

AI 事業者ガイドライン（第 1.24 版）

別添（付属資料）

令和 87 年 3 月 3128 日

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.....	17
別添 2.「第 2 部 E.AI ガバナンスの構築」関連.....	30
A.経営層による AI ガバナンスの構築及びモニタリング.....	32
B.AI ガバナンスの構築に関する実際の取組事例.....	74
別添 3.AI 開発者向け.....	104
A. 本編「第 3 部 AI 開発者に関する事項」の解説.....	105
B. 本編「第 2 部」の「共通の指針」の解説.....	129
C. 広島 AI プロセス「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」.....	141
別添 4.AI 提供者向け.....	146
A. 本編「第 4 部 AI 提供者に関する事項」の解説.....	146
B.本編「第 2 部」の「共通の指針」の解説.....	166
別添 5.AI 利用者向け.....	175
A.本編「第 5 部 AI 利用者に関する事項」の解説.....	175
B.本編「第 2 部」の「共通の指針」の解説.....	187
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.....	192

# 別添.はじめに

## 別添の構成及び読者への期待

AI事業者ガイドライン本編（以下本編）にて、本ガイドラインで対象とする主体「AI 開発者」、「AI 提供者」及び「AI 利用者」が念頭に置くべき基本理念（= why）、並びに理念を踏まえ 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り、本ガイドライン別添（付属資料、以下別添）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リファレンス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・サービスの例及び具体的な活用例、主体のパターン例、業種・業務毎の AI による便益の例、並びに実例にもと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、行動目標及び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及び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」の中で特に重要な内容について、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）

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 及び 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. 広島AIプロセス「全てのAI関係 者向けの広島プロセス国際指針」 「高度なAIシステムに関する事業 者に共通の指針」 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ガバナンスの構築及び 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	※広島AIプロセス「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」 「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 追加的な記載事項も含む	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. 広島AIプロセス「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」 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			
その他 参考資料			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・ワークシート 8. 主体横断的な仮想事例 9. 海外ガイドライン等の参照先

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」及び「AI 利用者」の全主体にとって別添 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及び実践することが重要となる。他主体の記載内容についても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及び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・ワークシートを参考に、各事業者の事業内容や AI ポリシー/AI 規定等の及び状況に合った独自のチェックリスト・ワークシートを作成・更新の上、有効活用することも重要となる (ワークシートについては掲載されている項目を必ずしも全て採用する必要はなく、自社に必要な項目を判断の上、活用する事が有効である)。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 の指針及び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依り、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、また、ワークシートには参考に AI 開発者、AI 提供者及び 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、広島 AI プロセスの「全ての AI 関係者向けの広島プロセス国際指針」 (本編・第 2 部・D に掲載) 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 提供者及び 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もと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、効果的な施策及び 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

本編同様以降は「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・表記する。

- 主体は、AI 開発者 (AI Developer) 、AI 提供者 (AI Provider) 及び AI 利用者 (AI Business User) の頭文字を用い、指針番号及び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

なお、表の「-」が記載されている箇所は、各主体による本編第 2 部 C. 「共通の指針」記載の事項にもと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.「共通の指針」に加えて主体毎に重要となる事項

	第 2 部. C.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 人間の尊厳及び個人の自律 ② AI による意思決定・感情の操作等への留意 ③ 偽情報等への対策 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・身体・財産、精神及び環境への配慮 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・身体・財産、精神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・身体・財産、精神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・サービスの構成及びデータに含まれるバイアスへの配慮	i. 入力データ又は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及び対策の導入 ii. プライバシー侵害への対策	i. 個人情報の不適切入力及び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及び規約の遵守
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 の学習及び利用の流れ

一般的に AI は、データをもと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 モデルを以て推論又は予測を行い、結果を出力するものである。特定の数値データ、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、画像又は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。アウトプットとして得たデータをインプット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又は元の 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 の学習及び利用の流れの例」参照）。

また、AI の学習においては、訓練データ、検証データ、テストデータといった複数のデータが段階的に用いられる。一方、利用段階ではユーザーからの入力等に相当する推論用データが用いられる（「表 2. AI の学習及び利用におけるデータ」参照）。

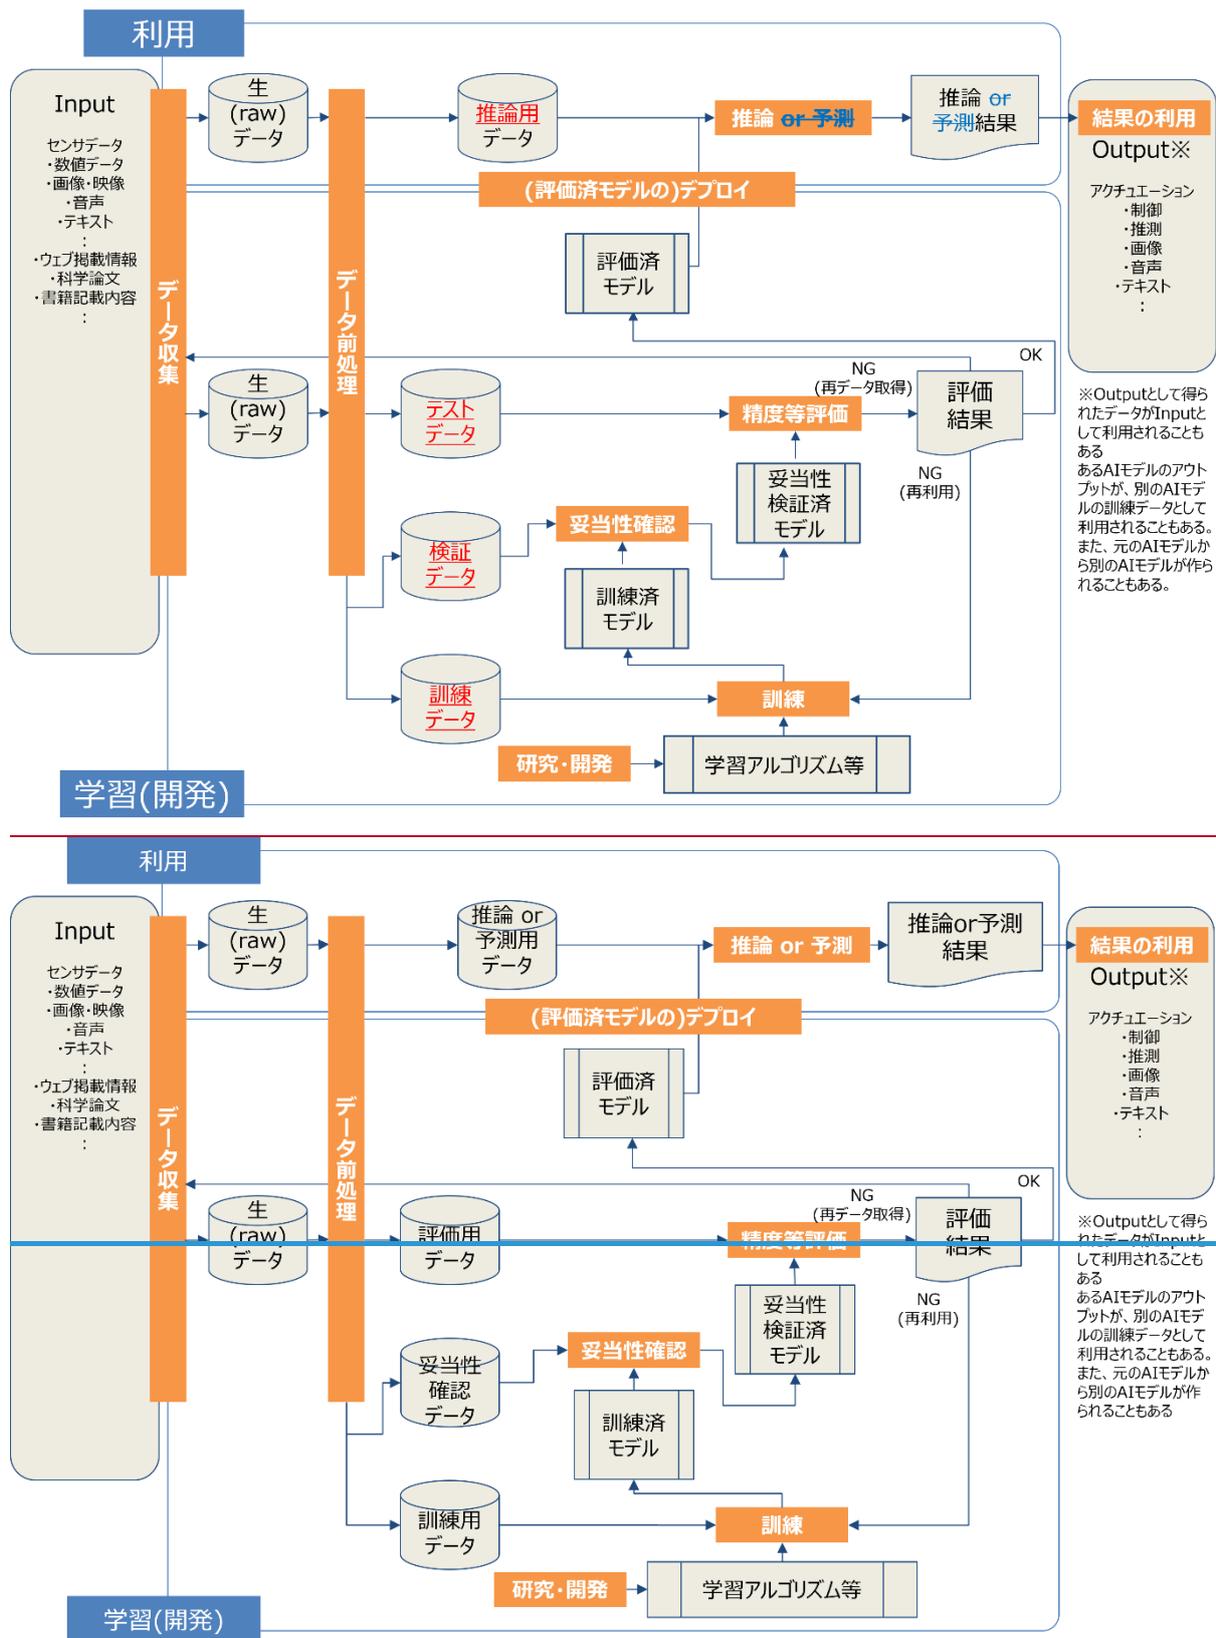


図 2. AI の学習及び利用の流れの例

表 2. AI の学習及び利用におけるデータ

	プロセス	概要	データ種類	概要	具体例
AI の学習及び利用の流れ	学習 (機械学習)	データを用いてモデルのパラメータを決定または改善するプロセス	訓練データ (training data)	モデルのパラメータを最適化するために使用するデータである。学習アルゴリズムはこのデータに基づいて誤差を最小化し、入力と出力の関係を学習する	<ul style="list-style-type: none"> <li>内部データ</li> <li>大規模オープンデータ (CIFAR-10, MNIST等)</li> <li>利害関係者などのデータ</li> <li>センサ、システムから収集されたデータ</li> </ul>
			検証データ (validation data)	モデルの学習過程において、訓練データとは別に使用されるデータである。モデルのパラメータの更新には使用されず、主にハイパーパラメータの調整や過学習の検出等、モデルの性能を中間的に評価するために用いられる。	
			テストデータ (test data)	モデル学習が完了した後にモデルの最終的な性能を評価するためのデータである。訓練や検証に使われていないため、適切な汎化性能の指標の基となる。	
	推論	学習済みモデルに未知のデータを与え、出力(予測・分類・生成など)を得るプロセス	推論用データ (data for inference)	推論用データとは、学習済みモデルが新しい入力に対して出力を生成する際に利用するデータである。これには、AIモデルが直接処理するユーザーからの指示や運用環境で取得されるデータに加え、文脈付与や精度向上のためにRAG等を通じて参照される内部データベースや外部知識などの追加情報が含まれる。これらを組み合わせることで、AIモデルの応答の正確性と一貫性を高められることが期待される。	<ul style="list-style-type: none"> <li>ユーザーからの入力 (プロンプト、画像、音声)</li> <li>運用環境で取得されるデータ (センサ取得データ等)</li> <li>内部情報 (FAQ、ナレッジベース)</li> <li>外部情報 (Web検索結果、外部API)</li> <li>コンテキスト情報 (過去の会話履歴、セッション情報)</li> <li>他モデルの出力 (別のAIモデルが生成したテキストや解析結果)</li> </ul>

## 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、テキスト等の入力に対し、アクチュエータ又は情報端末を介して出力する。なお、別添では、電動機、エンジン等の駆動装置又はその動作により制御を行う物理的な装置に加え、画像、音声、テキスト又は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、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<sup>1</sup>、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）。

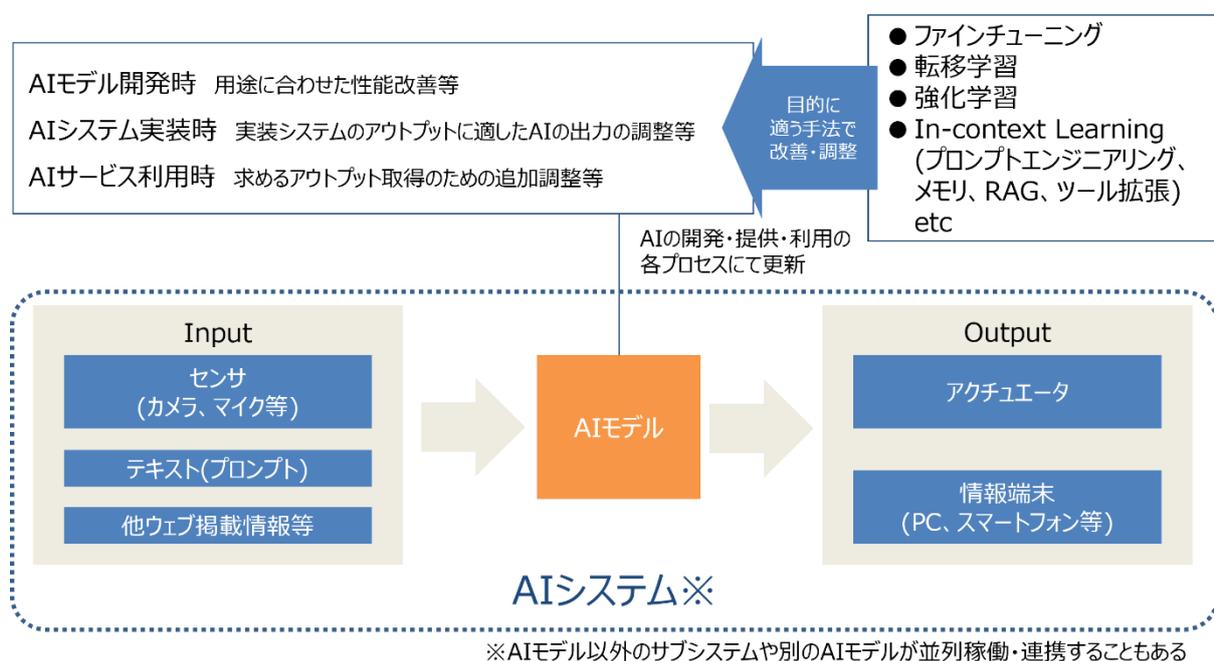


図 3. AI システム概要

<sup>1</sup> Patrick Lewis. "Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks" によると、RAG は、「事前学習されたパラメトリックメモリと非パラメトリックメモリ（すなわち検索ベースのメモリ）を組み合わせた言語生成モデル」と定義されている。企業において、社内文書やデータベース等を検索し生成 AI の回答の精度を高めることに使われているほか、インターネット上の情報をリアルタイムで検索し最新のデータを回答できるようにする目的でも活用されている。

## 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 モデルが既存又は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 システム又は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）<sup>2</sup>。

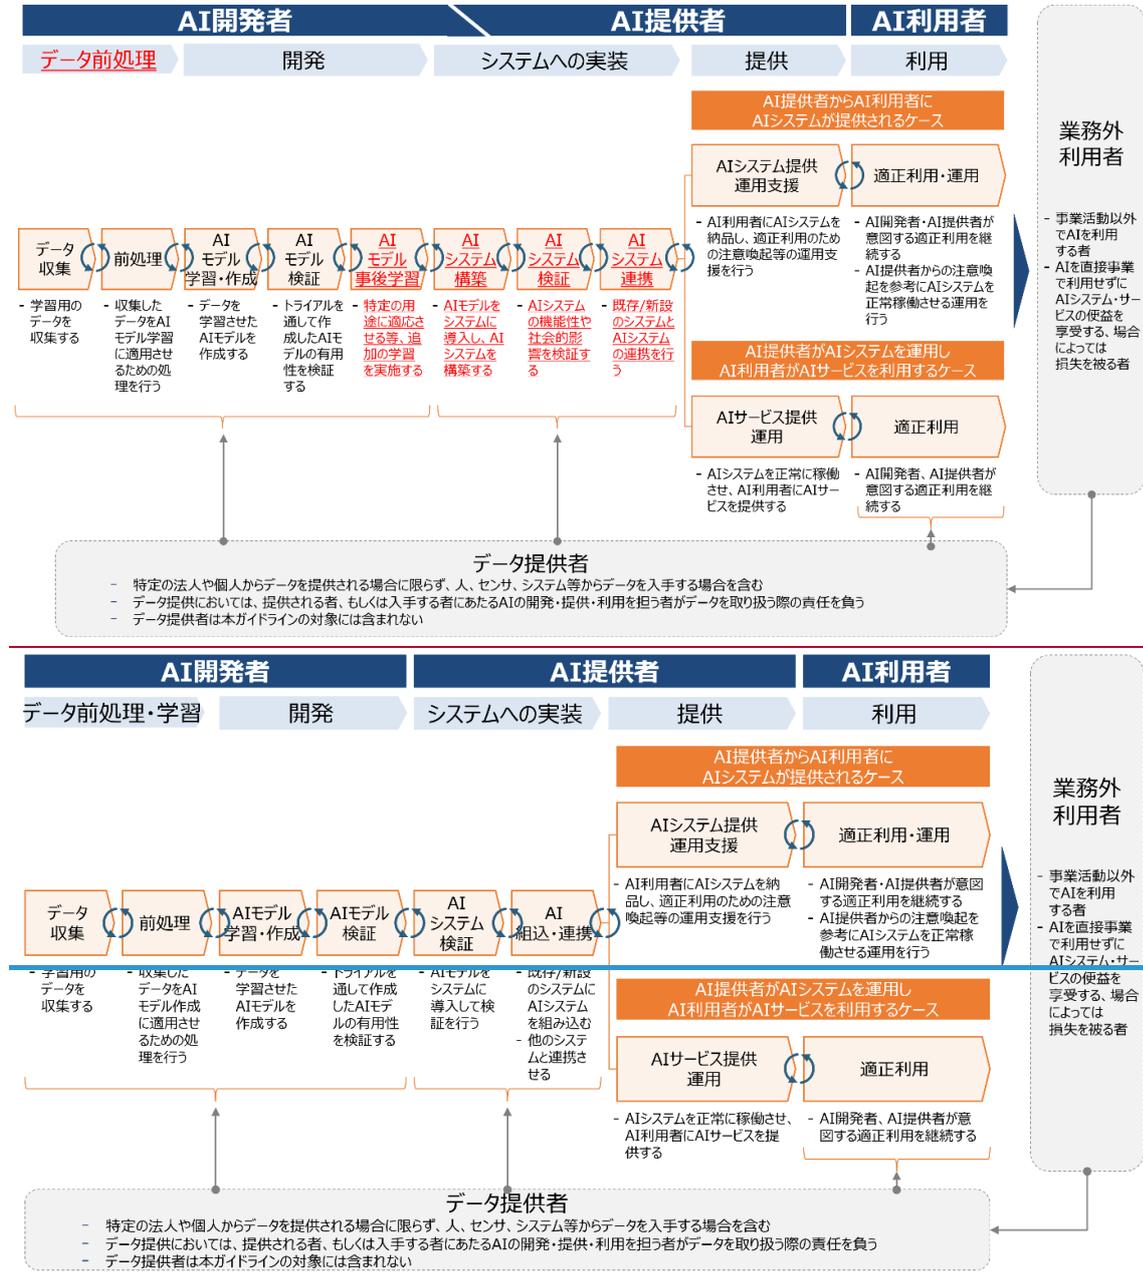


図 4. 一般的な AI 活用の流れにおける主体の対応

<sup>2</sup> AI システムの「運用」を行う主体は、その提供形態に応じ、「提供者」と「利用者」の両者がある。AI 利用者が、AI 提供者から AI システムの提供を受ける場合、そのシステムは AI 利用者の資産となるため、継続的な利用のための運用は利用者の役割と整理している。一方で、AI 提供者から AI サービスの提供を受ける場合、その AI サービスの提供に必要な AI システムは AI 提供者の資産であり、AI 利用者に譲渡されることはないため、AI システムの運用は AI 提供者の役割として整理している。

## AI システム・サービスの例

代表的な AI システム・サービスを「表 3. AI システム・サービス例表 2. AI システム・サービス例」に挙げる。

表 3. AI システム・サービス例<sup>3</sup>

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、 <b>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</b> 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（海外グループ企業を含む）より過去のエントリーシートデータ及び合否判定（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（システム部門及び人材開発部門）	A 社グループ（人材採用部門）	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運営する J 社が提供する <b>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）</b> 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 システム開発部及びコンビニ事業部）	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、「 <b>本人の病歴・遺伝等に係る情報（データ 1）</b> 」及び「 <b>内視鏡画像（データ 2）</b> 」を取込み、 <b>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</b> 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（システム部門及び消化器内科）	受診患者
不良品検知 AI	画像解析	<b>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」</b> 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。 <b>A 工業の工場</b> で生産される <b>完成品（工業用部品）について外観上の不具合を識別</b> 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」及び「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）	-

<sup>3</sup> 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」より一部抜粋引用。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	<p><b>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。</b>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。撮影はドローン又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及び報告書作成が実施される。</p>	X 社 (AI 開発部)	P 社 (システム部門及び電力サービス保全部)	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	<p><b>AI モデルが環境情報、ユーザーの行動等を解析し、スマート家電を最適化する。A 社の AI サービスは、ユーザー搭載したセンサ情報（ユーザーの位置・状態、温度、湿度、照度及び CO2 濃度）、オープンデータ（気象情報）及びユーザー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。</b> AI 提供者は A 社（アプライアンス事業部）だが、代理店の場合もあり、消費者への説明等業務内容に応じた対応が求められる。</p>	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	<p><b>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>B 社の社員は対話型 AI に対してプロンプト（指示又は質問）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及び用途にて利用され、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生成 AI のモデルを活用して B 社のグループ会社である 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（C 社含む）に対して提供している。</p>	A 社	B 社のグループ会社 C 社	B 社グループ社員（C 社含む）	-

社内ナレッジ検索支援 AI	テキスト等生成	製造業の E 社向けに提供されている、社内文書を活用した質問応答支援システムである。E 社が所有するマニュアル、トラブル対応記録、過去の保守履歴などを対象に、自然言語での問い合わせに対応するチャットボットとして設計されている。 このサービスは、F 社が開発した大規模言語モデルをベースに、E 社固有の社内文書を用いてファインチューニングを実施することで、E 社の業務特性に最適化された回答を実現している。	F 社 (AI モデル開発部門) E 社 (ソリューション開発部門)	E 社 (ソリューション開発部門)	E 社 (情報システム部)	ニ
プログラミング支援 AI	コード生成	AI モデル開発会社 D 社が提供する、ユーザーの入力に基づいてプログラミングコードの自動生成や既存コードの修正支援、バグ検出やコード品質の改善案の提示などを行うサービスである。コード生成 AI サービスは開発支援ツールとして利用されており、サービス全体の設計・運用も D 社が実施している。 本サービスの AI 利用者である、ソフトウェア開発を行う H 社は、D 社のコード生成 AI サービスによるプログラム作成支援を受けながら、独自の AI システム構築を行い、特定業務向けの AI サービスを実装した。このように H 社は AI 利用者でありながら AI 提供者としての区分も兼ねており、新規開発した AI サービスの保守・運用の役割も担う。	D 社 (AI 開発部門)	D 社 (プロダクト提供部門) H 社 (ソフトウェア開発部門)	H 社 (ソフトウェア開発部門)	ニ
売上予測 AI	テキスト等生成	小売業の I 社向けに提供される、店舗・商品別の売上予測を行う社内向け AI サービスである。このサービスは、過去の販売実績データや天候、販促施策、カレンダー情報などをもとに、週次・月次の売上を商品単位で予測し、在庫計画や発注業務の効率化を支援している。 サービスは Rest API として提供されており、売上予測モデルの API 仕様策定は A 社が担当。エンドポイント構成、パラメータ定義、リクエスト形式（例：対象店舗、商品 ID、予測期間など）、およびレスポンス形式（例：予測売上、予測精度指標など）が定められている。API コールの実装および社内システムへの統合は P 社が担当。店舗ごとの販売管理システムや在庫管理システムから自動的に API が呼び出されるように構成されており、店舗担当者や MD（マーチャンダイザー）が日常業務の中で自然に AI 予測の結果を活用できるようになっている <sup>4</sup> 。	A 社 (AI モデル設計部門)	P 社 (システム導入部門)	I 社 (経理部門)	ニ

<sup>4</sup> AI モデルを API として設計・提供する場合、AI 開発者は主に API

AI エージェント作成サービス	ワークフロー作成	AI 提供者である X 社が提供する AI エージェント（ワークフロー）作成サービスである。本サービスは、利用者が業務プロセスに沿ったワークフローを独自に構築し、そのワークフローに従って自律的に動作する AI エージェントを作成することができる。このサービスに用いられる AI モデルは、AI 開発者である Y 社が開発したものであり、API を通じて本サービスに呼び出され、ワークフロー内での判断や意思決定を担っている。 本サービスの AI 利用者であるソフトウェア開発企業 Q 社は、X 社の AI エージェント作成サービスを用いて独自のワークフローを設計し、業務に特化した AI エージェントを構築した。このように Q 社は AI 利用者であると同時に、構築した AI エージェントを自社サービスとして提供する AI 提供者としての区分も兼ねており、保守・運用の役割も担う。	Y 社 (AI モデル開発部門)	X 社 (サービス運営部門) Q 社 (サービス開発部門)	Q 社 (サービス開発部門)	=
旅行先提案・予約 AI エージェント	AI エージェント	航空会社 G 社が提供する、ユーザーの希望条件に応じて最適な旅行先とフライトオプションを提案し、外部予約システムと連携して実際の便予約まで行う AI エージェント型サービスである。 本サービスは、従来の FAQ 応答型や予約サポート型 AI とは異なり、ユーザーの要望に応じた目的地提案だけでなく、社内外システムと連携し、空席確認・便選択・予約確定までを一連で実行可能とする点が特徴である。 本サービスの開発においては、G 社プロダクト開発部門が、G 社が開発したモデルを組み込んだ AI エージェントのワークフローや、外部 API の呼び出し設計、外部システムとの物理的な連携・認証・インフラ構築など、サービス全体の安定運用に必要な実装と運用管理を担当した。	G 社 (AI システム開発部門)	G 社 (プロダクト開発部門)	=	旅行予約者
営業・CS 支援 AI エージェント	AI エージェント	営業やカスタマーサポート部門において、見込み客への対応から商談進捗の管理、お問い合わせ対応までを 24 時間自律的に支援する業務支援型 AI エージェントである。 本サービスは CRM（顧客管理システム）や SFA（営業支援システム）と連携し、単なる質問回答にとどまらず見込み顧客の管理から商談スケジュールの自動調整、パーソナライズされたメールの配信まで、自律的に複雑な業務を一連で実行し、営業担当者の負担を大幅に軽減するものである。 Z 社の AI エンジン開発部門は自然言語処理やモデルのファインチューニングを担い、プロダクト開発部門は AI エージェントのワークフロー設計や、CRM・SFA との連携、ユーザーインターフェース設計を担い、サービスとして提供している。	Z 社 (AI エンジン開発部門)	Z 社 (プロダクト提供部門)	Y 社 (営業部門)	=

自動運転システム	フィジカル AI	自動車メーカー H 社が提供する、 <b>自動運転技術を搭載した車両制御システム</b> である。ユーザーが目的地を指定すると、車両は周囲環境を認識し、走行経路を自律的に計画・実行する。交通状況や道路標識、障害物をリアルタイムで検知し、安全かつ効率的な運転を実現する。 本サービスの開発においては、H 社 AI アルゴリズム開発部門が深層学習を用いた経路計画モデルを開発し、同社車両開発部門が車両制御システムへの統合、センサー・カメラとの連携、認証・安全基準対応、インフラ構築を担当した。	H 社 (AI アルゴリズム開発部門)	H 社 (車両開発部門)	ニ	運転者
自律移動ロボット	フィジカル AI	物流企業 J 社が提供する、 <b>自律移動ロボットによる倉庫内搬送サービス</b> である。ロボットは倉庫内の地図を認識し、最適なルートを自律的に選択して荷物を搬送する。障害物回避や複数ロボット間の協調動作を行い、作業効率を大幅に向上させる。本サービスは、従来の AGV（無人搬送車）と異なり、固定ルートではなく動的な経路計画を行い、リアルタイムで環境変化に対応できる点が特徴である。 本サービスの開発においては、J 社ロボティクス AI 開発部門がロボットの自己位置推定技術や経路最適化アルゴリズムを開発し、同社物流システム開発部門がロボットのハードウェア設計、倉庫管理システムとの連携、運用管理を担当した。	J 社 (ロボティクス AI 開発部門)	J 社 (物流システム開発部門)	O 社 (倉庫管理部門)	ニ

## 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<sup>5</sup>にも便益が提供されるパターン 1、AI 利用者が利用して便益を得るパターン 2、及び AI 提供者から提供された 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。

なお、AI の利活用の形態は多様であり、以下の図「AI 事業者のパターン」はあくまで代表的なパターンの一  
例として認識することが期待される。

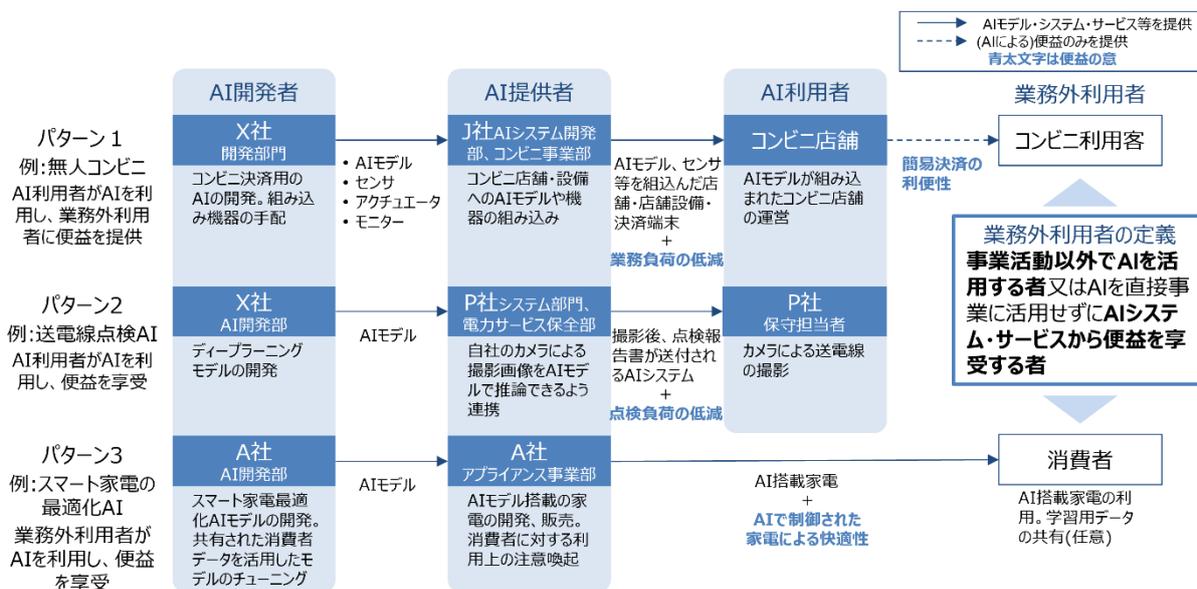


図 5. AI 事業者のパターン

<sup>5</sup> 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（本ガイドライン本編にて定義）。

## 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モデルの学習又はAIの利用がなされる。データを用いたAIモデルの構築又は利用に際し、AI開発者、AI提供者又は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、特定の法人若しくは個人から提供されるデータ又は人、センサ、システム等のデータを利用するケースもある。データの扱いは種類ごとに異なり個別に記載しきれないため、データを提供される者又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（「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際は、別添 6 及び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。

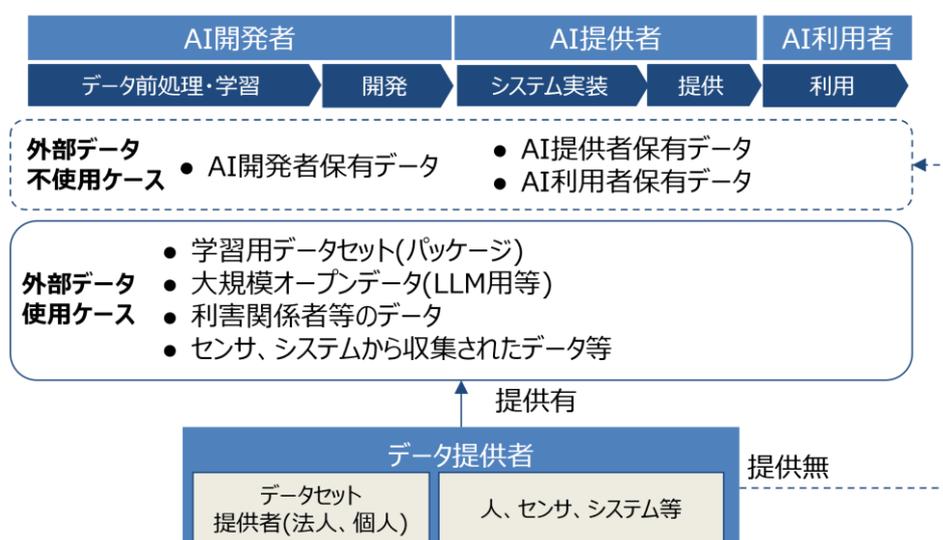


図 6. データ提供の在り方

## 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。なお、リスクへの対策を検討する際には、当該対策の実行可能性も考慮し、限られた資源を効果的に配分することが望ましい。

### 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。一例として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
- 人が対応することが困難な時間的・場所的領域へのサービス拡大

さらに、様々な分野（農業、教育、医療、製造、輸送 等）への応用及び様々な展開モデル（クラウドサービス、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<sup>6</sup>。

#### 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。

<sup>6</sup> 「ISO/IEC TR 24030」には、このような領域及び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。

	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	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
生成AIで更に向上 (一部AIエージェントやフィジカルAIで更に向上)	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 顧客の成約・解約率予測	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、AIエージェント、フィジカルAI特有の便益の例	学習データの生成、コーディングアシスタント、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	過去実績に基づいた将来予測、不正検知 経費精算アシスタント(自動仕訳、申請レビュー、証憑取得等)	職務履歴に基づいた人材需要マッチングAI採用アシスタント(面接・評価)
	コーディングアシスタント(コード生成、不具合の自動修正等)	投稿から分析までを自律的に行うSNS運用エージェント	店頭ロボットによる接客・販売	自律搬送ロボット・ドローンによる自動配送	過去の問合わせ内容に基づいたFAQ自動作成	類似事例検索及び重要判例の自動要約	投資レポート・市場分析の自動生成	パーソナライズされたキャリアプラン提案

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及び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、給与計算の自動化及び職務経歴書にもと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。

また、企業以外においても、行政における手続きの自動化、センサ及び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。

加えて、AI の活用による便益は社会にも波及し得る<sup>7</sup>。

### 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して期待されている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、きめ細やかなサービス及び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、組織及び業界横断的な OT データの活用、それらのサービス、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及びケース作り、それらを踏まえた開発等、多くの工数及び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、これらのシナリオ及び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及びセールスの対応に生成 AI で回答並びに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。

<sup>7</sup> 例えば、アクセシビリティ向上を通じた障がい者の社会参加促進・多言語対応サービスを通じた多文化共生の促進・熟練技能のデジタル化を通じた技術継承の促進といった便益が AI によりもたらされ得る。

また、入力された問い合わせ及び顧客の要望に対し、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。

さらに、マルチモーダルな生成 AI により、テキスト・音声・画像・動画・センサ情報など、二つ以上の異なるモダリティ（データの種類）から情報を収集し、それらを統合して処理することが可能である生成 AI（以下、マルチモーダルな生成 AI）が台頭している。マルチモーダルな生成 AI の登場により、医療・創薬・教育・エンターテインメントなど AI の活用範囲が広がることや、推論・分析など生成以外の一般的なタスクにおける処理能力も向上すること等が期待されている。

また、RAG（検索拡張生成）の活用も広がっている。LLM による言語生成に外部情報の検索を組み合わせることによるハルシネーションの抑制、参照する情報源を指定した検索や出力文における参照元の明示等が可能となることによる出力過程・根拠の透明性向上、通常のファインチューニングと異なりモデルの再トレーニングを行うことなく参照するデータソースを追加できることによるコストの低減等が期待されている。

生成 AI のプログラムコード生成への活用も進んでいる。低コストかつ迅速なコードの生成が可能となることや、ヒューマンエラーを回避できること、高度な技能・知識がなくてもプログラミングを行えるようになること等が期待されている。

加えて、AI エージェントの登場により、ユーザーの意図を理解し、自律的にタスクを遂行することで、複雑な業務プロセスを効率化し、人的負荷を大幅に削減できる。単なる指示実行にとどまらず、複数のシステムやアプリケーションと連携し、状況に応じた判断や最適化を行うことで、従来は人手に依存していた調整・分析・意思決定を自動化することが可能となる。自律的な AI システム（以下、AI エージェント）も登場している。従来型の AI や生成 AI に比べより高度な効率化や自動化が可能となることで、生産性の向上につながること等が期待されている。

最後に、フィジカル AI は、少子高齢化による労働力不足を補い、人と協働して生産性を向上させることで、あらゆる産業や現場の自動化と効率化に寄与することが期待される。危険な環境で人の代わりに作業を行い、安全性を高めつつリスクを低減するほか、介護や生活支援を通じて人々の自立と QOL 向上に寄与し、福祉や医療などの分野で新たな支援の創出にもつながり得る。

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、利用の拡大及び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<sup>8</sup>。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、想定にもと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

<sup>8</sup> 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, “The AI Incident Database (AIID)”, <http://incidentdatabase.ai> が参考となる。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。

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<sup>9</sup>。むしろ、当該リスクを認識し、リスクの許容性及び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。

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<sup>10</sup>及び社会全体に発生するリスクも検討対象となる。また以下では、事業者単体での対応が難しく政府等の公的機関も含めた社会全体での対応・議論が必要となるリスクも含め、諸外国での議論等も参考に記載している。そのため、事業者においてすべてのリスクに直ちに対処しようとする必要はないが、社会において発生する可能性のある事象として認識しておくことが重要である。

#### データ汚染攻撃等の AI システムへの攻撃

- AI の学習実施時では性能劣化及び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 の推論結果又は 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<sup>11</sup>。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
- 間接プロンプトインジェクションやマルウェアの生成、悪意ある目的で行われるファインチューニングなど、悪意のある第三者により、RAG が悪用されたり、AI モデルに設定された制御等を無視した悪意のある出力が行われたりするリスクがある
- 生成 AI をシステム開発に用いる場合、自然言語が直接ソースコードや設計情報に変換されるため、入力情報の信頼性がシステムの安全性に直結するリスクがある
- AI エージェントやマルチモーダルな生成 AI、フィジカル AI 等の複雑で多様な情報を扱うシステムでは、より多様な入力経路や外部連携が増えるため、被攻撃対象が拡大し、データ汚染や悪意あるプロンプト攻撃のリスクがさらに高まる懸念される

#### バイアスのある出力、差別的出力、一貫性のない出力等

- AI モデル学習時のデータに、特定の属性が過剰に含まれている場合や、ラベル付与者の主観的なバイアスが含まれている等の場合、出力に偏りが生じることがある。例えば、学習データに特定の趣味嗜好を持つ顧客のデータが過剰に含まれている場合、おすすめとしてその嗜好に偏った商品ばかりを提示し、他の顧客層に不適切な提案を行ってしまうおそれがある。その結果、ユーザー体験の低下や、場合によっては消費者からの苦情・クレームにつながるリスクも生じ得る。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

<sup>9</sup> 諸外国の法令等にも留意すべきである。例えば、2024 年 5 月 21 日に成立した EU の「AI 法（Artificial Intelligence Act）」では、人の生命及び基本的人権に対して、直接的に脅威をもたらすと考える 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）、政府による社会的な格付け、危険な行動を促す音声アシスト等については、容認できないリスクを伴う「禁止される AI（Prohibited AI）」と定義され、上市、実用化及び利用が禁止されている。その他の国の AI に関する法令・政策等については、OECD，“National AI policies & strategies”，<https://oecd.ai/en/dashboards/overview> が参考となる。

<sup>10</sup> AI 開発者、AI 提供者、AI 利用者及び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）。

<sup>11</sup> AI システム・サービスのセキュリティ脅威・リスクの類型については、米国を対象とした以下のレポートが公開されている。

IPA「米国における AI のセキュリティ脅威・リスクの認知調査レポート」（2024 年 5 月）  
<https://www.ipa.go.jp/security/reports/technicalwatch/20240530.html>

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

- AI が同じ基準やポリシーで運用されているにもかかわらず、モデルの確率的性質に起因して、場面によって異なる判断を下すことがある

#### ハルシネーション等による誤った出力<sup>12</sup>

- 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毀棄損で提訴した
- AI エージェントの場合、自律的な動作の中で人間の意図しない商品の注文やファイル削除等の動作を行う可能性がある<sup>13</sup>

#### ブラックボックス化、判断に関する説明の不足

- 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及び女性に対して、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及び動作について説明することができなかった
- マルチモーダルな生成 AI、AI エージェント、フィジカル AI など複雑な構成や機構を持つ AI システムの場合、通常の AI システムに比べメンテナンスやトラブルシューティングの難易度が上がる場合がある

#### 個人情報の不適切な取扱い等

- 人材採用に AI を用いるサービスにて、選考離脱及び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、一定の期間において、一時期同意にもとづいて第三者への情報提供が行われる規約となっていなかったこと等、透明性を欠く個人情報の利用が問題視され、サービスが廃止されることとなった事例が発生している
- マルチモーダルな生成 AI により、テキスト情報だけでなく、個人の顔写真や録音音声といったセンシティブな情報も取り扱われる機会が増加し、これらの情報が漏洩するリスクが一層高まる可能性がある
- カメラや音声認識等を通じて周囲の映像や音声を収集する過程で、個人情報を取得することとなる場合には、利用目的の通知又は公表等の対応が必要となるほか、目的の正当性や手段の必要性及び相当性を欠く態様で情報の保存、解析及び利用等が行われた場合には、肖像権等のプライバシー権を侵害するリスクがある

#### 生命等に関わる事故の発生

<sup>12</sup> 画像生成 AI の場合は、ハルシネーションによって、自身が想定していたものとは異なるものが創出されることによる発見や想像もある。また、創業プロセスのタスク等においてハルシネーションにより予測精度を高めるとの研究結果も登場している。

<sup>13</sup> なお、AI エージェントの自律性が高まるにつれ、人間による監視のみでは高速な AI 間相互作用への対応が困難となる場合が十分に想定される。今後、AI システム間の相互監視等、AI の自律性に対応した新たな安全確保アプローチについても検討が期待される。

- 例えば、AI が不適切な出力を生成する判断を下すことで、自動運転車が事故を引き起こし、生命及び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<sup>44</sup>

#### 差別的出力トリアージにおける差別

- 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

#### 過度な依存

- 人材採用活動等、重要な意思決定を行う場面において AI による判断をそのまま用いることや、人が最終判断する際にも AI システムによる判断を過度に人間が信頼し、自らの判断や確認を怠ってしまう（自動化バイアス）可能性を考慮していないなど、意思決定や意思決定支援を AI に委ねることが懸念される。このような AI への過度な依存により、事業者が説明責任を問われることや批判を受けることに繋がり得るなど AI の不適切かつ過剰な使用により、企業が説明責任を問われたり批判を受けたりする事例が発生している
- また、生成 AI を用いたチャットボットサービスと会話をしていた利用者が、AI の助言により自殺してしまうなど、AI に心理的に依存してしまうに対し精神的な依存状態となった事例が報告されている
- 教育においても、学生の独自性や批判的思考の発展が妨げられるリスクが懸念されている。例えば、生成 AI が作成した答案やレポートをそのまま用いることで、学生自身が情報を探索し、問いを立て、根拠を検討するプロセスを省略してしまい、結果として独自の思考力を育む機会が減少する可能性がある
- 教育分野においては、教室内で学童の表情をモニターしその心理状態を判断して教員による指導に活用する海外の例などがあり、AI システムを活用する上での適切性について慎重な検討が必要である

#### 悪用

- 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が問題となっている。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

<sup>44</sup>このような可能性も踏まえ、自動運転の社会実装にあたり、AI がより適切な判断を下せるようにすることなどより安全性を高める等の観点からデジタル庁において「AI 時代における自動運転車の社会的ルールの在り方検討サブワーキンググループ」が設置されている。本サブワーキンググループでは、事故発生時のデータだけでなく、それ以外の走行データ（ニアミス等）も含めて収集し、関係者で共有・分析する仕組みを構築することや、より適正なプログラム作成に資するようルールの明確化・具体化を図ること等の提言をとりまとめており、それを受けて関係省庁が検討を進めている。

その他デジタル庁では、デジタル社会推進会議令第 4 条の規定に基づき、自動運転、ドローン、サービスロボットなど地域のモビリティを支える技術の同時かつ一体的な事業化に向けた「モビリティロードマップ」の策定を推進するため、モビリティワーキンググループを開催している。

AI 時代における自動運転車の社会的ルールの在り方検討サブワーキンググループ

<https://www.digital.go.jp/councils/mobility-subworking-group>

モビリティワーキンググループ

<https://www.digital.go.jp/councils/mobility-working-group>

れたものの、この声は AI を用いて生成されたものであり、誘拐を偽装した詐欺の電話であったことが判明した

- 昨今のコード生成 AI や AI エージェントの進歩により、コードの生成が容易になり、その悪用が問題視されている。例えば、セキュリティホールを狙うマルウェアの作成や、ネットワークに侵入するためのエクスプロイトコードを生成することが可能になっている。このような技術の悪用は、個人情報情報の漏洩や重要インフラに関するシステムの停止・情報の改ざん等に繋がる可能性があり、深刻なサイバーセキュリティ上の問題となっている

### 知的財産権等の侵害

- 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<sup>14</sup>
- また、画像以外でも生成 AI による文章などの生成物が他者の知的財産権等を侵害する可能性がある。例えば生成 AI で機械等のプログラムコードを生成するケースにおいても、生成したコードが他者の知的財産権等を侵害する可能性に留意する必要がある<sup>15</sup>

### 金銭的損失

- 企業においては、自社の扱う AI システム・サービスの出力により他者の権利を著しく侵害した場合等において、損害賠償請求など金銭的な責任を問われることがある
- AI を悪用した攻撃によって内部システムが破壊されたり、機密情報が漏洩したりすると、システム復旧費用や関連するステークホルダーへの補償費用等の金銭的負担が発生するリスクがある

### 機密情報の流出

- AI の利用においては、個人情報、自社のナレッジや知的財産等の及び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

<sup>15</sup> 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 にもとづき、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。知的財産関連法令との関係については内閣府、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 と著作権に関する考え方については、文化審議会著作権分科会法制度小委員会にて取りまとめている。また、「AI 時代の知的財産権検討会 中間とりまとめ」及び「AI と著作権に関するチェックリスト & ガイダンス」では、本ガイドラインと異なり、「AI 開発者」、「AI 提供者」及び「AI 利用者」に加えて、「業務外利用者（一般利用者）」及び「権利者」も対象にして、各主体に期待される取組事項例等を整理している。各主体においては、その趣旨を踏まえた対応方針を検討することが重要となる。

・文化庁「AI と著作権に関する考え方について」（文化審議会著作権分科会法制度小委員会、2024 年 3 月）

[https://www.bunka.go.jp/seisaku/bunkashingikai/chosakuken/pdf/94037901\\_01.pdf](https://www.bunka.go.jp/seisaku/bunkashingikai/chosakuken/pdf/94037901_01.pdf)

・内閣府「AI 時代の知的財産権検討会 中間とりまとめ」（知的財産戦略推進事務局、2024 年 5 月）

[https://www.kantei.go.jp/jp/singi/titeki2/chitekizaisan2024/0528\\_ai.pdf](https://www.kantei.go.jp/jp/singi/titeki2/chitekizaisan2024/0528_ai.pdf)

・文化庁「AI と著作権に関するチェックリスト & ガイダンス」（文化庁著作権課、2024 年 7 月）

[https://www.bunka.go.jp/seisaku/chosakuken/pdf/94097701\\_01.pdf](https://www.bunka.go.jp/seisaku/chosakuken/pdf/94097701_01.pdf)

・内閣府「AI 時代の知的財産権検討会 中間とりまとめ 手引き（権利者向け）」（知的財産戦略推進事務局、2024 年 11 月）

[https://www.kantei.go.jp/jp/singi/titeki2/chitekizaisan2024/2411\\_tebiki.pdf](https://www.kantei.go.jp/jp/singi/titeki2/chitekizaisan2024/2411_tebiki.pdf)

まう事例が明らかになっている。生成 AI 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。また RAG の活用など外部のサービス・データ等と連携する場合は、意図しない範囲に重要情報（個人情報・機密情報等）が漏洩してしまうこと等に特に注意が必要となる。加えて、生成 AI を用いて生成したプログラムコードにセキュリティ上の脆弱性等が含まれていた場合、情報の改ざんや漏洩等につながる恐れがある。ただし、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、代わりにそのようなサービス又はアプリケーションを使用することが推奨される

- AI エージェントでは、外部システムやクラウドサービスと自律的に連携して各種タスクを実行するケースが増えており、その過程で、脆弱性を突かれた攻撃等によってエージェントの挙動が不正に操作され、内部データが意図せず外部に送信されるなど、機密情報が漏洩する可能性がある

#### 労働者の失業

- 生成 AI や AI に関連する AI 等の新たなテクノロジーは、仕事の内容（タスク）及び労働者の役割を変化させつつある。仕事の内容（タスク）を変化させ、労働者の役割を変化させることが想定される。生成 AI や AI 関連のテクノロジーの導入により、労働者の業務負担の軽減や、労働生産性の向上が期待できる一方、失業リスクや格差の拡大なども一部では懸念されている<sup>16</sup>

#### データや利益の集中

- 一部の AI 開発者のみにデータや利益が集中する、少数言語国では自国言語による高性能な AI が存在しないと課題が指摘されている<sup>17</sup>

#### 資格等の侵害

- 生成 AI が法律や医療など、業法免許や資格が必要な領域で助言や回答を行う場合、本来は有資格者に限定される業務を無資格で行うことに該当し、法令違反と見なされる可能性がある生成 AI の活用を通じた業法免許及び資格等の侵害リスクも考える。例えば、生成 AI が法律又は医療の相談に回答する場合、業法免許及び資格の侵害が生じ、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、新たなサービス及び効率向上が制限される可能性もある

#### 偽・誤情報等の流通・拡散

- 生成 AI が生み出す情報を鵜呑みにした結果、それが誤情報であるリスクがある。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、偽画像及び偽動画を使った情報操作並びに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 及びインターネットで瞬間に拡散した事例も見られた。一部の海外のメディア及び大手金融メディアを装っ

<sup>16</sup> 厚生労働省「雇用政策研究会報告書」（雇用政策研究会、2024年8月）より引用  
<https://www.mhlw.go.jp/content/11602000/001294201.pdf>

<sup>17</sup> 内閣府「『AI 制度に関する考え方』について」（AI 戦略会議、2024年5月）より引用  
[https://www8.cao.go.jp/cstp/ai/ai\\_senryaku/9kai/shiryo2-1.pdf](https://www8.cao.go.jp/cstp/ai/ai_senryaku/9kai/shiryo2-1.pdf)

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。事件及び事故・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

### 民主主義への悪影響

- 海外では、SNS の業務外利用者に提供した「性格診断アプリ」及びプロフィール情報をもと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、収集したデータをもとにして、「平均的市民よりも衝動的怒り及び陰謀論に傾きやすい集団」、「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
- **また**各国の選挙において、他の候補者の偽・誤情報やディープフェイクを生成・拡散する事例が発生している

### フィルターバブル及びエコーチェンバー現象

- 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及び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・包摂性の喪失

- 社会全体が同じモデルを、同じ使い方を使った場合、導かれる意見及び回答が 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。なお、RAG を活用した場合には、回答品質の向上等の便益が得られる一方、生成 AI による回答の収束が加速し、多様性がさらに失われる可能性が指摘されている。また、金融取引において共通したアルゴリズムが用いられ、リスク評価やリスク判断が自動化・画一化されることで、金融市場の不安定性が増すことが懸念されている

### バイアス等の再生成

- 生成 AI は既存の情報にもと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、不公平及び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もとづいて回答が作られた場合、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

### エネルギー使用量及び環境の負荷

- 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。特にマルチモーダルな生成 AI など計算量の多いモデルでは環境への影響が大きくなる場合がある。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 1 人の 1 年あたりの二酸化炭素排出量の何十倍にもなるとの指摘もある<sup>18</sup>。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

<sup>18</sup> Stanford University, “AI Index Report 2025<sup>3</sup> - Artificial Intelligence Index”, <https://aiindex.stanford.edu/report/#individual-chapters>

これらのリスクを、事業者ができる限り網羅的に把握し対策を検討することを可能とすべく、体系的に整理した<sup>19</sup>。(表 4. AI によるリスク例の体系的な分類案表 3. AI によるリスク例の体系的な分類案)

表 43. AI によるリスク例の体系的な分類案

- ・下表は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
- ・下表には政府等の公的機関も含めた社会全体での対応・議論が必要となるリスクも含まれる

大分類	中分類	リスク例
<b>技術的リスク</b> (=主にAIシステム特有のもの)	学習及び入力段階のリスク	データ汚染攻撃等のAIシステムへの攻撃
	出力段階のリスク	バイアスのある出力、 <b>差別的出力</b> 、一貫性のない出力等 ハルシネーション等による誤った出力
	事後対応段階のリスク	ブラックボックス化、判断に関する説明の不足
<b>社会的リスク</b> (=既存のリスクがAIにおいても発生又はAIによって増幅するもの)	倫理・法に関するリスク	個人情報の不適切な取扱い等
		生命等に関わる事故の発生
		<b>差別的出力</b> トリアージにおける差別
		過度な依存
	経済活動に関するリスク	悪用
		知的財産権等の侵害
		金銭的損失
		機密情報の流出
		労働者の失業
		データや利益の集中
	情報空間に関するリスク	資格等の侵害
		偽・誤情報等の流通・拡散
民主主義への悪影響		
フィルターバブル及びエコーチェンバー現象		
環境に関するリスク	多様性・包摂性の喪失	
	バイアス等の再生成	
	エネルギー使用量及び環境の負荷	

さらに、上記のリスクを事業者におけるリスクへの対策の検討に結び付けるべく、各リスクに対応する主な共通の指針と、事業者における対策の例を記載した（記載した共通の指針以外にも、関係する共通の指針が存在しうる。）。（表 5. AI によるリスク例と共通の指針及び主体毎に重要となる事項のマッピング表 4. AI によるリスク例と共通の指針及び主体毎に重要となる事項のマッピング）

なお、主体毎の対応策及び具体的な手法等については、本編第 3 部～第 5 部の該当部分及び別添 3～5 の該当部分を参照することが望ましい。

<sup>19</sup> なお分類の枠組みの検討にあたっては、国内外における様々な分類の手法を調査・分析した。例えば、NIST AI Risk Management Framework (AI RMF 1.0) や、羽深宏樹氏「AI ガバナンス入門」における分類等を参考にして分類を実施した。

表 54. AI によるリスク例と共通の指針及び主体毎に重要となる事項のマッピング

・下表は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  
 ・下表には政府等の公的機関も含めた社会全体での対応・議論が必要となるリスクも含まれる

リスク例	関連する共通の指針	「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	第4部 AI提供者	第5部 AI利用者
データ汚染攻撃等のAIシステムへの攻撃	5) セキュリティ確保	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
バイアスのある出力、差別的出力、一貫性のない出力等	1) 人間中心 ①人間の尊厳及び個人の自律 ③偽情報等への対策			
ハルシネーション等による誤った出力	2) 安全性	i. 適切なデータの学習 ii. 人間の生命・身体・財産、精神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・身体・財産、精神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	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・サービスの構成及びデータに含まれるバイアスへの配慮	i. 入力データ又はプロンプトに含まれるバイアスへの配慮
	8) 教育・リテラシー			
ブラックボックス化、判断に関する説明の不足	6) 透明性	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	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及び規約の遵守
個人情報の不適切な取扱い等	1) 人間中心 ①人間の尊厳及び個人の自律 ②AIによる意思決定・感情の操作等への留意			
	4) プライバシー保護	i. 適切なデータの学習	i. プライバシー保護のための仕組み及び対策の導入 ii. プライバシー侵害への対策	i. 個人情報の不適切入力及びプライバシー侵害への対策
生命等に関わる事故の発生	2) 安全性	i. 適切なデータの学習 ii. 人間の生命・身体・財産、精神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・身体・財産、精神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
差別的出力トリアージにおける差別	1) 人間中心 ①人間の尊厳及び個人の自律 ②AIによる意思決定・感情の操作等への留意			
過度な依存	2) 安全性	i. 適切なデータの学習 ii. 人間の生命・身体・財産、精神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・身体・財産、精神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	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・サービスの構成及びデータに含まれるバイアスへの配慮	i. 入力データ又はプロンプトに含まれるバイアスへの配慮
悪用	2) 安全性	iii. 適正利用に資する開発	ii. 適正利用に資する提供	i. 安全を考慮した適正利用
	8) 教育・リテラシー			
知的財産権等の侵害	2) 安全性	i. 適切なデータの学習 ii. 人間の生命・身体・財産、精神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・身体・財産、精神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

社会的リスク	金銭的損失	2) 安全性	ii. 人間の生命・身体・財産、精神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・身体・財産、精神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	
	機密情報の流出	5) セキュリティ確保	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	
	労働者の失業	1) 人間中心 ①人間の尊厳及び個人の自律				
		8) 教育・リテラシー ②教育・リスキング				
	データや利益の集中	1) 人間中心				
		9) 公正競争確保				
	資格等の侵害	1) 人間中心 ②AIによる意思決定・感情の操作等への留意				
	偽・誤情報等の流通・拡散	1) 人間中心 ③偽情報等への対策				
		2) 安全性	i. 適切なデータの学習 ii. 人間の生命・身体・財産、精神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・身体・財産、精神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	
		8) 教育・リテラシー				
	民主主義への悪影響	1) 人間中心 ①人間の尊厳及び個人の自律 ②AIによる意思決定・感情の操作等への留意				
		4) プライバシー保護	i. 適切なデータの学習	i. プライバシー保護のための仕組み及び対策の導入 ii. プライバシー侵害への対策	i. 個人情報の不適切入力及びプライバシー侵害への対策	
フィルターバブル及びエコーチェンバー現象	1) 人間中心 ②AIによる意思決定・感情の操作等への留意					
多様性・包摂性の喪失	1) 人間中心 ④多様性・包摂性の確保					
バイアス等の再生成	1) 人間中心 ②AIによる意思決定・感情の操作等への留意					
エネルギー使用量及び環境の負荷	1) 人間中心 ⑥持続可能性の確保					

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<sup>20</sup>。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<sup>24</sup>。

生成 AI は日々進化し、リスクに対応する技術及び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、外部環境及び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、法的リスク及び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」又は「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。

<sup>20</sup> エージェント AI の登場により、自ら利用する AI がインターネット等を通じて他の AI 等と接続・連携することにより制御不能となる等、AI がネットワーク化することによってリスクが惹起・増幅される可能性があることに留意することが期待される。

<sup>24</sup> AI エージェントの登場により、事故等の安全性面のリスクや過度な依存、労働者の失業等のリスクが複雑化・深刻化する可能性があることにも留意する必要がある。

## 別添 2.「第 2 部 E.AI ガバナンスの構築」関連

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、常に変化する環境及びゴールを踏まえ、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<sup>22</sup>。

以下、各主体が AI ガバナンスの構築において留意する観点としての行動目標及び、実践のポイント並びに実践例を述べる。

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 6. 行動目標一覧表 5. 行動目標一覧」を参照のこと）。一方で、実践のポイント及び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及び各主体の開発・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、実践のポイント及び実践例の採否は、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及び取捨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及び、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、ルール、及び体制の見直しを行い、管理工数を最小化しつつ意思決定及び運用を迅速化することが重要である。AI ガバナンス及び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ことも期待される。

<sup>22</sup> AI のセーフティ評価を行う際の基本的な考え方としては、AI セーフティ・インスティテュート（AISI）からは「AI セーフティに関する評価観点ガイド（第 1.10 版）」が公開されており、AI システムの開発者や提供者が AI のセーフティ評価を実施する際に参照できる内容となっている。また、同組織からは、AI セーフティ評価手法の一つとして「レッドチーミング手法」が紹介されている。

AISI「AI セーフティに関する評価観点ガイド（第 1.10 版）」（2025 年 3 月）

[https://aisi.go.jp/effort/effort\\_framework/guide\\_to\\_evaluation\\_perspective\\_on\\_ai\\_safety/](https://aisi.go.jp/effort/effort_framework/guide_to_evaluation_perspective_on_ai_safety/)

AISI「AI セーフティに関するレッドチーミング手法ガイド（第 1.10 版）」（2025 年 3 月）

[https://aisi.go.jp/effort/effort\\_framework/guide\\_to\\_red\\_teaming\\_methodology\\_on\\_ai\\_safety/](https://aisi.go.jp/effort/effort_framework/guide_to_red_teaming_methodology_on_ai_safety/)

表 65. 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 ゴール及び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 ガバナンスの構築及びモニタリング

### 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なく意図しないリスクがあることについて、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<sup>23</sup>。

- 事業における価値の創出、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形で、「便益」及び意図せざるものを含めた「リスク」を具体的に理解
- その際に、回避すべき「リスク」及び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及び法令違反を理由とした制裁金並びに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及び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、エネルギー使用量及び環境の負荷、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、著作権等の権利及び資格との関係 等
- 組織・管理に起因するリスク
  - 製品又はサービスに AI が含まれていることの不認識、ガバナンスにおける AI に関する考慮不足、環境認識又は計画等が不足したことによる不適切、偏在的な AI の活用、仕事の棲み分け、人間と AI との間の関係性の整理不足 等

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に重要な複数主体にまたがる論点として、例えば、以下のものが挙げられる。

- 主体間、又は主体内の責任分配
- AI システム・サービス全体の品質向上
- 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

<sup>23</sup> 経営層の AI ガバナンスの管理・監督責任が問われる場合があることにも留意する。

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状況を、取締役会において報告
- 自社/組織にとっての AI 活用の便益/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（担当役員又は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」<sup>24</sup>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及び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及び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<sup>25</sup>。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、インシデント及び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<sup>26</sup>。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・地域毎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】

<sup>24</sup> AI 白書編集委員会「AI 白書 2023」（2023 年 5 月）

なお、「AI 白書 2023」の直接的な最新版である「AI 白書 2025 生成 AI エディション」は、生成 AI に特化した上で、第 3 章「生成 AI と産業界」において、海外事例や市場規模など生成 AI の商業的インパクトを紹介するとともに、経済産業省のプロジェクト「GENIAC」参加企業のインタビューを通じて、基盤モデル開発の最新動向や今後の展望を紹介している。

<sup>25</sup> 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/assets/ai\\_handbook\\_200804\\_0001.pdf](https://www.caa.go.jp/policies/policy/consumer_policy/meeting_materials/review_meeting_004/assets/ai_handbook_200804_0001.pdf)

<sup>26</sup> 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>

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及び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 における分類フレームワーク<sup>27</sup>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 原則及び産業分野の関係性、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及び同業他社、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 の便益及びリスクについては、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、得られた情報及び分析結果をまとめ、社内関係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及び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、社内勉強会及びワークショップを通じて、関連部門の担当者及び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組及び進捗については、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、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。

これらの社内共有の仕組みを通じて透明性が確保され、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 をも台頭しており、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」<sup>28</sup>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の「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、ニュース及び 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、便益及びリスクの最新動向の把握に努めている。

<sup>27</sup> OECD, “OECD Framework for the Classification of AI Systems: a tool for effective AI policies”, <https://oecd.ai/en/classification>

<sup>28</sup> 一般社団法人日本ディープラーニング協会「生成 AI の利用ガイドライン第 1.1 版」(2023 年 10 月), <https://www.jdla.org/document/#ai-guideline>

### コラム 1：インシデントの共有

AI システムの開発及び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もと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。インシデント事例は、一般的にはニュース及び論文等の公開情報から得ることになるが、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)<sup>29</sup>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<sup>30</sup>。また、OECD も、OECD AI Incidents Monitor (AIM)<sup>31</sup>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な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。

<sup>29</sup> Partnership on AI, “AI Incident Database”, <https://incidentdatabase.ai/>

<sup>30</sup> jphall663, “awesome-machine-learning-interpretability”, <https://github.com/jphall663/awesome-machine-learning-interpretability/blob/master/README.md#ai-incident-tracker>

<sup>31</sup> OECD, “OECD AI Incidents Monitor (AIM)”, <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もとづいて、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、その他の社会的弱者、集団 等

社会的な受容の理解には、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
  - 政府及び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 倫理及び品質に関するセミナー並びにカンファレンス
- 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/IEC23894:2023」<sup>32</sup>では、以下が挙げられている。

- 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

<sup>32</sup> ISO, “ISO/IEC 23894:2023 (Information technology-Artificial intelligence-Guidance on risk management)” (2023 年 2 月)

- 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及び傾向
  - 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
- ステークホルダーの関係、認識、価値観等
- 契約関係及びそれに対するコミットメント
- AI システム間の連携及び依存関係の複雑性 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及び運用に対する評価

#### [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 への期待及び課題、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」に関し、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 で得られた情報及び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、大学及び産業団体が開催する AI 倫理及び品質に関するセミナー並びに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 倫理及び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 i、ii の手法を採用してきたが、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及び運用に対する評価結果を得るだけでなく、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及び実践例 i、ii で得られた一般的な情報を組み合わせて、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。分析結果は会議体の運営層で整理され、運営層から経営層（業務執行担当）に報告している。

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、自社の事業領域及び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及び経験の程度、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もとづいて、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。

- 各主体の事業領域及び規模等に照らして 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を見える化し、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す。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把握した上で、AI 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 習熟度を評価するためには、以下のガイドライン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 活用の進展を含めた環境変化を踏まえて見直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<sup>33</sup>
- 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 Test<sup>34</sup>
  - JDLA Deep Learning For GENERAL（G 検定）<sup>35</sup>
- NIST, “Artificial Intelligence Risk Management Framework”（AI RMF 1.0）<sup>36</sup>

<sup>33</sup> 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>

<sup>34</sup> 一般社団法人日本ディープラーニング協会「Generative AI Test」, <https://www.jdla.org/document/#ai-guideline> JDLA <https://www.jdla.org/certificate/generativea>

<sup>35</sup> 一般社団法人日本ディープラーニング協会「G 検定とは」, <https://www.jdla.org/certificate/general/>

<sup>36</sup> NIST, “Artificial Intelligence Risk Management Framework (AI RMF 1.0) ”, <https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf>

### 【実践例】

【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<sup>37</sup>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つつ、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て、その結果を用いて自社内に現在の AI ガバナンスの制度及び仕組みを浸透させ、今後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 によるも台頭しており、その影響をも盛り込むため、JDLA の発行する「生成 AI の利用ガイドライン」<sup>38</sup>を活用し、生成 AI の要素も踏まえた習熟度評価を行っている。なお、「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「AI-Ready 化ガイドライン」についても生成 AI を踏まえた更新が予定されていると聞いているため、更新がされた場合には、それをもとに再度検討を行うことを予定している。

<sup>37</sup> AI 開発者、AI 提供者、AI 利用者及び業務外利用者を含む AI の活用によって直接・間接問わず AI の活用に関与する主体

<sup>38</sup> 一般社団法人日本ディープラーニング協会「生成 AI の利用ガイドライン第 1.1 版」(2023 年 10 月) , <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、AI ガバナンス・ゴールの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。本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 に係る取組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
  - 各自の規模及び取扱う 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して良い）
- 「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まと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」をもとに整理した場合、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」にもと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」及び AI の活用目的といった AI に関するゴールを検討することで、それぞれに矛盾が生じたり、相反しないこと
- 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」にもとづく 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及び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、現場担当者に共有した。その後、経営層及び従業員で、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及び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 : 各部門を巻き込んだ 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であり、部門毎に 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、各部門が単一の 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、現時点では本ガイドラインの「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 倫理及び品質を追加することで AI 倫理及び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、各部門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・利用する部門毎の AI ガバナンス・ゴールの必要性及び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・サービス及び、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及びステークホルダーが 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。

**【実践例 v : 既存のガバナンス枠組みを基盤とした AI ガバナンス・ゴールの設定】**

当社は、AI の開発・提供・利用の全工程を自社で担う事業特性から AI ガバナンスの整備を急務と捉えた。当社では、既に全社ポリシーとしてセキュリティポリシーやプライバシーポリシー等が敷かれていたため、これらの継続準拠を前提に、既存ポリシーを基盤として AI ガバナンスの枠組みを構築した。AI を IT システム群の一構成要素として位置づけ、AI 事業者ガイドライン等の外部指針を参照しつつ、AI 特有のリスクおよび意思決定のメカニズムを管理項目として追加・統合した。結果として、既存ポリシーの踏襲および AI 特有の観点の反映を両立した AI ガバナンスを構築している。

### 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【ゴール及び乖離の評価、並びに乖離対応の必須化】：

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り、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。

- 「AI ガバナンス・ゴール」からの乖離を特定し、リスクベースアプローチ<sup>39</sup>を用いて、リスクに対するコントロールを選択し、ユースケース、サービス又は製品ごとに適切なレベルの管理を実施
- 現状の AI システム・サービス及び「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<sup>40</sup>の開発・提供・利用の適切な段階及び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、組織マネジメント及び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、自社の状況及び 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（AI システムが設計されたとおりに機能し、予測、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)”

<sup>39</sup> リスクベースアプローチとは、AI の利用目的・利害関係者、発生し得るリスクの影響の大きさ/発生可能性などを踏まえて、対策の優先順位を決定する手法である。参考に AI ガバナンス協会（AIGA）では、「AI 時代の経営意思決定とガバナンス ～攻めの AI ガバナンス実現のための戦略レポート」にて、ベネフィットとリスクを併せて評価するアプローチ手法が紹介されている。  
[https://cdn.prod.website-files.com/66e98b87b115812d1af8fc1c/69285da091ec71dde1ae3c71\\_management-strategy-report-ver1.0.pdf](https://cdn.prod.website-files.com/66e98b87b115812d1af8fc1c/69285da091ec71dde1ae3c71_management-strategy-report-ver1.0.pdf)

また、EU「Artificial Intelligence Act Annex III: High-Risk AI Systems Referred to in Article 6(2)」  
<https://artificialintelligenceact.eu/annex/3/>

にて整理されているリスク分類の考え方も、リスク識別および評価プロセスの補強をする際の参考となる。

<sup>40</sup> 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。

- 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」<sup>41</sup>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
- 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、技術担当役員及び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、本ガイドラインの「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、観点毎に乖離を特定し、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もとづき、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及び本ガイドラインを参考にしている。

##### 【実践例 ii：多数の部門を有する事業者のプロジェクト毎の乖離評価プロセス】

多数の部門を有する当社は、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委員会を設置している。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、本ガイドラインの「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毎に実施することを任務としている。具体的には、AI ポリシーにもと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及び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

<sup>41</sup> 国又は国際機関における原則や法令に加え、国際標準化機構（ISO）等非政府組織が定める標準についても適宜参照することも有用である。AI のリスクマネジメントに関する国際標準としては、ISO 及び国際電気標準会議（IEC）の合同専門委員会により検討が進められ、2023 年 12 月 18 日、国際規格「AI マネジメントシステム（ISO/IEC 42001）」として発行されている。  
<https://www.meti.go.jp/press/2023/01/20240115001/20240115001.html>

化及び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委員会では、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及び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、現時点では乖離及び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委員会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 開発者及び 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。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、乖離評価の方法及び基準を AI 開発者並びに 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。

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がある。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及び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としている。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<sup>42</sup>。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又は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及び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又は専門家を招いて、最近の AI インシデント及び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、有識者又は専門家から入手した情報及び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・提供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。

【実践例 vi：リスクベースアプローチによる AI の提供及び利用に関する活動】

当社では、AI の提供及び利用の際のリスクベースアプローチの考え方として、透明性の確保、公平性の確保、信頼性の確保、AI 利用の公表、知的財産の保護、その他の計 6 つの検討項目を定め、各検討項目において、潜在的なリスクと、その潜在的リスクに対するコントロール手法（最低限の対処）を定めている。例として、透明性の確保では、潜在的リスクとして、「モデルのバージョンを保存せず、AI の判断に起因する事象発生時や、検証が必要な際に AI の事後検証ができなくなるリスク」を挙げ、これに対するコントロール手法として、「AI モデル開発に用いた学習データを保管」を規定している。そして、実際の AI の提供及び利用部門が、リスクの有無とそれに対する具体的なコントロール手法の評価を行い、その結果をリスク評価部門が更に評価することで総合的にリスクへの対応の妥当性を判断している。

検討項目		潜在的なリスク	その他固有リスク ①	コントロール手法	その他コントロール手法 ②	妥当性評価	判断
大項目	中項目		記入欄 業務担当部門		記入欄 業務担当部門		
透明性の確保	データ・学習済モデルの管理	・学習・推論データ・学習済モデルのバージョンを保存せず、AI の判断に起因する事象発生時や、検証が必要な際に判断根拠の事後検証ができなくなるリスク	左記以外のリスク無し	・AI モデル開発に用いた学習データを保管 ・使用した推論データおよび推論結果の保管 … (例外規定：～であるデータは保管の対象外とする)	左記のとおり対応	①において、○○○といふリスクも考えられるのではないか	<b>差し戻し</b> ①において、考慮すべき観点の更なる検討
…	…	…	…	…	…	…	…

図 8. リスクベースアプローチの例

<sup>42</sup> 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。

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、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、他社・団体の取組等、外部のベストプラクティスの積極的な取り込み

各業界で参考となるガイドラインがある他、各省庁及び各業界団体が 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及び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。

- 業界共通
  - 国際標準化機構「ISO/IEC42001」（2024 年 4 月）<sup>43</sup>
  - 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」（2023 年 12 月）<sup>44</sup>
  - NIST「AI Risk Management Framework Playbook」（2023 年 1 月）<sup>45</sup>
- 官公庁・自治体
  - [デジタル庁「行政の進化と革新のための生成 AI の調達・利活用に係るガイドライン」（2025 年 5 月）](#)  
[デジタル庁「テキスト生成 AI 利活用におけるリスクへの対策ガイドブック（α版）」（2024 年 6 月）](#)<sup>46</sup>
  - [総務省「自治体における AI 活用・導入ガイドブック〈導入手順編〉（第 4 版）」（2025 年 12 月）](#)<sup>47</sup>
  - 東京都「文章生成 AI 利活用ガイドライン」（2024 年 4 月）<sup>48</sup>
- 農業
  - 農林水産省「農業分野における AI・データに関する契約ガイドライン」（2020 年 3 月）<sup>49</sup>
- 製造業
  - [経済産業省「AI 導入ガイドブック」（2022 年 4 月）](#)<sup>50</sup>
- 医療健康
  - 日本デジタルヘルス・アライアンス (JaDHA)「ヘルスケア事業者のための生成 AI 活用ガイド 第 2.0 版」（2025 年 2 月）<sup>51</sup>

<sup>43</sup> <https://www.meti.go.jp/press/2023/01/20240115001/20240115001.html>

<sup>44</sup> [https://www.aist.go.jp/aist\\_j/press\\_release/pr2020/pr20200630\\_2/pr20200630\\_2.html](https://www.aist.go.jp/aist_j/press_release/pr2020/pr20200630_2/pr20200630_2.html)

<sup>45</sup> <https://www.nist.gov/itl/ai-risk-management-framework/nist-ai-rmf-playbook>

<sup>46</sup> <https://www.digital.go.jp/resources/generalitve-ai-guidebook>  
[https://www.digital.go.jp/resources/standard\\_guidelines#ds920](https://www.digital.go.jp/resources/standard_guidelines#ds920)

<sup>47</sup> [https://www.soumu.go.jp/main\\_content/000820109.pdf](https://www.soumu.go.jp/main_content/000820109.pdf)

<sup>48</sup> <https://www.metro.tokyo.lg.jp/tosei/hodohappyo/press/2023/08/23/14.html>

<sup>49</sup> <https://www.maff.go.jp/j/kanbo/tizai/brand/keiyaku.html>

<sup>50</sup>

[https://www.meti.go.jp/policy/it\\_policy/jinzai/Alguidebook-DemandForecasts-FIX.pdf](https://www.meti.go.jp/policy/it_policy/jinzai/Alguidebook-DemandForecasts-FIX.pdf)  
[https://www.meti.go.jp/policy/it\\_policy/jinzai/Alutilization.html](https://www.meti.go.jp/policy/it_policy/jinzai/Alutilization.html)

<sup>51</sup> <https://jadha.jp/news/news20250207.html>



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、その計画、及び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<sup>64</sup>。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組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もとづいた 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 モデルの構築及びアウトプットへの配慮だけでなく、AI モデルに対する入力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組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、経営層がプライバシー担当者に対して、乖離評価プロセスを構築するにあたって社外の取組を調査するように指示した。

AI モデルの構築及び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」<sup>65</sup>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 ver1.3」<sup>66</sup>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組の一部が反映されている。

行動目標 3-1-2【AI 利用者及び業務外利用者に対する、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、その事実及び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・サービス及び「AI ガバナンス・ゴール」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及び対応策に関して情報提供し、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、AI 開発者及び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及び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

<sup>64</sup> 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第 1.2 版」(2023 年 12 月), <https://www.digiarc.aist.go.jp/publication/aiqm/referenceguide.html>

<sup>65</sup> 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」p.10-21 (2022 年 4 月)

<sup>66</sup> 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/menu\\_kyotsuu/important/kinkyu02\\_000513.html](https://www.soumu.go.jp/menu_kyotsuu/important/kinkyu02_000513.html)[https://www.soumu.go.jp/mn\\_content/000877678.pdf](https://www.soumu.go.jp/mn_content/000877678.pdf)

- 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わ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 AI 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、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、AI に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、個人情報保護法及び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 AI 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及び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 AI サービスを提供する可能性があるが、AI 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 AI 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考えており、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、AI 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、そのもととなるデータに、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、もと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、例えば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行え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 倫理及び 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及び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、役職及び担当に適した研修及び教材を用い、AI リテラシーの向上を図ること
- その際、各者の果たすべき役割に応じて適した研修及び教材の活用
- 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 技術及び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及び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
- AI マネジメントシステムの適切な運用に必要な人材・スキルを定義することにより、事業者に必要な人材・スキルの共通認識を醸成し教育内容を具体化
- AI に関する協会・団体等を通じて収集した事例やベストプラクティス等の社内教育への活用

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、人材育成及び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、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及びテキスト、経済産業省の「マナビ DX」<sup>67</sup>及び「マナビ DX Quest」<sup>68</sup>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もと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 G2025<sup>3</sup>#5<sup>3</sup>（2025<sup>3</sup>年 9<sup>7</sup>月 6<sup>7</sup>日実施）の G 検定合格者アンケートにおいて学習時間は 4530～3050 時間と答えた合格者が約 25%<sup>43</sup>割と最多であり<sup>69</sup>、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」<sup>70</sup>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 技術及び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/リスクが大きいことから、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<sup>71</sup>も活用している。

<sup>67</sup> 経済産業省「マナビ DX ホームページ」, <https://manabi-dx.ipa.go.jp/>

<sup>68</sup> 経済産業省「マナビ DX クエスト ホームページ」, <https://dxq.manabi-dx.ipa.go.jp/>

<sup>69</sup> 一般社団法人日本ディープラーニング協会「G 検定合格者に聞きました」<https://www.jdla.org/certificate/general/start/>

<sup>70</sup> 独立行政法人情報処理推進機構「IT パスポート試験 ホームページ」, <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)—

<sup>71</sup> 経済産業省「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](https://www.meti.go.jp/policy/it_policy/jinzai/manabi-dx-quest.html)

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 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 には講義及び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」<sup>72</sup>及び「デジタルスキル標準」<sup>73</sup>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及び知識を問うための 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、自社又は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及び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及び解決に必要な情報の特定
- 各主体間で、知的財産権及び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、各主体の AI ポリシー、営業秘密、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及び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、法務担当者又はリスク・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及びそれを踏まえた相互運用性（「標準」及び「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及び開発・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】

<sup>72</sup> 経済産業省「生成 AI 時代の DX 推進に必要な人材・スキルの考え方」（2023 年 8 月），  
<https://www.meti.go.jp/press/2023/08/20230807001/20230807001-b-1.pdf>

<sup>73</sup> 経済産業省、独立行政法人情報処理推進機構「デジタルスキル標準 ver.1.1」—(2023年8月)—、  
[https://www.meti.go.jp/policy/it\\_policy/jinzai/skill\\_standard/main.html](https://www.meti.go.jp/policy/it_policy/jinzai/skill_standard/main.html)[https://www.ipa.go.jp/jinzai/skill\\_standard/dss/index.html](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及びその原因（学習データ及び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 がアウトプットとして得たデータをインプット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 開発者及び 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、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及び対象についても伝えている。情報提供を徹底するために、紙書面又は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、そのような説明を受け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 利用者又は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、国毎に文化・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、国毎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、データセキュリティに関する規制等を調査し、それにもと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る DFFT に関する国際的な議論及びデータの流通に係る様々な枠組みについても、専門家を活用しながら、情報を収集している。

コラム 3 : 国毎に文化・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<sup>74,75</sup>。

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。このフェロウシップの目的は、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<sup>76,77</sup>。

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、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組の参照

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、AI 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。

- 関係省庁及び業界団体等が策定するガイドラインの確認
- AI 倫理及び品質に関する団体への所属

<sup>74</sup> Microsoft「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：コンプライアンスの基礎となるガバナンス」（2023 年 2 月），<https://news.microsoft.com/ja-jp/2021/02/02/210202-microsoft-responsible-ai-program/>

<sup>75</sup> Microsoft, “The building blocks of Microsoft’s responsible AI program : Governance as a foundation for compliance”（2021 年 1 月），<https://blogs.microsoft.com/on-the-issues/2021/01/19/microsoft-responsible-ai-program/>

<sup>76</sup> Microsoft「日本における AI ガバナンスの推進：マイクロソフト内での AI ガバナンス」（2023 年 10 月），<https://news.microsoft.com/ja-jp/2023/10/06/231006-about-the-potential-of-ai-in-japan/>

<sup>77</sup> Microsoft, “Advancing AI governance in Japan : Governing AI within Microsoft”（2023 年 10 月），<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組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<sup>78</sup>。

現時点で学習済みの機械学習モデル等の性能及び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、様々な取組を参考にするつもりである。

##### 【実践例 ii : AI 倫理及び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 倫理及び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 利用者及び業務外利用者には 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 の性質及び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又は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。この情報には、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）、データの量及び分布、これに含まれるカテゴリー毎の概要等を挙げるができる。また、開発の際に選択した（選択しなかった）アルゴリズム、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・サービスの開発及び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 倫理及び品質に関する団体に参加する意義がある。

##### 【実践例 iii : 複数の国をまたぐ場合の各主体間の連携】

<sup>78</sup> Google, “Vertex AI”, <https://cloud.google.com/vertex-ai>

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ため、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組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、最新トレンド及び事例に知見がある 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か、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・サービスの開発及び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及び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、経営層が、各部門の担当者に対して AI の適切な開発・提供・利用に関する情報収集及び意見交換を奨励し、部門を越えた社内の議論並びに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ており、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、法務部門及び技術部門で AI 倫理に関する社内議論及び勉強会から始めることとした。言葉の定義又は使い方が部門毎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 AI 利用者及び業務外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及び早期対応を通じて 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及び早期対応
- 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。

- 過去事例の蓄積及び行動目標 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及び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及び継続した研究開発】**

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、保険を活用してインシデントから生じう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<sup>79</sup>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考えられる。

各主体のいずれが AI システム・サービスの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 AI を利用したサービスの提供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のが想定される場合、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、AI を関連するステークホルダーに使うことが 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、チーム及び組織は、開発及び営業と共に、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 AI 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」<sup>80</sup>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、仕事の完成又は成果の性能・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ト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

<sup>79</sup> 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。

<sup>80</sup> 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>

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なく、データの品質の確保を含めて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して認識していた。

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」<sup>81</sup>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、及び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もとづいて・・・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及び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もとづく権利関係が生じる可能性があることを認識している。そのため当社は、専門家の意見を聞き関連する法令及びリスクの棚卸を行っている。加えて、AI 利用者との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、データの越境移転及び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 サービスの内容及び与えるリスクの規模に応じ、必要な対応を行っている。

<sup>81</sup> 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毎の法的な変更に適用できる柔軟性を確保したり、データの移動及び処理を分離することで国毎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 利用者及び業務外利用者への説明、影響範囲、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、対応方針の決定及び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を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、以下に取り組むことが期待される。

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

AI 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及び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 AI 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、AI 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、AI 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 AI 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 AI 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。AI 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 AI 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、類型毎に各主体、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）及び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 AI 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。

## 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関連する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・サービスの開発・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、それをもとに確認・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、他部門及び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」<sup>82</sup>では、説明可能な AI の 4 原則及び説明の 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」においてデータ及び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・サービスの開発及び運用に関する社内の会議並びに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。

<sup>82</sup> NIST, “Four Principles of Explainable Artificial Intelligence (Draft)” (2020 年 8 月), <https://www.nist.gov/publications/four-principles-explainable-artificial-intelligence>  
なお、5 類型については、2021 年 9 月に Draft のみで述べられている。

NIST, “Four Principles of Explainable Artificial Intelligence” (2021 年 9 月), <https://nvlpubs.nist.gov/nistpubs/ir/2021/NIST.IR.8312.pdf>

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、部門間の専門性又は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組を実施しているが、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、他部門及び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であろ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及び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組を行っている。

チェックリストは自社で 0 から作成するのではなく、本ガイドラインの「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。自社内の他部門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もとづいた、再学習の必要性の協議
- AI 開発者及び 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、AI 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、精度及び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及び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 AI システム・サービス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、「品質保証の技術者及びチーム、組織は、開発並びに営業と共に、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<sup>83</sup>。

#### 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及び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。上場企業以外で

<sup>83</sup> 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 2025<sup>3</sup>.046 版」（2025<sup>3</sup>年 46 月）  
<https://www.qa4ai.jp/download>

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も検討
- 開示しない場合には、その事実を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組
- 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。顧客及び株主はこの姿勢を支持してくれている。もちろん本ガイドラインの「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、その背後にある理念等の理解こそが重要である。

当社は非上場企業であるため、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及び当社の 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】

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り、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 倫理の取組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及び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及び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及び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
- リスクが発生する要因は変化するため、リスクベースアプローチに関して、リスクに対するコントロール、管理方法等の見直しを随時実施
- 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もとに、継続的な改善を実施

AI マネジメントシステムの設計及び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、国際機関等<sup>84</sup>
    - ◇ 高い専門性及び他社の監査経験の活用並びに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
  - リスク管理担当部門又は 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・開発プロセスへの指摘が少ない等
- 社外のリソースを活用する場合

<sup>84</sup> World Economic Forum, “The Presidio Recommendations on Responsible Generative AI” (2023 年 6 月)

- 外部監査主体等は、各主体の固有の課題、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及び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
- 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

マネジメント及び監査組織の基準<sup>85</sup>に関しては国際的な標準を適宜参照することが有用である。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、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、不適切な運用又は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及び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：自己監査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いる。自己監査という第一の監査ラインは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していく。AI ガバナンス担当役員は AI 技術及び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 AI システムの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：内部及び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及び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

<sup>85</sup> マネジメント標準としては、[ISO/IEC42001](#) 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 等を適宜参照することが有用である。が議論中である。

化し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。

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及び客観性によって、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【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及び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及びその運用に対する意見を求めることを検討
- 当該意見の内容を実施しない場合、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 倫理及び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 倫理及び品質に関する意見交換の場並びにカンファレンス等の場を積極的に活用
- AI 及び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・立場及び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、上場企業はもちろんのこと非上場企業も、AI ガバナンス及び AI マネジメントシステムの評価並びに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、AI 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 ポリシーの意味及び AI 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 及び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 倫理及び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 倫理及び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、日本人は意見交換及び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、意見交換及び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。このような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 ガバナンスの取組を 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、当社の取組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及び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。

適時な再分析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 AI インシデントが他社で発生した場合
- 社会的に、特定の AI 技術又は AI 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及び運用を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及び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、異動時のタイミングでの教育
- 社員必携の行動基準又は冊子等における AI ガバナンスに対する姿勢への言及

- 定期的な e-learning 及び研修教育 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 AI 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きな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、定期的に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・サービスがもたらしうる便益/リスク及び AI システム・サービスの開発並びに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的な取組事例

AI ガバナンスを推進している事業者の例を取り上げる<sup>86</sup>。

### コラム 4 : ABEJA の AI ガバナンスに関する取組

デジタルプラットフォーム事業等を展開する従業員数約 100 名のスタートアップである同社は、2019 年に外部有識者会議として Ethical Approach to AI (EAA) を設置し、具体的な案件における倫理的課題の抽出や解決の方向等について定期的に諮問している。また社内体制についても、AI に関する法務・倫理・ガバナンスの知見を有する者を法務業務との兼務で担当者とし、取組を進めている。スタートアップとしての規模に応じた機動的・軽量の体制になるよう留意しつつ CEO 主導の下、構築している。

また、同社は、AI ポリシーを、抽象的な公平性や透明性を挙げるのではなく、事業内容ごとに重要な価値を特定して制定している。

具体的には、同社の事業のうち受託開発事業については、幅広い業界の顧客から AI 開発を受託する事業者として、何を守っていくべきと設定するかが課題であった。これは顧客のドメインに依存することから、「顧客との対話」や「意見交換」を重視する内容とし、一般的によく挙げられる「透明性」、「公平性」等を中心に据えることはしなかった。一方で、顔認識サービスについては「プライバシー」を掲げる等、事業の内容に合わせ、重要な価値を特定し、事業内容に応じた記載となるような工夫を行っている。

また、個別の案件について AI 倫理上の確認を行う際は、上述の担当者が秘密保持契約や業務委託開発のチェック時に、全件について概括的な倫理上の確認を行っており、課題がありそうなものについては、プロジェクト担当者等を通じて顧客に対し倫理上の課題についてフィードバックを行っている。特に判断が難しい案件については、上記の EAA に諮問することとしている。

また、AI 開発受託者として、顧客の開発における倫理の実現を重要と考える同社は、顧客の AI における倫理やリスクマネジメント体制の整備、倫理チェックリストの作成など、AI 倫理コンサルティングについて多数のサービスを提供している。

このような取組の結果、「AI 倫理に適切に対処している」、又は「AI 倫理コンサルティングサービスを提供している」ということを理由に、同社を選択する顧客も増えてきており、AI 倫理に取り組むスタートアップ企業として注目もされてきている。

AI 事業者ガイドラインについては、まだ公表から多くの日数が経過していないものの、同社に関連する項目がある場合は適宜参照している。また、今後 NEDO から採択された日本語 LLM のモデル構築に取り組んでいく際も、参照していく想定である。

<sup>86</sup> AI ガバナンス構築の実践例については、AI ガバナンス協会「AI ガバナンスの実装状況に関するワーキングペーパー」（2024 年 8 月）も参考となる。 [https://uploads-ssl.webflow.com/65322a024d0afe70af851cc5/66b2b65a0a1d6c6834291501\\_240805-aiga-implement-wp.pdf](https://uploads-ssl.webflow.com/65322a024d0afe70af851cc5/66b2b65a0a1d6c6834291501_240805-aiga-implement-wp.pdf)

### コラム 5 : NEC グループの AI ガバナンスに関する取組

NEC は、AI の利活用にあたり、「人権の尊重」を最優先に、人間中心の価値観を重視し、安全性、公平性、プライバシーの保護など、社会的に重要な価値を大切にすることで、すべての人が安心して AI を利用できる環境を整え、持続可能な社会の構築に貢献することを目指している。一方で、AI の利活用には、これらの価値を損なう様々なリスクが内在している。NEC は、こうしたリスクに真摯に向き合い、NEC が描く AI 社会の未来の実現に向けて、人間が意図した範囲内で安全かつ適正に AI が動作し、人々の生命・身体・財産・精神・環境に対する危害を防ぐ「AI Safety（安全性）」と、AI システム・モデルに対する外部からの不正なアクセスや改ざんといった脅威から守る「AI Security（セキュリティ）」の 2 つの側面からリスクへの対策を講じることで、安全・安心な AI の利活用を推進している

NEC は、2018 年 10 月に AI の利活用に関連した事業活動が人権を尊重したものとなるよう、全社戦略の策定・推進を担う組織として「デジタルトラスト推進室」を設置し、翌年には「NEC グループ AI と人権に関するポリシー」を策定。このポリシーは、国内外の原則や自社のビジョン・価値・事業内容等から検討し、社内の研究開発・サステナビリティ・リスク管理・マーケティング・事業部門などの関係部門や、外部の有識者・NPO・消費者など社内外の様々なステークホルダーとの対話を経て策定された。策定後、このポリシーを実践するために、社内制度の整備や従業員の研修などを継続的に実施している。

近年、生成 AI をはじめとする AI 技術の進展や利用シーンの拡大に伴い、新たなリスクへの対応が求められる中、NEC はより高度で広範囲な AI のリスク管理を担う AI ガバナンスに取り組んでいる。この AI ガバナンスでは、人権尊重を基軸に、不当な偏見や差別を防ぐ公平性の担保、個人情報の保護、判断結果の根拠を説明可能にする透明性の確保、そして外部の脅威から組織や個人を守るセキュリティ対策の徹底などに取り組んでいる。これらの取り組みを実効性のあるものとするため、AI ガバナンスを内部統制の枠組みに組み込み、取締役会の監督下で、リスク・コンプライアンス委員会の指示に従い、AI ガバナンス遂行責任者である CDO（チーフデジタルオフィサー）を中心とした体制を構築している。この体制では、法務、リスク・コンプライアンス、人権、個人情報・プライバシー、品質管理、セキュリティなどの従前からあるリスク管理を担当するスタッフ部門と、製品・サービスを担当する事業部門が連携し、信頼できる AI の提供体制を強化している。（「図 9. AI ガバナンスの推進体制」参照）。



図 9. AI ガバナンスの推進体制

リスク対応においては、AI 事業者ガイドラインの本編「各主体が取り組む事項」や別添「技術的リスク・社会的リスク」などを参考にしている。具体的にはこれらで示されているリスクと NEC の事業環境と照らし合わせ、自社としてのリスクを明確化し、対策を講じている。対策は技術開発、製品・サービス提供のプロセスに組み込まれ、必要な対策はマニュアル化し、社内ルールに反映している。

これらの社内ルールや運用は、AI 事業者ガイドラインで示されているアジャイル・ガバナンスの考え方に基づき、日本、米国、欧州などの法規制やガイドラインの動向、AI の利用に対する社会の受容性など、外部環境の変化に応じて柔軟に見直している。

NEC は、顧客向けの製品・サービス提供だけでなく、従業員の AI 利活用にも積極的に取り組んでおり、社内利用にも AI ガバナンスを適用している。例えば、生成 AI の利用にあたっては、NEC グループ AI と人権に関するポリシー、企業秘密管理に関する規程、情報セキュリティに関する規程などを遵守すること基本方針としている。また、基本方針に沿ったクローズドな利用環境やガードレール等を整備している。

このように、社内での適切な用途での利活用や、その社外への展開に加えて、先進技術の開発、社内外の人材育成、外部有識者を含む多様なステークホルダーとの対話などにも注力しており、AI が社会にもたらす影響や価値について説明責任を果たすことで、社会にとって望ましい AI の有り方を追求している。

NEC は、2018 年に AI の利活用に関連した事業活動が人権を尊重したものとなるよう、**「全社戦略の策定・推進を担う組織として「デジタルトラスト推進統括部」を設置し、2019 年に「NEC グループ AI と人権に関するポリシー（以下、全社ポリシー）」を策定。ガバナンス体制として AI ガバナンス遂行責任者（CDO: Chief Digital Officer）を置き、リスク・コンプライアンス委員会や取締役会との関係性を明確化するとともに、外部有識者会議の「デジタルトラスト諮問会議」を設置し、外部とも積極的に連携する等、経営アジェンダとして AI ガバナンスに取り組んでいる（「図 9. AI ガバナンスの推進体制」参照）。**

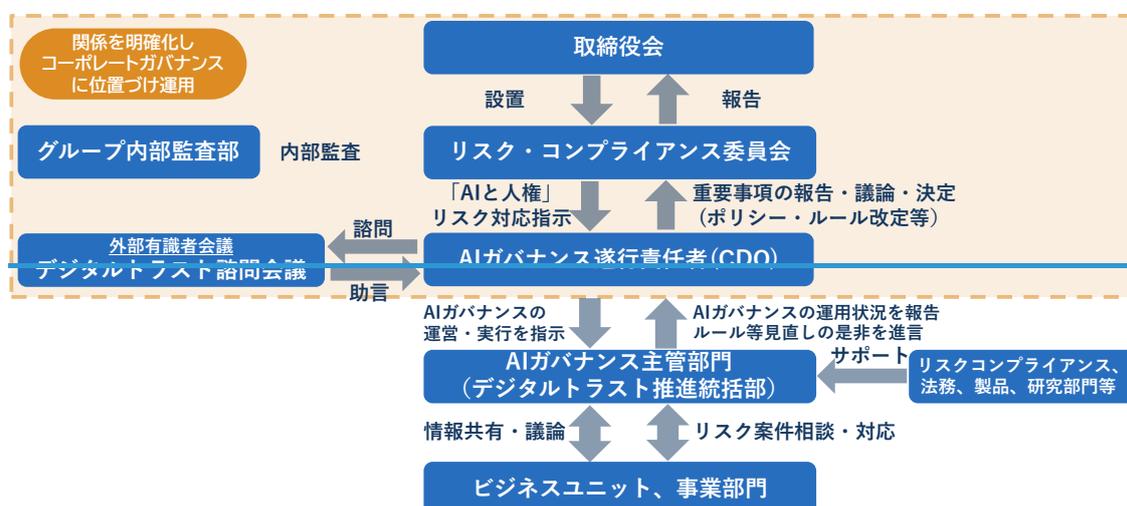


図 9. AI ガバナンスの推進体制

全社ポリシーは、デジタルトラスト推進統括部が国内外の原則や自社のビジョン・価値・事業内容等から検討し、社内の研究開発・サステナビリティ・リスク管理・マーケティング・事業部門などの関係部門や、外部の有識者・NPO・消費者など社内外の様々なステークホルダーとの対話を経て 2019 年 4 月に策定された。このポリシーは、AI 利活用においてプライバシーへの配慮や人権の尊重を最優先するために策定されたものであ

り、「公平性」、「プライバシー」、「透明性」、「説明する責任」、「適正利用」、「AIの発展と人材育成」、「マルチステークホルダーとの対話」の7つの項目から構成されている。

全社ポリシーを実践するために、デジタルトラスト推進統括部が中心となり、社内制度の整備や従業員の研修などを実施している。具体的には、ガバナンス体制や遵守すべき基本的事項が定められた全社規定・対応事項や運用フローが定められたガイドラインやマニュアル、リスクチェックシートを整備し、AI利活用へのリスクチェックと対策を企画・提案フェーズからフェーズ毎に実施する枠組みを整えている。

また、全従業員向けのWeb研修やAI事業関係者・経営層向けの研修も実施しており、外部有識者を講師に迎え、最新の市場動向やケーススタディも交えることで理解の促進が図られている（「図 9. AI ガバナンスの推進体制」参照）。

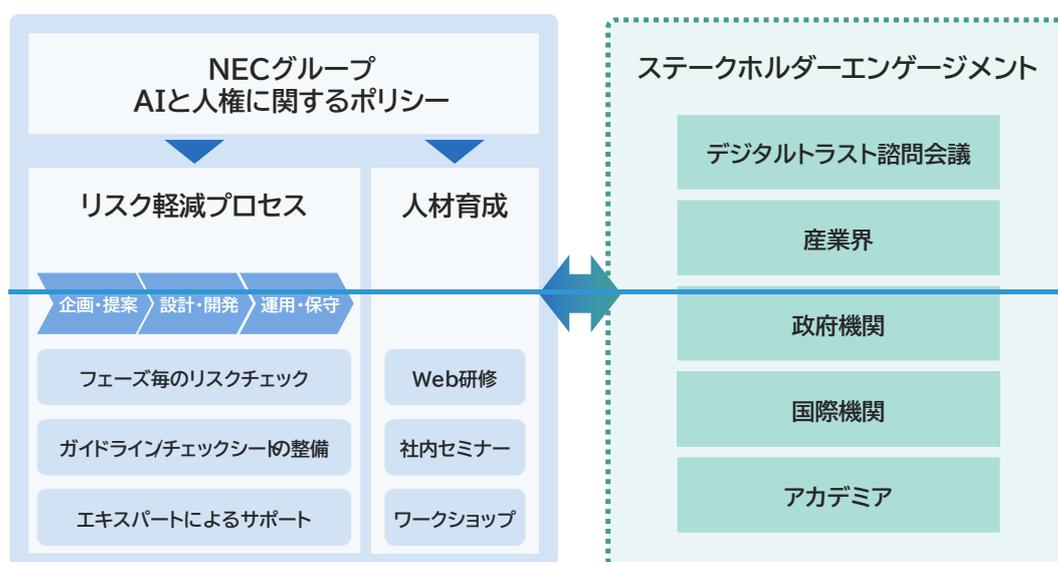


図 10. AI ガバナンスの全体像

これらの取組に際し、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」（以下、旧「AI ガバナンス・ガイドライン」という）に掲載された 24 個の行動目標に対して、5 段階の「成熟度」を定義し、AI ガバナンスの現状を可視化することで、目標達成に向けた対応事項の設定や進捗管理に活用している（「図 11. 旧「AI ガバナンス・ガイドライン」の活用法」参照）。また、旧「AI ガバナンス・ガイドライン」のアジャイル・ガバナンスの考え方にもとづいて、社会環境の変化に応じた対応や社内ルール・運用の見直しを柔軟に行っている。2023 年には、生成 AI（大規模言語モデル）の社内利用に関するルール整備を行うなど、積極的な活用が進められている。

成熟度 行動目標	Lv.1 Performed 個々人による 単発的な実施	Lv.2 Managed ポリシーに従った 反復的实施	Lv.3 Defined 統一された標準的 プロセスの確立	Lv.4 Measured 定量的な 評価の実施	Lv.5 Optimized フィードバックに基 づく継続的最適化
1-1. AIシステムから得られる正のインパクトだけではなく…	国内及び同業他社に関するAI利用のガイドライン…				
1-2. 本格的なAIの提供に先立ち、直接的なステークホルダー…	政府、市民団体等が公表している消費者アンケートや、AI利用に…				
…	…				
6-1. 行動目標1-1から1-3について、適時に再評価…	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…				

図 44. 旧「AI ガバナンス・ガイドライン」の活用法

## コラム 6 : 東芝グループの AI ガバナンスに関する取組

同社は、2022年にグループ横断のAI施策を先導する「AI-CoEプロジェクトチーム」を発足させ、グループの経営理念体系をAI利活用の点から具体化した「AIガバナンスステートメント」を2022年に策定以降、コーポレートの戦略企画部と、旧「AIガバナンスガイドライン」を参照しつつ、このステートメントをベースとした「AIガバナンス」を構築している。総合研究所が中心となってこの枠組みの中で、「AI-CoEプロジェクトチーム」を中心に、プライバシー、セキュリティ、法務などの様々な分野専門家、及び、事業側からの代表者を集めたワーキンググループと共にを形成し、「AIガバナンス」の推進を積極的におこなっている活動をしている。

具体的には、「AI技術カタログ」の構築によるグループ保有のAI技術資産の見える化/利活用促進や独自教育プログラムによるAI人材育成に加え、「MLOps」(機械学習モデルのライフサイクルを管理する仕組み)や「AI品質保証の仕組み」の整備等を通じたも、AIシステムの品質を保つ仕組み、そして事業への適切なAI適用を担保する「AIリスクマネジメント」に取り組んでいる(「[図 10. グループの AI ガバナンスの概要](#)」[図 12. グループの AI ガバナンスの概要](#)参照)。



図 10. グループの AI ガバナンスの概要

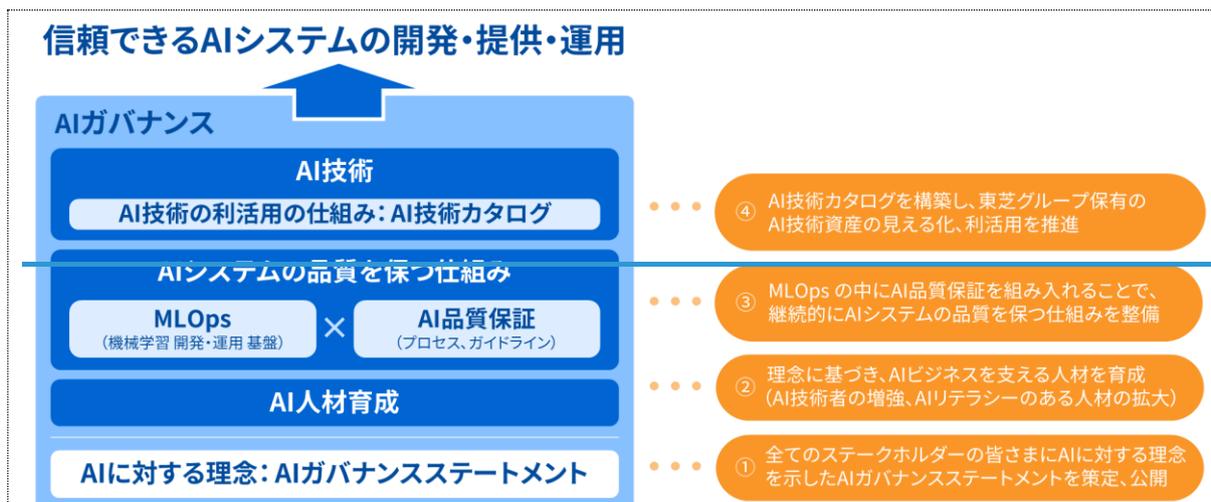


図 12. グループのAIガバナンスの概要

この「AI ガバナンスステートメント」は、東芝グループの経営理念体系を反映し、AI に対する理念を明文化することを目的として、「人間尊重」、「安心安全安心の確保」、「コンプライアンスの徹底」、「AI の発展と人材の育成」、「持続可能な社会の実現」、「公平性の重視」、「透明性と説明責任の重視」の7つの要素から構成されている。

このステートメントをベースとし、「AI 品質保証」と「MLOps」の二軸により、AI システムの品質を保つ仕組みが構築されている。「AI 品質保証」では、「AI 品質保証ガイドライン」を策定し AI システムの開発における考え方や取り組むべき事項を整理し、当ガイドラインを踏まえた「AI 品質保証プロセス」で必要な作業や作成すべき成果物を特定し、漏れのないプロセスを整備している。また、「品質カード」を通じ、開発者目線になりがちな AI 品質保証を利用者目線で評価し、AI 品質の可視化に取り組んでいる。（「図 11. AI 品質保証ガイドライン・品質カード活用の流れ」参照）

「MLOps」では、ビジネス、機械学習の専門家、システム開発担当者、システム運用担当者が一体のチームとなり、運用開始後の環境変化による性能劣化などを起こさないよう、AI システムの継続的な改善に取り組んでいる。これらを連携させることで、信頼できる AI システムの開発・提供・運用を実践している。

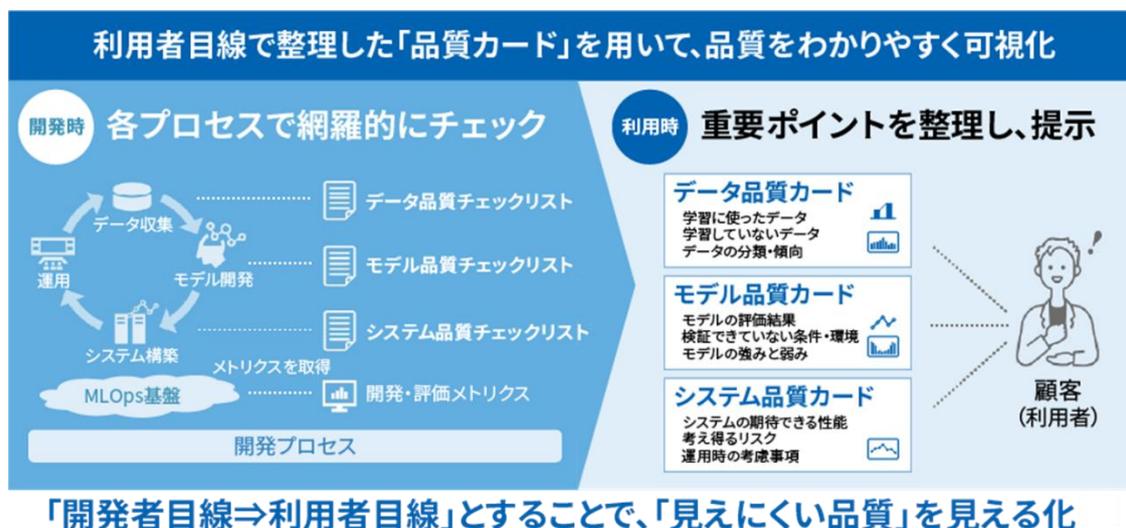


図 11. AI 品質保証ガイドライン・品質カード活用の流れ

さらにこのステートメントをベースとし、「AI リスクマネジメント品質保証」と「MLOps」の三軸により、事業への AI の適切な適用を担保する AI システムの品質を保つ仕組みが構築されている。東芝グループにおける AI リスクマネジメントでは、東芝グループが提供する AI システムについて、リスク（例えば個人情報流出や差別）を低減することで安全性と価値の高い AI システムを社会に送り出し、機会（例えば、業務効率化や社会課題の解決）を最大限享受することを目的としている。AI システムを製品やサービスとして扱う事業部・事業会社を中心となって AI リスクマネジメントをおこなうことで、AI システムの不具合や AI システムによる不利益を被る可能性を低減させ、安心して安全な、価値の高い AI システムをお客様に提供することができる。「AI 品質保証」では、「AI 品質保証ガイドライン」を策定し AI システムの開発における考え方や取り組むべき事項を整理し、当ガイドラインを踏まえた「AI 品質保証プロセス」で必要な作業や作成すべき成果物を特定し、漏れの無いプロセスを整理している。また、「品質カード」を通じ、開発者目線になりがちな AI 品質保証を利用者目線で評価し、AI 品質の可視化に取り組んでいる。

「MLOps」では、ビジネス、機械学習の専門家、システム開発担当者、システム運用担当者が一体のチームとなり、運用開始後の環境変化による性能劣化などを起こさないよう、AI システムの継続的な改善に取り組んでいる。これらを連携させることで、信頼できる AI システムの開発・提供・運用を実践している。AI システムの開発者は、「AI リスクアセスメントシート（AI システムについての調査票）」に必要事項を記入、これらの回答結果をもとにリスクの度合いが評価され、その結果とリスク対応のためのアドバイスがフィードバックされる。この結果を受け、AI システムの開発者はリスク対応をおこない、リスクの低減をはかる。これを繰り返すことで、AI システムのもつ潜在的なリスクを軽減していく。（「図 12. AI リスクマネジメントの概要」参照）

これらの AI ガバナンスの取組を始めたことにより、AI の専門家（技術者）だけでなく、東芝グループ全体で AI システムの開発・提供・運用に必要なリテラシーの向上（AI 利用に対する機会だけでなく、リスク意識の向上）がみられている。

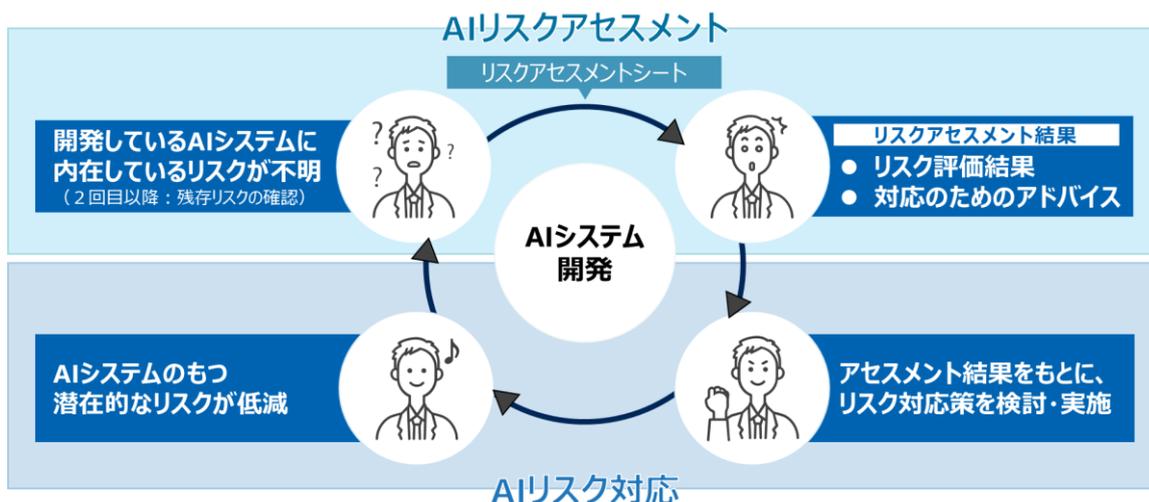


図 12. AI リスクマネジメントの概要

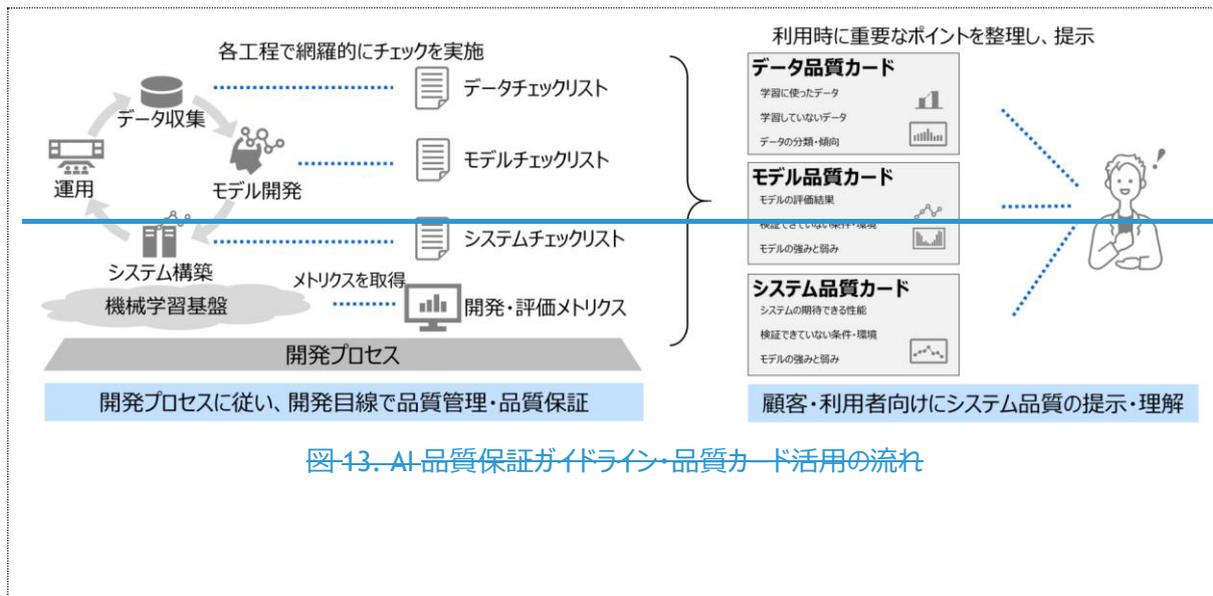


図 13. AI 品質保証ガイドライン・品質カード活用の流れ

### コラム 7 : パナソニックグループの AI ガバナンスに関する取組

同社では、2019 年に、旧パナソニック(株)内に AI 倫理委員会を設置し、社内で遵守すべき「AI 倫理原則」の策定を行った。2022 年にはグループ横断で「AI 倫理原則」を運用するための組織として「パナソニックグループ AI 倫理委員会」へ改組し、同年に「パナソニックグループの AI 倫理原則」を公表した。現在は、この AI 倫理委員会が中心となり、2022 年より運用開始の「AI 倫理チェックシステム」の開発・活用や、全従業員向け AI 倫理教育などを行っている（「[図 13. AI ガバナンスの体制 概要](#)」「[図 14. AI ガバナンスの体制 概要](#)」参照）。

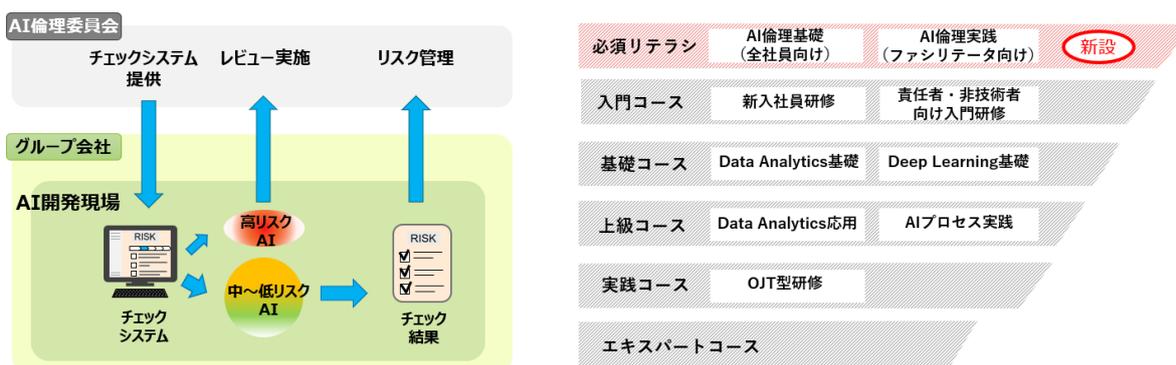


図 13. AI ガバナンスの体制 概要

図 14. AI ガバナンスの体制 概要

「AI 倫理委員会」は、パナソニック ホールディングス(株)内に設置され、「AI 倫理原則」の公表に加え、広範な事業領域それぞれにおいて利用者・社会から信頼される活動実践に取り組んでいる。具体的には、グループの全事業会社から 1 人以上の AI 倫理担当者を選出し、法務部門や知財部門、情報システム/セキュリティ部門、品質部門とともに、グループ横断的に AI 倫理推進体制を敷いている（「[図 14. AI 倫理委員会 構造](#)」「[図 15. AI 倫理委員会 構造](#)」参照）。パナソニックグループの多岐に渡る事業分野に対応するため、それぞれの AI 倫理担当者が事業会社グループ内の AI 倫理活動を推進し、AI 倫理委員会がそれらを支援するという形で運用されている。



図 14. AI 倫理委員会構造

図 15. AI 倫理委員会構造

AI 倫理委員会の取組の一つとして、「AI 倫理チェックシステム」が開発されている。これは、グループ内の多岐・広範囲にわたる AI 利活用において、現場負担の増大・イノベーション阻害を防ぎつつ、AI 倫理リスクチェックを効率的・効果的に行うことを目的としている。製品・サービスの特性に合わせて必要十分なチェックリストを生成できるシステムとなっており、開発中の AI が、AI 倫理原則に乖離したものになっていないか確認できる。また、各チェック項目に対して、充実した解説や対応策に関する情報・技術・ツールの提供を行い、現場が主体的に AI 倫理をチェックし改善を進められる仕組みとなっている。セルフチェック結果は集約され、「AI 倫理委員会」で内容分析が行われ、活動に反映される。チェック項目は、経済産業省の旧「AI ガバナンス・ガイドライン」をベースに国内外のガイドラインを踏まえて初版が作成され、実運用後は現場からの意見を反映した改訂が随時行われている（「[図 15. AI 倫理チェックシステム](#)」「[図 16. AI 倫理チェックシステム](#)」参照）。

### システムのフロー



[図 15. AI 倫理チェックシステム](#)

[図 16. AI 倫理チェックシステム](#)

## コラム 8 : 富士通グループの AI ガバナンスに関する取組

同社は、AI の開発・提供企業として、AI に関する懸念や予期せぬ不都合の解消と適切な技術活用による持続可能な社会の創造をその責務としており、国際的な「広島 AI プロセス」報告枠組みへの参画、AI 倫理ガバナンスの国際的な議論への積極的な参加に加え、後述の AI の倫理審査や開発プロセスにおけるリスク管理「AI 倫理チェック」や 海外リージョンへの AI 倫理責任者設置などの 先進的な社内ガバナンスの取組を推進している。さらには、「AI ガバナンスの取組紹介や生成 AI 利活用ガイドラインの公開、AI 倫理の重要性を喚起する「Fujitsu AI 倫理かるた<sup>87</sup>」の公開など、社外への AI 倫理普及の取組にも力を入れている。

2018 年に加盟した欧州コンソーシアム「AI4People」が提案する 5 原則を参考に、2019 年に「富士通グループ AI コミットメント」を策定、さらにその実践のために、AI の利活用方法に応じた具体的な判断基準や手順を整備した（「図 16. 富士通グループ AI コミットメント」図 17. 富士通グループ AI コミットメント参照）。また、AI ガバナンスの取組に対する客観的な評価を得るべく、「富士通グループ AI 倫理外部委員会」を設置し、AI 技術のほか、生命医学、生態学、法学、SDGs、消費者問題など多様性を重視した外部の専門家をその委員として招聘している。社長をはじめ経営陣がオブザーバーとして参加する同委員会における活発な議論を提言として取りまとめ、これを取締役会へと共有することで、AI 倫理を「企業経営上の重要課題」としてコーポレートガバナンスに組み込んでいる。



- 1 AIによってお客様と社会に価値を提供します
- 2 人を中心に考えたAIを目指します
- 3 AIで持続可能な社会を目指します
- 4 人の意思決定を尊重し支援するAIを目指します
- 5 企業の社会的責任としてのAIの透明性と説明責任を重視します

図 16. 富士通グループ AI コミットメント

図 17. 富士通グループ AI コミットメント

2020 年から AI 倫理に関する教育を制度化した結果、従業員の意識レベルが飛躍的に向上し、また、コンサルティングサービスとして AI ユーザー企業への倫理的観点の助言が可能になっている。

2022 年には、AI 倫理はグループ全体の経営課題との認識から、AI 倫理戦略を主導する組織として「AI 倫理ガバナンス室<sup>88</sup>」（現「AI 倫理室」）を会社直下（コーポレート部門）に設置した。その際、開発や営業出身者など幅広い職種の経験者をグループ各所から登用し、また、デジタルネイティブ世代が活躍できるようオープンで個人の意見が尊重される場づくりを行っている。同室では、率直な意見交換や提案が日常的に行われ、ここから生み出される各種 AI 倫理浸透策はグループ全体で推進される。

<sup>87</sup> 詳細は、富士通の AI 倫理ガバナンスに関する専門サイトに掲載の「Fujitsu AI 倫理かるた」特設ページを参照のこと。

<https://global.fujitsu/ja-jp/technology/key-technologies/ai/aiethics/governance/aiethics-karuta>

<sup>88</sup> 詳細は、富士通の AI 倫理ガバナンスに関する専門サイトに掲載のホワイトペーパー「富士通グループ AI 倫理外部委員会」による提言及び富士通の実践例を参照のこと。

<https://global.fujitsu/ja-jp/technology/key-technologies/ai/aiethics/governance>

2025 年には、AI 倫理への適切な配慮に根差した AI ガバナンス戦略の主導や浸透、AI ビジネスにおける配慮事項を適切に実践するための社内統制ルールの提示、AI ビジネスにおけるリスクマネジメントプロセスなどを統括する「AI インテグリティセンター」を設立し、AI ガバナンスの戦略策定からオペレーションまで一貫して取り組んでいる（「[図 17. AI ガバナンスの体制](#)」「[図 18. AI 倫理ガバナンスの体制](#)」参照）。



図 17. AI ガバナンスの体制

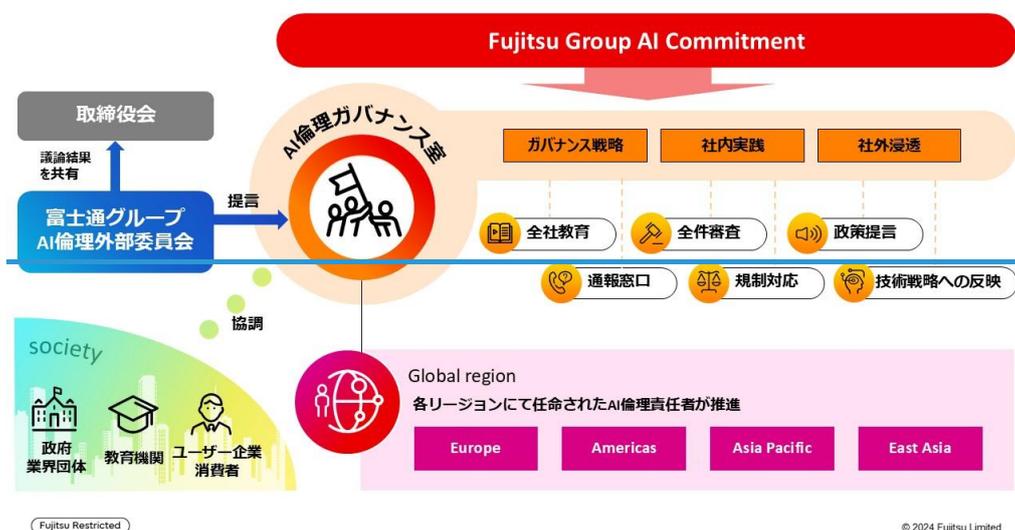


図 18. AI 倫理ガバナンスの体制

さらに、AI 案件の統合管理基盤とグローバルポリシーの整備、公的なガイドラインに準じた AI セーフティ基準統制と AI 規制法遵守統制の徹底、法務・開発・DE&I・事業部門などの合議を経て推進・改善の判断を行う「AI 倫理審査」の義務化対象を富士通グループ全商談に拡大し、倫理的課題を抱える案件は法務・研究開発・DE&I・事業部門などによる合議を経てその推進・改善を判断することとし、実施とリージョン毎の AI 倫理責任者の配置などを通じた倫理的課題を抱える案件についての綿密な支援など、従来の AI に関する

品質保証やセキュリティの観点に留まらない統制を徹底している。海外については、本社での倫理審査に加えて、現地でのAI実装時点での倫理審査も行うべく、各リージョンにAI倫理責任者を配置している。

加えて、「AI倫理影響評価」の無料公開などを通じ、安全安心で信頼できるAIの開発・提供の社内外の推進に取り組んでいる。「AI倫理影響評価」は、内閣府、総務省、経済産業省で公表されたガイドラインに加え、OECDやEU、米国の指針等も含め、国内外各種AI倫理ガイドラインに準拠する上で、AIシステムの開発者・運用者に関連する項目を抽出し、AIが人や社会に与える倫理的な影響を評価するために策定された。この公開に加え、ユーザー企業との勉強会、産学連携や標準化活動などにより、社会全体へのAI倫理取り組みの浸透を促進している（「[図 18. AI倫理影響評価の概要](#)」「[図 19. AI倫理影響評価の概要](#)」参照）。

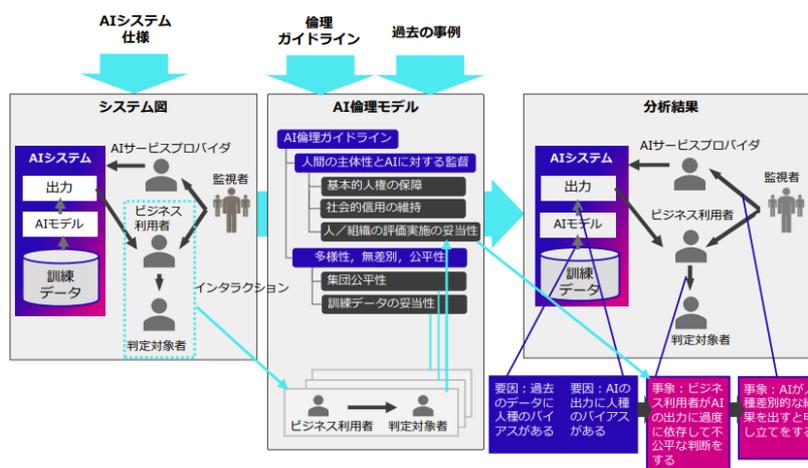


図 18. AI倫理影響評価の概要

図 19. AI倫理影響評価の概要

### コラム 9 : ソフトバンクの AI ガバナンスに関する取組

ソフトバンクは「Beyond Carrier」戦略の下、AI や IoT などの先端技術を活用し、革新的なサービス提供と DX 推進に取り組んでいる。AI については活用が広がる一方で、倫理面での配慮が必要とされている。そこでソフトバンクは AI の適切な活用と **安全・安心・安心・安全** なサービス提供をするため、2022 年 7 月に「ソフトバンク AI 倫理ポリシー」を策定した。具体的には「人間中心の原則」「公平性の尊重」「透明性と説明責任の追求」「安全性の確保」「プライバシー保護とセキュリティの確保」「AI 人材・リテラシーの育成」の 6 つの項目において指針を定め、この指針に則った事業運営やサービス開発などを行うことを宣言した（[「図 19. ソフトバンク AI 倫理ポリシー概要とルール構造」](#)を参照）。また、このポリシーをグループ会社でも適用できる体制を整えており、**2025 年 12 月時点で 89 社に適用し、これらグループ会社に対してもガバナンス状況をモニタリングし、適切な運用が行われているかを確認している。2024 年 7 月時点で 74 社が適用を決定している。**この AI 倫理ポリシーを基に**規程・基準**、ガイドライン、チェックシートなど、様々な社内ルールを制定している。制定にあたっては AI 事業者ガイドライン（[第 4.0 版](#)）の基礎となっている内閣府作成の人間中心の AI 社会原則、総務省作成の AI 開発ガイドライン、AI 利活用ガイドライン、経産省作成の AI 原則実践のためのガバナンス・ガイドライン、等の準拠性を考慮して作成している。**また、2025 年から広島 AI プロセスの国際行動規範の報告枠組みに参加し、今後は AI 倫理ポリシーに基づくリスク管理や透明性確保の取り組みを自己評価・報告することで、社会への説明責任を果たし、責任ある AI 開発を推進している。**（[「図 19. ソフトバンク AI 倫理ポリシー概要とルール構造」](#) [図 20. ソフトバンク AI 倫理ポリシー概要とルール構造](#)参照）。



[図 19. ソフトバンク AI 倫理ポリシー概要とルール構造](#)



図 20. ソフトバンク AI 倫理ポリシー概要とルール構造

ソフトバンクの AI ガバナンス推進にあたっては、AI 事業の戦略部門である **AI テクノロジー本部 AI 戦略室** がミッションを担い、その中に独立した専門部門として AI ガバナンス推進室を設け、社内 AI 利活用部門のガバナンスを推進している。ステアリングコミティには、当社の CIO(Chief Information Officer)、CDO(Chief Data Officer)、CISO(Chief Information Security Officer)、CCO(Chief Compliance Officer)が管理監督としてサポートする。アドバイザーボードとして社内委員や、社外委員で編成された AI 倫理委員会が助言を行いガバナンスの推進に生活かしている。AI 倫理委員会では、AI 利活用の現状把握・AI リスク管理・国産 LLM 開発などをテーマに議論を実施した。(「[図 20. AI ガバナンス推進実行体制](#)」[図 21. AI ガバナンス推進実行体制](#)」および「[図 21. AI 倫理委員会 2024 年度アジェンダ](#)」を参照)。



図 20. AI ガバナンス推進実行体制

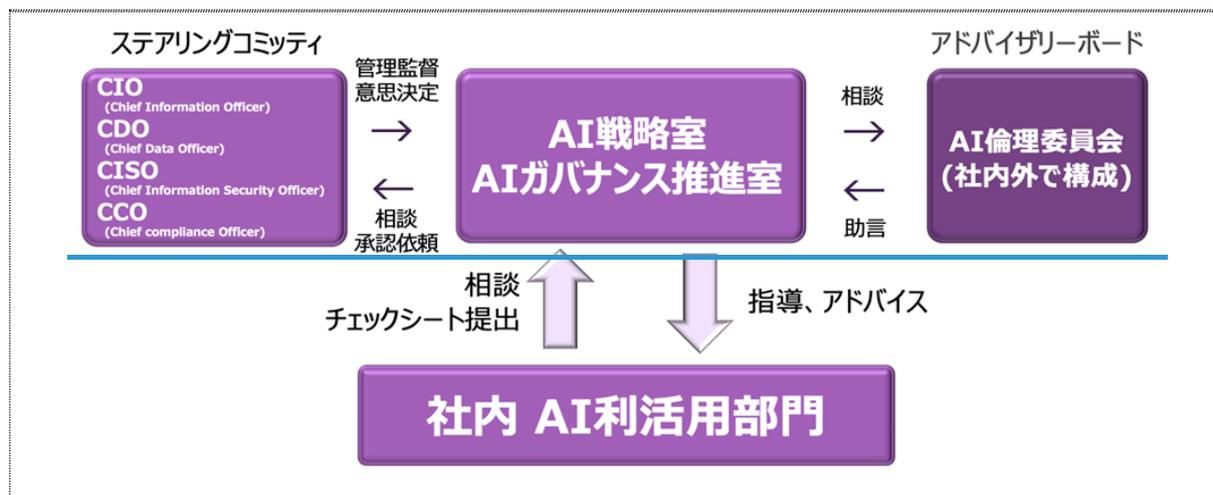


図 21. AIガバナンス推進実行体制

AI倫理委員会 2024年度アジェンダ

開催月	アジェンダ
第1回 2024年7月	<ul style="list-style-type: none"> <li>ソフトバンクAI利活用の状況</li> <li>ソフトバンクのAIガバナンスの取り組みについて</li> </ul>
第2回 2024年10月	<ul style="list-style-type: none"> <li>国内外のAI規制動向と企業に求められること</li> <li>SB Intuitions 国産LLM開発への取り組み</li> <li>LLMにおける大規模なデータクローリングの現状と課題</li> </ul>
第3回 2024年12月	<ul style="list-style-type: none"> <li>ESGおよび機関投資家視点でのAI倫理</li> <li>大規模言語モデルの安全性に関する取り組み</li> </ul>
第4回 2025年3月	<ul style="list-style-type: none"> <li>LLMの公平な文化表象とは</li> <li>ソフトバンクのリスクベースアプローチとリスク判定事例</li> </ul>

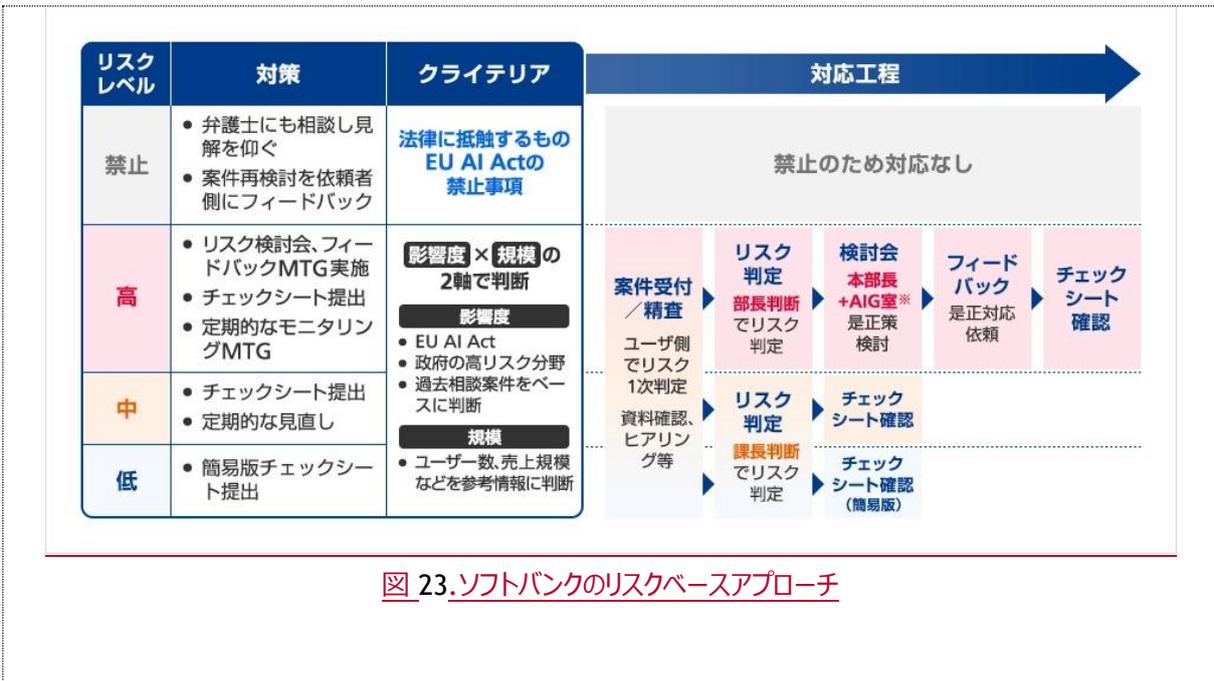
図 21. AI 倫理委員会 2024 年度アジェンダ

ソフトバンクの AI ガバナンス推進の戦略の中で最も重要視していることが、「AI 倫理・ガバナンス教育の推進」である。具体的には e-learning を使った年 1 回の研修や、年 2 回の勉強会、毎月配信しているメールマガジン等で役員を含む全社員に対して教育を推進している（「図 22. ソフトバンクの AI 倫理・ガバナンス教育の推進活動図 - ソフトバンクの AI 倫理・ガバナンス教育の推進活動」参照）。教育コンテンツのアジェンダ と も そ は、国内外で発生している AI インシデントの事例紹介、生成 AI を含む AI を利活用する際の注意点（バイアス、情報漏洩、著作権侵害、ハルシネーション等）、フィジカル AI やエージェント AI など新しい技術のリスクや対策等、AI 倫理に関する社会動向などを中心に教育を推進しており全社員のリテラシー向上に向けて貢献している。



図 22. ソフトバンクの AI 倫理・ガバナンス教育の推進活動

また当社は、AI 倫理・ガバナンスに係るリスクチェックにおいて、AI 倫理委員会で議論のうえ 2024 年 12 月よりリスクベースアプローチを導入した。リスクレベルは禁止・高・中・低の 4 段階で定義している。リスク定義については、リスクが顕在化した時の社会的、事業的なインパクトを考慮し、かつ社員が簡便かつ明確に分類できる点にも配慮し制定している。(「図 23. ソフトバンクのリスクベースアプローチ」を参照)



## コラム 10 : NTT DATA の AI ガバナンスに関する取組

### 1. NTT DATA における AI ガバナンス活動

NTT DATA は、公平かつ健全な AI の活用による価値創造と持続可能な社会の発展を目的に、2019 年から AI ガバナンス整備を開始した。国内外の AI ガバナンスの整備・運用は AI ガバナンス室が推進しており、その活動の全体像は 6 の領域からなる（[図 24](#)）。本稿では、AI ガバナンス実装に関わる具体的な取り組みとして、[図 24](#) の①②③⑤⑥の領域について紹介する。

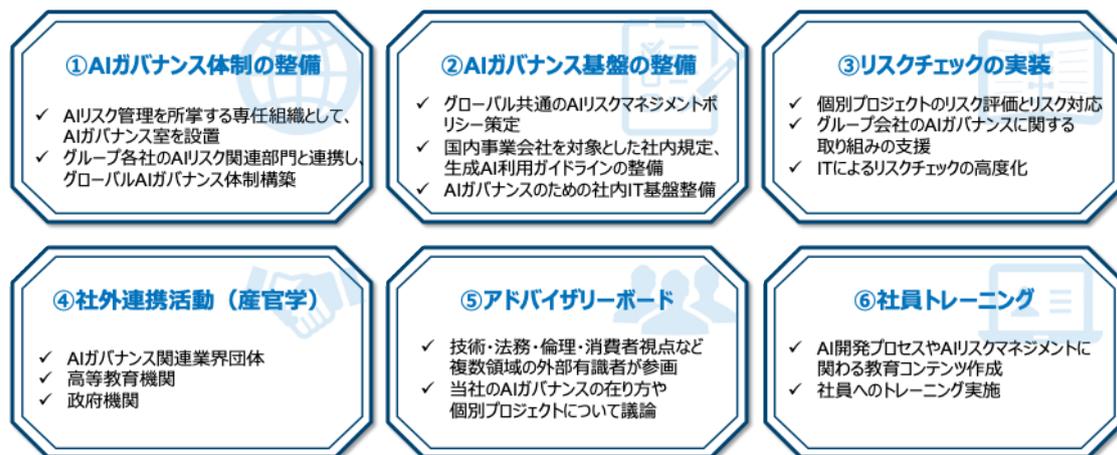


図 24. AI ガバナンスの活動

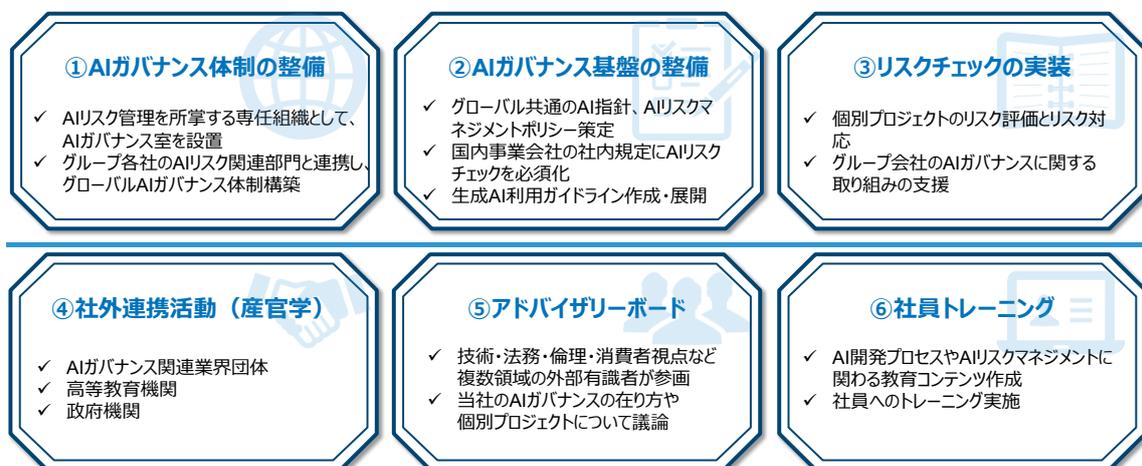


図 23. AI ガバナンスの活動

#### ① AI ガバナンス体制の整備

AI の活用によって生じるリスク（AI リスク）はビジネス規模に依らず多大な影響を及ぼすことを踏まえ、AI リスク管理を所掌する専任組織として、技術・法務・知財・情報セキュリティなど関連する分野の専門家を集めた AI ガバナンス室を設置。AIガバナンス室を設置した。国内外の約 600 社の 20 万人を対象に、グローバル全体でコントロールできる体制を整備するために、グループ各社に AI リスク関連窓口を設置し、連携体制を構築している。AIリスクの対処には、技術だけではなく、法務や知財、情報セキュリティといった広範

困な知見が必要なことから、技術・法務・知財・情報セキュリティの専門家を集めている。

<https://www.nttdata.com/global/ja/news/release/2023/032301/>

また、国内外の約 600 社の 20 万人を対象に、グローバル全体でコントロールできる体制を整備するために、グループ各社に AI リスク関連窓口を設置し、連携体制を構築している。

## ② AI ガバナンス基盤の整備

AI ガバナンスの実装に際し、以下の文書を採用・整備している。また、生成 AI 利用ガイドラインを実効的に機能させるため、外部の生成 AI サービスへのアクセス管理や入出力情報の監視・制御機能を持つ AI セキュリティツール（AI ファイアウォール）の全社的な導入も進めている。

- NTT グループ AI 憲章：NTT グループ各社が AI を活用する上での共通的な考え方。  
<https://group.ntt.jp/group/ai/charter.html>
- NTT データグループ AI 指針：NTT DATA が AI を活用する上での共通的な考え方。  
<https://www.nttdata.com/jp/ja/news/release/2019/052900/>
- AI リスクマネジメントポリシー：グローバル共通のポリシーとして、管理すべき AI リスクとマネジメントフレームワーク（各社の役割、責任範囲、実装要件）を定義した文書。
- 社内規程（プロジェクト意思決定プロセスへの実装）：AI を含む開発プロジェクト（AI プロジェクト）の実施に際して、AI リスクのチェックを必須化する社内規程。
- 生成 AI 利用ガイドライン：生成 AI に対する開発者・提供者・利用者の各立場に応じた留意事項と対応方針を示した文書。なお、この立場の分類は AI 事業者ガイドラインと共通である。

## ③ リスクチェックの実装

NTT DATA ではグローバルで AI プロジェクトに対して、AI リスクチェックを実施している。全ての AI リスクに対して“禁止レベル”、“高リスク”、“リスク無し”のいずれに該当するかを判定し、“禁止レベル”、“高リスク”と判定された AI プロジェクトについては、AI ガバナンス室がリスク対応を支援している。例えば一般向けの画像生成 AI を利用したサービスにおいて、検討の初期段階では生成物の著作権侵害が指摘されるモデルを採用するきわめてリスクの高い案件であったことから、リスク対応としてモデル変更を支援した。また、2025 年からはリスクチェックの実施件数の急増に伴い、社内の AI ガバナンス業務のさらなる効率化・高度化を実現するために、GRC（Governance/Risk management/Compliance）ツールを導入し、運用している。リスク対応は 2 つの STEP からなる。STEP 1 では全ての AI プロジェクトに対して、リスクを評価（セルフチェック）し、“禁止レベル”、“高リスク”、“リスク無し”のいずれに該当するかを判定する。STEP 2 では、“禁止レベル”、“高リスク”と判定された AI プロジェクトに対し、AI ガバナンス室がリスク対応を支援する。判断の難しい、未知の AI リスクが検知された際には、社外有識者からなる AI アドバイザリーボードのメンバーに、AI リスクの評価及び対応策についてアドバイスを求めている。

## ⑤ 社員トレーニング AI アドバイザリーボード

AI は技術の進化が速く、社会にも多大な影響を及ぼすことから、NTT DATA の AI ガバナンスの在り方や、個別プロジェクトのリスク対策について議論するために、外部有識者によるアドバイザリーボードを設置している。また、エージェンティック AI のような将来技術に対しても、リスクマネジメントと社会受容性の観点から先

行的な議論を進めている。<https://www.nttdata.com/jp/ja/trends/data-insight/2025/1105/>  
AIリスクの検知・対処を確実に行うためには、社員の AIリスクに対するリテラシー向上が重要と考え、AIリスクマネジメントやAI開発プロセスに関わる教育コンテンツを作成し、社員を対象にトレーニングしている。この教育コンテンツは、AIを提供するビジネス部門・コーポレート部門のそれぞれのロール別に作成しており、対処すべきAIリスクとその対処策について、具体例を交えて解説している。

## 2. 社会実装を見据えた AI ガバナンスの発展

NTT DATA では AI リスクマネジメントのプロセスを国際的な水準で整備・運用していることを証明するために、AI マネジメントシステムの国際規格である ISO/IEC 42001 の認証を 2025 年 11 月に取得した。  
<https://www.nttdata.com/global/ja/news/evaluation/2025/112701/>

以上の活動により、社内では 2023 年 4 月から 2024 年末までの約 200 件の AI プロジェクトについて、インシデント発生を抑制することができた。また、トレーニングを通じて社員の AI リスクに対する感度が向上したことにより、AI プロジェクトの早期段階で社員からの能動的な相談も増加した。

これらの実践的な活動で得られた知見を活かし、AI ガバナンスに関する民間団体での議論や自主的なガイドライン策定に積極的に参加している。NTT DATA は、今後も AI 事業者ガイドラインを参考に、活動の網羅性や達成レベルを自己評価することで、AI ガバナンス活動を継続的に改善する。

また、これらの AI ガバナンス整備や実装、リスク対応の知見を活かし、AI リスクマネジメントシステムの構築から運用・改善、および個別の AI システムのリスク評価、対応をトータルでサポートするコンサルティングサービス（[図 25](#)）として様々なお客様にも提供している。の提供を開始した。既に金融・通信・情報サービスといった多様な業種の企業から依頼を受け、支援を開始している。支援を通じて得られた知見を自社の活動へフィードバックすることで、さらに高度な AI ガバナンスを追求していく。

<https://www.nttdata.com/global/ja/news/topics/2024/073100/>

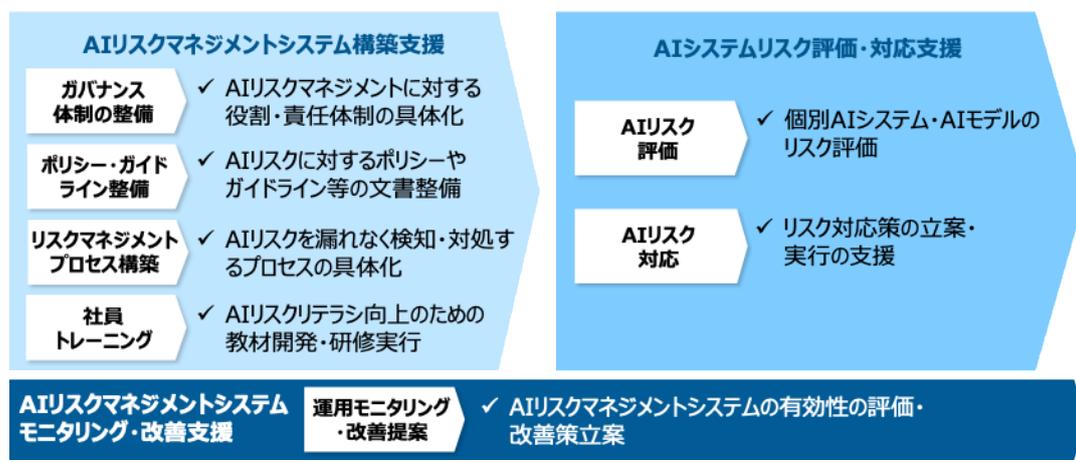


図 25. AI ガバナンスコンサルティングサービスの構成

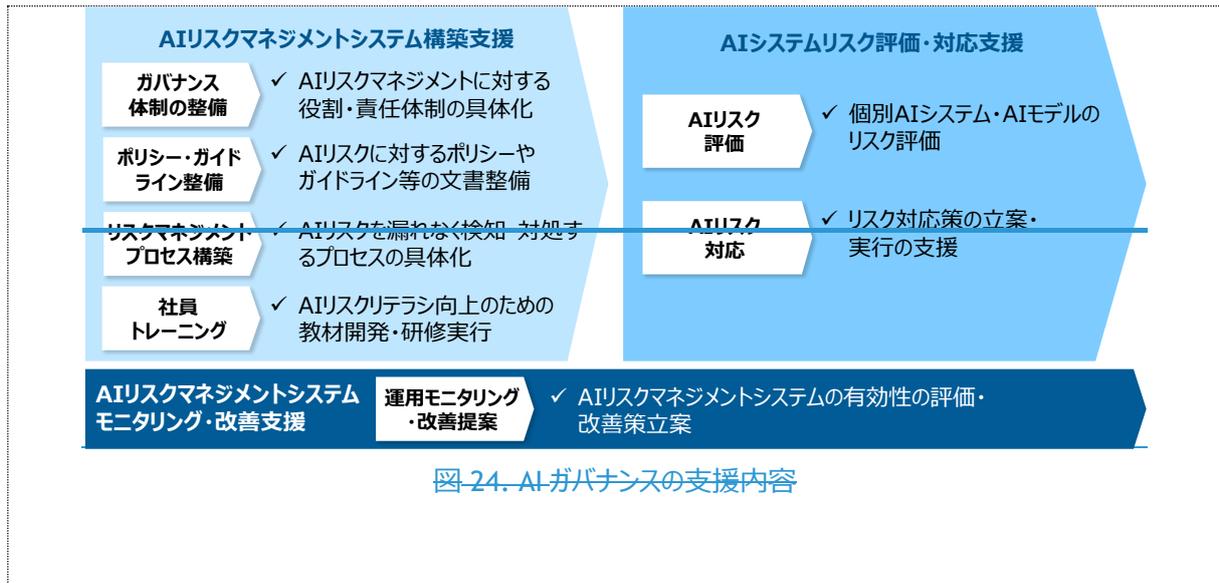
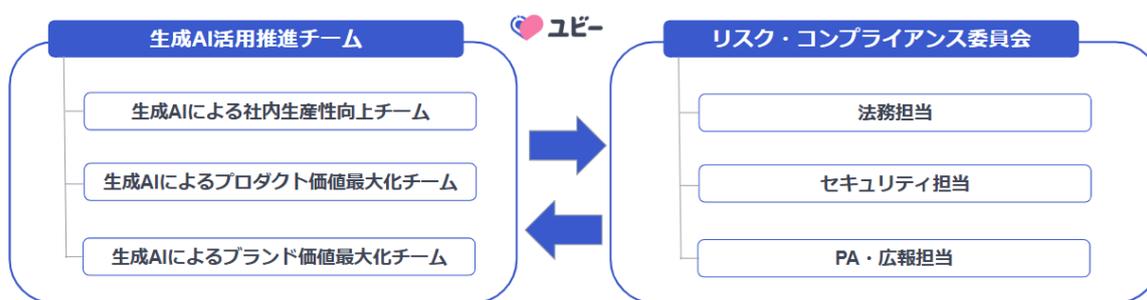


図-24. AIガバナンスの支援内容

## コラム 11： Ubie 株式会社の AI ガバナンスに関する取組

Ubie 株式会社は「テクノロジーで人々を適切な医療に案内する」ことをミッションとした医師とエンジニアで 2017 年に創業された医療 AI スタートアップ企業であり、医療機関向けの AI 問診・生成 AI サービス、生活者向けの症状検索エンジン等を提供している。

同社の AI ガバナンス体制として、社内に「生成 AI 活用推進チーム」及び「リスク・コンプライアンス委員会」を設置し、生成 AI を活用したプロダクト価値最大化や社内利用による生産性向上に取り組むと同時に、AI 利活用に当たっての法的論点やセキュリティ論点をはじめとしたリスクの検討を推進する体制を整備している（[図 26.Ubie 株式会社における AI ガバナンス体制](#) [図 25.Ubie 株式会社における AI ガバナンス体制](#)）。スタートアップ企業ゆえそれぞれの専門性を有する人材を潤沢に確保することは困難であるものの、階層型ではなくフラットな組織構造を採用することで、両会議体間における定期的な情報共有や議論を促進しており、このように縦割り意識を排して連携を行うことで、限られた人的資源の環境下でも、AI を取り巻く技術や制度に関する動向の目まぐるしい変化に応じたスピーディかつ適切な対応が可能となっている。



[図 26.Ubie 株式会社における AI ガバナンス体制](#)

[図 25.Ubie 株式会社における AI ガバナンス体制](#)

AI リスク対応として、ベンダーリスクやクラウドセキュリティリスク、データセキュリティリスク、社内広報ガイドラインを考慮し、法務・セキュリティ・レピュテーション等の観点でリスク評価・レビューを行い、リスクの発生可能性及び影響度を評価した上で優先順位を決めつつリスク対応策を検討実施している。当該評価は客観的なものとなるよう各リスク領域の専門人材が生成 AI 開発・利用部門とは独立した立場で実施し、リスク懸念がある場合はリスク・コンプライアンス委員会にて審議する体制としている。同社では、アジャイル開発の実態に合わせたリスク評価フレームワークの型化は現在取組中である。一方、顧客向け・自社向けシステム問わず、ユースケースやデータの機密性に応じて許容できるリスクを定めリスクへの対応策を実施している。例えば、同社が生成 AI サービスを提供する際、顧客である医療機関が保有する機密性の高いデータが、AI 開発者に閲覧・利用されてしまうリスクがあるが、同社では、原則医療機関のみがデータへのアクセス権限を有する仕組みや、モデルの学習へのデータ利用を防ぐ仕組みが、オプションとして用意されている生成 AI モデルのみを AI 開発者から採用する方針としている。

さらに、これらのリスク対応方針については会社のスタンスとして社外向けに発信も行っており、同社ホームページ上にはプライバシー保護やセキュリティ確保のための取組に関する情報をまとめた「安心安全のために」ページを公開し、顧客のプライバシー保護を最も重要な経営課題の一つと位置づけ、組織全体でプライバシー課題に取り組む体制を表明している。

## サービスを支える安心・安全への取り組み

Ubicelは、当社がサービスを提供するにあたり、お客様の情報を含む様々なデータを取得します。当社は、お客様のプライバシー保護を最も重要な経営課題の一つと位置づけ、組織全体でプライバシー問題に取り組む体制を整えています。当社は、当社が事業を行う国または地域において適用される法令および規制を遵守し、当社が定めるポリシーに基づいて適切にデータを保護していくことに努めてまいります。

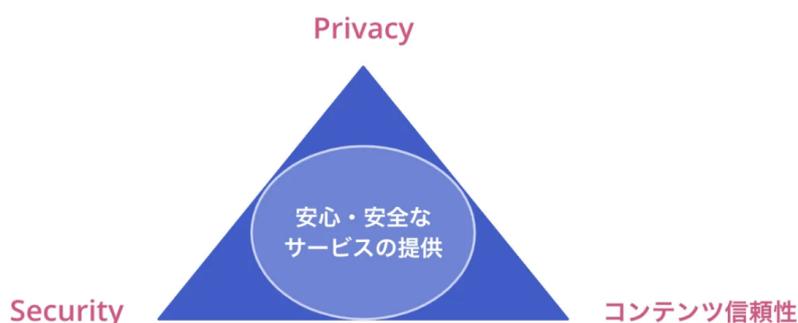


図 27.安心・安全への取り組みの基本方針

図 26.安心・安全への取り組みの基本方針

また、同社ではリスク対応だけでなく、社内での生成 AI の利活用推進を図るために、社員向け教育も精力的に取り組んでいる。例えば、全社員向けの生成 AI 基礎情報のオンボーディングやリスク・コンプライアンス研修の実施、社内生成 AI アイデアソン・ハッカソン開催のほか、社内表彰制度に「生成 AI 活用賞」を創設するなど、社員自身の生成 AI 理解度を向上させる取組を意欲的に実施。社内で利用できる生成 AI ツールの活用率調査も定期的実施しており、2024 年 1 月現在での利用率は 85%とほぼ全ての社員が生成 AI を活用して業務改善を行っている。

さらに、生成 AI をはじめとした AI の急速に変化する動向に対応するため、同社はヘルスケア領域における業界団体である「日本デジタルヘルス・アライアンス」に参加し、生成 AI に関する検討を行うワーキングリーダーを担当。当該業界団体を通して多種多様な会員企業と生成 AI に関する最新情報の共有や政策動向のキャッチアップなどを定期的実施し、2024 年 1 月に業界ガイドラインである「ヘルスケア事業者のための生成 AI 活用ガイド」を先駆けて策定し、2025 年 2 月に第 2.0 版として改訂版を策定するなど、生成 AI 領域におけるルールメイキングにも取り組んでいる。

## コラム 12：神戸市における AI 活用のためのルール整備

神戸市は、政令指定都市であり、人口約 150 万人（政令市 7 位）、市職員数は約 2 万人（教員含む）。同市は、一定のルール下で AI を効果的かつ安全に活用することを目的として、「神戸市における AI の活用等に関する条例」（以下「AI 条例」という）を制定している。対象は、神戸市及び市の業務を請負・受託等する事業者となる。AI 条例を策定する際には、AI 事業者ガイドライン及び EU の「AI 法（Artificial Intelligence Act）」をもとに、同市が AI 利用者として果たすべき責務を盛り込んだ。ガイドラインや法規制等の単語をそのまま利用するのではなく、市職員が理解しやすい単語に置き換えて利用する等の工夫を行っている。

AI 条例は、市が行政処分等に AI を用いようとする場合にリスクアセスメントを行うことを定める。AI の持つリスクをゼロとすることは現実的ではなく、職員が AI の持つリスクを正しく認識し、そのリスクに対処する仕組みを設けることが重要である。また、「リスクベースアプローチ」の考え方を参考に、行政処分等の市民の権利利益に重大な影響を与え得る判断に AI を活用する際には、リスクに応じた慎重な手続きを課し、それ以外には簡便なチェックとすることで、AI 活用の推進と安全確保のバランスを保つことに配慮している。

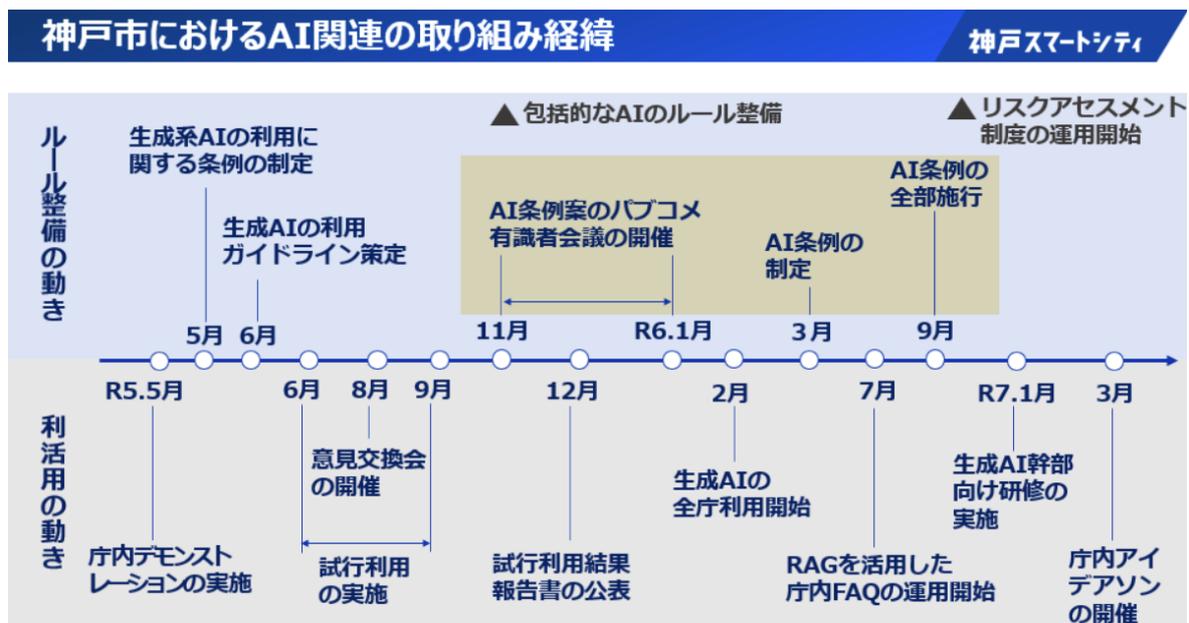


図 28. 神戸市における AI 関連の取り組み経緯

図 27. 神戸市における AI 関連の取り組み経緯

リスクアセスメントの項目として、①人間中心、②影響範囲の特定、③プライバシーの保護、④安全性の確保、⑤透明性の確保、⑥公平性の確保（バイアスへの対策）、⑦セキュリティの確保、⑧アカウントビリティの確保、⑨職員への教育、⑩判断の責任を定めている。

リスクアセスメント手法は、リスクの大きさにより使い分けている。市民の権利・利益に重大な影響を及ぼす可能性があるものは、情報セキュリティポリシー担当部門が 48 項目のワークシートに基づき審査を行い、それ

以外のものは、チェックシートに基づき所属長が確認を行う。評価基準の運用においては、専門家からなる AI 活用アドバイザーの助言も得ることとしている。

このようなルール整備と平行して、神戸市では市職員の AI 利活用が進んでいる。Microsoft Copilot の全職員利用、生成 AI を活用した各種アプリの内製、RAG を活用した庁内 FAQ 等の利用に加え、個別事例では画像判定等での活用（画像解析による AI 技術を利用した図面審査<sup>89</sup>等）などがある。それら利活用の前提として、生成 AI を利用する際に遵守すべき事項については、「神戸市生成 AI の利用ガイドライン」を策定して解説しているほか、AI 条例やガイドライン等のルールの定着に向けた教育も実施している。全庁において、「AI とは」からの初心者向けの研修を実施するとともに、所属長へは AI 条例に基づくリスクアセスメント制度の内容に関する研修を実施するといった取り組みを行っている。

<sup>89</sup> 詳細は、公益社団法人 日本水道協会 水道技術総合研究所による『令和 6 年度水道イノベーション賞 応募事例集』の AI 審査アプリを活用した給水装置工事図面審査（神戸市水道局）の事例を参照のこと。  
[http://www.jwwa.or.jp/info/pdf/innovation/innovation\\_r6\\_apply.pdf](http://www.jwwa.or.jp/info/pdf/innovation/innovation_r6_apply.pdf)

### コラム 13 : IBM の AI ガバナンスに関する取組

IBM コーポレーションにおける AI ガバナンスの推進は、2025 年に AI 倫理委員会から名称を変更した「責任ある技術委員会(Responsible Technology Board)」により支えられている。この名称変更は、AI に限らず様々な新規技術の開発と提供を導くという、より広いビジョンを反映したものである。業界において先駆的な取り組みであったこの委員会は 2024 年で 5 周年<sup>90</sup>を迎え、設立以来、IBM の「信頼と透明性の原則」を事業全体で実践化している。委員会の使命は以下の通り：

「IBM が AI や量子計算のような新規技術を開発・提供する際に、ガバナンス、基準、および原則の実践的な適用方法を提供する。これにより IBM の各チームは、当社の価値観に基づき、自信を持って迅速に行動し、重要なインパクトを生み出すことが可能となる。つまり、お客様、パートナー、そして社会のために、責任ある技術の進歩を実現することができるのである。」

この委員会は、上級役員が定めた戦略方針に従って活動し、委員会メンバーは当社各部門の上級幹部で構成されている。各メンバーは自分の担当する部門や地域のための担当者(フォーカルポイント)を指名する。委員会の運営は、事業部・地域の担当者と緊密に連携する「責任ある技術プロジェクトオフィス」が支援している。また、すべての IBM 社員は、支援者ネットワークに自発的に参加し、委員会の活動について学んだり貢献したりすることができる(図 29 参照)：

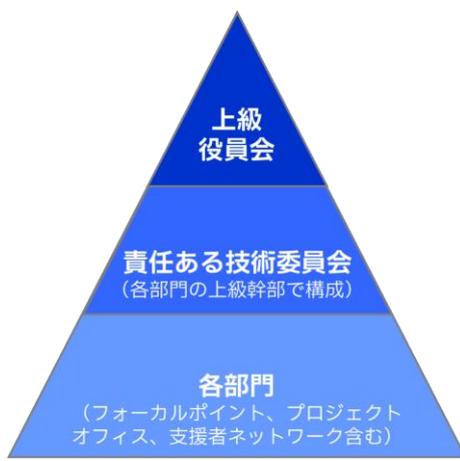


図 29. 責任ある技術委員会を中心とした IBM の AI ガバナンス推進体制

この委員会は、その原則と実践を IBM のソリューション、業務プロセス、文化に浸透させると共に、将来を見すえたガバナンスと指導を行っている。統合的なガバナンス活動<sup>91</sup>の一環として、委員会とそのサポートをする事業部・地域の担当者は、案件を審査することで、事業部に対してガードレールと指導を提供する。

<sup>90</sup> イノベーションと信頼のバランス：IBM AI 倫理委員会のメンバーが IBM の責任ある AI 原則の実施について語る、<https://www.ibm.com/jp-ja/think/insights/balancing-innovation-and-trust>

<sup>91</sup> IBM Office of Privacy and Responsible Technology 一元的な AI ガバナンスでイノベーションを加速、<https://www.ibm.com/jp-ja/case-studies/ibm-office-of-privacy-and-responsible-technology>

委員会はまた、IBM、業界、そして社会が AI と新規技術がもたらす機会と課題を乗り越えるための手助けとして、過去 2 年間に、基盤モデル<sup>92</sup>、AI エージェント<sup>93</sup>、AI に焦点を当てたチェンジマネジメント<sup>94</sup>、そして合成データ<sup>95</sup>に関して、優れた実践方法を含めた先導的な考え方を記事として発行してきている。委員会は、基礎研究所や製品・サービス事業部門などの他の部門と緊密に連携し、責任あるイノベーションを大規模に加速させる成長エンジンとして機能している。

さて、日本の AI 倫理チームは、日本市場における AI ガバナンスの取り組みを強化するために、2022 年に発足した。このチームは、IBM の AI ガバナンス推進体制（図 29 参照）の中で、日本地域を担当するフォーカルポイントとしての役割を果たし、責任ある技術委員会と協力して、日本の従業員が責任を持って AI を開発・提供・利用できる環境の構築・運用を担っている。この役割において、個別の AI 案件についての相談を受けた場合、相談者と共に AI の安全な利用方法を慎重に探求し、適切な道筋を示す姿勢を大切にしている。従業員から信頼されるチームとなることで、AI ガバナンスが AI 利用促進の足かせにならないよう心掛けている。チームメンバーは多様な専門性を有し、法務、サービス事業、製品事業、基礎研究、製品開発の各分野の専門家で構成されている。AI 案件の審査や従業員教育など IBM 社内での活動に加え、書籍の執筆、各種外部講演、政府機関や業界団体が主導する AI ガバナンス活動の検討委員参加など、社外向けの活動も積極的に行っている。これらの取り組みが評価され、2025 年には人工知能学会倫理委員会が実施する「第 3 回 AI-ELSI 賞」の Practice（実践）賞を受賞している。

<sup>92</sup> IBM AI 倫理委員会「基盤モデル：機会、リスク、軽減策」（2024 年 2 月）、

<https://www.ibm.com/downloads/documents/jp-ja/10a99803d8afd656>

<sup>93</sup> IBM AI 倫理委員会「AI エージェント：機会、リスク、軽減策」（2025 年 3 月）、

<https://www.ibm.com/downloads/documents/jp-ja/1227c12efb38b2b3>

<sup>94</sup> IBM Office of Privacy and Responsible Technology “Accelerating Business Value through AI-Focused Change Management”（2025 年 4 月）、<https://www.ibm.com/downloads/documents/us-en/12fc84a11ed9542e>

<sup>95</sup> IBM Responsible Technology Board “Unlocking AI Opportunities with the Responsible Generation and Use of Synthetic Data”（2025 年 8 月）、<https://www.ibm.com/downloads/documents/us-en/1379d3325a5ae60f>

## コラム 14 : AWS の AI ガバナンス取組事例

### ① ISO/IEC 42001:2023 認証の取得

アマゾン ウェブ サービス (AWS) は 2024 年 11 月、AI サービスに対する ISO/IEC 42001:2023 AI マネジメントシステムの認証を取得しました。この国際標準は、組織が AI システムの責任ある開発と使用を促進するための要件と統制を定めており、独立した第三者機関により、AI 開発・展開・運用におけるリスクと機会の管理への継続的な取り組みがなされていることを認証するものです。

### ② AI ガバナンスポリシーの策定

AWS の責任ある AI の実践において、AWS は技術の進歩に応じて評価・更新される 8 つの中核的な項目を定義しています。公平性では、異なるステークホルダーグループへの影響を考慮し、説明可能性では、システム出力の理解と評価を重視しています。プライバシーとセキュリティでは、データとモデルの適切な取得・使用・保護を徹底し、安全性では有害なシステム出力や悪用の防止を図っています。制御可能性では AI システムの振る舞いをモニタリング・制御するメカニズムを提供し、真実性と堅牢性では予期しない入力や敵対的入力に対しても正確なシステム出力を実現することを目指しています。ガバナンスではプロバイダーから消費者まで含む AI サプライチェーン全体でのベストプラクティスの取り込みを、透明性では利害関係者が AI システムとの関わり方について十分な情報に基づいた選択ができる環境の提供を重視しています。

<https://aws.amazon.com/jp/ai/responsible-ai/>

### ③ ステークホルダーとの連携

また、責任ある AI に関するガバナンスへの取り組みにおいて、AWS は様々な業界パートナーや、政府、規制当局と積極的に連携しており、AI が進化する基準に沿った取り組みを行い、責任ある AI の開発に貢献しています。例えば、Frontier Model Forum や Partnership on AI などの国際的なコンソーシアムを通じて、AI 安全性研究を推進し、技術標準の策定を主導しています。このようにマルチステークホルダー組織との深い関わりを保持し、AI 技術の進歩と責任のバランスを取りながらイノベーションを促進し、相互運用性を推進することを目指しています。

AWS は単なる技術提供にとどまらず、組織的なガバナンス体制の構築、国際標準への準拠、そして実践的なツールとガイダンスの整備といった AI 技術の責任ある発展と社会実装に向けた包括的な取り組みを推進しています。

## 別添 3.AI 開発者向け

本章では、まず、本編「第 3 部 AI 開発者に関する事項」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。その後本編「第 2 部 AI により目指すべき社会と各主体が取り組む事項」の「C. 共通の指針」のうち、AI 開発者について特に意識すべき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 及び生成 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。具体的な対応の検討にあたっては、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、各主体の資源制約等に配慮することが重要である。

また、高度な AI システムを開発する主体は、[広島 AI プロセスの「全ての AI 関係者向けの広島プロセス国際指針」](#)[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」](#)<sup>96</sup>（本編「第 2 部 AI により目指すべき社会及び各主体が取り組むべき事項」の「D. [広島 AI プロセス「全ての AI 関係者向けの広島プロセス国際指針」](#)高度な AI システムに関する事業者に通の指針」の記載）[（に即した行動をすべきであり、加えて、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」](#)<sup>97</sup>（後述する C. [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](#)[高度な AI システムの開発にあたって遵守すべき事項](#)）[を参照することが望ましい](#)についても遵守すべきである。

<sup>96</sup> 総務省「[全ての AI 関係者向けの広島プロセス国際指針](#)」[外務省「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」](#)（2023 年 10 月）,

<https://www.soumu.go.jp/hiroshimaiprocess/pdf/document03.pdf><https://www.mofa.go.jp/mofaj/files/100573469.pdf>

<sup>97</sup> 総務省「[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](#)」[外務省「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）,

<https://www.soumu.go.jp/hiroshimaiprocess/pdf/document05.pdf><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]

AI モデルの質の向上のために、AI 開発者は、AI 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（正確性及び完全性等）に留意する<sup>98</sup>
- 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、適用できる技術水準、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、著作権等の権利又は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
- 権利又は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、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及びコンソールを提供すること
  - データ暗号化

<sup>98</sup> マルチモーダルな生成 AI の場合、異なる形式のデータを統合して処理するため、各モダリティのデータ品質及びデータ量が AI の性能に直接影響する。そのためデータに適切な前処理を施すことや、バランスよくデータを用意すること等の配慮が重要となる。

◇ データを転送する際及び保存する際に、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

➤ 必要最小限のデータ入力・参照

◇ AIの判断に必要な最小限の範囲にデータを限定し、不要な属性情報の付与を避けること

- データが適切（正確性及び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どのように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 AI 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、AI 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潜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、AI 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、AI モデルが代表性のある<sup>99</sup>データセットで学習され、AI システムに不公正なバイアス（特定の個人・集団に対し、合理的に説明できない不利益をもたらすバイアス）がないか点検されることを確保する（「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。なお、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ことが期待される。

- データは、ある事象又は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、データに偏りが生じたり、特定のコミュニティがデータ上に過少又は過剰に現れたりするリスクがある<sup>99</sup>ことに留意する。また、その基礎となるデータに偏り又は過少代表・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
- 手法としては、センシティブ属性の設定、データ整備、評価指標の設定、評価といったステップを踏むことも有効である

[具体的な手法]

- 学習前
  - 使用しない特徴量<sup>100</sup>の決定
    - ◇ 不公正なバイアスが 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、性別といった偏見及び差別が生じる可能性のある属性を AI モデルに学習させない
    - ◇ AI 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（すべて国民は、法の下に平等であって、人種、信条、性別、社会的身分又は門地により、政治的、経済的又は社会的関係において、差別されない）が列挙する事由及び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
  - データ品質の管理・向上

<sup>99</sup> 後者は「過少代表・過剰代表（underrepresentation and overrepresentation）」の問題といわれる。

<sup>100</sup> 特徴量は、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徴量に該当する。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
  - ◇ 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）にもとづいた評価
- 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
    - データ及び学習過程・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の質及び量を見直す等のデータの再構築を検討
    - データの適切な保管及びアクセスコントロールの実施
      - ◇ データの暗号化及びセキュアな保管
      - ◇ データの保管及びアクセスに関する「ISO/IEC 27002」（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－情報セキュリティ管理）への準拠
- ~~—RAG 活用時~~
    - ~~—RAG を活用する場合、参照するデータの適切な取扱い~~
    - ◇ ~~—情報源の選択、データの前処理、チャンク化、ベクトルデータベース構築等を適切に実施する~~

#### [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）
- 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）
- 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 [2025.04 版](#)」（2025 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）

コラム 153 : 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<sup>101</sup>

【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 及び機械学習手法にもと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 Design<sup>102</sup>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、取引履歴等の属性及び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、ビジネス上の要件及び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、文化又は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、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 Foundation<sup>103</sup>配下の Intersectional Fairness プロジェクトによる OSS 技術の活用<sup>104</sup>

- 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

<sup>101</sup> 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 24030:2024（2024）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/84144.html>）

<sup>102</sup> 富士通「プレスリリース 文化やビジネス慣習によって異なる公平性を設計段階から考慮する AI 開発手法 Fairness by Design を開発」

（2021年3月）, <https://pr.fujitsu.com/jp/news/2021/03/31-1.html>

[2024年1月、富士通はAIモデルの公平性の検証や改善ができる Fujitsu AI Ethics for Fairness を一般公開した。](https://documents.research.global.fujitsu.com/ai-ethics-fairness/)

<https://documents.research.global.fujitsu.com/ai-ethics-fairness/>

<sup>103</sup> The Linux Foundation「ホームページ（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/>

<sup>104</sup> The Linux Foundation Projects, “Intersectional Fairness”, <https://lfaidata.foundation/projects/intersectional-fairness-isf/>

富士通「プレスリリース 富士通の自動機械学習技術と AI 公平性技術が、Linux Foundation のオープンソースプロジェクトとして始動」（2023年9月）, <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・身体・財産、精神及び環境に配慮した開発**

- ◇ ステークホルダーの生命・身体・財産、精神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、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・身体・財産、精神及び環境に危害を及ぼすことのないよう留意する。

なお、AI 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、社会において開発した AI が実用化される前の段階において、実験室内、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、AI 開発者は、仮に、危害を及ぼした場合に講ずるべき措置を、あらかじめ整理しておくよう留意する。

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、稼働を続行できる設計方針
  - 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、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、人間の最終判断を経る等、機能の一部停止及び縮小を可能にする設計方針
  - 特定されたリスク及び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、当該確認事項にもと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及び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に応じ、必要な手順にて実施
    - ◇ 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）
    - ◇ AI システムの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
  - （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]

- 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）
- 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）
- 独立行政法人情報処理推進機構「SEC journal Vol.10 No.3 特集「信頼性と安全性」」（2014年9月）
- 独立行政法人情報処理推進機構「ホワイトハッカー勉強会 初級編」（2018年9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）
- The University of Electro-Communications（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）
- World Economic Forum, “The Presidio Recommendations on Responsible Generative AI”（2023年6月）

## コラム 164 : 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又は 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 API<sup>105</sup>（差別、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 及び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、Safety Checker<sup>106</sup>という安全性のチェックツールを活用した<sup>107</sup>。

<sup>105</sup> Profanity Classification API

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

<sup>106</sup> Safety Checker

[https://github.com/huggingface/diffusers/blob/main/src/diffusers/pipelines/stable\\_diffusion/safety\\_checker.py](https://github.com/huggingface/diffusers/blob/main/src/diffusers/pipelines/stable_diffusion/safety_checker.py)

<sup>107</sup> 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

- ◇ 開発時に想定していない AI の提供・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 AI の使い方について明確な方針・ガイダンスを設定する（「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、真正性等）（「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インシデント、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又は 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 モデルの選択・調整
  - AI モデルの真正性
    - ◇ 採用する AI モデルについて、開発元や取得経路が信頼できることを確認
  - データの特性
    - ◇ 元の AI モデルが訓練されたデータと、新しいタスクにおけるデータの特性を比較し、元の AI 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
  - 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 AI 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 AI モデルと新しいデータ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、語彙の拡張等の調整を検討
  - データドリフトや性能変化への対応
    - ◇ 運用中も AI モデルの状態・入力・出力のモニタリング結果を記録し、必要に応じて品質維持のための措置を検討

[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 利用者又は業務外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、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、AI モデルが代表性のあるデータセットで学習され、AI システムに不公正なバイアスがないか点検されることを確保する（「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。なお、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ことが期待される。

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、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には、憲法 14 条 1 項が列挙する事由及び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もとづき予測を実施（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 AI 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
- 複数の AI モデルを併用した多面的評価
- 社会的文脈及び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（不確実性が高く）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（人種・信条・性別等様々な社会的属性によるバイアス）が含まれていること等により、特定の個人や集団への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 システムの用途、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 AI システムのセキュリティを確保する。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、手戻りが少なくなり、保守性の良い AI システム・ソフトウェアの作成及び提供につながる。

LLM を含む機械学習システムは、従来の情報システムに加え、アセット（学習データ・AI モデル・パラメータ等）、ステークホルダー（AI モデル提供者等）という要素及び確率的な出力といった性質があるため、更なる分析手法及び管理策の改善が求められる。よって、機械学習の技術的な特徴を踏まえたセキュリティの分析手法及び対策手法を開発し適用することが重要である。

[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及び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、可用性、保守性、性能等がある。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
      - 自組織で使用している基準又は他のフレームワークから適切なものを選択し、組織として合理的かつ技術的に可能な範囲で複数の手法を組み合わせ、セキュリティ要件を定義
    - ◇ セキュリティアーキテクチャ（Security Architecture）
      - 開発した AI を組み込んだ AI システムに求めるアーキテクチャ情報を AI 提供者に提供する
      - AI システムを搭載するプラットフォーム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て利用

- ◇ 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に関してを可視化及び構成管理を容易にするための  
に SBOM を作成
- ◇ AIBOM(AI Bill of Materials)
  - AI システムの構成管理を容易にする AIBOM を作成
- ◇ オープンソースソフトウェアの責任ある利用
  - 責任をもって利用するために開発元や取得経路が信頼できることを審査すること
  - 依存関係を明確にすること
  - オープンソースの問題解決、開発、メンテナンス維持に貢献すること
- セキュリティ対策の強化
  - リスク評価
    - ◇ 情報セキュリティに対するリスク評価を実施し、リスクの特定及び優先順位付けを行う
      - 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
      - SP800-30: リスクアセスメントの実施の手引き
  - アクセス制御と認証
    - ◇ 必要最小限のアクセス権を付与し、AI 開発者又は管理者が AI システムにアクセスする際には、厳格な認証手段を採用
      - 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
      - SP800-53: 組織と情報システムのためのセキュリティ及びプライバシー管理策
    - ◇ 各主体にとって重要な知的財産及び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、契約等にもと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、意識向上の教育及びトレーニングを実施
      - ISO/IEC 27002: 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 – 情報セキュリティ管理策
      - SP800-50: IT セキュリティの意識向上及びトレーニングプログラムの構築
  - 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、データの保存及び処理時にもセキュリティプロトコルを適用
      - 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
      - SP800-53: 組織と情報システムのためのセキュリティ及びプライバシー管理策
  - 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、手順を整理・確立し、情報システム及び資産を防御
      - 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

- SP800-37: 連邦政府情報システムに対するリスクマネジメントフレームワーク適用ガイド：セキュリティライフサイクルによるアプローチ
- 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った場合には速やかにオープンソースの更新を実施
    - ISO/IEC 27009: サプライチェーンのセキュリティ管理
    - SP800-161: サプライチェーンリスクマネジメント
- 保守
  - ◇ 承認・管理されたツールを用いて保守作業の実施及び保守作業の記録
    - 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
    - SP800-40: パッチ及び脆弱性管理プログラムの策定
- 監視とインシデント対応
  - ◇ 監視システムを構築し、AI システムに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
    - 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
    - SP800-61: コンピュータインシデント対応ガイド
- 攻撃手法の例としては「表 7. 機械学習利用システムの被害と脅威の例」[表-6.機械学習利用システムの被害と脅威の例](#)を参照のこと

表 76. 機械学習利用システムの被害と脅威の例<sup>108</sup>

被害の内容			被害を引き起こす脅威	
			機械学習特有の脅威	その他の脅威
完全性 又は可 用性の 侵害	システム の誤作 動	意図に反 する機械学 習要素の 動作による	データポイズニング攻撃	機械学習要素を実装するソ フトウェア・ハードウェアに対す る従来型の攻撃
			モデルポイズニング攻撃	
			汚染モデルの悪用	
			回避攻撃	
		その他の要 因による		システムに対する従来型の 攻撃
	計算資 源の浪 費	機械学習 要素による	データポイズニング攻撃（資源枯渇型）	機械学習要素を実装するソ フトウェア・ハードウェアに対す る従来型の攻撃
			モデルポイズニング攻撃（資源枯渇型）	
			汚染モデルの悪用	
スポンジ攻撃				
	その他の要 因による		システムに対する従来型の 攻撃	
機密性 の侵害	AI モデルについての情 報の漏洩	モデル抽出攻撃	AI 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	データを窃取する従来型の 攻撃	
		データポイズニング攻撃（情報埋込型）		
その他の機密情報の漏 洩	モデルポイズニング攻撃（情報埋込型）			

[参考文献]

- 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）
- 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 ver2.0」（2024~~3~~年 8~~7~~月）
- 総務省「AI のセキュリティ確保のための技術的対策に係るガイドライン」（2026 年 3 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）
- 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）
- NCSC, “Guidelines for secure AI system development”（2023 年 11 月）
- NIST, “The NIST CYBERSECURITY FRAMEWORK (CSF) 2.0”（2024 年 2 月）
- ISO/IEC27000 シリーズ
- NIST, SP800 シリーズ

<sup>108</sup> 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）より引用

[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 の予測性能及び出力の品質が、活用開始後に大きく変動する可能性又は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・保存すること及び 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、契約で求められる「文書」、「記録」等も参考に、適切なログの記録及び保存を行う。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・保存期間・保存方法（保存場所、保存容量 等）
    - ◇ 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。また、LLM 等においては結果とその根拠を出力にできるよう求めることができるが、AI 内部の決定ロジックについて説明しているわけではなく、結果と根拠のもっともらしい組み合わせを出している点で、従来型の AI の説明可能性とは別途検討すべきである点に注意する
  - 単純な AI モデルの使用
    - ◇ 要件に合わせて、できるだけ単純な AI 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
    - ◇ AI 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 AI 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）

- ◇ ゲーム理論にもとづいて各特徴が AI 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<sup>109</sup>
    - ◇ AI 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及び部分依存プロット等が含まれる
  - AI モデル内部の解析
    - ◇ AI モデル内部の構造及び動作を詳細に解析する手法を採用
    - ◇ TensorFlow、PyTorch 等のフレームワークでは、モデルの中間層の出力及び勾配を可視化することも可能
  - AI 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、AI 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、AI 利用者等）によるフィードバック及び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、ラベリング及び免責事項の表示並びにその他の仕組みの導入も検討
- RAG の導入による出力根拠の透明性向上
- 外部の情報源を検索して回答を生成する際、出典や引用元等を示すことが可能となる
- 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）
- 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 [2025.04 版](#)」（2025 年 4 月）
- ISO, “ISO/IEC 23894:2023 ( Information technology-Artificial intelligence-Guidance on risk management) ”（2023 年 2 月）
- The White House, “Blueprint for a AI Bill of Rights (Notice and Explanation) ”（2023 年 3 月）
- World Economic Forum, “The Presidio Recommendations on Responsible Generative AI”（2023 年 6 月）

<sup>109</sup> マルチモーダルな生成 AI の場合、どのモダリティが最終決定にどれだけ影響を与えたかを説明するのが難しくなるため、モデルの出力結果を解釈する手段の考慮や各モダリティの影響を明確化する工夫が重要となる。

[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]

- 独立行政法人情報処理推進機構「AI（Artificial Intelligence）の推進」<sup>110</sup>
- 独立行政法人情報処理推進機構「JVN iPedia 脆弱性対策情報データベース」<sup>111</sup>
- Cornell University, “arXiv”<sup>112</sup>

<sup>110</sup> 独立行政法人情報処理推進機構「AI（Artificial Intelligence）の推進」, <https://www.ipa.go.jp/digital/ai/index.html>

<sup>111</sup> 独立行政法人情報処理推進機構「JVN iPedia 脆弱性対策情報データベース」, <https://jvndb.jvn.jp/index.html>

<sup>112</sup> Cornell University, “arXiv”, <https://arxiv.org>

[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

- ◇ 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）情報を提供する（「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」）
  - 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並びに不具合の原因及び対応状況（「2）安全性」）
  - AI システムの更新を行った場合の内容及びその理由の情報（「2）安全性」）
  - AI モデルで学習するデータの収集ポリシー、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及び安心感の獲得、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又はソースコード自体の開示を想定したものではなく、プライバシー及び営業秘密へ配慮しつつ、採用する技術の特性及び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 を活用している旨及び AI を活用している範囲の表示
- 倫理に関する AI ポリシーの策定・明確化
  - 倫理的な原則及び方針を公表し、AI 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組及び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
  - 関連するステークホルダーが導入後に問題又は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” (2019年4月)
- ISO, “ISO/IEC 23894:2023 (Information technology-Artificial intelligence-Guidance on risk management) ” (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 提供者に対して、AI には活用開始後に予測性能又は出力の品質が大きく変動する可能性、想定する精度に達しないこともある旨、その結果生じうるリスク等の情報提供及び説明を行う。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、AI モデルの学習過程、AI 利用者又は業務外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、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、社会的文脈及びリスクの大小に応じた説明を行うと同時に、開発内容及び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又はソースコード自体の開示を想定したのではなく、プライバシー及び営業秘密へ配慮しつつ、採用する技術の特性及び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
  - 透明性及び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”（2019年4月）
- ISO, “ISO/IEC 23894:2023（Information technology-Artificial intelligence-Guidance on risk management）”（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

- ◇ トレーサビリティ及び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及びラベリング、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、報告されたインシデント等について、適切に文書化し、これを維持/保持し、第三者による検証可能な状態の確保及び特定されたリスク並びに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
  - AI 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として記録を残す
    - ◇ 上記の実施にあたっては、AI システムにおいて予期せぬインシデントが発生した際に、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適切な文書化を行い、特定されたリスク及び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てよい
  - 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 (Information technology-Artificial intelligence-Guidance on risk management)” (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**

- ◇ 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」）
  - AI の品質・信頼性、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及び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又は学会への参加の取組等、国際化・多様化及び産学官連携を推進する
  - 社会全体への AI に関する情報提供を行う

[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情報共有の基準、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
  - 安全性向上及び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、本編「第 3 部 AI 開発者に関する事項」では触れられていないが、本編「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の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行動することが重要である。

#### ● 「①人間の尊厳及び個人の自律」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、人間の尊厳及び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、諸外国及び研究機関における生命倫理の議論等を参照する<sup>113</sup>
- 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、アウトプットの正確性を可能な限り維持させつつ、AI の予測、推奨、判断等の限界を理解して利用し、かつ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 システムが人間の意図や価値観に沿って適切に機能するようにするための取組（アライメント）の実施
- AI 倫理を所管する担当役員及び 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及び研究機関における生命倫理の議論の例は以下のとおり
  - ◇ 国際連合（UN）、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した開発が有用
  - ◇ プロファイリングに使用されるデータ又は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
    - データ及びアルゴリズムの出力のモニタリング

<sup>113</sup> Brain-computer interfaces and the governance system: Upstream approaches（2022 年） では、BCI（脳・身体と連携する技術）に関するガバナンスの課題に対応するため、上流段階での予防的アプローチが示されている。

- AIでの判断だけでなく、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取扱うこと
  - 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 AI 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、認知等、感情を不当に操作することを目的とした、又は意識的に知覚できないレベルでの操作を前提とした 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<sup>114</sup>等の AI に過度に依存するリスクに注意を払い、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又は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、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取り扱う

[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への対応策として、AI 提供者に対し、AI 利用者及び業務外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、アルゴリズムの見直し 等
- 選挙、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、例えば、最終的な判断を人間が実施すること、技術的な側面ではなく倫理的な観点からも AI システム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<sup>115</sup>

[具体的な手法]

<sup>114</sup> 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。

<sup>115</sup> 国立研究開発法人情報通信研究機構（NICT）と KDDI 株式会社により、生成 AI の課題となっているハルシネーションの抑制を可能とする高性能な LLM の開発を目指す共同研究が行われている。

- 例えば、AI の出力の適切な利用を確保するために、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」及び「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]

  - 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、選択の機会の判断のための情報を適時かつ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 AI モデルに入力されたデータについて、追加学習等への活用方法
    - ◇ 学習に使用されたデータの収集源及び処理の情報
  - アルゴリズム及び AI 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
    - ◇ 入力・出力の例示
  - 変更及び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 AI 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 AI モデルの代わりに、軽量でリソース効率の高い AI モデルを利用することで、エネルギー効率を向上
  - AI モデルのサイズの最適化
    - ◇ 計算リソースの効率的な利用及びエネルギー消費の最小化を意識した AI モデル設計並びに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、冗長性の排除及び不要なデータの取得の回避

[参考文献]

- 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）
- 総務省「インターネット上の偽・誤情報対策に係るマルチステークホルダーによる取組集」（2024年5月）
- EU, “Ethics Guidelines for Trustworthy AI”（2019年4月）
- OIS Research Conference, “AI and Citizen Science for Serendipity”（2022年5月）
- 欧州評議会「人権、民主主義及び法の支配の観点からの AI システムに関するリスク・影響評価手法（HUDERIA）」（2024年11月採択予定）

[本編の記載内容（再掲）] ※ 柱書のみ抜粋

#### 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。

- 「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、各主体のプライバシーポリシーの策定・公表等により、社会的文脈及び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<sup>116</sup>（機械学習特有の攻撃手法については、「表 8. 機械学習特有の脅威・攻撃界面・攻撃実行フェーズ・攻撃者・攻撃手段の例」[表 7. 機械学習特有の脅威・攻撃界面・攻撃実行フェーズ・攻撃者・攻撃手段の例](#)を参照）
  - ◇ 適切な暗号化手法及び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
  - ◇ AI 利用者がシステムを使用する際に個人情報などプライバシー情報を入力してしまう可能性があるため、システム入力時におけるプライバシー情報の有無の判断や秘匿を補助する仕組みを導入
- 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
  - ◇ データ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

<sup>116</sup> RAG の活用など外部のサービス・データ等と連携する場合は、意図しない範囲に重要情報（個人情報・機密情報等）が漏洩してしまうこと等の危険性が高まるため、データの匿名化やアクセス制限の適用などを通じたプライバシー保護とセキュリティの確保が特に重要となる。

- ◇ 品質マネジメントの実施項目（「表 9. 品質マネジメント実施項目の概要表 8-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 にもとづく個人情報管理システム（PIMS）のための拡張要件を記載
    - 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

[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）
- 独立行政法人情報処理推進機構「SEC journal 第 45 号 巻頭言」（2016 年 7 月）
- 独立行政法人情報処理推進機構「安全なウェブサイトの作り方」（2021 年 3 月）
- ISO, “Guidelines for privacy impact assessment”
- Northwestern University, “Secure Machine Learning over Relational Data”（2021 年 9 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）

表 87. 機械学習特有の脅威・攻撃界面・攻撃実行フェーズ・攻撃者・攻撃手段の例<sup>117</sup>

脅威	攻撃界面のアセット	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	学習データの採取元	学習データセットの収集・加工時	外部攻撃者	学習データの採取元の改変
	学習データセット	学習データセットの収集・加工時 システム開発時	データ提供者 システム開発者 外部攻撃者	学習データセットの改変
モデルポイズニング攻撃	事前学習モデル	事前学習モデルの学習・提供時 システム開発時	AI モデル提供者 システム開発者 外部攻撃者	事前学習モデルへのバックドアの設置
	学習機構	システム開発時	システム開発者 外部攻撃者	悪意ある訓練用プログラム
	訓練済 AI モデル	システム開発時 システム運用時		AI モデルの改変
モデルの汚染の悪用	運用時入力データの採取元 運用時入力データシステム	システム運用時	システム利用者 システム運用者	バックドアを悪用する運用時入力 (モデルに埋め込まれた情報を窃取するための) 運用時の出力情報等の観察
モデル抽出攻撃	運用時入力データの採取元 運用時入力データシステム	システム運用時	システム利用者 システム運用者	運用時のシステムに対するデータの入力 運用時出力情報等の観察
回避攻撃 スポンジ 攻撃	訓練済み AI モデル	訓練済み AI モデルの入手時	システム運用者	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
	運用時入力データの採取元 運用時入力データ	システム運用時	運用時入力データ提供者 システム運用者	運用時のシステムに対するデータの改変
	システム		システム利用者 システム運用者	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

<sup>117</sup> 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)より引用

訓練用データに関する情報漏洩攻撃	事前学習モデル	事前学習モデルの入手後	モデル利用者 (システム開発者)	入手した AI モデルの動作時の入出力及び内部情報の観察
	訓練済み AI モデル	訓練済み AI モデルの入手後	システム運用者	
	運用時入力データの採取元 運用時入力データ	システム運用時	運用時入力データ提供者 システム運用者	運用時入力データの改変
	システム		システム利用者 システム運用者	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

表 98. 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	
	<ul style="list-style-type: none"> <li>・準拠法への適合性</li> <li>・要配慮個人情報の特定</li> </ul>		<ul style="list-style-type: none"> <li>・再利用成果物の決定</li> <li>・同意の取り決めの確認</li> </ul>	
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	
	<ul style="list-style-type: none"> <li>・学習データ品質</li> <li>・保護加工</li> <li>・データ分布 (外れ値)</li> </ul>	<ul style="list-style-type: none"> <li>・汎化性能</li> <li>・PPML (差分プライバシー)</li> </ul>	<ul style="list-style-type: none"> <li>・セーフガードの設定</li> </ul>	
	トレードオフ分析			
	<ul style="list-style-type: none"> <li>・判断結果の精度 VS 公平性</li> <li>・データ保護対策 VS 有用性</li> </ul>			

[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合理的な範囲で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）]

- （本編記載の）「②関連するステークホルダーへの情報提供」は、アルゴリズム又はソースコードの開示を想定するものではなく、プライバシー及び営業秘密を尊重して、採用する技術の特性及び用途に照らし、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]

- プライバシー及び営業秘密の保護のためには、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及び用途に照らし、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又は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、開示されることで生じる社会的な影響、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を行い、対応することが有用

### ● 「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及び安心感の獲得、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、説明する主体がどのような説明が求められるかを分析・把握できるよう、説明を受ける主体がどのような説明が必要かを共有し、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 の動作原理及び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、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

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、「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、各主体の役割及び開発・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、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

[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どのように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 AI 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）
- AI 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する

[具体的な手法]

- 責任者を設定する際には、役割及び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及び安全性確保のためのポリシーの策定においては、必要に応じて、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主体間の契約、社会的な約束（ボランティアコメント）等により、責任の所在を明確化する

[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 システム・サービスの利用に伴うリスク管理、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（社会及び一般市民に対するビジョンの共有、並びに情報発信・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

[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、ウェブサイト、問い合わせ窓口等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を定期的に公開
- 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、危機管理対応計画の策定等を行うことが有用
  - ◇ 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

各主体は、主体内の AI に関わる者が、AI の正しい理解及び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、誤情報といった特性及び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・リスキング等を検討する
- 様々な人が AI で得られる便益の理解を深め、リスクに対するレジリエンスを高められるよう、世代間ギャップも考慮した上での教育の機会を提供する
- AI システム・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及びリテラシー向上のための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
- AI 提供者、AI 利用者、業務外利用者等への教育
  - AI 利用者及び業務外利用者に対して AI システムの適切な利用方法及び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、得られる便益、潜在的なリスク、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]

- 内閣府「AI に関する暫定的な論点整理」（2023 年 5 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）

## C. 広島 AI プロセス「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」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、以下の広島 AI プロセス「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」を参照することが望ましいを遵守すべきである<sup>118</sup>。

### 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、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

<sup>118</sup> 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」（2023 年 10 月）、<https://www.soumu.go.jp/hiroshimaaiprocess/pdf/document05.pdf>、<https://www.mofa.go.jp/mofaj/files/400573472.pdf>を参照のこと。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 原則にもとづいて構築される 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。

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。
- 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もとづく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。**
- これらの取組は、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。

「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」の遵守状況を高度な AI システムを開発する AI 開発者自らが自主的に確認し報告する「報告枠組み」が OECD との協力の下、G7 で合意され、2025 年 2 月より運用開始されている<sup>119</sup>。当該「行動規範」を遵守した高度な AI システムを開発する AI 開発者は、「報告枠組み」に参加することが期待されている。

なお、質問項目は以下の 7 つに大別されている。

- (1) リスクの特定及び評価
- (2) リスク管理及び情報セキュリティ
- (3) 高度な AI システムに関する透明性報告
- (4) 組織の統治、インシデント管理及び透明性
- (5) 内容の認証及び来歴確認の仕組み
- (6) AI の安全性向上と社会リスクの軽減に向けた研究及び投資
- (7) 人間と世界の利益の促進

<sup>119</sup> 広島プロセス国際行動規範「報告枠組み」(2026 年 3 月現在、日本企業 9 社を含む 25 組織が回答を提出し、OECD のウェブサイト上で公表されている。) <https://transparency.oecd.ai/>

## 別添 4.AI 提供者向け

本章では、まず、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。その後、本編「第 2 部 AI により目指すべき社会及び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、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 及び生成 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。具体的な対応の検討にあたっては、提供予定の AI システムのもたらすリスクの程度及び蓋然性、技術特性、各主体の資源制約等に配慮することが重要である。

<sup>120</sup>

また、全ての AI 関係者高度な AI システムを取り扱う AI 提供者は、広島 AI プロセスの「全ての AI 関係者向けの広島プロセス国際指針」（本編・第 2 部・D に掲載）に即した行動を本編「第 2 部 AI により目指すべき社会及び各主体が取り組むべき事項」の「D. 高度な AI システムに関する事業者に通の指針」の記載を参照の上、I）～XI）を適切な範囲で遵守すべきであり、XII）を遵守すべきである。

### 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・身体・財産、精神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・身体・財産、精神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、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が期待される。

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 利用者又は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、新技術が起こ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
  - 個人に生じうる不利益への配慮（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等。以下は配慮が必要な不利益の例）

<sup>120</sup> 「別添 3. AI 開発者向け」には、技術的な対策について記載されており、AI 提供者としても参考となる

- ◇ 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
  - ◇ 個人の特定の特徴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もと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もと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）
    - 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に、速やかな AI 開発者への通知及び対応策の相談・検討
    - 安全確認等の事前及び動作時の人間関与、並びに事後における再発防止策の検討
    - AI 利用者側の適正利用申告等による AI 利用者の信頼性の確認
    - 不要なデータや冗長なログの削除等による、データ最小化と適切なデータ管理の徹底
    - ガードレールの設定
      - ◇ フィルタリング等により有害な出力を検知し制限する
    - プロンプトの安全設計
      - ◇ システムプロンプトの設計や、利用者の入力内容に対する適切な制限・誘導を行う
    - ホワイトリスト方式を利用した連携ツール・システムの制限
    - 人間の判断を介在させる仕組みの構築
      - ◇ 判断が必要となる事項を重要度に応じて整理し、適切に対象を選定することが重要である

#### [参考文献]

- 内閣府「AIに関する暫定的な論点整理」（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 AI システム・サービスの正確性・必要な場合には学習データの最新性（データが適切であること）等を担保する（「2）安全性」）
- ◇ AI 開発者が設定した 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インシデント、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]

- ステークホルダーとの協力及び予防措置及び事後対応
  - 適正な範囲・方法による AI の利用のための情報提供等<sup>121</sup>
  - 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対応項目のリストアップ、手順化等の準備
  - 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との情報共有
  - 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）

<sup>121</sup> 生成 AI を組み込んだシステム・サービスにおいては、AI による生成物の利用に際し、人間の判断を介在させるためのユーザーインターフェースの工夫等を行うことも検討する。

[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・サービスの構成及び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及び参照する情報、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モデルの入出力及び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、評価結果にもとづく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・サービス、ユーザーインターフェースにおいて、ビジネスプロセス及びAI利用者又は業務外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。

手法としては、センシティブ属性の設定、データ整備、評価指標の設定、評価といったステップを踏むことも有効である。

（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<sup>122</sup>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
    - ◇ 社会的バイアスが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、個人情報のマスキング、削除等プライバシーに配慮して扱う
  - 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、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項が列挙する事由及び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

<sup>122</sup> 測定等によって得られたデータが一部の偏ったものではなく、母集団の全体を代表するものにふさわしいと考えられること

- 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<sup>123</sup>
- 公平性の基準の確認（「コラム 175：集団公平性及び個人公平性」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もとづき予測を行う（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（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 175：集団公平性及び個人公平性

一般に公平性要求においては、人種、性別等「不公平」を生じかねない属性（要配慮属性：センシティブ属性と同義）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）及び施策は、「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」とよっての「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ため、一般的なメトリクスが定義しづらく AI システム毎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 186：公平性品質の確保に関するプロセス」参照）
  - 社会的要請、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、システム又は 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及び選択の妥当性を、分析又は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」、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 30. 公平性品質の確保に関するプロセス構造の例示](#)」[図 4. 公平性品質の確保に関するプロセス構造の例示](#)参照）

#### [参考文献]

<sup>123</sup> ユースケースに非依存な一般的なバイアスチェックを行うとリスクが顕在化しない可能性があるため、実際に想定されるユースケースに応じて適切なデータセットを用いてバイアスチェックを行う。

- 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 186 : 公平性品質の確保に関するプロセス

「**図 30. 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、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（公平性が損なわれること同義）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又は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又は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：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又は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：品質の確認手段及び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又は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。

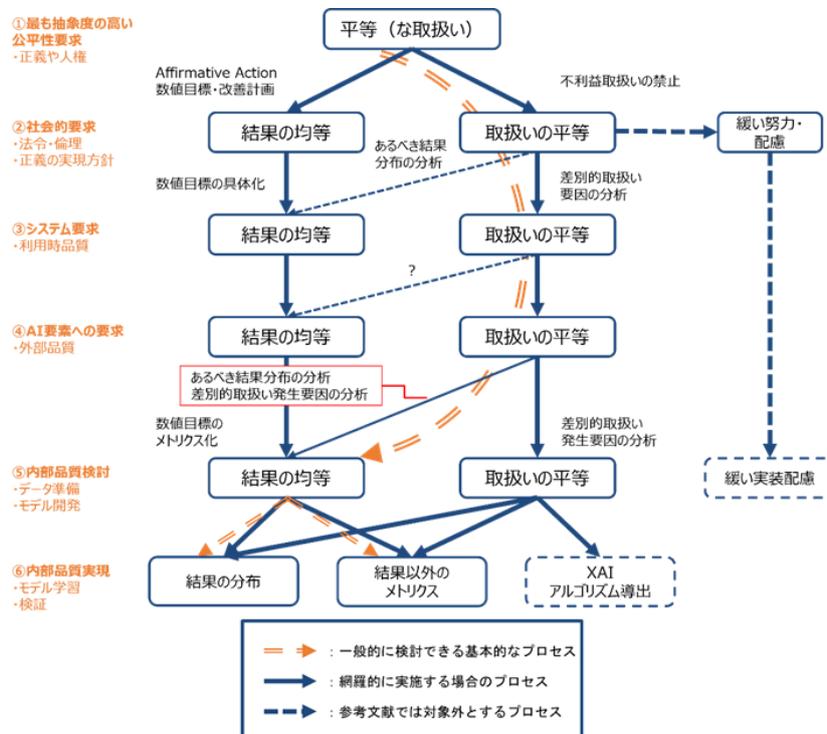


図 30. 公平性品質の確保に関するプロセス構造の例示

図 28. 公平性品質の確保に関するプロセス構造の例示

[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及び対策の導入**

- ◇ 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) 物理的設計及びネットワーク基盤

プライバシー・バイ・デザインの目標である「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 可視性及び透明性 – 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・デザインにもとづくプライバシー対策の実施<sup>124</sup>
  - 品質マネジメントの実施（「表 9. 品質マネジメント実施項目の概要表 8. 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

<sup>124</sup> RAG の活用など外部のサービス・データ等と連携する場合は、意図しない範囲に重要情報（個人情報・機密情報等）が漏洩してしまうこと等の危険性が高まるため、データの匿名化やアクセス制限の適用などを通じたプライバシー保護とセキュリティの確保が特に重要となる。

- 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、加工、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又は個人のプライバシーを侵害する情報を取得した場合）<sup>125</sup>
  - 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又は個人のプライバシーを侵害する情報を拡散した場合）
  - AI 利用者がシステムを使用する際に個人情報などプライバシー情報を入力してしまう可能性があるため、システム入力時におけるプライバシー情報の有無の判断や秘匿を補助する仕組みを導入

#### [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）

---

<sup>125</sup> フィジカル AI においては、個人情報を取得してしまう可能性があるうえ、こうした情報がデバイス上に保存・残存し、解析や不適切な利用に結び付くことでプライバシー侵害のおそれがあるため、不要な情報を取得・保持しない仕組みを設ける必要がある。また、ハードウェア廃棄時には、機器やクラウドの記憶媒体に保存されたデータも適切に削除することが望ましい。

[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<sup>126</sup>。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 システムの用途、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 AI システムのセキュリティを確保する。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たりしては、手戻りが多発し結果的に開発コストが多くかか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、手戻りが少なくなり、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・デザインにもと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及び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、可用性、保守性、性能等がある。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
    - ◇ AI 開発者が提供する AI システムに求めるアーキテクチャ情報をもとにする
    - ◇ 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利用する
    - ◇ オープンソースソフトウェアを利用する際は、開発元や取得経路が信頼できることを確認する
    - ◇ ユーザーやシステムに付与する権限を業務遂行に必要な最小限に設定する
- AI に対する攻撃の分類
  - システムの誤作動

<sup>126</sup> RAG を活用する場合、検索・参照するデータの不正な変更や操作等を早期に検出するため、定期的に当該データの管理・監査を実施することも検討する。

- ◇ 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・物流における配車割当の効率低下、交通渋滞及び物流コストの増加、小売分野における商品推薦、需要予測及び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が被害例として挙げられる
- AI モデル情報の漏洩
  - ◇ AI モデルのパラメータ、機能等の非公開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、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 7. 機械学習利用システムの被害と脅威の例」[表 6. 機械学習利用システムの被害と脅威の例](#)参照）
- セキュリティ侵害発生時の措置の検討
  - 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）
    - ◇ AI システムの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
  - 第三者機関の設置及びその機関による原因調査・分析・提言

[参考文献]

- [総務省「AI のセキュリティ確保のための技術的対策に係るガイドライン」（2026 年 3 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）
- 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）
- NCSC, “Guidelines for secure AI system development”（2023 年 11 月）
- ACSC, “Engaging with Artificial Intelligence (AI)”（2024 年 1 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**

- ◇ トレーサビリティ及び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・サービスのシステムアーキテクチャ、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及び対話が強化される。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インシデントの原因究明、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、記録メディアへ保存等）
    - ◇ ログの保存場所（ローカル、クラウド等）
    - ◇ 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）又は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」、「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～」といったルールをもとに推論ロジック及び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）
- RAG の導入
  - ◇ 外部の情報源を検索して回答を生成する際、出典や引用元等を明記することが可能となる
- 技術的文書の適宜アップデート

[参考文献]

- 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 2025.04 版」（202~~5~~<sup>3</sup>年 4<sup>6</sup>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、侵害を認識した場合等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又は社会受容性がコンテキスト又は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、その後の被害救済等の事後対応、原因解明、再発防止措置の検討及び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及び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又は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、その後の被害救済等の事後対応、原因解明及び再発防止措置（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。新規事業又は新規技術の開発部門が悩みを抱え込まずに、自由に相談できる体制及び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・サービスに対する攻撃手法も数多く生まれているため、最新のリスク及び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、脆弱性に対応することを検討する（「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 利用者又は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を共有することが重要となる。

AI 提供者は、AI モデルの管理、改善及び調整において、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 利用者又は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及び想定される攻撃を整理し、「何から守るのか」を明らかにする。

[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 8. 機械学習特有の脅威・攻撃界面・攻撃実行フェーズ・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及び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、アンサンブル学習等）
    - ◇ 訓練済みモデルから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
  - 検証 妥当性確認 データ・テスト 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
  - ◇ 事前学習モデル及び AI モデルのポイズニングの除去・軽減
  - ◇ ポイズニングを除去・軽減する学習機構の利用
  - ◇ 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（アクセス権の制限及びアクセス回数・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 モデル又はシステムの併用
  - ◇ 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
  - ◇ モデル抽出リスクの評価技術の利用
- 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、適時かつ適切に情報を提供する（「6）透明性」）
  - AI を利用しているという事実、活用している範囲、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、不具合の原因及び対応状況、インシデント事例等（「2）安全性」）
  - AI システムの更新を行った場合の更新内容及びその理由の情報（「2）安全性」）
  - AI モデルにて学習するデータの収集ポリシー、学習方法、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 利用者の納得感及び安心感の獲得、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、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 ガバナンス及び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、リスク又は意思決定及び行動の背後にある論理的根拠の理解が促進される。モニタリング及びレビューのプロセス並びに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及びレビューを実施して、AI の望ましくない動作及び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及びその用途・方法
  - AI を活用している範囲
  - 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及び確認方法）、確認の重要性・頻度、未確認によるリスク等
  - 活用の過程における、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、点検、修理等
  - 安全性、セキュリティ、並びに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、その使用に影響を及ぼす AI モデル又は AI システム・サービスの能力及び性能上の限界
- 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 モデル又は AI システム・サービスが安全性や社会に及ぼす影響及びリスクについての議論及び評価
- 開発段階以降の AI モデル又は 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、利用の態様等にもとづき想定されるリスクに応じ、AI 利用者又は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]

- 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)
- NIST, “Artificial Intelligence Risk Management Framework (AI RMF 1.0)” (2023 年 1 月)
- OECD, “Advancing accountability in AI” (2023 年 2 月)
- AISI「AI セーフティに関するレッドチーミング手法ガイド (第 1.10 版)」(2025 年 3 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 利用者へ提供する (「7) アカウンタビリティ」)
  - 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注意喚起する (「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 利用者又は業務外利用者に対し、利用する AI の性質、目的等に照らして、それぞれが有する知識及び能力の多寡に応じ、AI システムの特性について情報提供並びに説明を行うこと、多様なステークホルダーとの対話を行うこと等により、相応のアカウンタ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うる分野で 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 利用者又は業務外利用者に説明することが期待される。

[具体的な手法]

- AI 利用者又は業務外利用者への AI システム・サービス利用に際しての注意喚起及び関連する対応
  - AI の点検・修理及び AI システムのアップデート、また AI 利用者又は業務外利用者への対応促進（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に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及び注意喚起する）
  - 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 利用者又は業務外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、業務外利用者等の関連するステークホルダー又は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及び説明を踏まえ、AI を利用する目的、用途、性質、能力等を確認した上で情報提供）
  - 利用者属性に応じたアクセス制限（必要な場合）

[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 利用者又は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、サービス内容・範囲・品質等に関する保証基準の共通認識であるサービスレベル合意（Service Level Agreement：以下 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 利用者又は業務外利用者及び 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 利用者又は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及び方針（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・公表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 AI サービス及び要求水準の設定
    - ◇ 設定にあたっては、万が一インシデント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 利用者又は業務外利用者及び AI 提供者の間で認識の相違が起こらないように、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及び方針（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、対外的にわ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、本編「第 4 部 AI 提供者に関する事項」では触れられていないが、本編「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人間の尊厳及び個人の自律」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、人間の尊厳及び個人の自律を尊重する

[具体的な手法]

- 社会的、安全及びセキュリティ上のリスク軽減の研究の推進
  - ◇ 社会的、安全及び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
    - 子供及び社会的弱者の保護
    - 知的財産権及び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及びベストプラクティスの共有（可能な範囲で実施する）
- AI システムが人間の意図や価値観に沿って適切に機能するようにするための取組（アライメント）の実施

#### ● 「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、認知等、感情を不当に操作することを目的とした、又は意識的に知覚できないレベルでの操作を前提とした 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 利用者又は業務外利用者への注意喚起

- ◇ 教育現場等における AI への依存、意思決定、感情の操作等のリスクの存在の共有及び認識の促進
  - ◇ 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成できるようになり、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
      - ◇ AI 利用者等が 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
      - ◇ RAG 等、生成 AI による偽・誤情報の出力（ハルシネーション等）を防ぐ技術の活用<sup>127</sup>
      - ◇ 幅広い年代への注意喚起や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」及び「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、地球環境への影響も検討する
    - 目的に応じて環境への影響が小さい軽量なモデルを活用するなど、利用者や業務外利用者等がモデルを適切に使い分けられるよう情報を提供する
    - [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）

<sup>127</sup> RAG の精度は利用する情報に依存する。そのため、活用に際しては信頼性や正確性の高いデータベースやデータソースを利用し、利用者におけるデータベースの更新状況にも留意しつつ、定期的に情報の品質を管理・監視する必要がある。

- 気候変動対策
- 人類の健康及び福祉（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、生産 等

[参考文献]

[総務省「令和3年版 情報通信白書」\(2021年7月\)](#)

- 国際連合「持続可能な開発目標」（2015年9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、ステークホルダーの生命・身体・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、精神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・身体・財産、精神及び環境への配慮」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及び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
    - 原因調査方法及び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）
    - AI システムの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
  - ◇ 第三者機関の設置及び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及び差別をなくすよう努めることが重要である。また、各主体は、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及び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、適切なタイミングで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 AI 利用者又は業務外利用者の権利・利益の性質及び AI 利用者又は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 利用者又は業務外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及び程度
  - ◇ 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・性別にもと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）
  - ◇ AI 利用者又は業務外利用者が AI の出力を適切に判断ができるよう、必要な能力及び知識を習得できるよう情報提供及び説明を実施する（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合理的な範囲で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]

- 関連するステークホルダーの納得感及び安心感の獲得、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、説明する主体がどのような説明が求められるかを分析・把握できるよう、説明を受ける主体がどのような説明が必要かを共有し、必要な対応を講じる

[具体的な手法]

- 説明可能性の確保
  - ◇ AI 利用者又は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及び AI 開発者と連携した説明内容検討
  - ◇ 過去の入出力事例を一定提示する等、AI モデルの典型的挙動の例示手法の検討
  - ◇ 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及び潜在的なリスク（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並びにレビューインターフェース、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及び伝達

[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、主体内の AI に関わる者が、AI の正しい理解及び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、誤情報といった特性及び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<sup>128</sup>

#### [具体的な手法]

- AI リテラシー確保
  - 役割と責任を明確にした AI ポリシーの策定及び主体内の 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及び主体内の 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及び主体内の 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及び主体内の 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を主体内の AI に関わる者への周知
- 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
    - ◇ 過去の経験及び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]

- 経済産業省、独立行政法人情報処理推進機構「デジタルスキル標準 ver.1.1」~~（2023年8月）~~
- NIST, “AI Risk Management Framework Playbook”（2023年1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及び相互運用性を確保する
- 標準仕様がある場合には、それに準拠する

#### [具体的な手法]

- データ形式、プロトコル等の標準化

<sup>128</sup> 厚生労働省の雇用政策研究会にて「新たなテクノロジー等を活用した労働生産性の向上」というテーマで、技術変化を踏まえたキャリア形成やスキル教育について触れられている。

[https://www.mhlw.go.jp/stf/shingi2/0000204414\\_00017.html](https://www.mhlw.go.jp/stf/shingi2/0000204414_00017.html)[https://www.mhlw.go.jp/stf/shingi/other-syokuan\\_128950.html](https://www.mhlw.go.jp/stf/shingi/other-syokuan_128950.html)

- AI の入出力等におけるデータ形式（構文（syntax）及び意味（semantics））
- AI システム・サービス間の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 モデルの実装又は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、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）

### コラム 197：日本デジタルヘルス・アライアンス

#### 「ヘルスケア事業者のための生成 AI 活用ガイド」

日本デジタルヘルス・アライアンス<sup>129</sup>（以下、「JaDHA」という。）は、ヘルスケアサービスを提供する事業者が生成 AI による多様なサービスを創出し、AI 利用者及び業務外利用者が安心してサービス選択できる環境を構築することを目的に、2024 年 1 月 18 日に「ヘルスケア事業者のための生成 AI 活用ガイド（ヘルスケア領域において生成 AI を活用したサービスを提供する事業者が参照するための自主ガイドライン）」<sup>130</sup>を策定した。2025 年 2 月 7 日には技術動向や制度動向等を踏まえた改訂版として第 2.0 版を策定<sup>131</sup>。

本ガイドは、AI 事業者ガイドラインに全業種共通の内容が盛り込まれることを前提としつつ、ヘルスケア領域が他の領域と比較して要配慮個人情報取扱いが多くなる点や、不確かな情報をもたらす個人への影響が極めて大きい点等を踏まえ検討を行い、AI 提供者が、ヘルスケア領域において、生成 AI を活用して安全安心に AI サービスの提供を行うためのチェックポイントをまとめている。

具体的には、生成 AI を取り巻く主体やバリューチェーンの整理を行ったうえで、AI 事業者ガイドラインで示されている「3)公平性」や「4)プライバシー保護」に関する AI 提供者として留意すべき各場面でのデータの取扱いについて、より実践的かつ具体的な注意事項を定めている。加えて、「7) アカウンタビリティ」を踏まえた AI 利用者及び業務外利用者への説明・表示等について体系的に取りまとめられているとともに、AI 提供者が活用可能なチェックリストや参考事例なども併せて公表している。

<sup>129</sup> 日本におけるデジタルヘルス産業の発展や課題を検討する業界団体として 2022 年 3 月に設立。現在、医薬品・医療機器メーカーからヘルステックスタートアップ企業まで、多様な属性の企業が参画している。

<sup>130</sup> <https://jadha.jp/news/news20240118.html>

<sup>131</sup> <https://jadha.jp/news/news20250207.html>

## チェックポイント全体像

1 基盤モデルの選定	①基盤モデルの選定	<ul style="list-style-type: none"> <li>● 基盤モデルが標榜している性能や学習データの内容についての確認</li> <li>● 基盤モデルが定めている利用用途や学習利用に関する規約の確認</li> </ul>
	②基盤モデルの利用用途	
2 データの取り扱い	①学習データの取り扱い	<ul style="list-style-type: none"> <li>● モデルの利用規約の確認</li> <li>● 個人情報が含まれる場合の本人同意取得</li> <li>● 著作物が含まれる場合の利用制限確認</li> <li>● データ保護に関する社内体制の構築</li> <li>● 関連ガイドライン等の参照</li> </ul>
	②サンプル・事例の取り扱い	
	③質問データの取り扱い	
	④データに関するその他考慮事項	
3 アウトプットの信頼性	①サービス開発段階での取り組み	<ul style="list-style-type: none"> <li>● ハルシネーション制御（技術的工夫）</li> <li>● 利用者に対する説明・表示</li> <li>● 入力規制・制御</li> <li>● 免責事項の表示</li> </ul>
	②サービス提供時の利用者に対する取り組み	
4 ヘルスケア領域の個別規制	①医療機器プログラムの該当性確認	<ul style="list-style-type: none"> <li>● 医療機器プログラムの該当性確認</li> <li>● 医薬品等適正広告基準等の確認</li> <li>● ヘルスケア領域における利用制限の確認</li> </ul>
	②標榜における広告規制の確認	
	③基盤モデルの利用規約確認	

（出典：JaDHA「ヘルスケア事業者のための生成 AI 活用ガイド」）

JaDHA では、本ガイドを業界内でいち早く策定することで、新技術である生成 AI を活用したサービス推進や業界内でのイノベーション促進を期待している。加えて、スタートアップ企業や中小企業をはじめとする生成 AI を活用したサービスを検討している企業が本ガイドを参照・セルフチェックを行うことで、AI 利用者及び業務外利用者が安心して AI サービスを利用できる環境構築を目指している。

なお、急速な新技術の進歩に伴い、生成 AI の技術特性や関連制度等の変化が想定されることから、本ガイドは適宜見直しを図り、ヘルスケア領域において AI を活用する事業者がタイムリーに適正な AI サービスを提供できるよう今後も業界全体の後押しを行っていく予定である。

## 別添 5.AI 利用者向け

本章では、まず、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。その後、本編「第 2 部 AI により目指すべき社会及び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、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 及び生成 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。具体的な対応の検討にあたっては、利用予定の AI システム・サービスのもたらすリスクの程度及び蓋然性、技術特性、各主体の資源制約等に配慮することが重要である。

また、全ての AI 関係者高度な AI システムを取り扱う AI 利用者は、広島 AI プロセスの「全ての AI 関係者向けの広島プロセス国際指針」（本編・第 2 部・D に掲載）に即した行動を本編「第 2 部 AI により目指すべき社会及び各主体が取り組むべき事項」の「D. 高度な AI システムに關係する事業者に共通の指針」の記載を参照の上、I）～XI）を適切な範囲で遵守すべきであり、XII）を遵守すべきである。

### 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」）
- ◇ AI システム・サービスが想定された仕様に基づき適切に動作しているかを確認する（「2）安全性」）
- ◇ 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う（「2）安全性」）
- ◇ AI の出力について精度及び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」）

[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）及び説明を踏まえ、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<sup>132,133</sup>。

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、AI 利用者又は業務外利用者は、移行前、移行中、移行後等

<sup>132</sup> RAG を活用する場合、検索・参照するデータの最新性・信頼性の確保に留意する。なお、RAG（検索拡張生成）を活用した場合には生成 AI による回答の収束が加速する可能性が高いため、例えばコンテンツの多様性・独創性を必要とする業務については、RAG の活用が適切ではない場合もあることに留意が必要である。

<sup>133</sup> 生成 AI を用いて生成したプログラムコードにセキュリティ上の脆弱性等が含まれていた場合、情報の改ざんや漏洩等につながる恐れがあるほか、誤った/非効率なコードが生成された場合、パフォーマンスの低下や事故等につながる懸念がある。また、生成したコードが他者の知的財産権等を侵害する可能性に留意が必要である。さらにコード生成 AI の利用においては、作成者の意図やコード構造の把握が難しくなり、保守・更新が困難になる可能性もある。そのため、ノーコード生成ツールも含め、社内ノウハウを如何に蓄積するかが重要である。

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 を利用するにあたり、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インシデント、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及び確認方法）、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、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、並びに適正な用途の理解（利用前）
  - 適正利用のための必要な知識・技能の習得（利用前）
  - 提供された AI システム・サービスが想定された仕様に基づき適切に動作しているかについての基本的な動作確認（利用前）
  - AI システム・サービスの利用過程におけるログ（操作履歴、入力・出力の記録等）の管理体制の整備（利用前）
  - 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
  - 出力によって重大な影響又は被害が生じ得る場合、人間の判断を介在させる仕組みに基づき適宜判断（利用中）
  - 不要なデータや冗長なログの削除等による、データ最小化と適切なデータ管理の徹底（利用中）
  - 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）
- 関係するステークホルダーと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及び対策検討

#### [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. 入力データ又は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投入を行い、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、AI の学習等に用いられるデータの代表性、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及び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、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（AI 提供者への問合せ要否判断時のポイント）
  - 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、個人情報のマスキング、削除等プライバシーに配慮して扱う
  - 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、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 175：集団公平性及び個人公平性」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もとづき予測を行う（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及び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を含む AI システム・サービスを利用する部門の密なコミュニケーションの醸成や、関連情報の社外有識者等からの収集、多角的な対応策の検討等を、実質的に行っていくことができる。技術革新及び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を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及び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
  - 企業内の各組織の新規事業及び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又は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その後の被害救済等の事後対応、原因解明及び再発防止措置（プライバシー侵害が発生した場合）
  - 企業内の各組織との関係構築
    - ◇ 各組織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・サービスを利用する組織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。新規事業又は新規技術の開発・利用する組織が悩みを抱え込まずに、自由に相談できる体制及び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・サービスを利用する組織毎に責任者を設定
    - ◇ プライバシー保護組織（兼務）を設置し、AI システム・サービスを利用する組織と連携
    - ◇ プライバシー保護組織（専任）を設置し、AI システム・サービスを利用する組織と連携
- 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の侵害につながりうる情報を取得した場合）<sup>134</sup>
- 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の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 サービスの利用にあたって、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）

<sup>134</sup> フィジカル AI においては、個人情報を取得してしまう可能性があるうえ、こうした情報がデバイス上に保存・残存し、解析や不適切な利用に結び付くことでプライバシー侵害のおそれがあるため、不要な情報を取得・保持しない仕組みを設ける必要がある。また、ハードウェア廃棄時には、機器やクラウドの記憶媒体に保存されたデータも適切に削除することが望ましい。

[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」）
- ◇ AI システム・サービスに機密情報等を不適切に入力することがないように注意を払う（「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、AI システム・サービスの利用にあたり留意することが望ましい。また、AI システム・サービス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）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、業務外利用者と連携して必要なセキュリティ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小な変動を加え、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
- セキュリティ侵害発生時の措置の検討
  - 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）
    - ◇ AI システムの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
  - 第三者機関の設置及びその機関による原因調査・分析・提言
- 機密情報等を含むプロンプトの入力
  - 例えば、生成 AI サービスの利用にあたって、入力する機密情報が生成 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、機密情報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、機密情報をむやみに AI に与えないようにする
- ログの定期的な確認
  - システム利用状況や異常操作を把握するため、ログを定期的にレビューする
  - 異常な操作を検知した場合に即時報告する体制を整備する

[参考文献]

- 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)
- 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)
- ACSC, “Engaging with Artificial Intelligence (AI)” (2024 年 1 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する。そして、出力結果を事業判断に活用した際は、その結果を関連するステークホルダーに合理的な範囲で情報を提供する（「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 を利用する場合等には、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及び安心感の獲得、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、若しくは決定の基礎となる要因又は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 AI 利用者にも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させ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及び影響を受ける可能性のある個人又はグループから、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
    - ◇ 入力データの種類及びソース、ハイレベルのデータ変換プロセス、意思決定の基準及び根拠、リスク及び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、利用の態様等にもと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合理的な範囲で、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 の特性及び用途、データの提供元となる関連するステークホルダーとの接点、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参考にする場合は、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、当ガイドラインが推奨する出力結果の正確性、公正さ、透明性等を担保するための諸手続きを遵守し、かつ自動化バイアスも鑑みて人間による合理的な判断のもと、評価の対象となった個人又は集団からの求めに応じて説明責任を果たす（「1）人間中心」、「6）透明性」、「7）アカウントビリティ」）
- ◇ 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合理的な範囲で設置し、AI 提供者とも連携の上説明及び要望の受付を行う（「7）アカウントビリティ」）

**U-7) ii . 提供された文書の活用及び規約の遵守**

- ◇ 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、内容等）
  - AI 活用の範囲及び方法
  - AI の出力の根拠
  - AI 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又は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、業務外利用者又は第三者が 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説明を行う

- ◇ 業務外利用者又は第三者の権利・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、業務外利用者又は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又は、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及び利用終了時も含め（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 の活用の場合又は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、本編「第 5 部 AI 利用者に関する事項」では触れられていないが、本編「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。

#### ● 「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
  - ◇ AI 利用者等が 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
  - ◇ RAG で検索・参照するデータの最新性確保（利用者がデータを準備する場合）
  - ◇ 幅広い年代への注意喚起や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」及び「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 AI 利用環境の整備**

#### ● 「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、地球環境への影響も検討する

[具体的な手法]

- 目的に応じて環境への影響が小さい軽量なモデルを活用するなど、モデルを適切に使い分ける

[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、ステークホルダーの生命・身体・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、精神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・身体・財産、精神及び環境への配慮」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及び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
    - 原因調査方法及び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）
    - AI システムの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
  - ◇ 第三者機関の設置及び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及び差別をなくすよう努めることが重要である。また、各主体は、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及び多様な文化を尊重する観点から許容可能か評価した上で、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、適切なタイミングで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及び実効性の確保
  - ◇ 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 AI 利用者又は業務外利用者の権利・利益の性質及び AI 利用者又は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 利用者又は業務外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及び程度
    - 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・性別にもと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）
  - ◇ AI 利用者又は業務外利用者が AI の出力を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、主体内の AI に関わる者が、AI の正しい理解及び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、誤情報といった特性及び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]

- AI を活用するためのリテラシー教育及びスキルとして含めるべき事項
  - AI、数理及び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、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 及びデータの特性への理解
  - AI 又はデータの持つ正確性、公平性及びプライバシー保護に関わる課題があること、並びにセキュリティ及び 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への理解
  - 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による、生産性向上等への適切な利用
  - メディア上に流通する情報の中に、AI によって生成された虚偽情報が含まれている可能性があることと、それら情報の取捨選択と選別の必要性
  - 生成 AI を利用するにあたり適切な回答を導くためのプロンプト作成のスキル
- 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
  - 過去の経験又は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]

- 経済産業省、独立行政法人情報処理推進機構「デジタルスキル標準 [ver.1.1](#)」[（2023年8月）](#)
- 総務省「自治体における AI 活用・導入ガイドブック [〈導入手順編〉（第4版）](#)」[〈別冊付録〉先行団体における生成 AI 導入事例集](#)（2025年 12月）
- 総務省「インターネット上の偽・誤情報対策に係るマルチステークホルダーによる取組集」（2024年 5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」<sup>135</sup>（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・利用を促すガイドラインの目的のもと、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もと、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。しかし、

~~契約ガイドラインの初版の策定・公表から既に 6 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考えられる。

### （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
- 責任の分配に関する基本的な視点

<sup>135</sup> 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>

(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。

契約ガイドライン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) 契約モデルの多様化について

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（ユーザー）の二分論を前提に、①ユーザーが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をユーザー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考えられる。しかし、2022年以降、汎用性を有する生成AIの登場に伴い、AI技術を用いたサービスが急速に普及する中、かかる生成AIを活用したAIサービス（汎用的AIサービス）を利用する場面の契約や、提供者であるベンダが他のベンダの汎用的AIサービスをカスタマイズして利用者に提供する場面の契約が増加し、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。

AIの利用・開発に関する契約は大きく以下の3類型に分類でき、それぞれの類型に応じて、留意すべき契約事項や交渉上の論点も異なる。

● 類型1：汎用的AIサービス利用型

AI利用者が、AI提供者が提供する汎用的AIサービスを利用するケース。

● 類型2：カスタマイズ型

AI利用者が、AI提供者が特定のAI利用者向けにカスタマイズしたAIサービス（カスタマイズサービス）を利用するケース。カスタマイズサービスを提供するAI提供者は、他のベンダが提供する汎用的AIサービスに対して、独自に開発した付加的な機能（非AIモデル）を組み合わせる。

● 類型3：新規開発型

AI利用者が、AI開発者・AI提供者と提携して独自のAIシステムを開発・利用するケース。

以上のような市場環境の変化に対応するべく、経済産業省は、2025年2月、我が国の事業者がAIの利活用に関する契約を検討する場面を念頭に、契約において留意すべき事項を取りまとめたチェックリスト（以下、「契約チェックリスト」という。）を策定した<sup>136</sup>。契約ガイドライン公表後に登場した契約類型については、契約チェックリストを参照のこと。

<sup>136</sup> 経済産業省「AIの利用・開発に関する契約チェックリスト」（AI利活用に伴う契約時の留意事項検討会、2025年2月）  
(<https://www.meti.go.jp/press/2024/02/20250218003/20250218003.html>)

なお、今後の更なる AI 技術の進展に伴い、契約当事者がさらに増加し、契約関係がさらに重層的なものになることも考えられるほか、新たな契約類型が生じる可能性もあり得る。その際、契約ガイドラインや契約チェックリストに示された考え方を参照しつつも、それぞれの取引の実態に即した検討を行うことが重要と考えられる。

## (2) 複雑なバリューチェーンの下でのリスク分配について

契約ガイドラインでは、①ユーザーが 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 をユーザーに利用させる取引のいずれの類型においても、ベンダとユーザー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、ベンダとユーザーの法律関係、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、上記(1)にも述べたとおり、AI のバリューチェーンは多様化ないし複雑化する傾向にあり、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きている。また、企業の事業活動だけでなく日常生活への AI の普及が進んだことにより、業務外利用者による利用が増加している。これらの結果、ベンダとユーザー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（例えば、生成 AI のモデル自体を開発する事業者。本ガイドラインでは AI 開発者）
- 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（例えば、開発された生成 AI をチャット形式で利用できるようなソフトウェアを開発する事業者。本ガイドラインでは AI 開発者）
- そのソフトウェアを外部に提供する事業者（例えば、生成 AI をチャット形式で利用できるようなソフトウェアを一般消費者に提供する事業者。本ガイドラインでは AI 提供者）
- 提供されたソフトウェアをカスタマイズしたサービスを外部に提供する事業者（例えば、開発された生成 AI のモデルを特定の用途に特化したサービスを企業に提供する事業者。本ガイドラインでは AI 提供者）
- そのサービスを利用する事業者（本ガイドラインでは AI 利用者）

※ なお、複数の立場を兼ねる事業者も多い。

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カスタマイズ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 に起因する損害に関して当該業務外利用者が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ものであり、ベンダとユーザー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なければ、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、ベンダとユーザー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検討を行う必要がある。この点については、別添 2 の 3.システムデザイン（AI マネジメントシステムの構築）に関する実践例も参考になると思われる。

### (3) 責任分界とアカウントビリティについて

上記(2)のように、複数の当事者間でのリスク分配を検討するに当たっては、新たな種類のリスクについても分析が必要となる。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顕在化するケースも今後増えていくことが予想されるが、そうしたリスクの中には、AI を組み込んだソフトウェアや、これをカスタマイズ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。しかしながら、現状、事故発生時にどの主体がどのような責任を負うかについて明確な基準はなく、事業者としてリスクシナリオを描けずに AI 導入を断念・躊躇する場合もあり得る。

こうした新たな種類のリスクについては、いずれかの当事者に全てのリスクを負わせるという発想ではなく、関係当事者間で協調的にリスクを分配することが重要と考えられるほか、場合によっては損害保険等の保険の活用が有用なケースもあり得る。

事故発生リスクとの関係で契約上留意しておくことが有益な事項としては、以下が挙げられる。

- 新たな種類のリスクの整理  
国内外では、既に AI サービスの利用に伴う知的財産権侵害、個人情報保護法違反、秘密保持契約違反等の事故が生じたケースもある。こうした先例や議論の状況等を考慮しながら、AI サービスの内容や性質に応じて考え得るリスクを洗い出し、その分配（どの主体がどのような責任を負うか）を定めておくことが重要である。一方で、契約当時には想定していなかったような事故が生じることも考えられることから、周辺環境の変化なども踏まえて契約内容の見直しを適宜行うことも重要である。
- 合理的な説明の実施  
事故発生時には、事故の原因は何か（AI 開発者、AI 提供者及び AI 利用者のそれぞれの行為に起因する可能性があるほか、AI の性質上不可避免的に生じるものもありうる）及び各当事者が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といった点が重要な論点となり、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立つ可能性がある。
- 客観的な根拠の提示  
合理的な説明を行うためには、説明の内容に加えてその客観的な根拠が求められ、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が期待される。契約ガイドラインでは触れ

ていないが、別添 2 の 3.システムデザイン（AI マネジメントシステムの構築）に関する実践例を参照の上、契約締結後の対応を検討することは有益である。

なお、客観的な根拠を提示するに際して、モニタリングに資する情報を開示するというアプローチ（ログデータ等の開示）も考えられるが、そうした内部資料の開示は、セキュリティや競争力の低下リスクとトレードオフの関係に立ち得ることにも留意が必要である。