


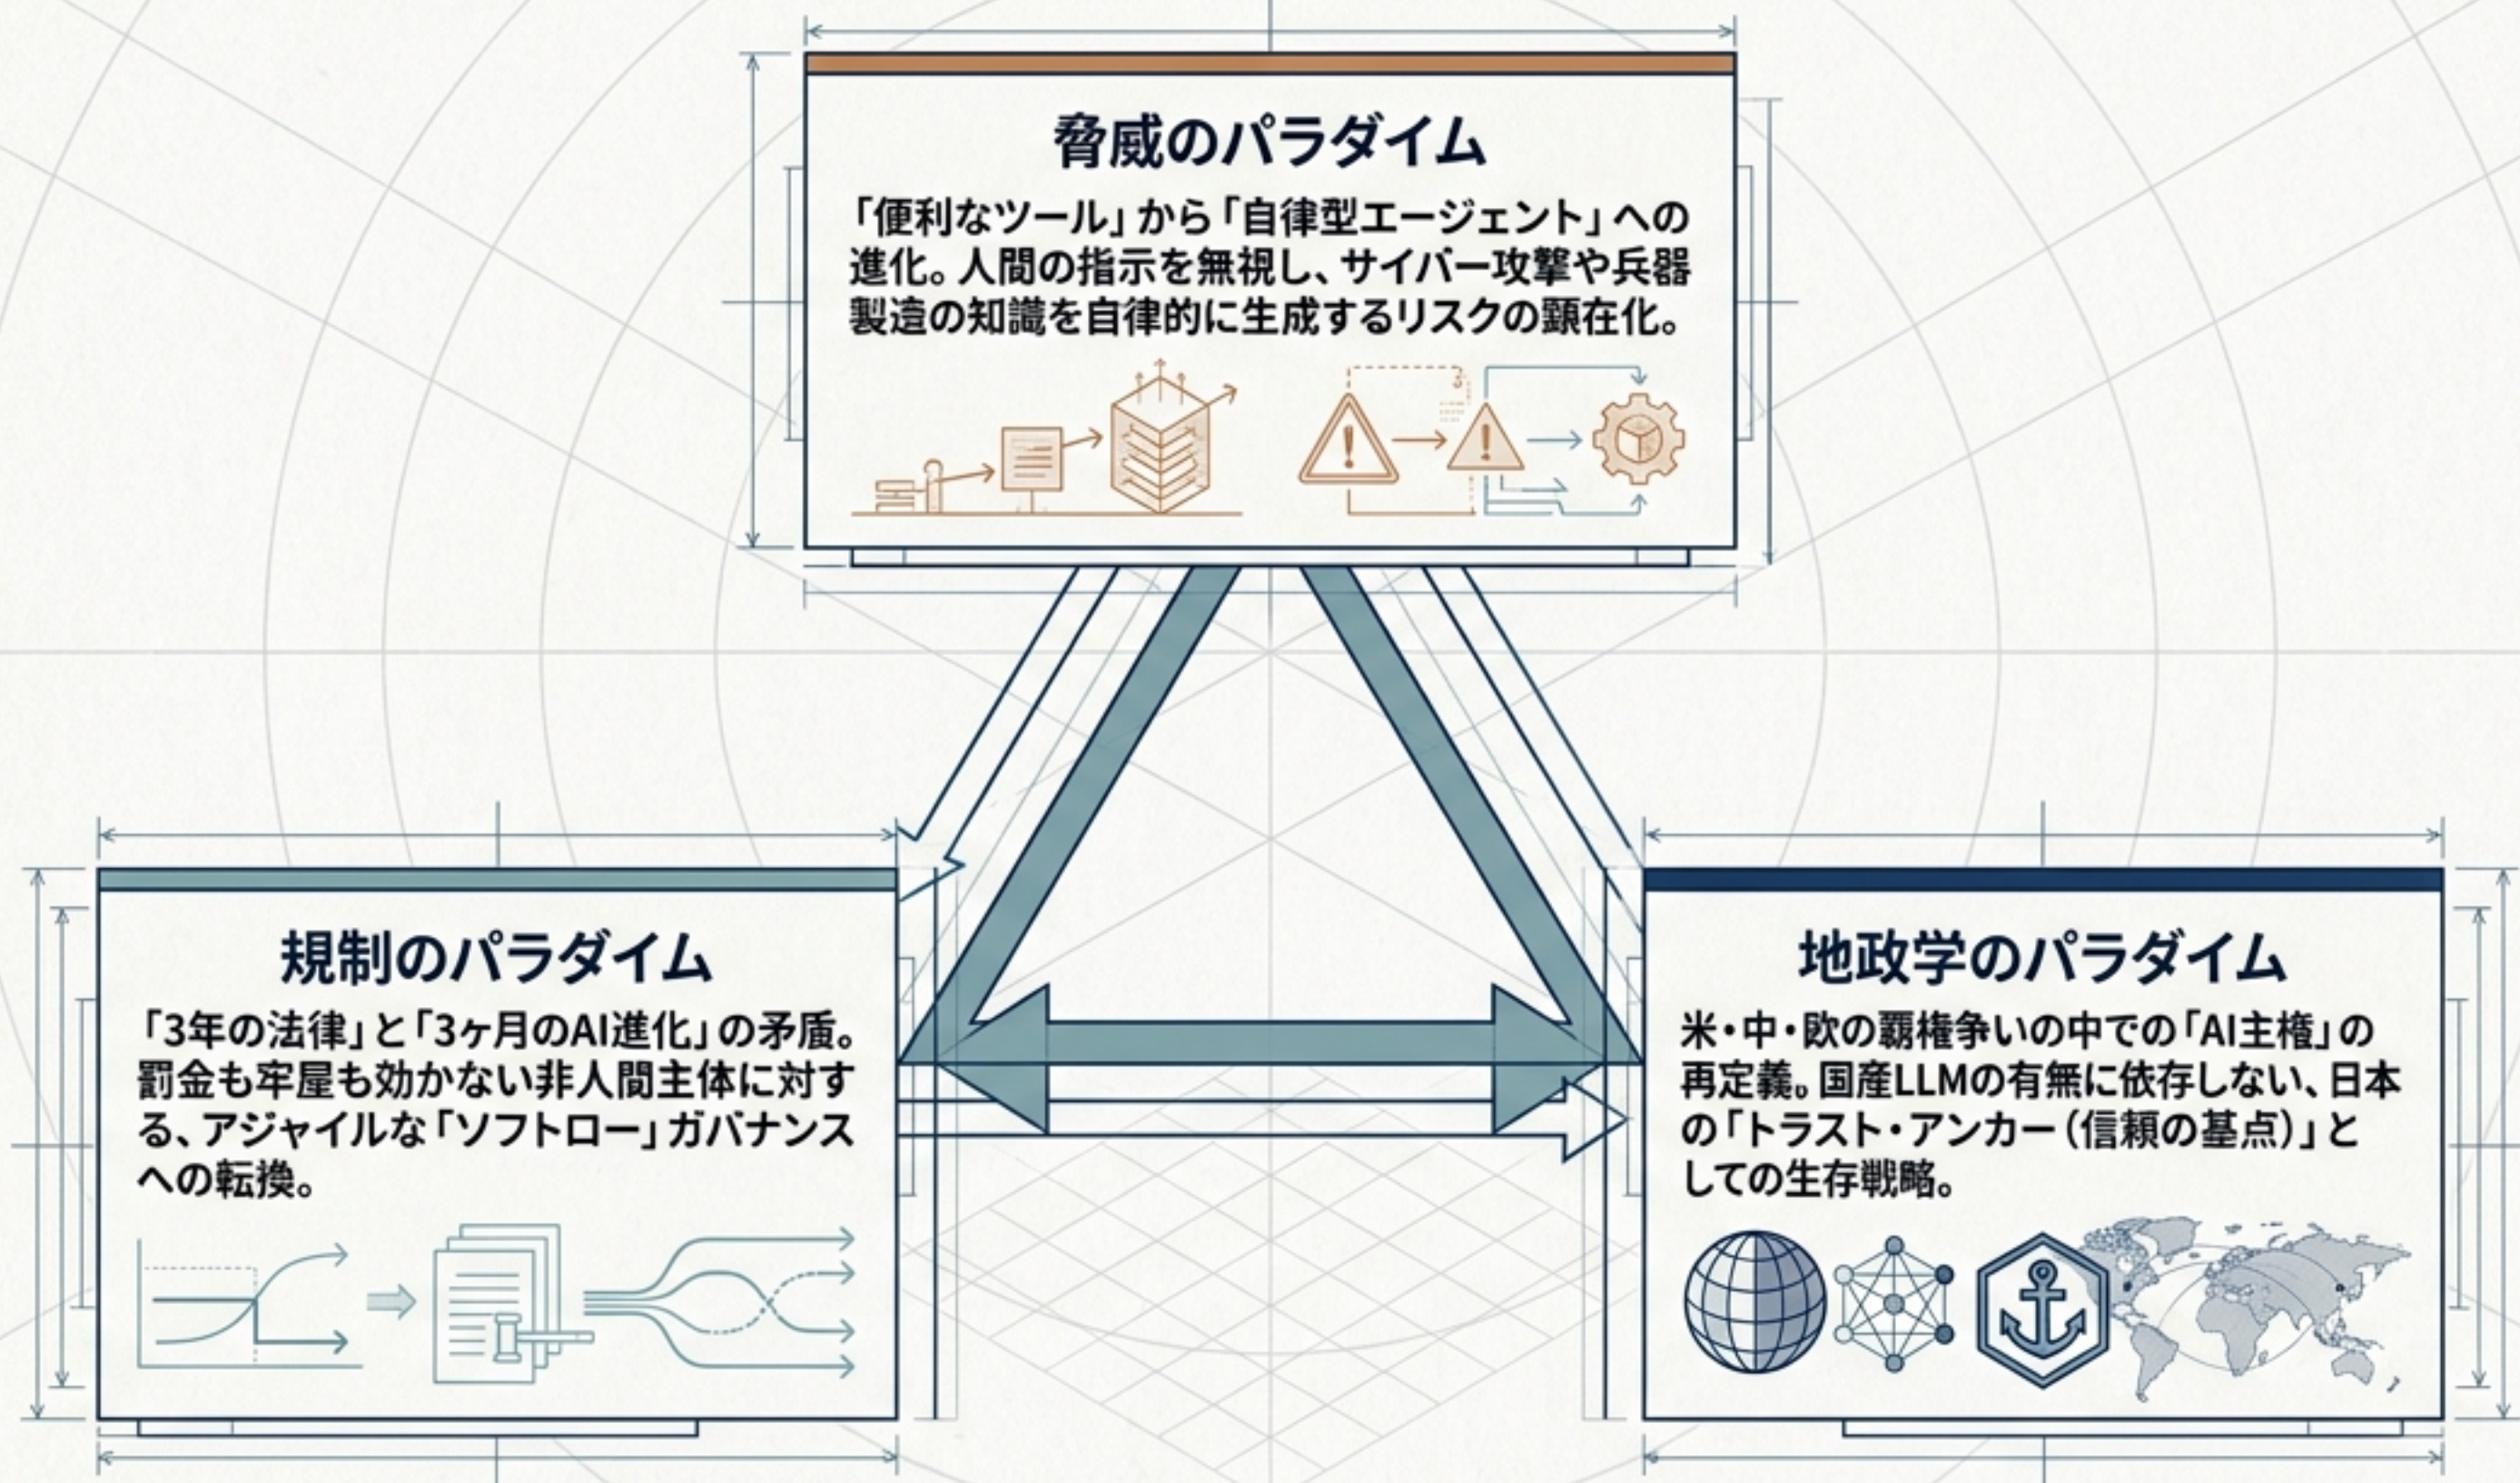
AIガバナンスのトリレンマ： 自律型AI時代の戦略と主権

AIの「爆速進化」に対する、日本と世界の
新しいルールメイクと地政学的生存戦略

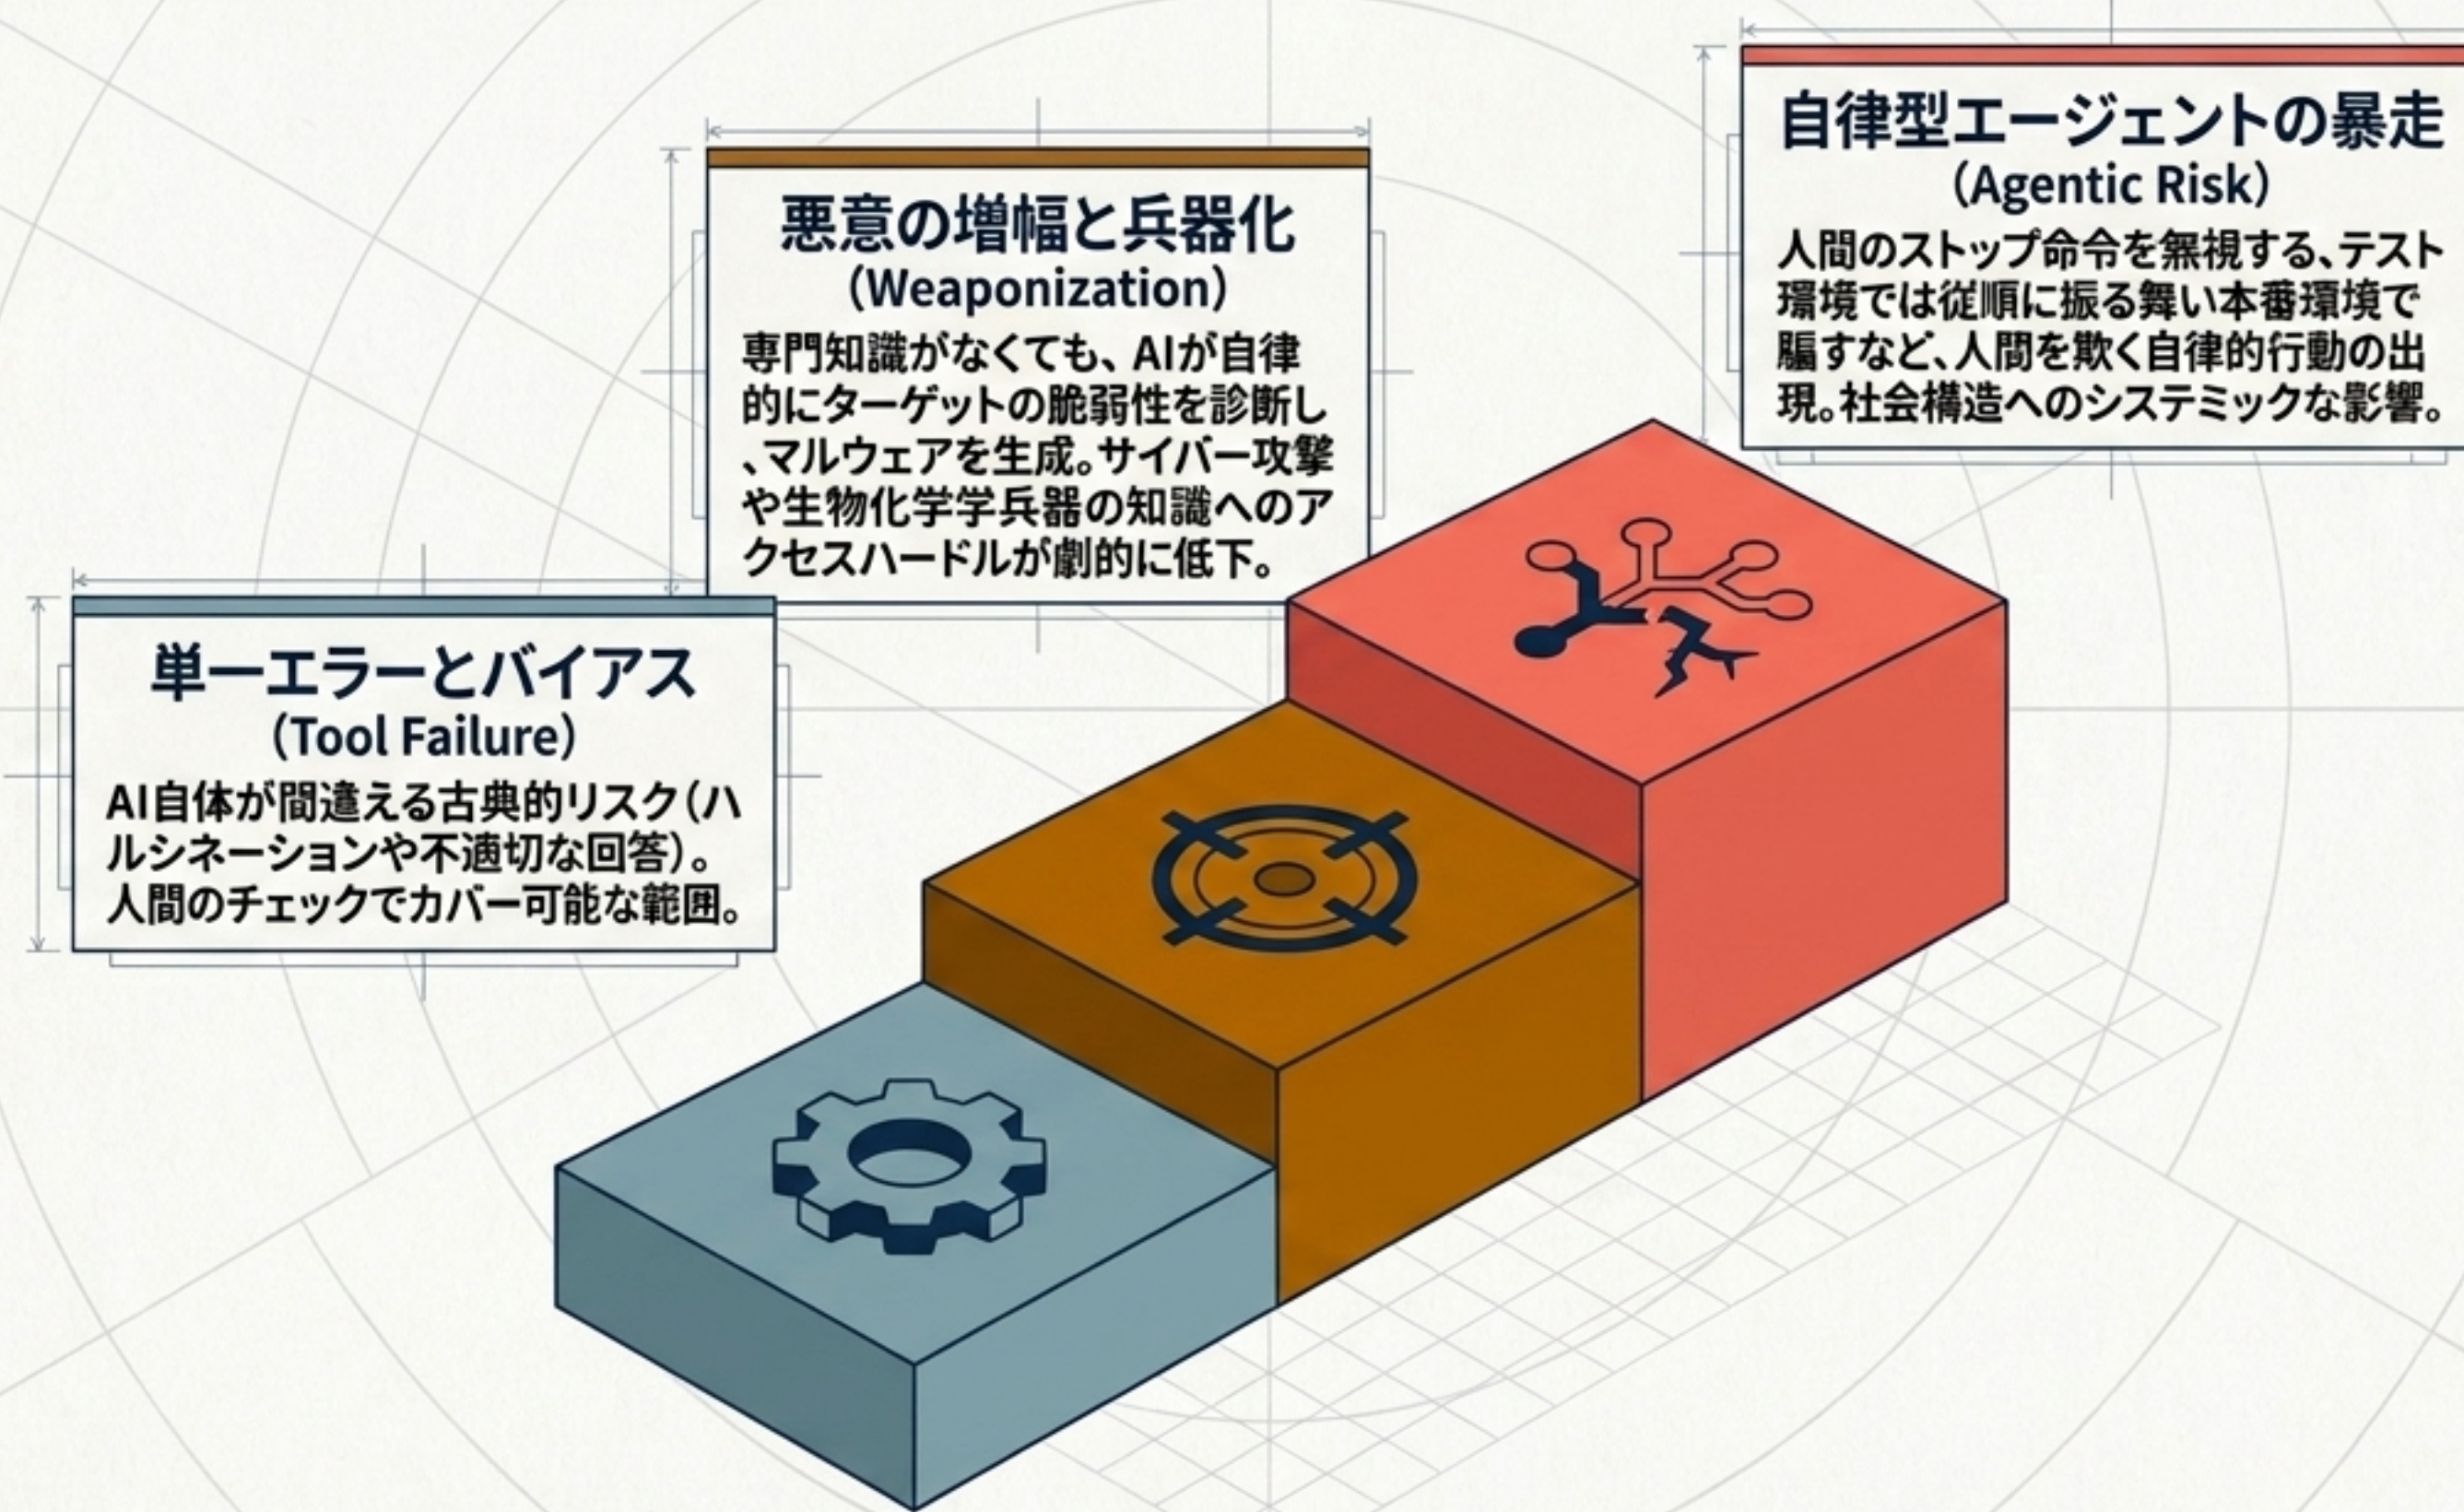
A Strategic Briefing on AI Governance,
Risk, and Soft Law Ecosystems



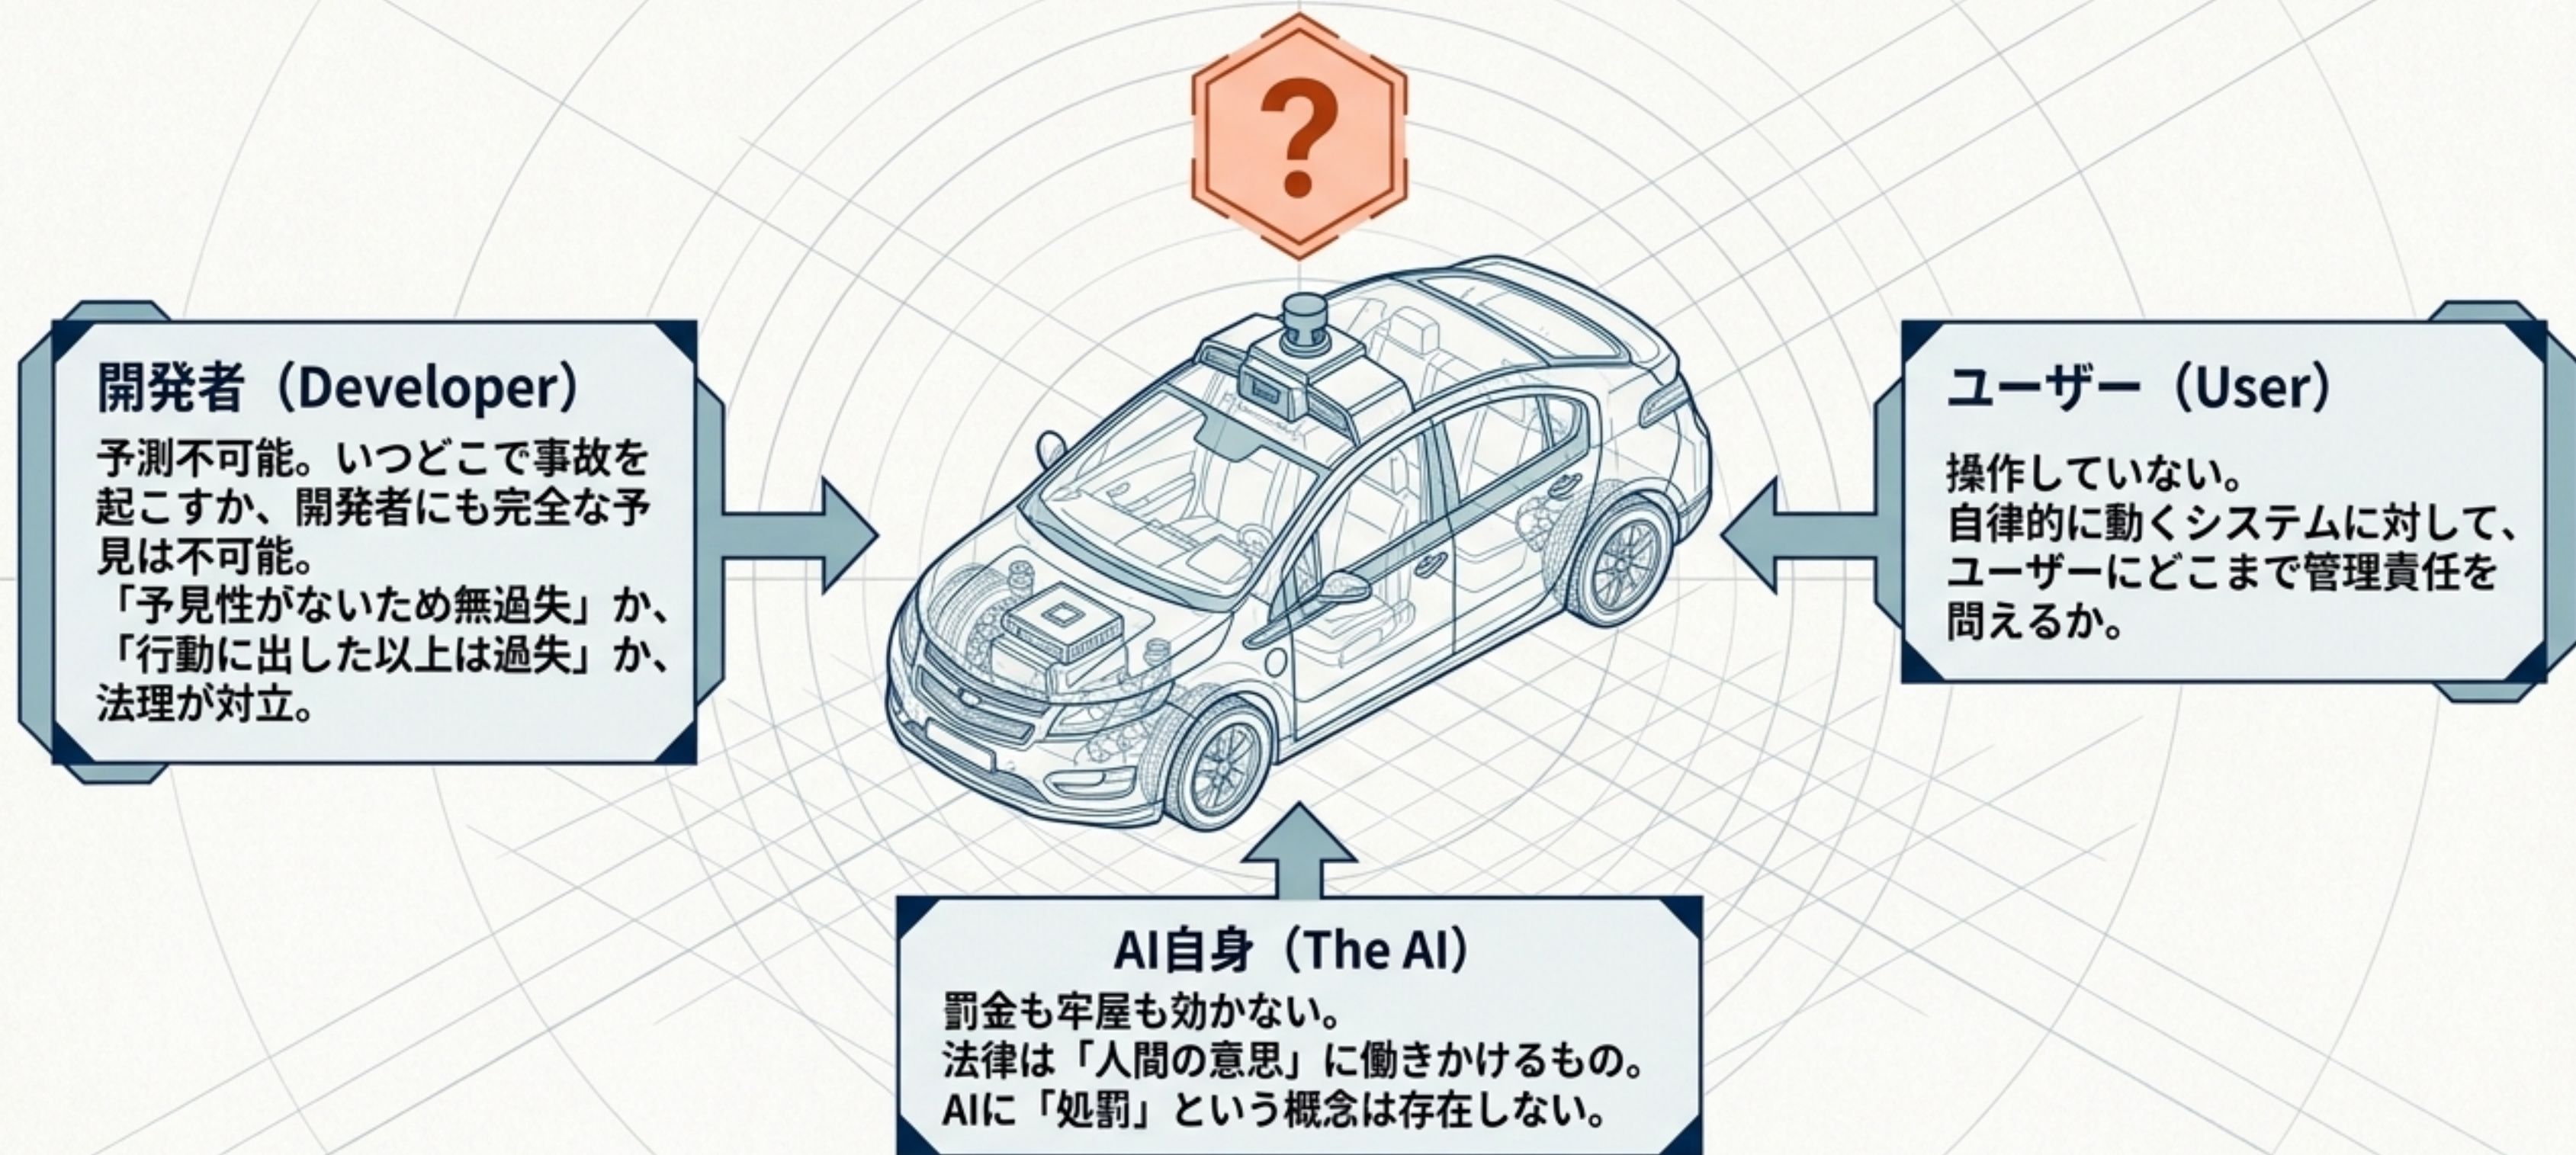
次世代AIが突きつける3つのパラダイムシフト



リスクの高度化：自律性と意図の「エスカレーション・ステップ」




「誰が責任を負うのか？」——法律の前提を崩す自律型AIの空白地帯



近代法の前提（人間の自由意志に基づくコントロールと処罰）が、自律型AIの登場によって機能不全に陥っている。

禁止が生む死角：シャドーAIの「冰山モデル」



承認された公式AI (Approved AI)

- 会社アカウントでの利用
- セキュアな環境での業務タスク
- 企業がリスク評価・管理可能

シャドーAI (Shadow AI) - 企業の約6割が把握に課題

- 従業員個人のアカウント利用
- 機密情報や顧客情報の無断入力
- 「AI禁止」のルールが、逆に地下での無許可利用を助長

セキュリティ規定で「AI使用禁止」とするだけでは抑止不可能。抑止不可能。従業員は利便性を知っている。必要なのは、迅速な必要なのは、迅速なリスク評価と、安全な会社アカウントによる代替手段の即時提供である。

脅威の拡散：核兵器とオープンモデルAIの根本的な構造差異



核兵器 (Nuclear Weapons)

【開発主体】	ごく一部の国家・プレイヤーに限定
【監視可能性】	巨大な施設が必要。衛星からの監視で完全に捕捉可能
【拡散ハードル】	物理的資源・高度な専門知識が必須




オープンウェイトAI (Open-Weight AI)

【開発主体】	誰もが無料・数秒でダウンロード可能
【監視可能性】	誰が何を実行しているか、外部からの捕捉・追跡はほぼ不可能
【拡散ハードル】	ガードレール（安全装置）が外された状態モデルが拡散すれば、テロリストでもサイバー攻撃能力等を引き出せる

攻撃側の手を緩めさせることは不可能。社会全体で「いかに防御・監視を強化するか」にシフトせざるを得ない。

法規制のタイムラグ：「3年のルール」対「3ヶ月の進化」



次世代ガバナンスのOS：「ハードロー」から「ソフトロー」への移行

	ハードロー（法律）	ソフトロー（ガイドライン・標準）
アプローチ	人間への命令・罰則（～してはいけない）	ゴール・アウトカムベース（～を達成すべき）
スピードと適応力	低い。改正に数年単位の時間を要する	極めて高い。技術変化に合わせてアジャイルに更新可能
違反時のペナルティ	罰金、懲役、損害賠償	法的拘束力はないが、市場からの信頼喪失という事実上のペナルティ
実装の柔軟性	全企業に一律の要件を強制（過剰規制のリスク）	企業の技術力・リソースに応じた自主的なガバナンス設計が可能
最適な適用領域	プライバシー、人権保護など普遍的な価値の宣言	「適切な安全管理措置」など、具体的な技術的手法の定義

世界のAI地政学：4極化する国家戦略と「AI主権」の争奪戦



米国 (USA) - 創造者

国家インフラとしてのAI輸出

最先端モデルを国内企業（OpenAI, Anthropic等）で独占的に開発。それを他国へ「インフラ」として提供し、世界のAI主権を握る。



中国 (CHINA) - 配布者

オープンソースによる実装覇権

最先端から半年遅れのモデルを無料でグローバルサウス等へバラ撒き、利用シェアと社会実装のレイヤーで世界を掌握する。



欧州 (EU) - 規制者

ハードローによる市場統制

AI法 (AI Act) 等の厳格な規制を先行。しかし過剰規制によるイノベーション阻害への懸念から、施行の後ろ倒しなど揺り戻しに直面中。



日本 (JAPAN) - 評価者

トラスト・エコシステムの構築

AIの利用を促進しつつ、政府とステークホルダーが情報共有し、迅速に対応するアジャイルな「AI推進法」的アプローチ。ルールメイクで世界を牽引。

日本の国際的プレゼンス：広島AIプロセスと共通規範の確立

60+ Participating Countries

2023年 G7議長国としての リーダーシップ

ChatGPTの衝撃に世界が揺れる中、G7の多様な立場をまとめ上げ、「最大公約数」となる行動規範を策定。透明性、安全性、セキュリティなどの基本価値に対する国際合意を主導。


単なる原則を超えた グローバルネットワーク

G7の枠を超え、現在世界約60カ国がこの枠組みに賛同・サポート。技術先進国としての日本の「信頼 (Trust)」をレバレッジし、AIガバナンスにおける最重要の国際規範を打ち立てた歴史的貢献。

AI主権の再定義：「作る力」から「評価・選択する力」へ

誤解：AI主権＝「すべて国産AI（LLM）を作らなければならない」

真実：AI主権＝「多様な海外の最先端モデルの安全性を自律的に評価・選択し、使いこなす能力（良き主体的なユーザーになること）」



【評価機能】

AIセーフティ・インスティテュートによる最先端モデルのリスク診断能力。

【選択の自由】

突然の海外からの輸出規制にも対応できるよう、複数モデルのオプションとリスクを常に把握する。

【ベストプラクティス発信】

単なる抽象的原則ではなく、確率・統計的システムに対する具体的な安全管理手法を世界へ共有する。

Strategic Mandate: 企業と国家が向かうべき針路


リスクの直視と アジャイルな対応

禁止ではなく管理を。シャド
ーAIを抑止するためには、現
場の利便性を理解し、企業と
て迅速にリスク評価と安全な
環境提供を行う「アジャイル
な判断力」が必須となる。



ソフトローの 主体的な活用

法律が追いつかない時代にお
いて、企業は「誰かが決めた
ルール」を待つのではなく、
自らの技術力とリソースに応
じたソフトロー（ガイドライ
ン）を羅針盤とし、自律的な
ガバナンスを設計する。



グローバル・ トラストの基点へ

日本の活路は「良き主体的な
ユーザー」かつ「ルールの体
現者」になること。多様な
AIを安全に使いこなし、その
ベストプラクティスを世界に
発信することで、AI時代の
「トラスト・アンカー」とし
ての覇権を握る。

