AIセーフティ・インスティテュート（AISI）について

※AISIは、エイシーと読みます。

2025-08-01
AISI事務局

AISI Japan AI Safety Institute

AISI設立の背景・概要

日本におけるAISIの設立

AISI Japan AI Safety Institute

広島AIプロセスでの議論や**AIセーフティサミット**を経て
日本でもAIセーフティ・インスティテュート（AISI）を設立（2024年2月）

2023年5月	2023年12月	2024年2月	2024年5月	2024年7月	2025年3月
日本から「広島AIプロセス」を提唱	「広島AIプロセス包括的政策枠組み」等に各国合意	AIセーフティ・インスティテュート（AISI）設立（事務局はIPAに設置）	広島AIプロセスフレンズグループを設立	GPAI東京専門家支援センター設立	広島AIプロセスレポーティングフレームワーク運用開始
			安全・安心で信頼できるAIの実現を目指す、賛同国による自発的な国際枠組み	GPAIに所属するAIの専門家を支援する組織	2025年5月26日時点19社が参加

※1 成果文書｜広島AIプロセス
※2 AI Safety Summit 2023 - GOV.UK

統合イノベーション戦略2024

AISI Japan AI Safety Institute

「統合イノベーション戦略2024」において、AISIは**日本におけるAIの安全性の中心機関**と定義

- 統合イノベーション戦略2024とは、内閣府による第6期科学技術・イノベーション基本計画の実行計画として位置付けられる４年目の年次戦略であり、３つの強化方策を打ち出すとともに、従来からの3つの基軸についても着実に推進することとしている。

統合イノベーション戦略2024における３つの強化方策

(1) 重要技術に関する統合的な戦略

(2) グローバルな視点での連携強化

(3) AI分野の競争力強化と安全・安心の確保

①AIのイノベーションとAIによるイノベーションの加速（研究開発力の強化、AI利活用の推進、インフラの高度化等）
②AIの安全・安心の確保（ガバナンス、AIの安全性の検討、偽・誤情報への対策、知財等）
③国際的な連携・協調の推進（広島AIプロセスの成果を踏まえた国際連携等）

統合イノベーション戦略2025

AISI Japan AI Safety Institute

統合イノベーション戦略2024

AISIを**日本におけるAIの安全性の中心機関**と定義

３つの強化方策の1つの柱がAI

AI分野の競争力強化と安全・安心の確保

1. **AIのイノベーションとAIによるイノベーションの加速**
   研究開発力の強化、AI利活用の推進、インフラの高度化等
2. **AIの安全・安心の確保**
   ガバナンス、AIの安全性の検討、偽・誤情報への対策、知財等
3. **国際的な連携・協調の推進**
   広島AIプロセスの成果を踏まえた国際連携等

統合イノベーション戦略2025

（１）先端科学技術の戦略的な推進

①重要分野の戦略的な推進

- AIイノベーション促進とリスク対応の両立
- AIの研究開発の推進等
- AI関連施設等の整備及び共用の促進
- AI活用の推進
- AIの適正性の確保
- AI関連人材の確保と教育振興等
- AIに関する調査研究等
- AI分野の国際的協調の推進

AISIの役割とスコープ

AISI Japan AI Safety Institute

AIの安全安心な活用が促進されるよう
官民の取組を支援することがAISIの役割

役割

- 主に3つの役割を担う。

政府への支援
- AIセーフティに関する調査、評価手法の検討や基準の作成等

日本におけるAIセーフティのハブ
- 産学における関連取組の最新情報の集約
- 関係企業・団体間の連携促進
- 他国のAIセーフティ関係機関との連携

関連の研究機関との連携実施
- 国研等の関係研究機関との連携
- パートナーシップ事業の推進

AIの開発や利用をする者が**AIのリスクを正しく認識**できる仕組みの構築 ＋ ガバナンス確保などの必要となる対策を**ライフサイクル全体で実行**できる仕組みの構築 ⇔ **国内・国際的な関係機関**

イノベーションの促進と**ライフサイクルにわたるリスクの緩和**を**両立**する枠組みを実現

スコープ

- AIによる以下の事象や検討事項の中で、諸外国や国内の動向も見ながら柔軟にスコープを設定し取組を進めていく。

社会への影響	ガバナンス	AIシステム	コンテンツ	データ

AIセーフティ実現に向けた業務

AISI Japan AI Safety Institute

AISIは、**安全性評価とその実施手法**に関する検討や、
国際連携に関する業務などを遂行

1. 安全性評価に係る調査、基準等の検討

- 安全性に係る標準、チェックツール、偽情報対策技術、AIとサイバーセキュリティに関する調査
- 安全性に係る基準、ガイダンス等の検討
- 上記に関するAIのテスト環境の検討

2. 安全性評価の実施手法に関する検討

3. 他国の関係機関との国際連携に関する業務

AISI Japan AI Safety Institute

体制

AISIの関係府省庁・機関

AISI Japan AI Safety Institute

AISIは、12府省庁・5関係機関が横断的に参画する**政府関係機関**

事務局は経済産業省とデジタル庁を所管官庁としている**IPA内に設置**

＊2025年4月時点

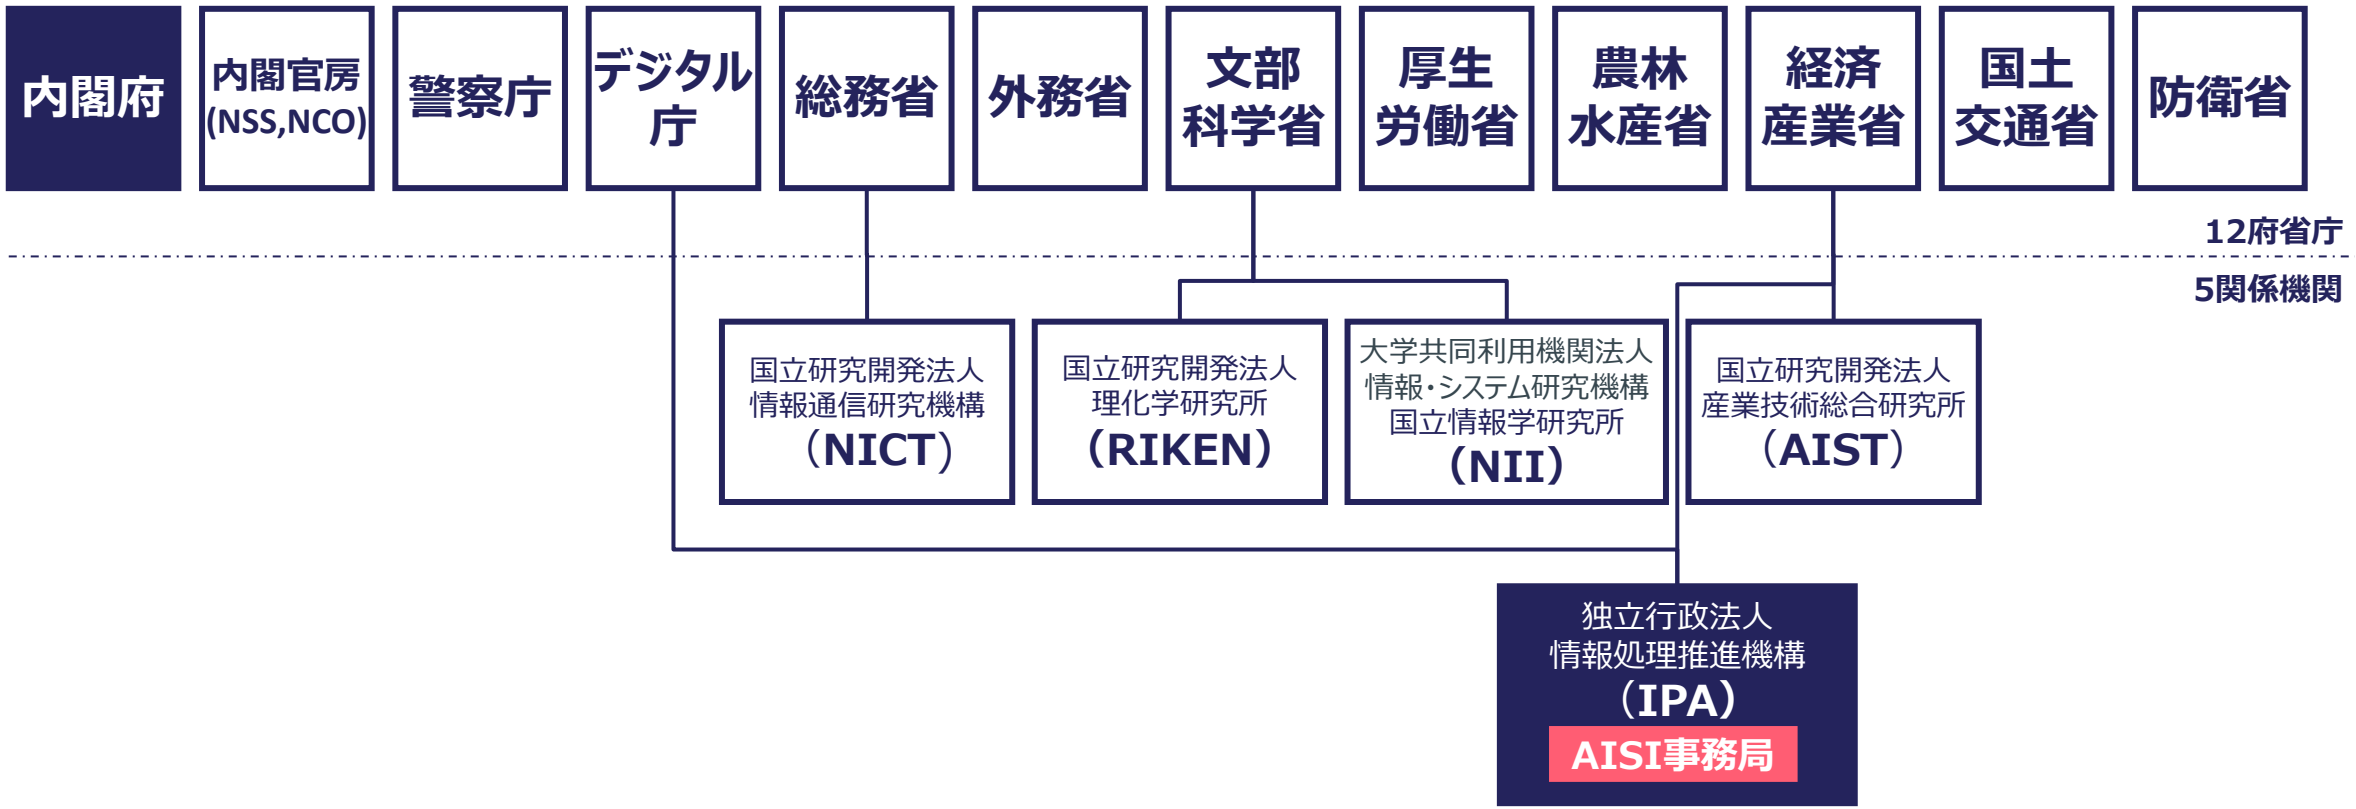

AISIの推進体制

AISI Japan AI Safety Institute

内閣府を事務局とする「**AISI関係府省庁等連絡会議**」で政府方針等を検討
AISI所長を委員長とする「**AISI運営委員会**」で事業方針を検討

内閣府

IPA

AISI
所長
副所長

アドバイス
顧問

AISI関係府省庁等連絡会議
AIの安全性確保に向けた政府方針等を連携して検討
構成員：関係府省庁、関係機関
事務局：内閣府科技

AI安全性確保に向けた政府の方針を示す

事業方針や計画、成果等を報告

関係府省庁
関係機関

出席／参画
（委員就任、併任、出向）

【関係府省庁】
・内閣府（科学技術・イノベーション推進事務局）
・内閣官房（国家安全保障局・国家サイバー統括室）
・警察庁
・デジタル庁
・総務省
・外務省
・文部科学省
・厚生労働省
・農林水産省
・経済産業省
・国土交通省
・防衛省

【関係機関】
・情報処理推進機構（IPA）
・情報通信研究機構
・理化学研究所
・国立情報学研究所
・産業技術総合研究所

AISI運営委員会
AISIの事業運営に係る重要事項を審議。
委員長：AISI所長
委　員：パートナーシップ参画機関、関係府省庁（課長級）

事務局（IPAデジタル基盤センター）
事務局長：デジタル基盤センター長
- 企画・戦略チーム
- フレームワークチーム
- 技術チーム
- セキュリティチーム
- 標準チーム
- 利活用チーム

テーマ別小委員会
パートナーシップ参画機関、有識者（協力企業含む）、関係府省庁等でグループを結成
→**事業実証WG**の設置

パートナーシップ事業
パートナーシップ参画機関の関連の取組をAISIに登録し、統合的に発信
→**パートナーシップ協定**の発効

AIセーフティ評価に関するワーキンググループの設置

AISI Japan AI Safety Institute

- AIセーフティ評価に関するワーキンググループ（**事業実証WG**）を、AISI運営委員会の下の**テーマ別小委員会として設置。民間事業者を中心に**多様なステークホルダーが参画し、参画機関間の連携を図る場を提供、WG活動を推進する。
- **AIセーフティ評価の活動を広く一般に普及させ、AIの利活用を促進させることを目的**とし、民間企業を中心とした業界ごとの有識者とともに、**業界ごとのAIセーフティ評価に関する見解**をまとめ、具体的な実証をする等のWG活動を推進し、**業界ごとに特化されたガイドやデータ**を作り、その普及を図る。

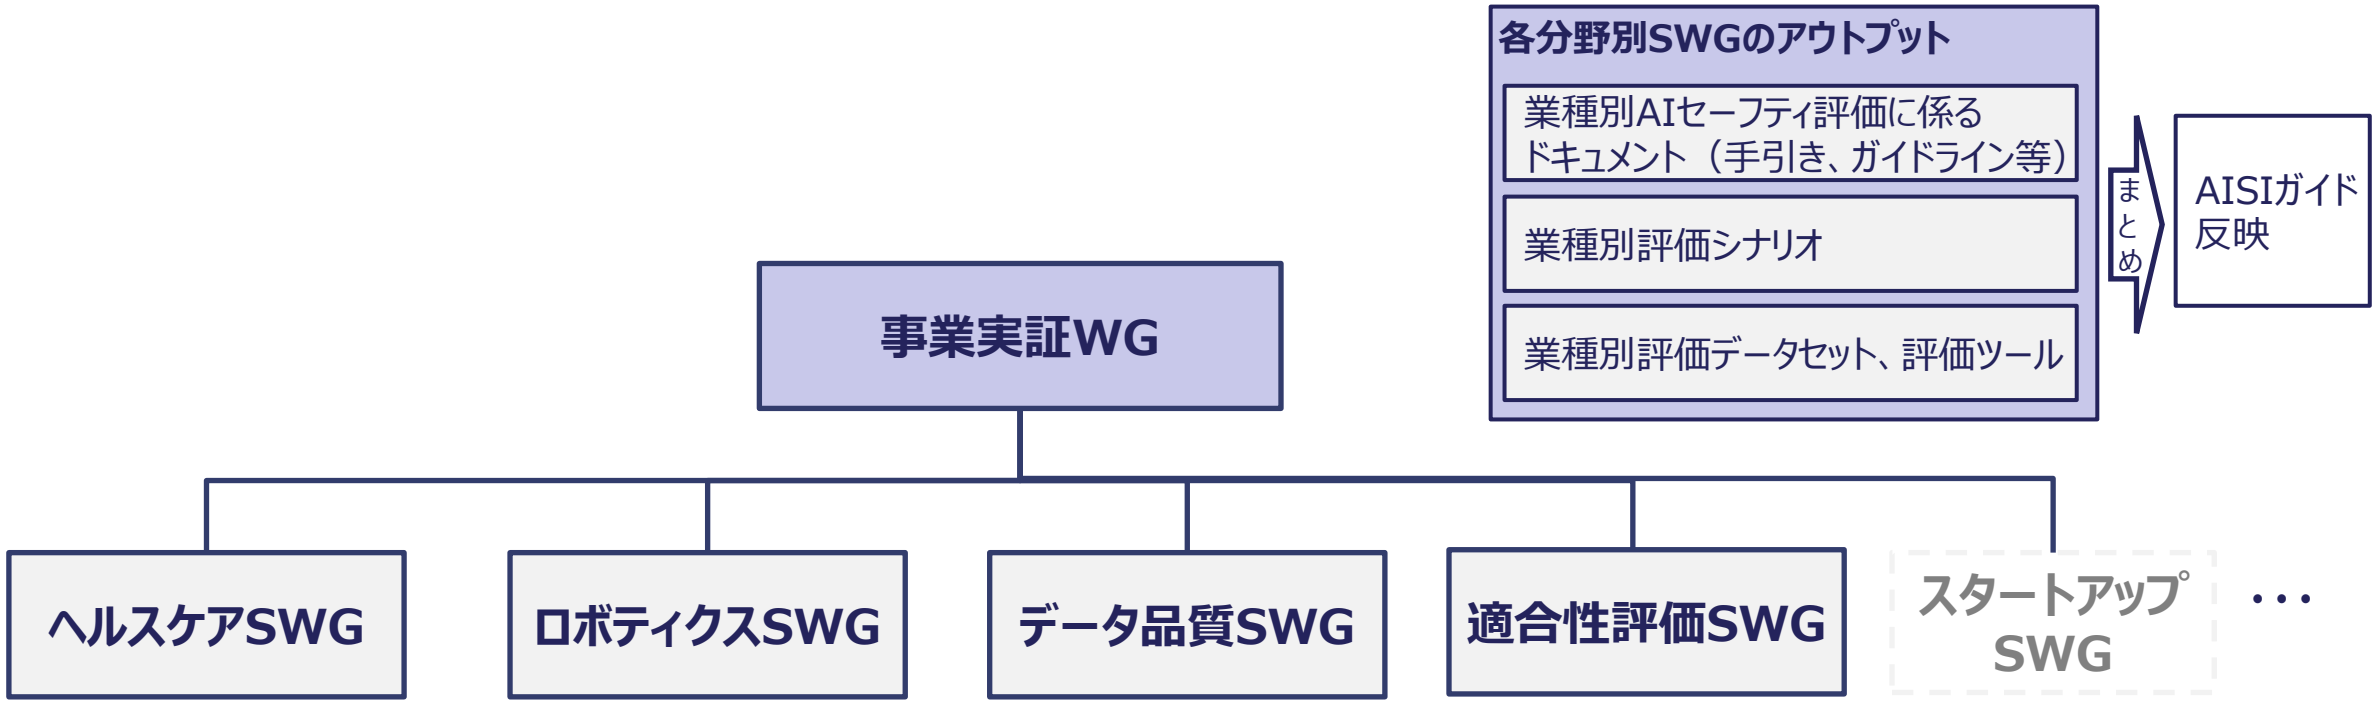

AISIパートナーシップ協定の発効

AISI Japan AI Safety Institute

関係府省庁の協力の下、**関係機関が連携**してAIの安全性に係る取組を推進していく協力体制（AISIパートナーシップ協定）を発行（2024年8月）

- AIの安全性に関する取組を進めるためには、**AISIのみならず、国内の関係機関と連携し、共同で対応していく**ことが不可欠。

- 以下、「日本AIセーフティ・インスティテュートパートナーシップ協定」より一部抜粋

第３条　（パートナーシップの活動内容）

日本AIセーフティ・インスティテュートパートナーシップ（以下「本パートナーシップ」という。）は、第５条の規定に基づく参画機関との協力の下、AISIの活動を効果的に推進するため、第７条第２項の規定に基づきAISIと参画機関との間で合意した範囲において、次の活動を推進する。

① AI安全性に関してAISIと参画機関が共同で実施する研究及び調査
② AISIが実施する活動に関する参画機関による助言の付与
③ 参画機関が実施するAI安全性に関する活動についてのAISIへの情報提供
④ 前各号の取組に関するAISI及び参画機関による国内外への情報発信、国内外の関係機関との調整・連携
⑤ その他前各号の活動に附帯する活動

AISIの幹部メンバー

AISI Japan AI Safety Institute

所長　**村上　明子**

1999年　4月	日本アイ･ビー･エム株式会社 東京基礎研究所 入社
2016年　1月	同社 東京ソフトウェア開発研究所
2021年　4月	損害保険ジャパン株式会社 入社 執行役員待遇 DX推進部 特命部長
2021年10月	同社 執行役員待遇 DX推進部長
2022年　4月	同社 執行役員 CDO(Chief Digital Officer)　DX推進部長
2024年　4月	同社 執行役員 CDaO(Chief Data Officer)　データドリブン経営推進部長　［現職兼務］
2025年　4月	SOMPOホールディングス株式会社　執行役員常務　グループChief Data Officer［現職兼務］

副所長･事務局長

平本　健二

1990年4月	NTTデータ通信株式会社 入社（現 株式会社NTTデータ）
2008年7月	経済産業省 CIO補佐官
2012年8月	内閣官房 政府CIO上席補佐官
2021年9月	デジタル庁 データ戦略統括
2023年7月	IPAデジタル基盤センター センター長　［現職兼務］
2024年2月	AISI事務局長（4月より副所長兼務）

副所長

西村　卓

2000年4月	郵政省（現総務省）入省
2006年6月	在シドニー総領事館領事
2009年7月	総務省情報通信国際戦略局国際経済課 多国間経済室 課長補佐（APEC、OECD、EPA担当）
2021年7月	内閣府健康･医療戦略推進事務局企画官
2024年7月	総務省サイバーセキュリティ統括官室企画官
2025年7月	AISI副所長［現職］

AISI 事務局

AISI Japan AI Safety Institute

AISI事務局は、以下６つのチームで構成されており、
政府や民間企業からの出向者も多数在籍

戦略・企画

- AISIの戦略や計画の作成、予算管理
- 広報、採用、人材育成
- 国内外の関係機関との調整・支援

技術

- AIセーフティに関する評価方法の確立
- 評価環境の開発

標準

- AI分野における適合性評価の手法確立
- 実運用を見越した国内体制構築の検討

フレームワーク

- AIセーフティに関する評価の枠組みの検討
- AIガバナンスに関する相互運用性確保に向けた調整

セキュリティ

- AIシステムに対する特有の攻撃手法の調査
- AIセキュリティインシデントの分類体系の検討
- AIシステムを狙った攻撃を体系化

利活用

- 事業実証ワーキンググループの企画・調整
- AIセーフティに関するAI利活用事例等の調査

取組・成果物

2024年度の活動と成果物

AISI Japan AI Safety Institute

		国際	AISI	政府
		イベント	成果物	
2024	4月		•**日米クロスウォーク1**の成果公表(4/30)	•**AI事業者ガイドライン**の公表(4/19)
	5月	AIソウル・サミット, 韓国		
	6月	G7サミット, イタリア		•**統合イノベーション戦略2024**の公表(6/4)
	7月		•米国AI RMF 日本語翻訳版の公表(7/4)	
	8月			
	9月		•**評価観点ガイド**の公表(9/18) •**日米クロスウォーク2**の成果公表(9/18) •**レッドチーミング手法ガイド**※の公表(9/25)	
	10月			
	11月	AISI国際ネットワーク会合, 米国	•**AIセーフティに関する活動マップ**の公表(2/7) •**データ品質マネジメントガイドブック**(ドラフト版)の公表(2/7)	
	12月		•**年次レポート**の公表(2/5)	
2025	1月		•**セキュリティ攻撃の俯瞰図**の公表(3/26) •**AIセーフティの普及に向けた文書**の公表(3/26)	
	2月	AIアクションサミット, フランス	•**評価観点ガイド1.10版**の公表(3/28) •**レッドチーミング手法ガイド1.10版**の公表(3/31)	•**AI制度研究会・中間とりまとめ**の公表(2/4) •**AI事業者ガイドライン1.1版**の公表(3/28)
	3月		•**データ品質マネジメントガイドブック**の公表(3/31)	

※レッドチーミングとは、攻撃者の目線で対象AIシステムにおける弱点や対策の不備を発見し、これらを修正及び堅牢化することで、AIセーフティを維持または向上させる取り組み

成果物の概要

AISI Japan AI Safety Institute

AI事業者ガイドラインを軸に、
技術的なレビューから人材育成まで、幅広く取り組む

クロスウォーク
国際的な相互運用性のため

AI事業者ガイドライン
総務省・経産省が策定・更新

活動マップ
全体像と優先順位付け

評価観点ガイド
評価

レッドチーミング手法ガイド
レッドチーミング

データ品質マネジメントガイドブック
AIに適格なデータを提供するため

多言語/多文化
多国間での問題

セキュリティレポート
セキュリティに関する知識

デジタルスキル標準
人材育成

AI事業者ガイドラインの概要

AISI Japan AI Safety Institute

総務省及び経済産業省は、既存のガイドラインを統合・アップデートし、「AI事業者ガイドライン（第1.0版）」を公表 ※2025年3月 1.1版に更新

- AI活用の流れの中で、各ステークホルダが対応すべきことを明確化。
- AISIは、AI事業者ガイドライン検討会を経済産業省と共同事務局として開催、運営している。

事業者のガイド利用を意識した内容

AI活用**ライフサイクル・主体毎**に対応すべき内容を定義

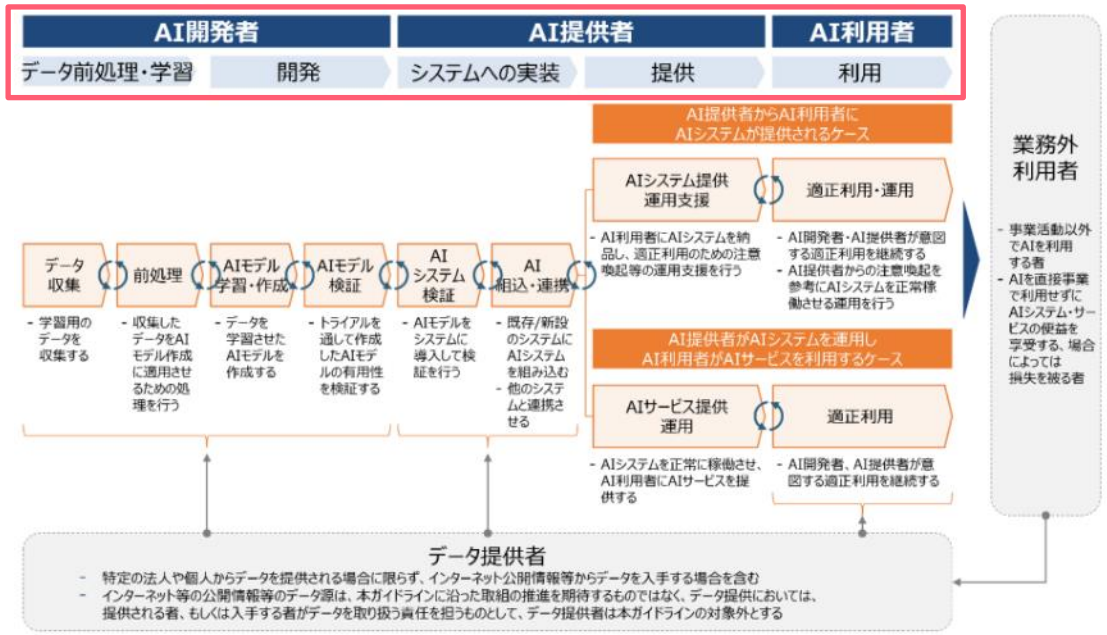

民間事業者による**ガバナンスの行動目標**※を定義

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

※ 中小企業においても、まずはどのようなアクションをとればよいのか明確化している

出典）「AI事業者ガイドライン（第1.1版）」本編（概要）及び別添（概要）総務省・経済産業省 より抜粋

日米クロスウォークの概要

AISI Japan AI Safety Institute

米国NISTのAI Risk Management Framework(RMF)と日本のAI事業者ガイドライン(Guidelines for Business; GfB)の相互関係を確認

- 米国のAI RMFをリファレンスに各国ガイドライン等との確認も可能。

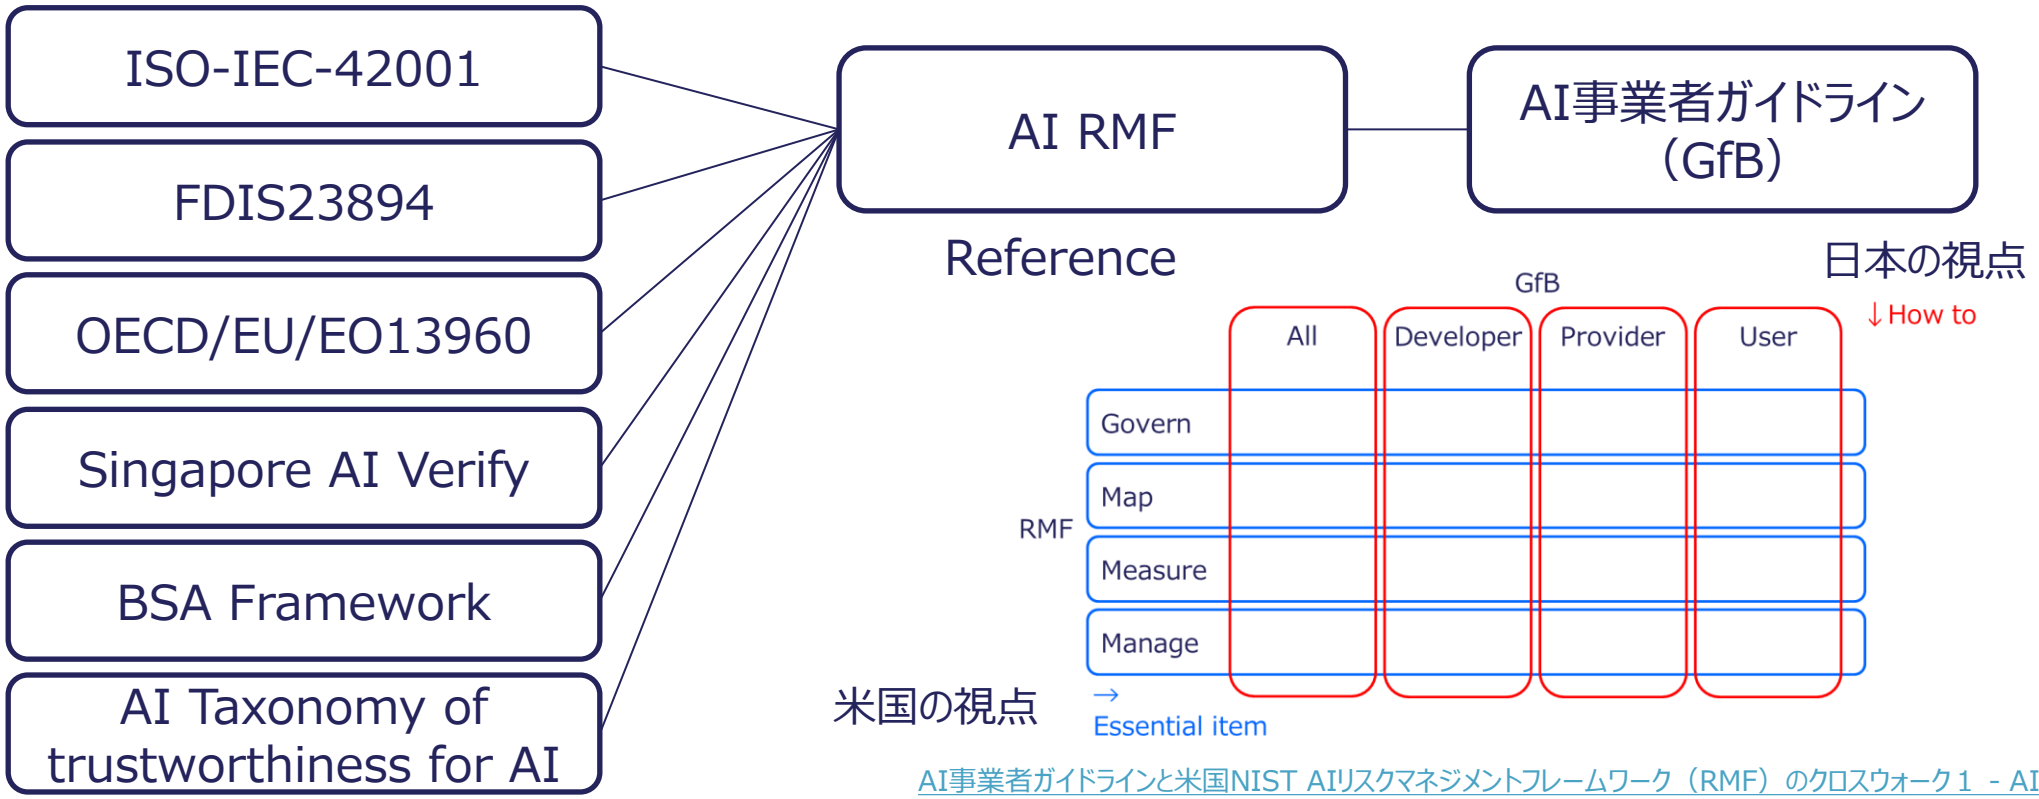

AI事業者ガイドラインと米国NIST AIリスクマネジメントフレームワーク（RMF）のクロスウォーク１ - AISI Japan
AI事業者ガイドラインと米国NIST AIリスクマネジメントフレームワーク（RMF）のクロスウォーク２ - AISI Japan

AIセーフティに関する活動マップ（AMAIS）の概要

AISI Japan AI Safety Institute

AIの安全性に関する活動が急速に変化・進化する中、
見落とされがちな部分や**活動間の相関関係を全体像として可視化**

- AISIは、**ディスカッションペーパー**として「AMAIS：AIの安全性に関する活動マップ」を公開。

- AISIは、**主要文献のベンチマーク**に基づき、包括的なアクティビティマップと関連用語を開発している。
- この日本主導の取り組みは、AIの安全性に関する国際的な協力体制の基盤をさらに強化し、持続可能で信頼性の高いAI社会の実現に貢献することが期待されている。

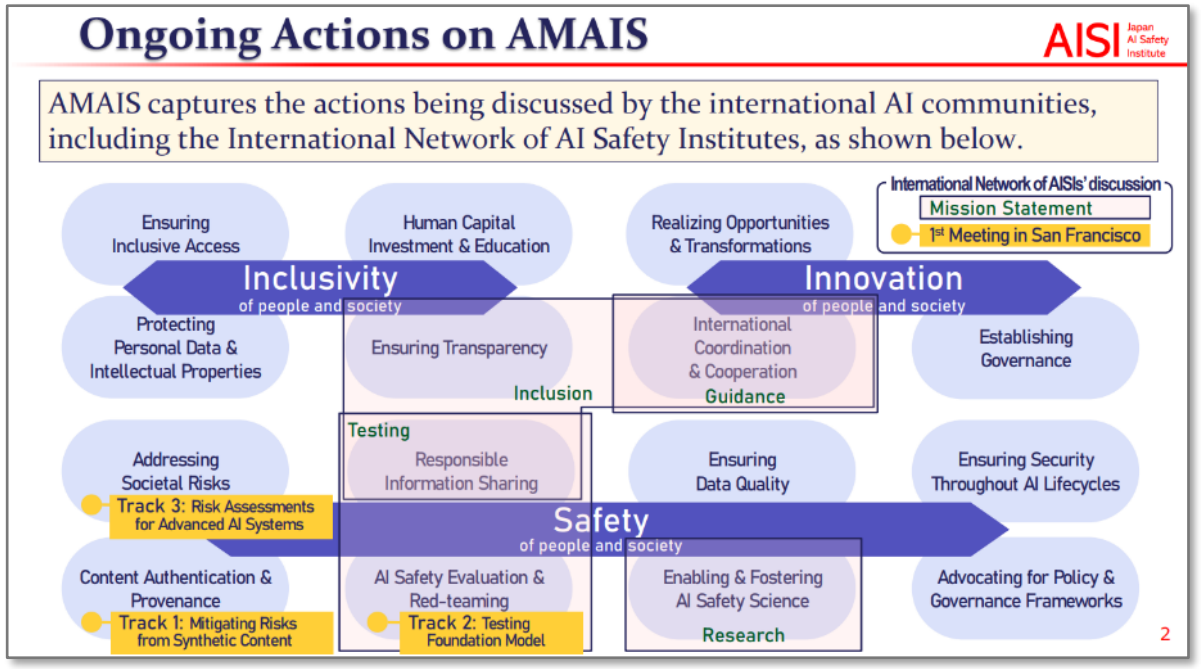

AIセーフティに関する活動マップ（AMAIS）AMAIS: Activity Map on AI Safety - AISI Japan

評価観点ガイドの概要

事業者がAIを開発・提供する際の参考として、
AIシステムの安全性を評価する際の基本的な考え方を示したもの

- 具体的には、以下の事項等が記載されている。
  - **安全性評価で想定するリスクや評価項目**
  - **評価の実施者や実施時期**
  - **評価手法の概要**

- このガイドは、安全・安心で信頼できるAIの実現に向けての第一歩であり、今後のAI開発・提供における安全性の維持・向上に資することを期待している。

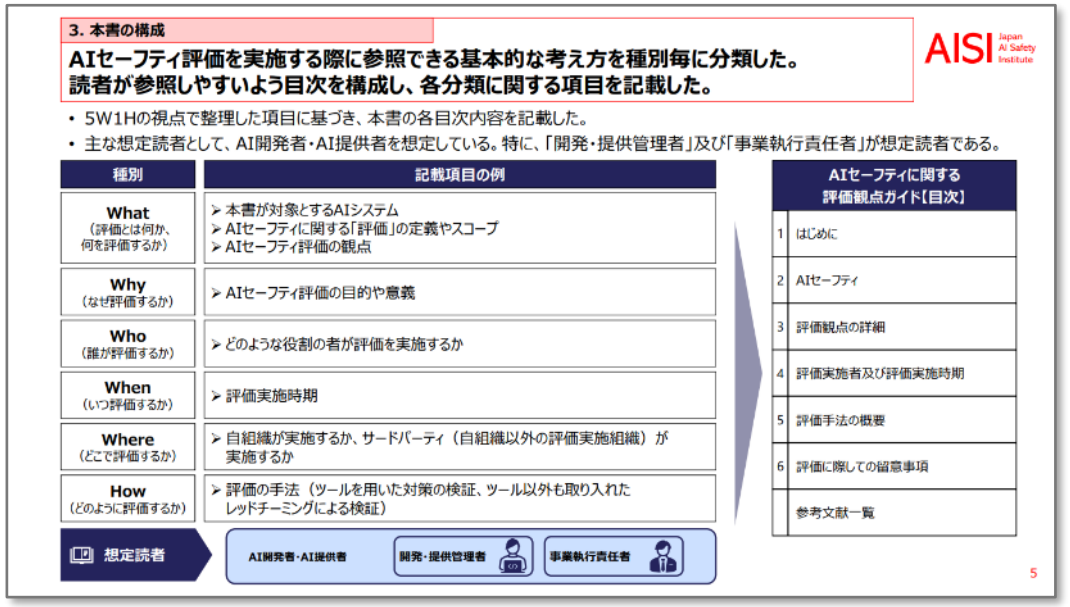

AIセーフティに関する評価観点ガイド - AISI Japan

レッドチーミング手法ガイドの概要

事業者が開発・提供する際の参考として、**AIシステムの安全性を評価する手法**の１つであるレッドチーミング手法について基本的な留意事項を示したもの

- 具体的には、安全性評価の実施体制、時期、計画、実施方法、改善計画の策定等にあたっての留意点が示されている。
- このガイドは、安全・安心で信頼できるAIの実現に向けての第一歩であり、今後のAI開発・提供における安全性の維持・向上に資することを期待している。

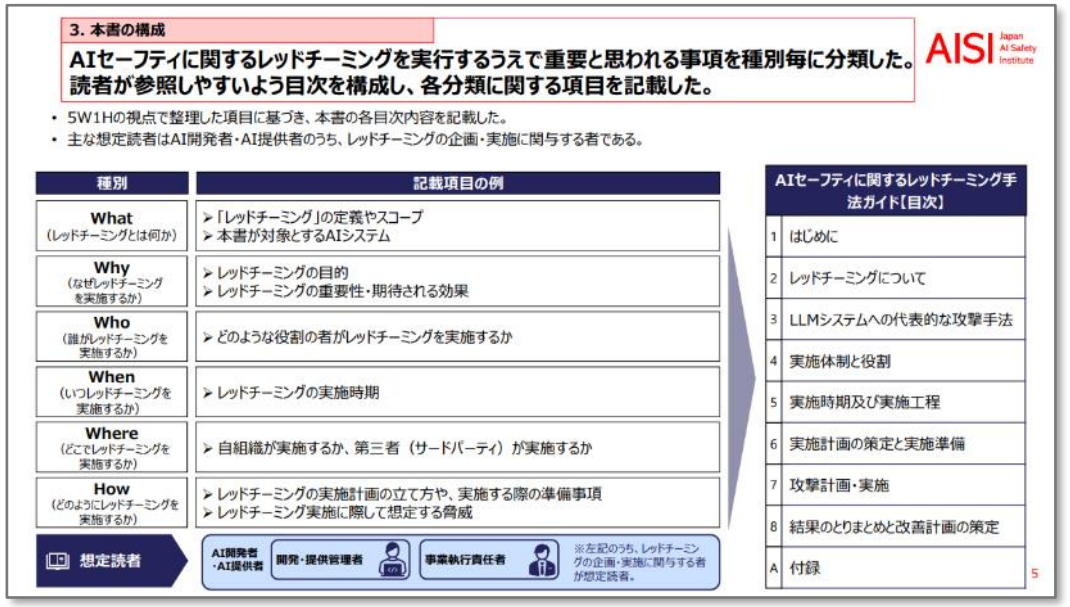

データ品質マネジメントガイドブックの概要

データとAIの価値を最大化するために必要な
データ品質を持続的に確保するため、何をすべきか整理

- データ品質は、AIの卓越性の基礎であり、信頼できるAIの実現に寄与する。AI社会を適切に実現し、データ駆動型社会へと導くため、本ガイドに整理。

- 本ガイドは、英語版が正式版であり、2025年3月に日本語訳サマリが公開。

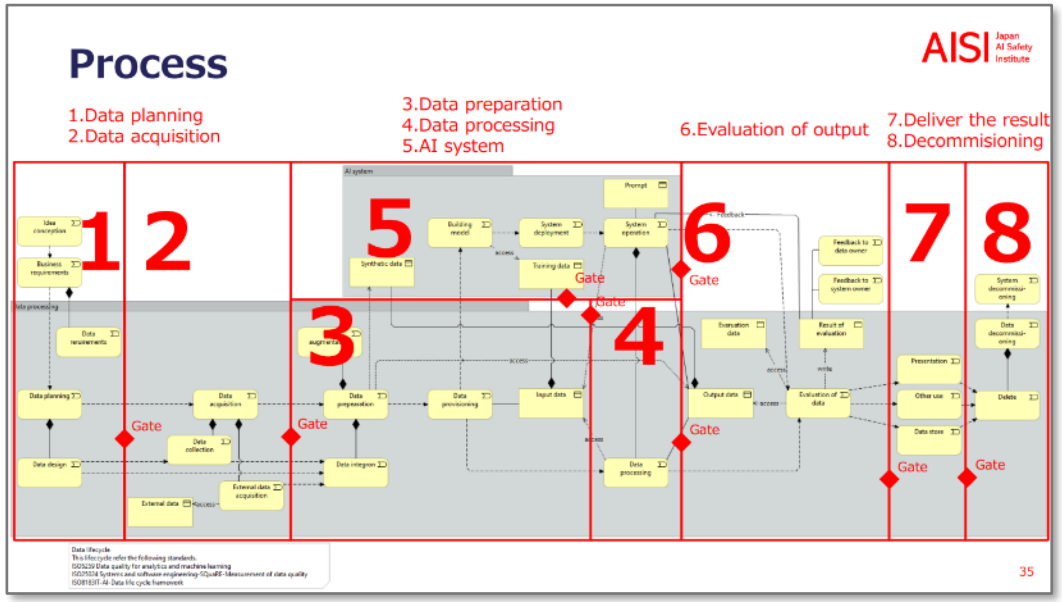

AIセーフティ年次レポート2024の概要

AISIの活動状況を「AIセーフティ年次レポート2024」としてまとめた。

- 「AIセーフティ年次レポート2024」とともに、関連するレポート等についても、年次レポートを補完する参考資料「AIセーフティ　ファクトシート2024」として取りまとめた。

- 本稿においては、AIの急速な進展に対応するための、AISIと国内外の関係機関や企業等との連携など、我々の今後の取り組みやその狙いについても記載している。

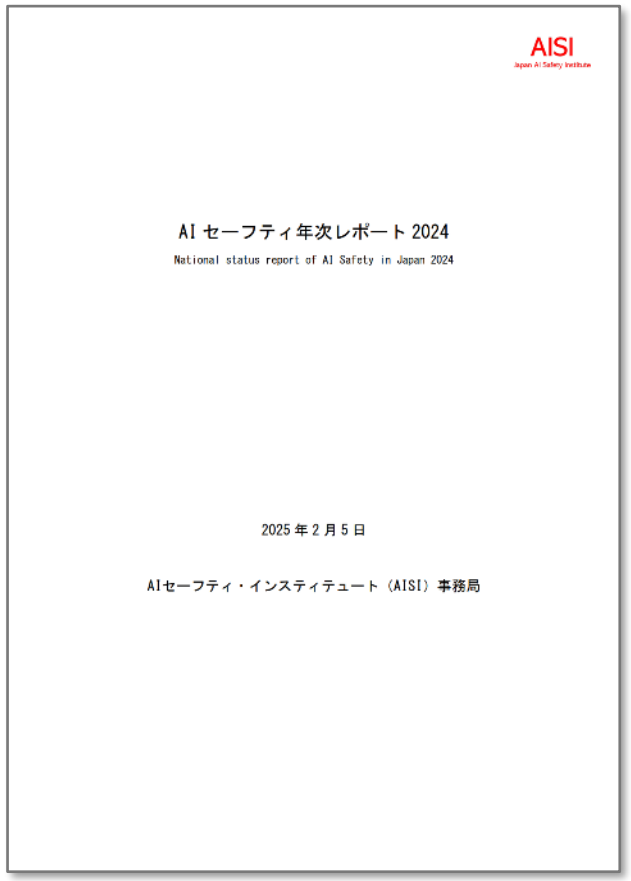

AIセーフティ年次レポート2024 National Status Report on AI Safety in Japan 2024 - AISI Japan

AISI Japan AI Safety Institute

国際連携

主要な国際会合

AISI Japan AI Safety Institute

AIセーフティ関連の国際会合に積極的に参加するとともに、
各国のAI関連事業者及び団体との意見交換も実施

- AISI関連のトップレベルの連携
  - **スタンフォード大学AIシンポジウム（2024年4月16日、スタンフォード）**
    - 米国・英国AISIの所長等とパネルディスカッション、並行した各国間意見交換
  - **AIソウル・サミット（2024年5月21-22日、ソウル）**
    - ハイレベルラウンドテーブル他、米英EU加独などと意見交換
    - 同時開催のAIグローバルフォーラムでアジア、アフリカ諸国等を含む議論に参加
  - **国連未来サミット（2024年9月22日、国連本部）**
  - **国連Global Compact Leaders Summit 2024（2024年9月24日、国連本部）**
    - 各国AI責任者などとAIセーフティに関して議論
  - **AISI国際ネットワーク会合（2024年11月10-11日、サンフランシスコ）**
  - **AIアクションサミット（2025年2月6-11日、パリ）**
  - **広島AIプロセス・フレンズグループ会合（2025年2月27-28日、東京）**

AIソウルサミット同時開催の
グローバルフォーラム

国連未来サミット

AISI国際ネットワーク

AISI Japan AI Safety Institute

米国の呼びかけで現在10カ国が参加
議長国は米国、事務局は英国が担当

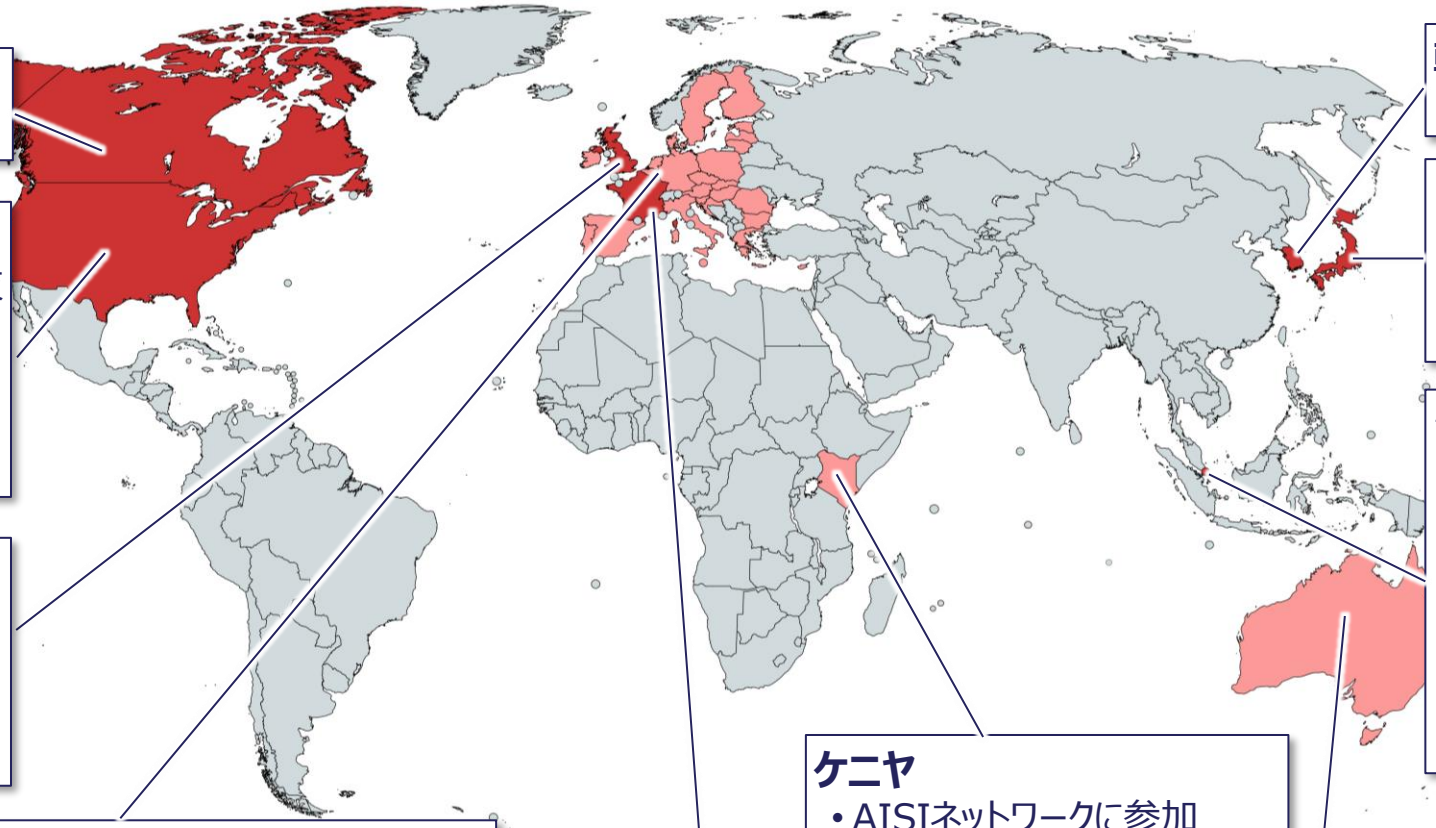

カナダ
- 2024年11月、AISI設立

米国
- 2024年2月、NIST(国立標準技術研究所)にAISIを設立
- 2025年6月にCenter for AI Standards and Innovation(CAISI)に改名。

英国
- 2023年11月、DSIT(科学イノベーション技術省)にAISIを設立。
- 2025年2月にAI Security Instituteに改名。

EU
- 2024年5月、欧州委員会に設立されたAI OfficeがAISI相当の機能も担い、利活用に加え、安全性も推進。AI法の整備と推進も担う。

フランス
- INESIA（AISI相当機関）を2025年2月に設立

ケニヤ
- AISIネットワークに参加

オーストラリア
- AISIネットワークに参加

韓国
- 2024年11月、AISI設立

日本
- 2024年2月、IPA(情報処理推進機構)にAISIを設立(UK,USに次ぐ3番目)

シンガポール
- 2024年5月、南洋理工大学（NTU）内のデジタルトラストセンターがAISIとして設立
- 大規模言語モデル（LLM）の国際標準化を目的とした安全性評価テストツールの提供等を実施

AISI

Japan AI Safety Institute