

AI-IRS

AIインシデントレスポンス・アプローチブック (概要版)

Approach Book for AI Incident Response System: AI-IRS
~ A Foundation for Trustworthy AI ~

2026-1
AIセーフティ・インスティテュート

AISI Japan
AI Safety Institute

AIシステム向けインシデントレスポンスの枠組み「AI Incident Response System (AI-IRS)」について

近年、AIが意思決定や業務効率化など事業の中核として活用され始めてきています。一方で、仮に中核を担うAIの誤判断やサイバー攻撃による停止などが発生した場合、事業活動に大きな被害をもたらす可能性があります。特にAIでは、ブラックボックス性（処理過程が不透明で、意思決定の内実を非常に把握しにくい性質）や自律性（目標達成に向けて人の介入なく自ら学習・判断・行動等を行う性質）などの性質により、AIシステムではリスク対策を実施してインシデントの発生を未然に防ぐ予防的統制が、従来システムに比べて難易度が高いと見込まれます。AIシステムではゼロリスクの達成が困難である前提に立ち、インシデント発生時にも事業影響を最小化する取り組みが重要です。

これらを背景として、従来の情報システムにおけるインシデントレスポンスをAIシステムにも適用・拡張させる新たな枠組みであるAI-IRSを提示します。AI-IRSでは、観測性（可視化）と制御性（封じ込め）を中心核に、運用中の挙動を把握し、問題箇所を切り離すことで被害を最小化する枠組みです。既存の開発・運用プロセスに容易に追加でき、運用負荷とインシデントの影響の双方を抑えられます。

また、AI-IRSは組織内部の取り組みに限定されず、サプライチェーンにまたがるAIライフサイクルの全体を観測・制御し、異常の検知・封じ込め・復旧を自律化する共通基盤の整備に向けたビジョンも示しています。

この枠組みにより、AIシステムを用いて事業活動を行う組織が、AIを制御可能な戦略資産として位置づけ、運用のレジリエンスを確立し、事業継続性を確保し、さらにはイノベーションの加速を促進することが重要になります。組織や社会における整備・運用を進める際のきっかけや参考として、ぜひご活用ください。

AIインシデント対応に向けたアプローチ

- 日々進化するAIでは、今まで以上にリスクへの予防的対策が困難となるため、リスクの発生(=AIインシデント)に備えた対策はより重要となる
- AISIはAIセーフティ実現に向け活動(評価観点ガイド、レッドチーミング手法ガイド、評価ツールの公開 等)
- これらはシステムの防御・堅牢性を高める予防的対策となるが、AIシステムではAIエージェントの活用などが進み、よりAIインシデントレスポンスが困難となることが想定される
- AIインシデントが発生した際に、AIシステムを評価し影響を最小限に抑える取り組みを進める必要がある

予防的対策
✓開発段階や運用開始後定期的なAIセーフティ評価の実施
✓AIシステムの不適切な動作が発生しないことを事前に評価し、発生自体を防止する
✓システムの防御・堅牢性を高め、AIインシデントを発生させないAIシステムを構築する

課題
✓全てのリスクに事前に対策することは不可能
✓特にAIシステムでは内部ロジックの把握が難しく、AIインシデントの原因調査が困難になる等、想定される
✓AIインシデントは必ず発生するという前提に立った対策が必要

+発見的対策
✓AIシステムにおけるAIインシデント発生時の影響最小化と迅速な復旧に向けた対策
✓AIインシデントレスポンス能力の評価に加え社会基盤の確立も必要
✓組織の枠を超えた社会システムの安定的な継続を維持する

項番	タイトル
1	はじめに
1-1	背景・想定読者
1-2	スコープ
2	AI-IRSの仕組み
2-1	GAP分析とケース毎の整理
2-2	対応レベルの評価指標
2-3	関連する要素
2-4	想定される効果事例
3	未来予想
3-1	AIインシデントレスポンスの未来予想

1-1. 背景・想定読者

日々進化するAIでは、今まで以上にリスクへの**予防的対策**が困難となるため、リスクの発現（＝インシデント）に備えた**発見的対策**はより重要となる

背景	課題
<ul style="list-style-type: none"> ➤ AIリスクは複雑化し予防だけでは限界。迅速なインシデントレスポンス態勢の構築が不可欠 ➤ 競争力強化へAI活用を推進しつつ、評価とインシデントレスポンス態勢の同時強化が求められる ➤ 従来のインシデントレスポンス関連ガイドはAIに未対応 ➤ インシデント対応態勢と合わせて、SBOM等の基盤整備も求められる 	<ul style="list-style-type: none"> ➤ AI導入で新種・進化するリスクが増大。運用中に挙動が変化し、従来型の固定手順やパッチ対応だけでは不十分 ➤ AIのブラックボックス性や自己更新により仮に検知できても、その後の原因究明・修復が難化する ➤ 日本国内では予防偏重の傾向。一度インシデントが発生すると、影響が長期化する。発見的統制の強化が必要


想定読者	<p>AIシステムを業務に導入・運用する組織において、以下に記載する幅広い立場の関係者</p> <ul style="list-style-type: none"> ✓ CAIO（最高AI責任者）、CISO（最高情報セキュリティ責任者）などのマネジメント層 ✓ CSIRT（コンピュータセキュリティインシデント対応チーム）、SOC（セキュリティオペレーションセンター）、ISIRT（情報セキュリティインシデント対応チーム）などのインシデント対応関連専門部隊 ✓ AIにおける共通的なルールや方針を立案する政策担当者 等
------	--

位置付け	<p>本紙は、組織がAIインシデントレスポンス強化するためのベストプラクティスを羅列したものではない。組織や社会がAIシステムやAI利用におけるインシデントレスポンス強化の必要性や観点、未来像などを示すことで、読者にこれらを認識いただき、組織や社会における整備・運用を進める上でのきっかけや参考となることを期待する</p>
------	---

1-2. スコープ

インシデントレスポンスのライフサイクル（準備、検知・分析、封じ込め・根絶・復旧、事後対応）のうち、検知・分析、封じ込め・根絶・復旧がスコープ

- AIシステムにおいても、従来のシステム構成の中にAIが搭載されているという認識の上で、**NIST SP800-61 Rev.3** ^{*}に定められているインシデントレスポンスのライフサイクル（準備、検知・分析、封じ込め・根絶・復旧、事後対応）は有効であるが、各ライフサイクル内での具体的な対応策が変わってくる（追加される）と想定
- 現状のシステムにおけるインシデントレスポンスのライフサイクル（準備、検知・分析、封じ込め・根絶・復旧、事後対応）において、**AIシステムの場合に追加で対応が必要**になる観点の検討が必要と判断
- AISIでは、上記ライフサイクルのうち、インシデントが発生した際の緊急対応フェーズとなる検知・分析、封じ込め・根絶・復旧フェーズをスコープに、対応レベルを評価することを目指して**「観測性」「制御性」**の二つの指標で整理する



2-1. GAP分析とケース毎の整理

インシデントレスポンスに関する既存の枠組み（NIST SP800-61）を基に、AIシステムにおけるインシデント対応をオーバーレイする

- まずは現状のシステムにおけるインシデントレスポンスのライフサイクル（準備、検知・分析、封じ込め・根絶・復旧、事後対応）のうち、インシデントが発生した際の緊急対応フェーズとなる検知・分析、封じ込め・根絶・復旧フェーズをスコープに、**AIシステムの場合に追加で対応が必要になる内容**について、現状とのGAP分析として整理する。
- また、AIの技術は日々進化しており、それに合わせたインシデントレスポンスの仕組みや体制を検討することが有効となるケース毎に整理する。状況の変化に合わせて、ケースの追加や更新を検討する。
- これらの取り組みにより、AIが起因となるインシデントに対しても、影響の軽減につなげることができる。

GAP分析


観測性と制御性における対応内容について、AIシステムの場合に追加等が必要な内容を整理

分類	AIシステムにおいて追加される対策（例）
観測性	従来のソースコードルールベースバグ探索では検知困難なため、入力データとAIの出力結果の不規則な逸脱・異常値検知方法・フローの検討 等
制御性	改ざんされたモデルの過去バージョンへの切替/再訓練や、悪意ある学習データ（データポイズニング）が混入した場合の該当データの局所除去・再学習の検討 等



ケース毎の整理

AIの技術的進歩や利用方法のトレンドに合わせたインシデントレスポンスの対応方法例を整理



2-2. 対応レベルの評価指標

AIインシデントレスポンスにおいて、**観測性と制御性**を両立することが、
インシデントレスポンス態勢の強化に繋がる

- GAP分析を制御性、観測性の2つの軸で再整理し、AIシステムにおける対応の抜け漏れを防ぐことを目的とする。

制御性 観測性	可制御	不可制御
可観測	【理想状態】(○観測・○制御) AIの挙動を把握・制御でき、運用・封じ込めが容易でインシデントへの対応ができる。	【制御不足状態】(○観測・✗制御) AIの内部状態や行動を観測できるが、操作できない状態にある。封じ込め不能リスク。
不可観測	【観測不足状態】(✗観測・○制御) AIの挙動を止めるなどの対応ができるが、原因分析のための情報が得られず、過剰な範囲を停止するなど非効率な制御状態にある。	【非管理状態】(✗観測・✗制御) AIの挙動を観測も制御もできない。最も危険な状態。

⇒ 可観測 + 可制御の状態を目標に対応することが重要である (組織やサービスの置かれる状況によって、具体的に求められる内容は異なる)

- ケース毎に整理した結果の一部を記載する (詳細な整理結果は、詳細版を参照)

RAG 

- 機微情報の漏洩
- データ汚染による不正動作…

✓ 迅速な原因分析を可能にするための出力プロンプトのもとになった情報が含まれている**RAGのトレース機能**の導入

✓ インシデントの原因となった**RAGのみ**をサービスから切り離す機能、およびRAGなしでもサービス継続できる仕組みの導入 等

AIIエージェント 

- 自律判断によるトレース困難さ
- 外部不正リソースの利用…

✓ 各コンポーネント毎の通信（入力・出力）をリアルタイムに検査し、インシデントの発生および発生個所を即座に検知する仕組みの導入

✓ インシデントの原因となったコンポーネントのみに対して停止/切り離しを行い、サービス継続への影響を最小限に抑える仕組みの導入 等

2-3. 関連する要素

AIにおけるインシデントレスポンス態勢構築にあたって、組織における対策の実施に加えて、**組織をまたいだ仕組み構築も重要**

- AI時代のインシデント対応力は、個別最適の対策だけでは限界があり、**組織をまたいだ仕組みづくりが重要**
- 組織をまたいだ仕組みづくりとして有効なものとして、以下がある

SBOM for AI	AIライフサイクルに関わるサプライチェーン全体において、メタデータ、データセット、システム特性などの情報を集める仕組み。静的な部品表ではなく、AIシステムの構成変更を反映できる動的なレポジトリ運用を想定。(G7がビジョンを公開)
Cyber AI Profile	NIST SP800-53（情報システムに求められるセキュリティ管理策を示した文書）の枠組みにAI特有のリスク対策を重ね合わることを想定したもの。AIシステムにおけるセキュリティ統制の指針として期待されている。

- 官民・業界横断の協調が、復旧を加速し損害を最小化することに繋がる
- 共通の指標と監査可能な証跡を整え、**サプライチェーン全体の透明性と説明責任を高めることで、平時の準備と有事の指揮統制を両立させる**
- 上記のインシデントレスポンスにおける活用例として、**SBOM for AIとCVE等の外部情報突合でリスクの所在を可視化**し、インシデント検知や原因調査の迅速化に繋げる。また**Cyber AI Profile**で要件と手順を定め、あらゆる組織においての共通の標準として整備することで、**サプライチェーンを連鎖する影響の最小化**に繋げる

インシデントレスponsにおける各要素の活用

要素

SBOM for AI



活用例

リスクの所在の可視化 等

Cyber AI Profile




要件と手順の標準化 等

...

2-4. 想定される効果事例

AI-IRS導入により、AIシステムにおいてもインシデント箇所を具体的に検知し、早急に対応できるようになる


- ここでは、3つの想定インシデント事例（自動計画AIエージェント誤実行、ファインチューニング誤ラベル混入、RAGデータ汚染）を基に説明する



3-1. AIインシデントレスポンスの未来予想

AI-IRSはSBOM for AI、CVE解析、分散トレース等でライフサイクルを観測・制御し、異常の検知・封じ込め・復旧を自律化

[AIインシデントレスポンスシステムの未来予想イメージ図]



AIシステムとAI-IRSが連携して常時インシデントレスポンス態勢を自動で運用・対応・改善していくプラットフォームの整備

(a) 封じ込め手段の登録・準備

AIシステム開発時には、開発環境からAIの構成来歴に関するデータがAI-IRSに送られる。また、AIランタイムで実施可能な封じ込め手段の登録が行われる。

(b) 検知・分析

AI-IRS側にはAIシステムの構成情報や外部情報（脆弱性情報 等）が統合管理されており、これらの情報とAIシステムの情報（ログ、アラート等）を突合することで異常の検知や問題個所の局所特定を行う

(c) 封じ込め

検知・分析した結果を基に、影響を最小限にする方法で局所的な封じ込め対応を実施する

予め定めておいた指標を基に処理を自動実行する従来のオートメーションと異なり、**AI-IRSの内部にもAIが活用され**、収集情報の選定や整理、外部情報との突合、インシデント兆候分析、最適な封じ込め対策の判断等を自律的に行う。運用を通じて自らPDCAを回していく**自己改善型システム（AI as an Incident Judge）として機能する**

AI-IRSへの投資は安全性への支出だけではなく、事業継続性と市場からの信頼確保を通じた長期的なビジネスチャンスに繋がる。このことは、**AI時代に組織が競争力を得るために重要な要素となる**また、AI-IRSを組織をまたいだ共通基盤として整備・運用することで、**社会システムの安定的な継続に繋がる**

AISI

Japan AI Safety Institute