2019 年 3 月 29 日））、広義の人工知能の外延を厳密に定義することは困難である。本ガイドラインにおける AI は「AI システム」自体や、機械学習をするソフトウェアやプログラムを含む抽象的な概念とする。

（参考として JIS X22989 では ISO/IEC22989 に基づき、以下のように定義されている）

＜学問分野＞ AI システムのメカニズム及び適用の研究開発

注釈 1. 研究開発は、コンピュータサイエンス、データサイエンス、自然科学、人文科学、数学等、幾つもの分野にわたって行うことが可能である

- **AI システム**

活用の過程を通じて様々なレベルの自律性をもって動作し学習する機能を有するソフトウェアを要素として含むシステムとする（機械、ロボット、クラウドシステム等）。

（参考として JIS X22989 では ISO/IEC22989 に基づき、以下のように定義されている）

人間が定義した所与の目標の集合に対して、コンテンツ、予測、推奨、意思決定等の出力を生成する工学的システム

注釈 1. 工学的システムは、人工知能に関連する様々な技法及びアプローチを使用して、作業の実施に使用可能であるデータ、知識、プロセス等を表すモデルを開発することが可能である

注釈 2. AI システムは、様々な自動化のレベルで動作するように設計されている

⁵ 大規模言語モデルに代表される基盤モデルは、様々なサービスを支える個別モデルを生み出すコアの技術基盤である。基盤モデルから派生する下流の幅広いタスクに適応させたモデルの開発や、また、開発過程そのものから得られる知見等の観点から、一般的な AI とは異なる性質を持つ

(参考として OECD AI Principles overview では以下のように定義されている)

AI システムは、明示的または暗黙的な目的のために推測するマシンベースのシステムである。受け取った入力から、物理環境または仮想環境に影響を与える可能性のある予測、コンテンツ、推奨、意思決定等の出力を生成する。AI システムが異なれば、導入後の自律性と適応性のレベルも異なる

- **高度な AI システム**

最先端の基盤モデル及び生成 AI システムを含む、最も高度な AI システムを指す。

- **AI モデル (ML モデル)**

AI システムに含まれ、学習データを用いた機械学習によって得られるモデルで、入力データに応じた予測結果を生成する。

(参考として JIS X22989 では ISO/IEC22989 に基づき、以下のように定義されている)

入力データ又は情報に基づいて推論 (inference) 又は予測を生成する数学的構造

例：単変量線形関数 $y = \theta_0 + \theta_1 x$ が、線形回帰を使用して訓練されている場合、結果のモデルは、 $y = 3 + 7x$ のようになる

注釈 1. 機械学習モデルは、機械学習アルゴリズムに基づく訓練の結果として得られる

- **AI サービス**

「AI システム」を用いた役務を指す。利用者への価値提供の全般を指しており、AI サービスの提供・運営は、AI システムの構成技術に限らず、人間によるモニタリングやステークホルダーとの適切なコミュニケーション等の非技術的アプローチも連携した形で実施される。

- **生成 AI**

文章や画像、プログラム等を生成できる AI モデルに基づく AI の総称を指す。

- **AI ガバナンス**

AI の利活用によって生じるリスクをステークホルダーにとって受容可能な水準で管理しつつ、そこからもたらされる正のインパクトを最大化することを目的とする、ステークホルダーによる技術的、組織的、及び社会的システムの設計及び運用。

第2部 AIにより目指すべき社会と各主体が取り組む事項

第2部では、まず、AIにより目指す社会としての「A. 基本理念」を記載する。更に、その実現に向け、各主体が取り組む「B. 原則」とともに、そこから導き出される「C. 共通の指針」を記載する。また、高度なAIシステムに関係する事業者が遵守すべき「D. 高度なAIシステムに関係する事業者に共通の指針」を記載する。加えて、この「C. 共通の指針」を実践しAIを安全安心に活用していくために重要な「E. AIガバナンスの構築」についても記載する。

A. 基本理念

「はじめに」で述べたとおり、我が国が2019年3月に策定した「人間中心のAI社会原則」においては、AIがSociety 5.0の実現に貢献することが期待されている。また、AIを人類の公共財として活用し、社会の在り方の質的变化や真のイノベーションを通じて地球規模の持続可能性へとつなげることが重要であることが述べられている。そして、以下の3つの価値を「基本理念」として尊重し、「その実現を追求する社会を構築していくべき」としている。

① 人間の尊厳が尊重される社会（Dignity）

AIを利活用して効率性や利便性を追求するあまり、人間がAIに過度に依存したり、人間の行動をコントロールすることにAIが利用される社会を構築するのではなく、人間がAIを道具として使いこなすことによって、人間の様々な能力をさらに発揮することを可能とし、より大きな創造性を発揮したり、やりがいのある仕事に従事したりすることで、物質的にも精神的にも豊かな生活を送ることができるような、人間の尊厳が尊重される社会を構築する必要がある

② 多様な背景を持つ人々が多様な幸せを追求できる社会 （Diversity and Inclusion）

多様な背景と価値観、考え方を持つ人々が多様な幸せを追求し、それらを柔軟に包摂した上で新たな価値を創造できる社会は、現代における一つの理想であり、大きなチャレンジである。AIという強力な技術は、この理想に我々を近づける一つの有力な道具となりうる。我々はAIの適切な開発と展開によって、このように社会の在り方を変革していく必要がある

③ 持続可能な社会（Sustainability）

我々は、AIの活用によりビジネスやソリューションを次々と生み、社会の格差を解消し、地球規模の環境問題や気候変動等にも対応が可能な持続性のある社会を構築する方向へ展開させる必要がある。科学・技術立国としての我が国は、その科学的・技術的蓄積をAIによって強化し、そのような社会を作ることに貢献する責務がある




図 5. 基本理念

この大きな考え方自体は、著しい技術の発展によっても変わるものではなく、目指すべき理念であり続けている。したがって、AI の発展に伴い、日本及び多国間の枠組みで目指すべき方向性として、これらの基本理念が尊重されるべきである。

B. 原則

この「基本理念」を実現するためには、各主体がこれに沿う形で取組を進めることが重要であり、そのために各主体が念頭におく「原則」を、各主体が取り組む事項と、社会と連携した取組が期待される事項に整理した。この「原則」は、「人間中心の AI 社会原則」を土台としつつ、OECD の AI 原則等の海外の諸原則を踏まえ、再構成したものである。

各主体が取り組む事項

各主体は、基本理念より導き出される人間中心の考え方を基に、AI システム・サービスの開発・提供・利用を促進し、人間の尊厳を守りながら、事業における価値の創出や社会課題の解決等、AI の目的を実現していくことが重要である。このため、各主体は、AI 活用に伴う社会的リスクの低減を図るべく、安全性・公平性といった価値を確保することが重要である。また、個人情報の不適正な利用等の防止を始めとするプライバシー保護、システムの脆弱性等による可用性の低下や外部からの攻撃等のリスクに対応するセキュリティ確保を行うことが重要である。上記を実現するために、各主体は、システムの検証可能性を確保しながら、ステークホルダー⁶に対する適切な情報を提供することにより透明性を向上させ、アカウンタビリティを果たすことが重要となる。

加えて、今後、AI アーキテクチャの多様化に伴うバリューチェーン変動等により、各主体の役割が変動する可能性を踏まえた上で、各主体間で連携し、バリューチェーン全体での AI の品質の向上に努めることが重要である。

⁶ AI 開発者、AI 提供者、AI 利用者、業務外利用者以外の第三者を含む AI の活用によって直接・間接の影響を受ける可能性がある全ての主体（以降同様）

なお、これらの取組は、各主体が開発・提供・利用する AI システム・サービスの特性や用途、目的や社会的文脈を踏まえ、各主体の資源制約を考慮しながら自主的に進めることが重要である。このような対応を行うことで、各主体が、AI のリスクを最低限に抑制しつつ、AI システム・サービスの開発・提供・利用を通じて最大限の便益を享受することが期待される。

社会と連携した取組が期待される事項

AI による社会への便益を一層増大させ、我々が目指すべき理念を実現していくためには、各主体それぞれの取組に加え、社会（政府・自治体やコミュニティも含む）と積極的に連携することが期待される。このため、各主体は、社会と連携して、社会の分断を回避し、全ての人々に AI の恩恵が行き渡るための教育・リテラシー確保の機会を提供することが期待される。加えて、新たなビジネス・サービスが創出され、持続的な経済成長の維持と社会課題の解決策が提示されるよう、公正競争の確保やイノベーションの促進に貢献していくことが期待される。

C. 共通の指針

取組にあたり、各主体は、以下に述べる 1) 人間中心に照らし、法の支配、人権、民主主義、多様性、公平公正な社会を尊重するよう AI システム・サービスを開発・提供・利用し、憲法や知的財産関連法令、個人情報保護法をはじめとする関連法令、AI に係る個別分野の既存法令等を遵守すべきであり、国際的な指針等の検討状況についても留意することが重要である^{7,8}。

各主体が連携して、バリューチェーン全体で取り組むべきことは、具体的には、以下のとおり整理される。

1) 人間中心

各主体は、AI システム・サービスの開発・提供・利用において、後述する各事項を含む全ての取り組むべき事項が導出される土台として、少なくとも憲法が保障する又は国際的に認められた人権を侵すことがないようにすべきである。また、AI が人々の能力を拡張し、多様な人々の多様な幸せ（well-being）の追求が可能となるよう行動することが重要である。

① 人間の尊厳と個人の自律

- ✧ AI が活用される際の社会的文脈を踏まえ、人間の尊厳と個人の自律を尊重する
- ✧ 特に、AI を人間の脳・身体と連携させる場合には、その周辺技術に関する情報を踏まえつつ、諸外国や研究機関における生命倫理の議論等を参照する

⁷ 事業の地理的な展開状況、開発された AI モデルを用いる AI 提供者・AI 利用者の所在地、学習を行うサーバの所在地等に応じ、各準拠法に従う必要がある。我が国の国内法に準拠する場合は、データの類型に応じ、個人情報、知的財産権、機密情報等にそれぞれ適用される法令に適合した取扱いを行う。また、データの取扱いにおいては、法令で定められていなくともステークホルダー間の契約関係において、利用が禁止される場合が存在することにも留意すべきである。

⁸ 知的財産関連法令との関係については内閣府知的財産戦略推進事務局や文化庁等での議論が進められており、今後の検討状況について留意すべきである。特に AI と著作権の関係については、文化審議会著作権分科会法制度小委員会にて、AI の開発・学習において著作権者の許諾なく著作物の利用が認められる範囲の明確化や、生成物による著作権侵害リスクの軽減方策等に関する考え方を整理しているところであり、各主体においては、その趣旨を踏まえることが重要である。

- ✧ 個人の権利・利益に重要な影響を及ぼす可能性のある分野において AI を利用したプロファイリングを行う場合、個人の尊厳を尊重し、生じうる不利益等を慎重に検討した上で、不適切な目的に利用しない
- ② AI による意思決定・感情の操作等への留意
- ✧ 人間の意思決定や認知等、感情を不当に操作することを目的とした、もしくは操作を前提とした AI システム・サービスの開発・提供・利用は行わない
 - ✧ AI システム・サービスの開発・提供・利用において、自動化バイアス⁹等の AI に過度に依存するリスクに対して、必要な対策を講じる
 - ✧ フィルターバブル¹⁰に代表されるような情報や価値観の傾斜を助長し、AI 利用者を含む人間が本来得られるべき選択肢が不本意に制限されるような AI の活用にも注意を払う
 - ✧ 特に、選挙やコミュニティでの意思決定等をはじめとする社会に重大な影響を与える手続きに関連しうる場合においては、AI の出力について慎重に検討する
- ③ 偽情報等への対策
- ✧ 生成 AI によって、内容が真実・公平であるかのように装った情報を誰でも作ることができるようになり、AI が生成した偽情報・誤情報・偏向情報が社会を不安定化・混乱させるリスクが高まっていることを認識した上で、必要な対策を講じる
- ④ 多様性・包摂性の確保
- ✧ 公平性の確保に加え、いわゆる「情報弱者」や「技術弱者」を生じさせず、より多くの人々が AI の恩恵を享受できるよう社会的弱者による AI の活用を容易にするよう注意を払う
 - ユニバーサルデザイン、アクセシビリティの確保、関連するステークホルダー¹¹への教育・フォローアップ 等
- ⑤ 利用者支援
- ✧ 合理的な範囲で、AI システム・サービスの機能及びその周辺技術に関する情報を提供し、選択の機会を適時適切に提供する機能が利用可能である状態とする
 - デフォルトの設定、理解しやすい選択肢の提示、フィードバックの提供、緊急時の警告、エラーへの対処 等
- ⑥ 持続可能性の確保
- ✧ AI システム・サービスの開発・提供・利用において、ライフサイクル全体で、地球環境への影響も検討する

⁹ 人間の判断や意思決定において、自動化されたシステムや技術への過度の信頼や依存が生じる現象を指す。

¹⁰ 「フィルターバブル」とは、アルゴリズムがネット利用者個人の検索履歴やクリック履歴を分析し学習することで、個々にとっては望むと望まざるとにかかわらず見たい情報が優先的に表示され、利用者の観点に合わない情報からは隔離され、自身の考え方や価値観の「バブル（泡）」の中に孤立するという情報環境を指す。このようなもととある人間の傾向とネットメディアの特性の相互作用による現象と言われているものとして、「フィルターバブル」の他、「エコーチェンバー」も挙げられる。そういったリスクがある一方で、AI はパーソナライズされた的を絞った返答を業務外利用者等に提供し、有益な形で提案を行うことを可能とするという便益もある。

¹¹ AI 開発者、AI 提供者、AI 利用者、業務外利用者を含む直接・間接問わず AI の活用に関与する主体（以降同様）

これら全てを前提とした上で、各主体は、AI のパフォーマンス（有用性）を可能な範囲で高め、人々に便益と豊かさを与え、幸福を実現することが期待される。

2) 安全性

各主体は、AI システム・サービスの開発・提供・利用を通じ、AI に関わる全ての者の生命・心身・財産に危害を及ぼすことがないようにすべきである。加えて、環境に危害を及ぼすことがないようにすることが重要である。

① 人間の生命・心身・財産、及び環境への配慮

- ✧ AI の出力の正確性を含め、要求に対して十分に動作している（信頼性）
- ✧ 様々な状況下でパフォーマンスレベルを維持し、無関係な事象に対して著しく誤った判断を発生させないようにする（堅牢性（robustness））
- ✧ AI の活用や意図しない AI の動作によって生じうる権利侵害の重大性、侵害発生の可能性等、当該 AI の性質・用途等に照らし、必要に応じて客観的なモニタリングや対処も含めて人間がコントロールできる制御可能性を確保する
- ✧ 適切なリスク分析を実施し、リスクへの対策を講じる
- ✧ 人間の生命・心身・財産、及び環境へ危害を及ぼす可能性がある場合は、講ずべき措置について事前に整理し、AI に関わる全ての者に関連する情報を提供する
 - 関連するステークホルダーが講ずべき措置及び利用規則を明記する
- ✧ AI システム・サービスの安全性を損なう事態が生じた場合の対処方法を検討し、当該事態が生じた場合に速やかに実施できるよう整える

② 適正利用

- ✧ 主体のコントロールが及ぶ範囲で本来の目的を逸脱した提供・利用により危害が発生することを避けるべく、AI システム・サービスの開発・提供・利用を行う

③ 適正学習¹²

- ✧ AI システム・サービスの特性や用途を踏まえ、学習等に用いるデータの正確性・必要な場合には最新性（データが適切であること）等を検討する
- ✧ 学習等に用いるデータの透明性の支援や法的枠組みの遵守、AI モデルの更新等を合理的な範囲で適切に実施する

3) 公平性

各主体は、AI システム・サービスの開発・提供・利用において、特定の個人ないし集団へのその人種、性別、国籍、年齢、政治的信念、宗教等の多様な背景を理由とした不当で有害な偏見や差別を最小化することが重要である。また、各主体は、潜在的なバイアスを最小化するよう留意し、それでも回避できないバイアスがあることを認識しつつ、この回避できないバイアスが人権や多様な文化を尊重する観点から

¹² AI 提供者・AI 利用者においてもファインチューニング、再学習を行う場合は AI 開発者と同様に安全性の担保に努めることが重要となる。

許容可能か評価をした上で、AI システム・サービスの開発・提供・利用を行うことが重要である。

① AI モデルの各構成技術に含まれるバイアスへの配慮

- ✧ 不適切なバイアスを生み出す要因は多岐に渡るため、各技術要素（学習データ、モデルの学習過程、AI 利用者が入力するプロンプト¹³、AI モデルの推論時に参照する情報や連携する外部サービス等）及び利用者の振る舞いを含めて、公平性の問題となり得るバイアスの要因となるポイントを特定する
- ✧ AI システム・サービスの特性や用途によっては、潜在的なバイアスが生じる可能性についても検討する

② 人間の判断の介在

- ✧ AI の出力結果が公平性を欠くことがないよう、AI に単独で判断させるだけでなく人間の判断を介在させる利用を検討する
- ✧ バイアスが生じていないか、AI システム・サービスの目的、制約、要件、決定を明確かつ透明性のある方法により分析し、対処するためのプロセスを導入する
- ✧ 無意識のバイアスや潜在的なバイアスに留意し、多様な背景、文化、分野のステークホルダーと対話した上で、方針を決定する

4) プライバシー保護

各主体は、AI システム・サービスの開発・提供・利用において、その重要性に応じ、プライバシーを尊重し、保護することが重要である。その際、関係法令を遵守すべきである。

① AI システム・サービス全般におけるプライバシーの保護

- ✧ 個人情報保護法等の関連法令の遵守や、各主体のプライバシーポリシーの策定・公表等により、社会的文脈や人々の合理的な期待を踏まえ、各主体を含むステークホルダーのプライバシーが尊重され、保護されるよう、その重要性に応じた対応を取る
- ✧ 以下の事項を考慮しつつ、プライバシー保護のための対応策を検討する
 - 個人情報保護法に基づいた対応の確保
 - 国際的な個人データ保護の原則及び基準の参照¹⁴

5) セキュリティ確保

¹³ 大規模言語モデルを始めとする生成 AI では、AI 利用者は、コンテキスト内学習と呼ばれる学習方法により、学習済パラメータを更新することなく、AI 利用者の入力（プロンプトと呼ばれる）に応じて、特定のタスクに対する学習を行わせることが可能である。

¹⁴ OECD, Recommendation of the Council concerning Guidelines Governing the Protection of Privacy and Transborder Flows of Personal Data, OECD/LEGAL/0188 や ISO/IEC 29100:2011 Information technology Security techniques Privacy framework 等プライバシーに関する国際的な指針を踏まえることが期待される。また、より広範囲での個人データの円滑な越境移転や各国における規律の相互運用性を促進させる等の目的で Global Cross-Border Privacy Rules (CBPR) Forum が立ち上がっており、日本も 2022 年 4 月に参加し、Global CBPR Framework を公表している。また、生成 AI に関しては、G7 データ保護プライバシー機関ラウンドテーブル会合による「生成 AI に関する声明」（2023 年 6 月）及び GPA (Global Privacy Assembly) による「生成 AI システムに関する決議」（2023 年 10 月）も参照。

各主体は、AI システム・サービスの開発・提供・利用において、AI の振る舞いについて外部的操作によって意図せぬ変更や停止が生じることのないようにセキュリティを確保することが重要である。

① AI システム・サービスに影響するセキュリティ対策¹⁵

- ✧ AI システム・サービスの機密性・完全性・可用性を維持し、常時、AI の安全な活用を確保するため、その時点での技術水準に照らして合理的な対策を講じる
- ✧ AI システム・サービスの特性を理解し、正常な稼働に必要なシステム間の接続が適切に行われているかを検討する
- ✧ 推論対象データに微細な情報を混入させることで関連するステークホルダーの意図しない判断が行われる可能性を踏まえて、AI システム・サービスの脆弱性を完全に排除することはできないことを認識する

② 最新動向への留意

- ✧ AI システム・サービスに対する外部からの攻撃は日々新たな手法が生まれており、これらのリスクに対応するための留意事項を確認する

6) 透明性¹⁶

各主体は、AI システム・サービスの開発・提供・利用において、AI システム・サービスを活用する際の社会的文脈を踏まえ、AI システム・サービスの検証可能性を確保しながら、必要かつ技術的に可能な範囲で、ステークホルダーに対し合理的な範囲で適切な情報を提供することが重要である。

① 検証可能性の確保

- ✧ AI の判断にかかわる検証可能性を確保するため、データ量やデータ内容に照らし合理的な範囲で、AI システム・サービスの開発過程及び利用時の入出力等、AI の学習プロセス及び推論過程や判断根拠等のログを記録・保存する
- ✧ ログの記録・保存にあたっては、利用する技術の特性や用途に照らして、その目的、頻度等について検討する

② 関連するステークホルダーへの情報提供

- ✧ AI との関係の仕方、AI の性質及び目的等に照らして、それぞれが有する知識や能力に応じ以下について取りまとめた情報の提供と説明を行う
 - AI システム・サービス全般
 - AI を利用しているという事実

¹⁵詳細な手法については、英国サイバーセキュリティセンター（NCSC）「セキュアな AI システム開発のためのガイドライン（Guidelines for secure AI system development）」（2023 年 11 月）も参照。

<https://www8.cao.go.jp/cstp/stmain/20231128ai.html>

¹⁶ 透明性については、諸外国でも様々な定義がある。例えば、NIST, Artificial Intelligence Risk Management Framework（January 2023）では、透明性（システムで何が起きたかについて答えられること）、説明可能性（システムでどのように決定がなされたかについて答えられること）、解釈可能性（なぜその決定がされたかについてその意味や文脈について答えられること）と分類されており、European Commission, ETHICS GUIDELINES FOR TRUSTWORTHY AI（April 2019）では、トレーサビリティ、説明可能性、コミュニケーションが取り上げられている。本文書では、情報開示に関する事項を広く「透明性」とする。

- データ収集及びアノテーションの手法
 - 学習及び評価の手法
 - 基盤としている AI モデルに関する情報
 - AI システム・サービスの能力、限界、提供先における適切/不適切な利用方法
 - AI システム・サービスの提供先や AI 利用者が所在する国・地域等において適用される関連法令等
 - ✧ 多様なステークホルダーとの対話を通じて積極的な関与を促し、社会的な影響や安全性に関する様々な意見を収集する
 - ✧ 加えて、AI システム・サービスを提供・利用することの優位性を、実態に即して関連するステークホルダーに示す
- ③ 合理的かつ誠実な対応
- ✧ 上記の「②関連するステークホルダーへの情報提供」は、アルゴリズムやソースコードの開示を想定するものではなく、プライバシーや営業秘密を尊重して、採用する技術の特性や用途に照らし、社会的合理性が認められる範囲で実施する
 - ✧ 公開されている技術を用いる際には、それぞれ定められている規程に準拠する
 - ✧ 開発した AI システムのオープンソース化にあたっては、社会的な影響を検討する
- ④ 関連するステークホルダーへの説明可能性・解釈可能性の向上
- ✧ 関連するステークホルダーの納得感や安心感の獲得、また、そのための AI の動作に対する証拠の提示等を目的として、どのような説明が求められるかを分析・把握し、必要な対応を講じる
 - AI 提供者：AI 開発者に、どのような説明が必要となるかを共有する
 - AI 利用者：AI 開発者・AI 提供者に、どのような説明が必要となるかを共有する

7) アカウンタビリティ¹⁷

各主体は、AI システム・サービスの開発・提供・利用において、トレーサビリティの確保や共通の指針の対応状況等について、ステークホルダーに対して、各主体の役割や開発・提供・利用する AI システム・サービスのもたらすリスクの程度を踏まえ、合理的な範囲でアカウンタビリティを果たすことが重要である。

① トレーサビリティの向上

- ✧ データの出所や AI システム・サービスの開発・提供・利用中に行われた意思決定等について、技術的に可能かつ合理的な範囲で追跡・遡求が可能な状態を確保する

② 共通の指針の対応状況の説明

- ✧ 共通の指針の対応状況について、ステークホルダー（サプライヤーを含む）に対してそれぞれが有する知識や能力に応じ、例えば以下の事項を取りまとめた情報の提供と説明を定期的に行う

¹⁷ アカウンタビリティを説明可能性と定義することもあるが、本ドキュメントでは情報開示は透明性で対応することとし、アカウンタビリティとは AI に関する事実上・法律上の責任を負うこと及びその責任を負うための前提条件の整備に関する概念とする。

- 全般
 - 共通の指針の実践を妨げるリスクの有無や程度に関する評価
 - 共通の指針の実践の進捗状況
- 「人間中心」関連
 - 偽情報等への留意、多様性・包摂性、利用者支援、持続可能性の確保の対応状況
- 「安全性」関連
 - AI システム・サービスに関する既知のリスクと対応策、安全性確保の仕組み
- 「公平性」関連
 - AI モデルを構成する各技術要素（学習データ、モデルの学習過程、AI 利用者が入力するプロンプト、AI モデルの推論時に参照する情報や連携する外部サービス等）によってバイアスが含まれること
- 「プライバシー保護」関連
 - AI システム・サービスにより自己やステークホルダーのプライバシーが侵害されるリスクと対応策、並びにプライバシー侵害が発生した場合に講ずることが期待される措置
- 「セキュリティ確保」関連
 - AI システム・サービスの相互間連携や他システムとの連携が発生する場合、その促進のために必要な標準準拠等
 - AI システム・サービスがインターネットを通じて他の AI システム・サービス等と連携する場合に発生しうるリスクとその対応策

③ 責任者の明示

- ✧ 各主体においてアカウントビリティを果たす責任者を設定する

④ 関係者間の責任の分配

- ✧ 関係者間の責任について、業務外利用者も含めた各主体間の契約や社会的な約束（ボランティア・コミットメント）等により、責任の所在を明確化する

⑤ ステークホルダーへの具体的な対応

- ✧ 必要に応じ、AI システム・サービスの利用に伴うリスク管理や安全性確保のための各主体の AI ガバナンスに関するポリシー、プライバシーポリシー等の方針を策定し、公表する（社会や一般市民に対するビジョンの共有や情報発信・提供を行うといった社会的責任を含む）
- ✧ 必要に応じ、AI の出力の誤り等について、ステークホルダーからの指摘を受け付ける機会を設けるとともに、客観的なモニタリングを実施する
- ✧ ステークホルダーの利益を損なう事態が生じた場合、どのように対応するか方針を策定してこれを着実に実施し、進捗状況については必要に応じて定期的にステークホルダーに報告する

⑥ 文書化

- ✧ 上記に関する情報を文書化して保管し、必要なときに、必要なところで、入手可能かつ利用に適した形で参照可能な状態とする

各主体が社会と連携して取り組むことが期待される事項は、具体的には、下記のとおり整理される。

8) 教育・リテラシー

各主体は、各主体内の AI に関わる者が、AI に係る正しい理解と社会的に正しい利用ができる知識・リテラシー・倫理感を持つために、必要な教育を行うことが期待される。また、各主体は、AI の複雑性や誤情報といった特性や、意図的な悪用の可能性もあることを勘案して、ステークホルダーに対しても教育を行うことが期待される。¹⁸

① AI リテラシーの確保

✧ 各主体内の AI に関わる者が、その関わりにおいて十分なレベルの AI リテラシーを確保するために必要な措置を講じる

② 教育・リスクリング

✧ 生成 AI の活用拡大によって、AI と人間の作業の棲み分けが変わっていくと想定されるため、新たな働き方ができるよう教育・リスクリング等を検討する

③ ステークホルダーへのフォローアップ

✧ AI サービス全体の安全性を高めるため、必要に応じて、ステークホルダーに対して教育やリテラシー確保のためのフォローアップを行う

9) 公正競争確保

各主体は、AI を活用した新たなビジネス・サービスが創出され、持続的な経済成長の維持と社会課題の解決策の提示がなされるよう、AI をめぐる公正な競争環境の維持に努めることが期待される。

10) イノベーション

各主体は、社会全体のイノベーションの促進に貢献するよう、努めることが期待される。

① オープンイノベーション等の推進

✧ 国際化・多様化や産学官連携、オープンイノベーションを推進する

✧ AI のイノベーションに必要なデータが創出される環境の維持に配慮する

② 相互接続性・相互運用性への留意

✧ 自らの AI システム・サービスと他の AI システム・サービスとの相互接続性と相互運用性を確保する

¹⁸ 経済産業省・（独）情報処理推進機構は、個人の学習や企業の人材確保・育成の指針として DX 時代の人材像を「デジタルスキル標準」として整理（2022 年 12 月）。生成 AI の利用を通じた更なる企業 DX の推進に向けて、2023 年 8 月に「生成 AI 時代の DX 推進に必要な人材・スキルの考え方」を取りまとめ、指示（プロンプト）の習熟や「問いを立てる」「仮説検証する」等の必要性をスキル標準に反映。

③ 適切な情報提供

◇ 自らのイノベーションを損なわない範囲で必要な情報提供を行う

以上の事項に加え、AI 開発者、AI 提供者、AI 利用者のそれぞれで重要となる事項について、「表 1. 共通の指針に加えて主体毎に重要となる事項」とおり整理される。表の「-」が記載されている箇所は、各主体による「第 2 部 共通の指針」記載の事項に基づく対応が期待されており、対応不要を意味するものではない。

なお、以降は「表 1 共通の指針に加えて主体毎に重要となる事項」に記載されている内容（項目）を、[主体 - 指針番号) 記載内容.]のルールにて識別・表記していく。主体は、開発者（Developer）、提供者（Provider）、利用者（User）の頭文字を用い、指針番号、記載内容の番号は同表に記載の番号にて表記する（例：D-2) i. は AI 開発者の安全性に関する適切なデータの学習についての重要事項を指す）。

表 1. 共通の指針に加えて主体毎に重要となる事項

	第 2 部. 共通の指針	共通の指針に加えて主体毎に重要となる事項		
		第 3 部. AI 開発者 (D)	第 4 部. AI 提供者 (P)	第 5 部. AI 利用者 (U)
1) 人間中心	① 人間の尊厳と個人の自律 ② AI による意思決定・感情の操作等への留意 ③ 偽情報等への留意 ④ 多様性・包摂性の確保 ⑤ 利用者支援 ⑥ 持続可能性の確保	-	-	-
2) 安全性	① 人間の生命・心身・財産、及び環境への配慮 ② 適正利用 ③ 適正学習	i. 適切なデータの学習 ii. 人間の生命・心身・財産、及び環境に配慮した開発 iii. 適正利用に資する開発	i. 人間の生命・心身・財産、及び環境に配慮したリスク対策 ii. 適正利用に資する提供	i. 安全を考慮した適正利用
3) 公平性	① AI モデルの各構成技術に含まれるバイアスへの配慮 ② 人間の判断の介在	i. データに含まれるバイアスへの配慮 ii. AI モデルのアルゴリズム等に含まれるバイアスへの配慮	i. AI システム・サービスの構成やデータに含まれるバイアスへの配慮	i. 入力データ、プロンプトに含まれるバイアスへの配慮
4) プライバシー保護	① AI システム・サービス全般におけるプライバシーの保護	i. 適切なデータの学習 (D-2) i. 再掲)	i. プライバシー保護のための仕組みや対策の導入 ii. プライバシー侵害への対策	i. 個人情報の不適切入力とプライバシー侵害への対策
5) セキュリティ確保	① AI システム・サービスに影響するセキュリティ対策 ② 最新動向への留意	i. セキュリティ対策のための仕組みの導入 ii. 最新動向への留意	i. セキュリティ対策のための仕組みの導入 ii. 脆弱性への対応	i. セキュリティ対策の実施
6) 透明性	① 検証可能性の確保 ② 関連するステークホルダーへの情報提供 ③ 合理的かつ誠実な対応 ④ 関連するステークホルダーへの説明可能性・解釈可能性の向上	i. 検証可能性の確保 ii. 関連するステークホルダーへの情報提供	i. システムアーキテクチャ等の文書化 ii. 関連するステークホルダーへの情報提供	i. 関連するステークホルダーへの情報提供
7) アカウント ビリティ	① トレーサビリティの向上 ② 共通の指針の対応状況の説明 ③ 責任者の明示 ④ 関係者間の責任の分配 ⑤ ステークホルダーへの具体的な対応 ⑥ 文書化	i. AI 提供者への共通の指針の対応状況の説明 ii. 開発関連情報の文書化	i. AI 利用者への共通の指針の対応状況の説明 ii. サービス規約等の文書化	i. 関連するステークホルダーへの説明 ii. 提供された文書の活用と規約の遵守
8) 教育・ リテラシー	① AI リテラシーの確保 ② 教育・リスキリング ③ ステークホルダーへのフォローアップ	-	-	-
9) 公正競争確保	-	-	-	-
10) イノベーション	① オープンイノベーション等の推進 ② 相互接続性・相互運用性への留意 ③ 適切な情報提供	i. イノベーションの機会創造への貢献	-	-

D. 高度な AI システムに関する事業者に通の指針

高度な AI システムに関する事業者は、広島 AI プロセスを経て策定された「全ての AI 関係者向けの広島プロセス国際指針」並びにその基礎となる「高度な AI システムを開発する組織向けの広島プロセス国際指針」を踏まえ、「C. 共通の指針」に加え、以下を遵守すべきである¹⁹。ただし、I) ～ XI) は AI 開発者にのみ適用される内容もあるため、第 3 ～ 5 部に後述のとおり、各主体は適切な範囲で遵守することが求められる。

- I) AI ライフサイクル全体にわたるリスクを特定、評価、軽減するために、高度な AI システムの開発全体を通じて、その導入前及び市場投入前も含め、適切な措置を講じる（「2）安全性」、「6）透明性」）
 - 具体的には、レッドチーム²⁰等の様々な手法を組み合わせ、多様/独立した内外部テスト手段を採用することや、特定されたリスクや脆弱性に対処するための適切な緩和策を実施する
 - 上記テストを支援するために、開発中に行われた意思決定に関するトレーサビリティを確保するように努める
- II) 市場投入を含む導入後、脆弱性、及び必要に応じて悪用されたインシデントやパターンを特定し、緩和する（「5）セキュリティ確保」「7）アカウンタビリティ」）
 - リスクレベルに見合った適切なタイミングで、AI システムの活用状況のモニタリングを実施し、それらに対処するための適切な措置を講じる
 - ✧ 他の利害関係者と協力して、報告されたインシデントの適切な文書化を維持し、特定されたリスクと脆弱性を軽減することが奨励される
- III) 高度な AI システムの能力、限界、適切・不適切な使用領域を公表し、十分な透明性の確保を支援することで、アカウンタビリティの向上に貢献する（「6）透明性」、「7）アカウンタビリティ」）
 - データの出所に始まり、どのような意思決定を行ったかについて、合理的な説明を行い、トレーサビリティを確保するため文書化・公表する
 - 関連するステークホルダーが AI システムの出力を解釈し、AI 利用者や業務外利用者が適切に活用できるようにするために、明確で理解可能な形で文書化・公表する
- IV) 産業界、政府、市民社会、学界を含む、高度な AI システムを開発する組織間での責任ある情報共有とインシデントの報告に向けて取り組む（「5）セキュリティ確保」、「6）透明性」、「7）アカウンタビリティ」、「10）イノベーション」）
 - 具体的には、モニタリング結果の報告書やセキュリティや安全性のリスクに関する関連文書等が含まれる
- V) 特に高度な AI システム開発者に向けた、個人情報保護方針及び緩和策を含む、リスクベースのアプローチに基づく AI ガバナンス及びリスク管理方針を策定し、実施し、開示する（「4）プライバシー保護」、「7）アカウンタビリティ」）

¹⁹ 詳細は、G7 デジタル・技術大臣会合（2023 年 12 月）で採択された「広島 AI プロセス G7 デジタル・技術閣僚声明」における「広島 AI プロセス包括的政策枠組み」の「II. 全ての AI 関係者向け及び高度な AI システムを開発する組織向けの広島プロセス国際指針」を参照。

https://www.soumu.go.jp/menu_news/s-news/01tsushin06_02000283.html

²⁰ 攻撃者がどのように対象組織を攻撃するかの観点で、セキュリティ態勢や対策の有効性を確認するチーム

- 適切な場合には、プライバシーポリシーを公表する
 - AI ガバナンスに関するポリシーや実行するための組織を確立し、開示することが期待される
- VI) AI のライフサイクル全体にわたり、物理的セキュリティ、サイバーセキュリティ、内部脅威に対する安全対策を含む、強固なセキュリティ管理に投資し、実施する（「5」セキュリティ確保）
- 情報セキュリティのための運用上の対策や適切なサイバー/物理的アクセス制御等も検討する
- VII) 技術的に可能な場合は、電子透かしやその他の技術等、AI 利用者及び業務外利用者が、AI が生成したコンテンツを識別できるようにするための、信頼できるコンテンツ認証及び来歴のメカニズムを開発し、導入する（「6」透明性）
- 具体的には、適切かつ技術的に実現可能な場合、組織の高度な AI システムで作成されたコンテンツ認証及び来歴メカニズムが含まれる
 - 透かし等を通じた特定のコンテンツが高度な AI システムで作成されたかどうかを AI 利用者及び業務外利用者が判断できるツールや API の開発に努める
 - ✧ AI 利用者及び業務外利用者が AI システムと相互作用していることを知ることができるよう、ラベリングや免責事項の表示等、その他の仕組みを導入することが奨励される
- VIII) 社会的、安全、セキュリティ上のリスクを軽減するための研究を優先し、効果的な軽減策への投資を優先する（「10」イノベーション）
- AI の安全性、セキュリティ、信頼性の向上やリスクへの対処に関する研究が含まれる
- IX) 世界の最大の課題、特に気候危機、世界保健、教育等（ただしこれらに限定されない）に対処するため、高度な AI システムの開発を優先する（「10」イノベーション）
- 信頼性のある人間中心の AI 開発に向けた取組を実施し、同時に業務外利用者も含めたリテラシーの向上のための支援をする
- X) 国際的な技術規格の開発を推進し、適切な場合にはその採用を推進する（「10」イノベーション）
- 電子透かしを含む国際的な技術標準とベストプラクティスの開発に貢献し、適切な場合にはそれを利用し、標準開発組織（SDO）と協力する
- XI) 適切なデータインプット対策を実施し、個人データ及び知的財産を保護する（「2」安全性、「3」公平性）
- 有害な偏見バイアスを軽減するために、訓練データやデータ収集等、データの質を管理するための適切な措置を講じることが奨励される
 - 訓練用データセットの適切な透明性も支援されるべきであり、適用される法的枠組みを遵守する
- XII) 高度な AI システムの信頼でき責任ある利用を促進し、貢献する（「5」セキュリティ確保、「8」教育・リテラシー）
- 高度な AI システムが特定のリスク（例えば偽情報の拡散に関するもの）をどのように増大させるか、新たなリスクをどのように生み出すか等の課題を含め、各主体及びステークホルダーのリテラシーや認識等の向上のための機会を提供する

- 各主体間で連携し、高度な AI システムに関する新たなリスクや脆弱性を特定し、対処するための情報共有を行うことが奨励される

E. AI ガバナンスの構築

各主体間で連携しバリューチェーン全体で「共通の指針」を実践し AI を安全安心に活用していくためには、AI に関するリスクをステークホルダーにとって受容可能な水準で管理しつつ、そこからもたらされる便益を最大化するための、AI ガバナンスの構築が重要となる。また、「Society 5.0」を実現するためには、サイバー空間とフィジカル空間を高度に融合させたシステム（CPS）の社会実装を進めつつ、その適切な AI ガバナンスを構築することが不可欠である。CPS を基盤とする社会は、複雑で変化が速く、リスクの統制が困難であり、こうした社会の変化に応じて、AI ガバナンスが目指すゴールも常に変化していく。そのため、事前にルールや手順が固定された AI ガバナンスではなく、企業・法規制・インフラ・市場・社会規範といった様々なガバナンスシステムにおいて、「環境・リスク分析」「ゴール設定」「システムデザイン」「運用」「評価」といったサイクルを、マルチステークホルダーで継続的かつ高速に回転させていく、「アジャイル・ガバナンス」の実践が重要となる²¹。

なお、具体的な検討にあたっては開発・提供・利用予定の AI のもたらすリスクの程度及び蓋然性や、各主体の資源制約に配慮することが重要である。

- ① まず、AI システム・サービスがライフサイクル全体においてもたらしうる便益/リスクや開発・運用に関する社会的受容、「外部環境の変化」や AI 習熟度等を踏まえ、対象となる AI システム・サービスに関連する「環境・リスク分析」を実施する
- ② これを踏まえ、AI システム・サービスを開発・提供・利用するか否かを判断し、開発・提供・利用する場合には、AI ガバナンスに関するポリシーの策定等を通じて「AI ガバナンス・ゴール²²の設定」を検討する。なお、このゴールは、各主体の存在意義、理念・ビジョンといった経営上のゴールと整合したものとなるように設定する
- ③ 更に、このゴールを達成するための「AI マネジメントシステムの設計」を行った上で、これを「運用」する。その際には、各主体が、AI ガバナンス・ゴールとその運用状況について外部の「ステークホルダー」に対する透明性、アカウントビリティ（公平性等）を果たすようにする
- ④ その上で、リスクアセスメント等をはじめとして、AI マネジメントシステムが有効に機能しているかを継続的にモニタリングし、「評価」及び継続的改善を実施する
- ⑤ AI システム・サービスの運用開始後も、規制等の社会的制度の変更等の「外部環境の変化」を踏まえ、再び「環境・リスク分析」を実施し、必要に応じてゴールを見直す

²¹ 別添（付属資料）において、経済産業省「AI 原則実践のためのガバナンス・ガイドライン Ver. 1.1」を土台とした、AI ガバナンス実践のための詳細解説に加え、各主体の具体的な取組事項としての「行動目標」及び各主体を想定した仮想的な「実践例」も記載しているため、ご参照のこと。

²² AI ガバナンス・ゴールとして、本ガイドラインに記載の「共通の指針」への対応事項からなる自社の取組方針（「AI ポリシー」等、呼称は各主体により相違）や、「共通の指針」への対応事項を包含しつつそれ以外の要素を含む取組方針（データ活用ポリシー等）を設定すること等が考えられる。また、AI を活用することによって包摂性を向上させる等の便益を高めるための指針を提示してもよい。また、呼称も各主体に委ねられている。




図6. アジャイル・ガバナンスの基本的なモデル

また、AI ガバナンスの検討にあたっては、バリューチェーンを念頭に置き、以下の点に留意することが重要である。

- バリューチェーン/リスクチェーンの観点で主体間の連携を確保する
 - ✧ 複数主体にまたがる論点：AI リスク把握、品質の向上、各 AI システム・サービスが相互に繋がることによる新たな価値の創出（System of Systems）、AI 利用者のリテラシー向上等
 - ✧ 主体間で整理が必要になりうる点：学習用データ・生成された AI モデルに関する権利関係の契約等
- データの流通をはじめとしたリスクチェーンの明確化と開発・提供・利用の各段階に適したリスク管理、AI ガバナンス体制の構築を実施する
 - ✧ AI 開発からサービス実施にわたるバリューチェーン/リスクチェーンが複数国にまたがることが想定される場合、データの自由な越境移転（Data Free Flow with Trust、以下「DFFT」という）の確保のための適切な AI ガバナンスに係る国際社会の検討状況と、それを踏まえた相互運用性（「標準」と「枠組み間の相互運用性」の二側面）

これらを効果的な取組とするためには、経営層がリーダーシップを発揮することが重要である。なお、その際は、短期的な利益の追求の観点から単なるコストと捉えるのではなく、各主体の持続的成長と中長期的な発展を志向した先行投資として捉えることが重要である。そのリーダーシップの下、上記のサイクルを回しつつ、具体的に各組織の戦略や企業体制に AI ガバナンスを落とし込んでいくことで、各組織の中で文化として根付かせることが期待される。

第3部 AI 開発者に関する事項

AI 開発者は、AI モデルを直接的に設計し変更を加えることができるため、AI システム・サービス全体においても AI の出力に与える影響力が高い。また、イノベーションを牽引することが社会から期待され、社会全体に与える影響が非常に大きい。このため、自身の開発する AI が提供・利用された際にどのような影響を与えるか、事前に可能な限り検討し、対応策を講じておくことが重要となる。

AI 開発の現場においては、時に、正確性を重視するためにプライバシーや公平性が損なわれたり、プライバシーを重んじすぎて透明性が損なわれたり等、リスク同士や倫理観の衝突の場面がある。その場合、当該事業者における経営リスクや社会的な影響力を踏まえ、適宜判断・修正していくことが重要である。また、AI システムにおいて予期せぬ事故が発生した際に、AI のバリューチェーンに連なる者は、全て何らかの説明を求められる立場に将来立つ可能性があることを念頭に置き、AI 開発者としても、どのような関与を行ったかについて、合理的な説明を行うことができるよう記録を残すことが重要である。

以下に AI 開発者にとって重要な事項を挙げる。

● データ前処理・学習時

➤ D-2) i. 適切なデータの学習

- ◇ プライバシー・バイ・デザイン等を通じて、学習時のデータについて、適正に収集するとともに、第三者の機密情報、個人情報、知的財産権に留意が必要なもの等が含まれている場合には、法令に従って適切に扱うことを、AI のライフサイクル全体を通じて確保する（「2）安全性」、「4）プライバシー保護」、「5）セキュリティ確保」）
- ◇ 学習前・学習全体を通じて、データのアクセスを管理するデータ管理・制限機能の導入検討を行う等、適切な保護措置を実施する（「2）安全性」、「5）セキュリティ確保」）

➤ D-3) i. データに含まれるバイアスへの配慮

- ◇ 学習データ、モデルの学習過程によってバイアス（学習データには現れない散在的なバイアスを含む）が含まれることに留意し、データの質を管理するための相当の措置を講じる（「3）公平性」）
- ◇ 学習データ、モデルの学習過程からバイアスを完全に排除できないことを踏まえ、必要に応じて、単一手法ではなく多様な手法に基づく開発を並行して行う（「3）公平性」）

● AI 開発時

➤ D-2) ii. 人間の生命・心身・財産、及び環境に配慮した開発

- ◇ AI 開発者は、ステークホルダーの生命・心身・財産、及び環境に危害を及ぼすことがないよう、以下の事項を検討する（「2）安全性」）
 - 様々な状況下で予想される利用条件下でのパフォーマンスだけでなく、予期しない環境で

の利用にも耐えうる性能の要求

- リスク（連動するロボットの制御不能や不適切な出力等）を最小限に抑える方法（ガードレール技術等）

➤ D-2) iii. 適正利用に資する開発

- ◇ AI 開発者は、開発時に想定していない提供・利用により危害が発生することを避けるため、安全に利用可能な範囲を設定して開発を行う（「2）安全性」）
- ◇ 事前学習済の AI モデルに対する事後学習を行う場合に、学習済 AI モデルを適切に選択する（商用利用可能なライセンスかどうか、事前学習データ、学習・実行に必要なスペック等）（「2）安全性」）

➤ D-3) ii. AI モデルのアルゴリズム等に含まれるバイアスへの配慮

- ◇ AI モデルを構成する各技術要素（AI 利用者が入力するプロンプト、AI モデルの推論時に参照する情報や連携する外部サービス等）によってバイアスが含まれることまで検討する（「3）公平性」）
- ◇ AI モデルからバイアスを完全に排除できないことを踏まえ、単一手法ではなく多様な手法に基づく開発を並行して行う（「3）公平性」）

➤ D-5) i. セキュリティ対策のための仕組みの導入

- ◇ AI システムの開発の過程を通じて、採用する技術の特性に照らし適切にセキュリティ対策を講ずる（セキュリティ・バイ・デザイン）（「5）セキュリティ確保」）

➤ D-6) i. 検証可能性の確保

- ◇ AI の予測性能や出力の品質が、活用後に大きく変動する可能性や想定する精度に達しないこともある特性を踏まえ、事後検証のための作業記録を保存しつつ、その品質の維持・向上を行う（「2）安全性」、「6）透明性」）

● **AI 開発後**

➤ D-5) ii. 最新動向への留意

- ◇ AI システムに対する攻撃手法は日々新たなものが生まれており、これらのリスクに対応するため、開発の各工程で留意すべき点を確認する²³（「5）セキュリティ確保」）

➤ D-6) ii. 関連するステークホルダーへの情報提供

- ◇ AI 開発者は、自らの開発する AI システムについて、例えば以下の事項を適時かつ適切に関連するステークホルダーに（AI 提供者を通じて行う場合を含む）説明できるようにする（「6）透明性」）
 - AI システムの学習等による出力又はプログラムの変化の可能性（「1）人間中心」）

²³ 総務省「AI セキュリティ情報発信ポータル」（https://www.mbsd.jp/aisec_portal/）等を通じて情報を収集することができる。

- AI システムの技術的特性、安全性確保の仕組み、利用の結果生じる可能性のある予見可能なリスク及びその緩和策等の安全性に関する情報（「2）安全性」）
 - 開発時に想定していない提供・利用により危害が発生することを避けるための AI 開発者が意図する利用範囲（「2）安全性」）
 - AI システムの動作状況に関する情報、不具合の原因と対応状況（「2）安全性」）
 - 更新を行った場合の内容とその理由の情報（「2）安全性」）
 - AI モデルで学習するデータの収集ポリシーやその学習方法及び実施体制等（「3）公平性」、「4）プライバシー保護」、「5）セキュリティ確保」）
- D-7) i. AI 提供者への共通の指針の対応状況の説明
- ◇ AI 開発者は、AI 提供者に対して、AI には活用後に予測性能や出力の品質が大きく変動する可能性や想定する精度に達しないこともある特性がある旨や、その結果生じるリスク等の情報提供と説明を行う。具体的には以下の事項を周知する（「7）アカウントビリティ」）
- AI モデルを構成する各技術要素（学習データ、モデルの学習過程、AI 利用者が入力すると想定するプロンプト、AI モデルの推論時に参照する情報や連携する外部サービス等）において含まれる可能性があるバイアスへの対応等（「3）公平性」）
- D-7) ii. 開発関連情報の文書化
- ◇ AI 開発者は、トレーサビリティと透明性の向上のため、AI システムの開発過程、意思決定に影響を与えるデータ収集やラベリング、使用されたアルゴリズム等について、可能な限り第三者が検証できるような形で文書化する（「7）アカウントビリティ」）

以下に、AI 開発者の取組が期待される事項を挙げる。

- D-10) i. イノベーションの機会創造への貢献
- ◇ AI 開発者は、可能な範囲で以下の事項を実施し、イノベーションの機会の創造に貢献することが期待される（「10）イノベーション」）
- 品質・信頼性や開発の方法論等の研究開発を行う
 - 持続的な経済成長の維持と社会課題の解決策が提示されるよう貢献する
 - DFFT 等の国際議論の動向の参照、AI 開発者コミュニティや学会への参加等の取組を行う等、国際化・多様化や産学官連携を行う
 - 社会全体への情報提供を行う

「高度な AI システムを開発する組織向けの広島プロセス国際行動規範」における追加的な記載事項

なお、高度な AI システムを開発する AI 開発者については、上記に加え、「第 2 部 D. 高度な AI システムに係る事業者に通じる共通の指針」及び「高度な AI システムを開発する組織向けの広島プロセス国際行動規範」²⁴を遵守すべきである。

以下、「第 2 部 D. 高度な AI システムに係る事業者に通じる共通の指針」との比較において、当該「行動規範」において追加的に記載されている事項を示す。なお、当該「行動規範」全体の内容については、「別添 3. A. 高度な AI システムの開発にあたって遵守すべき事項」を参照のこと。

- I. AI ライフサイクル全体にわたるリスクを特定、評価、軽減するために、高度な AI システムの開発全体を通じて、その導入前及び市場投入前も含め、適切な措置を講じる
 - リスク軽減のための緩和策を文書化するとともに、定期的に更新すべき。また、各主体はセクターを超えた関係者と連携してこれらのリスクへの緩和策を評価し、採用すべき
- II. 市場投入を含む導入後、脆弱性、及び必要に応じて悪用されたインシデントやパターンを特定し、緩和する
 - 報奨金制度、コンテスト、賞品等を通じて、責任を持って弱点を開示するインセンティブを与えることの検討を奨励
- III. 高度な AI システムの能力、限界、適切・不適切な使用領域を公表し、十分な透明性の確保を支援することで、アカウントビリティの向上に貢献する
 - 透明性報告書に加えて、使用説明書や関連する技術的文書等が含まれ、これらは最新に保たれるべき
- IV. 産業界、政府、市民社会、学界を含む、高度な AI システムを開発する組織間での責任ある情報共有とインシデントの報告に向けて取り組む
 - AI システムの安全性やセキュリティ等を確保するための共有の基準、メカニズムを開発、推進すべき。加えて、AI のライフサイクル全体にわたって、適切な文書化や他の主体との協力、関連情報の共有や社会への報告を実施すべき
- V. 特に高度な AI システム開発者に向けた、個人情報保護方針及び緩和策を含む、リスクベースのアプローチに基づく AI ガバナンス及びリスク管理方針を策定し、実施し、開示する
 - 可能であれば、AI のライフサイクル全体を通じて、AI リスクを特定・評価・予防・対処するための AI ガバナンス方針を策定・実施・開示し、定期的に更新すべき。また、事業者の職員等に対する教育方針を確立すべき
- VI. AI のライフサイクル全体にわたり、物理的セキュリティ、サイバーセキュリティ、内部脅威に対する安全対策を含む、強固なセキュリティ管理に投資し、実施する

²⁴ 広島 AI プロセスに関する G7 首脳声明「高度な AI システムを開発する組織向けの広島プロセス国際行動規範」（2023 年 10 月）

なお、同文書は高度な AI システムにおける動向に対応して、既存の OECD AI 原則に基づいて構築される living document であることに注意が必要である。

<https://www.mofa.go.jp/mofaj/files/100573472.pdf>

- 高度な AI システムのサイバーセキュリティリスクの評価や、適切で安全な環境での作業と文書の保管の義務付けをすべき。無許可で公開されるリスク等に対応するための対策、知的財産や企業秘密の保護と整合性のある強固な内部脅威検知プログラムの確立をすべき
- VII. 技術的に可能な場合は、電子透かしやその他の技術等、AI 利用者及び業務外利用者が、AI が生成したコンテンツを識別できるようにするための、信頼できるコンテンツ認証及び来歴のメカニズムを開発し、導入する
 - 透かしや識別子を利用することに加え、各主体がこの分野の状況を前進させるために協力し、研究に投資すべき
- VIII. 社会的、安全、セキュリティ上のリスクを軽減するための研究を優先し、効果的な軽減策への投資を優先する
 - 民主的価値の維持や人権の尊重、子どもや社会的弱者の保護等、リスクに対処するための優先的な研究、協力等を行うべき。加えて、環境や気候への影響を含むリスクを積極的に管理し、リスクに関する研究とベストプラクティスを共有することを奨励
- IX. 世界の最大の課題、特に気候危機、世界保健、教育等（ただしこれらに限定されない）に対処するため、高度な AI システムの開発を優先する
 - 個人や地域社会が AI の利用から利益を得るためのデジタル・リテラシーのイニシアティブを支援し、一般市民の教育と訓練を促進すべき。また、市民社会やコミュニティ・グループとの協力により、課題の特定や解決策の開発もすべき
- X. 国際的な技術規格の開発を推進し、適切な場合にはその採用を推進する
 - 国際的な技術標準の開発に加え、AI が生成したコンテンツと他のコンテンツを区別できる技術標準の開発をすべき
- XI. 適切なデータインプット対策を実施し、個人データ及び知的財産を保護する
 - データの質の管理のための適切な対策として、透明性、プライバシー保護のための機械学習や、機密データ等の漏洩のテストとファインチューニングを含む対策を実施し、著作権で保護されたコンテンツを含め、プライバシーや知的財産等に関する権利を尊重するために適切なセーフガードの導入を奨励される

第4部 AI 提供者に関する事項

AI 提供者は、AI 開発者が開発する AI システムに付加価値を加えて AI システム・サービスを AI 利用者に提供する役割を担う。AI を社会に普及・発展させるとともに、社会経済の成長にも大きく寄与する一方で、社会に与える影響の大きさゆえに、AI 提供者は、AI の適正な利用を前提とした AI システム・サービスの提供を実現することが重要となる。そのため、AI システム・サービスに組み込む AI が当該システム・サービスに相応しいものか留意することが重要である。加えて、ビジネス戦略や社会環境の変化によって AI に対する期待値が変わることも考慮して、適切な変更管理、構成管理やサービスの維持を行う。

AI システム・サービスを AI 開発者が意図している範囲で実装し、正常稼働や適正な運用を継続し、AI 開発者に対しては、AI システムが適正に開発されるように求めることが重要である。AI 利用者に対しては、AI システムの提供及び運用のサポート又は AI システムの運用をしつつ AI サービスを提供することが重要である。提供に際し、社会やステークホルダーに対する権利侵害等、意図しない不利益を生じさせることがないように留意し、合理的な範囲でインシデント事例等を含む関連情報の共有を行い、より安全、安心で信頼できる AI システム・サービスを提供することが期待される。

以下に AI 提供者にとって、重要な事項を挙げる。

● AI システム実装時

- P-2) i. 人間の生命・心身・財産、及び環境に配慮したリスク対策
 - ✧ AI 利用者を含む関連するステークホルダーの生命・心身・財産、及び環境に危害を及ぼすことがないように、提供時点で予想される利用条件下でのパフォーマンスだけでなく、様々な状況下で AI システムがパフォーマンスレベルを維持できるようにし、リスク（連動するロボットの制御不能や不適切な出力等）を最小限に抑える方法（ガードレール技術等）を検討する（「2）安全性」）
- P-2) ii. 適正利用に資する提供
 - ✧ AI システム・サービスの利用上の留意点を正しく定める（「2）安全性」）
 - ✧ AI 開発者が設定した範囲で AI を活用する（「2）安全性」）
 - ✧ 提供時点でデータの正確性・必要な場合には最新性（データが適切であること）等を担保する（「2）安全性」）
 - ✧ AI 開発者が開発した AI の想定利用環境と AI システム・サービスの利用者の利用環境に違い等がないかを検討する（「2）安全性」）
- P-3) i. AI システム・サービスの構成やデータに含まれるバイアスへの配慮
 - ✧ 提供時点でデータの公平性の担保、参照する情報や連携する外部サービス等のバイアスを検討する（「3）公平性」）
 - ✧ AI モデルの入出力や判断根拠を定期的に評価し、バイアスの発生をモニタリングする。また、必要に応じて、AI 開発者に AI モデルを構成する各技術要素のバイアスの再評価、評価結果に

基づく AI モデル改善の判断を促す（「3」 公平性）」

- ◇ AI モデルの出力結果を受け取る AI システムやユーザーインターフェースにおいて、ビジネスプロセスや利用者の判断を恣意的に制限するようなバイアスが含まれてしまう可能性を検討する（「3」 公平性）」
- P-4) i. プライバシー保護のための仕組みや対策の導入
 - ◇ AI システムの実装の過程を通じて、採用する技術の特性に照らし適切に個人情報へのアクセスを管理・制限する仕組みの導入等のプライバシー保護のための対策を講ずる（プライバシー・バイ・デザイン）（「4」 プライバシー保護）」
- P-5) i. セキュリティ対策のための仕組みの導入
 - ◇ AI システム・サービスの提供の過程を通じて、採用する技術の特性に照らし適切にセキュリティ対策を講ずる（セキュリティ・バイ・デザイン）（「5」 セキュリティ確保）」
- P-6) i. システムアーキテクチャ等の文書化
 - ◇ トレーサビリティと透明性の向上のため、意思決定に影響を与える提供する AI システムのシステムアーキテクチャやデータの処理プロセス等について文書化する（「6」 透明性）」

● AI システム・サービス提供後

- P-2) ii. 適正利用に資する提供
 - ◇ 適切な目的で AI システム・サービスが利用されているかを定期的に検証する（「2」 安全性）」
- P-4) ii. プライバシー侵害への対策
 - ◇ AI システム・サービスにおけるプライバシー侵害に関して適宜情報収集し、侵害があった場合は適切に対処するとともに、再発の防止を検討する（「4」 プライバシー保護）」
- P-5) ii. 脆弱性への対応
 - ◇ AI システムに対する攻撃手法も数多く生まれているため、最新のリスクやそれに対応するために提供の各工程で気を付けるべき点の動向を確認する。また、脆弱性の解消を検討する（「5」 セキュリティ確保）」
- P-6) ii. 関連するステークホルダーへの情報提供
 - ◇ 提供する AI システム・サービスについて、例えば以下の事項を平易かつアクセスしやすい形で、適時かつ適切に説明できるようにしておく（「6」 透明性）」
 - AI を利用しているという事実や適切/不適切な使用方法等（「6」 透明性）」
 - 提供する AI システム・サービスの技術的特性、利用によりもたらす結果より生じる可能性のある予見可能なリスク及びその緩和策等の安全性に関する情報（「2」 安全性）」

- AI システム・サービスの学習等による出力又はプログラムの変化の可能性（「1）人間中心」）
- AI システム・サービスの動作状況に関する情報、不具合の原因と対応状況、インシデント事例等（「2）安全性」）
- 更新を行った場合の更新内容とその理由の情報（「2）安全性」）
- AI モデルにて学習するデータの収集ポリシーやその学習方法及び実施体制等（「3）公平性」、「4）プライバシー保護」、「5）セキュリティ確保」）

➤ P-7) i. AI 利用者への共通の指針の対応状況の説明

- ✧ AI 利用者に適正利用を促し、以下の情報を AI 利用者に提供する（「7）アカウントビリティ」）
 - 正確性・必要な場合には最新性（データが適切であること）等が担保されたデータの利用についての注意喚起（「2）安全性」）
 - コンテキスト内学習による不適切な AI モデルの学習に対する注意喚起（「2）安全性」）
 - 個人情報を入力する際の留意点（「4）プライバシー保護」）
- ✧ 提供する AI システム・サービスへの個人情報の不適切入力についての注意喚起（「4）プライバシー保護」）

P-7) ii. サービス規約等の文書化

- ✧ AI 利用者、業務外利用者に向けたサービス規約を作成する（「7）アカウントビリティ」）
- ✧ プライバシーポリシーを明示する（「7）アカウントビリティ」）

なお、高度な AI システムを取り扱う AI 提供者は、第 2 部 D. 高度な AI システムに関係する事業者に通の指針について以下のように対応する。

- I) ～XI) 適切な範囲で遵守すべきである
- XII) 遵守すべきである

第5部 AI 利用者に関する事項

AI 利用者は、AI 提供者から安全、安心で信頼できる AI システム・サービスの提供を受け、AI 提供者が意図した範囲内で継続的に適正利用及び必要に応じて AI システムの運用を行うことが重要である。それにより業務効率化や生産性、創造性の向上等 AI によるイノベーションの最大の恩恵を受けることが可能となる。また、人間の判断を介在させることにより、人間の尊厳や自律を守りながら自己や社会を潤し、予期せぬ事故を防ぐことも可能となる。

AI 利用者は、社会やステークホルダーから AI の能力や出力結果に関して説明を求められた場合、AI 提供者等のサポートを得てその要望に応えることが期待され、関係者に留まらず、社会及びステークホルダーからの理解を得られるよう努めることに加え、より効果的な AI 利用のために必要な知見習得も期待される。

以下に AI 利用者にとって、重要な事項を挙げる。

● AI システム・サービス利用時

- U-2) i. 安全を考慮した適正利用
 - ✧ AI 提供者が定めた利用上の留意点を遵守して、AI 提供者が設計において想定した範囲内で AI システム・サービスを利用する（「2）安全性」）
 - ✧ 正確・必要な場合には最新性（データが適切であること）等が担保されたデータの入力を行う（「2）安全性」）
 - ✧ AI の出力について精度やリスクの程度を理解し、様々なリスク要因を確認した上で利用する（「2）安全性」）
- U-3) i. 入力データ、プロンプトに含まれるバイアスへの配慮
 - ✧ 著しく公平性を欠くことがないよう公平性が担保されたデータの入力を行い、プロンプトに含まれるバイアスに留意して、責任をもって AI 出力結果の事業利用判断を行う（「3）公平性」）
- U-4) i. 個人情報の不適切入力とプライバシー侵害への対策
 - ✧ AI システム・サービスへ個人情報を入力することがないよう注意を払う（「4）プライバシー保護」）
 - ✧ AI システム・サービスにおけるプライバシー侵害に関して適宜情報収集し、防止を検討する（「4）プライバシー保護」）
- U-5) i. セキュリティ対策の実施
 - ✧ AI 提供者によるセキュリティ上の留意点を遵守する（「5）セキュリティ確保」）
- U-6) i. 関連するステークホルダーへの情報提供
 - ✧ 著しく公平性を欠くことがないよう公平性が担保されたデータの入力を行い、プロンプトに含まれるバイアスに留意して AI システム・サービスから出力結果を取得し、結果を事業判断に活用し

た際は、その結果が必要な関連するステークホルダーに周知する（「3）公平性」、「6）透明性」）

➤ U-7) i. 関連するステークホルダーへの説明

- ✧ 関連するステークホルダーの性質に応じて害のない範囲で、適正な利用方法を含む情報提供を平易かつアクセスしやすい形で行う（「7）アカウントビリティ」）
- ✧ 関連するステークホルダーから提供されるデータを用いることが予定されている場合には、AI の特性や用途、提供先との接点、プライバシーポリシー等を踏まえ、データ提供の手段、形式等について、あらかじめ当該ステークホルダーに情報提供する（「7）アカウントビリティ」）
- ✧ 当該 AI の出力結果を特定の個人又は集団に対する評価の基礎とする場合には、AI を利用している旨を評価対象となっている当該特定の個人又は集団に対して通知し、必要に応じて合理的な範囲で人間による判断を求める機会を設ける（「1）人間中心」）
- ✧ 利用する AI システム・サービスの性質に応じて、関連するステークホルダーからの問合せに対応する窓口を設置し、AI 提供者とも連携の上説明や要望の受付を行う（「7）アカウントビリティ」）

➤ U-7) ii. 提供された文書の活用と規約の遵守

- ✧ AI 提供者から提供された AI システム・サービスについての文書を適切に保管・活用する（「7）アカウントビリティ」）
- ✧ AI 提供者が定めたサービス規約を遵守する（「7）アカウントビリティ」）

なお、高度な AI システムを取り扱う AI 利用者は、第 2 部 D. 高度な AI システムに関係する事業者に共通の指針について以下のように対応する。

- I) ～XI) 適切な範囲で遵守すべきである
- XII) 遵守すべきである

AI 事業者ガイドライン案
別添（付属資料）

別添.はじめに.....	2
別添 1.第 1 部関連.....	5
A.AI に関する前提.....	5
B.AI による便益/リスク.....	12
別添 2.第 2 部関連 [E.AI ガバナンスの構築].....	18
A.経営層による AI ガバナンスの構築とモニタリング	20
B.AI ガバナンスの構築に関する実際の取組事例.....	61
別添 3.AI 開発者向け.....	62
A. 本編「第 3 部 AI 開発者に関する事項」の解説.....	63
B. 本編「第 2 部」の「共通の指針」の解説	85
別添 4.AI 提供者向け.....	100
A. 本編「第 4 部 AI 提供者に関する事項」の解説.....	100
B.本編「第 2 部」の「共通の指針」の解説.....	120
別添 5.AI 利用者向け.....	128
A.本編「第 5 部 AI 利用者に関する事項」の解説.....	128
B.本編「第 2 部」の「共通の指針」の解説.....	138
別添 6.「AI・データの利用に関する契約ガイドライン」を参照する際の主な留意事項について	142

別添.はじめに

別添の構成と読者への期待

AI事業者ガイドライン案本編（以降本編）にて、本ガイドライン案で対象とする主体「AI 開発者」、「AI 提供者」、「AI 利用者」が念頭に置くべき基本理念（= why）と、理念を踏まえ AI に関し行うべき取組の指針（= what）を示した。各主体は指針を実現するにあたり、具体的なアプローチを決めて実践する必要がある、AI事業者ガイドライン別添（付属資料、以降別添）では、参考となる実践（= how）について扱い、具体的な取組についての Reference の位置づけで作成している。

別添 1 にて本ガイドラインで前提としている AI システムの例や AI システム・サービスの具体的な活用例、主体の関わり等、業種、業務ごとの AI による便益の例、事例に基づくリスクの例を記載している。また、別添 2 にて AI ガバナンスの構築のために事業者がとるべき行動について実践例を通して理解を深められる内容を盛り込んでいる。

加えて、別添 3 にて「AI 開発者」向け、別添 4 にて「AI 提供者」向け、別添 5 にて「AI 利用者」向けの重要事項の解説を記載している。それぞれ、A、B の 2 パートに分け、A では本編 3 部～5 部に記載した主体別の重要事項に関して補足的な解説と実践にあたっての具体的な手法を記載している。B では、本編 3～5 部に記載していないものの、本編 2 部記載の共通の指針の中で特に意識すべき内容について、具体的な手法を記載している。

さらに、データを扱う契約にあたって参考となる「AI・データの利用に関する契約ガイドライン」を参照する際の留意事項を別添 6 にて記載している。（「図 1. 本ガイドラインの構成」記載の別添 7～9 は本資料とは別資料として作成）



図 1. 本ガイドラインの構成

本編及び別添の記載内容を確認する中で別添 1 を合わせて参照することで、記載の前提となっている AI 及び AI による便益/リスクを具体的に把握することができ、記載内容をより深く理解ができるようになると想定している。また、別添 2 を参照することで、事業者自身の AI 活用における AI ガバナンスの構築のための行動目標を具体的な実践例を通して把握することが可能となるため、「AI 開発者」、「AI 提供者」、「AI 利用者」の全主体は別添 1、2 を参照することが重要となる。

別添 3～5 は主体別となっているため、各主体それぞれが該当する内容を確認し、把握した実践例を参考に取組を検討、実践することが重要となる。自身とは異なる主体の記載内容については、本編と合わせて参照しておくことで、バリューチェーン全体でのリスクの低減等の施策検討につながりうるため、可能な限り把握することが期待される。

加えて、AI によるリスクを抑えつつ便益を享受する取組の立案、実践を確実に推進するため、別添 7（別資料）のチェックリストを参考に、各事業者の事業内容や状況に合ったチェックリストを作成の上、有効活用することも重要となる。チェックリストには本編 2 部 C. 記載の指針及び重要事項が実施できているか確認できるよう、フォーマットに 10 の指針と確認事項としての重要事項を記載している。各事業者がそれぞれの状況に応じ、カスタマイズして必要に応じて活用することを前提に作成しており、参考に AI 開発者、AI 提供者、AI 利用者それぞれが作成した場合の記載例も掲載している。また、本編 2 部 D 記載の高度な AI システムに関係する事業者が重要事項実施の確認に活用できるフォーマット及び別添 2 に記載している AI ガバナンスの構築の確認に活用できるフォーマットも載せており、取組から AI ガバナンスまでの実施確認に資する構成としている。実際の AI サービスは目的・活用技術・データ・利用環境等によって多様なユースケースが想定され、技術の発展、外部環境の変化等も踏まえつつ、AI 開発者、AI 提供者、AI 利用者が連携して最適なアプローチを検討することが期待され、効果的な連携の一助となると想定している。

なお、本ガイドラインは本編、別添を通してリスクベースアプローチの考えに基づいて記載しており、事業者も同様に自らが重点的に対策すべきことと不要なことを見極め、効果的な施策、AI ガバナンス構築を実現することを期待している。別添は本編で示された方向性を達成する手段の一例であり、本編に記載されている指針全てに関する実践及び解説を網羅的に記載しておらず、また、事業者の事業運営形態も様々であることが想定されることから、この付属資料を全て記載とおりに実施することが求められているものではない。

本ガイドラインにおける表現の解説

なお、本編同様以降は「表 1. 主体共通の指針主体とそれに加えて重要となる主体ごとの事項」に記載されている内容（項目）を、[主体 - 指針番号] 記載内容.] のルールにて識別・表記していく。主体は、開発者（Developer）、提供者（Provider）利用者（（Business）User）の頭文字を用い、指針番号、記載内容の番号は同表に記載の番号にて表記する（例：D-2） i. は AI 開発者の安全性に関する適切なデータの学習についての重要事項を指す）。表 1 において、「-」が記載されている箇所は、各主体による本編「2 部 C. 共通の指針」記載の事項に基づく対応が期待されており、対応不要を意味するものではない。

表 1. 主体共通の指針に加えて主体毎に重要となる事項

	第 2 部. 共通の指針	共通の指針に加えて主体毎に重要となる事項		
		第 3 部. AI 開発者 (D)	第 4 部. AI 提供者 (P)	第 5 部. AI 利用者 (U)
1) 人間中心	① 人間の尊厳と個人の自律 ② AI による意思決定・感情の操作等への留意 ③ 偽情報等への留意 ④ 多様性・包摂性の確保 ⑤ 利用者支援 ⑥ 持続可能性の確保	-	-	-
2) 安全性	① 人間の生命・心身・財産、及び環境への配慮 ② 適正利用 ③ 適正学習	i. 適切なデータの学習 ii. 人間の生命・心身・財産、及び環境に配慮した開発 iii. 適正利用に資する開発	i. 人間の生命・心身・財産、及び環境に配慮したリスク対策 ii. 適正利用に資する提供	i. 安全を考慮した適正利用
3) 公平性	① AI モデルの各構成技術に含まれるバイアスへの配慮 ② 人間の判断の介在	i. データに含まれるバイアスへの配慮 ii. AI モデルのアルゴリズム等に含まれるバイアスへの配慮	i. AI システム・サービスの構成やデータに含まれるバイアスへの配慮	i. 入力データ、プロンプトに含まれるバイアスへの配慮
4) プライバシー保護	① AI システム・サービス全般におけるプライバシーの保護	i. 適切なデータの学習 (D-2) i. 再掲)	i. プライバシー保護のための仕組みや対策の導入 ii. プライバシー侵害への対策	i. 個人情報の不適切入力とプライバシー侵害への対策
5) セキュリティ確保	① AI システム・サービスに影響するセキュリティ対策 ② 最新動向への留意	i. セキュリティ対策のための仕組みの導入 ii. 最新動向への留意	i. セキュリティ対策のための仕組みの導入 ii. 脆弱性への対応	i. セキュリティ対策の実施
6) 透明性	① 検証可能性の確保 ② 関連するステークホルダーへの情報提供 ③ 合理的かつ誠実な対応 ④ 関連するステークホルダーへの説明可能性・解釈可能性の向上	i. 検証可能性の確保 ii. 関連するステークホルダーへの情報提供	i. システムアーキテクチャ等の文書化 ii. 関連するステークホルダーへの情報提供	i. 関連するステークホルダーへの情報提供
7) アカウンタビリティ	① トレーサビリティの向上 ② 共通の指針の対応状況の説明 ③ 責任者の明示 ④ 関係者間の責任の分配 ⑤ ステークホルダーへの具体的な対応 ⑥ 文書化	i. AI 提供者への共通の指針の対応状況の説明 ii. 開発関連情報の文書化	i. AI 利用者への共通の指針の対応状況の説明 ii. サービス規約等の文書化	i. 関連するステークホルダーへの説明 ii. 提供された文書の活用と規約の遵守
8) 教育・リテラシー	① AI リテラシーの確保 ② 教育・リスキリング ③ ステークホルダーへのフォローアップ	-	-	-
9) 公正競争確保	-	-	-	-
10) イノベーション	① オープンイノベーション等の推進 ② 相互接続性・相互運用性への留意 ③ 適切な情報提供	i. イノベーションの機会創造への貢献	-	-

別添 1.第 1 部関連

A.AI に関する前提

AI の学習と利用の流れ

一般的に AI は、データを元に事前の学習過程を経て AI モデルを構築し、利用時にはその AI モデルを以て推論や予測を行い、結果を出力するものである。特定の数値データや画像等のデータを用いた AI モデルを利用する従来からある AI に加え、本ガイドラインでは大量のテキストや画像、インターネット上の掲載情報を学習する生成 AI も対象とする。Output として得たデータを Input として再学習に利用するケースもあり、ある AI モデルのアウトプットが、別の AI モデルの訓練データとして利用されること、元の AI モデルから別の AI モデルが作られることもある（「図 2. AI の学習と利用の流れの例」参照）。




図 2. AI の学習と利用の流れの例

AI システム概要

AI の機能を有するソフトが組み込まれたシステムを AI システムとして扱う。AI システムはセンサデータやテキスト等の入力に対し、アクチュエータや情報端末を介して出力する。なお、別添では、電動機やエンジン等の駆動装置、その動作により制御を行う物理的な装置に加え、画像や音声、テキスト、推測結果を出力する装置の総称としてアクチュエータとしている。

AI の開発・提供・利用のそれぞれのフェーズにおいて、ファインチューニングや転移学習、強化学習、In-Context Learning（プロンプトエンジニアリング、メモリ、RAG: Retrieval-Augmented Generation、ツール拡張）等の手段により改善・調整がなされ、AI システムが更新されていくケースもある（「図 3. AI システム概要」参照）。




図 3. AI システム概要

AI の開発から利用までのバリューチェーン

AI 開発者によって、収集されたデータを用いた AI モデルの構築が行われ、AI 提供者により AI モデルが既存 / 新設のシステムに組み込まれて AI システムが構築される。構築された AI システムやそのシステムによる AI サービスが AI 利用者に提供され、利用される（「図 4. 一般的な AI 活用の流れにおける主体の対応」参照）。




図 4. 一般的な AI 活用の流れにおける主体の対応

AI システムの例

代表的な AI システム・サービスを「表 2. AI システム・サービス例」に挙げる。

表 2. AI システム・サービス例¹

ケース名	活用 AI	概要	AI 開発者	AI 提供者	AI 利用者	業務外利用者
採用 AI	テキスト解析	A 社グループのグローバル各社における人材採用部門が、 エントリーシートの書類選考を判断する際の参考情報として使用される AI サービス である。 A 社 AI 開発部門は、AI 利用者である A 社人材採用部門（海外グループ会社を含む）より過去のエントリーシートデータと合否判定（内定の判定）結果を受領し、機械学習（分類モデル）で合否判定を支援する AI モデルを作成している。	A 社（開発部門）	A 社（人材開発部門）	A 社グループ（人材採用担当部門）	採用申込者
無人コンビニ	画像解析	全国のコンビニエンスストアチェーンを経営する J 社が提供する 画像認識 AI を活用した無人コンビニ（店内の客が商品を取るだけで AI が代金を計算し、店外に出る際に電子マネー等で一括決済ができるコンビニ） である。当 AI サービスには X 社で開発された無人コンビニ向けの AI システムを搭載している。	X 社	J 社（AI システム開発部）、（コンビニ事業部）	コンビニ店舗	コンビニ利用客
がん診断 AI	テキスト・画像解析	マルチモーダル学習を使用しており、「 本人の病歴・遺伝等に係る情報（データ 1） 」と「 内視鏡画像（データ 2） 」を取込み、 内視鏡での診察中にリアルタイムにがんの可能性が高い部分をハイライト する。医師は出力画像を観察して、がんの可能性があるか判断する。 A 社が AI を開発しつつ、がん診断 AI システムを医療機関に提供している。	A 社（AI 開発部門）	A 社（医療 IT サービス部門）	医療機関（消化器内科）	受診患者
不良品検知 AI	画像解析	ディープラーニングの画像生成及び認識モデルを用いた「完成品の検品システム」 である。従来、完成品（工業用部品）の検品は目視確認で行われるため多大な人件費を要していた。そこでディープラーニングを用いた完成品の自動検品を製造ラインに組み込むことにした。 A 工業の工場 で生産される 完成品（工業用部品）について外観上の不具合を識別 する。通常出荷される完成品の総数に対して、工場内で識別される欠陥品の数は極めて少ないため、「完成品と異なる画像を生成する AI モデル」と「正常品を正しく識別できる AI モデル」を活用している。ディープラーニングのモデルは委託先である B 社にて開発が行われている。	B 社（製造ソリューション）	A 工業（製造管理部）	A 工業（製造ライン@工場）	-

¹ 東京大学未来ビジョン研究センター、リスクチェーンモデル掲載ケース事例より抜粋引用。本ガイドラインの主体整理に合わせて、AI 開発者・AI 提供者・AI 利用者・業務外利用者を記載。

送電線の点検 AI	画像解析	ディープラーニングによる画像解析技術を用いた「架空送電線の診断サービス」である。送電線を点検する画像解析を行い、自動で異常箇所を検出する。 送電線の点検は基本的に保守担当者による高倍率スコープを用いた目視点検によって実施されるが、山間部等の目視確認が容易でない環境における送電線については、ヘリコプターで撮影した動画を熟練の保守担当者がスロー再生で目視確認する必要があり、長時間の作業時間を要していた。このような背景により、P 社では、X 社の画像認識の AI を導入し送電線の異常箇所を判別及び報告書作成までを自動化することとなった。撮影はドローンもしくはヘリコプターによって行われる。リアルタイムでの判断は行わないが、撮影作業の完了後速やかに画像認識の AI によって異常箇所の判別と報告書作成が実施される。	X 社 (AI 開発部)	P 社 (電力サービス保全部) X 社 (AI 開発チーム)	P 社 (保守担当)	-
スマート家電の最適化 AI	センサデータ解析	AI モデルが環境情報やユーザの行動等を解析し、スマート家電を最適化する。A 社の AI サービスは、空間に搭載したセンサ情報（ユーザの位置・状態、温度、湿度、照度、CO2 濃度）、オープンデータ（気象情報）、ユーザからのフィードバック（ストレス、快適度の意見等）を取得して AI モデルが分析を行い、スマート家電機器（スマート冷蔵庫（食材管理、レシピ提案等）、空調、床暖房、空気清浄機、ロボット掃除機、換気システム等）を自動制御する。	A 社 (AI 開発部)	A 社 (アプライアンス事業部)	-	消費者
対話型 AI 社内導入	テキスト等生成	生成 AI を活用した社内向けの AI アシスタントサービスである。 B 社の社員は対話型 AI に対してプロンプト（指示や質問）を入力することで回答を得ることができる。質問、プログラミング、文書生成、翻訳、要約等、社内業務のあらゆる目的や用途にて利用され、業務の生産性向上に寄与している。 A 社のクラウドプラットフォーム及び LLM を活用して B 社グループ C 社が AI アシスタントサービスを実装し、B 社グループ社員に対して提供している。	A 社	B 社 グループ C 社	B 社 グループ	-

AI 事業者のパターン

事業で活用される AI のバリューチェーンには、AI 利用者によって AI が利用され、AI 利用者に加え業務外利用者²にも便益が提供されるパターン 1 と、AI 利用者が利用して便益を得るパターン 2、AI 提供者から提供され

² 事業活動以外で AI を活用する者又は AI を直接事業に活用せずに AI システム・サービスから便益を享受する、場合によっては損失を被る者（ガイドライン本編にて定義）。

た AI システム・サービスを業務外利用者が利用し便益を得るパターン 3 がある（「図 5. AI 事業者のパターン」参照）。

パターン 1 では業務外利用者に AI のシステム（サービス）は提供されず、便益のみが提供される。




図 5. AI 事業者のパターン

データ提供者について

AI の開発・提供・利用のそれぞれのフェーズにおいてデータが活用されて、AI モデルの学習や AI の利用がなされる。データを用いた AI モデルの構築や利用に際し、AI 開発者、AI 提供者、AI 利用者自身で保有するデータを利用して外部のデータを利用しないケースがある。一方で、特定の法人や個人から提供されるデータや人、センサ、システム等の中で、機密性・完全性・可用性を管理不可能なデータ源から取得した外部のデータを利用するケースもある。管理不可能なデータ源に対して指針や重要事項を適用することは極めて困難であり、本ガイドラインではデータを提供される者もしくは入手する者に該当する AI 開発者・AI 提供者・AI 利用者に関するデータの扱いについて記載するとし、データ提供者側にとっての重要事項は記載しない（「図 6. データ提供の在り方」参照）。

ただし、特定の法人又は個人とデータの授受を行うに際しては別添 6 とその中で言及している「AI・データの利用に関する契約ガイドライン」を参照して、データを提供される者、データを提供する者（データ提供者）双方で合意・契約の上、データの活用を進めることが重要となる。




図 6. データ提供の在り方

B.AI による便益/リスク

AI は、新規ビジネスを生み出したり、既存ビジネスの付加価値を高めたり、生産性を向上させたりする等の便益をもたらす一方で、リスクも存在する。

このリスクについては可能な限り抑制することが期待される。一方で、過度なリスク対策を講じることは、コスト増になる等、AI 活用によって得られる便益を阻害してしまうことから、リスク対策の程度をリスクの性質及び蓋然性の高さに対応させる「リスクベースアプローチ」の考え方が重要である。

AI による便益

AI の活用による便益は多岐にわたっており、技術の進展に伴い拡大し続けている。

AI は、各主体において、価値を創造するために活用することができる。その結果として、以下が期待できる。

- 運営コストの削減
- 既存事業のイノベーションを加速させる新製品・サービスの創出
- 組織の変革

さらに、様々な分野（農業、教育、医療、製造、輸送 等）への応用や、様々な展開モデル（クラウドサービスやオンプレミスシステム、サイバーフィジカルシステム 等）の活用が考えられる³。

便益の例

以下の「図 7 企業活動における AI による便益の例」は、企業活動における AI による便益のごく一例を示したもののだが、企業活動の全般にわたり、効果を発揮しうる。

	開発	マーケティング	販売	物流・流通	顧客対応	法務	ファイナンス	人事
従来から存在する便益の例 (生成AIで更に向上)	コード検証、ドキュメント作成の自動化	広告用メールの自動配信	受注後の対応メール等の自動発信	需要予測に基づく生産・在庫数最適化	チャットボットによる自動対応	翻訳	財務諸表の自動作成	給与計算等の自動化
	類似コード・データの抽出・検証	データに基づいたパーソナライゼーション広告	チャネル別、ニーズ別の売上予測	配送ルート最適化	過去の問合せ内容に基づいたFAQ作成	法務文章のレビュー	過去実績にもとづいた将来予測、不正検知	職務経歴書等に基づいた人材需要マッチング
生成AI特有の便益の例	学習データの生成、コーディネータアシスタント、新製品のプレインストーミング	販売促進(マーケティング素材・キャッチコピー等)の自動作成	営業トークスクリプトの自動作成	物流条件交渉のアシスタント	対応内容の自動生成、要約	規定に基づいた契約書ドラフトの自動生成	文脈を踏まえた上での社内問合せ対応	文脈を踏まえた上での人事面接の対応

図 7 企業活動における AI による便益の例

例えば、物流の領域では、AI を用いたロボットによる配送の自動化や需要予測によるバリューチェーンの最適化、人事の領域では、給与計算の自動化や職務経歴書に基づいた人材需要マッチング等、データを活用した効率化に AI が活用され、多様な用途で業務の効率化・最適化が行われている。

³ ISO/IEC TR 24030 には、このような領域や展開モデルをカバーする広範なユースケース集が収録されている。

また、企業以外においても、行政における手続きの自動化や、センサや画像情報等を用いた農場での作業支援システム、診療履歴等の利用による医療分野への活用等も行われている。

さらに、B2C の領域では、チャットボット、自動運転、検索システム、音声アシスタント等、多岐にわたるサービスが展開されている。

生成 AI による可能性

上記に加え、直近では生成 AI が台頭している。生成 AI は DX への遅れをとった日本企業の巻き返しの引き金となる可能性も高い。

日本企業の特徴として、良質の OT（Operational Technology）データの蓄積やきめ細やかなサービスや作業等が挙げられる。これらを従来型の AI を活用することによって実現しようとした場合、組織や業界横断的な OT データの活用やそれらのサービスや作業等において AI を活用するためのデータインターフェースの統合、大量のデータの準備、多くのパターンを想定したシナリオやケース作り、及びそれらを踏まえた開発等、多くの工数や専門的な知識が必要であった。ここに生成 AI を活用すると、これらのシナリオやケース作り自体を自動化でき（自己教師あり学習）、幅広い企業の AI 活用を促進することが可能となる。実際に、小売企業のコールセンターやセールスの対応に生成 AI で回答や資料を作成することにより、生産性を高めている事例もある。また、入力された問い合わせや顧客の要望に対し、社内のデータを参照することにより複数のパターンの回答・資料を作成するようなシステムが可能となっている。

グローバルの激しい競争を勝ち抜くためにも、生成 AI を積極的に取り入れる形でデジタル戦略の見直しを行う等、自身が享受できる便益を正しく理解し、可能性を模索するとともに、積極的な姿勢を持つことが期待される。

AI によるリスク

便益が広がる一方で、利用の拡大や新技術の台頭に伴い、それらが生み出すリスクも増大している。特に生成 AI の普及に伴っては、偽情報・誤情報の生成・発信等リスクの多様化・増大が進むほか、知的財産権の尊重を求める声が高まっている。

具体的には、以下のような事例が生じている⁴。なお、ここで取り上げるリスクについては代表的なものであって AI のリスクを網羅したものではなく、想定に基づく事案も含んでおり、あくまで一例として認識することが期待される。よって、本リスクの存在を理由として直ちに AI の開発・提供・利用を妨げるものではない⁵。むしろ、当該リスクを認識し、リスクの許容性や便益とのバランスを検討したうえで、積極的に AI の開発・提供・利用を行うことを通じて、競争力の強化、価値の創出、ひいてはイノベーションに繋げることが期待される。

⁴ 海外事例については、2,000 以上のレポートが掲載されている Partnership on AI による The AI Incident Database（AIID）が参考となる。
<http://incidentdatabase.ai> 詳細は、後述する「コラム 1：インシデントの共有」を参照のこと。なお、各事例の括弧内は、本編において対応する「共通の指針」を示している。

⁵ 諸外国の法令等にも留意すべきである。例えば、EU の AI Act では、人の生命や基本的人権に対して、直接的に脅威をもたらすと考えうる AI システム（例えば、潜在意識への操作（治療目的は対象外）等）や、政府による社会的な格付けや、危険な行動を促す音声アシスト等について、「許容できないリスク」と記載されており、議論が続いている（2023 年 11 月時点）。

なお、リスクは、各事業者に発生する不利益ではなく、ステークホルダー⁶や社会全体に発生するリスクも検討対象となる。

バイアスのある結果や差別的な結果の出力（人間中心、公平性）

- IT 企業が自社で AI 人材採用システムを開発したが、女性を差別するという機械学習面の欠陥が判明した。この原因としては、学習に使用した過去 10 年間の履歴書において、応募者のほとんどが男性であったことから、男性を採用することが好ましいと AI が認識したためといわれている。当該企業は、女性を差別しないようにプログラムの改善を試みたものの別の差別を生むとして運用を取りやめる結果になった

フィルターバブルやエコーチェンバー現象（人間中心）

- SNS 等によるレコメンドを通じた社会の分断が問題視されている。例えば、自分の見たい情報にのみ囲まれるフィルターバブルや、自分と同じような考えばかりが周囲から帰ってくるエコーチェンバー現象を通じて、AI 利用者及び業務外利用者が極端な考えの持ち主になる懸念も指摘されている

多様性の喪失（人間中心）

- 社会全体が同じモデルを、同じ温度感で使った場合、導かれる意見や回答が LLM によって収束してしまい、多様性が失われる可能性がある

不適切な個人情報の取扱い（プライバシー保護、人間中心）

- 透明性を欠く個人情報の利用が問題視されている。例えば、人材採用に AI を用いるサービスにて、選考離脱や内定辞退の可能性を AI により提供した際、学生等の求職者への説明が不明瞭であった他、一時期第三者への情報提供への同意内容がない規約となっていたこと等から、個人情報保護法及び職業安定法にも違反することが判明し、サービスは廃止されることとなった
- 個人情報の政治利用も問題視されている。例えば、SNS の業務外利用者に提供した「性格診断アプリ」やプロフィール情報を基に収集した個人情報を使用し、個々のパーソナリティを把握し、それに働きかけることで、依頼者に有利な投票行動をするようにターゲティング広告を打つ選挙支援活動が実施された。具体的には、収集したデータを基にして、「平均的市民よりも衝動的怒りや陰謀論に傾きやすい集団」や「神経症とダークトライアド特性」等を分類して、自陣営に有利になる記事が大量に投稿された。この行為は個人情報を使った選挙活動への介入であり、国の根幹である民主主義をゆがめると懸念された（民主主義への悪影響）

生命、心身、財産の侵害（安全性、公平性）

- 例えば、AI が不適切な判断を下すことで、自動運転車が事故を引き起こし、生命や財産に深刻な損害を与える可能性がある。このようなシナリオでは、AI の誤動作による大規模な事故リスクが懸念される
- インシデント発生時に優先順位付けを行うトリアージにおいては、AI が順位を決定する際に倫理的なバイアスを持つことで、公平性の喪失等が生じる可能性がある。医療場面のトリアージにて活用される際には、特定的人群に対して差別的な医療判断が行われることで、生命に対する脅威が発生する可能性がある

⁶ AI 開発者、AI 提供者、AI 利用者、業務外利用者以外の第三者を含む AI の活用によって直接・間接の影響を受ける可能性がある全ての主体（以降同様）。

データ汚染攻撃（セキュリティ確保）

- AI の学習実施時では性能劣化や誤分類につながるような学習データへの不正データ混入、サービス運用時では、アプリケーション自体を狙ったサイバー攻撃、AI の推論結果や AI への指示であるプロンプトを通じた攻撃等もリスクとして存在する。例えば、とあるチャットボットでは、悪意のある集団による人種差別的な質問の組織的な学習により、ヘイトスピーチを繰り返し発言するようになった

ブラックボックス化、判断に関する説明の要求（透明性、アカウントビリティ）

- AI の判断のブラックボックス化に起因する問題も生じている。とあるクレジットカードにおいて、同じ年収を有する男性と女性に対して、女性の方が利用限度額が低いとの報告が SNS 上で広がった。この問題に対し、金融当局が調査を実施し、クレジットカードを提供した企業に対してアルゴリズムの正当性の証明を求めた。しかし、企業はアルゴリズムの具体的な機能や動作について説明することができなかった
- AI の判断に関する透明性を求める動きも上がっている。とある IT 企業では、自社 AI を活用した人事評価ツールを導入した。その際、従業員の労働組合は団体交渉を行い、AI の学習データ・アウトプットの内容説明、判断の材料と結果との関連性の具体的説明を求めたものの、企業側が開示を拒否。労働組合が賃金決定プロセスの透明化を求めて労働委員会に救済の申し立てを行った

エネルギー使用量と環境の負荷（人間中心）

- AI の利用拡大により、計算リソースの需要も拡大しており、結果として、データセンターが増大、そこでのエネルギー使用量の増加が懸念されている。AI 開発に使われる大量の電力使用による二酸化炭素排出量は、米国人の 1 年あたりの排出量の何十倍にもなるとの指摘もある⁷。ただし、例えばエネルギー管理に AI を導入することで、効率的な電力利用も可能となる等、AI による環境への貢献可能性もある点も忘れてはならない

なお、生成 AI で顕在化したリスクとしては、以下が挙げられる。

悪用（安全性、教育・リテラシー）

- AI の詐欺目的での利用も問題視されている。中でも、AI で合成された音声を利用した詐欺は急増している。とある女性に、娘の声で助けを求める電話があり、100 万ドルの身代金が要求されたものの、この声は AI を用いて生成されたものあり、誘拐を偽装した詐欺の電話であったことが判明した

機密情報の流出（セキュリティ確保、教育・リテラシー）

- AI の利用においては、個人情報や機密情報がプロンプトとして入力され、その AI からの出力等を通じて流出してしまうリスクがある。例えば、AI サービスの利用上、従業員が業務利用のため、機密情報に該当するソースコードを、業務外利用者向けの対話型生成 AI に入力してしまう事例が明らかになっている。生成 AI 系サービスでは利用障壁が下がっていることから、特に、企業のルール等が未整備の場合、企業による管理の外で、従業員が業務に業務外利用者向けの生成 AI を用い、リスクの高い使用をする恐れもある。た

⁷ スタンフォード大学、AI Index Report 2023 - Artificial Intelligence Index <https://aiindex.stanford.edu/report/#individual-chapters>

だし、エンタープライズグレードのセキュリティ機能が組み込まれた、ビジネス利用を想定した対話型生成 AI も存在する。企業は、特に機密情報を処理するにあたっては、代わりにその追うサービスやアプリケーションを使用することが推奨される

ハルシネーション（安全性、教育・リテラシー）

- 生成 AI が事実と異なることをもっともらしく回答する「ハルシネーション」に関しては AI 開発者・提供者への訴訟も起きている。とあるテレビ番組の出演者が、「自身が金銭の横領で提訴されている」という偽情報を生成 AI が拡散しているのを発見。生成 AI に虚偽の告訴状まで作られたとして、当該生成 AI を開発・提供する企業を名誉棄損で提訴した

偽情報、誤情報を鵜呑みにすること（人間中心、教育・リテラシー）

- 生成 AI が生み出す誤情報を鵜呑みにすることがリスクとなりうる。例えば、米国の弁護士が審理中の民事訴訟で資料作成に生成 AI を利用した結果、存在しない判例を引用してしまったことが問題となった
- ディープフェイクは、各国で悪用例が相次いでいる。海外では、偽画像や偽動画を使った情報操作や世論工作が発生している。「国防総省付近で爆発が起きた」とする生成 AI で作られた偽画像が SNS やインターネットで瞬く間に拡散した事例も見られた。一部の海外のメディアや大手金融メディアを装った偽アカウントもこの情報を広げたことで、平均株価が一時 100 ドル以上下落するに至った。事件や事故・災害等の偽情報を企業のアカウントが拡散してしまう事例も発生している

著作権との関係（安全性）

- 生成 AI の活用にあたっては、一部のステークホルダーから知的財産権の取扱いについて議論が提起されている。海外においては、アーティストの作品について、生成 AI に学習させ画像を生成した場合に、AI が学習した作品に似た画像が生成される場合があるとして、複数のアーティストが集団訴訟を起こした事例がある⁸

資格等との関係（安全性）

- 生成 AI の活用を通じた業法免許や資格等の侵害リスクも考える。例えば、生成 AI が法律や医療の相談に回答する場合、業法免許や資格の侵害が生じ、法的問題が発生する可能性がある。このリスクを回避しようとした場合、業界全体で生成 AI の導入が遅れ、新たなサービスや効率向上が制限される可能性もある

バイアスの再生成（公平性）

- 生成 AI は既存の情報に基づいて回答を作るため、その答えを鵜呑みにする状況が続くと、既存の情報に含まれる偏見を増幅し、不公平や差別的な出力が継続/拡大する可能性がある。例えば、男女差別が存在する状況のデータに基づいて回答が作られており、その回答を信じる人が増えると、男女差別が固定化される危険性が高まる

⁸ 日本においては、学習・開発段階においては著作権法 30 条の 4 に基づき、著作物は、情報解析その他の当該著作物に表現された思想又は感情を自ら「享受」し又は他人に「享受」させることを目的としない場合には、その必要と認められる限度で、著作権者の許諾なく利用可能である。他方、生成・利用段階においては、著作権法で利用が認められている場合を除き、通常の著作権侵害と同様に、依拠性・類似性により判断される。

このように、技術発展により AI 活用による便益が大きくなる一方で、従来型 AI でも現れていたリスクが生成 AI の台頭によりさらに増大傾向にある。また、生成 AI により新たに顕在化したリスクもある。加えて、多くの生成 AI サービスで利用障壁が下がったことから、意図しないリスクを伴う使われ方をする恐れもある。

生成 AI は日々進化し、リスクに対応する技術やアイデアも日々進歩している。しかし、生成 AI の本質的なリスクはその技術的な特性に大きく依存しており、抽象的な議論に終始しないためにも、対策を考える際には、「より良い使い方の工夫」として有効な AI ガバナンスを考えていくことが重要である。

さらに、生成 AI のリスクは、外部環境や技術動向により変化し、「再現性」がなくエラーの原因も特定しにくい。そのため、社会技術的な標準化、テストの妥当性、フィードバックループの確立、法的リスクや人権リスクの再定義等が必要であり、文脈に合わせた適切な証跡を確保することも重要である。

以上を踏まえ、AI の便益を享受しつつリスクを抑制し、AI の事業活用による競争力の強化等に繋げるため、AI ガバナンス構築の必要性が高まっている。

なお、リスクを恐れるあまり、「リスクがゼロになるまで AI を活用しないこと」や「完全なセーフガードを引く」ということを通じて各主体が動くことができなくなることも一種のリスクであることに留意することが重要である。

別添 2.第 2 部関連 [E.AI ガバナンスの構築]

別添 1. B.「AI による便益/リスク」にて述べたとおり、AI の便益を享受しリスクを抑制するためには、AI に関するリスクをステークホルダーにとって受容可能な水準で管理しつつ、そこからもたらされる便益を最大化するための、AI ガバナンスの構築が重要となる。その際、常に変化する環境とゴールを踏まえ、最適な解決策を適用し、適切に作動しているか評価・見直し続けることが各主体に期待される。

以下、各主体が AI ガバナンスの構築において留意すべき観点としての行動目標と、実践のポイント及び実践例を述べる。

このうち、行動目標については、一般的かつ客観的な目標であり、社会に対して一定のリスクを与えうる AI システム・サービスの開発・提供・利用に関わる全ての主体が実施することが重要である（全体像については、「表 3 行動目標一覧」を参照のこと）。一方で、実践のポイントや仮想企業を想定した実践例は、各主体が置かれた個別具体的な状況や、各主体の開発・提供・利用する AI システム・サービスの目的、方法、評価の対象により、どの要素が有用であるかは異なる。そのため、実践のポイントや実践例の採否は、各主体に委ねられる。また、採用する場合であっても、各主体の事情に応じた修正や取舍選択の検討が期待される。

なお、各主体内で IT、プライバシー、セキュリティのガバナンス等と連携することや、バリューチェーン全体で各主体間が連携することで、ステークホルダーの要求に応じた AI ガバナンス体制の整備・運営を行うことが期待される。また AI ガバナンスの構築では、アジャイル・ガバナンスに従い、仕組みやルール、体制の見直しを行い、管理工数を最小化しつつ意思決定や運用を迅速化することが重要である。AI ガバナンスとマネジメントを適正化し、限られたリソースを効率的に活用するために、適切な権限委譲の促進も期待される。

表 3 行動目標一覧

分類	行動目標
1.環境・リスク分析	1-1 便益/リスクの理解 1-2 AI の社会的な受容の理解 1-3 自社の AI 習熟度の理解
2.ゴール設定	2-1 AI ガバナンス・ゴールの設定
3.システムデザイン	3-1 ゴールと乖離の評価及び乖離対応の必須化 3-2 AI マネジメントの人材のリテラシー向上 3-3 各主体間・部門間の協力による AI マネジメント強化 3-4 予防・早期対応による利用者のインシデント関連の負担軽減
4.運用	4-1 AI マネジメントシステム運用状況の説明可能な状態の確保 4-2 個々の AI システム運用状況の説明可能な状態の確保 4-3 AI ガバナンスの実践状況の積極的な開示の検討
5.評価	5-1 AI マネジメントシステムの機能の検証 5-2 社外ステークホルダーの意見の検討
6.環境・リスクの再分析	6-1 行動目標 1-1～1-3 の適時の再実施

A.経営層による AI ガバナンスの構築とモニタリング

1.環境・リスク分析

行動目標 1-1【便益/リスクの理解】：

各主体は、経営層のリーダーシップの下、AI の開発・提供・利用の目的を明確化したうえで、AI から得られる便益だけではなく意図しないリスクがあることも各主体の事業に照らして具体的に理解し、これらを経営層に報告し、経営層で共有し、適時に理解を更新する。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組む。

- 事業における価値の創出や社会課題の解決等の AI の開発・提供・利用の目的を明確に定義
- 自社の事業に結びつくかたちで、「便益」や、意図せざるものを含めた「リスク」の性質を具体的に理解
- その際に、回避すべき「リスク」や、複数主体にまたがる論点に留意し、バリューチェーン/リスクチェーン全体で便益を確保、リスクを削減
- 迅速に「経営層に報告/共有する」仕組みを構築

「リスク」としては、具体的には以下のようなものが挙げられ、これらのリスクに起因して、レピュテーションの低下や法令違反を理由とした制裁金や損害賠償責任の負担等による損失が生じる可能性もある。リスクについての詳細は、別添 1.「B.AI による便益/リスク」を参照いただきたい。

- AI 全般に共通するリスク
 - バイアスのある結果や差別的な結果の出力、フィルターバブル・エコーチェンバー、偽情報、不適切な個人情報の取扱い、データ汚染攻撃、ブラックボックス化、機密データの漏洩、AI システム・サービスの悪用、エネルギー使用量と環境の負荷、バイアスの再生成 等
- 生成 AI により顕在化したリスク
 - ハルシネーション、誤情報を鵜呑みにすること、著作権等の権利や資格との関係 等
- 組織・管理に起因するリスク
 - 製品やサービスに AI が含まれていることの不認識
 - 既存のガバナンスにおける AI に関する考慮の不足
 - 環境認識や計画等が不足した状況における不適切又は偏在的な AI の活用
 - 仕事の棲み分け等、人間と AI との間の関係性の整理不足

なお、バリューチェーン/リスクチェーン全体での便益の確保、リスクの削減に努めるため重要な「複数主体にまたがる論点」としては、以下のものが挙げられる。

- 主体間、又は主体内の責任分配
- 品質の向上
- 各 AI システム・サービスが相互に繋がることによる新たな価値の創出の可能性（System of Systems）
- AI 利用者・業務外利用者のリテラシー向上

また、「経営層への報告・共有」については、自社/組織の特性に応じて最も適した仕組みを設計することが期待されるが、例えば、以下のような方法が考えられる。

- 取締役会に対して責任を負う AI ガバナンスに関する社内組織（AI 倫理委員会、AI 倫理審査委員会等）を設置
- AI ガバナンスに関する取組について、取締役会において報告
- 自社/組織にとっての便益/リスクを整理した資料の文書化、回覧
- 社内で活用しているガバナンスフレームワークへの反映 等

[実践例]

【実践例 i：便益・リスクの把握】

各主体は、経営層のリーダーシップの下（担当役員や現場に一任するのではなく、経営層自らが主導することを通じて実施することも含む、以下同様）、便益だけではなくリスクについても検討し、その検討結果を経営層で共有するとともに、適時に理解を更新することが重要となる。

便益は既知と思われるが、当社は、独立行政法人情報処理推進機構（IPA）がまとめている AI 白書⁹のような包括的・網羅的な解説書等を用いて AI 技術がもたらしうる便益を改めて整理した。

また当社は、これから開発・提供・利用しようとしている AI システム・サービスと同じ又は類似の機能や分野においてインシデントが過去に起きていないか、あるいは、過去に起きていないとしてもインシデントが起きる具体的な可能性が指摘されていないかについて調査した。インシデント情報は様々な文書やインターネットから入手することができる。当社は、日本での開発・提供・利用のみを予定しているため、日本で共有されている情報の収集から始めた。その際、消費者庁の「AI 利活用ハンドブック～AI をかしこく使いこなすために～」から参照した¹⁰。例えば、チェックポイントに「AI が音声を誤認識してしまい、間違えた指示をしたり、普段の会話情報が収集されたりしてしまう可能性があります。」が挙げられているが、これは潜在的なインシデントを業務外利用者の視点から表現したものである。

また、インシデントや将来起きうることに言及した AI に関する書籍も充実している。日本ディープラーニング協会（JDLA）の G 検定は倫理的事項も対象としており、この検定の一環としてインシデントに関する情報を得ることができる。「プロファイリングに関する最終提言」では、いくつかのケースがわかりやすく解説されている¹¹。さらに、当社では、AI システム・サービスに対する社会的受容が国・地域ごとに異なりうることを認識しつつも、後述する「コラム 1：インシデントの共有」で挙げられているインシデントデータベースも参考にした。これまでの分析では、個人情報の取扱い、公平性、安全性に関するものが多いことがわかっている。なお、個々の具体的な AI システム・サービスの便益/リスク分析は、行動目標 3-1 の乖離評価時に行う予定である。

【実践例 ii：AI の活用範囲が広い場合のフレームワークを活用したリスクの把握】

当社は、開発・提供・利用している AI システム・サービスの分野が多様であることから、実践例 i に加え、社会的に影響を及ぼしたインシデントや、影響が生じる可能性が指摘されている将来的課題について、その全体像を把握するために、一般的なフレームワークに照らしながら、大まかに整理している。当社では、OECD における

⁹ AI 白書編集委員会「AI 白書 2023」（2023 年 5 月）

¹⁰ 消費者庁「AI 利活用ハンドブック～AI をかしこく使いこなすために～」（2020 年 7 月），
https://www.caa.go.jp/policies/policy/consumer_policy/meeting_materials/review_meeting_004/AI_handbook.html

¹¹ パーソナルデータ+α 研究会「プロファイリングに関する最終提言」（2022 年 4 月），
<https://wp.shojihomu.co.jp/wp-content/uploads/2022/04/ef8280a7d908b3686f23842831dfa659.pdf>

分類フレームワーク¹²を参照しつつ、独自のフレームワークを作成し使用している。OECD における分類フレームワークのうち、環境・リスク分析に概ね対応する Economic Context の章では、OECD の AI 原則と産業分野の関係性、ビジネス用途、ステークホルダー、影響の範囲等の視点から一般的なフレームワークが提示されている。これらの分類はリスクを大まかに理解するための補助的ツールにすぎないことに留意しつつ、現在、自社のフレームワークへの反映を検討している。なお、個々の具体的な AI システム・サービスの便益/リスク分析は、行動目標 3-1 の乖離評価時に行う予定である。

【実践例 iii：AI の活用範囲が広い場合の複数主体と連携した便益/リスクの把握】

当社は、AI システム・サービスの開発・提供・利用の範囲が広く、インシデントが生じると社会に大きな影響を与えることを自覚している。そのため、AI の便益/リスクについては、自社が直接関与した経験と同業他社や場合によっては他の業界の経験から得られた情報を組み合わせることでより有用性の高い分析が可能であると考え、文理横断的な社内勉強会等で分析を行っている。そして、この分析を一定の頻度で継続することで、インシデントが起きる前であっても、適時に AI ガバナンス・ゴールの見直しについて検討できるようにしている。

【実践例 iv：把握した便益/リスクの社内共有】

当社では、AI システム・サービスの開発・提供・利用の範囲が広く、その影響が社会全体に及ぶことを認識している。よって、AI の便益とリスクについては、社内での共有が重要であると考え、以下の手順を踏んでいる。

まず、得られた情報や分析結果をまとめ、関連者に対して資料を文書化し、回覧している。この文書は関係者からのコメントやフィードバックを受け付けており、積極的な意見交換が行われている。具体的には、社内勉強会やワークショップを通じて、関連部署の担当者や関心を持つメンバーとディスカッションを行い、異なる視点からの意見を取り入れている。

また、社内において、AI ガバナンスに関する取り組みや進捗については、専任の責任者が指名され、取締役会での報告を行っている。これにより、透明性が確保され、経営層との効果的なコミュニケーションが促進されている。社内共有の仕組みを通じて、組織全体が AI の便益を最大限に享受し、同時にリスクを適切にコントロールできる環境を構築している。

【実践例 v：生成 AI への対応】

直近では生成 AI も台頭しており、自社にとっても機会であると考えられている。自社の業務に活用するにあたり、JDLA の発行する「生成 AI の利用ガイドライン」¹³に沿って、自社内での利用ガイドラインの策定を行っている。併せて、個人情報保護委員会が出した「生成 AI サービスの利用に関する注意喚起等」等の行政からの情報発信も確認している。また、ニュースや SNS 等を通じ生成 AI に関する情報の収集も欠かせない。これらを通じて、便益やリスクの最新の動向の把握に努めている。

¹² OECD, OECD FRAMEWORK FOR THE CLASSIFICATION OF AI SYSTEMS (Feb2022) ,
OECDFrameworkfortheclassificationofAIsystems (oecd-ilibrary.org)

¹³ <https://www.jdla.org/document/#ai-guideline>

コラム 1：インシデントの共有

AI システムの開発や運用に伴うリスクについては過去のインシデントに学ぶ部分が多い。AI システムはデータセットに基づいて帰納的に構築され、そのリスクには意図していないものも多いことから、リスクを低減するためには過去のインシデントを理解することが有効である。これらのインシデント事例は、一般的にはニュースや論文等の公開情報から得られることになるが、必要な情報にアクセスすることは簡単なことではない。

このアクセス性の課題に対応するために、Partnership on AI は、2020 年 11 月に The AI Incident Database (AIID) ¹⁴をリリースした。AIID には 2,000 以上のインシデントが URL リンク付きで掲載されており、検索用のアプリも提供されている。Partnership on AI 以外にも、GitHub 上で AI Incident Tracker が公開されている¹⁵。

また、OECD も、OECD AI Incidents Monitor (AIM) ¹⁶をリリースした。AIM では、インシデントとして、世界のニュースを監視しており、ニュースインテリジェンスプラットフォームである Event Registry から提供された毎日 150,000 件を超える英語記事が掲載に向け分析されている。

他方で、このようなデータベースを持続的に整備することは課題であるようだ。AIID のインシデント事例は学者らが提供した初期リストがほとんどであるという。AI の提供が進み情報が増加する中、重要な情報を中心に蓄積していくことも課題であるという。また、公開情報になっていない各社の「ヒヤリ・ハット」はそれ自体が重要な経験であって各社の知的財産と評価しうる場合もあることから、インシデント事例を積極的に集めて「共有財産」とすることは容易ではないという指摘もある。

¹⁴ <https://incidentdatabase.ai/>

¹⁵ jphall663, awesome-machine-learning-interpretability, <https://github.com/jphall663/awesome-machinelearning-interpretability/blob/master/README.md#ai-incident-tracker>.

¹⁶ <https://oecd.ai/en/incidents>

行動目標 1-2【AI の社会的な受容の理解】：

各主体は、経営層のリーダーシップの下、AI の本格的な開発・提供・利用に先立ち、ステークホルダーの意見に基づいて、社会的な受容の現状を理解することが期待される。また、AI システム・サービスの本格的な開発・提供・利用後も、外部環境の変化を踏まえ、適時にステークホルダーの意見を再確認するとともに、新しい視点を更新することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組む。

- ステークホルダーを特定
- 特定した上で、「社会的な受容」の理解に努め、AI を開発・提供・利用
- 提供開始後も、急速に変化する外部環境を考慮し、必要に応じて適時にステークホルダーの意見を再確認

ステークホルダーの特定は、提供する AI がライフサイクル全体を通じて個人、組織、地域社会、社会、地球環境に及ぼす潜在的な便益、リスクを検討したうえで実施する。なお、想定したステークホルダーよりも範囲が大きくなる可能性が高い点に留意することが期待される。例えば、OECD の分類フレームワーク¹⁷では、ステークホルダーとして以下の者が挙げられている。

- 各主体に所属する者
- 業務外利用者
- 企業（business）
- 政府機関
- 研究機関
- 科学者/研究者
- 市民団体
- 子どもやその他の社会的弱者、集団 等

「社会的な受容」の確認には、以下のような情報を参照することが有用である。

- 公的文書、学術調査 等
 - 政府やシンクタンクが公表しているアンケート
 - 研究論文
 - AI システム・サービスに対する市民団体からの意見
 - AI 倫理や品質に関するセミナーやカンファレンス
- 最新のニュース
 - インシデント事例の調査
 - SNS・ブログ・掲示板・報道等での業務外利用者を含むステークホルダーの反応

組織の外部環境としては、例えば ISO/IEC23894:2023¹⁸では、以下が挙げられている。

¹⁷ <https://oecd.ai/en/classification>

¹⁸ ISO/IEC 23894:2023

- 社会的、文化的、政治的、法律的、規制の、金融的、技術的、経済的、環境的要因
 - AI に関するものを含む関連法令
 - 政府、市民社会、学会、業界団体等が発行する AI に関するガイドライン
 - 分野別のガイドライン、フレームワーク 等
- 組織のゴールに影響を与える要因と傾向
 - AI の各分野における技術動向・進歩
 - 社会科学的な指針における整理を含む AI システム導入の社会的・政治的な意義
- 外部ステークホルダーの関係、認識、価値観等
- 契約関係とそれに対するコミットメント
- AI システム間の連携と依存関係の複雑性 等

また、ステークホルダーの意見の再確認のためには、以下の方法が有効である。

- ステークホルダーからの直接フィードバック
- AI の有識者による自社 AI マネジメントシステムや運用に対する評価

[実践例]

【実践例 i: 社会的受容の理解】

当社では、政府、公的機関、シンクタンク等が公表している業務外利用者に対するアンケートを最初の手がかりに、社会的受容の理解に努めた。例えば、消費者庁は、「消費者のデジタル化への対応に関する検討会 AI ワーキンググループ」において、「①消費者の AI に関する理解の状況、②消費者による AI への期待と課題、利用意向、③消費者が利用している AI 提供サービス（どのようなリスクを抱えているか）、④AI のサービスに係るリスク」について、どの程度認識・理解して活用しているかについて、アンケート調査を実施し、その結果を公表している。当社は、国際的な展開も考えていることから、海外の業務外利用者のアンケート調査も参考にした。さらには、AI システム・サービスに対する市民団体の意見も参考にした。

ここで得られた社会的な受容に関する情報は、AI ガバナンスの全体的な設計の際に用いられることになるため、経営層が意思決定できるように、枝葉をそぎ落として、幹となる情報を抽出することが求められる。当社では、行動目標 1-1 で得られた情報や分析を活用しながら、様々な AI システム・サービスを、いかなる説明をしても社会的に理解が得られる水準に達していない可能性が高い用途、積極的かつ十分に説明することで社会的に理解が得られる可能性が高い用途、必要に応じて説明することで社会的に理解が得られる可能性が高い用途、業務外利用者にリスクを与える可能性が低い用途等、リスクの大きさにしたがって区分する等して、リスクベースで社会的受容を整理している。

【実践例 ii : 外部セミナー等を活用した社会的受容の理解】

当社では、実践例 i に加えて、大学や産業団体が開催する AI 倫理や品質に関するセミナーやカンファレンスに担当者を積極的に派遣している。最近では、これらのセミナー等がウェビナー形式で開催されることも多く、以前よりも効率的に情報が得られるようになってきた。海外のウェビナーにアクセスすれば、AI 倫理や品質の国際的な動向を把握することも可能である。

【実践例 iii：ステークホルダーを通じた社会的受容の理解】

これまで当社では実践例 ii のような実務を採用してきたが、AI システム・サービスを本格的かつ広範に開発・提供・利用していることから、当社が適切に AI を利用することに対するステークホルダーからの期待が比較的高いと理解している。そのため、経営層のリーダーシップの下、ステークホルダーの意見を間接的・受動的に把握するのではなく、直接的・積極的に把握するという方針に切り替えた。

この新しい方針の下、当社では、AI の社会的受容の事情に詳しい有識者を招聘し AI ガバナンスに関する外部有識者等を含む会議体を定期的で開催している。当社の AI マネジメントシステムや運用に対する評価を得るだけでなく、AI に対する一般的な社会的受容等、当社が置かれた環境への理解を深めるためにも、この会議体を活用している。また、実践例 i、ii で得られる一般的な情報と比較して、会議体で得られる情報は当社向けに深掘りされたものであり、かつ、広く知られていない情報であることが多いという特徴があると認識している。そして、この会議体で得られた情報と実践例 i、ii で得られた一般的な情報と組み合わせて、社会的な受容についてリスクベースで精緻に分析している。分析結果は運営層で整理され、運営層から経営層（業務執行担当）に報告されている。

行動目標 1-3【自社の AI 習熟度の理解】：

各主体は、経営層のリーダーシップの下、行動目標 1-1、1-2 の実施を踏まえ、活用しようとする AI の用途、自社の事業領域や規模等に照らしてリスクが軽微であると判断した場合を除き、自社の AI システム・サービスの開発・提供・利用の経験の程度、AI システム・サービスの開発・提供・利用に関与するエンジニアを含む従業員の人数や経験の程度、当該従業員の AI 技術及び倫理に関するリテラシーの程度等に基づいて、自社の AI 習熟度を評価し、適時に再評価する。可能であれば、合理的な範囲でその結果をステークホルダーに公開することが期待される。リスクが軽微であると判断し、AI 習熟度の評価をしない場合には、評価しないという事実をその理由とともにステークホルダーに公開することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組む。

- 各主体の事業領域や規模等に照らして「AI 習熟度」の評価の必要性を検討
- 必要であると判断した場合、AI のリスクへの対応力が見える化し、AI 習熟度（AI システム・サービスの開発・提供・利用時に求められる準備がどれだけでできているのか）を評価する
 - 可能であれば、合理的な範囲でその結果をステークホルダーに公開
- 必要ではないと判断した場合、可能であれば、合理的な範囲でその事実を、理由とともにステークホルダーに公開

AI システム・サービスによる効率化等に成功した場合は、人材不足の解消、生産性の向上、高付加価値事業の開発等ビジネスにとって便益をもたらしうる。一方で、野放図な AI システム・サービスのビジネス提供は、意図せずして、公平性が損なわれたり、安全性の問題が生じたりする等、AI 特有のリスクも伴う。したがって、各主体は、これらの AI 導入の負の側面とも言うべきリスクをよく把握した上で、導入にとりかかることが求められ、そのために「AI 習熟度」の評価が重要となる。

「AI 習熟度」を確認するためには、以下の活用が有用である。なお、いずれのガイドラインについても、生成 AI 活用の進展を含め、環境変化を踏まえた見直しが必要とされる可能性があるため、最新の状況を確認することが期待される。

- 日本経済団体連合会「AI 活用による Society 5.0 for SDGs の実現に向けて」（2023 年 6 月）に掲載のガイドライン¹⁹
- 一般社団法人日本ディープラーニング協会が実施する検定試験
 - Generative AI Test²⁰
 - JDLA Deep Learning For GENERAL（G 検定）²¹
- NIST, Artificial Intelligence Risk Management Framework（AI RMF 1.0）²²

[実践例]

¹⁹ 日本経済団体連合会「AI 活用による Society 5.0 for SDGs の実現に向けて」（2023 年 6 月），

<https://www.keidanren.or.jp/policy/2023/041.html>

²⁰ <https://www.jdla.org/certificate/generativeai>

²¹ <https://www.jdla.org/certificate/general/>

²² <https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf>

【実践例 i : 「AI 活用による Society 5.0 for SDGs の実現に向けて」(2023 年 6 月)に掲載のガイドラインを活用した習熟度の評価】

当社では、AI システム・サービスの開発・提供・利用の際に便益だけに気をとられて、リスクやリスクへの配慮が不足して、結果として AI システム・サービスの導入によりステークホルダーが大きなダメージを被ったりすることのないように、経営層のリーダーシップの下、自社の AI 習熟度を評価し、適時に再評価している。

AI 習熟度の評価には、日本経済団体連合会の「AI 活用による Society 5.0 for SDGs の実現に向けて」(2023 年 6 月)に掲載のガイドラインを用いている。その理由は、自社の AI システム・サービスが社会に与える便益/リスクの大きさ及び関連するステークホルダー²³の広がり、自社の AI 習熟度に相応しているか否かについて評価するためである。そして当社は、AI 習熟度を AI ガバナンス・ゴールの検討を含む、AI ガバナンス全体の検討に役立てている。

【実践例 ii : 「AI 活用による Society 5.0 for SDGs の実現に向けて」(2023 年 6 月)に掲載のガイドラインを参照し、独自の指標を用いた習熟度の評価】

当社は、AI ガバナンスの検討の取組を本格的に始めたばかりである。したがって、AI 習熟度の評価として、「AI 活用による Society 5.0 for SDGs の実現に向けて」(2023 年 6 月)に掲載のガイドラインを参照しつつ、その中から数項目を選択し、自社の AI ガバナンスに適した独自の指標を作成している。当該指標を用いて評価をしつつ、自社内に現在の AI ガバナンスの制度や仕組みが浸透するにつれ、より多くの項目を用いて AI 習熟度を図るよう計画を立てている。

【実践例 iii : 生成 AI に関する習熟度の評価】

直近では生成 AI も台頭しており、その影響も盛り込むため、JDLA の発行する「生成 AI の利用ガイドライン」²⁴を活用し、生成 AI の要素も踏まえた検討を行っている。なお、「AI-Ready 化ガイドライン」についても生成 AI の文脈を踏まえた上での更新が予定されていることより、更新がされた場合には、それを基に再度検討を行うことを予定している。

²³ AI 開発者、AI 提供者、AI 利用者、業務外利用者を含む直接・間接問わず AI の活用に関与する主体

²⁴ <https://www.jdla.org/document/#ai-guideline>

2.ゴール設定

行動目標 2-1【AI ガバナンス・ゴールの設定】：

各主体は、経営層のリーダーシップの下、AI システム・サービスがもたらしうる便益/リスク、AI システム・サービスの開発・提供・利用に関する社会的受容、自社の AI 習熟度を考慮しつつ、設定に至るプロセスの重要性にも留意しながら、自社の AI ガバナンス・ゴール（例えば AI ポリシー）を設定するか否かについて検討し、設定する。また、設定したゴールについてはステークホルダーに対して公開することが期待される。潜在的なリスクが軽微であることを理由に AI ガバナンス・ゴールを設定しない場合には、設定しないという事実をその理由とともにステークホルダーに公開することが期待される。「AI 事業者ガイドライン」における「共通の指針」が十分に機能すると判断した場合は、自社の AI ガバナンス・ゴールに代えて当該「共通の指針」をゴールとしてもよい。

なお、ゴールを設定しない場合であっても、本ガイドラインの重要性を理解し、行動目標 3 から 5 に係る取り組みを適宜実施することが期待される。

【実践のポイント】

各主体は、経営層のリーダーシップの下、以下に取り組む。

- 各主体の「AI ガバナンス・ゴール」を設定するかを検討
 - 各自の規模や取扱う AI のリスクに応じて柔軟に設定
- 必要であると判断した場合、ゴールを設定する
 - 可能であれば、合理的な範囲で当該ゴールをステークホルダーに対して公開する
- 必要ではないと判断した場合、可能であれば、合理的な範囲でその事実を、理由とともにステークホルダーに公開

「AI ガバナンス・ゴール」の構成要素としては、以下が考えられ、代表例も様々な文献で紹介されている。

- 本ガイドラインに記載の「共通の指針」への対応事項からなる自社の取組方針（「AI ポリシー」等呼称は各自により相違）
- 「共通の指針」への対応事項に加え、プライバシーに関するデータ活用の指針等を取り纏めたプライバシーポリシー 等
- AI 活用により包摂性向上等の便益を高めるためのポリシー
- リスクへの許容度

加えて、外部公開を想定する「AI ガバナンス・ゴール」を作成する段階で、社員の意識向上のためにも、非公開で社員用の「行動基準」を定め、社内（特に実務担当者）に周知することも有用である。

また、本ガイドラインに記載の「共通の指針」は、「AI ガバナンス・ゴール」としても活用が可能であり、各主体独自の AI ガバナンス・ゴールを設定する場合でも、「共通の指針」の内容を参考にすることが期待される。「AI ガバナンス・ゴール」を「共通の指針」を基に整理した場合、生じうる「リスク」も「共通の指針」に紐付けて整理することで、「共通の指針」に基づいたリスクの評価も可能となる。

なお、「AI ガバナンス・ゴール」の設定にあたっては、以下の事項にも留意する。

- 各主体の存在意義、理念・ビジョンといった経営上のゴールに沿って AI ガバナンス・ゴールや AI の活用目的といった AI に関するゴールも検討することで、それぞれに矛盾が生じたり、相反したりすることがないこと
- 各主体の存在意義、理念・ビジョンといった経営上のゴールと、これと整合した AI に関するゴールについては、AI ガバナンス・ゴールに基づく PDCA サイクルを組織マネジメントに落とし込む際に併せて伝達していくこと
- ステークホルダーを見極めることで、ステークホルダーから期待されるインパクトやステークホルダーが懸念するリスクを検討し、これと齟齬のないようにすること

[実践例]

【実践例 i：AI ガバナンス・ゴールを設定しない場合】

当社は、AI システムの開発を始めて間もなく、当面は社会に対する潜在的なリスクが軽微な用途の AI システム・サービスのみを取扱う予定である。そのため、当社は AI ガバナンス・ゴールを設定していないが、潜在的なリスクが軽微とは言えない用途まで事業範囲を拡大する際には、AI ガバナンス・ゴールの設定について検討するつもりである。もちろん、検討内容を記録し、AI ガバナンス・ゴールを設定しない理由等をステークホルダーに説明できるようにしている。

【実践例 ii：小規模な事業者における AI ガバナンス・ゴールの設定】

当社は、AI システムの開発を始めて間もないものの、自社の開発する AI システムのリスクは軽微ではないため、AI ガバナンスへの取組を始めることとした。しかし、従業員数も少ないため、AI ガバナンス担当者等を特別に設定することは難しい。よって、経営者にて、自社の経営理念とも紐付けた「自社としての AI 開発の在り方」を描いた上で、現場担当者に共有をした。その後、経営層と従業員とで、実際に起きたインシデントについても共有しながら、「自社としての AI 開発の在り方」のブラッシュアップと全社としての目線合わせを行った。結果として、A4 一枚程度の内容ではあるものの、これを自社の AI ガバナンス・ゴールとすることとした。

【実践例 iii：各事業部を巻き込んだ AI ガバナンス・ゴールの設定】

当社は事業ポートフォリオが多様な主体であり、事業部ごとに AI 技術への関わり方が異なる。また、それぞれが独立しているカンパニー制を採用していることから、単一の AI ガバナンス・ゴールに合意することは容易ではない。そのため、現時点では「AI 事業者ガイドライン」の「共通の指針」を尊重することとし、それと並行して AI に関する全社的な研修の一部に AI 倫理や品質を追加することで AI 倫理や品質に対する理解を高めていくことを狙っている。さらに AI 相談窓口を社内に設置して、事業部からの事例集めを行っている。対外的には動きが遅く見えるかもしれないが、AI ガバナンス・ゴールの合意に向けたプロセスに価値があると考えている。なお、主体全体の AI ガバナンス・ゴールを設定する手前の段階で、AI システム・サービスを開発・提供・利用する事業部ごとの AI ガバナンス・ゴールの必要性や内容を検討することもありうると考えている。

【実践例 iv：ステークホルダーを巻き込んだ AI ガバナンス・ゴールの設定】

当社は、AI システム・サービスの開発・提供・利用に加え、他の主体の支援にも豊富な経験を有し、潜在的なリスクが軽微ではないと見られている用途向けの AI システム・サービスも開発・提供・利用している。これまで自社で開発した AI システム・サービスや、他社に提供した AI システム・サービスから重大なインシデントが発生したことはないが、当社が提供する AI システム・サービスの用途の中には社会的な受容が定まっていないものも多い

と理解している。そこで当社は、ステークホルダーとのコミュニケーションの強化を図るために AI ガバナンス・ゴールを設定し、公表している。ステークホルダーが当社のポリシーを理解しているため、AI システム・サービスを開発する担当者とステークホルダーとが AI 技術に対する基本姿勢を共有でき、コミュニケーションが円滑になったと評価されている。

3.システムデザイン（AI マネジメントシステムの構築）

行動目標 3-1【ゴールと乖離の評価、及び乖離対応の必須化】：

各主体は、経営層のリーダーシップの下、各主体の AI の AI ガバナンス・ゴールからの乖離を特定し、乖離により生じる影響を評価した上、リスクが認められる場合、その大きさ、範囲、発生頻度等を考慮して、その受容の合理性の有無を判定し、受容に合理性が認められない場合に AI の開発・提供・利用の在り方について再考を促すプロセスを、AI マネジメントシステム全体、及び AI システム・サービスの設計段階、開発段階、利用開始前、利用開始後等の適切な段階に組み込むことが期待される。経営層は、再考プロセスについて基本方針等の方針策定、運営層はこのプロセスの具体化を行うことが重要である。そして、AI ガバナンス・ゴールとの乖離評価には対象とする AI の開発・提供・利用に直接関わっていない者が加わるようにすることが期待される。なお、乖離があることのみを理由として AI の開発・提供・利用を恣意的に不可とする対応は適当ではない。そのため、乖離評価はリスクを評価するためのステップであって、改善のためのきっかけにすぎない。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組む。

- 現状の AI システム・サービスと「AI ガバナンス・ゴール」からの乖離を特定・評価
- リスクが認められる場合、その受容の合理性の有無を判定
- 受容に合理性が認められない場合、開発・提供・利用の在り方を再考/再考するためのプロセス²⁵の開発・提供・利用の適切な段階や各主体内の組織における意思決定プロセスへの組み込み
- 上記は経営層がリーダーシップを取って、その意思決定に責任を持ち、運営層が具体化した上で、継続的に実施
 - AI ガバナンス、組織マネジメントやプロジェクトマネジメントの仕組みを構築する責任は、運用責任と等しく重たいことを認識し、一意に取り組む
- 各主体内での認識の醸成を行うため、決定した乖離評価項目を各主体内で共有
 - 提供する AI の内容に応じて、各主体間で連携をして乖離評価を実施

なお、場合によっては外部の有識者の知見を活用しながら、自社の状況や AI システム・サービスのリスクの程度に合わせ以下のような資料を参考に、乖離評価プロセスを構築することが期待される。

- 行動目標 3-1-1 で述べるような各業界の標準的な乖離評価プロセス
- NIST, Artificial Intelligence Risk Management Framework (AI RMF 1.0)
- OECD, FRAMEWORK FOR THE CLASSIFICATION OF AI SYSTEMS
- Alan Turing Institute, Human Rights, Democracy, and the Rule of Law Assurance Framework for AI Systems

ISO/IEC 42001 においては、経営層のリーダーシップの下、AI マネジメントシステムと組織のビジネスプロセスを確実に統合させることが重要である旨が述べられており、具体的に以下の事項が期待されている

- AI マネジメントシステムに十分なリソースを確保すること

²⁵ 開発用語では一般的に、CI（Continuous Integration）や、CD（Continuous Delivery）等と呼ばれている。

- 効果的な AI マネジメントの重要性及び AI マネジメントシステムの要件に適合することの重要性を各主体内で伝えること
- AI マネジメントシステムが意図した AI ガバナンス・ゴールを達成できるようにすること
- AI マネジメントシステムの有効性に貢献する人材を指揮・支援すること
- 継続的な改善を促進すること
- その他、関連する主体への支援を実施し、各自の責任分野においてリーダーシップを発揮すること

[実践例]

【実践例 i：小規模な事業者の乖離評価プロセス】

当社は小規模企業であり、技術担当役員と開発担当者の距離が近く、プロジェクト数がそれほど多くないこともあり、技術担当役員は全てのプロジェクトを十分に把握できている。技術担当役員は、「AI 事業者ガイドライン」の「共通の指針」からの乖離を評価するための観点を設定し、開発担当者に対し、全ての AI システム開発プロジェクトについて、実務上可能な限り早い段階に、観点ごとに乖離を特定し、乖離により生じる影響を評価し、技術担当役員に報告するように指示している。そして、技術担当役員は、開発担当者以外の者も加えた開発担当者との会議において、開発担当者の報告内容に基づき、乖離により生じる影響を改めて評価し、リスクがある場合には、その受容の合理性の有無を判定し、受容に合理性が認められない場合に AI の提供の在り方について再考することとしている。

このプロセスの運用にあたっては、行動目標 3-1-1 にしたがって、当社が属する業界における標準的な乖離評価や本ガイドラインを参考にしながら、社内運用の標準化に努めている。

【実践例 ii：多数の事業部を有する事業者のプロジェクトごとの乖離評価プロセス】

多数の事業部を有する当社は、AI ガバナンス担当役員を決め、この役員の下に AI ガバナンスに関する社内組織を設置している。この委員会は、特定の AI システム・サービスの開発・提供・利用プロジェクトを担当する者以外から構成されており、「AI 事業者ガイドライン」の「共通の指針」を踏まえて当社が策定した AI ポリシーからの乖離評価をプロジェクトごとに実施することを任務としている。具体的には、AI ポリシーに基づいた評価リストを作成し、AI システム・サービスの開発・提供・利用について当該評価リストを用いて乖離を特定し、乖離により生じる影響を評価し、リスクがある場合、その受容の合理性の有無を判定し、受容に合理性が認められない場合に AI の開発・提供・利用の在り方を再考するよう、プロジェクト担当者に促すこととしている。乖離評価のためのリストについては、行動目標 3-1-1 にしたがって、当社が属する業界における標準的な乖離評価や本ガイドラインを参考にしながら作成しているが、実際のプロジェクトを選定し、経営層がプロジェクト担当者に伴走することで、リストの精緻化や運用の定着化を図る工夫もしている。なお、AI ガバナンスに関する社内組織では、プロジェクト担当者に対し、その再考の結果を報告するよう求めることとし、その報告内容の合理性に懸念がある場合には、AI ガバナンス担当役員からプロジェクトを所管する役員にその旨を通知し、適宜調整を図ることとしている。

なお、AI システム・サービスに伴うリスクは、用途、範囲、活用態様によって大きく異なり、プロジェクトを推進している担当者がその性質や程度を最もよく知っているとも考えられることから、潜在的なリスクが軽微であることが明らかな場合に経営層がプロジェクト会議に同席して簡素な乖離評価とする等、厳格な乖離評価を一律に求めない運用も考えられる。しかし、現時点では乖離やリスクを評価するためのノウハウがまだ当社内に十分蓄積されていないこともあり、AI ガバナンスに関する社内組織による一律の乖離評価を全てのプロジェクトが通過すべき必須のゲートとし、今後の経過を見ることとしている。

【実践例 iii：各主体間で連携をした乖離評価プロセス】

乖離評価のプロセスは、複数社によって担われるべき場合がある。例えば、サービスを他者に提供する AI 提供者が、AI システムの開発を自ら行うのではなく、AI 開発者にその開発を委託する場合、AI 開発者と AI 提供者の両者が乖離評価プロセスを分担することが合理的である場合がある。そしてこの場合、AI システムの開発から運用に至るまでに想定される流れはもちろん、乖離評価の方法や基準を AI 開発者と AI 提供者の間で共有することが重要である。AI 提供者が AI システムを用いたサービスの提供に伴うリスクを軽視する場合には、AI 開発者は難しい立場に置かれることになるため、このような対応は重要である。

このような委託を受けて AI システムの開発を行うことがある当社では、当社の責に帰すべき事情がある場合を除いて、AI システムの運用上の事故はサービスを提供する AI 提供者が負うこととなる契約を結んでいるが、それでも、この種の事故が発生したときに当社も紛争に巻き込まれるリスクはある。そのため、納入した AI システムの運用方法にも無関心ではいられない。実際、プロジェクトの終盤で運用上のリスクに気がつき、当該プロジェクトの再設計を AI 提供者に助言した上で、その再設計のコストの一部を負担せざるを得なかった経験がある。そのため、当社が属する業界における標準的な乖離評価や本ガイドラインを参考にしながら、個々の評価項目の意味を十分に理解した上で、乖離評価プロセスを確立し、自社で開発せず他者にサービスを提供するのみである AI 提供者にも共有するようにした。懸念項目を網羅している乖離評価プロセスを活用し、しかも早めに乖離評価を行うことで、顧客との交渉はスムーズになってきている。

次の実践例のように、通常の乖離評価プロセスに加えて、広く議論を行うことが必要な場合がある。

【実践例 iv：小規模な事業者であるものの、AI のリスクに鑑み実施する追加的な対応】

当社は AI システムの開発を主たる事業とする小規模企業である。技術担当役員が全てのプロジェクトについて進捗報告を受けることになっており、その報告の中には、公平性等の AI 倫理に関する事項も含まれている。AI 倫理の問題の中には、妥当な出力結果が得られるように十分なデータセットを用意する等技術的な配慮で対応できる事項もあるが、社会的にセンシティブな領域ではそれだけでは不十分な場合がある。

そこで当社では、そのようなセンシティブな領域における AI システムのプロジェクトの場合には、法務担当役員等を含めて話し合いをすることになっている。センシティブな領域の特定には、すでに広範囲に AI システム・サービスの開発・提供・利用しているリーディング企業の考え方等を参考にしている。このような情報収集には実務的な雑誌が有効である²⁶。そのような雑誌には概要記事が掲載されることが多く、その概要記事を手がかりにインターネット等で深い情報に当たることが効率的かつ効果的である。

個々のプロジェクトに関して外部の有識者や専門家を招いて意見交換している企業もあることは知っている。当社も事業の拡大に合わせて、そのような意見交換の場も設置していきたいと考えている。

【実践例 v：各主体に加え、必要に応じて外部有識者と連携した乖離評価】

当社は AI システム・サービスを開発している部門と運用している部門が混在する大規模企業である。すでに AI ポリシーを定め、当該ポリシーからの乖離評価を全てのプロジェクトに対して実施している。過去に対応したことのある分野におけるプロジェクトであれば、プロジェクトの早い段階で経営層が対応すれば十分であるが、これまでに対応したことがないセンシティブな分野において AI システム・サービスを開発したり利用したりする場合には、通

²⁶ センシティブな領域への対応の参考例に、舟山聡「AI 倫理に対する企業の取組み（1）」NBLNo.1170（2020 年 5 月）等がある。

常のプロセスではなく個別に相談してもらうようにしている。そして、そのような相談を受けたときには、開発部門、運用部門、法務部門等の責任者からなる横断的な会議を開催し、議論することとしている。経営層が通常の乖離評価プロセスにおいてそのようなプロジェクトを発見した場合も同様である。

当社では、定期的に外部の有識者や専門家を招いて、最近の AI インシデントやセンシティブ分野に関する情報を早い段階でキャッチできるようにしている。そのため、今のところは、有識者や専門家から入手した情報や一般的な助言を踏まえて、横断的な会議で議論すれば十分に対応可能である。他方で、当社の AI システム・サービスの用途先が広がってきていることから、今後は個別のプロジェクトに関しても外部の有識者等に意見を求める必要が出てくるのではないかと考えている。

行動目標 3-1-1【業界の標準的な乖離評価プロセスとの整合性の確保】：各主体は、経営層のリーダーシップの下、業界における標準的な乖離評価プロセスの有無を確認し、そのようなプロセスが存在する場合には、それを自社のプロセスに取り込むことが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 自社の知見・経験に留まらず、業界における標準的な乖離評価プロセスや他社・団体の取り組み等、外部のベストプラクティスの積極的な取り組み

各業界で参考となるガイドラインがある他、各省庁や各業界団体が AI の信頼性評価に関するガイドラインを公表している場合もあるので、自社に関係する省庁や団体の情報も確認することも有用である。

例えば、以下が挙げられる。

- 経済産業省「我が国の AI ガバナンスの在り方²⁷⁾
- 経済産業省、厚生労働省、消防庁「プラント保安分野 AI 信頼性評価ガイドライン²⁸⁾
- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン²⁹⁾
- パーソナルデータ+α 研究会 プロファイリングにおける「自主的取り組みに関するチェックリスト」
- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3³⁰⁾
- NIST, AI Risk Management Framework Playbook³¹⁾
- EU「信頼できる AI のためのアセスメントリスト」³²⁾
- IMDA, AI Verify An AI Governance Testing Framework and Toolkit³³⁾

²⁷⁾ 経済産業省「我が国の AI ガバナンスの在り方 ver1.1」（2021 年 7 月）

²⁸⁾ 経済産業省、厚生労働省、消防庁「プラント保安分野 AI 信頼性評価ガイドライン第 2 版」（2021 年 3 月），
<https://www.meti.go.jp/press/2020/03/20210330002/20210330002-2.pdf>

²⁹⁾ 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン第 4 版」（2023 年 12 月），
<https://www.digiarc.aist.go.jp/publication/aiqm/AIQuality-requirements-rev4.1.0.0112-signed.pdf>

³⁰⁾ 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver.1.3」（2023 年 4 月），
https://www.soumu.go.jp/mAiIn_content/000877678.pdf

³¹⁾ National Institute of Standards and Technology, AI Risk Management Framework Playbook（January, 2023）
https://aifc.nist.gov/AI_RMF_Knowledge_Base/Playbook

³²⁾ EU, Assessment List for Trustworthy Artificial Intelligence（ALTAI）（2020 年 6 月），
<https://digital-strategy.ec.europa.eu/en/library/assessment-list-trustworthy-artificial-intelligence-altai-self-assessment>

³³⁾ The Infocomm Media Development Authority, AI Verify - An AI Governance Testing Framework and Toolkit（May, 2022）
<https://aiverifyfoundation.sg/>

- 金融庁「モデル・リスク管理に関する原則」³⁴

[実践例]**【実践例 i：他社や他団体のガイドラインの乖離評価プロセスへの取り込み】**

AI ガバナンスの実践では多様な視点が欠かせない上に、他社との認識共有も必要であるから、自社だけで考えるのではなく他社や団体等の取り組みを参考にすべきある。このように考えている当社では、経営層に対して、乖離評価（AI システムが設計されたとおりに機能し、予測や推論等のタスクをどれだけ正確に実行できるかを測定する）プロセスを構築するにあたって社外の取り組みを調査するように指示した。

当社は産業用途の AI システムの開発を主たる事業としていることから、産業用途を中心に調査を行った。調査を進めていくと、例えば、経済産業省、厚生労働省、消防庁が、「プラント保安分野 AI 信頼性評価ガイドライン」、それを実施するための「実施内容記録フォーマット³⁵」、記載例をまとめた「信頼性評価実用例³⁶」を公表していることがわかった。また、AI プロダクト品質保証コンソーシアムが公表している「AI プロダクト品質保証ガイドライン³⁷」には、Voice User Interface、産業用プロセス、自動運転、OCR の事例が掲載されていることがわかった。さらに、国立研究開発法人産業技術総合研究所が「機械学習品質マネジメントガイドライン」を公表しており、産業用途別の実アプリケーションを対象とする具体的適用事例としてのリファレンスガイドを作成していることもわかった。加えて、ガイドラインに沿った品質マネジメントのプロセスと、その計画や記録に適した機械学習品質マネジメントガイドラインアセスメントシートの様式、さらにはその利用説明書も収録している³⁸。当社の現在の乖離評価プロセスには、これらの具体的な取り組みの一部が反映されている。

【実践例 ii：個人情報を取扱う場合の留意点の乖離評価プロセスへの取り込み】

当社では、業務外利用者から得られたデータに基づいた AI システム・サービスを開発・提供・利用している。AI ガバナンスの実践、特にプライバシー確保の実践にあたっては、AI モデルの構築とアウトプットへの配慮だけではなく、AI モデルに対するインプットデータの取扱いへの配慮が必要であると認識している。当社には個人情報の取扱いに関する豊富な経験があるが、そうであっても社外の取り組みに積極的に目を向けることが重要であると考えている。そこで、経営層に対して、乖離評価プロセスを構築するにあたって社外の取り組みを調査するように指示した。

AI モデルの構築とアウトプットへの配慮については、例えば、パーソナルデータ+α 研究会が提示しているプロファイリングにおける「自主的取り組みに関するチェックリスト」³⁹があることがわかった。「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3⁴⁰」については、インプットとアウトプットの両方の観点から AI に関する記述も見られるため参考になった。当社の現在の乖離評価プロセスには、これらの具体的な取り組みの一部が反映されている。

³⁴ 金融庁「モデル・リスク管理に関する原則」（2021 年 11 月） https://www.fsa.go.jp/common/law/ginkou/pdf_02.pdf

³⁵ 信頼性評価実施記録フォーマット <https://www.meti.go.jp/press/2020/03/20210330002/20210330002-3.pdf>

³⁶ 信頼性評価実用例概要（7 例） <https://www.meti.go.jp/press/2020/03/20210330002/20210330002-4.pdf>

³⁷ AI プロダクト品質保証コンソーシアム「AI プロダクト品質保証ガイドライン 2023.06 版」（2023 年 6 月），
<https://www.qa4AI.jp/QA4AI.Guideline.202306.pdf>

³⁸ 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントリファレンスガイド」（2022 年 7 月），
<https://www.digiarc.aist.go.jp/publication/aiqm/referenceguide.html>

³⁹ パーソナルデータ+α 研究会「プロファイリングに関する最終提言」（2022 年 4 月），p.10-21

⁴⁰ 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver.1.3」（2023 年 4 月），
https://www.soumu.go.jp/mAIIn_content/000877678.pdf

行動目標 3-1-2【利用者に対する、乖離可能性/対応策に関する十分な情報提供】：

各主体は、経営層のリーダーシップの下、提供している AI システム・サービスに一定の乖離が発生しうる場合には、ステークホルダーに対して、その事実や当該乖離への対応策に関する十分な情報を提供するとともに、問い合わせ先も明確にすることが期待される。

【実践のポイント】

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- AI システム・サービスと「AI ガバナンス・ゴール」との間に乖離が発生しうる場合は、ステークホルダーにその事実や対応策に関し情報提供をし、問い合わせへの対応等を通じたコミュニケーションを図ること
- 情報提供の効果を高めるために、開発主体や業界団体等とも連携しながら、様々な情報発信を通じて、AI 利用者及び業務外利用者のリテラシーの向上にも貢献していくこと
- 乖離によって生じるリスクの性質や蓋然性の大きさに応じて、情報提供の程度を検討すること

ステークホルダーのリテラシーに合わせた情報提供の具体例としては、用語の選択が挙げられる。

- リテラシーに幅がある場合には、AI システム・サービスの基本的な仕組みについて触れ、どのステークホルダーも理解できるよう平易に説明
- リテラシーが高いステークホルダーの場合、専門用語を交えつつメリハリをつけて説明

また、問い合わせ受付を通じたコミュニケーションについては、以下が挙げられる。

- 前提としての問い合わせ先の明記
- システムに AI が用いられていることをホームページ等の分かりやすい位置に明記

[実践例]**【実践例 i：「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」を参考にした情報提供】**

当社は AI システム・サービスを運用し、不特定多数の業務外利用者に対してサービスを提供している。サービス提供相手の AI に関するリテラシーに大きな幅があることが予想されることから、当社では、AI システム・サービスの運用にあたり、適切なリスク管理を行い、リスクを最小限にするための措置をとっていることや、情報の厳格な安全管理を行っていること等、リスクに関連する情報を、不慣れな業務外利用者でも理解できるようにわかりやすく整理して提供するとともに、問い合わせ先を明確にしている。これらの情報に加え、上述のとおり、サービス提供相手の AI に関するリテラシーに大きな幅があることが予想されることから、当社では、提供される情報等に AI システム・サービスの出力が用いられていることが業務外利用者に明らかな場合を除き、AI を使っていることをわかりやすく表示するとともに AI を活用したときのメリットとデメリットを明示している。そして、AI を好まない業務外利用者には代替サービスがあることも表示している。個人情報を取扱う場合もあることから、個人情報保護法や個人情報保護委員会のガイドラインに準拠することはもちろんのこと、「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」を参考にしつつ、業務外利用者との継続的なコミュニケーションを確立している。

【実践例 ii：提供先の AI リテラシーに合わせた情報提供（提供先の AI リテラシーが高い場合）】

当社は、実践例 i と同様、AI システム・サービスを運用し、外部にサービスを提供しているが、ビジネスで利用する企業に提供している点で実践例 i と異なる。当社のサービスの提供先は AI リテラシーが比較的高いため、

提供している AI システム・サービスには一定の乖離が発生しうる可能性や当該乖離への対応策について、専門的な用語も交えながらメリハリをつけた説明をするとともに、問い合わせ先を明確にしている。

今後、業務外利用者向けに AI システムを用いたサービスを提供する可能性があるが、サービス提供先の AI へのリテラシーに応じて十分な情報を提供していきたいと考えている。

【実践例 iii：AI リテラシーに合わせた情報提供（提供先の AI リテラシーに幅がある場合）】

当社は、実践例 i と同様の対応をしているが、AI 利用者及び業務外利用者が自らの判断で AI システムを用いたサービスを選択できるようにすること自体に付加価値があると信じており、他社との差別化のために情報提供の在り方を工夫している。また、AI システム・サービスだけではなく情報提供の在り方についてもフィードバックをもらうように工夫している。

【実践例 iv：AI 開発者等との連携】

当社は、実践例 i と同様の対応をしているが、AI 利用者及び業務外利用者からの問い合わせに対応するために必要な情報を AI 開発者から提供してもらえるように、その旨を契約で明確にしている。AI 利用者及び業務外利用者からの「フィードバック」は AI 開発者にとっても貴重な情報であることもあり、迅速に対応してもらっている。

コラム 2：データ提供者による、AI 開発者に対する乖離評価の十分な情報提供

データ提供者は、AI 開発者・AI 提供者が適切に乖離評価をできるようにするために、データの収集元、収集方針、収集基準、アノテーション付与基準、利用制約等のデータセットに関する情報を提供し、AI 開発者は十分な情報を提供するデータ提供者からデータセットを取得することが期待される。生成 AI の LLM の場合、データセットに関する情報提供に限界がある場合もあるため、サービス提供元から可能な限りの情報提供を受け、その事実を関連するステークホルダーで共有する。

[留意点]

AI システム・サービスは、公平性等に関わる品質に関して、その基となるデータに、大いに依存している。よって、AI 開発者・AI 提供者が適切に乖離評価を行うためには、基となるデータについてデータ提供者から、十分な情報提供を受けることが前提となる。

なお、データセットに関する情報は、以下のようなものが該当する。

- データ収集ポリシー：データ収集に対する考え方等
- データの収集元：オリジナルデータの提供元・提供者、データ収集の範囲等
- データの収集方針：収集の対象・項目、収集の手法、収集した期間等
- データの収集基準：収集したデータの条件、クレンジングの方法、データの偏り等
- データのアノテーション付与基準：画像/音声/テキスト等のアノテーションルール
- データの利用制約：他の権利に由来する制約等
- データの活用目的：特に個人情報を含むデータの場合、当該個人に提示された具体的な目的等

[実践例]

当社は、AI 開発者・AI 提供者にデータを提供しているデータ提供者であり、AI システムを開発する企業が適切に乖離評価をできるようにするために、データの収集元、収集方針、収集基準、アノテーション付与基準、利用制約等のデータセットに関する情報を提供している。また、十分に整理されていないデータセットを提供する場合であっても、乖離評価に必要なデータの収集元等の基本的な情報を十分に提供している。

行動目標 3-2【AI マネジメントシステムの人材リテラシー向上】：

各主体は、経営層のリーダーシップの下、AI マネジメントシステムを適切に運営するために、外部の教材の活用も検討し、AI リテラシーを戦略的に向上させることが期待される。例えば、AI システム・サービスの法的・倫理的側面に責任を負う役員、マネジメントチーム、担当者には、AI 倫理や AI の信頼性に関する一般的なリテラシー向上のための教育を、AI システム・サービスの開発・提供・利用プロジェクトの担当者には AI 倫理だけではなく生成 AI を含む AI 技術に関する研修を、全者に対して AI マネジメントシステムの位置づけや重要性についての教育を提供することが考えられる。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 外部講師によるものを含め、役職や担当に適した研修や教材を用い、AI リテラシーを向上させるような取組

- その際、各者の果たすべき役割に応じて適した研修や教材の活用
- 特に重要となる AI 倫理については全社員に受講させる等の工夫
- 今般の生成 AI に関する動向等を踏まえ、生成 AI 技術や、出力結果の信頼性に関する研修を行う等の工夫
- 行動目標 5-1 の AI マネジメントシステムの設計や運用から独立した関連する専門性を有する者による評価を自社で行う場合に、そのような専門性を社員が習得できるような配慮

なお、AI 技術の進歩に伴い求められる AI リテラシーも変化するため、人材育成と技術変化のスピードのミスマッチに留意する。

[実践例]

【実践例 i：外部教材等を活用した教育】

当社は小規模企業であり、研修対象者が少ないことから、AI リテラシーの向上の研修プログラムを自前で用意せず、外部の教材を用いることとした。米国の教育技術の営利団体である Coursera や日本ディープラーニング協会（JDLA）等が提供しているオンライン講座やテキスト、経済産業省の「マナビ DX」⁴¹や「マナビ DX Quest」⁴²等、国内外を含めて様々な教育プログラムが利用可能である。

当社は、研修対象者の到達度を計るための JDLA の検定試験シラバスに基づいたプログラムを活用している。JDLA の G 検定は、AI 技術の基礎から AI 倫理まで幅広く含む内容である。また、JDLA 主催の G2023#3（2023 年 7 月 7 日実施）の G 検定合格者アンケートにおいて学習時間は 15～30 時間と答えた合格者が 3 割と最多であり⁴³、研修対象者に過度な負担にならないことも確認している。

また、当社は AI も含めたデジタル技術を活用するためには社員のデジタルリテラシー向上が必須であると考えており、「IT パスポート」⁴⁴の取得を全社的に推奨している。

これまで実施してきて、当社が期待している効果が出ていると思っている。例えば、AI システム・サービスのインシデントについてニュースで断片的に聞いたことがあった程度の人が、AI 技術の初歩から倫理的な側面まで習得したことで、AI のリスクについても当事者意識を持って考えてくれるようになった。

【実践例 ii：自社教材を用いた教育】

当社は、AI システム・サービスの開発・提供・利用を事業の柱の 1 つとする大企業である。AI 技術や倫理に関する教材が外部にあることは知っているが、AI システム・サービスの提供数が多く、社会への便益/リスクが大きいため、汎用的な外部教材ではなく、自社の AI システム・サービスの用途を想定した事例を充実させた自社教材を使っている。加えて、AI を利用した実践的な社内教育に向けては、経済産業省の「マナビ DX Quest」におけるデータ付きケーススタディ教材⁴⁵も活用している。

AI に関する研修プログラムを作成した当初は、AI 技術に関する講義の最後に AI 倫理のパートを設けていたが、外部有識者を招聘した委員会からの指摘をきっかけに、AI 倫理に対する経営層の関心が一層高まり、AI

⁴¹ <https://manabi-dx.ipa.go.jp/>

⁴² <https://dxq.manabi-dx.ipa.go.jp/>

⁴³ Japan Deep Learning Association「G 検定合格者に聞きました」<https://www.jdla.org/certificate/general/start/>

⁴⁴ <https://www3.jitec.ipa.go.jp/JitesCbt/index.html> 2024 年度より生成 AI に関する問題を出題予定。

⁴⁵ マナビ DX Quest「データ付きケーススタディ教材の提供について」https://www.meti.go.jp/policy/it_policy/jinzai/manabi-dx-quest.html

倫理だけを独立させた e-learning を作成し、全社員に受講してもらっている。この e-learning には講義と確認テストが含まれており、AI 倫理に詳しくない人でも 1 時間程度で終わることができるように工夫されている。自社の AI システム・サービスの用途に関連づけることで短時間でも高い学習効果が得られていると考えている。

【実践例 iii:生成 AI に関する教育】

直近では生成 AI に対応する人材の育成も必要だと考えている。経済産業省の「生成 AI 時代の DX 推進に必要な人材・スキルの考え方」⁴⁶や「デジタルスキル標準」⁴⁷を参考に、「マナビ DX」に掲載されている生成 AI 関連の e-learning の受講を従業員へ推奨するとともに、生成 AI を適切に利用するための能力や知識を問うための JDLA の検定試験である「JDLA Generative AI Test」の活用も検討している。

行動目標 3-3【各主体間・部門間の協力による AI マネジメント強化】：

各主体は、学習等に使用するデータセットの準備から AI システム・サービスの開発・提供・利用までの全てを自部門で行う場合を除き、経営層のリーダーシップの下、営業秘密等に留意しつつ、自社や自部門のみでは十分に実施できない AI システム・サービスの運用上の課題と当該課題の解決に必要な情報を明確にし、公正競争確保の下で、可能かつ合理的な範囲で共有することが期待される。その際に、必要な情報交換が円滑に行われるよう、各主体間で予め情報の開示範囲について合意し、秘密保持契約の締結等を検討することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 各主体のみでは解決できない AI システム・サービスの運用上の課題や解決に必要な情報の特定
- 各主体間で、知的財産権やプライバシー等に留意しつつ、可能かつ合理的な範囲での共有
- 上記は、各種法令・規制や各主体の AI ポリシー、営業秘密や限定提供データ等、公正競争確保が前提

関連する法令・規制として不正競争防止法や個人情報保護法等が考えられるのに加え、各主体間の契約も当然関連するため、法務担当者やリスク・コンプライアンス担当者に確認すべきである（詳細は「別添 6. 「AI・データの利用に関する契約ガイドライン」を参照する際の主な留意事項について」をご参照）。

また、各主体が複数の国にまたがる場合、データの自由な越境移転（Data Free Flow with Trust、以下「DFFT」という）の確保のための適切な AI ガバナンスに係る国際社会の検討状況やそれを踏まえた相互運用性（「標準」と「枠組み間の相互運用性」の二側面）に留意し、データの流通をはじめとしたリスクチェーンの明確化と開発・提供・利用の各段階に適したリスク管理・AI ガバナンスを実施する。

[実践例]

【実践例 i：AI に詳しくない顧客に向けた丁寧な情報共有】

⁴⁶ <https://www.meti.go.jp/press/2023/08/20230807001/20230807001-b-1.pdf>

⁴⁷ <https://www.ipa.go.jp/jinzai/skill-standard/dss/index.html>

当社は、開発した AI システムを顧客に納入し、当該顧客が AI サービスの運用にあっている。この AI システム・サービスは運用環境の変化によって精度が低下し、場合によっては設備の破損等の損害につながるおそれがある。そのため、顧客に対しては、AI システムの出力のモニタリングを依頼し、品質劣化の判断の仕方も伝えている。

AI に詳しくない顧客に対して、モニタリング等を単に依頼するだけでは機能しない。AI システム・サービスのメンテナンスが必要な理由とその原因（学習データと運用時の入力データの分布が変化する等）、当該原因による出力の変化の傾向等について、時間をかけて説明して納得してもらう必要がある。標準的な情報を提供すれば十分な場合もあるが、AI システム・サービス開発側がそのように考えた場合でも、納入先に積極的に質問を促し、可能な限り認識を一致させることが重要である。必要に応じて、保守サービス契約等を締結し、納入後であっても積極的に質問を受け付ける体制を整えることも重要である。また、AI システム・サービスの再学習を行った場合には、再学習によって出力がどのように変化したかを丁寧に説明することが重要である。例えば、再学習の留意点として、AI が Output として得たデータを Input として再学習に利用するケースで起きる劣化問題である「モデル破綻」（AI が自分自身の誤りを繰り返し学習し、その誤りが徐々に蓄積されることで、AI システム・サービスのパフォーマンスが徐々に劣化していく現象）等についても説明している。

【実践例 ii：円滑な情報共有のための秘密保持契約の締結】

当社は、上記の情報共有が円滑に行われるように、AI 開発者と AI 提供者の間で予め情報の開示範囲について合意しておき、秘密保持契約の締結も締結している。

【実践例 iii：口頭による追加的な説明を通じた情報共有の徹底】

当社が開発している AI システムは、特定のデータセットによって学習させたものであり、データセットに含まれていない対象に適用すると好ましくない出力結果となる可能性がある。そのため、当該 AI システムを AI 利用者に提供しようとする AI 提供者に対して、学習等に利用したデータ、利用したモデルの概要や精度等の性能を説明するだけでなく、AI システムを利用すべきではない状況や対象についても伝えている。情報提供を徹底するために、紙書面や電子書面で伝えるだけでなく、別途時間を確保して口頭でも説明し、そのような説明を行ったことにサインしてもらうようにしている。

【実践例 iv：複数の国をまたぐ場合の情報共有】

当社は日本に本社を置く AI の開発・提供を行う企業である。当社は AI システム・サービスをグローバルに提供しており、AI 利用者や業務外利用者が海外に籍を置く場合には、リスク管理上、より注意を払った連携が欠かせないと考えている。特に、国ごとに文化・風土・AI に関する受容性等の社会的な差異がある点には配慮することが重要である。

また、国ごとに異なる法的規制に対応するため、当社は、AI 利用者及び業務外利用者の所在国における個人情報保護法に相当する法律や、データセキュリティに関する規制等を調査し、それに基づいたセキュリティ対策等を構築している。

加えて、当社のビジネスに影響を与えうる DFFT に関する国際的な議論やデータの流通に係る様々な枠組みについても、専門家も活用しながら、情報を収集している。

コラム 3：国ごとに文化・風土・AI に関する受容性等の社会的な差異がある点への配慮事例

実際の対応例として、Microsoft Corporation が採用している Hub&Spoke モデル（Spoke 部分でサービス提供国・地域からも AI Champ を任命し当該国・地域の視点を取り入れながら対応している）がある^{48,49}。

また、同社のマルチステークホルダーエンゲージメントの例として、スティムソンセンターの Strategic Foresight Hub（戦略的展望ハブ）と組んで立ち上げた Global Perspectives Responsible AI Fellowship がある。このフェローシップの目的は、AI に関する様々な議論にグローバルサウス諸国の関係者を招き入れることとされている^{50,51}。

行動目標 3-3-1【各主体間の情報共有による現状理解】：

各主体は、経営層のリーダーシップの下、学習等に使用するデータセットの準備から AI システム・サービスの利用までの全てを自社で行う場合を除き、営業秘密に留意しつつ、各主体間の、関連する情報共有の現状を理解し、適時に理解を更新することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- AI システムの開発に用いたデータの取得源/データの量・質や分布、カテゴリー毎の概要等の情報の共有
- 共有の際、産業技術総合研究所の「機械学習品質マネジメントガイドライン」等の情報共有の標準化に向けた取り組みの参照

その際、各主体が以下のことを正しく理解することが期待される。このため、各主体間の情報共有を円滑化し、AI 技術の社会実装を促進するためにも、共有情報を標準化することが期待される。

- AI システムの開発は、提供・利用の場面を想定
- AI システムの提供は、AI システムがどのような制約下で開発されたものか、サービスとしてどのように利用されるかを正しく理解したうえで実施
- AI サービスの利用は、提供者の意図した利用方法を理解し、その範囲内で実施

情報の共有/取得の方法としては、以下が挙げられる。

- 関係省庁や業界団体等が策定するガイドラインの確認
- AI 倫理や品質に関する団体への所属

⁴⁸ マイクロソフトの責任ある AI プログラムの詳細について（2021/2/2）：コンプライアンスの基礎となるガバナンス
<https://news.microsoft.com/ja-jp/2021/02/02/210202-microsoft-responsible-ai-program/>

⁴⁹ The building blocks of Microsoft's responsible AI program（2021/1/19）：Governance as a foundation for compliance
<https://blogs.microsoft.com/on-the-issues/2021/01/19/microsoft-responsible-ai-program/>

⁵⁰ 日本における AI ガバナンスの推進（2023/10/6）：マイクロソフト内での AI ガバナンス
<https://news.microsoft.com/ja-jp/2023/10/06/231006-about-the-potential-of-ai-in-japan/>

⁵¹ Advancing AI governance in Japan（2023/10/5）：Governing AI within Microsoft
<https://blogs.microsoft.com/on-the-issues/2023/10/05/responsible-ai-governance-japan/>

- 海外を含めた先行事例の参照
 - 専門機関のレポートの参照
 - セミナー等への参加
 - 専門家への取材 等

[実践例]

【実践例 i：各主体間の情報共有の標準化に向けた取組】

当社では、自社の情報提供の在り方を決めるにあたって、経営層のリーダーシップの下、営業秘密に留意しつつ、各主体間の情報共有の現状を理解し、定期的に理解を更新することとした。

情報収集を進めていくと、各主体間の情報共有の標準化に向けた様々な取り組みがなされていることもわかった。例えば、国立研究開発法人産業技術総合研究所は、機械学習利用システムの品質に関する社会合意としての基準とすることを目的の 1 つに掲げ、「機械学習品質マネジメントガイドライン」を公表しており、経済産業省、厚生労働省、消防庁が、このガイドラインを基礎として、プラント保安分野の信頼性評価実施記録フォーマットを作成していることもわかった。また、食品の成分表示等が人々の責任ある意思決定に貢献しているように、AI モデルの性能も表示していくことが重要であるとの認識の下、モデルカードの提案がなされていることも把握した⁵²。

現時点で学習済みの機械学習モデル等の性能や品質を各主体間で共有するための標準的な文書化手続きはないが、社内の体制を整備するにあたっては、自社の独自基準を一から考えるのではなく、様々な取り組みを参考にするつもりである。

【実践例 ii：AI 倫理や品質に関する団体を通じた各主体間の情報共有の現状理解】

当社は、AI 倫理や品質に関する団体に所属し、AI システム・サービスの性能等に関する情報提供の適切な在り方について他の所属企業と積極的に意見交換している。AI 利用者や業務外利用者には AI システム・サービスに関する十分な情報を提供することが重要であるが、AI の性質や限界等に詳しいわけではないことから、専門家以外には理解が難しいような情報や、膨大かつ詳細な情報を一方的に提供しておけばよいと考えることは適当ではない。情報提供の適切な在り方を考えるためには、自社の直接的な経験だけではなく、他社との意見交換を通じて間接的に多くのステークホルダーと触れていくことも重要と捉えている。

AI 開発者から AI 提供者に伝えるべきと思われる情報には、例えば、AI システムの開発に用いたデータに関する情報がある。例えば、データの取得源（オープンデータということもある）、データの量や分布、これに含まれるカテゴリー毎の概要等を挙げることができる。また、開発の際に選択した（選択しなかった）アルゴリズムや、生成されたモデルの概要、特に、どのような条件下でテストを行い、その結果、どの程度の精度が得られたか等を説明することも重要である。

これらの観点は AI システム・サービスの開発や提供の経験が豊富な企業にとっては目新しいものではないが、当社は「伝え方」が重要であると考えている。どのような内容をどの程度の深さで説明するかである。各主体間の情報共有の現状を理解することは、AI ガバナンスの全体設計を考える上で重要であり、そこに AI 倫理や品質に関する団体に参加する意義がある。

⁵² Google, “Vertex AI,” <https://cloud.google.com/vertex-ai>

【実践例 iii：複数の国をまたぐ場合の各主体間の連携】

当社は、AI 開発・提供を行う企業である。他主体との連携が多いことより、情報共有を重要度の高いものと位置づけ、積極的に海外を含めた先進事例の動向調査を行っている。

まず、大学、専門機関等のレポートを参照している。加えて、これらのレポート等で紹介されている先進企業のホームページに掲載されている取り組み事例を参照している。

また、SNS 等での情報も直近では重要度が増しているように思っている。SNS 等のオンラインプラットフォームでの投稿を見るとともに、セミナーの案内等も参照し、自社に関連深いものについては積極的に従業員に参加を促している。

加えて、定期的に、最新トレンドや事例に知見がある AI に関するコンサルタント等の専門家を自社に招聘し、自社の戦略にどのように落とし込むとともに、どのような行動に繋げるべきか、アドバイスを受けている。

行動目標 3-3-2【環境・リスク分析のための日常的な情報収集・意見交換の奨励】：

各主体は、経営層のリーダーシップの下、日常的に、AI システム・サービスの開発や運用に関するルール整備、ベストプラクティス、インシデント等の情報を収集するとともに、社内外の意見交換を奨励することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 日常的な、ルール整備、ベストプラクティス、インシデント等の情報収集
- AI マネジメントチームを社内に設置している場合であっても、社内の他部門との議論や勉強会を開催したり、他社も参加する団体活動に関与

[実践例]**【実践例 i：経営層を主体とした議論の奨励】**

AI 倫理に関しては、指針こそ定まりつつあるが、指針の尊重の在り方については正解のない中で模索していくしかないこと、さらには他社も同様に活動していることから、経営層に対して AI の適切な開発・提供・利用に関する情報収集や意見交換を奨励し、部門を越えた社内の議論や勉強会で共有するように指示している。

このような活動を継続することで、決定版のような解決策はないものの大きなトレンドをつかめるようになってきた。このような活動の成果を、適時に実施される環境・リスクの分析に反映している。

【実践例 ii：小規模な事業者における議論の奨励】

当社は AI システムを開発する小規模企業である。社内には AI 倫理の尊重よりも成長を重視すべきという意見があるため、法務部門と技術部門で AI 倫理に関する社内議論や勉強会から始めることとした。言葉の定義や使い方が部門ごとに異なる可能性があるためファシリテーター役を設置したところ、円滑に議論が進み、成長を重視すべきと話していたエンジニアもすでに公平性等を取扱う論文に接していて、AI 倫理に対する認識に大きな違いがないことがわかってきた。エンジニアは AI 倫理の尊重を技術によって実現することに関心を示し始めてから、開発プロセスが AI 倫理に整合的なものに変化しつつある。今後は社外との意見交換も進めたい。

行動目標 3-4【予防・早期対応による利用者のインシデント関連の負担軽減】：

各主体は、経営層のリーダーシップの下、インシデントの予防と早期対応を通じて AI 利用者及び業務外利用者のインシデント関連の負担を軽減することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- システム障害、情報漏洩、クレームの発生等のインシデントの予防と早期対応
- ライフサイクル全体を通じてインシデントを予防し、又は発生した場合に早期に対応できる体制を構築

インシデントを予防し、又は発生した場合に早期に対応できる体制の構築の際には以下の点に留意する。

- 過去事例の蓄積や行動目標 3-3 で収集した情報の活用による予防策・事前準備策の検討
- 関連する主体間での責任の分配（リスクを軽減できる者への分配）
- 確率的に一定の経済的損失が発生する用途に対応する保険の活用を通じた経済的な損失への早期の対応

[実践例]**【実践例 i：責任所在の明確化】**

AI システム・サービスの開発・提供・利用には、AI 開発者、AI 提供者、AI 利用者、業務外利用者等様々な立場の主体や個人が関与することが多く、さらに AI にはいわゆるブラックボックス性があることから、責任の所在が曖昧になりやすい。インシデントを予防するためには、リスクを軽減できる者に責任を分配することが重要である。よって、当社ではインシデントが生じた際の責任者を明確化し、当該責任者に一定の権限を付与することで、インシデントへ早期に対応できる体制を構築している。また、インシデントの発生に備えて事前に準備することでインシデントへの早期対応力を高めることも重要である。

【実践例 ii：インシデントに備えた保険の活用と継続した研究開発】

当社は、実践例 i の実施を基本としつつ、一部の用途では保険の活用を検討している。社会全体への恩恵が大きいかかわらず、AI システム・サービスの動作に関して一定の不確実性が避けられず、まれに一定の経済的な損失が発生してしまう用途では、保険を活用することでインシデントから生じる経済的な損失に早期に対応することで AI 利用者及び業務外利用者の負担を軽減することが重要であると考えている。もちろん、AI 利用者及び業務外利用者の信頼を継続的に高めていくためには AI システム・サービスの不確実性を低減していくことが重要であると認識しており、そのための研究開発を継続している。

行動目標 3-4-1【各主体間の不確実性への対応負担の分配】：

各主体は、経営層のリーダーシップの下、リスクを全体で最小化できるように AI システム・サービスの不確実性への対応の責任所在を明確化することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- そもそも AI システム・サービスの不確実性については、技術的に一定の対応は可能⁵³ではあるものの、完全に取り除くことが難しいという前提を認識
- その上で、各主体間での責任所在を可能かつ合理的な範囲で明確化

各主体間での責任所在の明確化においては、契約等が有効な場合もあると思われる。

契約については、各主体のいずれが AI 品質を保証する必要があるかについては議論があり、各 AI システム・サービスによって状況が異なるが、本ガイドラインの「別添 6. 「AI・データの利用に関する契約ガイドライン」を参照する際の主な留意事項について」も参考になる。

加えて、AI 開発からサービス実施にわたるバリューチェーン・リスクチェーンが複数国にまたがることが想定される場合、データの越境移転、データローカライゼーション等に係る適切な AI ガバナンスの検討にも留意する。

[実践例]

【実践例 i：他の主体への情報連携を通じた不確実性への対応】

AI システムを開発する当社は、このような指針を踏まえ、関連するステークホルダーに使ってもらうことが AI 技術への社会的な信頼向上に資すると考えている。情報を集めていくと、AI 提供者の中には、AI システム・サービスは従来型のソフトウェアの延長上にあると考え、AI 開発者が AI システム・サービスの品質に関する全ての責任を負うべきと考えている企業もあることがわかった。他方で、AI 提供者が AI システム・サービスへの期待を理解し、AI 提供者自身が腹落ちするまで丁寧に説明することで、AI 提供者自身が再学習のタイミングを判断できる場合があることがわかった。そして、「AI システム品質保証ガイドライン」に記載されているように、「品質保証の技術者やチーム、組織は、開発や営業と共に、AI システムに関する顧客の理解を深めるような活動を行う」ことが重要であるという考え方が少しずつ広がっている現状を理解した。ただ、依然として AI 開発者が品質を保証すべきという考え方が根強いことから、「AI システム品質保証ガイドライン」のような活動が与える好影響が広がることに期待しつつ、不確実性への対応負担に関する調査を今後も定期的に行いたいと考えている。

【実践例 ii：責任追及時に備えた説明の準備】

当社は、他社が開発した AI システムを用いてサービスを提供している AI 提供者である。AI 開発者とは、「AI・データの利用に関する契約ガイドライン⁵⁴」のモデル契約書を参考にした契約書を用いて契約を締結している。これによれば、AI システム・サービス（学習済みモデル）の AI 開発者は、仕事の完成や成果の性能・品質等の保証は行わない一方、一定以上の注意水準をもって業務を行わなければならないことになっている。当社はあくまで他社が開発した AI システム・サービスを運用しているにすぎないという意識があり、AI システム・サービスの運用に関連して不適切な事例が発生したり、それ以外の場面で業務外利用者から説明を求められたりした場合に、AI 提供者である当社がどのようなアカウンタビリティを果たすことが重要であるかを真剣に考えていなかった。

しかし、最終的な法的責任の所在はともかく、AI 利用者に対して直接サービスを提供しているのは当社である以上、当社が運用している AI システム・サービスについて AI 利用者から説明を求められた場合に、少なくとも一次的にこうした要求に対応する責任の一切を免れることはできないことと、十分な説明ができない場合に当社

⁵³ 適切なデータセットの準備、適切なモデルの選択、AI システム利用開始前の検証や試験の実施等の AI システムの開発時の対応によって不確実性の低減を目指すアプローチがある。

⁵⁴ 経済産業省「AI・データの利用に関する契約ガイドライン」（2018 年 6 月）

https://www.meti.go.jp/policy/mono_info_service/connected_industries/sharing_and_utilization/20180615001-1.pdf

にレピュテーションリスクが生じることに気がついてからは、AI 開発者の協力を得ながら、リスク低減のために AI 提供者ができることを行い、必要に応じてそのことを説明していくという方針に変えた。

【実践例 iii：データの取扱いに関する不確実性への対応】

当社では、当社が保有するデータを利用した AI システムの開発を他社に委託することを計画しているが、当社にはデータの取扱いに関するノウハウが乏しく、クレンジング等のデータの前処理だけではなく、データの品質の確保を含めた一切切を他社に任せたいと考えていた。当社は、現在保有するデータを集めて AI システムの AI 開発者に提供してしまえば、データを取扱うプロである AI 開発者がデータに必要な処理を行ってくれ、当社が希望する AI システム・サービスを開発してくれるものだと思って認識していた。

しかし、開発委託前に情報を収集していくと、一般の主体間におけるデータの提供においても参考となる内容としてまとめられている「AI・データサイエンス人材育成に向けたデータ提供に関する実務ガイドブック」⁵⁵があることがわかり、そこには「提供前の委託データの品質をコントロールできるのは委託者のみ」であるという考え方や、一定の前提の下では「成果の利用による利益も委託者のみに帰属することから・・・危険責任と報償責任の考え方に基づいて・・・創出された成果の利用・実施等に伴う損害の責任は、原則として委託者が負う」と考えられる場合があること等、AI 開発者の留意事項がまとめられていた。

現在は、AI システムの開発に必要なデータの内容は、当社が開発を予定している AI システム・サービスの内容によって定まってくること、AI 開発者の側で対応できることには限界があること等を理解している。当社はここで一度立ち止まり、データ提供段階であっても AI システム・サービスの開発・提供・利用のライフサイクルの重要な一部であることを踏まえ、各主体間の不確実性への対応負担について再検討することを考えている。

【実践例 iv：生成 AI における不確実性への対応】

当社は、生成 AI を用いた AI システム・サービスの開発・提供を、他国を含む AI 利用者に対して行っている企業である。

まず、生成 AI においては著作権を含む権利関係において問題が生じる可能性が高まる点に留意し、学習用データ・生成モデルに関する著作権やその他の権利について、明確で公平な契約を締結することに重点を置いている。開発プロセスにおいて使用されるデータが多国籍であるため、異なる法的枠組みに基づく権利関係が生じる可能性があるとして認識している。そのため当社は、専門家の意見を聞き関連する法令やリスクの棚卸を行っている。加えて、AI 利用者と負うべき責任範囲の明確化を行っている。その際、検討プロセスを文書に残し透明性を確保することで、法的な問題が発生した場合でも、円滑に解決に向け動くことができるように配慮を行っている。

【実践例 v：複数の国にまたがる場合の不確実性への対応】

また、当社は、AI のバリューチェーン・リスクチェーンが複数国にまたがる場合の課題に対処するため、データの越境移転やデータローカライゼーションに関する AI ガバナンスを検討している。その際には、専門家のアドバイスを受けつつ、関係する各国の法令を確認した上で、提供する AI サービスの内容や与えるリスクの規模に応じ、必要な対応を行っている。

⁵⁵ 経済産業省「AI・データサイエンス人材育成に向けたデータ提供に関する実務ガイドブック」（2021 年 3 月）

当社は、国際的な規制の変化に柔軟に対応できるよう、リスクヘッジとして異なるデータストレージ方法の検討も始めている。具体的には、地域別のデータセンターの展開を行い特定国でのデータ取扱いの法的要件に対応することができるようにしたり、クラウドを活用することで国ごとの法的な変更に適用できる柔軟性を確保したり、データの移動や処理を分離することで国ごとの異なる法的環境への対応をスムーズに行うために、データの分散型処理も検討している。

行動目標 3-4-2【インシデント発生時の対応の事前検討】：

各主体は、経営層のリーダーシップの下、AI インシデント発生時に、AI 利用者や業務外利用者への説明、影響範囲や損害の特定、法的関係の整理、被害救済措置、被害拡大防止措置、再発防止策の検討等を速やかに実施するため、対応方針の決定や計画の策定を検討するとともに、当該対応方針又は計画に関して適宜実践的な予行演習の実施を検討することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- AI インシデント発生時の対応方針や計画を策定
- 上記について、適宜実践的な予行演習を実施

インシデント発生時に備え以下のような体制をあらかじめ整備することが期待される。

- 連絡受付窓口の設置
- 対応担当役員のアサイン
- 対応担当者個々の役割分担
- 対応アプローチ・プロセス
- リスク管理部門等の社内関係者への連絡体制
- 顧問弁護士等の社外関係者や専門家への連絡体制
- ステークホルダーに対して通知するプロセス等

なお、AI システム・サービスのインシデントの事業への影響が大きい場合は、事業継続計画（BCP）を実際に発動させる際の重大要素として、AI インシデントを盛り込むことも検討する。

[実践例]

【実践例 i：小規模な事業者におけるインシデントに備えた体制整備】

当社は AI システム・サービスを提供する中小企業である。AI インシデントの発生可能性をできるだけ低くすることはもちろん重要であるが、インシデント発生の可能性をゼロにすることは困難であるため、発生時の損害を最小限に抑えるための計画の策定・発動が重要であると認識している。

具体的には、インシデントが発生した場合に備えて、連絡受付窓口の設置、対応を担当する役員のアサイン、社内における連絡体制はもちろん、社外の関係者・専門家への連絡体制を整備している。あらゆるインシデントに万全に対応することは困難だが、自社の AI サービスの内容に鑑みて想定される主なインシデントについて、ある程度典型的に整理した上で、大まかな対応方針を策定している。また、策定した対応方針の実施可否の確認のため、定期的に予行演習も実施している。

【実践例 ii：外部専門家の巻き込みを通じたインシデントに備えた体制整備】

当社は AI システム・サービスを開発・提供する大企業である。インシデントの発生時の対応を速やかに行えるように、連絡受付窓口の設置、担当役員のアサイン、リスク管理部門、法務部門、広報部門、危機管理部門との連絡・連携体制はもちろん、社外の関係者、専門家への連絡体制も整備している。

また、想定しうるインシデントを複数パターン想定し、どういった法的責任が発生しうるかについてあらかじめ専門家に相談して整理し、その上でリスク評価を実施している。人身・物損事故、プライバシー侵害、財産的損害等、様々な種類の被害が生じうるので、類型ごとに各主体、業務外利用者等の法的責任関係を予め整理しておくことは有用である。また、AI システム・サービスに固有の考慮要素として、異常な結果を出力する原因が多様であること（アルゴリズムの異常、学習データの真正性、学習データの偏り等）や、想定外の影響が生じやすいことも念頭に置いている。想定外の事態が発生した場合であっても、事業への影響を低減させるような技術上・運用上の仕組みを定期的にアップデートするよう努力している。

【実践例 iii：BCP への AI インシデントの盛り込みを通じたインシデントに備えた体制整備】

当社は、全社的に BCP（事業継続計画）を策定しているが、当社が運用している AI システムが停止した場合に事業継続に支障を生じるおそれがあるため、BCP の発動トリガーの 1 つに AI インシデントを盛り込むこととし、AI システムの全部又は一部を停止することとなった場合に備えた初動対応及び事業継続のための計画を策定している。また、計画を策定するだけでは意味がなく、有事に計画を実行できないことが大きなリスクになることを認識し、毎年少なくとも一度は計画を実践するための演習を行っている。

またチェックリストがやみくもに肥大化すると形骸化しやすいため、チェックリストの項目数に注意を払い、自社内で浸透した項目は外し、最新項目に入れ替える等、随時チェックすべき項目の洗練化を行っている。

4.運用

行動目標 4-1【AI マネジメントシステム運用状況の説明可能な状態の確保】：

各主体は、経営層のリーダーシップの下、例えば、行動目標 3-1 の乖離評価プロセスの実施状況について記録する等、AI マネジメントシステムの運用状況について外部の関連するステークホルダーに対する透明性、アカウントビリティを果たすことが期待される

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 適切かつ合理的な範囲で、AI マネジメントシステムの運用状況について外部ステークホルダーに対して説明可能な状況にすること

AI マネジメントシステムの運用状況のアカウントビリティを高めるためには、以下のような取組が有用である。

- 行動目標 3-1 の乖離評価プロセスの実施状況の記録
- AI システム・サービス開発・提供・利用に関する社内/外部との会議記録の保持（担当者以外の関係者も閲覧可能な状態を確保）
- AI に関する社内研修の実施

乖離評価プロセスの実施状況の記録については、独自に乖離評価のためのチェックリストを作成し、それを基に確認・記録することも有用である。

- 検討にあたっては別添 7（別資料）チェックリストを参照し、カスタマイズすることも有用

なお、他部門や外部に対しての説明を目的とした際、可能な限り正確かつ理解できるものとするため、海外文書等の記載内容も参考となる。

例えば、NIST「説明可能な AI の 4 原則」⁵⁶では、説明可能な AI の 4 原則や説明の 5 類型について解説している。

[実践例]

【実践例 i：記録の徹底と閲覧を通じた説明可能な状態の確保】

「運用」においてデータや情報を得ておくことが改善に向けた意思決定につながるため、当社では、環境・リスクの再分析、評価等を通じた改善の肝は「運用」にあると考えている。

当社では、AI ガバナンスの実践に限らず、さらなる改善のために記録を残すことを重視しており、システムデザインについての記録を残すことは当然であると考えている。例えば、個々の AI システム開発プロジェクトにおける乖離評価を記録し、AI に関する研修を実施した場合には実施概要を作成し、AI システム・サービスの開発や運

⁵⁶ NIST, Four Principles of Explainable Artificial Intelligence (Draft) (2020 年 8 月)

2021 年 9 月になお、5 類型については、Draft のみで述べられている。

(Draft) <https://www.nist.gov/publications/four-principles-explainable-artificial-intelligence>
<https://nvlpubs.nist.gov/nistpubs/ir/2021/NIST.IR.8312.pdf>

用に関する社内の会議や他の主体との会議の議事録を残し、担当者以外の関係者もそれらを閲覧できるようにしている。

当社は比較的規模の大きな企業であるため、一般的なコーポレートガバナンスに関連する行動目標には困難を感じていない。しかし、企業内の組織的分化が進んでいることから、比較的新しい技術である AI については、部門間の専門性や理解度にギャップが生まれ、組織間連携に影響が出ないか心配している。例えば、行動目標 3-1-2 にしたがって設置した問い合わせ窓口に関し、問い合わせ担当者が、技術的な内容を理解できずに、重大インシデントへの気づきが遅れることも恐れている。行動目標 3-2 にしたがって、従業員のリテラシーの向上のための取り組みを実施しているが、当面は、外部からの問い合わせについては、概要だけではなく詳細も経営層に積極的に報告することとしている。

なお、行動目標 3-1 の乖離評価プロセスの実施状況の記録等については、他部門や外部への説明という目的のため、可能な限り正確かつ相手に理解できる記録とし、説明の限界を意識できるよう努めている。

【実践例 ii：小規模な事業者におけるチェックリストを用いた記録】

当社は AI システムを開発する小規模企業である。技術担当役員は全てのプロジェクトを把握しており、自らプログラミングしたり論文を読解したりする等 AI に大変詳しく、AI 倫理の問題についても強い関心を持っている。そのため当社では、部門間の専門性のギャップが問題になることはないと考えている。他方で、プロジェクトに関わる人たちの専門性が高いために、いちいち確認しなくても、行動目標ができていそうと思込みがちである。そのため、プロジェクトの進捗報告のレポートに乖離評価チェックリストを添付し、技術担当役員が必要に応じて聞き取りできるように工夫している。

また、当社は専門性が高い集団であることから、世間の認識とのずれが生じやすい傾向があると分析している。そのため、運用状況を確認しつつ、行動目標 3-3-2 にしたがって日常的な情報収集や意見交換から得られた状況を定期的に共有することで、社会的受容に意識を向けるようにしている。

【実践例 iii.AI ライフサイクル全体を通じたチェックリストの活用】

当社は AI システム・サービスの開発・提供を行う企業である。チェックリストを活用して AI ライフサイクル全体にわたり、未然にリスクを防ぐ取り組みを行っている。

チェックリストは自社で 0 から作成するのではなく、AI 事業者ガイドラインの「別添 7（別資料）チェックリスト」を材料とし、自社流にカスタマイズしながら作成を行っている。チェックリストの作成にあたっては、各主体のみで対応する事項もあるものの、主体間での連携が必要な事項もある。自社内の他部署と連携をしてチェックリストのカスタマイズを行うとともに、顧客である AI 利用者とも議論をしつつ、AI ライフサイクル全体を考慮したうえで自社流のチェックリストの作成を行った。

またチェックリストがやみくもに肥大化すると形骸化しやすいため、チェックリストの項目数に注意を払い、自社内で浸透した項目は外し、最新項目に入れ替える等、随時チェックすべき項目の洗練化を行っている。

行動目標 4-2【個々の AI システム運用状況の説明可能な状態の確保】：

各主体は、経営層のリーダーシップの下、個々の AI システム・サービスの仮運用及び本格運用における乖離評価を継続的に実施するために、仮運用及び本格運用の状況をモニタリングし、PDCA を回しながら、結果を記録

することが期待される。AI システムを開発する主体は、AI システムを提供・利用する主体による当該モニタリングを支援することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 各主体の AI の運用の状況をモニタリングし、PDCA を回しながら、結果を記録
- 各主体が単独で対応することが難しい場合には、各主体間で連携

具体的に、以下のような場合に各主体が連携をすることが有用な場合がある。

- AI 開発者主体による、性能に大きく影響する入力・出力のログの自動取得の設定
- AI 開発者主体による、AI 提供者に対する具体的なモニタリングの方法の説明
- AI システム・サービスからの出力に基づいた、再学習の必要性の協議
- AI 開発者と AI 提供者との間の、AI システム・サービスに期待する内容のすり合わせ

[実践例]

【実践例 i：主体間での連携したログの記録】

当社は AI システム・サービスを運用し、当該システム・サービスを AI 利用者に提供している企業である。AI 開発者に依頼して AI システム・サービスを開発したが、精度だけではなく公平性にも対応できるように、データセットの内容から AI モデルの振る舞いの確認に至るまで、開発担当者から説明を受けてきた。この開発担当者からは、開発時に想定した利用者像と実際の利用者像に違いが生じてきた場合には、精度や公平性の確保のために AI システム・サービスのメンテナンスが必要であると言われた。

AI システム・サービスのコードを解釈できるほどの知識を持つ従業員は当社にいないことから、AI 開発者に依頼し、性能に大きく影響する入力や出力のログを自動的に取れるようにしてもらうとともに、モニタリングの仕方を教えてもらった。その後、行動目標 3-1 の一環として、チェックリストを作成し、性能維持のための管理方法を定めた。現在は、この管理方法により継続的にモニタリングを行い、記録を残している。

【実践例 ii：主体間で連携した再学習のタイミングの通知】

当社は、他社が提供する AI システム・サービスを開発する企業である。当社は AI システム・サービスを法的に所有しているわけではないが、保守契約を通じて、他者の運用に一定の責任を負っていて、AI 提供者としての側面も有している。このような状況では、AI システム・サービスの性能維持のためのモニタリングにおいて、日常的に AI システム・サービスを運用している企業（AI 提供者）の協力が欠かせない。実際、この AI 提供者は、AI システム・サービスからの出力を記録し、品質の著しい劣化を出力から判断し、実際の状況も確認した上で、再学習の必要性について当社に報告することになっており、その後の再学習の必要性に関する会議にも AI 提供者が加わることとしている。

AI 提供者が再学習のタイミングを判断できる理由は、AI 提供者自身が AI システム・サービスに対して具体的に何を求めている、具体的に何ができるかを良く理解しているからである。AI 開発者は、AI 提供者の AI システム・サービスへの期待を理解し、AI 提供者自身が腹落ちするまで何ができるかを丁寧に説明することが重要であ

る。「AI システム品質保証ガイドライン」に記載されているように、「品質保証の技術者やチーム、組織は、開発や営業と共に、AI プロダクトに関する顧客の理解を深めるような活動を行う」ことが重要である⁵⁷。

行動目標 4-3【AI ガバナンスの実践状況の積極的な開示の検討】：

各主体は、AI ガバナンス・ゴールの設定、AI マネジメントシステムの整備や運用等に関する情報を、コーポレートガバナンス・コードの非財務情報に位置づけ、開示することを検討することが期待される。上場会社以外であっても、AI ガバナンスに関する活動の情報を開示することを検討することが期待される。そして、検討の結果、開示しないと判断した場合には、開示しないという事実をその理由とともにステークホルダーに公開することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 自社の AI に対する基本的な考え方から、AI マネジメントシステムの整備・運用等まで、AI ガバナンスに関する情報の透明性の確保を検討
- 開示する場合には、コーポレートガバナンス・コードの非財務情報に位置づけること等も検討
- 開示しない場合には、その事実をその理由とともにステークホルダーに公開

具体的に、開示することが期待される AI に関する情報として、例えば、以下のようなものが考えられる。

これらを対外的に公表することは、社内外の信頼感の醸成/認知拡大/意識向上等にもつながると考えられる。

- 自社の AI に関する基本的な考え方/AI ポリシー
- AI 倫理に関する自社の取り組み
- 自社の AI ガバナンス

[実践例]

【実践例 i：ホームページ等を通じた AI ガバナンス・ゴールの開示】

当社は AI システムを開発する小規模企業である。AI システムの開発は単なる技術的な営みではなく、社会に対する深い理解に支えられていなければならないと考えており、AI ガバナンス・ゴールを明示的に設定することよりも、この考え方を社内に浸透させることを優先している。顧客や株主はこの姿勢を支持してくれている。もちろん「AI 事業者ガイドライン」の「共通の指針」を尊重することが重要であると考えているが、その背後にある思想の理解こそが重要である。

当社は非上場会社であるため、コーポレートガバナンス・コードの対象ではないが、ホームページ等で AI に対する上述の考え方を積極的に発信している。当社の潜在的な顧客や当社の AI システム・サービスの業務外利用者は、AI システム・サービスを技術的なツールではなく、社会技術的なツールであると受け止めてくれており、他社との差別化にもつながっている。

【実践例 ii：非財務情報への記載の検討】

⁵⁷ AI プロダクト品質保証コンソーシアム「AI プロダクト品質保証ガイドライン 2023.06 版」(2023 年 6 月)、p.2-8

当社は AI システムを開発する上場企業である。AI の適切な開発は当社の重要なテーマであるところ、すでに自社の AI ポリシーを設定し、その達成に向けた体制の整備を終えている。そして、これらの活動内容を自社のホームページで公表し、プレス発表もした。他方で、これらの活動について経営層から強いメッセージを発することを検討したが、当社の AI 関連事業は、現時点では、中長期的な収益に直接影響を与えないことから、そのようなメッセージを発するまでには至っていない。

このような中、先日、ある機関投資家から企業ガバナンスに関するアンケートが届き、そこには AI 倫理への対応ぶりを聞く設問があった。このようなアンケートに企業の中長期的な発展に対する投資家の意向が反映されているとすれば、AI 倫理も企業の健全な発展を判断するために必要な情報であることがうかがえる。今後は、改めて、AI 倫理の取り組みを統合報告書に掲載することを含め、経営層からの積極的な情報発信を検討していく予定である。

5.評価

行動目標 5-1【AI マネジメントシステムの機能の検証】：

各主体は、経営層のリーダーシップの下、AI マネジメントシステムの設計や運用から独立した関連する専門性を有する者に、AI ガバナンス・ゴールに照らして、乖離評価プロセス等の AI マネジメントシステムが適切に設計され、適切に運用されているか否か、つまり行動目標 3、4 の実践を通じ、AI ガバナンス・ゴールの達成に向けて、AI マネジメントシステムが適切に機能しているか否かの評価と継続的改善を求めることが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 継続的改善に向けた評価の重点ポイントを、経営層が自らの言葉で明示
- AI マネジメントシステムの設計や運用から独立した関連する専門性を有する者を割り当て
- 上記の者による AI マネジメントシステムが適切に機能しているか否かのモニタリング
- モニタリングの結果を基に、継続的な改善を実施

AI マネジメントシステムの設計や運用から独立した関連する専門性を有する者は、具体的に以下が想定される。

- 自社で実施する場合
 - 内部監査部門
 - AI マネジメントシステムに監査対象業務に関与していない AI 開発者を加えた自己監査 等
- 社外のリソースを活用する場合
 - 外部監査主体や国際機関等⁵⁸
 - ◇ 高い専門性と他社の監査経験の活用や応用が可能である者

また、それぞれの場合において、以下の点に留意することが重要である。

- 自社で実施する場合
 - リスク管理担当部署や AI ガバナンス担当役員（その直属の監査担当者）への報告を義務付ける等、実効性を高めるための対策を講じること
 - 内部監査部門に AI の技術的な側面を理解できる者を配置したり、内部監査部門による監査に各部門が協力する等、内部監査部門が AI に詳しくないことを理由に評価が表面的なものにならないよう配慮すること
 - ◇ 例えば、監査での指摘事項が、見えやすい運用プロセスに偏り、設計・開発プロセスが少ない等
- 社外のリソースを活用する場合
 - 上記外部監査主体等は、各主体の固有の課題や個別の具体的な状況等について必ずしも詳しい訳ではない。よって、外部監査主体等に任せるのではなく、各事業者においても、社会的受容の情報収集やステークホルダーとの対話等を自発的に進めることが重要となること

⁵⁸ World Economic Forum, "The Presidio Recommendations on Responsible Generative AI"（2023 年 6 月）

- 外部のリソースを使う必要性が高いケースとしては、関連するステークホルダーに対して、AI マネジメントシステムが適切に機能しているかを説明する必要性が生じる状況が考えうる。その際には、どの国のどのような管理基準、評価基準に応じて、どのスコープでの評価、報告が必要とされているかを明確にしたうえで、その評価を実施可能な専門性を有した社外リソースを選定することが重要となること

マネジメントや監査組織の基準⁵⁹に関しては現在国際的にも議論中であり、動向を確認することが期待される。

[実践例]

【実践例 i：内部監査部門を通じたモニタリング】

当社には AI マネジメントシステムの導入前から社内規定の運用等を監査する独立した内部監査部門がある。AI マネジメントシステムの導入時に内部監査部門の業務範囲を拡張し、AI マネジメントシステムをその対象に加えた。当社では、内部監査担当者が、各部門の協力を仰ぎながら、組織や規定等が、適切に運用され、有効に機能しているかを調査及び確認し、不適切な運用や機能不全が見られた場合は、当該部門に改善を求めるとともに、他部門のベストプラクティスがあれば、それを共有している。

AI システム・サービスに対する社会的受容は変化している。当社では、社会的受容に歩調を合わせた改善こそが重要であると考えており、環境・リスク分析を参考にしながら、社会からの期待が高い分野やインシデントの報告数が多い分野を中心に内部監査を行っている。改善に向けた各部門の協力が得られるように、全ての分野に対して一律に社内ルール等への厳密な適合性評価を行うのではなく、リスクの高い分野を選定している。選定理由を伝えると各部門の協力を得られやすい。

【実践例 ii：外部リソースを活用したモニタリング】

当社は AI システムを開発する小規模企業である。AI マネジメントシステムを評価する内部監査部門を設けず、AI マネジメントシステムに直接関与していない開発部門内の者を加えて自己監査を行ってもらっている。この自己監査という第一の監査ラインはチェック機能不全に陥り、身内に甘くなる傾向があるため、自己監査結果を AI ガバナンス担当役員直属の監査担当者に報告させ、報告内容を整理して、AI ガバナンス担当役員に報告することになっている。AI ガバナンス担当役員は AI 技術や倫理に詳しいことから、自己監査中心でありながらも十分に機能していると考えている。現在は、第三者的な視点を強化するとともに、内部監査は改善のためにあることを伝えるために、部門横断的なフィードバック会合を開催して監査結果を共有するとともに意見交換を行うことを検討している。

【実践例 iii：内部と外部を組み合わせたモニタリング】

当社には内部監査部門があるが、AI マネジメントシステムに関しては外部監査を活用してみることにした。外部監査には高い専門性と他社の監査経験の横展開を期待している。AI システムに対する社会的受容は変化していて相場感が形成されていない。自社なりに十分に対応できていると自負していても死角があるかもしれない。

⁵⁹マネジメント標準としては、Information technology—Artificial intelligence—Management system が、監査組織の基準としては、ISO/IEC42006 Information technology—Artificial intelligence—Requirements for bodies providing audit and certification of artificial intelligence management systems が議論中である。

外部監査サービスはコンサルティングファーム等を中心に提供されている。外部専門家による監査を受けることで、社内外の専門的な情報を活用したアドバイスを受けることができる。また、外部専門家のアドバイスの第三者性と客観性によって、社内へのフィードバックがよりスムーズになる効果も期待している。

このようなメリットがある一方で、受け身になる可能性を心配している。外部専門家はそれぞれの企業に固有の課題等に必ずしも詳しいわけではない。外部専門家のアドバイスを最大限活用するためには、外部監査に頼った場合でも AI に対する社会的受容を能動的に理解しようという姿勢が重要である。

行動目標 5-2【社外ステークホルダーの意見の検討】：

各主体は、経営層のリーダーシップの下、ステークホルダーから、AI マネジメントシステムやその運用に対する意見を求めることを検討することが期待される。そして、検討の結果、当該意見の内容を実施しないと判断した場合には、その理由をステークホルダーに説明することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- ステークホルダーから、AI マネジメントシステムやその運用に対する意見を求めることを検討
- 当該意見の内容実施しない場合、その理由をステークホルダーに説明

また、ステークホルダーと協働できるよう、以下のような取組を通じてネットワークを構築し、日常的に自社の事情に即したアドバイスを得ることができる状態にしておくことが重要である。

- 外部講師を交えた社内研修を開催
- AI 倫理や品質に関心が高い人々と業務外で緩やかなネットワークを形成し、情報交換
- AI 倫理や品質に関する意見交換の場やカンファレンス等の場を積極的に活用
- AI やそれ以外の分野の専門家で構成される AI ガバナンスに関する外部有識者等を含む組織を設置

[実践例]

【実践例 i：AI ガバナンスに関する外部有識者等を含む組織を通じた検討】

コーポレートガバナンス・コードの「株主以外のステークホルダーとの適切な協働」の章には、従業員、顧客、取引先、債権者、地域社会をはじめとするステークホルダーとの適切な協働に努め、とりわけ取締役会・経営層は、これらのステークホルダーの権利・立場や健全な事業活動倫理を尊重する企業文化・風土の醸成に向けてリーダーシップを発揮することが重要であるとまとめられている。また、AI システム・サービスの適切な開発・提供・利用への関心が高まっていることから、上場会社はもちろんのこと非上場会社も、AI ガバナンスやマネジメントシステムの評価や見直しにあたってはステークホルダーとの協働が求められる場合がある。

当社は、AI ポリシーの設定やポリシー達成に向けた体制作り等の初期設定は企業自身が行うべきものであり、その後の改善も企業自身が主体的に行うべきと考えているが、「社会からの見え方」を知るためにステークホルダーとの協働も重視している。当社はすでに AI ポリシーを定めるとともに、AI ポリシーの意味やポリシー達成のための活動を公表している。しかし、「社会からの見え方」を知り、客観的な倫理性を確保する必要があると考え、ステークホルダーと対話を重ねていくことを目的として、AI やそれ以外の分野の専門家で構成される AI ガバナンスに関する外部有識者等を含む組織を設置することとし、AI 技術の専門家だけでなく、法律、環境問題、消

費者問題の専門家も招聘している。一般的な指摘を受けるだけでは不十分であることから、当社の具体的な課題を提示して深い洞察を得られるように工夫している。

【実践例 ii：意見交換の場を活用した検討】

実践例 i のような外部有識者委員会の設置のような「見える施策」に目が行きがちであるが、そのような場だけが全てではないと考えている。重要なことは、AI 倫理や品質に関心の高い人々とのネットワークに緩やかにつながり、この情報交換網の中に入ることである。当社の経営層には、AI 倫理や品質に関する意見交換の場で積極的に発言したり、カンファレンス等のスピーカーを積極的に引き受けたりするように促している。もちろん、そのような活動を業績評価に含めている。

このようなアプローチでは、意見が集まらないという懸念の声を聞く。この懸念の背景には、日本人は意見交換やカンファレンスの場において本音で話さないことがあると考えられる。しかし、自分から意見を発信することで相手の意見を引き出す、いわゆる「アクティブソナー型」の人たちは、意見交換やカンファレンスの後に個人的に意見をくれる人がいることを知っている。このように意見を得ることこそが重要と考えている。

この経営層の人脈をたどり、外部講師を交えた社内研修を開催したことがあった。この研修では、当社の AI ガバナンスの取り組みを AI 関連業務に従事する従業員に対して説明することに加え、当社の取り組みをこの外部講師に評価してもらった。この外部講師は当社の経営層と日常的に意見交換をしていることから、当社の事情に即したアドバイスを得ることができ、研修受講者から好評価を得たところである。

このような状況であるため、外部有識者委員会の設置についても検討しているが、今のところは必要性を感じていない。

6.環境・リスクの再分析

行動目標 6-1【行動目標 1-1～1-3 の適時の再実施】：

各主体は、経営層のリーダーシップの下、行動目標 1-1 から 1-3 について、新技術の出現、規制等の社会的制度の変更等の外部環境の変化を迅速に把握し、適時に再評価、理解の更新、新たな視点の獲得等を行い、それを踏まえた AI システムの改良ないし再構築、運用の改善を行うことが期待される。なお、行動目標 5-2 を実施する際に、既存の AI マネジメントシステムやその運用だけではなく、環境・リスク分析を含め、本指針でも重視しているアジャイル・ガバナンスに即した AI ガバナンス全体の見直しに向けた外部からの意見を得ることも検討することが期待される。

[実践のポイント]

各主体は、経営層のリーダーシップの下、以下に取り組むことが期待される。

- 新技術の出現、AI に関連した技術革新、規制等の社会的制度の変更等の外部環境の変化を把握すること
- 適時に再評価、理解の更新、新たな視点の獲得等を行い、それに即した AI システムの改善、再構築、運用の変更等を行うこと
- AI ガバナンスの考え方を組織の文化として根付かせること

社会的なトレンドについては、定期的に外部有識者を招集した会議を開催する等を通じて外部の情報を取得することも重要となる。

適切な再評価のタイミングは各主体によって様々ではあるが、定期的（四半期/半年/年次等）な実施とは別に、以下のようなタイミングも候補となる。

- 重大な「ヒヤリ・ハット」が発生した場合
- 重大なインシデントが他社で発生した場合
- 社会的に、特定の AI 技術やインシデントへの注目が高まった場合
- 社会的に、規制環境が変化した場合

重大な「ヒヤリ・ハット」の発生を認識する体制構築としては、例えば、以下の工夫が有用である。

- 従業員が「ヒヤリ・ハット」を報告しやすくする仕組みの整備
 - 匿名報告システムの導入、ヒヤリ・ハットの報告者に対する報奨制度の導入、啓発活動 等
- 定期的なリスク評価とモニタリング体制の構築

なお、AI ガバナンスに係る体制や運用を実効的に機能させていくためには、AI ガバナンスの考え方を組織全体へ浸透させ、文化として根付かせていくべきである。そのためには、各主体に所属する者が AI ガバナンスについて、自身の役割を認識するとともに部分最適に陥らないように全体最適の当事者意識を持つことが重要である。各主体内における文化の醸成に係る取組の例としては、以下が挙げられる。

- 組織横断的なコンソーシアムやコミュニティ活動等地道な日々の AI ガバナンス伝承活動を評価する人事評価制度の導入
- 新入社員配属時、部署異動時のタイミングでの教育サポート

- 社員必携の行動基準や冊子等における AI ガバナンスに対する姿勢への言及
- 定期的な e-learning や研修教育 等

[実践例]

【実践例 i：経営層への報告機会に合わせた再分析】

当社では、重大な「ヒヤリ・ハット」が生じた場合、特定のインシデントへの社会の注目が大きく高まった場合、規制環境が変化した場合等を除き、定期的に環境・リスクの分析を行い、経営層にレポートすることとしている。AI システム・サービスの適切な開発・提供・利用をめぐる議論は非常に活発であるが、アジャイルな再分析による AI ガバナンス疲れを防ぎ、大きなトレンドをアジャイルに把握することを重視している。経営層への報告機会は大いなるトレンドに目を向ける良い機会である。

【実践例 ii：AI ガバナンスに関する外部有識者等を含む会議体の実施に合わせた再分析】

当社は、実践例 i のように定期的に環境・リスクの分析を行っているが、AI ガバナンスと AI マネジメントシステムの検証には重複する要素もあることから、定期的開催される外部有識者を招聘した AI ガバナンスに関する外部有識者等を含む組織の議題に、AI システム・サービスがもたらす便益/リスクと AI システム・サービスの開発や提供に関する社会的受容を盛り込み、外部有識者からこれらの論点に関する大きなトレンドを得るようにしている。

B.AI ガバナンスの構築に関する実際の取組事例

コラムを掲載予定

別添 3.AI 開発者向け

本章では、まず、「AI 開発者に関する事項」（第 3 部）に記載されている内容について、「ポイント」及び「具体的な手法」を解説し、その後「AI により目指すべき社会と各主体が取り組む事項」（第 2 部）の「C. 共通の指針」のうち、AI 開発者について特に重要なものについて[具体的な手法]を解説する。

なお、ここで述べる[具体的な手法]は、あくまで一例である。従来からある AI と生成 AI の双方について書かれているもの、あるいは一方のみに当てはまるものもある。具体的な検討にあたっては、開発予定の AI のもたらすリスクの程度及び蓋然性、技術特性、各主体の資源制約に配慮することが重要である。

また、最も高度な AI システムを開発する主体は、広島 AI プロセスにおいて制定された「高度な AI システムを開発する組織向けの広島プロセス国際指針⁶⁰」及び「高度な AI システムを開発する組織向けの広島プロセス国際行動規範⁶¹」についても留意すべきである。

⁶⁰ <https://www.mofa.go.jp/mofaj/files/100573469.pdf>

⁶¹ <https://www.mofa.go.jp/mofaj/files/100573472.pdf>

A. 本編「第3部 AI 開発者に関する事項」の解説

[本編の記載内容（再掲）]

データ前処理・学習時

D-2) i. 適切なデータの学習

- ◇ プライバシー・バイ・デザイン等を通じて、学習時のデータについて、適正に収集するとともに、第三者の機密情報、個人情報、知的財産権に留意が必要なもの等が含まれている場合には、法令に従って適切に扱うことを、AI のライフサイクル全体を通じて確保する（「2）安全性」、「4）プライバシー保護」、「5）セキュリティ確保」）
- ◇ 学習前・学習全体を通じて、データのアクセスを管理するデータ管理・制限機能の導入検討を行う等、適切な保護措置を実施する（「2）安全性」、「5）セキュリティ確保」）

[ポイント]

データ、モデルの質の向上の重要性を前提に、AI 開発者は、AI システムの学習等に用いるデータの質に留意することが重要となる。

- 利用する AI の特性及び用途を踏まえ、AI の学習等に用いるデータの質（正確性や完全性等）に留意する
- また、AI によりなされる判断は、事後的に精度が損なわれたり、低下したりすることが想定されるため、想定される権利侵害の規模、権利侵害の生じる頻度、技術水準、精度を維持するためのコスト等を踏まえ、あらかじめ精度に関する基準を定めておくことが期待される。精度が当該基準を下回った場合には、データの質に留意して改めて学習させる
- なお、ここで言う「精度」には、AI が倫理的に正しい判断を行っているか（例えば、AI が暴力的な表現を行っていないか、ヘイトスピーチ等を行っていないか 等）も含まれる

[具体的な手法]

- データに個人情報、機密情報、著作権等の権利や法律上保護される利益に関係するものが含まれていないか、確認を実施
 - 固有表現抽出
 - ◇ 人名、クレジットカードの番号 等
- 権利や法律上保護される利益に関係するものが含まれる場合には、個人情報・機密情報・著作権等の適切な取扱いを実施
 - 差分プライバシー
 - ◇ AI 開発者が実際のデータを知ることがないように、データにノイズを加えること
 - データ管理コンソール
 - ◇ 個人情報を提供した者が個人情報の提供の可否や範囲、承諾の撤回等を行う、かつこれらの現状を簡単に把握できるツールやコンソールを提供すること

- データの暗号化
 - ◇ データを転送する際や保存する際に、強力な暗号化アルゴリズムを使用して情報を保護すること
- データが適切（正確性や完全性等の品質が確保されている）かつ安全であることを保証するための対策を実施
 - タイムスタンプの確認 等
- 技術的に可能で合理的な範囲で、データの出所を把握するための手段の実施
 - データリネージ（来歴メカニズムの構築）
 - ◇ データが元々どこから来たのか、どのように収集され、管理され、時間の経過とともに各主体内で移動したのかを知ること
 - ◇ 当該データは、コンテンツを作成したサービス又はモデルの識別子を含むが、利用者情報を含める必要はない

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第4版」（2023年12月）
- NIST, AI Risk Management Framework Playbook（2023年1月）

[本編の記載内容（再掲）]

データ前処理・学習時

D-3) i. データに含まれるバイアスへの配慮

- ◇ 学習データ、モデルの学習過程によってバイアス（学習データには現れない散在的なバイアスを含む）が含まれることに留意し、データの質を管理するための相当の措置を講じる（「3）公平性」）
- ◇ 学習データ、モデルの学習過程からバイアスを完全に排除できないことを踏まえ、必要に応じて、単一手法ではなく多様な手法に基づく開発を並行して行う（「3）公平性」）

[ポイント]

AI 開発者は、AI システムの判断にバイアスが含まれることに留意する。また、AI システムの判断によって個人及び集団が不当に差別されないように留意する。

- データセットは、ある事象や現象の一部分を切り取ったものでしかなく、現実世界を完全に反映したものではない。そのため、データセットに偏りが生じたり、特定のコミュニティがデータセット上に過少又は過剰に現れたりするリスクがある⁶²ことに留意する。また、その基礎となるデータセットに偏りや過少代表・過剰代表がないかを確認する
- 現実社会の偏見・偏向がデータセットに潜在し、結果として既存の差別が継承・再生産されてしまう可能性があるため、「公正さ（fairness）」との関係で留意する

[具体的な手法]

- 学習前
 - 使用しない特微量⁶³の決定
 - ◇ 不当なバイアスが AI システムに生じているかを確認するといった限定的な場合を除いて、人種、民族、性別といった偏見や差別が生じる可能性のある属性をモデルに学習させない
 - ◇ モデルに学習させない属性を決定する際には、憲法 14 条 1 項が列举する事由や、国際的な人権に関するルールで言及されている属性を考慮する
 - ◇ AI が学習するデータ量が少なすぎてバイアスが生じることを防ぐために、意図した動作をするために必要となるおおよそのデータ量の水準も考慮に入れる
 - データの品質の管理・向上
 - ◇ データセットの再構築
 - 例えば、データの男女比が AI の開発目的にとって相応しくなるように一部データを削除、アノテーション内容を調整
 - ◇ ラベルの見直し
 - データの前処理において、学習データのラベルは多くの場合人間が作成・付与するため、（意図的に又は意図せずに）ラベル付与を行う者のバイアスが入り込むことに留意

⁶² 後者は「過少代表・過剰代表（underrepresentation and overrepresentation）」の問題といわれる。

⁶³ 特微量は、データの特徴を数値で表現したもので、機械学習で使用される。例えば、身長や体重等が人の特微量に該当する。これらの数値はアルゴリズムに供給され、モデルの学習や予測に利用される。

- ◇ データの代表性への留意
- ◇ ISO/IEC 27001（情報セキュリティ、サイバーセキュリティ及びプライバシー保護－情報セキュリティマネジメントシステム－要求事項）への準拠
- ◇ ISO/IEC 25012（ソフトウェア工学－ソフトウェア製品品質要求事項及び評価（SQuaRE）－データ品質モデル）に基づいた評価
- 学習中
 - 公平性に関するペナルティ項を追加した正則化の実施
 - ◇ 公平性に関する制約条件付きの最適化手法を使用すること
 - RLHF（Reinforcement Learning from Human Feedback：人間による評価を利用した強化学習）の実施
 - ◇ AI モデルの出力に人間の価値基準・嗜好を反映させるための学習プロセス
- 学習後
 - データや学習過程・結果のモニタリングの実施
 - ◇ 必要に応じて人間がアルゴリズムを調整したり、定期的に学習させるデータセットの質や量を見直す等のデータセットの再構築を検討
 - データの適切な保管とアクセスコントロールの実施
 - ◇ データの暗号化とセキュアな保管
 - ◇ データの保管とアクセスに関する ISO/IEC 27002（情報技術－セキュリティ技術－情報セキュリティ管理策の実践のための規範）への準拠

[参考文献]

- デジタル庁「データ品質ガイドブック（B 版）」（2021 年 6 月）
- パーソナルデータ+α 研究会「プロファイリングに関する最終提言」（2022 年 4 月）
- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- NIST, AI Risk Management Framework Playbook（2023 年 1 月）
- AI プロダクト品質保証コンソーシアム「AI プロダクト品質保証ガイドライン」（2023 年 6 月）

コラム 4 : データ前処理・学習時におけるデータに含まれるバイアスへの配慮についての事例⁶⁴**【ユースケース名】**

7 分で融資 (Loan in 7 minutes)

【スコープ】

顧客の行動を分析した上で、AI が数分間で与信判断を行い、顧客に最適な融資提案を行う完全自動化ソリューション

【データを取扱うシーン】

ソリューションは、内部（例えばトランザクションデータ）及び外部（例えば信用情報機関）システムと相互作用の上、顧客に関するすべての詳細情報を収集し、AI と機械学習手法に基づくアルゴリズムの適用によって自動的にリスクの推定を実行し、顧客に対する適切なオファーを計算する。

【実装手段】

設計段階から公平性を考慮する開発手法 Fairness by Design⁶⁵の活用

- 設計段階からステークホルダーの意見を取り入れる参加型デザイン手法を用いて、ローン審査の判断基準となる収入、勤務先、取引履歴等の属性と、公平性に関わる年齢、性別、国籍等の属性の重みを数値化することで、ビジネス上の要件と公平性をバランスさせた AI モデルの開発を可能とし、さらに、公平性に関わる属性、文化やビジネス慣習の違いでは容認されない偏見を除去する手法として、年齢や性別、国籍等の属性が特定の条件で組み合わせられた時に現れる交差バイアスを軽減するアルゴリズムも組み込む

潜在的バイアスへの対策として、Linux Foundation⁶⁶配下の Intersectional Fairness プロジェクトによる OSS 技術の活用⁶⁷

- Intersectional Fairness は、複数の属性の組み合わせによって引き起こされる交差バイアスに対処するためのバイアス検出及び緩和技術であり、既存の単一属性バイアス緩和方法を活用して、交差バイアスに関して機械学習モデルの公平性を確保する

⁶⁴ データに含まれるバイアス等への配慮に関する事例を示す。この事例は、日本産業標準調査会（JISC）が日本国の代表を担っている国際標準化機関 ISO、及び IEC が共同で設置した専門委員会 ISO/IEC JTC1 配下の分科委員会 SC 42（ISO/IEC JTC 1/SC 42）が策定した技術報告書 ISO/IEC TR 24030（2021）に収集されたユースケースを引用したものである。<https://www.iso.org/standard/77610.html>

⁶⁵ <https://pr.fujitsu.com/jp/news/2021/03/31-1.html>

⁶⁶ 世界最大で最も普及しているオープンソース ソフトウェア プロジェクト <https://www.linuxfoundation.jp/>

⁶⁷ <https://lfaidata.foundation/projects/intersectional-fairness-isf/>
<https://pr.fujitsu.com/jp/news/2023/09/15.html>

[本編の記載内容（再掲）]

AI 開発時

D-2) ii. 人間の生命・心身・財産、及び環境に配慮した開発

- ◇ AI 開発者は、ステークホルダーの生命・心身・財産、及び環境に危害を及ぼすことがないよう、以下の事項を検討する（「2）安全性」）
 - 様々な状況下で予想される利用条件下でのパフォーマンスだけではなく、予期しない環境での利用にも耐えうる性能の要求
 - リスク（連動するロボットの制御不能や不適切な出力等）を最小限に抑える方法（ガードレール技術等）

[ポイント]

AI 開発者は、想定される被害の性質・態様等を踏まえ、必要に応じて対応策を講ずることにより、AI システムが人の生命・心身・財産、及び環境に危害を及ぼすことのないよう留意する。

なお、開発者は、AI システムの制御可能性に関するリスクを評価するため、あらかじめ検証及び妥当性の確認を行うことが期待される。こうしたリスク評価の手法としては、社会において実用化される前の段階において、実験室内やセキュリティが確保されたサンドボックス等の閉鎖空間において実験を行うことが考えられる。

また、開発者は、仮に、危害を及ぼした場合に講ずるべき措置について、あらかじめ整理するよう留意する。

加えて、既存の法令・ガイドラインの遵守に加え、新技術が起こす問題に対しては新技術で対応するという発想も期待される。

[具体的な手法]

- 予期しない環境での利用にも耐えうる性能の要求
 - フェールセーフ機能の実装
 - ◇ 障害発生時、安全を優先してシステムを移行する設計
 - フォールトトレラント設計
 - ◇ 構成要素の一部が故障、停止等しても予備の系統に切り替える等して機能を保ち、稼動を続ける設計方針
 - フールプルーフ設計
 - ◇ 誤った操作をしても、安全に稼働させる設計
- リスク（連動するロボットの制御不能や不適切な出力等）の最小化
 - AI ガバナンスの構築
 - ガードレールの設定
 - フォールバック設計
 - ◇ 問題発生時には、ルールベースでシステムを動かすことや人間の最終判断を経る等、機能の一部停止や縮小を可能にする設計方針
 - 特定されたリスクや脆弱性に対処するための適切な緩和策の検討・実施
 - 段階的な見直しプロセスの導入
 - ◇ AI システムに対して、詳細な確認事項を用意

- ◇ 導入前、市場投入前等、AI ライフサイクル全体において、当該確認事項に基づいた見直しを実施
- 透明性のある開発戦略の採用
 - 安全性を損なうことのない開発のために、開発設計等の上流において潜在的なリスクの特定や、開発プロセス全体を通じたリスクの軽減を行うための戦略の立案
- 危害発生時の措置の検討
 - 初動措置
 - ◇ 当該 AI を含むシステムの急用度等の文脈に応じ、必要な手順にて実施
 - 当該システムのロールバック、代替システムの利用等による復旧
 - システムの停止
 - ◇ キルスイッチ
 - ネットワークからの遮断
 - 危害の内容の確認
 - 関係者への報告
 - （重大な損害が生じた場合）第三者機関による原因調査・分析・提言 等
- リスクに対応する新技術の検討
 - 新しいサイバー攻撃を検知・防御する AI の開発
 - AI による不適切な生成物を削除する AI の開発 等

[参考文献]

- IPA SEC journal Vol.10 No.3 特集「信頼性と安全性」（2014 年 9 月）
- 国立大学法人 電気通信大学 Fallback and Recovery Control System of Industrial Control System for Cybersecurity （2017 年 10 月）
- IPA 「ホワイトハッカー勉強会 初級編」（2018 年 9 月）
- 総務省、経済産業省 「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）
- パーソナルデータ+α 研究会「プロファイリングに関する最終提言」（2022 年 4 月）
- NIST, AI Risk Management Framework Playbook （2023 年 1 月）
- WEF, The Presidio Recommendations on Responsible Generative AI （2023 年 6 月）
- 総務省「デジタル空間における情報流通に関する現状と課題」（2023 年 11 月）
- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

コラム 5：リスクを最小化するためのガードレールの活用事例

AI システムのリスクの最小化のためには、そのリスクを抑制するための仕組みとしての「ガードレール」の検討をすることが期待される。当該「ガードレール」には複数の種類があり、開発時に求める事項に応じて活用することが期待される。

例えば、以下が挙げられる

- Topical Rail
 - 特定のユースケースや AI 利用者及び業務外利用者の意図に関連しないトピックに触れないようにする手法
- Moderation Rail
 - 回答に倫理的に不適切な言葉が含まれないようにする手法
- Fact Checking and Hallucination Rail
 - 虚偽又は幻覚の答えを出力することを避ける手法
- Jailbreaking Rail
 - 悪意のある攻撃に対する堅牢性を確保する手法

具体的なガードレール手法の活用事例として、rinna 株式会社では、開発者向けに Profanity Classification API⁶⁸（差別や残虐行為、政治・宗教等にかかわる不適切な表現を検出し、SNS やレビュー等の監視に活用できる API）の提供を行っている。また、日本語に特化した画像生成モデルの公開、サービスへの組み込みを行った際には、生成されたコンテンツに対して不適切な画像のチェックを行うために、SafetyChecker⁶⁹という安全性のチェックツールを活用した⁷⁰。

⁶⁸ Profanity Classification API

<https://developers.rinna.co.jp/api-details#api=profanity-classification-api&operation=profanity-classification-api>

⁶⁹ SafetyChecker

https://github.com/huggingface/diffusers/blob/main/src/diffusers/pipelines/stable_diffusion/safety_checker.py

⁷⁰ 日本語に特化した画像生成モデル（Japanese Stable Diffusion）の公開時のモデルカード: Safety Module の項目参照

<https://huggingface.co/rinna/japanese-stable-diffusion>

[本編の記載内容（再掲）]

AI 開発時

D-2) iii. 適正利用に資する開発

- ◇ AI 開発者は、開発時に想定していない提供・利用により危害が発生することを避けるため、安全に利用可能な範囲を設定して開発を行う（「2）安全性」）
- ◇ 事前学習済の AI モデルに対する事後学習を行う場合に、学習済 AI モデルを適切に選択する（商用利用可能なライセンスかどうか、事前学習データ、学習・実行に必要なスペック等）（「2）安全性」）

[ポイント]

AI 開発者は、AI システムを開発するにあたり、AI の活用時に生じうる又は生じた事故、セキュリティ侵害・プライバシー侵害等によりもたらされる又はもたらされた被害の性質・態様等に応じて、関係者と協力して予防措置及び事後対応（情報共有、停止・復旧、原因解明、再発防止措置等）に取り組むことが期待される。

[具体的な手法]

- ガードレールの設定
 - Topical Rail
 - ◇ 特定のユースケースや AI 利用者及び業務外利用者の意図に関連しないトピックに触れないようにする手法
 - Moderation Rail
 - ◇ 回答に倫理的に不適切な言葉が含まれないようにする手法
- 目的と照らした AI モデルの調整
 - データセットの特性
 - ◇ 元のモデルが訓練されたデータセットと、新しいタスクにおけるデータセットの特性を比較し、元のモデルが学習した特徴が新しいタスクにも適用可能であるかを検討する
 - 新しいタスクのドメイン
 - ◇ ファインチューニングが行われる新しいタスクのドメイン（領域）が、元のモデルのドメインと一致するか確認する。異なるドメインの場合、一部の層のみをファインチューニングする等の調整を検討
 - 言語の一致
 - ◇ 元のモデルと新しいデータセットの言語が一致していることを確認する。異なる場合、トークン化の方法や語彙の拡張等の調整を検討

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

[本編の記載内容（再掲）]

AI 開発時

D-3) ii. AI モデルのアルゴリズム等に含まれるバイアス等への配慮

- ◇ AI モデルを構成する各技術要素（AI 利用者が入力するプロンプト、AI モデルの推論時に参照する情報や連携する外部サービス等）によってバイアスが含まれることまで検討する（「3）公平性」）
- ◇ AI モデルからバイアスを完全に排除できないことを踏まえ、単一手法ではなく多様な手法に基づく開発を並行して行う（「3）公平性」）

[ポイント]

AI 開発者は、AI に用いられる学習アルゴリズムにより、AI の出力にバイアスが生じる可能性があることに留意する。

また、AI によりなされた判断結果の公平性を保つため、AI を活用する際の社会的文脈、人々の合理的な期待及び AI を活用した判断の対象となっている者の権利利益に与える重大性を踏まえ、その判断を用いるか否か、あるいは、どのように用いるか等に関し、人間の判断を介在させることが期待される。

[具体的な手法]

- バイアスの検出、監視
 - AI 利用者が入力するプロンプトに対する留意
 - ◇ AI 提供者に対し、AI 利用者との利用規約等の締結必要性を喚起
 - 推論時の情報・外部サービスの確認 等
- 特徴量の見直し
 - 各事業者におけるセンシティブ属性（公平性の観点から排除すべき対象者の性別や人種等の個人の属性）を明確化
 - ◇ このような属性を明確化する際には、憲法 14 条 1 項が列挙する事由や、国際的な人権に関するルールで言及されている属性を考慮
 - センシティブ属性に関し、確保すべき公平性の内容を明確化
 - ◇ 集団公平性
 - センシティブ属性を取り除き、非センシティブ属性のみに基づき予測を実施（unawareness）
 - センシティブ属性の値が異なる複数のグループ間で、同じ予測結果を確保（demographic parity）
 - 実際の結果に対する予測結果の誤差の比率を、センシティブ属性の値によらないように調整（equalized odds）
 - ◇ 個人公平性
 - センシティブ属性以外の属性値が等しい個人に対してはそれぞれ同じ予測結果を付与

- 類似した属性値を持つ個人には類似した予測結果を付与（Fairness through awareness）
- 機械学習モデルにおいて、バイアスを考慮したモデルを使用
 - IPW（Inverse Probability Weighting）の使用
 - ☆ 収集されたデータに対して、グループによる重み付けによって対等性を確保する手法 等
- 機械学習システムにおける公平性の実現（定性的なアプローチから定量的な手法へ）
 - AI 開発者は、AI 提供者が分析した公平性のリスクについて、必要に応じて実装段階から「結果の均等」等定量的な公平性メトリクスを通じた実現を検討
- 社会的文脈や人々の合理的な期待を踏まえ、人間の判断を介在
 - 統計的な将来予測が（不確定性が高く）難しい場合
 - 特定の個人又は集団に重大な影響を与える場合等、意思決定（判断）に対し納得ある理由を必要とする場合
 - 学習データにマイノリティ等に対する社会的バイアスが含まれていること等により、人種・信条・性別に基づく差別が想定される場合 等

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

[本編の記載内容（再掲）]

AI 開発時

D-5) i. セキュリティ対策のための仕組みの導入

- ◇ AI システムの開発の過程を通じて、採用する技術の特性に照らし適切にセキュリティ対策を講ずる（セキュリティ・バイ・デザイン）（「5）セキュリティ確保」）

[ポイント]

AI のセキュリティに留意し、AI システムの機密性・完全性・可用性を確保するため、その時点での技術水準に照らして合理的な対策を講ずることが期待される。また、セキュリティが侵害された場合に講ずるべき措置について、当該 AI の用途や特性、侵害の影響の大きさ等を踏まえ、あらかじめ整理しておくことが期待される。

「情報セキュリティを企画、設計段階から組み込むための方策」で内閣サイバーセキュリティセンター（NISC）により定義されているセキュリティ・バイ・デザイン等を参考にし、開発プロセスの早い段階からセキュリティを考慮することで、開発するシステムのセキュリティを確保する。従来のような後付けでセキュリティ機能を追加したり、出荷直前になってセキュリティツールを実行しては、手戻りが多発したり、結果的に開発コストが多くなってしまう可能性がある。開発の早い段階でセキュリティ対策を行うことで、手戻りが少なく、コスト削減に繋がり、保守性の良いシステム・ソフトウェアの作成及び提供につながる。

[具体的な手法]

- セキュリティ・バイ・デザイン
 - セキュリティ対策の実施例
 - ◇ 脅威分析（Threat Assessment）
 - ソフトウェアが直面する脅威や想定される攻撃を明確化、ソフトウェアを「何から守るのか」明確化
 - ◇ セキュリティ要件（Security Requirements）
 - ソフトウェア自身のセキュアな動作を定義。要件の種類にはシステムの機能に関する要件や、可用性、保守性、性能等の要件あり。セキュリティ要件とは、システム要件のうちセキュリティに関する要件のことであり、システムを安全に運用するために必要な目標の定義を実施。システム要件定義書の一部として、又はセキュリティ要件定義書として、セキュリティ要件を記述
 - ◇ セキュリティアーキテクチャ（Security Architecture）
 - 自組織で独自のアーキテクチャを考えるよりも、AI システムを搭載するプラットフォームの提供元が推奨しているアーキテクチャをカスタマイズしつつ利用
 - ◇ ソフトウェア部品表（SBOM: Software Bill of Materials）
 - 製品に組み込まれるソフトウェア一式を可視化及び構成管理を容易にするために SBOM 作成を取り入れ
 - ◇ オープンソースソフトウェアの責任ある利用

- オープンソースソフトウェアを使用する際には、オープンソースパッケージの審査を行い、依存関係に対するコードの貢献を促進し、重要なコンポーネントの開発とメンテナンスを維持するために協力することが責任を果たすことになる
- セキュリティ対策の強化
 - アクセス制御と認証
 - ◇ 必要最小限のアクセス権を付与
 - ◇ 開発者や管理者がシステムにアクセスする際には、厳格な認証手段を採用
 - ◇ 各主体にとって重要な知的財産や営業秘密に該当する内容については、強固な内部脅威検知プログラムを確立
 - 意識の向上及びトレーニング
 - ◇ 関連するポリシー、手順、契約等に基づいたサイバーセキュリティに関する義務と責任を果たせるように、意識向上の教育やトレーニングを実施
 - データセキュリティの確保
 - ◇ データの転送時には暗号化を使用し、データの保存や処理時にもセキュリティプロトコルを適用
 - 情報を保護するためのプロセス及び手順
 - ◇ セキュリティポリシー、プロセス、手順が維持され、情報システムと資産の防御の管理に使用
 - オープンソース活用時等の不具合等への留意
 - ◇ オープンソースに含まれるバグ等の情報があつた場合には速やかに更新を実施
 - 保守
 - ◇ 承認・管理されたツールを用いて保守作業の実施
 - ◇ 保守作業の記録
 - 監視とインシデント対応
 - ◇ 監視システムを構築し、異常が検出された場合はインシデント対応プロセスを実施
 - ◇ 生じたインシデントについて適切な文書化を行い、特定されたリスクと脆弱性の軽減を検討
- 攻撃手法の例としては「表 4 機械学習システムの被害を引き起こす各攻撃の例」を参照のこと

表 4 機械学習利用システムの各被害を引き起こす攻撃の例

被害の内容		被害を引き起こす攻撃	
		機械学習特有の攻撃	その他の攻撃
システムの誤動作	AI モデルの誤動作によるもの AI モデルの解釈機能の誤動作によるもの	データポイズニング攻撃 モデルポイズニング攻撃 回避攻撃 バリデーション用・テスト用データの改変	AI モデルやその解釈機能を実装するソフトウェア・ハードウェアに対する従来型の攻撃
	意図に反する機能を実現する AI モデルの正常動作によるもの	データポイズニング攻撃（機能変更型） モデルポイズニング攻撃（機能変更型）	

		・バリデーション用・テスト用データの 改変	
	その他	-	システムに対する従 来型の攻撃
AI モデルについての情報の漏洩		モデル抽出攻撃	モデルを窃取する従 来型の攻撃
訓練用データに含まれるセンシティブ情報の漏 洩		訓練用データに関する情報漏洩攻 撃 モデルポイズニング攻撃（情報漏 洩型）	データを窃取する従 来型の攻撃

[参考文献]

- NIST, “CYBERSECURITY FRAMEWORK”（2018 年 4 月）
- 経済産業省「OSS の利活用とそのセキュリティ確保に向けた管理手法に関する事例集」（2021 年 4 月）
- 独立行政法人情報処理推進機構「セキュリティ・バイ・デザイン導入指南書」（2022 年 8 月）
- 経済産業省「ソフトウェア管理に向けた SBOM の導入に関する手引」（2023 年 7 月）
- 英国サイバーセキュリティセンター（NCSC）「セキュアな AI システム開発のためのガイドライン（Guidelines for secure AI system development）」（2023 年 11 月）
- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

[本編の記載内容（再掲）]

AI 開発時

D-6) i. 検証可能性の確保

- ◇ AI の予測性能や出力の品質が、活用後に大きく変動する可能性や想定する精度に達しないこともある特性を踏まえ、事後検証のための作業記録を保存しつつ、その品質の維持・向上を行う（「2）安全性」「6）透明性」）

[ポイント]

AI 開発者は、AI の入出力等の検証可能性を確保するため、開発時のログを記録・保存することや、AI 提供者等が入出力のログが取得できるような形で AI システムを開発することが期待される。

AI 開発者は、AI 提供者が AI システムを理解し適切に AI 利用者へ提供できるように、透明性が担保されるような手段で AI システムを設計・開発することが期待される。

[具体的な手法]

- ログの記録・保存
 - 具体的には、以下のログを記録・保存
 - ◇ AI 開発時に何のデータを使用したのか？ 等
 - 必要な「ログ」を検討するとき、自組織が認証を受けているマネジメントシステムや契約で求められる「文書」や「記録」等も参考にし、適切なログの記録と保存を行う。具体的には、以下を考慮
 - ◇ ログの記録・保存の目的
 - ◇ ログの精度
 - ◇ ログ取得・記録の頻度
 - ◇ ログの時刻の記録・保存期間・保存場所の容量
 - ◇ ログの保護
 - 機密性、完全性、可用性等の確保
 - ◇ 開示するログの範囲 等
- 説明可能性・解釈可能性を高めるための手法を検討する。なお、以下の検討にあたっては、開発とのトレードオフが生じる懸念もあるため、留意すること。
 - 単純なモデルの使用
 - ◇ 要件に合わせて、できるだけ単純なモデルを可能であれば選択
 - ロジスティック回帰、決定木 等
 - 局所的な説明手法
 - ◇ モデルの予測を説明する際に、局所的な説明手法を使用
 - ◇ 特定のデータポイントに対するモデルの挙動を説明する手法であり、LIME（Local Interpretable Model-agnostic Explanations）等が代表的
 - SHAP 値（SHapley Additive exPlanations）
 - ◇ ゲーム理論に基づいて各特徴がモデルの予測にどれだけ寄与しているかを評価することで、各特徴の相対的な影響を理解しやすくなる

- 特徴の寄与度可視化
 - ◇ モデルが重要視している特徴を可視化する手法を使用
 - これには、特徴の重要度プロットや部分依存プロット等が含まれる
- モデル内部の解析
 - ◇ モデル内部の構造や動作を詳細に解析する手法を採用
 - ◇ TensorFlow や PyTorch 等のフレームワークでは、モデルの中間層の出力や勾配を可視化することも可能
- モデルアーキテクチャの選択
 - ◇ 解釈可能性を重視するために、モデルのアーキテクチャの選択にも注意
- ステークホルダー参加型の手法の検討
 - ◇ ステークホルダー（AI 提供者や AI 利用者等）によるフィードバックやドメインエキスパートの知識の取り入れ
- 技術的に可能な場合において、AI を活用した旨を明示する電子透かしの導入
 - ◇ AI 利用者及び業務外利用者が、自身が AI システムと相互作用していることを認識ができるようにするため、ラベリングや免責事項の表示やその他の仕組みの導入も検討
- AI に対する複数の入力と出力の組合せをもとにした AI の出力の傾向の分析
 - 例えば、入力パターンを少しずつ変化させたときの出力の変化の観測 等

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- ISO「ISO/IEC 23894:2023 情報技術－人工知能－リスク管理に関するガイダンス」（2023 年 2 月）
- The White House, "Blueprint for a AI Bill of Rights（Notice and Explanation）"（2023 年 3 月）
- AI プロダクト品質保証コンソーシアム「AI プロダクト品質保証ガイドライン」（2023 年 6 月）
- World Economic Forum, "The Presidio Recommendations on Responsible Generative AI"（2023 年 6 月）

[本編の記載内容（再掲）]

AI 開発後

D-5) ii. 最新動向への留意

- ◇ AI システムに対する攻撃手法は日々新たなものが生まれており、これらのリスクに対応するため、開発の各工程で留意すべき点を確認する（「5）セキュリティ確保」）

[ポイント]

AI 開発者は、技術的な洞察を深め、より先進的で持続可能な AI 開発を実施するために、最新動向に留意することが期待される。

これを通じ、AI 開発者は、AI 提供者と連携して、リスクの程度に見合った適切なタイミングで、AI システムが意図したとおりに活用され、導入後の脆弱性、インシデント、新たなリスク、悪用を監視し、それらに対処するための適切な措置を講じることが期待される。

[具体的な手法]

- 以下を通じた最新動向の確認
 - 国際会議、arXiv 等の論文
 - JVN iPedia 脆弱性対策情報データベース
 - SNS 等の開発者コミュニティ
 - オープンソースプロジェクトの参照
 - 報道 等

[参考文献]

- 総務省「AI セキュリティ情報発信ポータル」
 - https://www.mbsd.jp/aisec_portal/
- arXiv
 - <https://arxiv.org>
- JVN iPedia 脆弱性対策情報データベース
 - <https://jvndb.jvn.jp/index.html>

[本編の記載内容（再掲）]

AI 開発後

D-6) ii. 関連するステークホルダーへの情報提供

- ◇ AI 開発者は、自らの開発する AI システムについて、例えば以下の事項を適時かつ適切にステークホルダーに（AI 提供者を通じて行う場合を含む）説明できるようにする（「6）透明性」）
 - AI システムの学習等による出力又はプログラムの変化の可能性、AI の能力と、性能上の重大な限界（「1）人間中心」）
 - AI システムの技術的特性、安全性確保の仕組みやテストの結果、利用の結果生じる可能性のある予見可能なリスク及びその緩和策等の安全性に関する情報（「2）安全性」）
 - 開発時に想定していない提供・利用により危害が発生することを避けるための AI 開発者が意図する利用範囲（「2）安全性」）
 - AI システムの動作状況に関する情報、不具合の原因と対応状況（「2）安全性」）
 - 更新を行った場合の内容とその理由の情報（「2）安全性」）
 - AI モデルで学習するデータの収集ポリシーやその学習方法及び実施体制等（「3）公平性」、「4）プライバシー保護」、「5）セキュリティ確保」）

[ポイント]

AI 開発者は、ステークホルダーの納得感や安心感の獲得、また、そのための AI の動作に対する証拠の提示等を目的として、自らの開発する AI システムについての共通の指針の遵守の状況を説明することが期待される（AI 提供者を通じて行う場合も含む）。

なお、これはアルゴリズムやソースコード自体の開示を想定したものではなく、プライバシーや営業秘密へ配慮しつつ、採用する技術の特性や用途に照らし合理的な範囲で実施することが期待される。

[具体的な手法]

- AI を活用している旨の表示
- 倫理に関するポリシーの策定・明確化
 - 倫理的な原則や方針を公表し、開発者の倫理規定に対するコミットメントを明確にする
 - ◇ 合理的な範囲での個人データ、ユーザープロンプト、AI システムの出力、プライバシー等に関するポリシーの開示も含まれる
 - 詳細は、別添 2. 行動目標 2-1【AI ガバナンス・ゴールの設定】を参照のこと
- ステークホルダーとの対話
 - ウェブサイト等を通じてステークホルダーに対して倫理的な取り組みや透明性の向上に関する情報を提供しつつ、対話を実施
 - ◇ 詳細は、別添 2. 行動目標 5-2【社外ステークホルダーの意見の検討】を参照
 - 関係するステークホルダーが導入後に問題や脆弱性を発見した際、AI 開発者に対する報告を促す仕組みを検討

- ◇ 例えば、導入後に、関連するステークホルダーを通じた脆弱性の発見を促進するため、インシデントの発生報告に対して報奨金制度等のインセンティブを設ける 等
- ◇ 詳細は、別添 2.行動目標 3-4-2【インシデント/紛争発生時の対応の事前検討】を参照

[参考文献]

- EU "Ethics Guidelines for Trustworthy AI (AI 倫理ガイドライン)" (2019 年 4 月)
- ISO「ISO/IEC 23894:2023 情報技術－人工知能－リスク管理に関するガイダンス」(2023 年 2 月)

[本編の記載内容（再掲）]

AI 開発後

D-7) i. AI 提供者への共通の指針の対応状況の説明

- ◇ AI 開発者は、AI 提供者に対して、AI には活用後に予測性能や出力の品質が大きく変動する可能性や想定する精度に達しないこともある特性がある旨や、その結果生じうるリスク等の情報提供と説明を行う。具体的には以下の事項を周知する（「7）アカウントビリティ」）
 - AI モデルを構成する各技術要素（学習データ、モデルの学習過程、AI 利用者が入力すると想定するプロンプト、AI モデルの推論時に参照する情報や連携する外部サービス等）において含まれる可能性があるバイアスへの対応等（「3）公平性」）

[ポイント]

AI 開発者は、AI 提供者に対して、有意義かつ有用な情報を提供し、社会的文脈やリスクの大小に応じた説明を行うと同時に、開発内容と技術的な評価に関する理解可能な形式でのレポート等をできる限り開示することが期待される。

なお、これはアルゴリズムやソースコード自体の開示を想定したものではなく、プライバシーや営業秘密へ配慮しつつ、採用する技術の特性や用途に照らし合理的な範囲で実施することが期待される。

[具体的な手法]

- 営業秘密等を侵さない範囲内で対応状況の説明を実施しつつ、トレードオフが生じた場合には以下の事項を実施
 - 透明性や倫理等の観点から非開示を許容できるか/どこまで公開すべきか評価すること
 - その決定過程を文書化すること
 - その決定に意思決定者が責任を持つこと
 - 決定内容を適切かつ継続的に監督すること

[参考文献]

- EU "Ethics Guidelines for Trustworthy AI（AI 倫理ガイドライン）"（2019 年 4 月）
- ISO「ISO/IEC 23894:2023 情報技術－人工知能－リスク管理に関するガイダンス」（2023 年 2 月）

[本編の記載内容（再掲）]

AI 開発後

D-7) ii. 開発関連情報の文書化

- ◇ AI 開発者は、トレーサビリティと透明性の向上のため、AI システムの開発過程、意思決定に影響を与えるデータ収集やラベリング、使用されたアルゴリズム等について、可能な限り第三者が検証できるような形で文書化する（「7）アカウントビリティ」）

（注）ここで文書化されたものをすべて開示するという意味ではない。

[ポイント]

AI 開発者は、必要に応じてステークホルダーと協力しつつ、AI の開発過程や、報告されたインシデント等について、適切に文書化しつつこれを維持/保持し、第三者による検証可能な状態の確保や、特定されたリスクと脆弱性を軽減することに留意することが期待される。

[具体的な手法]

- 文書化の実施
 - 開発過程の文書化
 - ◇ データの出所に始まり、どのような意思決定を行ったかについて、合理的な説明を行い、トレーサビリティを確保するため透明性報告書等の記録を残す
 - ◇ 上記の実施にあたっては、AI システムにおいて予期せぬ事故が発生した際に、AI のバリューチェーンに連なる者は、すべて何らかの説明を求められる立場に将来立つ可能性があることを念頭に置く
 - 報告されたインシデントの文書化
 - ◇ インシデントについては、適切な文書化を行い、特定されたリスクと脆弱性を軽減するよう検討する
- 文書化の方法
 - これらの文書は定期的に更新
 - 文書化の形式及び媒体は、各主体が選択する。必ずしも紙媒体ではなくともよい
 - 活用の文脈に応じて、ステークホルダーが利用できるものとする

[参考文献]

- ISO「ISO/IEC 23894:2023 情報技術－人工知能－リスク管理に関するガイダンス」（2023 年 2 月）

[本編の記載内容（再掲）]

AI 開発後

D-10) i. イノベーションの機会創造への貢献

- ◇ AI 開発者は、可能な範囲で以下の事項を実施し、イノベーションの機会の創造に貢献することが期待される（「10）イノベーション」）
 - 品質・信頼性や開発の方法論等の研究開発を行う
 - 持続的な経済成長の維持と社会課題の解決策が提示されるよう貢献
 - DFFT 等の国際議論の動向の参照、AI 開発者コミュニティや学会への参加等の取組を行う等、国際化・多様化や産学官連携を行う
 - 社会全体への情報提供を行う

[ポイント]

AI 開発者は、AI モデルを直接的に設計し変更を加えることができるため、AI システム・サービス全体においても AI の出力に与える影響力が高く、イノベーションを牽引することが特に社会から期待される

[具体的な手法]

- AI システムの安全性、セキュリティ、信頼性を確保するための共有の基準、ツール、メカニズム、ベストプラクティスを開発し、推進し、必要に応じて採用するためのメカニズムを構築
 - 安全性向上やセキュリティ確保のためのベストプラクティスを組織間で共有
 - 産業界、学术界、政府機関、非営利団体等、ステークホルダーと連携

B. 本編「第 2 部」の「共通の指針」の解説

ここでは、「第 3 部 AI 開発者に関する事項」では触れられていないが、「第 2 部」の「共通の指針」のうち、AI 開発者にとって特に重要なものについて、具体的な手法を解説する。

なお、AI 提供者もしくは AI 利用者から要求があった場合に AI 開発者は必要な情報提供等の措置を講じる。

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

1) 人間中心

各主体は、AI システム・サービスの開発・提供・利用において、後述する各事項を含む全ての取り組むべき事項が導出される土台として、少なくとも憲法が保障する又は国際的に認められた人権を侵すことがないようにすべきである。また、AI が人々の能力を拡張し、多様な人々の多様な幸せ（well-being）の追求が可能となるように行動することが重要である。

● 「①人間の尊厳と個人の自律」関連

[関連する記載内容（本編の記載内容の再掲）]

- AI が活用される際の社会的文脈を踏まえ、人間の尊厳と個人の自律を尊重する
- 特に、AI を人間の脳・身体と連携させる場合には、その周辺技術に関する情報を踏まえつつ、諸外国や研究機関における生命倫理の議論等を参照する
- 個人の権利・利益に重要な影響を及ぼす可能性のある分野において AI を利用したプロファイリングを行う場合、個人の尊厳を尊重し、生じうる不利益等を慎重に検討した上で、不適切な目的に利用しない

[具体的な手法]

- AI 倫理を所管する担当役員や AI ガバナンスに関する社内組織を設置
- AI の開発時に参照可能な諸外国や研究機関における生命倫理の議論の例は下記のとおり
 - ◇ 国際連合（UN）や世界保健機関（WHO）等の国際機関が発行するレポート 等
 - ◇ 大学等の学術機関の出す研究論文
- 個人の権利・利益に重要な影響を及ぼす可能性のある分野において AI を利用したプロファイリングを行う場合においては、特に以下の点に留意をした開発が有用
 - ◇ プロファイリングに使用されるデータやアルゴリズムに潜在的なバイアスがある場合、これを最小限に抑え、公正かつ平等な結果を得ること
 - データとアルゴリズムの出力のモニタリング
 - 当該個人が人間による判断を受ける機会を確保 等
 - ◇ プロファイリングに使用されるデータに個人情報が含まれている場合、当該個人情報を適切に扱うこと
 - データクリーンルームの設置

- プライバシー保護機械学習の実施 等
 - ◇ 開発したシステムが適切に機能し、個人に対する潜在的なリスクを適切に管理できるようにすること
- 「②AI による意思決定・感情の操作等への留意」関連
[関連する記載内容（本編の記載内容の再掲）]
 - 人間の意思決定や認知等、感情を不当に操作することを目的とした、もしくは操作を前提とした AI システム・サービスの開発・提供・利用は行わない
 - AI システム・サービスの開発・提供・利用において、自動化バイアス⁷¹等の AI に過度に依存するリスクに対して、必要な対策を講じる
 - フィルターバブルに代表されるような情報や価値観の傾斜を助長し、AI 利用者を含む人間が本来得られるべき選択肢が不本意に制限されるような AI の活用にも注意を払う
 - 特に、選挙やコミュニティでの意思決定等をはじめとする社会に重大な影響を与える手続きに関連する場合においては、AI の出力について慎重に検討する
[具体的な手法]
 - 自動化バイアス等への AI に過度に依存するリスクに対する対応策としては、AI 提供者に対し、AI 利用者への注意喚起を依頼することが有用
 - フィルターバブルへの対処法としては、例えば、セレンディピティ（偶然・予想外の発見）の考慮等が有用
 - ◇ 具体的には、多様な情報源の利用や、アルゴリズムの見直し 等
 - 選挙やコミュニティでの意思決定等をはじめとする社会に重大な影響を与える手続きに関連する場合においては、例えば、最終的な判断を人間が実施することや、技術的な側面ではなく倫理的な観点からもプロジェクトの評価を行うことが有用
- 「③偽情報等への対策」関連
[関連する記載内容（本編の記載内容の再掲）]
 - 生成 AI によって、内容が真実・公平であるかのように装った情報を誰でも作ることができるようになり、AI が生成した偽情報・誤情報・偏向情報が社会を不安定化・混乱させるリスクが高まっていることを認識した上で、必要な対策を講じる
[具体的な手法]
 - 例えば、ファクトチェック（真偽検証、事実言明の真実性・正確性を調査し、検証結果を報告する仕組み）等のガードレール手法のほか、生成 AI による生成物であることを表示すること等が有用
- 「④多様性・包摂性の確保」関連
[関連する記載内容（本編の記載内容の再掲）]
 - 公平性の確保に加え、いわゆる「情報弱者」や「技術弱者」を生じさせず、より多くの人々が AI の恩恵を享受できるよう社会的弱者による AI の活用を容易にするよう注意を払う

⁷¹ 人間の判断や意思決定において、自動化されたシステムや技術への過度の信頼や依存が生じる現象を指す。

[具体的な手法]

- 例えば、ユニバーサルデザイン、アクセシビリティの確保、関連するステークホルダーへの教育・フォローアップ等が有用

- 「⑤利用者支援」関連

[関連する記載内容（本編の記載内容の再掲）]

- 合理的な範囲で、AI システム・サービスの機能及びその周辺技術に関する情報を提供し、選択の機会を適時適切に提供する機能が利用可能である状態とする

[具体的な手法]

- データの取扱いに関する情報の説明
 - ◇ AI 開発者が作成したモデルに入力されたデータの活用方法
 - ◇ 学習に使用された元のデータの収集源や処理の情報
- アルゴリズムやモデルの透明性の確保
 - ◇ 可能であれば、アルゴリズムロジックの開示
 - ◇ イン・アウトの例示
- 変更やアップデートの通知

- 「⑥持続可能性の確保」関連

[関連する記載内容（本編の記載内容の再掲）]

- AI システム・サービスの開発・提供・利用において、ライフサイクル全体で、地球環境への影響も検討する

[具体的な手法]

- 軽量モデルの採用
 - ◇ AI に求める要件に沿う形で、大規模で高精度なモデルの代わりに、軽量でリソース効率の高いモデルを利用することで、エネルギー効率を向上
- モデルのサイズの最適化
 - ◇ 計算リソースの効率的な利用やエネルギー消費の最小化を意識したモデル設計やアルゴリズムの開発を実施
- データの効果的な利用
 - ◇ データの品質向上や冗長性の排除、不要なデータの取得の回避

[参考文献]

- EU "Ethics Guidelines for Trustworthy AI（AI 倫理ガイドライン）"（2019 年 4 月）
- 総務省「ファクトチェックをとりまく世界と日本の状況・課題」（2019 年 5 月）
- OIS Research Conference, "AI and Citizen Science for Serendipity"（2022 年 5 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

4) プライバシー保護に関する留意事項

各主体は、AI システム・サービスの開発・提供・利用において、その重要性に応じ、プライバシーを尊重し、保護することが重要である。その際、関係法令を遵守すべきである

● 「①AI システム・サービス全般におけるプライバシーの保護」関連

[関連する記載内容（本編の記載内容の再掲）]

- 個人情報保護法等の関連法令の遵守や、各主体のプライバシーポリシーの策定・公表等により、社会的文脈や人々の合理的な期待を踏まえ、ステークホルダーのプライバシーが尊重され、保護されるよう、その重要性に応じた対応を取る

[具体的な手法]

- プライバシーの保護のためのセキュリティ対策の強化（機械学習特有の攻撃手法については、「表 5 機械学習特有の攻撃の実行フェーズ・攻撃者・攻撃手段の例」を参照）
 - ✧ 適切な暗号化手法やアクセス制御の仕組みを導入
 - ✧ 個人情報を漏らさないようにするためのテスト、ファインチューニングを実施
 - ✧ 特に重要性が高いものについては、プライバシー保護機械学習、セキュア機械学習等の導入も検討
- データのアクセスを管理するデータ管理・制限機能の導入検討
 - ✧ アクセスへの認可の導入
 - ✧ データマネジメント組織の立ち上げ
 - CDO（Chief Data Officer）の設置
 - プライバシー保護管理者の指名
 - プライバシーの取組に対するリソースの投入
 - 人員配置、人材育成等
 - ✧ データ運用ルール策定の策定と周知
- プライバシーに関するアセスメントの実施
 - ✧ Privacy Impact Assessment（PIA、プライバシー影響評価）
 - AI システムで収集・処理される情報、情報の流れ、ステークホルダーを可視化し、整理
 - AI システムに対してプライバシーリスクを特定
 - 各リスクの影響度、発生可能性を判定し、リスクの大きさを評価
 - リスクの大きさによってリスク対応の方向性（低減・回避・受容・移転）を決定し、対応計画を策定
 - ✧ 品質マネジメントの実施項目（「表 6 品質マネジメント実施項目の概要」を参照）
- 個人情報の取扱いに関連する ISO 規格の取得
 - ✧ ISO/IEC 27001
 - 情報セキュリティマネジメントシステム（ISMS）に関する国際規格で、情報セキュリティの維持・管理に焦点を当てている

- ✧ ISO/IEC 27701:
 - ISO/IEC 27001 に基づく個人情報管理システム（PIMS）のための拡張要件
 - プライバシー保護に焦点を当てた標準であり、AI 開発者が個人情報の適切な管理を確保するために利用可能
- ✧ ISO/IEC 29100
 - プライバシーのための国際規格で、個人情報の保護に関する基本的な原則と要件を提供
- ✧ ISO/IEC 27018
 - クラウドサービスにおける個人情報の保護に関する国際規格
 - クラウドサービスを提供する AI 開発者が、クラウド環境における個人情報の適切な取扱いを確保するために利用可能

表 5 機械学習特有の攻撃の実行フェーズ・攻撃者・攻撃手段の例

攻撃手法	攻撃の実行フェーズ	攻撃者の例	攻撃の手法の典型例
データポイズニング攻撃 バリデーション用データ・テスト用データの改変	学習データセットの収集・加工時	データ提供者 外部攻撃者	訓練用データセットへの悪意あるデータの追加
	システム開発時	外部攻撃者	訓練用データセットの改変
	システム運用時	システム利用者	（バックドアの悪用等の場合は）モデルを誤作動させる運用時入力
モデルポイズニング攻撃	事前学習モデルの学習・提供時	モデル提供者 外部攻撃者	事前学習モデルへのバックドアの設置
	システム開発時	外部攻撃者	悪意ある訓練用プログラム AI モデルの改変
	システム運用時	システム利用者	（バックドアの悪用等の場合は）AI モデルを誤作動させる運用時入力 （情報を漏洩させる攻撃の場合は）運用時の出力情報等の観察
回避攻撃	AI モデルの入手後	運用時入力データ提供者 システム利用者	入手した AI モデルの入出力や内部情報の観察 運用時入力データの生成・改変
	システム運用時		運用時のシステムに対する悪意あるデータの入力
	システム運用時	運用時入力データ提供者	運用時入力データの改変

		システム利用者	運用時のシステムに対する悪意あるデータの入力 運用時の出力情報等の観察
モデル抽出攻撃	システム運用時	システム利用者	運用時のシステムに対するデータの入力 運用時の出力情報等の観察
訓練用データに関する情報漏洩攻撃	AI モデルの入手後	外部攻撃者	入手した AI モデルの入出力や内部情報の観察
	システム運用時	システム利用者	運用時のシステムに対するデータの入力 運用時の出力情報等の観察

[参考文献]

- 経済産業省「情報セキュリティ管理基準（平成 28 年改訂版）」（2016 年 3 月）
- IPA SEC journal 第 45 号 巻頭言（2016 年 7 月）
- IPA「安全なウェブサイトの作り方」（2021 年 3 月）
- Northwestern University, "Secure Machine Learning over Relational Data"（2021 年 9 月）
- ISO "Guidelines for privacy impact assessment"

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

6) 透明性に関する留意事項

各主体は、AI システム・サービスの開発・提供・利用において、AI システム・サービスを活用する際の社会的文脈を踏まえ、AI システム・サービスの検証可能性を確保しながら、必要かつ技術的に可能な範囲で、ステークホルダーに対し合理的な範囲で適切な情報を提供することが重要である。

● 「③合理的かつ誠実な対応」関連

[関連する記載内容（本編の記載内容の再掲）]

- 上記の「②関連するステークホルダーへの情報提供」は、アルゴリズムやソースコードの開示を想定するものではなく、プライバシーや営業秘密を尊重して、採用する技術の特性や用途に照らし、社会的合理性が認められる範囲で実施する
- 公開されている技術を用いる際には、それぞれ定められている規程に準拠する
- 開発した AI システムのオープンソース化にあたっては、社会的な影響を検討する

[具体的な手法]

- プライバシーと営業秘密の尊重のためには、例えば、非技術者向けの説明文書の作成が有用
- 情報提供は一度すれば完了する訳ではなく、採用する技術の特性や用途に照らし、可能な範囲でステークホルダーと対話を積み重ねることが有用。また、そのためのコミュニケーションデザインを設計・開発と同じように、プロアクティブにデザインしメンテナンスしていくことが重要
- 公開されている技術やライブラリを使用する際には、ライセンスを確認しこれを遵守
 - ✧ 特に、商用禁止ライセンス等には留意
- 開発した AI システムをオープンソース化する際には、例えば、プロジェクトが開示されることで生じうる社会的な影響や、関連するステークホルダーへのヒアリングを通じたリスクの洗い出し等が有用

● 「④関連するステークホルダーへの説明可能性・解釈可能性の向上」関連

[関連する記載内容（本編の記載内容の再掲）]

- 関連するステークホルダーの納得感や安心感の獲得、また、そのための AI の動作に対する証拠の提示等を目的として、どのような説明が求められるかを分析・把握し、必要な対応を講じる
 - ✧ AI 提供者：AI 開発者に、どのような説明が必要となるかを共有する
 - ✧ AI 利用者：AI 開発者・AI 提供者に、どのような説明が必要となるかを共有する

[具体的な手法]

- 例えば、AI の動作原理や意思決定プロセスについて、非技術者向けの説明資料を用意すること等が有用
 - ✧ その他、説明時の留意点としては、別添 2. 行動目標 4-1【AI マネジメントシステム運用状況の説明可能な状態の確保】を参照

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

7) アカウンタビリティ に関する留意事項

各主体は、AI システム・サービスの開発・提供・利用において、トレーサビリティの確保や共通の指針の対応状況等について、ステークホルダーに対して、各主体の役割や開発・提供・利用する AI システム・サービスのもたらすリスクの程度を踏まえ、合理的な範囲でアカウンタビリティを果たすことが重要である。

[関連する記載内容（本編の記載内容の再掲）の抜粋、及び、具体的な手法]

● 「①トレーサビリティの向上」関連

[関連する記載内容（本編の記載内容の再掲）]

- データの出所や AI の開発・提供・利用中に行われた意思決定等について、技術的に可能かつ合理的な範囲で追跡・遡求が可能な状態を確保

[具体的な手法]

- データリネージ（来歴メカニズムの構築）
 - ✧ データが元々どこから来たのか、どのように収集され、管理され、時間の経過とともに各主体内で移動したのかを知ること
 - ✧ 当該データは、コンテンツを作成したサービス又はモデルの識別子を含むが、利用者情報を含める必要はない
- AI で生成したコンテンツである旨の表示（コンテンツ認証）
- モデルのバージョン管理
- トレーニングプロセスのログの取得
- バックトラッキングとアップデート履歴の追跡

● 「③責任者の明示」関連

[関連する記載内容（本編の記載内容の再掲）]

- 各事業者内部においてアカウンタビリティを果たす責任者を設定
- 必要に応じ、AI システム・サービスの利用に伴うリスク管理や安全性確保のための各主体の AI ガバナンスに関するポリシー、プライバシーポリシー等の方針を策定し、公表

[具体的な手法]

- 責任者を設定する際には、役割や責務を明確に定義することが有用
- AI システムの利用に伴うリスク管理や安全性確保のためのポリシーの策定においては、必要に応じ、AI 提供者と連携
- 上記のポリシー等の公表としては、ステークホルダーが容易にアクセスできるように、各主体のウェブサイト等の活用が有用

● 「④関係者間の責任の分配」関連

[関連する記載内容（本編の記載内容の再掲）]

- 関係者間の責任について、業務外利用者も含めた各主体間の契約や社会的な約束（ボランティアコミットメント）等により、責任の所在を明確化

[具体的な手法]

- 契約を通じた責任の所在の明確化については、必要に応じ、「別添 6. 「AI・データの利用に関する契約ガイドライン」を参照する際の主な留意事項について」を参照することが有用である
- 社会的な約束としては、例えば、業界団体等で連携した倫理規範の策定等といった形式が想定される

● 「⑤ステークホルダーへの具体的な対応」関連

[関連する記載内容（本編の記載内容の再掲）]

- 必要に応じ、AI の出力の誤り等について、ステークホルダーからの指摘を受け付ける機会を設けるとともに、客観的なモニタリングを実施
- ステークホルダーの利益を損なう事態が生じた場合、どのように対応するか方針を策定してこれを着実に実施し、進捗状況については必要に応じて定期的にステークホルダーに報告

[具体的な手法]

- ステークホルダーからの指摘を受け付ける機会を設ける際には、例えば、ウェブサイトや問い合わせ窓口でのフィードバックの場を設ける
 - ◇ 詳細は、別添 2. 行動目標 5-2【社外ステークホルダーの意見の検討】を参照
- 可能な範囲で、AI システムのモニタリング結果の定期的に公開
- ステークホルダーの利益を損なう事態が生じた際に備え、例えば、危機管理対応計画の策定等を実施することが有用
 - ◇ 詳細は、別添 2. 行動目標 3-4-2【インシデント/紛争発生時の対応の事前検討】を参照

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- World Economic Forum, "The Presidio Recommendations on Responsible Generative AI"（2023 年 6 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

8) 教育・リテラシー に関する留意事項

各主体は、各主体内の AI に関わる者が、AI に係る正しい理解と社会的に正しい利用ができる知識・リテラシー・倫理感を持つために、必要な教育を行うことが期待される。また、各主体は、AI の複雑性や誤情報といった特性や、意図的な悪用の可能性もあることを勘案して、ステークホルダーに対しても教育を行うことが期待される。

[関連する記載内容（本編の記載内容の再掲）]

- 各主体内の AI に関わる者が、その関わりにおいて十分なレベルの AI リテラシーを確保するために必要な措置を講じる
- 生成 AI の活用拡大によって、AI と人間の作業の棲み分けが変わっていくと想定されるため、新たな働き方ができるよう教育・リスティング等を検討する
- AI サービス全体の安全性を高めるため、必要に応じてステークホルダーに対して教育やリテラシー確保のために必要なフォローアップを行う

[具体的な手法]

- AI 開発者への教育
 - 最新の攻撃手法等、変化を厭わず学び続けるマインド及び文化の醸成
 - バリューチェーン全体での連携推進と、連携をすることにより生じるトレードオフの把握
 - 社会的責任の必要性の高まりの訴求 等
- 業務外利用者等への教育
 - AI 利用者や業務外利用者に対して AI システムの適切な利用方法や潜在的なリスクについて教育
 - AI 開発者が開発している AI システムについての適切な利用方法や得られる便益、潜在的なリスクやリスクの対応方法等について、リテラシーを高める目的で情報発信

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- NIST, AI Risk Management Framework Playbook（2023 年 1 月）
- 内閣府「AI 戦略会議の論点整理」（2023 年 5 月）

C. 高度な AI システムの開発にあたって遵守すべき事項

最先端の基盤モデル及び生成 AI システムを含む、高度な AI システムを開発する AI 開発者については、以下の「高度な AI システムを開発する組織向けの広島プロセス国際行動規範」を遵守すべきである⁷²。

高度な AI システムを開発する組織向けの広島プロセス国際行動規範（仮訳）（抜粋）

I) AI ライフサイクル全体にわたるリスクを特定、評価、軽減するために、高度な AI システムの開発全体を通じて、その導入前及び市場投入前も含め、適切な措置を講じる。

- これには、レッドチーミング等の評価方法を組み合わせて、多様な内部テスト手段や独立した外部テスト手段を採用することや、特定されたリスクや脆弱性に対処するために適切な緩和策を実施することが含まれる。テストと緩和策は、例えば、システムが不合理なリスクをもたらさないように、ライフサイクル全体を通じてシステムの信頼性、安全性、セキュリティの確保を目指すべきである。このようなテストを支援するために、開発者は、データセット、プロセス、システム開発中に行われた意思決定に関連して、トレーサビリティを可能にするよう努めるべきである。これらの対策は文書化され、定期的に更新される技術文書によってサポートされるべきである。
- このようなテストは、リスクと脆弱性を特定するため、また、偶発的か意図的かを問わず、セキュリティ、安全性、社会的リスク、その他のリスクに対処するための行動を通知するために、安全な環境で実施されるべきであり、また、特に導入前及び市場投入前等の AI ライフサイクル全体におけるいくつかのチェックポイントで実施されるべきである。テスト措置の設計と実施において、組織は以下のリスクに適切に注意を払うことを約束する：
 - 高度な AI システムが、非国家主体も含め、兵器の開発、設計の取得、使用への参入障壁を低くする方法等、化学、生物、放射性、核のリスク。
 - 攻撃的サイバー能力とは、システムが脆弱性の発見、悪用、又は作戦上の利用を可能にする方法等であり、そのような能力の有用な防御的応用の可能性があり、システムに含めることが適切であるかもしれないことを念頭に置くこと。
 - 健康及び/又は安全に対するリスク。システムの相互作用やツールの使用による影響を含み、例えば物理的なシステムを制御したり、重要なインフラに干渉したりする能力を含む。
 - モデルが自分自身のコピーを作ったり、"自己複製"したり、他のモデルを訓練したりすることによるリスク。
 - 高度な AI システムやモデルが有害な偏見や差別を生じさせたり、プライバシーやデータ保護に関連する法令等適用される法的枠組みへの違反につながったりする可能性等、社会的リスクや個人やコミュニティに対するリスク。
 - 偽情報の助長やプライバシーの侵害等、民主主義の価値や人権に対する脅威。

⁷² 全文については、広島 AI プロセスに関する G7 首脳声明「高度な AI システムを開発する組織向けの広島プロセス国際行動規範」を参照のこと。なお、なお、同文書は高度な AI システムにおける最近の進展に対応して、既存の OECD AI 原則に基づいて構築される living document であることに注意が必要である。また、高度な AI システムとは、最先端の基盤モデル及び生成 AI システムを含む、最も高度な AI システムと定義されている。<https://www.mofa.go.jp/mofaj/files/100573472.pdf>

- 特定の事象が連鎖反応を引き起こし、都市全体、領域活動全体、地域社会全体にまで重大な悪影響を及ぼすリスク。
 - 各組織は、セクターを超えた関係者と協力して、これらのリスク、特にシステミック・リスクに対処するための緩和策を評価し、採用することを約束する。
 - また、これらのコミットメントに取り組む組織は、高度なAIシステムのセキュリティ、安全性、偏見と偽情報、公平性、説明可能性と解釈可能性、透明性に関する研究と投資を促進し、悪用に対する先進的AIシステムの堅牢性と信頼性を高めることに努めるべきである。
- II) 市場投入を含む導入後、脆弱性、及び必要に応じて悪用されたインシデントやパターンを特定し、緩和する。**
- 組織は、リスクレベルに見合った適切なタイミングで、AIシステムを意図したとおりに使用し、導入後の脆弱性、インシデント、新たなリスク、悪用を監視し、それらに対処するための適切な措置を講じるべきである。組織は、例えば、責任を持って弱点を開示するインセンティブを与えるための報奨金制度、コンテスト、賞品等を通じて、導入後に第三者やユーザーが問題や脆弱性を発見し報告することを促進することの検討が奨励される。組織はさらに、他の利害関係者と協力して、報告されたインシデントの適切な文書化を維持し、特定されたリスクと脆弱性を軽減することが奨励される。適切な場合には、脆弱性を報告する仕組みは、多様な利害関係者が利用できるものでなければならない。
- III) 高度なAIシステムの能力、限界、適切・不適切な使用領域を公表し、十分な透明性の確保を支援することで、アカウントビリティの向上に貢献する。**
- これには、高度なAIシステムの重要な新規公表全てについて、有意義な情報を含む透明性報告書を公表することが含まれるべきである。
 - これらの報告書、使用説明書、及び関連する技術的文書は、適宜、最新に保たれるべきであり、例えば、以下のようなものが含まれるべきである；
 - 潜在的な安全性、セキュリティ、社会的リスク及び人権に対するリスクについて実施された評価の詳細。
 - 適切な使用領域に影響を及ぼすモデル／システムの能力と性能上の重大な限界。
 - 有害な偏見、差別、プライバシー侵害への脅威、公平性への影響等、モデルやシステムが安全性や社会に及ぼす影響やリスクについての議論と評価。
 - 開発段階以降のモデル／システムの適合性を評価するために実施されたレッドチーミングの結果
 - 組織は、適切かつ関連性のある導入者及び利用者がモデル／システムのアウトプットを解釈し、利用者がそれを適切に使用できるようにするために、透明性報告書内の情報を十分に明確で理解可能なものにすべきである。また、透明性報告書は、技術文書や使用説明書等の強固な文書化プロセスによってサポートされ、提供されるべきである。
- IV) 産業界、政府、市民社会、学界を含む、高度なAIシステムを開発する組織間での責任ある情報共有とインシデントの報告に向けて取り組む**
- これには、評価報告書、セキュリティや安全性のリスク、危険な意図的又は意図しない能力、AIのラ

ライフサイクル全体にわたるセーフガードを回避しようとするAI関係者の試みに関する情報等を含むが、これらに限定されない、適切な情報の責任ある共有が含まれる。

- 各組織は、高度なAIシステムの安全性、セキュリティ、信頼性を確保するための共有の基準、ツール、メカニズム、ベストプラクティスを開発し、推進し、必要に応じて採用するためのメカニズムを構築するか、それに参加すべきである。
- これには、特に安全性と社会に重大なリスクをもたらす高度なAIシステムに関して、AIのライフサイクル全体にわたって適切な文書化と透明性を確保することも含まれるべきである。
- 組織は、高度なAIシステムの安全性、セキュリティ、信頼性を向上させる観点から、AIのライフサイクル全体にわたって他の組織と協力し、関連情報を共有し、社会に報告すべきである。また、組織は、必要に応じて、関連する公的機関とも連携し、前述の情報を共有すべきである。
- このような報告は、知的財産権を保護すべきである。

V) 個人情報保護方針及び緩和策を含む、リスクベースのアプローチに基づくAIガバナンス及びリスク管理方針を策定し、実施し、開示する

- 組織は、AIのライフサイクルを通じて、実現可能であれば、リスクを特定し、評価し、予防し、対処するための説明責任とガバナンスのプロセス等を含む、リスク管理とガバナンスの方針を策定し、開示し、実施するための適切な組織的メカニズムを導入すべきである。
- これには、個人データ、ユーザープロンプト、高度なAIシステムのアウトプットを含め、適切な場合にはプライバシーポリシーを開示することが含まれる。組織は、リスクベースのアプローチに従って、AIガバナンス方針と、これらの方針を実施するための組織的メカニズムを確立し、開示することが期待される。これには、AIのライフサイクルを通じて実行可能な場合には、リスクを評価し、軽減するための説明責任とガバナンス・プロセスが含まれるべきである。
- リスク管理方針は、リスクベースのアプローチに従って策定されるべきであり、AIシステムに関連する様々なリスクに対処するために、適切かつ関連するAIのライフサイクル全体にわたってリスク管理の枠組みを適用すべきであり、また、方針は定期的に更新されるべきである。
- 組織は、職員が自らの責任及び組織のリスク管理慣行を熟知していることを確保するための方針、手順及び研修を確立すべきである。

VI) AIのライフサイクル全体にわたり、物理的セキュリティ、サイバーセキュリティ、内部脅威に対する安全対策を含む、強固なセキュリティ管理に投資し、実施する。

- これには、情報セキュリティのための運用上のセキュリティ対策や、適切なサイバー／物理的アクセス制御等を通じて、モデルの重み、アルゴリズム、サーバー、データセットを保護することが含まれる。
- また、高度なAIシステムのサイバーセキュリティが関連する環境及び関連するリスクに照らして適切であることを確保するため、サイバーセキュリティリスクの評価を実施し、サイバーセキュリティポリシー及び適切な技術的・制度的解決策を実施することも含まれる。また、組織は、高度AIシステムのモデルの重みの保管と作業を、アクセスが制限された適切で安全な環境で行うことを義務付け、無許可で公開されるリスクと不正アクセスされるリスクの両方を低減するための対策を講じる必要がある。これには、脆弱性管理プロセスを導入し、セキュリティ対策を定期的に見直して、それらが高い水準に維持され、リスクに対処するのに適切であり続けることを保証するコミットメントが含まれる。

- これにはさらに、例えば、非公開のモデルの重みへのアクセスの制限等の、最も貴重な知的財産や企業秘密に対する保護と整合性のある、強固な内部脅威検知プログラムの確立も含まれる。

VII) 技術的に可能な場合は、電子透かしやその他の技術等、ユーザーがAIが生成したコンテンツを識別できるようにするための、信頼できるコンテンツ認証及び来歴のメカニズムを開発し、導入する。

- これには、適切かつ技術的に実現可能な場合、組織の高度なAIシステムで作成されたコンテンツのコンテンツ認証及び来歴メカニズムが含まれる。来歴データには、コンテンツを作成したサービス又はモデルの識別子を含めるべきであるが、ユーザー情報を含める必要はない。組織はまた、透かし等を通じて、特定のコンテンツが高度なAIシステムで作成されたかどうかをユーザーが判断できるツールやAPIの開発に努めるべきである。組織は、この分野の状況を前進させるために、必要に応じて、協力し、研究に投資すべきである。
- 組織はさらに、可能かつ適切な場合には、利用者がAIシステムと相互作用していることを知ることができるよう、ラベリングや免責事項の表示等、その他の仕組みを導入することが奨励される。

VIII) 社会的、安全、セキュリティ上のリスクを軽減するための研究を優先し、効果的な軽減策への投資を優先する。

- これには、AIの安全性、セキュリティ、信頼性の向上を支援し、主要なリスクに対処する研究の実施、協力、投資及び適切な緩和ツールの開発への投資が含まれる。
- 組織は、AIの安全性、セキュリティ、信頼性の向上を支援し、民主的価値の維持、人権の尊重、子どもや社会的弱者の保護、知的財産権とプライバシーの保護、有害な偏見、偽・誤情報、情報操作の回避等の重要なリスクに対処する優先的な研究を実施し、協力し、投資することにコミットする。組織はまた、適切な緩和ツールの開発に投資することにコミットし、環境や気候への影響を含む高度なAIシステムのリスクを積極的に管理し、その便益が実現されるよう努力する。
- 組織は、リスク緩和に関する研究とベストプラクティスを共有することが奨励される。

IX) 世界の最大の課題、特に気候危機、世界保健、教育等（ただしこれらに限定されない）に対処するため、高度なAIシステムの開発を優先する。

- これらの取り組みは、国連の持続可能な開発目標の進捗を支援し、グローバルな利益のためにAIの開発を奨励するために行われる。
- 組織は、信頼できる人間中心のAIの責任あるスチュワードシップを優先し、また、高度なAIシステムの利用から利益を得ることができるようにし、個人や地域社会がこれらの技術の性質、能力、限界、影響をよりよく理解できるようにするデジタル・リテラシーのイニシアティブを支援するため、学生や労働者を含む一般市民の教育と訓練を促進すべきである。組織は、市民社会やコミュニティ・グループと協力して、優先課題を特定し、世界最大の課題に取り組むための革新的な解決策を開発すべきである。

X) 国際的な技術規格の開発を推進し、適切な場合にはその採用を推進する。

- 組織は、組織のテスト方法、コンテンツの認証及び来歴メカニズム、サイバーセキュリティポリシー、公開報告、その他の手段を開発する際にも、電子透かしを含む国際的な技術標準とベストプラクティ

スの開発に貢献し、適切な場合にはそれを利用し、標準開発組織（SDO）と協力することが奨励される。特に、AIが生成したコンテンツとAI以外が生成したコンテンツを利用者が区別できるようにするための、相互運用可能な国際的な技術標準や枠組みの開発に取り組むことが奨励される。

XI) 適切なデータインプット対策を実施し、個人データ及び知的財産を保護する。

- 組織は、有害な偏見を軽減するために、訓練データやデータ収集等、データの質を管理するための適切な措置を講じることが奨励される。
- 適切な対策には、透明性、プライバシーを保護するトレーニング技術、及び／又はシステムが機密データや機微データを漏らさないようにするためのテストとファインチューニングが含まれる。
- 組織は、著作権で保護されたコンテンツを含め、プライバシーや知的財産に関する権利を尊重するために、適切なセーフガードを導入することが奨励される。
- 組織はまた、適用される法的枠組みを遵守すべきである。

別添 4.AI 提供者向け

本章では、「本編第 4 部 AI 提供者に関する事項」に記載されている内容について、「ポイント」及び「具体的な手法」を解説する。加えて、「本編第 2 部 AI により目指すべき社会と各主体が取り組むべき事項」の「C. 共通の指針」のうち、AI 提供者が特に意識すべき具体的な手法を解説する。

なお、高度な AI システムを取り扱う AI 提供者は、必要に応じて、「本編第 2 部 AI により目指すべき社会と各主体が取り組むべき事項」の「D. 高度な AI システムに関係する事業者に通じる指針」の記載を参照の上、XII) 及び I) ～ XI) を適切な範囲で遵守すべきである。

A. 本編「第 4 部 AI 提供者に関する事項」の解説

[本編の記載内容（再掲）]

- AI システム実装時

P-2) i . 人間の生命・心身・財産、及び環境に配慮したリスク対策

- ◇ AI 利用者を含む関連するステークホルダーの生命・心身・財産、及び環境に危害を及ぼすことがないよう、提供時点で予想される利用条件下でのパフォーマンスだけでなく、様々な状況下で AI システムがパフォーマンスレベルを維持できるようにし、リスク（運動するロボットの制御不能や不適切な出力等）を最小限に抑える方法（ガードレール技術等）を検討する（「2）安全性」）

[ポイント]

想定される被害の性質・態様等を踏まえ、AI 開発者等からの情報をもとに、必要に応じて対応策を講ずることにより、AI がアクチュエータ等を通じて人の生命・身体・財産に危害を及ぼすことがなくなることを期待される。

AI がアクチュエータ等を通じて人の生命・身体・財産に危害を及ぼした場合に講ずるべき措置について、あらかじめ整理しておくことが期待される。加えて、当該措置について、AI 利用者や業務外利用者に対し、必要な情報提供を行うことが期待される。

既存の法令・ガイドラインの遵守に加え、新技術が起す問題に対しては新技術で対応するという発想も重要である。

[具体的な手法]

- 人間の不利益への配慮
 - 個人に生じる不利益への配慮（個人の権利・利益に重要な影響を及ぼす可能性のある分野において AI を活用したプロファイリングを行う場合。以下は配慮が必要な不利益の例）
 - ◇ プロファイリング結果が事実と異なることにより誤った判断が下されること
 - ◇ 個人の特定の特征のみがプロファイリングで用いられることにより、個人が過小又は過大に評価されてしまうこと
 - ◇ 個人のプロファイリング結果の一部が特定の集団の特徴と共通である場合に、当該集団にネガティブな判断が下されると、当該個人も同様にネガティブな判断が下されうること

- ◇ プロファイリングの結果、特定の個人又は集団に対する不当な差別を助長する等人の権利・利益を損なう取扱いがなされること
- ◇ プロファイリング結果をもとに不確実な未来を予測する過程で、ネガティブな判断が入り込むこと
- ◇ 匿名の個人に関する情報に基づくプロファイリング結果と、特定の個人に関する情報に基づくプロファイリング結果とを突合することにより、匿名の個人が特定されてしまうこと
- インシデントの未然防止
 - AI システム全体で安全を確保できる仕組みの構築（フェールセーフの実現）
 - 速やかな AI 開発者への通知、対応策の相談・検討（AI 開発者も気づいていないようなリスクの存在を認識した場合）
 - 事前、動作時の人間関与、事後における再発防止策の検討
 - 提供を受ける AI 利用者の信頼性の確認

[参考文献]

- AI 戦略会議「AI に関する論点整理」（2023 年 5 月）
- The White House, " Executive Order on the Safe, Secure, and Trustworthy Development and Use of Artificial Intelligence"（2023 年 10 月）

[本編の記載内容（再掲）]

● AI システム実装時**P-2) ii. 適正利用に資する提供**

- ◇ AI システム・サービスの利用上の留意点を正しく定める（「2）安全性」）
- ◇ AI 開発者が設定した範囲で AI を活用する（「2）安全性」）
- ◇ 提供時点でデータの正確性・必要な場合には最新性（データが適切であること）等を担保する（「2）安全性」）
- ◇ AI 開発者が開発した AI の想定利用環境と AI システム・サービスの利用者の利用環境に違い等がないかを検討する（「2）安全性」）

● AI システム・サービス提供後

- ◇ 適切な目的で AI システム・サービスが利用されているかを定期的に検証する（「2）安全性」）

[ポイント]

AI 提供者は、AI システム・サービスを提供するにあたり、AI の活用により生じうる又は生じた事故、セキュリティ侵害・プライバシー侵害等によりもたらされる又はもたらされた被害の性質・態様等に応じて、関連するステークホルダーと協力して予防措置及び事後対応（情報共有、停止・復旧、原因解明、再発防止措置等）に取り組むことが期待される。

[具体的な手法]

- ステークホルダー間の協力と予防措置及び事後対応
 - 適正な範囲・方法による利用のための情報の提供
 - AI が人間の生命・身体・財産に危害を及ぼした場合に講ずるべき措置の実施
 - セキュリティが侵害された場合に講ずるべき措置の実施
 - 個人のプライバシーを侵害した場合に講ずるべき措置の実施
 - 新たなリスクを認識した場合のステークホルダー間での情報共有
 - 潜在的利用者を含む社会一般への啓発活動
 - 定期的な適正利用の確認

[参考文献]

- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）

[本編の記載内容（再掲）]

● AI システム実装時**P-3) i . AI システム・サービスの構成やデータに含まれるバイアスへの配慮**

- ✧ 提供時点でデータの公平性の担保、参照する情報や連携する外部サービス等のバイアスを検討する（「3）公平性」）
- ✧ AI モデルの入出力や判断根拠を定期的に評価し、バイアスの発生をモニタリングする。また、必要に応じて、AI 開発者に AI モデルを構成する各技術要素のバイアスの再評価、評価結果に基づく AI モデル改善の判断を促す（「3）公平性」）
- ✧ AI モデルの出力結果を受け取る AI システムやユーザーインターフェースにおいて、ビジネスプロセスや利用者の判断を恣意的に制限するようなバイアスが含まれてしまう可能性を検討する（「3）公平性」）

[ポイント]

AI 提供者は、AI システム・サービスの判断にバイアスが含まれる可能性があることに留意し、また、AI システム・サービスの判断によって個人及び集団が不当に差別されないよう配慮することが期待される。

（注）「公平性」には集団公平性・個人公平性等、複数の基準があることに留意することが重要である。

[具体的な手法]

- 各種バイアスによって AI の出力が決定づけられることへの留意
 - データの代表性によるバイアス
 - ✧ データの代表性が確保されないことによってバイアスが生じる可能性がある
 - ✧ 社会的バイアスを内在するデータを用いることによってバイアスが生じる可能性がある
 - ✧ 前処理の方法により利用時の入力データに意図せずバイアスが生じる可能性がある
 - データに含まれる個人情報の扱い
 - ✧ データの代表性を満たすために個人情報を含む大量のデータを集めようとする場合に、特に丁寧に扱う
 - アルゴリズムによるバイアス
 - ✧ アルゴリズム次第でセンシティブ属性（公平性の観点から排除すべき対象者の性別や人種等の個人の属性）によるバイアスが生じる可能性がある
 - センシティブ属性の明確化
 - ✧ このような属性を明確化する際には、憲法 14 条 1 項が列挙する事由や、国際的な人権に関するルールで言及されている属性を考慮する
 - センシティブ属性に関し確保すべき公平性の内容の明確化
 - 公平性の基準を満たす制約の機械学習アルゴリズムへの付加
 - バイアスをチェックするためのツール（ソフトウェア）の活用
- 公平性の基準の確認（「コラム 6：集団公平性と個人公平性」参照）
 - 集団公平性の基準（以下は基準例）
 - ✧ センシティブ属性を取り除き、非センシティブ属性のみに基づき予測を行う（unawareness）

- ✧ センシティブ属性の値が異なる複数のグループ間で、同じ予測結果を確保する (demographic parity)
- ✧ 実際の結果に対する予測結果の誤差の比率を、センシティブ属性の値によらないように調整する (equalized odds)
- 個人公平性の基準例 (以下は基準例)
 - ✧ センシティブ属性以外の属性値が等しい個人に対してはそれぞれ同じ予測結果を与える。
 - ✧ 類似した属性値を持つ個人には類似した予測結果を与える (Fairness through awareness)

コラム 6 : 集団公平性と個人公平性

一般に公平性要求においては、人種や性別等「不公平」を生じかねない属性（要配慮属性）についての扱いが問われる。この際、ある要配慮属性値について、異なる集団の間で差別（例：女性に不利な扱い）を起こさないことが集団公平性であり、一方で必ずしもそうした特定の属性による分類に限定せず「似た人」の間で差別を起こさないことが個人公平性である。現時点で汎用的に使える機械学習要素の公平性評価（メトリクス）や施策は、「要配慮属性」を要とする集団公平性を前提とするものが主流であって、断りが無い限り集団公平性視点を前提としている。前述したような「当事者個人」にとつての「正当性」が要求される場合は、個人公平性視点が求められる為、一般的なメトリクスが定義しづらくシステムごとに要求を満たすための施策を検討せねばならない。個人公平性については、距離学習を用いた「似た度合い」の研究等も提案されており今後に期待したい。

- 定性的なアプローチ・定量的な手法のプロセスを介した公平性の実現（「コラム 7 : 公平性品質の確保に関するプロセス」参照）
 - 社会的要請や AI システム・サービス利用時の品質に関するデータ等を定性的に扱い、公平性の欠如の発生をリスクと捉えるリスク分析アプローチ
 - ✧ まずは定性的に公平性を担保することを要求するが、必要に応じて実装段階から「結果の均等」等定量的な公平性メトリクスを用い、システムや AI 要素の中身の具体化が進むに伴って、定量的なアプローチも盛り込んでいく
 - ✧ 公平性メトリクスの設定や選択の妥当性を、分析や設計のアプローチによって担保しようとするもので、「リスク回避性」や機能安全性等の実現におけるリスク分析ベースのアプローチとも類似していると考えられる（「図 8. 公平性品質の確保に関するプロセス構造の例示」参照）。

コラム 7：公平性品質の確保に関するプロセス

「図 8. 公平性品質の確保に関するプロセス構造の例示」は、社会的要請や利用時品質等高い抽象度の段階における「取扱いの平等」を定性的に扱い、不公平性の発生をリスクと捉えたりリスク分析アプローチにより具体化し、必要に応じて開発のいずれかの段階から「結果の均等」等定量的な公平性メトリクスを通じて実現する一連のプロセスの一例を図示したものである。この図は個々の開発の考え方や段階の設定を拘束するものではなく、定性的なアプローチから定量的な手法に至る流れを整理するモデルである。

- ① 最も抽象度の高い公平性要求：「正義」あるいは「人権」のようなレベルでは、「平等」「平等な取扱い」であることが求められる。
- ② 社会的要求：法制度・あるいは暗黙の倫理的行動等の社会ルールのレベルでは「取扱いが平等である」ことを要求する場合と、数値目標等の形で「結果が平等である」ことを求められる
- ③ ④ システム要求/AI 要素への要求：システム全体の設計及び、機械学習要素の設計に対応するレベルとして、目標設定に結果の数値的な均等性と取扱いの平等性のいずれかが求められる。
- ⑤ 内部品質検討：次に、内部品質の一部システムの構築プロセスの中でも、目標設定に結果の数値的な均等性と取扱いの平等性のいずれかが求められる。
- ⑥ 内部品質実現：最後に、品質の確認手段と対応する内部品質のレベルでは、結果の統計的分布を分析する方法、結果分布以外の統計的・分析的指標をモニタリングする方法、そして実装の論理的構造から取扱いの平等性を説明する方法が考えられる。




図 8. 公平性品質の確保に関するプロセス構造の例示

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」(2023 年 12 月)

[本編の記載内容（再掲）]

● AI システム実装時**P-4) i . プライバシー保護のための仕組みや対策の導入**

- ✧ AI システムの実装の過程を通じて、採用する技術の特性に照らし適切に個人情報へのアクセスを管理・制限する仕組みの導入等のプライバシー保護のための対策を講ずる（プライバシー・バイ・デザイン）（「4）プライバシー保護」）

[ポイント]

プライバシー・バイ・デザイン は、三つの側面に幅広く適用されるべきである。

- 1) IT システム
- 2) 責任あるビジネス・プラクティス
- 3) 物理的設計とネットワーク基盤

プライバシー・バイ・デザインの目標 – プライバシーを確保すること、そして、組織のために、持続可能な競争的利点を獲得することが重要である。 – は、次に掲げる「プライバシー・バイ・デザイン 7つの基本原則」を実践することで達成することができる。

- ① 事後的ではなく事前的、救済的でなく予防的
- ② 初期設定としてのプライバシー
- ③ デザインに組み込まれるプライバシー
- ④ 全機能的 – ゼロサムではなく、ポジティブサム（トレードオフの関係を作ってしまうゼロサムアプローチではなく、全ての正当な利益及び目標を収めるアプローチ）
- ⑤ 最初から最後までセキュリティすべてのライフサイクルを保護
- ⑥ 可視性と透明性 – 公開の維持
- ⑦ 利用者のプライバシーの尊重 – 利用者中心主義を維持する

[具体的な手法]

- プライバシー・バイ・デザインに基づくプライバシー対策の実施
 - 品質マネジメントの実施（「表 6. 品質マネジメント実施項目の概要」参照）
 - ✧ 保護が必要なデータが準拠する法令等に適合しているか確認する
 - ✧ 法令が規定する要配慮個人情報を特定する
 - ✧ 再利用可能な成果物を決定する
 - ✧ データ提供者との同意の取り決めを確認し、取り決めに従いデータを扱う

表 6. 品質マネジメント実施項目の概要

事前分析 (主に AI 提供者)	要保護データ		成果物の取り扱い	
	・準拠法への適合性 ・要配慮個人情報の特定		・再利用成果物の決定 ・同意の取り決めの確認	
方式検討 (主に AI 開発者)	Pre ステージ		In ステージ	Post ステージ
	・学習データ品質 ・保護加工 ・データ分布（外れ値）		・汎化性能 ・PPML（差分プライバシー）	・セーフガードの設定
	トレードオフ分析			
	・判断結果の精度 VS 公平性 ・データ保護対策 VS 有用性			

- 関連するステークホルダー及び個人のプライバシーの尊重
 - 個人のプライバシーを侵害する情報の消去、AI のアルゴリズムの更新等（AI 利用者等関連するステークホルダー及び個人のプライバシーを侵害する情報を取得した場合）
 - 個人のプライバシーを侵害する情報の消去の依頼、AI のアルゴリズムの更新等（AI 利用者等関連するステークホルダー及び個人のプライバシーを侵害する情報を拡散した場合）

[参考文献]

- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）
- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- Ann Cavoukian, “Privacy by Design: The 7 Foundational Principles”（2011 年 9 月）

[本編の記載内容（再掲）]

● AI システム実装時

P-5) i . セキュリティ対策のための仕組みの導入

- ◇ AI システム・サービスの提供の過程を通じて、採用する技術の特性に照らし適切にセキュリティ対策を講ずる（セキュリティ・バイ・デザイン）（「5）セキュリティ確保」）

[ポイント]

AI のセキュリティに留意し、AI システムの機密性・完全性・可用性を確保するため、その時点での技術水準に照らして合理的な対策を講ずることが期待される。また、セキュリティが侵害された場合に講ずるべき措置について、当該 AI の用途や特性、侵害の影響の大きさ等を踏まえ、あらかじめ整理しておくことが期待される。

「情報セキュリティを企画、設計段階から組み込むための方策」で内閣サイバーセキュリティセンター（NISC）により定義されているセキュリティ・バイ・デザイン等を参考にし、開発プロセスの早い段階からセキュリティを考慮することで、開発するシステムのセキュリティを確保する。従来のような後付けでセキュリティ機能を追加したり、出荷直前になってセキュリティツールを実行しては、手戻りが多発したり、結果的に開発コストが多くなってしまう可能性がある。開発の早い段階でセキュリティ対策を行うことで、手戻りが少なく、コスト削減に繋がり、保守性の良い AI システムの実装及び提供につながる。

[具体的な手法]

- セキュリティ・バイ・デザインに基づくセキュリティ対策の実施
 - 脅威分析（Threat Assessment）の実施
 - ◇ AI システムが直面する脅威や想定される攻撃を明らかにする。AI システムを「何から守るのか」明らかにする
 - セキュリティ要件（Security Requirements）の定義
 - ◇ AI システム自身のセキュアな動作を定義する。要件の種類にはシステムの機能に関する要件や、可用性、保守性、性能等の要件がある。セキュリティ要件とは、システム要件のうちセキュリティに関する要件のことであり、システムを安全に運用するために必要な目標を定義する。システム要件定義書の一部として、又はセキュリティ要件定義書として、セキュリティ要件を記述する
 - セキュリティアーキテクチャ（Security Architecture）の選択
 - ◇ 自組織で独自のアーキテクチャを考えるよりも、AI システムを搭載するプラットフォームの提供元が推奨しているアーキテクチャをカスタマイズしつつ利用する
- AI に対する攻撃の分類
 - システムの誤作動
 - ◇ リスク回避性の低下として、自動運転における物体検知の失敗、運転補助における運転者の異常の見逃し、情報セキュリティ対策におけるマルウェア検知のすり抜け、防犯システムにおける侵入検知の失敗、異常行動検知の失敗、病理診断システムにおける偽陽性・偽陰性の増加等が被害例として挙げられる

- ◇ AI システムのパフォーマンスの低下として、交通・物流における配車の割当の効率低下、交通渋滞や物流コストの増加、小売分野における商品推薦や需要予測や店舗状況把握の正解率の低下、入学・雇用・人材配置の適切性の低下等が被害例として挙げられる
- ◇ 公平性の低下として、与信審査システムによる不公平・差別的な融資、人材評価システムによる不公平・差別的な入学・雇用・人材配置、防犯システムによる不公平・差別的な犯罪リスク判定等における公平性が例として挙げられる
- AI モデルについての情報の漏洩
 - ◇ AI モデルのパラメータや機能等の非公開の情報を漏洩させる攻撃は、AI モデルの機能に関する営業秘密等の漏洩を生じる場合がある
- 訓練用データに含まれるセンシティブ情報の漏洩
 - ◇ センシティブ情報が訓練用データに含まれている場合、訓練用データの情報を漏洩させる攻撃によって、プライバシーの侵害、営業秘密の漏洩、法規制・契約への違反等が生じる場合がある
 - ◇ 医療情報等の個人情報、顧客別売上情報、撮影禁止の軍事施設の画像データ等が訓練用データセットに含まれている場合には、訓練用データの情報を漏洩させる攻撃によって、個人に被害が及ぶ可能性がある（「表 4. 機械学習利用システムの各被害を引き起こす攻撃の例」参照）
- セキュリティ侵害対策の検討
 - 初動措置
 - ◇ AI システムのロールバック、代替システムの利用等による復旧
 - ◇ AI システムの停止（キルスイッチ）
 - ◇ ネットワークからの遮断
 - ◇ セキュリティ侵害の内容の確認
 - ◇ 関連するステークホルダーへの報告
 - 補償・賠償等を円滑に行うための保険の利用
 - 第三者機関の設置とその機関による原因調査・分析・提言

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- 独立行政法人情報処理推進機構「セキュリティ・バイ・デザイン導入指南書」（2022 年 8 月）
- 英国サイバーセキュリティセンター（NCSC）「セキュアな AI システム開発のためのガイドライン（Guidelines for secure AI system development）」（2023 年 11 月）

[本編の記載内容（再掲）]

● AI システム実装時**P-6) i. システムアーキテクチャ等の文書化**

- ✧ トレーサビリティと透明性の向上のため、意思決定に影響を与える提供する AI システムのシステムアーキテクチャやデータの処理プロセス等について文書化する（「6）透明性」）

[ポイント]

AI 提供者は、AI の入出力等の説明可能性を確保するため、AI システムの入出力等のログを記録・保存し、解釈可能な内容で文書化すると、プロセス自体の改善も容易になり、関連するステークホルダーとのコミュニケーションと対話が強化される。必要に応じて、リスク管理文書を公開する。文書化により透明性が高まり、人によるレビュープロセスが可能になることで説明可能性の確保につながる。

[具体的な手法]

- 説明可能性確保
 - AI システム・サービスのログの記録・保存
 - ✧ ログの記録・保存の目的（人の生命・身体・財産に危害を及ぼしうる分野における事故の原因究明や再発防止を目的としたものであるか等）
 - ✧ ログ取得の取得頻度・ログの精度・ログの保存期間
 - ✧ ログの保護（機密性、完全性、可用性等の確保）
 - ✧ ログ保存場所の容量
 - ✧ ログの時刻の記録（時刻同期による正確性確保等）
 - ✧ 開示するログの範囲
 - ✧ ログの保存方法（サーバー内に格納か、記録メディアに保存するか、等）
 - ✧ ログの保存場所（ローカルかクラウドか、等）
 - ✧ ログの確認手順（ログへのアクセス方法、等）
 - 解釈可能なアルゴリズムを実装する AI システムの採用
 - ✧ 利用する AI システムには、予め可読性の高い解釈可能な AI モデルを採用する
 - アルゴリズムによる判断結果の説明を一定程度行うための技術的手法の採用
 - ✧ 「AI の予測・認識プロセスの可読化」等、解釈可能な AI モデルに置き換えて説明を行う大域的な説明法（例えば、AI モデルの推論結果をデータセットに含まれるインスタンス（事例）や、それらを加工したデータにより説明する。例えば SHAP 等）
 - ✧ 「重要な特徴の提示」、「重要な学習データの提示」及びその「自然言語による表現」等、特定の入力に対する予測の根拠を提示する局所的な説明法（例えば、「～ならば～」といったルールを基に推論ロジックや判断根拠を説明する、入力データのうち推論に大きく影響を与える重要な要素を重みづけする等）
 - データの来歴の管理
 - ✧ AI の学習等に利用されたデータが、いつ、どこで、どういう目的で集められたデータなのかを管理（data provenance）する

- AI モデルの入出力の傾向の分析
 - ◇ AI に対する複数の入力と出力の組合せをもとに、AI の出力の傾向を分析する（例えば、入力パターンを少しずつ変化させたときの出力の変化の観測等）
- 技術的文書の適宜アップデート

[参考文献]

- OECD, Advancing accountability in AI （2023 年 2 月）
- AI プロダクト品質保証コンソーシアム「AI プロダクト品質保証ガイドライン」（2023 年 6 月）

[本編の記載内容（再掲）]

● AI システム・サービス提供後**P-4) ii . プライバシー侵害への対策**

- ☆ AI システム・サービスにおけるプライバシー侵害に関して適宜情報収集し、侵害があった場合は適切に対処するとともに、再発の防止を検討する（「4）プライバシー保護」）

[ポイント]

プライバシー侵害は個人的な感じ方の相違や、社会受容性がコンテキストや時間の経過で移り変わることから、常に関連する情報（市場動向、技術、制度等）を収集することが期待される。また、プライバシー侵害に詳しい有識者（学識者、コンサルタント、弁護士、消費者団体等）との関係性を構築し必要に応じて相談することも期待される。さらに、実際の事業においてプライバシー侵害が発生してしまった場合における初動対応やその後の被害救済等の事後対応、原因解析と改善対応も重要である。

[具体的な手法]

- プライバシー保護組織による対応
 - 企業内の各部門の新規事業やサービス内容に関する様々な情報の集約（プライバシー侵害が消費者や社会に発現するリスクを漏れなく見つけることを目的とする）
 - プライバシー保護責任者を中心とした初動対応やその後の被害救済等の事後対応、原因解析と改善対応（プライバシー侵害が発生した場合）
 - 企業内の各部門との関係構築
 - ☆ 事業部門等から寄せられるプライバシーに関連した相談を幅広く受けるだけでなく、AI システム・サービスを扱う部門に対して能動的に問題意識の共有を働き掛ける等、日ごろから常に接点を持つことが期待される。新規事業や新規技術開発部門が悩みを抱え込まずに、自由に相談できる体制や環境が形成されることが重要である
 - プライバシー保護組織の体制構築（体制のパターン例を以下に記載）
 - ☆ プライバシー保護組織はないが、AI システム・サービスを扱う部門毎に責任者を設定
 - ☆ プライバシー保護組織（兼務）を設置し、AI システム・サービスを扱う部門と連携
 - ☆ プライバシー保護組織（専任）を設置し、AI システム・サービスを扱う部門と連携

[参考文献]

- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）

[本編の記載内容（再掲）]

● AI システム・サービス提供後**P-5) ii . 脆弱性への対応**

- ☆ AI システムに対する攻撃手法も数多く生まれているため、最新のリスクやそれに対応するために提供の各工程で気を付けるべき点の動向を確認する。また、脆弱性の解消を検討する（「5）セキュリティ確保」）

[ポイント]

AI 提供者は、自ら提供する AI システム・サービスについて、AI 利用者や業務外利用者にセキュリティ対策のためのサービスを提供するとともに、過去のインシデント情報の共有を図ることが重要となる。

AI 提供者は、AI モデルの管理や改善、調整において、セキュリティ上に脆弱性が存在するリスクに留意することが期待される。また、AI 利用者や業務外利用者に対し、そのようなリスクが存在することを予め周知することが期待される。

「脅威分析」では AI システム・サービスが直面する脅威や想定される攻撃を明らかにし、「何から守るのか」明らかにする。

[具体的な手法]

- AI モデルに対する脆弱性に関するリスクへの留意（以下はリスク例）
 - 学習が不十分であること等の結果、AI モデルが正確に判断することができるデータに、人間には判別できない程度の微少な変動を加え、そのデータを入力すること等により、作為的に AI モデルが誤動作するリスク（例：Adversarial example 攻撃）
 - 教師あり学習において、不正確なラベリング等がなされたデータを混在させることで、誤った学習が行われるリスク
 - AI モデルが容易に複製できるリスク
 - AI モデルから学習に用いられたデータをリバースエンジニアリングできるリスク
- 機械学習特有の各種攻撃への対策（「表 5. 機械学習特有の攻撃の実行フェーズ・攻撃者・攻撃手段の例」参照）
 - データポイズニング攻撃
 - ☆ データセットの真正性、データセットの収集・加工プロセスの信頼性の確認
 - ☆ データセットにおけるデータポイズニングの検知技術の利用
 - ☆ データポイズニングに対するデータセットの頑健性を向上させる技術の利用（データ数を増加させることで、ポイズニングの影響を抑える等）
 - ☆ データポイズニングに対して頑健な学習方法による訓練（ランダムスムージングやアンサンブル学習等）
 - ☆ 開発用ソフトウェア・開発環境の脆弱性に対する従来型のセキュリティ対策
 - 妥当性確認データ・評価用データの改変（manipulation of validation/test data）
 - ☆ データセットの収集・加工プロセスの信頼性の確認
 - ☆ 開発用ソフトウェア・開発環境の脆弱性に対する従来型のセキュリティ対策

- モデルポイズニング攻撃
 - ◇ AI モデルの学習・提供プロセスの信頼性の確認
 - ◇ モデルポイズニングの検知技術の利用
 - ◇ 事前学習モデルや AI モデルのポイズニングの除去・軽減
 - ◇ 開発用ソフトウェア・開発環境の脆弱性に対する従来型のセキュリティ対策
 - ◇ 運用時システム環境・運用体制の脆弱性に対する従来型のセキュリティ対策
- 回避攻撃
 - ◇ 敵対的データに対する AI モデルの頑健性の向上・評価の手法
 - ◇ AI モデルへの入力の制限（アクセス権の制限やアクセス回数・頻度の制限）
 - ◇ 敵対的データの検知技術の利用
 - ◇ 複数の異なる AI モデルやシステムの併用
 - ◇ モデル抽出攻撃を防止・軽減する技術的対策
- モデル抽出攻撃
 - ◇ モデル抽出攻撃の検知技術の利用
 - ◇ AI モデルの出力情報等の加工
 - ◇ アンサンブル学習
- 訓練用データに関する情報漏洩攻撃
 - ◇ プライバシー保護学習
 - ◇ プライバシー保護データ生成

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）
- 独立行政法人情報処理推進機構 セキュリティ・バイ・デザイン導入指南書」（2022 年 8 月）

[本編の記載内容（再掲）]

● AI システム・サービス提供後

P-6) ii . 関連するステークホルダーへの情報提供

- ◇ 提供する AI システム・サービスについて、例えば以下の事項を平易かつアクセスしやすい形で、適時かつ適切に説明できるようにしておく（「6）透明性」）
 - AI を利用しているという事実や適切/不適切な使用方法等（「6）透明性」）
 - 提供する AI システム・サービスの技術的特性、利用によりもたらす結果より生じる可能性のある予見可能なリスク及びその緩和策等の安全性に関する情報（「2）安全性」）
 - AI システム・サービスの学習等による出力又はプログラムの変化の可能性（「1）人間中心」）
 - AI システム・サービスの動作状況に関する情報、不具合の原因と対応状況、インシデント事例等（「2）安全性」）
 - 更新を行った場合の更新内容とその理由の情報（「2）安全性」）
 - AI モデルにて学習するデータの収集ポリシーやその学習方法及び実施体制等（「3）公平性」、「4）プライバシー保護」、「5）セキュリティ確保」）

[ポイント]

AI 提供者は、個人の権利・利益に重大な影響を及ぼす可能性のある分野において AI を利用する場合等、AI を活用する際の社会的文脈を踏まえ、AI 利用者の納得感や安心感の獲得、また、そのための AI の動作に対する証拠の提示等を目的として、AI の出力結果の説明可能性を確保することが期待される。その際、AI をどのような説明が求められるかを分析・把握し、必要な対応を講じることが期待される。

リスクを評価して対処した後、AI システムが規制、AI ガバナンス、倫理基準に準拠しているかどうかを検証し、関連するステークホルダーと共有することが重要となる。これにより、リスクと、意思決定や行動の背後にある論理的根拠の理解が促進される。モニタリングとレビューのプロセスとツールを確立するだけでなく、定期的なコミュニケーションとレビューをして、AI の望ましくない動作やインシデントに関する情報についても関連するステークホルダーと確実に共有されるようにすることが重要である。

[具体的な手法]

- AI システム・サービスについての情報共有
 - 提供する AI システム・サービスが AI を用いたものであることとその用途・方法
 - AI の性質、利用の態様等に応じた便益及びリスク
 - 提供する AI システム・サービスの活用の範囲・方法に関する定期的な確認方法（特に、AI システムが自律的に更新される場合の観測、確認方法）、確認の重要性・頻度、未確認によるリスク等
 - 活用の過程を通じて、AI の機能を向上させ、リスクを抑制するために実施する AI システムのアップデート及び AI システムの点検・修理等
 - 安全性、セキュリティ、社会的リスク及び人権に対するリスクについて実施された評価の詳細

- 適切な使用領域とその使用に影響を及ぼす AI モデルや AI システム・サービスの能力と性能上の限界
- 有害な偏見、差別、プライバシー侵害の脅威、公平性への影響等、AI モデルや AI システム・サービスが安全性や社会に及ぼす影響やリスクについての議論と評価
- 開発段階以降の AI モデルや AI システム・サービスの適合性を評価するために実施されたレッドチーミングの結果
- 情報提供に際しての留意点
 - ✧ AI 利用者が必要な情報を適切なタイミングで共有する
 - ✧ AI システム・サービスについて提供すべき情報を利用前に提供する
 - ✧ AI システム・サービスの利用前に上記の情報を提供できない場合には、AI の性質、利用の態様等に基づき想定されるリスクに応じ、AI 利用者や業務外利用者からのフィードバックに対応する体制を整備する

[参考文献]

- NIST, Artificial Intelligence Risk Management Framework (AI RMF 1.0) (2023 年 1 月)
- OECD, Advancing accountability in AI (2023 年 2 月)
- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」(2023 年 4 月)

[本編の記載内容（再掲）]

● AI システム・サービス提供後

P-7) i . AI 利用者への共通の指針の対応状況の説明

- ☆ AI 利用者に適正利用を促し、以下の情報を AI 利用者に提供する（「7）アカウントビリティ」）
 - 正確性・必要な場合には最新性（データが適切であること）等が担保されたデータの利用についての注意喚起（「2）安全性」）
 - コンテキスト内学習による不適切な AI モデルの学習に対する注意喚起（「2）安全性」）
 - 個人情報を入力する際の留意点（「4）プライバシー保護」）
- ☆ 提供する AI システム・サービスへの個人情報の不適切入力についての注意喚起（「4）プライバシー保護」）

[ポイント]

AI 提供者は、人々と社会から AI への信頼を獲得することができるよう、他の共通の指針の趣旨に鑑み、AI 利用者や業務外利用者に対し、利用する AI の性質及び目的等に照らして、それぞれが有する知識や能力の多寡に応じ、AI システムの特性について情報提供と説明を行うことや、多様なステークホルダーとの対話を行うこと等により、相応のアカウントビリティを果たすことが期待される。

人の生命・身体・財産に危害を及ぼし得る分野で AI を活用する場合には、AI 提供者は、想定される被害の性質・態様等を踏まえ、AI 開発者等からの情報をもとに、必要に応じて対応策を講じ、その内容を合理的な範囲で AI 利用者に説明することが期待される。

[具体的な手法]

- AI 利用者等への AI システム・サービス利用に際しての注意喚起と関連する対応
 - AI の点検・修理及び AI システムのアップデート、また AI 利用者等への対応促進（AI がアクチュエータ等を通じて人の生命・身体・財産に危害を及ぼすことのないようすることを目的とする。問題が発見されてからアップデートが提供されるまでの間は、問題点を適時適切に情報提供、注意喚起する）
 - 人間の生命・身体・財産に危害を及ぼした場合に講ずるべき措置の情報提供（必要な場合）
 - 入出力等のログの記録・保存等による確認と不適切入力についての注意喚起（AI 利用者による悪意ある利用を抑止することを目的とする）
 - AI 利用者等の関連するステークホルダー及び個人のプライバシーを侵害した場合に講ずるべき措置
 - AI システム・サービスの適正な利用範囲及び利用方法（AI 開発者等からの情報提供や説明を踏まえ、AI を利用する目的、用途、性質や能力等を確認した上で情報提供）

[参考文献]

- The White House, "Blueprint for an AI Bill of Rights（Making Automated Systems Work for The American People）"（2022 年 10 月）

[本編の記載内容（再掲）]● AI システム・サービス提供後**P-7) ii . サービス規約等の文書化**

- ◇ AI 利用者、業務外利用者に向けたサービス規約を作成する（「7）アカウントビリティ」）
- ◇ プライバシーポリシーを明示する（「7）アカウントビリティ」）

[ポイント]

AI サービス提供における不透明さを解消し、適正なサービスレベルの維持・管理を実現する上で、SLA の活用が有効である。SLA により、サービスの範囲・内容・前提事項及びサービスレベルへの要求水準の明確化を行い、AI 利用者及び AI 提供者双方で共通認識を形成することが期待される。

AI 利用者や業務外利用者との信頼関係を構築し事業活動に対する社会の信頼を確保するためには、「個人情報保護に関する考え方や方針（いわゆる、プライバシーポリシー、プライバシーステートメント等）」を策定することが期待される。

[具体的な手法]

- サービス規約の作成
 - 対象となるサービスと要求水準の設定
 - ◇ 設定にあたっては、万一トラブルが発生した場合に業務に与える影響を考慮した上で優先順位を見極め、重要度が高いものを中心に定義を行う
 - ◇ サービスレベルを決定する際、AI 利用者と AI 提供者の間で認識の相違が起これないように、客観的な項目（定量的な数値、数式による測定等）を定める
- 個人情報保護に関する考え方や方針（プライバシーポリシー、プライバシーステートメント等）の策定・公表
 - 委託処理の明確化
 - ◇ 委託の有無、委託する事務の内容を明らかにする等、委託処理の透明化を進める
 - 公表
 - ◇ 方針を策定した後、それをホームページへの掲載等により公表し、あらかじめ、対外的に分かりやすく説明する
- 文書の適宜アップデート

[参考文献]

- 経済産業省「SaaS 向け SLA ガイドライン」（2008 年 1 月）
- The White House, "Blueprint for an AI Bill of Rights（Making Automated Systems Work for The American People）"（2022 年 10 月）

B.本編「第 2 部」の「共通の指針」の解説

ここでは、「第 4 部 AI 提供者に関する事項」では触れられていないが、「第 2 部」の「共通の指針」のうち、AI 提供者にとって特に重要なものについて、具体的な手法を解説する

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

1) 人間中心

各主体は、AI システム・サービスの開発・提供・利用において、後述する各事項を含む全ての取り組むべき事項が導出される土台として、少なくとも憲法が保障する又は国際的に認められた人権を侵すことがないようにすべきである。また、AI が人々の能力を拡張し、多様な人々の多様な幸せ（well-being）の追求が可能となるよう行動することが重要である。

● 「①人間の尊厳と個人の自律」関連

[関連する記載内容]

- AI が活用される際の社会的文脈を踏まえ、人間の尊厳と個人の自律を尊重する

[具体的な手法]

- 社会的、安全、セキュリティ上のリスク軽減の研究の推進
 - ✧ 社会的、安全、セキュリティ上のリスクを軽減するための研究、効果的な軽減策への投資（以下は研究内容の例）
 - 民主的価値の維持
 - 人権の尊重
 - 子供や社会的弱者の保護
 - 知的財産権とプライバシーの保護
 - 有害な偏見の回避
 - 偽・誤情報の回避
 - 情報操作の回避 等
 - ✧ リスク緩和に関する研究とベストプラクティスの共有（可能な範囲で実施する）

● 「②AI による意思決定・感情の操作等への留意」関連

[関連する記載内容]

- 人間の意思決定や認知等、感情を不当に操作することを目的とした、もしくは操作を前提とした AI システム・サービスの開発・提供・利用は行わない

[具体的な手法]

- 意思決定・感情の操作等への対策
 - ✧ AI 利用者への注意喚起
 - ✧ 教育現場等における AI への依存や意思決定及び感情の操作等のリスクの存在の共有、認識の促進

- ◇ 導入後の脆弱性発見及び報告を促進するためのインセンティブの検討（報奨金制度、コンテスト、商品等）
- 「③偽情報等への対策」関連
 - [関連する記載内容]
 - 生成 AI によって、内容が真実・公平であるかのように装った情報を誰でも作ることができるようになり、AI が生成した偽情報・誤情報・偏向情報が社会を不安定化・混乱させるリスクが高まっていることを認識した上で、必要な対策を講じる
 - [具体的な手法]
 - 偽情報・誤情報・偏向情報等のリスク回避策の考慮
 - ◇ 電子透かしやその他の技術等、AI 利用者が AI の生成した情報であることを識別できるための技術の開発及び導入
 - ◇ 幅広い年代への情報リテラシー教育の実施
- 「④多様性・包摂性の確保」関連
 - [関連する記載内容]
 - 公平性の確保に加え、いわゆる「情報弱者」や「技術弱者」を生じさせず、より多くの人々が AI の恩恵を享受できるよう社会的弱者による AI の活用を容易にするよう注意を払う
 - [具体的な手法]
 - 誰一人取り残さない AI 活用への心がけ
 - ◇ UI（ユーザーインターフェース）・UX（ユーザーエクスペリエンス）の改善
 - ◇ 安全安心な利用環境の整備
 - ◇ 公共デジタルプラットフォームの整備
- 「⑥持続可能性の確保」関連
 - [関連する記載内容]
 - AI システム・サービスの開発・提供・利用において、ライフサイクル全体で、地球環境への影響に配慮することが期待される
 - [具体的な手法]
 - グローバル共通の課題への考慮
 - ◇ 国連の持続可能な開発目標の進捗を支援し、グローバルな利益のための AI 開発・活用の奨励（以下はグローバル課題の例）
 - 気候変動対策
 - 人類の健康と福祉（世界保健）
 - 質の良い教育
 - 貧困の撲滅・飢餓のない世界
 - 衛生の維持
 - 手ごろな価格でのクリーンエネルギー
 - 不平等の撲滅

- 責任ある消費と生産 等

[参考文献]

- 国際連合「持続可能な開発目標」（2015 年 9 月）
- 総務省「令和 3 年版 情報通信白書」（2021 年 7 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

2) 安全性

各主体は、AI システム・サービスの開発・提供・利用を通じ、AI に関わる全ての者の生命・心身・財産、及び環境に危害を及ぼすことがないようにすることが重要である。

- 「①人間の生命・心身・財産、及び環境への配慮」関連

[関連する記載内容]

- AI システム・サービスの安全性を損なう事態が生じた場合の対処方法を検討し、当該事態が生じた場合に速やかに実施できるよう整える

[具体的な手法]

- インシデント対策の整理と発生時の措置の検討
 - ◇ インシデント対策の整理
 - 危害発生時の連絡体制の事前整備
 - 原因調査方法や復旧作業方法の整理
 - 再発防止策の検討・対応方針の整理
 - インシデントに関する情報共有方法の設定
 - ◇ 初動措置
 - AI システムのロールバック、代替システムの利用等による復旧
 - AI システムの停止（キルスイッチ）
 - ネットワークからの遮断
 - 危害の内容の確認
 - 関連するステークホルダーへの報告
 - ◇ 補償・賠償等を円滑に行うための保険の利用
 - ◇ 第三者機関の設置とその機関による原因調査・分析・提言

[参考文献]

- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

3) 公平性

各主体は、AI システム・サービスの開発・提供・利用において、特定の個人ないし集団へのその人種、性別、国籍、年齢、政治的信念、宗教等の多様な背景を理由とした有害な偏見や差別を排除することが重要である。また、各主体は、潜在的なバイアスを最小化するよう留意し、それでも回避できないバイアスがあることを認識しつつ、この回避できないバイアスが人権や多様な文化を尊重する観点から許容可能か評価をした上で、AI システム・サービスの開発・提供・利用を行うことが重要である。

● 「②人間の判断の介在」関連

[関連する記載内容]

- AI の出力結果が公平性を欠くことがないよう、AI に単独で判断させるだけでなく人間の判断を介在させる利用を検討する

[具体的な手法]

- 人間の判断の介在要否に関する判断（以下は判断基準の例）
 - ✧ AI の出力に影響を受ける業務外利用者の権利・利益の性質及び業務外利用者の意向
 - ✧ AI の出力の信頼性の程度（人間による判断の信頼性との優劣）
 - ✧ 人間の判断に必要な時間的猶予
 - ✧ 判断を行う AI 利用者に期待される能力
 - ✧ 判断対象の要保護性（例えば、人間による個別申請への対応か、AI システム・サービスによる大量申請への対応か等）
 - ✧ 統計的な将来予測の不確定性
 - ✧ 意思決定（判断）に対し納得ある理由の必要性和程度
 - ✧ 学習データにマイノリティ等に対する社会的バイアスが含まれていること等により、人種・信条・性別に基づく差別の想定度合い
- 人間の判断の実効性の確保
 - ✧ 説明可能性を有する AI から得られる説明を前提として、人間が判断すべき項目を事前に明確化しておく（AI の出力に対し、人間が最終判断をすることが適当とされている場合）
 - ✧ 適切に判断ができるよう必要な能力及び知識を習得する（AI の出力に対し、人間が最終判断をすることが適当とされている場合）
 - ✧ 人間の判断の実効性を確保するための対応を事前に整理しておく

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

6) 透明性

各主体は、AI システム・サービスの開発・提供・利用において、AI システム・サービスを活用する際の社会的文脈を踏まえ、AI システム・サービスの検証可能性を確保しながら、必要かつ技術的に可能な範囲で、ステークホルダーに対し適切な情報を提供することが重要である。

- 「④関連するステークホルダーへの説明可能性・解釈可能性の向上」関連

[関連する記載内容]

- ステークホルダーの納得感や安心感の獲得、また、そのための AI の動作に対する証拠の提示等を目的として、どのような説明が求められるかを分析・把握し、必要な対応を講じる

[具体的な手法]

- 説明可能性の確保
 - ◇ AI 利用者や業務外利用者のニーズ、意見等も踏まえた説明不足部分の明確化と AI 開発者と連携した説明内容検討
 - ◇ AI 開発者を含むステークホルダーとの連携によるコンテキスト分析と、潜在的なリスク（影響を被る対象、影響が起こりうる状況等）の調査・文書化
 - ◇ リスクを追跡するための監視及びレビューインターフェースと実施頻度、機能及び有効性の確保
 - ◇ ステークホルダーが苦情を提起できるプロセス等の救済メカニズムの確立と伝達

[参考文献]

- NIST, Artificial Intelligence Risk Management Framework (AI RMF 1.0) (2023 年 1 月)
- OECD, Advancing accountability in AI (2023 年 2 月)

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

8) 教育・リテラシー

各主体は、各主体内の AI に関わる者が、AI に係る正しい理解と社会的に正しい利用ができる知識・リテラシー・倫理感を持つために、必要な教育を行うことが期待される。また、各主体は、AI の複雑性や誤情報といった特性や、意図的な悪用の可能性もあることを勘案して、ステークホルダーに対しても教育を行うことが期待される。

[関連する記載内容]

- 各主体内の AI に関わる者が、その関わりにおいて十分なレベルの AI リテラシーを確保するために必要な措置を講じる
- 生成 AI の活用拡大によって、AI と人間の作業の棲み分けが変わっていくと想定されるため、新たな働き方ができるよう教育・リスキング等を検討する

[具体的な手法]

- リテラシー確保
 - 役割と責任を明確にした AI ポリシーの策定と主体内の AI に関わる者への周知
 - 信頼できる AI の特性についての定義と主体内の AI に関わる者への周知
 - AI システムに適用される法令についての情報収集と主体内の AI に関わる者への周知
 - AI システムから生じる可能性のある潜在的な悪影響の収集と主体内の AI に関わる者への周知
 - AI を含むデータ・デジタル技術が様々な業務で利用されていることの周知
- 教育・リスキング
 - AI リスク管理の技術的及び社会技術的側面に包括的に対応したトレーニングの実施
- 環境変化等へのレジリエンス向上のための教育
 - 「垂直思考」と「水平思考」を柔軟に切り替えるメンタル・ローテーション
 - 組織評価に求められるモデリングスキルの強化
 - アジャイル思考で苦手なスキル領域の学習水平線の延伸
 - 過去の経験やノウハウでは予測が難しい不確実性を分析するための評価スキルの向上
 - 組織評価の「重要ポイント」の変換（機動力のある“瞬発力＋持続力”へ）
 - AI ガバナンスの形態が中央集権型、分散型のハイブリッド化が進む中、複雑、高度化するマネジメントの再同期化（Configuration、Architecture、Synthesis、Dissemination）の評価方法

[参考文献]

- 内閣府「人間中心の AI 社会原則」（2019 年 3 月）
- NIST, AI Risk Management Framework Playbook（2023 年 1 月）
- 経済産業省・（独）情報処理推進機構「デジタルスキル標準 ver.1.1」（2023 年 8 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

10) イノベーション

各主体は、社会全体のイノベーションの促進に貢献するよう、努めることが期待される。

[関連する記載内容]

- 自らの AI システム・サービスと他の AI システム・サービスとの相互接続性と相互運用性を確保する

[具体的な手法]

- データ形式やプロトコル等の標準化
 - AI の入出力等におけるデータ形式（構文（syntax）及び意味（semantics））
 - 連携のための接続方式（特にネットワークを介す場合は各レイヤにおけるプロトコル）
 - 複数の AI モデルの実装、新しいデータセットの活用にあたり、言語が一致していることを確認する。異なる場合、トークン化の方法や語彙の拡張等の調整を検討

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

別添 5.AI 利用者向け

本章では、「本編第 5 部 AI 利用者に関する事項」に記載されている内容について、「ポイント」及び「具体的な手法」を解説する。加えて、「本編第 2 部 AI により目指すべき社会と各主体が取り組むべき事項」の「C. 共通の指針」のうち、AI 利用者が特に意識すべき具体的な手法を解説する。

なお、高度な AI システムを取り扱う AI 利用者は、必要に応じて、「本編第 2 部 AI により目指すべき社会と各主体が取り組むべき事項」の「D. 高度な AI システムに関係する事業者に共通の指針」の記載を参照の上、XII) 及び I) ～ XI) を適切な範囲で遵守すべきである。

A.本編「第 5 部 AI 利用者に関する事項」の解説

[本編の記載内容（再掲）]

- AI システム・サービス利用時

U-2) i. 安全を考慮した適正利用

- ◇ AI 提供者が定めた利用上の留意点を遵守して、AI 提供者が設計において想定した範囲内で AI システム・サービスを利用する（「2）安全性」）
- ◇ 正確・必要な場合には最新性（データが適切であること）等が担保されたデータの入力を行う（「2）安全性」）
- ◇ AI の出力について精度やリスクの程度を理解し、様々なりリスク要因を確認した上で利用する（「2）安全性」）

[ポイント]

AI 利用者は、AI 提供者からの情報提供（AI 開発者の情報を含む）や説明を踏まえ、AI を活用する際の社会的文脈にも配慮して、AI を利用すべきである。

また、アクチュエータ等を通じて稼働する AI の活用において、一定の条件に該当することにより人間による稼働に移行することが予定されている場合には、業務外利用者は、移行前、移行中、移行後等の各状態における責任の所在を予め認識しておくことが期待される。また、AI 提供者から、移行条件、移行方法等についての説明を受け、必要な能力及び知識を習得しておくことが期待される。

AI 利用者は、AI を利用するに当たり、AI 提供者からの情報提供（AI 開発者の情報を含む）を踏まえ、AI の活用により生じうる又は生じた事故、セキュリティ侵害・プライバシー侵害等によりもたらされる又はもたらされた被害の性質・態様等に応じて、関連するステークホルダーと協力して予防措置及び事後対応（情報共有、停止・復旧、原因解明、再発防止措置等）に取り組むことが重要である。

[具体的な手法]

- AI システム・サービスについての情報取得
 - 利用する AI システム・サービスの適正用途・方法
 - AI の性質、利用の態様等に応じた便益及びリスク

- AI の活用の範囲・方法に関する定期的な確認方法（特に、AI が自律的に更新される場合の観測、確認方法）、確認の重要性・頻度、未確認によるリスク等
- 活用の過程を通じて、AI の機能を向上させ、リスクを抑制するために実施する AI システムのアップデート及び AI の点検・修理等
- 適正な範囲・方法での利用
 - AI の性質、利用の態様等に応じた便益及びリスクの認識、適正な用途の理解（利用前）
 - 適正利用のための必要な知識・技能の習得（利用前）
 - 自らの AI の活用が適正な範囲・方法で行われているかについての定期的な確認（利用中）
 - AI システムのアップデート及び AI の点検・修理又はそれらを AI 提供者へ実施を依頼（活用の過程を通じて、AI の機能を向上させ、リスクを抑制することを目的とする）（利用中）
 - ◇ ただし、アップデートにより連携する他の AI に影響を及ぼしうることも考慮する
 - AI 提供者（又は AI 提供者を通じて AI 開発者）に対するインシデント情報のフィードバック（何らかインシデントが発生した場合、インシデントが起こる予兆があった場合を含む）
- ステークホルダー間で協力して行う予防措置及び事後対応
 - 適正な範囲・方法による利用のための情報の提供
 - AI が人間の生命・身体・財産に危害を及ぼした場合に講ずるべき措置の実施
 - セキュリティが侵害された場合に講ずるべき措置の実施
 - 個人のプライバシーを侵害した場合に講ずるべき措置の実施
 - 潜在的利用者を含む社会一般への啓発活動
 - インシデント等の情報の AI 提供者、AI 開発者との迅速な共有と対策検討

[参考文献]

- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）

[本編の記載内容（再掲）]

● AI システム・サービス利用時**U-3) i . 入力データ、プロンプトに含まれるバイアスへの配慮**

- ◇ 著しく公平性を欠くことがないよう公平性が担保されたデータの入力を行い、プロンプトに含まれるバイアスに留意して、責任をもって AI 出力結果の事業利用判断を行う（「3）公平性」）

[ポイント]

AI 利用者は、AI の出力結果について疑義がある場合には、必要に応じて、AI 提供者（又は AI 提供者を通じて AI 開発者）に問い合わせを行うことが期待される。

AI 利用者は、AI の出力が学習時のデータによって決定づけられる可能性があることを踏まえ、AI を活用する際の社会的文脈に応じて、以下のとおり、AI の学習等に用いられるデータの代表性やデータに内在する社会的なバイアス等に留意することが期待される。

AI 利用者は、AI によりなされた判断結果の公平性を保つため、AI を活用する際の社会的文脈や人々の合理的な期待を踏まえ、その判断を用いるか否か、あるいは、どのように用いるか等に関し、人間の判断を介在させることが期待される。

[具体的な手法]

- 各種バイアスによって AI の出力が決定づけられることへの留意
 - データの代表性によるバイアス
 - ◇ データの代表性が確保されないことによってバイアスが生じる可能性がある
 - ◇ 社会的バイアスを内在するデータを用いることによってバイアスが生じる可能性がある
 - ◇ 前処理の方法により利用時の入力データに意図せずバイアスが生じる可能性がある
 - データに含まれる個人情報の扱い
 - ◇ データの代表性を満たすために個人情報を含む大量のデータを集めようとする場合に、特に丁寧に扱う
 - アルゴリズムによるバイアス
 - ◇ アルゴリズム次第でセンシティブ属性（公平性の観点から排除すべき対象者の性別や人種等の個人の属性）によるバイアスが生じる可能性がある
 - センシティブ属性の明確化
 - センシティブ属性に関し確保すべき公平性の内容の明確化
 - 公平性の基準を満たす制約の機械学習アルゴリズムへの付加
- 公平性の基準の確認（「コラム 6：集団公平性と個人公平性」参照）。
 - 集団公平性の基準の確認（以下に基準例を記載）
 - ◇ センシティブ属性を取り除き、非センシティブ属性のみに基づき予測を行う（unawareness）
 - ◇ センシティブ属性の値が異なる複数のグループ間で、同じ予測結果を確保する（demographic parity）

- ◇ 実際の結果に対する予測結果の誤差の比率を、センシティブ属性の値によらないように調整する (equalized odds)
- 個人公平性の基準例の確認 (以下に基準例を記載)
 - ◇ センシティブ属性以外の属性値が等しい個人に対してはそれぞれ同じ予測結果を与える
 - ◇ 類似した属性値を持つ個人には類似した予測結果を与える (Fairness through awareness)

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第4版」(2023年12月)

[本編の記載内容（再掲）]

● AI システム・サービス利用時

U-4) i. 個人情報の不適切入力とプライバシー侵害への対策

- ✧ AI システム・サービスへ個人情報を不適切に入力することがないように注意を払う（「4）プライバシー保護」）
- ✧ AI システム・サービスにおけるプライバシー侵害に関して適宜情報収集し、防止を検討する（「4）プライバシー保護」）

[ポイント]

AI システム・サービスの利用に際しての個人情報の取扱いに関しては、個人情報保護委員会の「生成 AI サービスの利用に関する注意喚起等」等も参照の上、個人情報保護法の規律に従って、個人情報を適正に取り扱うべきである。

プライバシー保護組織を設けることで、社内の新規事業部門との密なコミュニケーションを醸成したり、関連情報を社外有識者等から収集したり、多角的に対応策を検討する等を、実質的に行っていくことができる。技術革新や消費者のプライバシー意識の高まりによって、日々、プライバシー保護の観点で考慮すべき範囲は拡大している。そのため、プライバシー問題に対して、技術革新、消費者の意識等社会の要請に対して多角的な検討・機敏な対応を担保できるようなプライバシー保護組織の構築することが重要となる。加えて、消費者等の個人情報をグローバルに取り扱う場合には、プライバシー保護に対応するために諸外国の法令の適用に関して十分な配慮をすることやグローバルな体制を構築すべきである。

[具体的な手法]

- プライバシー保護組織による対応
 - 企業内の各部門の新規事業やサービス内容に関する様々な情報の集約（プライバシー侵害が消費者や社会に発現するリスクを漏れなく見つけることを目的とする）
 - プライバシー保護責任者を中心とした初動対応やその後の被害救済等の事後対応、原因解析と改善対応（プライバシー侵害が発生した場合）
 - 企業内の各部門との関係構築
 - ✧ 事業部門等から寄せられるプライバシーに関連した相談を幅広く受けるだけでなく、AI システム・サービスを扱う部門に対して能動的に問題意識の共有を働き掛ける等、日ごろから常に接点を持つことが期待される。新規事業や新規技術開発部門が悩みを抱え込まずに、自由に相談できる体制や環境が形成されることが重要である
 - プライバシー保護組織の体制構築（体制のパターン例を以下に記載）
 - ✧ プライバシー保護組織はないが、AI システム・サービスを扱う部門毎に責任者を設定
 - ✧ プライバシー保護組織（兼務）を設置し、AI システム・サービスを扱う部門と連携
 - ✧ プライバシー保護組織（専任）を設置し、AI システム・サービスを扱う部門と連携
- プライバシー侵害時に講ずるべき措置の事前整理及び実施
 - プライバシー侵害時の講ずるべき措置の事前整理

- ◇ 個人のプライバシーを侵害した場合の措置について、AI 提供者から情報提供（AI 開発者からのものを含む）があった場合には、留意の上措置を検討する
- 個人のプライバシー侵害につながりうる情報の消去、AI のアルゴリズムの更新等（個人のプライバシーを侵害につながりうる情報を取得した場合）
- AI 提供者等への個人のプライバシー侵害につながりうる情報の消去の依頼、AI 開発者・AI 提供者等への AI のアルゴリズムの更新の依頼等（個人のプライバシーを侵害につながりうる情報を取得した場合）
- 個人情報を含むプロンプトの入力
 - 例えば、生成 AI サービスの利用に当たって、入力する個人データが生成 AI サービスの提供者において AI の学習データとして利用されることが予定されている場合には、同意を得られていない個人データを含むプロンプトを入力しないよう留意する
 - AI に入力する情報への留意
 - ◇ AI に過度に感情移入すること等により、特に秘匿性の高い情報（自己の情報のみならず他者の情報を含む）をむやみに AI に与えないようにする
 - プライバシーの尊重
 - ◇ 自らデータを収集して、利用する AI の学習等を行う場合には、収集等において個人のプライバシーを尊重する

[参考文献]

- 個人情報保護委員会「生成 AI サービスの利用に関する注意喚起等」（2023 年 6 月）
- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）

[本編の記載内容（再掲）]

● AI システム・サービス利用時**U-5) i. セキュリティ対策の実施**

◇ AI 提供者によるセキュリティ上の留意点を遵守する（「5）セキュリティ確保」）

[ポイント]

AI 利用者は、セキュリティが侵害された場合に講ずるべき措置について、AI 提供者から情報提供（AI 開発者の情報も含む）があった場合には、利用にあたり留意することが望ましい。また、AI を利用するにあたり、セキュリティ上の疑問を感じた場合は、AI 提供者（又は AI 提供者を通じて AI 開発者）等にその旨を報告することが期待される。

AI 利用者は、（業務外利用者側で）セキュリティ対策を実施することが想定されている場合には、AI 提供者からの情報提供（AI 開発者の情報も含む）を踏まえ、AI システムのセキュリティに留意し、必要な対策を講ずることが期待される。

[具体的な手法]

- 脆弱性に関するリスクの認識
 - 学習が不十分であること等の結果、AI モデルが正確に判断することができるデータに、人間には判別できない程度の微少な変動を加え、そのデータを入力すること等により、作為的に AI モデルが誤動作するリスク（例：Adversarial example 攻撃）
 - 教師あり学習において不正確なラベリング等がなされたデータを混在させることで、誤った学習が行われるリスク
 - AI モデルが容易に複製されるリスク
 - AI モデルから学習に用いられたデータをリバースエンジニアリングされるリスク
- セキュリティ侵害対策の検討
 - 初動措置
 - ◇ AI システムのロールバック、代替システムの利用等による復旧
 - ◇ AI システムの停止（キルスイッチ）
 - ◇ ネットワークからの遮断
 - ◇ セキュリティ侵害の内容の確認
 - ◇ 関連するステークホルダーへの報告
 - 補償・賠償等を円滑に行うための保険の利用
 - 第三者機関の設置とその機関による原因調査・分析・提言

[参考文献]

- 独立行政法人情報処理推進機構「セキュリティ・バイ・デザイン導入指南書」（2022 年 8 月）
- 独立行政法人情報処理推進機構「セキュリティ関係者のための AI ハンドブック」（2022 年 6 月）

[本編の記載内容（再掲）]

● AI システム・サービス利用時**U-6) i . 関連するステークホルダーへの情報提供**

- ◇ 著しく公平性を欠くことがないよう公平性が担保されたデータの入力を行い、プロンプトに含まれるバイアスに留意して AI システム・サービスから出力結果を取得し、結果を事業判断に活用した際は、その結果が必要な関連するステークホルダーに周知する（「3）公平性」、「6）透明性」）

[ポイント]

AI 利用者は、個人の権利・利益に重大な影響を及ぼす可能性のある分野において AI を利用する場合等、AI を活用する際の社会的文脈を踏まえ、業務外利用者の納得感や安心感の獲得、また、そのための AI の動作に対する証拠（AI システムが、予測、推奨、又は決定の基礎となる要因と意思決定プロセスに関する平明で理解しやすい情報）の提示等を目的として、AI の出力結果の説明可能性を確保することが期待される。その際、個人の信頼を構築し維持するためにどのような説明が求められるかを分析・把握し、必要な対応を講じることにより、AI の出力結果の説明可能性を向上することが期待される。

[具体的な手法]

- 関連するステークホルダーへの情報提供
 - 説明対象の明確化
 - ◇ AI 提供者が不開示とする範囲を限定した形（AI 開発者が設定するものを含む）での AI 提供者と契約の締結等を通じて、不開示範囲の明確化を行う
 - AI システム・サービスの導入前の説明方法及び説明自体のテスト
 - 説明に関するフィードバックの取得
 - ◇ 業務外利用者を含むステークホルダーや、影響を受ける可能性のある個人やグループから、説明の正確性、明確性等のフィードバックを取得する
 - AI モデルについての情報提供
 - ◇ インプットデータの種類とソース、ハイレベルのデータ変換プロセス、意思決定の基準と根拠、リスクとその緩和策等の情報提供を含める
 - 情報提供に際しての留意点
 - ◇ 業務外利用者が必要な情報を適切なタイミングで共有する
 - ◇ AI システム・サービスについて提供すべき情報を利用前に提供する
 - ◇ AI システム・サービスの利用前に上記の情報を提供できない場合には、AI の性質、利用の態様等に基づき想定されるリスクに応じ、業務外利用者からのフィードバックに対応する体制を整備する

[参考文献]

- NIST, Artificial Intelligence Risk Management Framework（AI RMF 1.0）（2023 年 1 月）
- OECD, Advancing accountability in AI（2023 年 2 月）

[本編の記載内容（再掲）]**● AI システム・サービス利用時****U-7) i .関連するステークホルダーへの説明**

- ✧ 関連するステークホルダーの性質に応じて害のない範囲で、適正な利用方法を含む情報提供を平易かつアクセスしやすい形で行う（「7）アカウントビリティ」）
- ✧ 関連するステークホルダーから提供されるデータを用いることが予定されている場合には、AI の特性や用途、業務外利用者との接点、プライバシーポリシー等を踏まえ、データ提供の手段、形式等について、あらかじめ当該ステークホルダーに情報提供する（「7）アカウントビリティ」）
- ✧ 当該 AI の出力結果を特定の個人又は集団に対する評価の基礎とする場合には、AI を利用している旨を評価対象となっている当該特定の個人又は集団に対して通知し、必要に応じて合理的な範囲で人間による判断を求める機会を設ける（「1）人間中心」）
- ✧ 利用する AI システム・サービスの性質に応じて、関連するステークホルダーからの問合せに対応する窓口を設置し、AI 提供者とも連携の上説明や要望の受付を行う（「7）アカウントビリティ」）

U-7) ii . 提供された文書の活用と規約の遵守

- ✧ AI 提供者から提供された AI システム・サービスについての文書を適切に保管・活用する（「7）アカウントビリティ」）
- ✧ AI 提供者が定めたサービス規約を遵守する（「7）アカウントビリティ」）

[ポイント]

AI 利用者は、業務外利用者が AI の活用について適切に認識できるよう、AI に関する利用方針を作成・公表し、通知を行うことが期待される。

[具体的な手法]

- 以下の事項を盛り込んだ AI に関する利用方針の開示
 - AI を利用している旨（具体的な機能・技術を特定できるのであれば、その名称と内容等）
 - 活用の範囲及び方法
 - AI の出力の根拠
 - 活用に伴うリスク
 - 相談窓口
 - 利用方針の開示・通知時の留意点
 - ✧ AI の出力が直接に業務外利用者や第三者に対して影響を及ぼす態様により AI を活用する場合には、業務外利用者や第三者が AI の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・開示し、問い合わせがあった場合には通知を行う
 - ✧ 業務外利用者や第三者の権利・利益に重大な影響を及ぼす可能性のある場合には積極的に通知を行う。（AI 提供者及び AI 利用者が、AI に関する利用方針を公表することが求められるのは、利用する AI の出力が、業務外利用者や第三者に直接の影響を及ぼす場合である

と考えられる。すなわち、人間の思考に供するための分析道具として AI を活用するにとどまる場合や、AI が原案を作成しつつも、最終的に人間が判断することが実質的に担保されている場合には、AI に関する利用方針の公表が必ずしも求められるわけではない。（ただし、自主的に公表されることが期待される）

- ☆ 通知又は公表は、利用開始前だけではなく、AI の動作に変更が生じたときや利用終了時も含め（特に AI の動作変更に伴い想定されるリスクに変更が生じる場合等）実施することが期待される
- ☆ 詐欺的行為の検出のための AI の活用の場合や、悪用のリスクが懸念される場合は、開示・通知の可否・内容・方法を検討の上、実施を判断する

[参考文献]

- NIST, Artificial Intelligence Risk Management Framework (AI RMF 1.0) (2023 年 1 月)
- The White House, "Blueprint for an AI Bill of Rights (Making Automated Systems Work for The American People) " (2022 年 10 月)

B.本編「第 2 部」の「共通の指針」の解説

ここでは、「第 5 部 AI 利用者に関する事項」では触れられていないが、「第 2 部」の「共通の指針」のうち、AI 利用者にとって特に重要なものについて、具体的な手法を解説する

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

1) 人間中心

各主体は、AI システム・サービスの開発・提供・利用において、後述する各事項を含む全ての取り組むべき事項が導出される土台として、少なくとも憲法が保障する又は国際的に認められた人権を侵すことがないようにすべきである。また、AI が人々の能力を拡張し、多様な人々の多様な幸せ（well-being）の追求が可能となるよう行動することが重要である。

- 「④多様性・包摂性の確保」関連

[関連する記載内容]

- 公平性の確保に加え、いわゆる「情報弱者」や「技術弱者」を生じさせず、より多くの人々が AI の恩恵を享受できるよう社会的弱者による AI の活用を容易にするよう注意を払う

[具体的な手法]

- 誰一人取り残さない AI 活用への心がけ
 - ◇ AI リテラシーの向上
 - ◇ デジタル・AI 人材の確保・育成
- 安全安心な利用環境の整備

[参考文献]

- 総務省「令和 3 年版 情報通信白書」（2021 年 7 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

2) 安全性

各主体は、AI システム・サービスの開発・提供・利用を通じ、AI に関わる全ての者の生命・心身・財産、及び環境に危害を及ぼすことがないようにすることが重要である。

● 「①人間の生命・心身・財産、及び環境への配慮」関連

[関連する記載内容]

- AI システム・サービスの安全性を損なう事態が生じた場合の対処方法を検討し、当該事態が生じた場合に速やかに実施できるよう整える

[具体的な手法]

- インシデント対策の整理と発生時の措置の検討
 - ◇ インシデント対策の整理
 - 危害発生時の連絡体制の事前整備
 - 原因調査方法や復旧作業方法の整理
 - 再発防止策の検討・対応方針の整理
 - インシデントに関する情報共有方法の設定
 - ◇ 初動措置
 - AI システムのロールバック、代替システムの利用等による復旧
 - AI システムの停止（キルスイッチ）
 - ネットワークからの遮断
 - 危害の内容の確認
 - 関連するステークホルダーへの報告
 - ◇ 補償・賠償等を円滑に行うための保険の利用
 - ◇ 第三者機関の設置とその機関による原因調査・分析・提言

[参考文献]

- 総務省、経済産業省「DX 時代における企業のプライバシーガバナンスガイドブック ver1.3」（2023 年 4 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

3) 公平性

各主体は、AI システム・サービスの開発・提供・利用において、特定の個人ないし集団へのその人種、性別、国籍、年齢、政治的信念、宗教等の多様な背景を理由とした有害な偏見や差別を排除することが重要である。また、各主体は、潜在的なバイアスを最小化するよう留意し、それでも回避できないバイアスがあることを認識しつつ、この回避できないバイアスが人権や多様な文化を尊重する観点から許容可能か評価をした上で、AI システム・サービスの開発・提供・利用を行うことが重要である。

● 「②人間の判断の介在」関連

[関連する記載内容]

- AI の出力結果が公平性を欠くことがないよう、AI に単独で判断させるだけでなく人間の判断を介在させる利用を検討する

[具体的な手法]

- 人間の判断の介在要否に関する判断と実効性の確保
 - ◇ 人間の判断の介在要否に関する判断（以下に判断基準の例を記載）
 - AI の出力に影響を受ける業務外利用者の権利・利益の性質及び業務外利用者の意向
 - AI の出力の信頼性の程度（人間による判断の信頼性との優劣）
 - 人間の判断に必要な時間的猶予
 - 判断を行う AI 利用者に期待される能力
 - 判断対象の要保護性（例えば、人間による個別申請への対応か、AI システム・サービスによる大量申請への対応か等）
 - 統計的な将来予測の不確定性
 - 意思決定（判断）に対し納得ある理由の必要性和程度
 - 学習データにマイノリティ等に対する社会的バイアスが含まれていること等により、人種・信条・性別に基づく差別の想定度合い
- 人間の判断の実効性の確保
 - ◇ 説明可能性を有する AI から得られる説明を前提として、人間が判断すべき項目を事前に明確化しておく（AI の出力に対し、人間が最終判断をすることが適当とされている場合）
 - ◇ 適切に判断ができるよう必要な能力及び知識を習得する（AI の出力に対し、人間が最終判断をすることが適当とされている場合）
 - ◇ 人間の判断の実効性を確保するための対応を事前に整理しておく

[参考文献]

- 国立研究開発法人産業技術総合研究所「機械学習品質マネジメントガイドライン 第 4 版」（2023 年 12 月）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

8) 教育・リテラシー

各主体は、各主体内の AI に関わる者が、AI に係る正しい理解と社会的に正しい利用ができる知識・リテラシー・倫理感を持つために、必要な教育を行うことが期待される。また、各主体は、AI の複雑性や誤情報といった特性や、意図的な悪用の可能性もあることを勘案して、ステークホルダーに対しても教育を行うことが期待される。

[関連する記載内容]

- 各主体内の AI に関わる者が、その関わりにおいて十分なレベルの AI リテラシーを確保するために必要な措置を講じる
- 生成 AI の活用拡大によって、AI と人間の作業の棲み分けが変わっていくと想定されるため、新たな働き方ができるよう教育・リスキリング等を検討する

[具体的な手法]

- AI を活用するためのリテラシー教育やスキルとして含めるべき事項
 - AI、数理やデータサイエンスに係る知識
 - データにバイアスが含まれることや使い方によってはバイアスを生じさせる可能性があること等の AI やデータの特性への理解
 - AI やデータの持つ公平性やプライバシー保護に関わる課題があることを認識できるような、セキュリティや AI 技術の限界に関する内容への理解
 - AI を含むデータ・デジタル技術が様々な業務で利用されていることの理解
 - AI を「問いを立てる」「仮説を立てる・検証する」等のスキルと掛け合わせることで、生産性向上等への適切な利用
- 環境変化等へのレジリエンス向上のための教育
 - 「垂直思考」と「水平思考」を柔軟に切り替えるメンタル・ローテーション
 - 組織評価に求められるモデリングスキルの強化
 - アジャイル思考で苦手なスキル領域の学習水平性の延伸
 - 過去の経験やノウハウでは予測が難しい不確実性を分析するための評価スキルの向上
 - 組織評価の「重要ポイント」の変換（機動力のある“瞬発力＋持続力”へ）
 - AI ガバナンスの形態が中央集権型、分散型のハイブリッド化が進む中、複雑、高度化するマネジメントの再同期化（Configuration、Architecture、Synthesis、Dissemination）の評価方法

[参考文献]

- 内閣府「人間中心の AI 社会原則」（2019 年 3 月）
- 経済産業省・（独）情報処理推進機構「デジタルスキル標準 ver.1.1」（2023 年 8 月）

別添 6.「AI・データの利用に関する契約ガイドライン」を参照する際の主な留意事項について

本編第 2 部でも説明したとおり、AI の開発・提供・利用には、それぞれの場面で複数の主体が関連する。そのため、AI の開発・提供・利用に関する各取引について、当事者間の権利と義務をできる限り明確に契約に定め、万が一紛争が生じた際の解決の指針を備えておくことが、それぞれの取引を円滑に進め、またこれらに伴う無用の紛争を予防するためにも期待される。

2018 年 6 月に初版が策定・公表された「AI・データの利用に関する契約ガイドライン⁷³」（2019 年 12 月に内容を一部更新した 1.1 版が公表。以下、「契約ガイドライン」という。）は、当時の課題を背景に、AI を利用したソフトウェアの開発・利用に関する契約やデータの提供/利用に関する契約、またこれらの契約の前提としてあらかじめ理解しておくべき事項等について、基本的な考え方を整理したものである。

契約ガイドラインが策定されたのは、AI の開発がこれから進み、実用化に向かう流れの中であり、AI の開発と活用を促すガイドラインの目的の下、これを通じて解決すべき課題として以下のものが挙げられていた。

- AI やデータの提供/利用に関する契約について、実務の蓄積が乏しいこと
- AI の技術的な特性や、データや AI の開発ノウハウの価値等について、当事者の間に認識・理解のギャップがあること

また、契約ガイドラインの策定時には、AI を活用したソフトウェアを開発する者と、その開発の成果を利用する者との間で行われる取引を円滑にすることで AI の開発や実用化を促すという狙いの下、そうした取引の障害となるものを取り除くことに問題意識が置かれていた。

契約ガイドラインの初版の策定・公表から既に 5 年が経過したが、その間の AI の開発や利用に関する状況の進展は目覚ましく、新たな技術や利用の方法が日々生み出されており、また、AI に関連する多くの技術が社会への普及に向かうフェーズに入っている。こうした経緯により、契約ガイドラインには、参照することが変わらず有益である内容と、公表後の状況の変化を考慮すべき内容とがあることに留意することが重要となる。

一例として、契約ガイドラインの記述のうち、主として AI 編第 2（AI 技術の解説）・第 3（基本的な考え方）とデータ編第 3（データ契約を検討するにあたっての法的な基礎知識）で言及されている以下の内容については、従前と同様に参照することが一般に有益な場合もあると思われる。

（AI 編）

- AI を利用したソフトウェア開発の特徴と AI の特性
- 知的財産権等に関する整理
- 権利の帰属や利用条件の設定に関する基本的な視点

⁷³ 経済産業省「AI・データの利用に関する契約ガイドライン 1.1 版」（2019 年 12 月）

<https://warp.da.ndl.go.jp/info:ndljp/pid/12685722/www.meti.go.jp/press/2019/12/20191209001/20191209001-1.pdf>

- 責任の分配に関する基本的な視点

(データ編)

- データの法的性質やデータに対する保護手段

また、契約ガイドラインで扱われている各種契約モデルについても、その解説を参照することは変わらず有益であると考えられるが、AI の開発・提供・利用に関する取引は、契約ガイドラインの策定時と比べて多様化しており、各種契約モデルと実際に行われる取引との差分については慎重に検討される必要がある。

他方、契約ガイドラインを参照する際には、公表後の状況の変化を考慮すべき事項として、特に以下の点に留意することが重要である。

(1) AI の開発と利用の概念について

契約ガイドラインでは、AI の開発を行う者（ベンダ）と AI を利用する者（ユーザ）の二分論を前提に、①ユーザが AI の開発をベンダに委託する取引と、②ベンダが開発した AI をユーザに利用させる取引の各類型について、開発契約と利用契約という二つのモデル契約を提供し、その解説を行っている。

AI の開発や利用に関する取引には、現在においても、こうした整理がそのまま当てはまるものも変わらず存在する場合もあると思われる。しかし、昨今、AI の開発から実用化へ、普及から応用へと向かう流れの中で、社会の関心は、どのような技術を開発するかから、技術をどのように利用するかへと、その比重を移してきており、契約ガイドラインが整理した類型に収まらない取引の重要性が増してきている。

(取引の例)

- AI を組み込んだソフトウェアの開発に関する取引
- AI の保守や運用に関する取引
- 特定の目的のための AI の最適化に関する取引
- AI やデータの活用に関するコンサルティングを中心とする取引

契約ガイドラインのモデル契約は、こうした取引との関係でそのまま用いることはできず、それぞれの取引の実態に即した検討を行う必要がある。例えば、AI の開発を行う者と、開発成果の保守運用を行う者とが異なる場合、AI の開発のノウハウを守ることと、開発成果の保守運用を実施することとが、トレードオフの関係に立つことがありうる。こうした事態への対処については、関連する限りで契約ガイドラインの記述を参照しながらも、実態に沿った解決策を見出していく必要がある。

(2) AI の開発・提供・利用と責任の分配について

契約ガイドラインでは、①ユーザが AI の開発をベンダに委託する取引と、②ベンダが開発した AI をユーザに利用させる取引のいずれの類型においても、ベンダとユーザの二者間で調整が可能なシンプルな利害関係モデルを

念頭に、ベンダとユーザの法律関係、特に成果の帰属や利用関係、当事者の損害や第三者の知的財産権等の権利侵害のリスクの負担等に関する考え方を整理することに記述が割かれている。

しかし、近時では、以下のような様々な事業者が AI の開発・提供・利用に関与するようになっており、AI のバリューチェーンは、契約ガイドラインの策定時と比べ、明らかに多様化ないし複雑化している。また、AI の普及が進んだことにより業務外利用者の存在を意識せざるを得なくなり、これらの結果、ベンダとユーザの二者間の関係に注目するだけでは十分に捉えることができない問題も生じてきている。

(事業者の例)

- AI を開発する事業者
- 開発された AI を組み込んだソフトウェアを開発する事業者
- そのソフトウェアを外部に提供する事業者
- 提供されたソフトウェアを利用したサービスを外部に提供する事業者
- そのサービスを利用する事業者

AI のバリューチェーン上で責任をどのように分配すべきかは、そうした問題の一つである。例えば、AI を組み込んだソフトウェアを利用したサービスが業務外利用者に提供されるケースでは、AI に起因する損害がエンドユーザに発生するリスクを引き受けるべきなのは誰かが問題となりうる。そうしたリスクの内容や程度は、AI の質だけではなく、ソフトウェアの提供方法や、サービスの提供や利用のあり方にも大きく影響を受けるのであり、ベンダとユーザという二者間の関係を超えて、バリューチェーンにおける各当事者の役割に目を向けるのであれば、その責任範囲に合理的な境界を設けることは難しい場合もありうる。

この境界の合理性との関係では、リスクを直接コントロールできない当事者によるリスクの引き受けという問題もある。上述のケースを例にとると、仮に、その提供や利用の方法にかかわらず、AI に起因する損害に対する責任の一切を AI 開発者が負うとすれば、自身では直接コントロールできないリスクも AI 開発者が引き受けることになる。このような事態は、交渉力に格差のある当事者間で起こりやすい一方で、影響力の大きい AI であれば、その AI 開発者がコントロールすべきリスクの範囲を広く捉えるべき場合もある。

契約ガイドラインでは、ベンダとユーザの二者間の取引に焦点を当てており、このように多様化ないし複雑化したバリューチェーンを前提とした責任分配のあり方については、個別の状況に応じて具体的に検討を行う必要がある。この点については、「別添 2.」における実践例も参考になると思われる。

(3) AI の開発・提供・利用とアカウントビリティについて

AI の普及や応用が進むにつれ、AI の開発・提供・利用に伴うリスクが増えるとともに、そうしたリスクが顕在化するケースも今後増えていくことが予想される。

そうしたリスクの中に、AI を組み込んだソフトウェアや、これを利用したサービスに関連して何らかの事故が起こり、それにより AI の開発・提供・利用の当事者や第三者に損害を生じさせるリスクがある。このケースで問題とな

るのは、事故を回避するために尽くすべき注意を尽くしていたかや、事故がそもそも AI に起因していたかの証明に関する問題がある。AI の開発・提供・利用の当事者には、それぞれのプロセスにどのような関与を行ったかについて、合理的な説明を行うことが求められる可能性がある。

こうした説明に対する責任は、AI の開発・提供・利用のすべての当事者の間でどのような契約が締結されていたとしても、事故について一次的な責任を負う当事者に発生する可能性があるものである。契約で定めることができるのは、契約の当事者限りでの責任の分担に限定される。契約の当事者以外の者により責任追及をされた場合に、AI のバリューチェーンに連なる者はすべて、一定の説明を求められる立場に将来立つ可能性がある。

説明の合理性との関係で問題となるのは、説明の内容に加えてその客観的な根拠であり、AI の開発・提供・利用に関する契約を締結の前後で、そうした根拠を整理しておくことは期待される。契約ガイドラインでは触れていないが、別添 2. の実践例を参照の上、契約締結後の対応を検討することは有益である。

なお、AI に関する技術の進展や普及は目覚ましく、新たな技術や利用方法が日々生み出されており、それに伴い、契約において留意すべき点も変化している。契約を考える上で重要なことは、AI の開発・提供・利用のそれぞれの取引の実態に即した契約のあり方やリスクの検討を行うことであり、上述の留意事項も踏まえ、「AI・データの利用に関する契約ガイドライン」を参照されたい。

チェックリスト素案 (全主体向け/AIガバナンスの構築)

利用上の留意点

ガイドラインに記載した内容に関して取り組むべき事項は、**各事業者の事業内容や置かれた状況等により、個々に異なります。**
このため、本チェックリストは、**あくまで各事業者が取り組むべき事項が何かを検討する際の材料をご提供するもの**であり、**各事業者それぞれの状況に応じ、カスタマイズして必要に応じて活用いただくこと**を前提としたものです。
したがって、必ずしも、全ての事項について、検討が必要となるものではありませんので、**活用の要否、各自の事情に応じた修正や取捨選択を検討ください。**
D列～F列の記載内容を基に、**G列以降を各事業者にてご検討いただき、各自が取り組むべきこと（あるいは内容）を具体化の上、活用ください。**
チェックリストを各自用カスタマイズし運用するには、A. チェックリストを作成する者（当該チェックリストを基に、各自のチェックリストのカスタマイズを行う者）、B. チェックを行う者（現場において実際のチェックを行う者）、C. 責任者（チェック内容に対して責任を負う者）を特定ください（各主体の規模によって、A.～C.が重複する場合もある）。

- A. チェックリストを作成する者
- B. チェックを行う者
- C. 責任者

	分類	確認事項 （ガイドライン「本編」を基に記載）	対応箇所	各自の事業に関連する事項 （該当しない場合はその理由）	他の主体との関係についての事項	✓	具体的な取組内容	最終検討日 (見直し日)
1. 環境・リスク分析	1-1	便益/リスクの理解	a. 事業における価値の創出や社会課題の解決等のAIの開発・提供・利用の目的を明確に定義したか？ b. 自社の事業に結びつくかたちで、「便益」や、意図せざるものを含めた「リスク」の性質を具体的に理解したか？ c. その際に、回避すべき「リスク」や、複数主体にまたがる論点に留意し、バリューチェーン/リスクチェーン全体での便益を確保、リスクを削減したか？ d. 迅速に「経営層に報告/共有する」仕組みを構築したか？	別添2.				
	1-2	AIの社会的な受容の理解	a. 潜在的なステークホルダーも含めたステークホルダーを特定したか？ b. 特定した上で、「社会的な受容」の理解に努め、AIを開発・提供・利用したか？ c. 提供開始後も、急速に変化する外部環境を考慮し、必要に応じて適時にステークホルダーの意見を再確認したか？	別添2.				
	1-3	自社の習熟度の理解	a. 各主体の事業領域や規模等に照らして「AI習熟度」の評価の必要性を検討したか？ b. 必要であると判断した場合、AIのリスクへの対応力を見る化し、AI習熟度（AIシステム・サービスの開発・提供・利用時に求められる準備がどれだけできているのか）を評価したか？ c. 必要ではないと判断した場合、その理由を整理したか？	別添2.				
2. ゴール設定	2-1	AIガバナンス・ゴールの設定	a. 各主体の「AIガバナンス・ゴール」を設定するかを検討したか？ b. 必要であると判断した場合、設定したゴールをステークホルダーに対して公開したか？ c. 必要ではないと判断した場合、その理由を整理したか？	別添2.				
3. システムデザイン	3-1	ゴールと乖離の評価、及び乖離対応の必須化	a. 現状のAIシステム・サービスと「AIガバナンス・ゴール」からの乖離を特定・評価したか？ b. リスクが認められる場合、その受容の合理性の有無を判定したか？ c. 受容に合理性が認められない場合、開発・提供・利用の在り方を再考/再考するためのプロセスを開発・提供・利用の適切な段階へ組み込んだか？ d. 上記を経営層がリーダーシップを取って、その意思決定に責任を持ち、運営層が具体化した上で、継続的に実施したか？ e. 各主体内での認識の醸成を行うため、決定した乖離評価項目を各主体内で共有したか？提供するAIの内容に応じて、各主体間で連携をして乖離評価を実施したか？	別添2.				
	3-1-1	業界の標準的な乖離評価プロセスとの整合性の確保	a. 自社の知見・経験に留まらず、業界における標準的な乖離評価プロセスや他社・団体の取り組み等、外部のベストプラクティスを積極的に取り込んだか？	別添2.				
	3-1-2	利用者に対する、乖離可能性/対応策に関する十分な情報提供	a. AIシステム・サービスと「AIガバナンス・ゴール」との間に乖離が発生しうる場合は、ステークホルダーにその事実や対応策に関し情報提供をし、問い合わせへの対応等を通じたコミュニケーションを図ったか？ b. 情報提供の効果を高めるために、開発主体や業界団体等とも連携しながら、様々な情報発信を通じて、AI利用者及び利害関係者等のリテラシーの向上にも貢献しているか？ c. 乖離によって生じるリスクの性質や蓋然性の大きさに応じて、情報提供の程度を検討したか？	別添2.				
	3-2	AIマネジメントシステムの人材リテラシー向上	a. 外部講師によるものを含め、役職や担当に適した研修や教材を用い、AIリテラシーを向上させるような取組を行ったか？ b. その際、各者の果たすべき役割に応じて適した研修や教材を活用したか？ c. 特に重要となるAI倫理については全社員に受講させる等の工夫をしたか？ d. 今般の生成AIに関する動向等を踏まえ、生成AI技術や、出力結果の信頼性に関する研修を行う等の工夫をしたか？ e. 行動目標5-1のAIマネジメントシステムの設計や運用から独立した関連する専門性を有する者による評価を自社で行う場合に、そのような専門性を社員が習得できるような配慮をしたか？	別添2.				
	3-3	各主体間・部門間の協力によるAIマネジメント強化	以下、各種法令・規制や各主体のAIポリシー、営業秘密や限定提供データ等、公正競争確保が前提である。 a. 各主体のみでは解決できないAIシステム・サービスの運用上の課題や解決に必要な情報を特定したか？ b. 各主体間で、知的財産権やプライバシー等に留意しつつ、可能な範囲で共有したか？	別添2.				
	3-3-1	各主体間の情報共有による現状理解	a. AIシステムの開発に用いたデータの取得源/データの量・質や分布、カテゴリ毎の概要等の情報を共有したか？ b. 共有の際、産業技術総合研究所の「機械学習品質マネジメントガイドライン」等の情報共有の標準化に向けた取り組みを参照したか？	別添2.				
	3-3-2	環境・リスク分析のための日常的な情報収集・意見交換の奨励	a. 日常的な、ルール整備、ベストプラクティス、インシデント等の情報収集を行っているか？ b. AIマネジメントチームを社内を設置している場合であっても、社内の他部門との議論や勉強会を開催したり、他社も参加する団体活動に関与しているか？	別添2.				
	3-4	予防・早期対応による利用者のインシデント関連の負担軽減	a. システム障害、情報漏洩、クレームの発生等のインシデントの予防と早期対応を行ったか？ b. ライフサイクル全体を通じてインシデントを予防し、又は発生した場合に早期に対応できる体制を構築したか？	別添2.				
	3-4-1	各主体間の不確実性への対応負担の分配	a. そもそもAIシステム・サービスの不確実性については、技術的に一定の対応は可能ではあるものの、完全に取り除くことが難しいという前提を認識共有を実施したか？ b. その上で、各主体間での責任所在を可能な範囲で明確化したか？	別添2.				

	3-4-2	インシデント発生時の対応の事前検討	a. AIインシデント発生時の対応方針や計画を策定したか？ b. 上記について、適宜実践的な予行演習を実施しているか？ c. インシデント発生時に備え、下記のような体制をあらかじめ整備したか？ ・連絡受付窓口の設置 ・対応担当役員のアサイン ・対応担当者個々の役割分担 ・対応アプローチ・プロセス ・リスク管理部門等の社内関係者への連絡体制 ・顧問弁護士等の社外関係者や専門家への連絡体制 ・影響を受けるステークホルダーに対して通知するプロセス等	別添2.
4. 運用	4-1	AIマネジメントシステム運用状況の説明可能な状態の確保	a. 適切かつ合理的な範囲で、AIマネジメントシステムの運用状況について外部ステークホルダーに対して説明可能な状況にしたか？ b. AIマネジメントシステムの運用状況のアカウンタビリティを高めるため、下記のような取組を行ったか？ ・行動目標3-1の乖離評価プロセスの実施状況の記録 ・AIシステム・サービス開発・提供・利用に関する社内/外部との会議記録の保持(担当者以外の関係者も閲覧可能な状態を確保) ・AIに関する社内研修の実施 c. 乖離評価プロセスの実施状況の記録については、独自に乖離評価のためのチェックリストを作成し、それを基に確認・記録したか？検討にあたっては当チェックリストを参照し、カスタマイズすることもある有用である。	別添2.
	4-2	個々のAIシステム運用状況の説明可能な状態の確保	a. 各主体のAIの運用の状況をモニタリングし、PDCAを回しながら、結果を記録したか？ b. 各主体が単独で対応することが難しい場合には、各主体間で連携したか？	別添2.
	4-3	AIガバナンスの実践状況の積極的な開示の検討	a. 自社のAIに対する基本的な考え方から、AIマネジメントシステムの整備・運用等まで、AIガバナンスに関する情報の透明性の確保を検討したか？ b. 開示する場合には、コーポレートガバナンス・コードの非財務情報に位置づけること等も検討したか？ c. 開示しない場合には、その事実をその理由とともにステークホルダーに公開したか？	別添2.
5. 評価	5-1	AIマネジメントシステムの機能の検証	a. 継続的改善に向けた評価の重点ポイントを、経営層が自らの言葉で明示したか？ b. AIマネジメントシステムの設計や運用から独立した関連する専門性を有する者を割り当てたか？ c. 上記の者によるAIマネジメントシステムが適切に機能しているか否かのモニタリングを行ったか？ d. モニタリングの結果を基に、継続的な改善を実施したか？	別添2.
	5-2	社外ステークホルダーの意見の検討	a. 様々なステークホルダーから、AIマネジメントシステムやその運用に対する意見を求めることを検討したか？ b. 当該意見の内容実施しない場合、その理由をステークホルダーに説明したか？	別添2.
6. 環境・リスクの再分析	6-1	1-1～1-3の適時の再実施	a. 新技術の出現、AIに関連した技術革新、規制等の社会的制度の変更等の外部環境の変化を把握するしたか？ b. 適時に再評価、理解の更新、新たな視点の獲得等を行い、それに即したAIシステムの改善、再構築、運用の変更等を行ったか？ c. AIガバナンスの考え方を組織の文化として根付かせているか？	別添2.

チェックリスト素案（事業者向け）

利用上の留意点

ガイドラインに記載した内容に関して取り組むべき事項は、**各事業者の事業内容や置かれた状況等により、個々に異なります。**
このため、本チェックリストは、**あくまで各事業者が取り組むべき事項が何かを検討する際の材料をご提供するもの**であり、**各事業者それぞれの状況に応じ、カスタマイズして必要に応じて活用いただくこと**を前提としたものです。
したがって、必ずしも、全ての事項について、検討が必要となるものではございませんので、**活用の要否、各自の事情に応じた修正や取捨選択を検討ください。**
D列～F列の記載内容を基に、**G列以降を各事業者にてご検討いただき、各自が取り組むべきこと（あるいは内容）を具体化の上、活用ください。**
チェックリストを各自用にカスタマイズし運用するには、A. チェックリストを作成する者（当該チェックリストを基に、各自のチェックリストのカスタマイズを行う者）、B. チェックを行う者（現場において実際のチェックを行う者）、C. 責任者（チェック内容に対して責任を負う者）を特定ください（各主体の規模によって、A.～C.が重複する場合もある）。

A. チェックリストを作成する者	
B. チェックを行う者	
C. 責任者	

分類	確認事項 （ガイドライン「本編」を基に記載）	対応箇所	各自の事業に関連する事項 （該当しない場合はその理由）	他の主体 との関係についての事項	✓	具体的な取組内容	最終検討日 （見直し日）
	1) 人間の尊厳と個人の自律 ①	a.AIが活用される際の社会的文脈を踏まえ、人間の尊厳と個人の自律を尊重しているか？ b.特に、AIを人間の脳・身体と連携させる場合には、その周辺技術に関する情報を踏まえつつ、諸外国や研究機関における生命倫理の議論等を参照しているか？ c.個人の権利・利益に重要な影響を及ぼす可能性のある分野においてAIを利用したプロファイリングを行う場合、個人の尊厳を尊重し、生じうる不利益等を慎重に検討した上で、不適切な目的に利用していないか？	1) 人間中心				
	1) AIによる意思決定・感情の操作等への留意 ②	a.人間の意思決定や認知等、感情を不当に操作することを目的とした、もしくは操作を前提としたAIシステム・サービスの開発・提供・利用は行っていないか？ b.AIシステム・サービスの開発・提供・利用において、自動化バイアス 等のAIに過度に依存するリスクに対して、必要な対策を講じているか？ c.フィルターバブル に代表されるような情報や価値観の傾斜を助長し、AI利用者を含む人間が本来得られるべき選択肢が不本意に制限されるようなAIの活用にも注意を払っているか？ d.特に、選挙やコミュニティでの意思決定等をはじめとする社会に重大な影響を与える手続きに関連しうる場合においては AIの出力について慎重に検討しているか？	1) 人間中心				
	1) 偽情報等への対策 ③	生成AIによって、内容が真実・公平であるかのように装った情報を誰でも作ることができるようになり、AIが生成した偽情報・誤情報・偏向情報が社会を不安定化・混乱させるリスクが高まっていることを認識した上で、必要な対策を講じているか？	1) 人間中心				
	1) 多様性・包摂性の確保 ④	公平性の確保に加え、いわゆる「情報弱者」や「技術弱者」を生じさせず、より多くの人々がAIの恩恵を享受できるよう社会的弱者によるAIの活用を容易にするよう注意を払っているか？ （ユニバーサルデザイン、アクセシビリティの確保、関連するステークホルダーへの教育・フォローアップ等）	1) 人間中心				
	1) 利用者支援 ⑤	合理的な範囲で、AIシステム・サービスの機能及びその周辺技術に関する情報を提供し、選択の機会を適時適切に提供する機能が利用可能である状態としているか？ （デフォルトの設定、理解しやすい選択肢の提示、フィードバックの提供、緊急時の警告、エラーへの対処等）	1) 人間中心				
	1) 持続可能性の確保 ⑥	AIシステム・サービスの開発・提供・利用において、ライフサイクル全体で、地球環境への影響を検討しているか？	1) 人間中心				
	2) 人間の生命・心身・財産、及び環境への配慮 ①	a.AIの出力の正確性を含め、要求に対して十分に動作している（信頼性）ことを確認しているか？ b.様々な状況下でパフォーマンスレベルを維持し、無関係な事象に対して著しく誤った判断を発生させないようにしているか？（堅牢性（robustness）） c.AIの活用や意図しないAIの動作によって生じうる権利侵害の重大性、侵害発生の可能性等、当該AIの性質・用途等に照らし、必要に応じて客観的なモニタリングや対処も含めて人間がコントロールできる制御可能性を確保しているか？ d.適切なリスク分析を実施し、リスクへの対策を講じているか？ e.人間の生命・心身・財産、及び環境へ危害を及ぼす可能性がある場合は、講ずべき措置について事前に整理し、AIに関わる全ての者に関連する情報を提供しているか？ f.関連するステークホルダーが講ずべき措置及び利用規則を遵守する必要がある事項についても明記しているか？ g.AIシステム・サービスの安全性を損なう事態が生じた場合の対処方法を検討し、当該事態が生じた場合に速やかに実施できるよう整えているか？	2) 安全性				
	2) 適正利用 ②	主体のコントロールが及ぶ範囲で本来の目的を逸脱した提供・利用により危害が発生することを避けるべく、AIシステム・サービスの開発・提供・利用を行っているか？	2) 安全性				
	2) 適正学習 ③	a.AIシステム・サービスの特性や用途を踏まえ、学習等に用いるデータの正確性・必要な場合には最新性（データが適切であること）等を検討しているか？ b.学習等に用いるデータの透明性の支援や法的枠組みの遵守、AIモデルの更新等を合理的な範囲で適切に実施しているか？	2) 安全性				
	3) AIモデルの各構成技術に含まれるバイアスへの配慮 ①	a.不適切なバイアスを生み出す要因は多岐に渡るため、各技術要素（学習データ、モデルの学習過程、AI利用者が入力するプロンプト、AIモデルの推論時に参照する情報や連携する外部サービス等）及び利用者の振る舞いを含めて、公平性の問題となり得るバイアスの要因となるポイントを特定しているか？ b..AIシステム・サービスの特性や用途によっては、潜在的なバイアスが生じる可能性についても検討しているか？	3) 公平性				
	3) 人間の判断の介在 ②	a.AIの出力結果が公平性を欠くことがないよう、AIに単独で判断させるだけでなく人間の判断を介在させる利用を検討しているか？ b.バイアスが生じていないか、AIシステム・サービスの目的、制約、要件、決定を明確かつ透明性のある方法により分析し、対処するためのプロセスを導入しているか？ c.無意識のバイアスや潜在的なバイアスに留意し、多様な背景、文化、分野のステークホルダーと対話した上で、方針を決定しているか？	3) 公平性				
	4) AIシステム・サービス全般におけるプライバシーの保護 ①	a.個人情報保護法等の関連法令の遵守や、各主体のプライバシーポリシーの策定・公表等により、社会的文脈や人々の合理的な期待を踏まえ、各主体を含むステークホルダーのプライバシーが尊重され、保護されるよう、その重要性に応じた対応を取っているか？ b.以下の事項を考慮しつつ、プライバシー保護のための対応策を検討しているか？ （個人情報保護法に基づいた対応の確保、国際的な個人データ保護の原則及び基準の参照）	4) プライバシー保護				

5) ①	AIシステム・サービスに影響するセキュリティ対策	a.AIシステム・サービスの機密性・完全性・可用性を維持し、常時、AIの安全な活用を確保するため、その時点での技術水準に照らして合理的な対策を講じているか？ b.AIシステム・サービスの特性を理解し、正常な稼働に必要なシステム間の接続が適切に行われているかを検討しているか？ c.推論対象データに微細な情報を混入させることで関連するステークホルダーの意図しない判断が行われる可能性を踏まえて、AIシステム・サービスの脆弱性を完全に排除することはできないことを認識しているか？	5) セキュリティ確保		
5) ②	最新動向への留意	AIシステム・サービスに対する外部からの攻撃は日々新たな手法が生まれており、これらのリスクに対応するための留意事項を確認しているか？	5) セキュリティ確保		
6) ①	検証可能性の確保	a.AIの判断にかかわる検証可能性を確保するため、データ量やデータ内容に照らし合理的な範囲で、AIシステム・サービスの開発過程及び利用時の入出力等、AIの学習プロセス及び推論過程や判断根拠等のログを記録・保存しているか？ b.ログの記録・保存にあたっては、利用する技術の特性や用途に照らして、その目的、頻度等について検討しているか？	6) 透明性		
6) ②	関連するステークホルダーへの情報提供	a.AIとの関係の仕方、AIの性質及び目的等に照らして、それぞれが有する知識や能力に応じ下記について取りまとめた情報の提供と説明を行っているか？ ・AIシステム・サービス全般；AIを利用しているという事実、データ収集及びアノテーションの手法、学習及び評価の手法、基盤としているAIモデルに関する情報、AIシステム・サービスの能力、限界、提供先における適切/不適切な利用方法、AIシステム・サービスの提供先やAI利用者が所在する国・地域等において適用される関連法令等 b.多様なステークホルダーとの対話を通じて積極的な関与を促し、社会的な影響や安全性に関する様々な意見を収集しているか？ c.AIシステム・サービスを提供・利用することの優位性を、実態に即して関連するステークホルダーに示しているか？	6) 透明性		
6) ③	合理的かつ誠実な対応	a.「関連するステークホルダーへの情報提供」は、アルゴリズムやソースコードの開示を想定するのではなく、プライバシーや営業秘密を尊重して、採用する技術の特性や用途に照らし、社会的合理性が認められる範囲で実施しているか？ b.公開されている技術を用いる際には、それぞれ定められている規程に準拠しているか？ c.開発したAIシステムのオープンソース化にあたっても、社会的な影響を検討しているか？	6) 透明性		
6) ④	関連するステークホルダーへの説明可能性・解釈可能性の向上	関連するステークホルダーの納得感や安心感の獲得、また、そのためのAIの動作に対する証拠の提示等を目的として、どのような説明が求められるかを分析・把握し、必要な対応を講じているか？ （AI提供者：AI開発者に、どのような説明が必要となるかを共有しているか？ （AI利用者：AI開発者・AI提供者に、どのような説明が必要となるかを共有しているか？）	6) 透明性		
7) ①	トレーサビリティの向上	データの出所やAIシステム・サービスの開発・提供・利用中に行われた意思決定等について、技術的に可能かつ合理的な範囲で追跡・遡求が可能な状態を確保しているか？	7) アカウンタビリティ		
7) ②	共通の指針の対応状況の説明	共通の指針の対応状況について、ステークホルダー（サプライヤーを含む）に対してそれぞれが有する知識や能力に応じ、例えば以下の事項を取りまとめた情報の提供と説明を定期的に行っているか？ ・全般：共通の指針の実践を妨げるリスクの有無や程度に関する評価共通の指針の実践の進捗状況 ・「人間中心」関連：偽情報等への留意、多様性・包摂性、利用者支援、持続可能性の確保の対応状況 ・「安全性」関連：AIシステム・サービスに関する既知のリスクと対応策、安全性確保の仕組み ・「公平性」関連：AIモデルを構成する各技術要素（学習データ、モデルの学習過程、AI利用者が入力するプロンプト、AIモデルの推論時に参照する情報や連携する外部サービス等）によってバイアスが含まれること ・「プライバシー保護」関連：AIシステム・サービスにより自己やステークホルダーのプライバシーが侵害されるリスクと対応策、並びにプライバシー侵害が発生した場合に講ずることが期待される措置 ・「セキュリティ確保」関連：AIシステム・サービスの相互連携や他システムとの連携が発生する場合、その促進のために必要な標準準拠等。AIシステム・サービスがインターネットを通じて他のAIシステム・サービス等と連携する場合に発生しう	7) アカウンタビリティ		
7) ③	責任者の明示	各主体においてアカウンタビリティを果たす責任者を設定しているか？	7) アカウンタビリティ		
7) ④	関係者間の責任の分配	関係者間の責任について、業務外利用者も含めた各主体間の契約や社会的な約束（ボランティアコミットメント）等により、責任の所在を明確化しているか？	7) アカウンタビリティ		
7) ⑤	ステークホルダーへの具体的な対応	a.必要に応じ、AIシステム・サービスの利用に伴うリスク管理や安全性確保のための各主体のAIガバナンスに関するポリシー、プライバシーポリシー等の方針を策定し、公表しているか？（社会や一般市民に対するビジョンの共有や情報発信・提供を行うといった社会的責任を含む） b.必要に応じ、AIの出力の誤り等について、ステークホルダーからの指摘を受け付ける機会を設けるとともに、客観的なモニタリングを実施しているか？ c.ステークホルダーの利益を損なう事態が生じた場合、どのように対応するか方針を策定してこれを着実に実施し、進捗状況については必要に応じて定期的にステークホルダーに報告しているか？	7) アカウンタビリティ		
7) ⑥	文書化	上記に関する情報を文書化して保管し、必要とときに、必要	7) アカウンタビリティ		
8) ①	AIリテラシーの確保	各主体内のAIに関わる者が、その関わりにおいて十分なレベルのAIリテラシーを確保するために必要な措置を講じているか？	8) 教育・リテラシー		
8) ②	教育・リスキリング	生成AIの活用拡大によって、AIと人間の作業の棲み分けが変わっていくと想定されるため、新たな働き方ができるよう教育・リスキリング等を検討しているか？	8) 教育・リテラシー		
8) ③	ステークホルダーへのフォローアップ	AIサービス全体の安全性を高めるため、必要に応じて、ステークホルダーに対して教育やリテラシー確保のためのフォローアップを行っているか？	8) 教育・リテラシー		
9)	公正競争確保	AIを活用した新たなビジネス・サービスが創出され、持続的な経済成長の維持と社会課題の解決策の提示がなされるよう、AIをめぐる公正な競争環境の維持に努めているか？	9) 公正競争確保		

10) ①	オープンイノベーション等の推進	a.国際化・多様化や産学官連携、オープンイノベーションを推進しているか？ b.AIのイノベーションに必要なデータが創出される環境の維持に配慮しているか？	10) イノベーション
10) ②	相互接続性・相互運用性への留意	自らのAIシステム・サービスと他のAIシステム・サービスとの相互接続性と相互運用性を確保しているか？	10) イノベーション
10) ③	適切な情報提供	自らのイノベーションを損なわない範囲で必要な情報提供を行っているか？	10) イノベーション

チェックリスト素案 (AI開発者向け 記載例)

利用上の留意点

ガイドラインに記載した内容に関して取り組むべき事項は、**各事業者の事業内容や置かれた状況等により、個々に異なります。**

このため、本チェックリストは、**あくまで各事業者が取り組むべき事項が何かを検討する際の材料をご提供するもの**であり、**各事業者それぞれの状況に応じ、カスタマイズして必要に応じて活用いただくこと**を前提としたものです。

したがって、必ずしも、全ての事項について、検討が必要となるものではありませんので、**活用の要否、各自の事情に応じた修正や取捨選択を検討ください。**

D列～F列の記載内容を基に、**G列以降を各事業者にてご検討いただき、各自が取り組むべきこと（あるいは内容）を具体化の上、活用ください。**

なお、このシートでは、G列以降に、オレンジ字にて記載例を示しています。

（エントリーシートの文章で、応募者に対し可否を判断する採用AI（XGBoost）の例。https://ifi.u-tokyo.ac.jp/wp/wp-content/uploads/2022/10/RCModel_Case01_Recruitment-AI_JP.pdf）

チェックリストを各自用カスタマイズし運用するには、A. チェックリストを作成する者（当該チェックリストを基に、各自のチェックリストのカスタマイズを行う者）、B. チェックを行う者（現場において実際のチェックを行う者）、C. 責任者（チェック内容に対して責任を負う者）を特定ください（各主体の規模によって、A.～C.が重複する場合もある）。

A. チェックリストを作成する者	AI倫理委員会担当者XXX
B. チェックを行う者	開発部門品質管理担当者XXX（AI倫理委員会XXXにより実施をサポート）
C. 責任者	AI倫理委員会担当者XXX

※必要に応じてチェックするタイミングを記入	分類	確認事項 (ガイドライン「本編」を基に記載)	対応箇所	各自の事業に関連する事項 (該当しない場合はその理由)	他の主体との関係についての事項	✓	具体的な取組内容 (別添(付属資料)該当箇所を基に検討)	最終検討日 (見直し日)
データ前処理・学習時に確認する事項	2)③ 適正学習	学習時のデータについて、 a. プライバシー・バイ・デザイン等を通じて、学習時のデータについて、適正に収集するとともに、第三者の機密情報、個人情報、知的財産権に留意が必要なもの等が含まれている場合には、法令に従って適切に扱うことを、AIのライフサイクル全体を通じて確保したか？ b. 学習前・学習全体を通じて、データのアクセスを管理するデータ管理・制限機能の導入検討を行う等、適切な保護措置を実施したか？	3部 2) 安全性 4) プライバシー保護 5) セキュリティ確保	a. 学習データ内に個人を特定する情報が含まれている可能性あり b. 学習データの保護措置によっては出力内容が異なる可能性あり			a. ・学習データに用いるエントリーシートについて、学習時に個人を特定する情報をクレンジングする（SpaCy & Presidioでの検出 + AI開発者による検証） ※モデルの汎化性能を確保する上でも個人を特定する情報を除く	
	3)① AIモデルの各構成技術に含まれるバイアスへの配慮	学習データ、モデルの学習過程において、 a. 学習データ、モデルの学習過程によってバイアス（学習データには現れない散在的なバイアスを含む）が含まれることに留意し、データの質を管理するための相当の措置を講じたか？ b. 学習データ、モデルの学習過程からバイアスを完全に排除できないことを踏まえ、必要に応じて、単一手法ではなく多様な手法に基づく開発を並行して行ったか？	3部 3) 公平性	a. b. ・応募者の属性(特定の国／地域／人種／性別／年齢)による不公平な予測結果が含まれる可能性あり ・学習データ不足等によるバイアスが含まれる可能性あり(例：外国籍の応募者、障害者雇用の対象者、従来重視していなかった職種等)	-		a. b. ・AI提供者が検討したリスク対策の計画(リスクチェーンモデルの内容)の検討に協力し、技術側で行うべきバイアスの評価を行う（データ及びモデルの特徴量）	
AI開発時に確認する事項	2)① 人間の生命・心身・財産、及び環境への配慮	開発時において、 a. 関連するステークホルダーを明確にしたか？ b. ステークホルダーの生命・心身・財産、及び環境に危害を及ぼすことがないよう、様々な状況下で予想される利用条件下でのパフォーマンスだけでなく、予期しない環境での利用にも耐えうる性能の要求を検討したか？ c. ステークホルダーの生命・心身・財産、及び環境に危害を及ぼすことがないよう、リスク(運動するロボットの制御不能や不適切な出力等)を最小限に抑える方法(ガードレール技術等)を検討したか？	3部 2) 安全性	a. ステークホルダーはAI提供者、採用担当者、応募者 b. 採用AIの利用環境においては、AIの出力結果が異なる可能性あり（予測結果や堅牢性） c. 検討の必要あり	AI提供者と、AI利用者からのエスカレーションの観点で連携の必要性があり		b. ・AIモデルの予測精度を評価する：分類の正確性	
							・AIモデルの堅牢性を評価する：句読点等のエントリーシートにおいて重要性が低い情報の違いによって、予測性能が著しく異ならないか	
							c. ・様々なグループ会社・職種・スキル要件を想定したバリエーションでAIモデルの予測結果と判断根拠を検証する	
							・(AI利用者の最終判断に向けて)AIモデルから判断根拠情報及び類似する判断事例を出力する ・本AIサービスに関わるリスクシナリオ及び技術的な対策について、関連するステークホルダーと共に検討する ・AI利用者からAIの予測性能に関わるエスカレーションがあった際にモデル・データを検証できる体制を作る ・モデルの再学習を実施できる体制・環境を作る	
	2)② 適正利用	a. 関連するステークホルダーを明確にしたか？ b. 開発時に想定していない提供・利用により危害が発生することを避けるため、安全に利用可能な範囲を設定して開発を行ったか？ c. 事前学習済のAIモデルに対する事後学習を行う場合に、学習済AIモデルを適切に選択（商用利用可能なライセンスかどうか、事前学習データ、学習・実行に必要なスペック等）したか？	3部 2) 安全性	a. ステークホルダーはAI提供者、採用担当者、応募者 b. 応募者の入力内容や採用提供者の使い方によりAIの出力結果が異なる可能性あり c. 通常の機械学習モデルによるケースのためAIモデルの調整は対象外	AI提供者と、AI利用者からのエスカレーションの観点で連携の必要性があり		b. ・予測対象とする文章の仕様を明確化する(対象：エントリーシート、言語：日本語、文字数：2000字以内)	
							・利用ログを保存する ・AI提供者が定義したAIサービスの要求仕様に応じて、AIモデルの目的関数及びユースケースの仕様を具体化する	
	3)① AIモデルの各構成技術に含まれるバイアスへの配慮	a. AIモデルを構成する各技術要素（AI利用者が入力するプロンプト、AIモデルの推論時に参照する情報や連携する外部サービス等）によってバイアスが含まれることまで検討したか？ b. AIモデルからバイアスを完全に排除できないことを踏まえ、単一手法ではなく多様な手法に基づく開発を並行して行ったか？	3部 3)公平性	a. b. 他に外部情報の参照やユーザー入力によって推論性能に影響を与えることがないため対象外	-			
	5)① AIシステム・サービスに影響するセキュリティ対策	AIシステムの開発の過程を通じて、採用する技術の特性に照らし適切にセキュリティ対策を講じたか？（セキュリティ・バイ・デザイン）	2部 5) セキュリティ確保	入力データやシステム間の接続によってはAIシステムの品質が変わる可能性あり	-		・AIシステムの開発において、必要なセキュリティ対策を検討する（エントリーシートのファイルを改ざんしないように書き込み不可にする）	

	6)①	検証可能性の確保	AIの予測性能や出力の品質が、活用後に大きく変動する可能性や想定する精度に達しないこともある特性を踏まえ、事後検証のための作業記録を保存しつつ、その品質の維持・向上を行ったか？	3部 2)安全性 6)透明性	本ケースにおいては、1)①への対応と同様	-		・AIシステムの開発において、必要なネットワーク要件を検討する ※イントラ内での利用のため、外部攻撃等のリスクについては会社の情報セキュリティ管理に依拠することで対応している
	1)③	偽情報等への留意	生成 AI によって、内容が真実・公平であるかのように装った情報を誰でも作ることができるようになり、AI が生成した偽情報・誤情報・偏向情報が社会を不安定化・混乱させるリスクが高まっていることを認識する。その上で、必要な対策を講じたか？	2部 1) 人間中心	AIが出力を生成する活用方法ではなく、社会的	-		
	3)②	人間の判断の介在	a. AIの出力結果が公平性を欠くことがないよう、AIに単独で判断させるだけでなく人間の判断を介在させる利用を検討したか？ b. バイアスが生じていないか、AIシステム・サービスの目的、制約、要件、決定を明確かつ透明性のある方法により分析し、対処するためのプロセスを導入したか？ c. 無意識のバイアスや潜在的なバイアスに留意し、多様な背景、文化、分野のステークホルダーと対話した上で、方針を決定したか？	3部 3)公平性	a. b. 本ケースにおいては、1,2のデータ前処理・学習時に留意すべき事項への対象と同様 c. 検討の必要あり	AI提供者・AI利用者と連携の必要性があり	c. AI提供者とAI利用者の代表者が中心となって、必要なステークホルダーとの協議を行う	
	4)①	AIシステム・サービス全般におけるプライバシーの保護	個人情報保護法等の関連法令の遵守や、各主体のプライバシーポリシーの策定・公表等により社会的文脈や人々の合理的な期待を踏まえ、ステークホルダーのプライバシーが尊重され、保護されるよう、その重要性に応じた対応を取ったか？	2部 4) プライバシー保護	個人情報が含まれる学習データのアクセス権限範囲やその扱いによってはステークホルダーのプライバシーが侵害される可能性あり	-		・本AIサービスの運営にアサインするにあたって、個人情報保護に係る誓約書にサインする
								・クレンジング前の学習データ(エントリーシート)を適切な格納場所に必要な担当者のみがアクセスする
AI開発後に確認する事項	5)②	最新動向への留意	a. AIシステムに対する攻撃手法は日々新たなものが生まれ、これらリスクに対応するため、開発の各工程で留意すべき点を確認したか？	3部 5) セキュリティ確保	a. 開発されたシステムはイントラ内での利用が想定されるため、開発者としてはデータの保護措置を実施。外部攻撃等のリスクについては、各主体(提供者/利用者)の情報セキュリティ管理に依拠	-		・リスクシナリオ及び対策の検討内容を整理する
								・学習データを適切な場所に格納する ・開発環境について適切なAI開発者にのみ適切なレベルのアクセス権限を付与する
	6)②	関連するステークホルダーへの情報提供	a. 関連するステークホルダーを明確にしたか？ また、関連するステークホルダーに対して、以下の説明を行ったか？ b. AIシステムの学習等による出力又はプログラムの変化の可能性 c. AIシステムの技術的特性、安全性確保の仕組みやテストの結果、利用の結果生じる可能性のある予見可能なリスク及びその緩和策等の安全性に関する情報 d. 開発時に想定していない提供・利用により危害が発生することを避けるためのAI開発者が意図する利用範囲 e. AIシステムの動作状況に関する情報、不具合の原因と対応状況 f. 更新を行った場合の内容とその理由の情報 g. AIモデルで学習するデータの収集ポリシーやその学習方法及び実施体制等	3部 1)人間中心 2)安全性 3)公平性 4)プライバシー保護 5)セキュリティ確保 6)透明性	a. 関連するステークホルダーはAI提供者、採用担当者、応募者 b. 出力又はプログラムの変化の可能性あり c. 当該情報は提供の必要あり d. 利用範囲はAI提供者で検討するため対象外 e. f. g. 当該情報は提供の必要あり	AI提供者と連携の必要性あり	b. f. AIシステムの出力内容・情報の変更についてはモデルカードに記録する	
								c. ・リスクシナリオ及び対策の検討内容を整理する e. ・AIシステムの障害発生状況を対応方法と併せて記録する g. ・学習データを適切な場所に格納する ・開発環境について適切なAI開発者にのみ適切なレベルのアクセス権限を付与する(1)②と同様) また、AIシステム・サービス全般に係る以下の情報をAI提供者に向けて提供する -データ収集及びアノテーションの手法 -トレーニング及び評価の手法 -基盤としているAIモデルに関する情報 -AIシステム・サービスの能力、限界(予測の苦手な対象等)
	7)②	AI提供者への共通の指針の対応状況の説明	a. AI提供者に対して、AIには活用後に予測性能や出力の品質が大きく変動する可能性や想定する精度に達しないこともある特性がある旨や、その結果生じるリスク等の情報提供と説明を行ったか？ b. 具体的には、AIモデルを構成する各技術要素（学習データ、モデルの学習過程、AI利用者が入力すると想定するプロンプト、AIモデルの推論時に参照する情報や連携する外部サービス等）において含まれる可能性があるバイアスへの対応等を周知したか？	3部 7) アカウンタビリティ	a. b. 想定されるリスクの認識を、AI提供者と合わせの必要あり	AI提供者と連携の必要性あり	a. b. ・リスクシナリオ及び対策の検討過程において、ステークホルダーへ説明すべき内容を整理し、説明する	
	7)⑥	開発関連情報の文書化	トレーサビリティと透明性の向上のため、AIシステムの開発過程、意思決定に影響を与えるデータ収集やラベリング、使用されたアルゴリズム等について、可能な限り第三者が検証できるような形で文書化したか？	3部 7) アカウンタビリティ	AIシステムの開発過程やアーキテクチャ、検討内容等の文書化により、トレーサビリティと透明性を確保の必要あり	-		・AIシステムのアーキテクチャを文書化する（学習データ、本番データの入力、AIシステムの推論、出力） ・AIシステムの開発に伴う情報を文書化する ・AIシステムの検討内容はモデルカードに記録する
その他の重要な事項	1)①	人間の尊厳と個人の自律の尊重	a. AIが活用される際の社会的文脈を踏まえ、人間の尊厳と個人の自律を尊重したか？ b. 特に、AIを人間の脳・身体と連携させる場合には、その周辺技術に関する情報を踏まえつつ、諸外国や研究機関における生命倫理の議論等を参照したか？ c. 個人の権利・利益に重要な影響を及ぼす可能性のある分野においてAIを利用したプロファイリングを行う場合、プライバシーや公平性を確保しつつ、個人の尊厳を尊重し、生じる不利益等を慎重にした上で、不適切な目的に利用していないか？	2部 1) 人間中心	a. AIシステムの活用方法によっては人間の尊厳と個人の自律が侵害される可能性あり b. 脳・身体と連携するケースではないため対象外 c. AIの予測結果に個人情報が含まれているため、活用方法によっては個人の権利・利益、プライバシーや公平性、個人の尊厳が侵害される可能性あり	-		a. ・AIシステムの開発において、学習データの収集やラベリング、モデルの性能評価等は、AI開発者だけで完結せず、AI提供者側で判断できるようにする
								c. ・AIシステムの開発において、実際の予測結果を学習データに用いる際には個人情報の取扱いに関わる誓約書の締結やアクセス権管理等を実施する

1)②	AIによる意思決定・感情の操作等への留意	a. 人間の意思決定や認知等、感情を不当に操作することを目的とした、もしくは操作を前提としたAIシステム・サービスの開発・提供・利用は行っていないか？ b. AIシステム・サービスの開発・提供・利用において、自動化バイアス等のAIに過度に依存するリスクに対して、必要な対策を講じたか？ c. フィルターバブルに代表されるような情報や価値観の傾斜を助長し、AI利用者を含む人間が本来得られるべき選択肢が不本意に制限されるようなAIの活用にも注意を払ったか？ d. 特に、選挙やコミュニティでの意思決定等をはじめとする社会に重大な影響を与える手続きに関連しうる場合においては、AIの出力について慎重に検討したか？	2部 1) 人間中心	a. b. AIシステムの活用方法によっては人間の意思決定を左右したり、自動化バイアス等を生じたりする可能性あり c. 応募者が入力するエントリーシートは企業が求める要件に沿った上で自由記述できるものであり、AIサービスが制限するものではないため対象外 d. 本ケースは、社会的な意思決定に関わるものではないため、対象外	a. b. ・(AI利用者の最終判断に向けて)AIモデルから判断根拠情報及び類似する判断事例を出力する (本ケースの場合、最終判断の局面でAI利用者がAIの判断を覆すことができるため、チェックリスト3.③と同様)
1)④	多様性・包摂性の確保	公平性の確保に加え、いわゆる「情報弱者」や「技術弱者」を生じさせず、より多くの人々がAIの恩恵を享受できるよう社会的弱者によるAIの活用を容易にするよう注意を払ったか？	2部 1) 人間中心	社内の人材採用担当者がいるため対象外 ・AI利用者が、障がい者雇用のプログラム等、電子ファイルによるエントリーシートを作成するための情報リテラシーが十分ではない人材採用のチャネルについて、本AIサービスとは別に人事業務として用意	
1)⑤	利用者支援	合理的な範囲で、AIシステム・サービスの機能及びその周辺技術に関する情報を提供し、選択の機会を適時適切に提供する機能が利用可能である状態としたか？	2部 1) 人間中心	AI利用者である採用担当者にとって、機能の選択の機会の提供が必要	・(AI利用者の最終判断に向けて)AIモデルから判断根拠情報及び類似する判断事例を出力する
1)⑥	持続可能性の確保	AIシステム・サービスの開発・提供・利用において、ライフサイクル全体で、地球環境への影響への配慮を行ったか？	2部 1) 人間中心	AIシステムの活用により、エネルギー消費等、環境負荷は一定発生	・本番運用及び再学習を含めて、開発環境における計算量・稼働時間・ストレージ使用量を記録する
6)③	合理的かつ誠実な対応	a. 「関連するステークホルダーへの情報提供」は、アルゴリズムやソースコードの開示を想定するものではなく、プライバシーや営業秘密を尊重して、採用する技術の特性や用途に照らし、社会的合理性が認められる範囲で実施したか？ b. 公開されている技術を用いる際には、それぞれ定められている規程に準拠したか？ c. 開発したAIシステムのオープンソース化にあたっても、社会的な影響を検討したか？	2部 6)透明性	a. 本ケースにおいては、技術情報を外部に開示することは求められていないため対象外 b. 公開されている情報を用いる際には、参照すべき規定がある場合あり c. 本ケースはオープンソース化を行わないため対象外	b. ・開発に用いるオープンソースのライブラリを一覧化する
6)②	関連するステークホルダーへの説明可能性・解釈可能性の向上	関連するステークホルダーを明確にして、その納得感や安心感の獲得、また、そのためのAIの動作に対する証拠の提示等を目的として、どのような説明が求められるかを分析・把握し、必要な対応を講じたか？	2部 6)透明性	ステークホルダーであるAI提供者、採用担当者、AI提供者と連携の応募者に対し、リスクとその対策の説明が必要になる可能性あり	リスクシナリオ及び対策の検討過程において、ステークホルダーへ説明すべき内容を整理する
7)①	トレーサビリティの向上	データの出所やAIの開発・提供・利用中に行われた意思決定等について、技術的に可能かつ合理的な範囲で追跡・遡求が可能な状態を確保したか？	2部 7)アカウントビリティ	ステークホルダーへの説明等のため、AIシステムの開発過程で行われた意思決定を振り返る必要が生じる可能性あり	・AIモデル及びAIシステムの開発・変更における検討過程と修正・検証内容をモデルカードに記録する ・利用ログを保存する ・アノテーションにおける異常値の検証を実施する(本ケースにおいては7と同じ対策)
7)③	責任者の明示	a. 各主体においてアカウントビリティを果たす責任者を設定したか？ b. 必要に応じ、AIシステム・サービスの利用に伴うリスク管理や安全性確保のための各主体のAIガバナンスに関するポリシー、プライバシーポリシー等の方針を策定し、公表したか？	2部 7)アカウントビリティ	a. アカウントビリティを果たす責任所在が明確である必要あり b. AI提供者が定める各ポリシーに準拠するため対象外	a. AI開発者の中でチーフデータサイエンティスト及びリードエンジニアを特定する
7)④	関係者間の責任の分配	関係者間の責任について、業務外利用者も含めた各主体間の契約や社会的な約束（ボランタリーコミットメント）等により、責任の所在を明確化したか？	2部 7)アカウントビリティ	AI提供者での検討に含まれるため対象外 AI提供者と連携の必要性あり	
7)⑤	ステークホルダーへの具体的な対応	a. 必要に応じ、AIの出力の誤り等について、ステークホルダーからの指摘を受け付ける機会を設けるとともに、客観的なモニタリングを実施したか？ b. ステークホルダーの利益を損なう事態が生じた場合、どのように対応するか方針を策定してこれを着実に実施し、進捗状況については必要に応じて定期的にステークホルダーに報告したか？	2部 7)アカウントビリティ	a. b. AIの出力に誤りが生じたり、ステークホルダーの利益を損なう事態が生じる可能性あり	a. b. ・AI利用者からAIの予測性能に関わるエスカレーションがあった際にモデル・データを検証できる体制にする ・モデルの再学習を実施できる体制・環境を作る

チェックリスト素案 (AI利用者向け 記載例)

利用上の留意点	ガイドラインに記載した内容に関して取り組むべき事項は、各事業者の事業内容や置かれた状況等により、個々に異なります。 このため、本チェックリストは、あくまで各事業者が取り組むべき事項が何かを検討する際の材料をご提供するものであり、各事業者それぞれの状況に応じ、カスタマイズして必要に応じて活用いただくことを前提としたものです。 したがって、必ずしも、全ての事項について、検討が必要となるものではありませんので、活用の要否、各自の事情に応じた修正や取捨選択を検討ください。 D列～F列の記載内容を基に、G列以降を各事業者にてご検討いただき、各自が取り組むべきこと（あるいは内容）を具体化の上、活用ください。 なお、このシートでは、G列以降に、オレンジ字にて記載例を示しています。 （エントリーシートの文章で、応募者に対し可否を判断する採用AI（XGBoost）の例。https://ifi.u-tokyo.ac.jp/wp/wp-content/uploads/2022/10/RCModel_Case01_Recruitment-AI_JP.pdf） チェックリストを各自用にカスタマイズし運用するには、A. チェックリストを作成する者（当該チェックリストを基に、各自のチェックリストのカスタマイズを行う者）、B. チェックを行う者（現場において実際のチェックを行う者）、C. 責任者（チェック内容に対して責任を負う者）を特定ください（各主体の規模によって、A.～C.が重複する場合もある）。
---------	---

	A. チェックリストを作成する者	AI倫理委員会担当者XXX
	B. チェックを行う者	人材採用担当者XXX（AI倫理委員会XXXにより実施をサポート）
	C. 責任者	AI倫理委員会担当者XXX

※必要に応じてチェックするタイミングを記入	分類	確認事項 (ガイドライン「本編」を基に記載)	対応箇所	各自の事業に関連する事項 (該当しない場合はその理由)	他の主体との関係についての事項	✓	具体的な取組内容	最終検討日 (見直し日)
AIシステム・サービス利用時に確認する事項	2) 適正利用 ②	a. AI提供者が定めた利用上の留意点を遵守して、AI提供者が設計において想定した範囲内でAIシステム・サービスを利用しているか？ b. 正確性・必要な場合には最新性（データが適切であること）等が担保されたデータの入力を行っているか？ c. AIの出力について精度やリスクの程度を理解し、様々なリスク要因を確認した上で利用しているか？	5部 2) 安全性	a. AI提供者による利用範囲の設定あり b. 正確・最新性データ（エントリーシート）の入力に留意することが必要 c. 出力結果の精度やリスクの程度を確認することが必要	人材採用部門と連携の必要性あり		a. ・人材採用部門と検討した上で、採用AIの利用目的・範囲を理解し、不適切な目的外利用を行わない b. ・予測対象とするエントリーシートが適切であることを確かめる c. ・リスクシナリオの中で人材採用担当者側で対応すべきリスクコントロールを認識する	
	3) ①	AIモデルの各構成技術に含まれるバイアスへの配慮	5部 3) 公平性	ユーザー入力によって推論性能に影響を与えることがないため対象外	-			
	4) ①	AIシステム・サービス全般におけるプライバシーの保護	5部 4) プライバシー保護	a. 入力情報は申込者のエントリーシートであり、個人情報が入力されても前処理で個人名は削除されるため、名前以外の個人情報と名前が紐づかず、個人情報の不適切入力にはならないため対象外 b. プライバシー侵害に関する情報収集、防止が必要	-		b. （通常の人事業務の内部統制として実施） ・エントリーシートを継続的に提供するために、キャリアコンサルタント及び申込者に対して事前にデータの利用範囲(AI開発者/AI提供者にデータを提供すること)と利用目的の説明と同意を得る	
	5) ①	AIシステム・サービスに影響するセキュリティ対策	5部 5) セキュリティ確保	※イントラ内での利用のため、外部攻撃等のリスクについては会社の情報セキュリティ管理に依拠	-		・社内の情報セキュリティのルールを遵守する ・セキュリティ上の疑義を感じた場合は、開発部門等にその旨を報告する	
	6) ②	関連するステークホルダーへの情報提供	5部 3) 公平性 6) 透明性	ユーザー入力によって推論性能に影響を与えることがないため対象外（受領したエントリーシートのファイル(書き込み不可)をアップロードするため)	-			
	7) ②	共通の指針の対応状況の説明	4部 1) 人間中心 7) アカウンタビリティ	関連するステークホルダーは直接利用しないため対象外	-			
	7) ⑥	文書化	5部 7) アカウンタビリティ	a. b. 人材採用部門から共有された最新の採用AIに関する利用方針に従って利用する必要がある	人材採用部門と連携の必要性あり		a. ・人材採用部門から受領した情報を社内のイントラから最新版を閲覧できるようにする b. ・人材採用部門の示すルールに沿った業務マニュアルを策定し、業務を遂行する	
	1) ④	多様性・包摂性の確保	2部 1) 人間中心	情報リテラシーが十分でない応募者への配慮が必要	-		・障がい者雇用のプログラム等、電子ファイルによるエントリーシートを作成するための情報リテラシーが十分ではない人材採用のチャネルは採用AIとは別に人事業務として用意する	
	2) ①	人間の生命・心身・財産、及び環境への配慮	2部 2) 安全性	a. 様々な状況において一定レベルの採用AIの出力確保が必要 b. 採用AIの制御可能性の確保が必要 c. リスクの把握が必要 d. 危害を及ぼす可能性の整理と情報提供が必要 e. 関連するステークホルダーは直接AIを利用しないため対象外 f. 採用AIの安全性が損なわれた場合の対策を検討しておくことが必要	-		a. ・人材採用部門からの事前説明に対する指摘・フィードバック、必要な範囲でのユーザーテストの実施 ・人材採用部門に対して、採用AIの利用状況、運用上や技術的な問題等についてフィードバックを行う b. ・業務プロセス上で人材採用担当者が書類選考の可否を判断する c. ・リスクシナリオと対策について説明を受け、改善点をフィードバックする d. ・候補者の心身や自社の財産、環境へ危害を及ぼす可能性について、事前に整理をする f. ・AIモデルが有効に機能しないと判断される場合の代替運用プロセスを検討する	
	3) ②	人間の判断の介在	2部 3) 公平性	a. 出力結果が含みうるバイアスの確認が必要 b. バイアスの分析・対処が必要 c. バイアスについての対話が必要	開発部門・人材採用部門との連携の必要性あり		a. ・著しい学習データの不足やモデル評価への影響に開発部門で対応できないバイアス(例：外国籍の応募者、障害者雇用の対象者、従来重視していなかった職種等)について、AI開発者から説明を受け業務側でカバーできるか確認する	

b.
・人材採用部門が検討したリスク対策の計画(リスクチェーンモデルの内容)について説明を受け、人材採用部門で最終判断を行う上で認識しておくべき事項を理解する

c.
・人材採用部門の代表者が中心となって、必要なステークホルダーとの協議を行う

8) ①	AIリテラシーの確保	各主体内のAIに関わる者が、その関わりにおいて十分なレベルのAIリテラシーを確保するために必要な措置を講じているか？	2部 8) 教育・リテラシー	採用AIのシステムを利用するにあたり、人材採用担当者がセキュリティ、プライバシー等に関するAIリテラシーを備えているか懸念がある	・採用AIサービスに関与するAI利用者に対して、必要な知識・経験を有しているか確かめ、不十分であれば人材採用部門がOJTでコーチングする
8) ②	教育・リスキング	生成AIの活用拡大によって、AIと人間の作業の棲み分けが変わっていくと想定されるため、新たな働き方ができるよう教育・リスキング等を検討しているか？	2部 8) 教育・リテラシー	システムのアップデートに応じて、AIシステムと利用方法が変わりうるが使いこなせない人材採用担当者が出る懸念がある	・システムアップデートの都度、人材採用担当者に対して、説明と教育の機会を設ける

チェックリスト素案（高度なAIシステムに関する事業者向け）

利用上の留意点

本シートは高度なAIシステムに関する事業者を対象とするチェックリストです。

ガイドラインに記載した内容に関して取り組むべき事項は、**各事業者の事業内容や置かれた状況等により、個々に異なります。**

このため、本チェックリストは、**あくまで各事業者が取り組むべき事項が何かを検討する際の材料をご提供するものであり、各事業者それぞれの状況に応じ、カスタマイズして必要に応じて活用いただくこと**を前提としたものです。

したがって、必ずしも、全ての事項について、検討が必要となるものではございませんので、**活用の要否、各自の事情に応じた修正や取捨選択を検討ください。**

D列～F列の記載内容を基に、**G列以降を各事業者にてご検討いただき、各自が取り組むべきこと（あるいは内容）を具体化の上、活用ください。**

チェックリストを各自用いカスタマイズし運用するには、A. チェックリストを作成する者（当該チェックリストを基に、各自のチェックリストのカスタマイズを行う者）、B. チェックを行う者（現場において実際のチェックを行う者）、C. 責任者（チェック内容に対して責任を負う者）を特定ください（各主体の規模によって、A.～C.が重複する場合もある）。

A. チェックリストを作成する者	
B. チェックを行う者	
C. 責任者	

	分類	確認事項 (ガイドライン「本編」を基に記載)	対応箇所	各自の事業に関連する事項 (該当しない場合はその理由)	他の主体との関係についての事項	✓	具体的な取組内容	最終検討日 (見直し日)
	I)	AIライフサイクル全体にわたるリスクを特定、評価、軽減するために、高度なAIシステムの開発全体を通じて、その導入前及び市場投入前も含め、適切な措置を講じる	a.レッドチーム 等の様々な手法を組み合わせて、多様/独立した内外部テスト手段を採用することや、特定されたリスクや脆弱性に対処するための適切な緩和策を実施しているか？ b.上記テストを支援するために、開発中に行われた意思決定に関するトレーサビリティを確保するように努めているか？	2) 安全性 6) 透明性				
	II)	市場投入を含む導入後、脆弱性、及び必要に応じて悪用されたインシデントやパターンを特定し、緩和する	a.リスクレベルに見合った適切なタイミングで、AIシステムの活用状況のモニタリングを実施し、それらに対処するための適切な措置を講じているか？ b.他の利害関係者と協力して、報告されたインシデントの適切な文書化を維持し、特定されたリスクと脆弱性を軽減しているか？	5) セキュリティ確保 7) アカウンタビリティ				
	III) □	高度なAIシステムの能力、限界、適切・不適切な使用領域を公表し、十分な透明性の確保を支援することで、アカウンタビリティの向上に貢献する	a.データの出所に始まり、どのような意思決定を行ったかについて、合理的な説明を行い、トレーサビリティを確保するため文書化・公表しているか？ b.関連するステークホルダーがAIシステムの出力を解釈し、AI利用者や業務外利用者が適切に活用できるようにするために、明確で理解可能な形で文書化・公表しているか？	6) 透明性 7) アカウンタビリティ				
	IV) □	産業界、政府、市民社会、学界を含む、高度なAIシステムを開発する組織間での責任ある情報共有とインシデントの報告に向けて取り組む	モニタリング結果の報告書やセキュリティや安全性のリスクに関する関連文書等を通して、高度なAIシステムを開発する組織間での責任ある情報共有とインシデントの報告に向けて取り組んでいるか？	5) セキュリティ確保 6) 透明性 7) アカウンタビリティ 10) イノベーション				
	V) □	高度なAIシステム開発者に向けた、個人情報保護方針及び緩和策を含む、リスクベースのアプローチに基づくAIガバナンス及びリスク管理方針を策定し、実施し、開示する	a.適切な場合には、プライバシーポリシーを公表しているか？ b.AIガバナンスに関するポリシーや実行するための組織を確立し、開示しているか？	4) プライバシー保護 7) アカウンタビリティ				
	VI) □	AIのライフサイクル全体にわたる、物理的セキュリティ、サイバーセキュリティ、内部脅威に対する安全対策を含む、強固なセキュリティ管理に投資し、実施する	情報セキュリティのための運用上の対策や適切なサイバー/物理的アクセス制御等を検討しているか？	5) セキュリティ確保				
	VII) □	技術的に可能な場合は、電子透かしやその他の技術等、AI利用者及び業務外利用者が、AIが生成したコンテンツを識別できるようにするための、信頼できるコンテンツ認証及び来歴のメカニズムを開発し、導入する	a.適切かつ技術的に実現可能な場合、組織の高度なAIシステムで作成されたコンテンツ認証及び来歴メカニズムを開発し、導入しているか？ b.透かし等を通じた特定のコンテンツが高度なAIシステムで作成されたかどうかをAI利用者及び業務外利用者が判断できるツールやAPIの開発をしているか？ c.AI利用者及び業務外利用者がAIシステムと相互作用していることを知ることができるよう、ラベリングや免責事項の表示等、その他の仕組みを導入しているか？	6) 透明性				
	VIII) □	社会的、安全、セキュリティ上のリスクを軽減するための研究を優先する	AIの安全性、セキュリティ、信頼性の向上やリスクへの対処に関する研究等、社会的、安全、セキュリティ上のリスクを軽減するための研究を優先しているか？	10) イノベーション				
	IX) □	世界の最大の課題、特に気候危機、世界保健、教育等（ただしこれらに限定されない）に対処するよう貢献する	信頼性のある人間中心のAI開発に向けた取組を実施し、同時に業務外利用者も含めたリテラシーの向上のための支援をしているか？	10) イノベーション				
	X) □	国際的な技術規格の開発を推進し、適切な場合にはその採用を推進する	電子透かしを含む国際的な技術標準とベストプラクティスの開発に貢献し、適切な場合にはそれを利用し、標準開発組織（SDO）と協力しているか？	10) イノベーション				
	XI) □	適切なデータインプット対策を実施し、個人情報及び知的財産を保護する	a.有害な偏見バイアスを軽減するために、訓練データやデータ収集など、データの質を管理するための適切な措置を講じているか？ b.透明性、プライバシーを保護するための機械学習や、機密データ等の漏洩のテストとファインチューニングなど、適切なデータインプット対策を実施し、個人情報及び知的財産を保護しているか？	2) 安全性 3) 公平性				
	XII) □	高度な AI システムの信頼でき責任ある利用を促進し、貢献する	a.各主体及びステークホルダーのリテラシー向上のための機会を提供しているか？ b.各主体間で連携し、高度なAIシステムに関する新たなリスクや脆弱性を特定し、対処するための情報共有を行っているか？	5) セキュリティ確保 8) 教育・リテラシー				