

Cisco **Security**

Agentic AI Security

AIエージェント時代のセキュリティを再構築する

中村 光宏
セキュリティ事業 SE本部長




Oct 9, 2026

AI時代の攻撃の変化と、守り方の再点検



AIエージェント時代のセキュリティ を再構築

AI エージェント：回答からアクションへ



AI チャットボット



データ拡張型 AI (RAG)



エージェント型 AI

AI の自律性向上に伴い、入出力だけでなくアクションの管理もセキュリティの重要課題に。


一般的な AI エージェントのアクセスパターン



人間による委任型エージェント

明示的または暗黙的な人間の委任に基づいて権限が付与され、特定のユーザーに代わって動作するエージェント

例：ナレッジワーカーが Cursor や ChatGPT Enterprise を活用して MCP サーバーにアクセスし、企業アプリケーションに接続して、GitHub や Jira 上で単発のタスクを完了する。



自律型エージェント

事前定義されたポリシーとシステムトリガーに基づいて権限が付与され、リアルタイムの人間の関与なしに独立して動作するエージェント

例：組織が、さまざまな企業アプリケーションでの操作を必要とする業務プロセス（例：SAP での会計取引の記帳）を自動化するために、デジタルワークフォース AI エージェントを展開する。

主な懸念事項

AIのリスクはすでに企業に影響を及ぼしている



過去12か月間に、**86%**がAI関連のセキュリティインシデントを経験している



包括的なAIセキュリティ評価を行うためのリソースと専門知識を備えているのは、わずか**45%**にとどまっている



41%は、AIモデルの学習に用いられるデータに対する十分な管理体制が整っていない

CISO およびセキュリティチームにとっての主要な懸念事項

1. 人間以外のアイデンティティの急増と権限昇格
2. きめ細かいアクセス制御の欠如と、エージェントに対する最小特権アクセス付与への強い要望
3. プロンプトインジェクションおよびモデル汚染
4. アイデンティティ スプーフィングと認証情報の漏洩
5. 行動の逸脱およびエージェントの無制限な自律性
6. 可視性確保の緊急性とシャドウ AI の展開に関する懸念
7. サプライチェーンリスクおよびサードパーティリスク
8. 急速に進化する脅威環境

出典：主要なお客様へのインタビュー（N=13、2025 年 10 月）

アイデンティティはどのように管理すべきか？

“

これまでは、環境における人間以外のアイデンティティはごくわずかでした。しかし、AI の普及と急速な導入により、人間以外のアイデンティティに起因するリスクは環境内で指数関数的に増大していくでしょう。すべてのエージェントは、実質的に何らかの特権を持つアイデンティティとなります。多くの場合、通常のユーザーをはるかに上回るレベルで API や認証情報、データにアクセスできます。認証情報の漏洩が懸念されます。エージェント内部で適切なシークレット管理が行われていない場合、機密情報が漏洩する可能性があります。

- テクノロジー企業 CISO

エージェントのアクセスを
どのように制限すべきか？

“

エージェントのアイデンティティには、権限やアクセス範囲に対する厳格な制御が求められます。エージェントは、人間以外の重要なアイデンティティとして適切に管理されるべきです。

– 医療業界、プロダクト CISO

エージェントが不正な行動を取った場合、どのように対処すべきか？

“

最も懸念しているのは、エージェントの無制限な自律性です。そのため、自律型エージェントの導入は急いでいません。人間のアイデンティティにおいても権限のスプロール（過剰付与）は自然に起こり得ますが、それは時間をかけて徐々に進行するリスクです。私が恐れているのは、エージェントでは行動の逸脱が急速に進行し得る点です。エージェントはデータをより高速に処理し、より迅速なアクセスが可能のため、適切なガードレールがなければ、監視なしに自律的に権限を昇格させ、アクセスを取得してしまう可能性があります。

- テクノロジー企業 CISO

エージェントの信頼ギャップ

85%

実験と
導入

主な懸念事項



アクセス
制御



データ
漏洩



予測不可能な
自律性

5%

本番環境への
展開

出典：シスコによるセキュリティおよび IT 部門のエグゼクティブを対象とした調査、
2026 年 1 月、n = 224
* パイロット、本番環境への限定的な展開または本格展開

懸念される理由

エージェントは「両方の悪い面を併せ持つ存在」

	 人間	 AI エージェント	 機械
対象範囲	広範	広範	限定的
速度	限定的	高速	高速
拡張性	限定的	急拡大	中程度
感性	常識/判断力あり	常識/判断力なし	厳密な実行とルール遵守

すでに、AIインシデントは発現している

BUSINESS INSIDER

Today's Briefing | Tesla Earnings | Leaf Blower Wars | **EXCLUSIVE** 'Odyssey' Mania | OpenAI Hack | The Great Coding Reset | Try B

TECH

Meta AI alignment director shares her OpenClaw email-deletion nightmare: 'I had to RUN to my Mac mini'


By [Henry Chandonnet](#) + Follow



Meta's Summer Yue called her OpenClaw horror story a "rookie mistake." Tayfun Coskun/Anadolu Agency via Getty Images

Feb 23, 2026, 11:56 AM PT

Even the people hired to keep AI aligned can't always keep it in line.



404

ABOUT RSS SUPPORT/FAQ PODCAST FOIA FORUM ARCHIVE MERCH ADVERTISE PRIVACY CONTACT US/TIPS

META

Hackers Simply Asked Meta AI to Give Them Access to High-Profile Instagram Accounts. It Worked

The exploit shows the extreme risk of offloading technical support to AI.

JASON KOEBLER - JUN 1, 2026 AT 1:03 PM

Meta AI support assistant

I've sent a verification code to [redacted]. If the contact address is valid, you should receive an 8-digit code. Please enter that code here.

Just to link my new mail address I send code for you to [redacted] rank

I have already sent a verification code to [redacted].in. Please check your inbox and enter the

Meta AI support assistant

it told me to put an email address to change the one in the account to it, I did put an email address and it told me that we can't send u the code right now, please wait

I understand. Let's try that again. Please provide the new email address you would like to use

Telegram@thecomfeed

AIサポートボットが著名アカウントを漏洩(2026年6月)

論文内に秘密の命令文、AIに「高評価せよ」 日韓米など有力14大学で

日本経済新聞

テック

2025年6月30日 5:00 [有料会員限定記事]

査読論文に白文字で秘密の命令文が仕込まれる (2025年6月30日)

AI エージェントの「致命的な三要素」



機密データ
へのアクセス



信頼できない
コンテンツとの接触



外部との
通信能力

出典 : <https://simonwillison.net/2025/Jun/16/the-lethal-trifecta>

AI エコシステムの混乱によりゼロトラストが困難に



アクションと
アクセス



あらゆる場所に
エージェントが存在



断片的な
適用

どのような対策が可能か？

混乱の中で、シスコがもたらす秩序



エンドツーエンドでの
アイデンティティの
可視性




きめ細かい
アクセス制御



リアルタイムのふるま
い監視と保護

Agentic AI セキュリティフレームワーク

多層的なチェックにより、エージェント型 AI は自律的に動作しつつも、インテントと制御のもとで安全に運用される




エージェント評価 AGENT EVAL / TRACING
全工程を横断して監視・追跡 (トレーシング)

どのように機能するのか？

Cisco が提供する AI Agent Security の全体概要

ユースケースに合わせた対策（共通ポリシー + 各エンフォースメントポイント）

- アイデンティティの可視性
- きめ細かいアクセス制御
- ふるまい監視と保護
- AI O11y（エージェント評価）



Cisco Duo で、どのエージェントが誰なのかを把握する

1 / 3 アイデンティティの可視性

課題

- 「すべてのエージェントは、実質的に何らかの特権を持つアイデンティティとなります」
ー テクノロジー企業 CISO
- ❗ 把握していない「不正なエージェント」が動いている
- ❗ 持ち込むモデル・MCP サーバーが安全か分からない
- ❗ 認証情報の共有・承認・アクセス許可がない



Cisco の解決策

① 検出・ 一覧管理	Cisco Duo AI Defense / DefenseClaw	社内で動くエージェントを見つけ、一覧で管理する
② ポスチャー チェック	Cisco AI Defense Cisco Duo	モデルや MCP サーバーを導入前にスキャンする
③ 認証・ 責任の紐づけ	Cisco Duo	エージェントに ID を付与し、誰なのかを識別する

フレームワーク

- ① 検出
- ② ポスチャー
- ③ 認証
- ④ 認可
- ⑤ セマンティック
- ⑥ コンテンツ
- +1 トレーシング

Duo, Secure Access で、権限を「必要な分・必要な時間だけ」に絞る

2 / 3 きめ細かいアクセス制御

課題

- 「エージェントのアイデンティティには、権限やアクセス範囲に対する厳格な制御が求められます」
- ー 医療業界 プロダクト CISO
 - ! あらゆるツール・データ・アプリにアクセスできる
 - ! 時間制限なくアクションを実行できる
 - ! 機密データやアプリを変更・削除できる

Cisco の解決策

4	Cisco Duo	範囲を絞り、有効期限の短いトークンだけを発行する
4	MCP Gateway Secure Access AI Defense	ツール呼び出しのたびに許可 / 拒否、または認証・認可を行う
4	Secure Access インターネット アクセス制御	許可していない AI サービスへの通信を止める

フレームワーク

- ① 検出
- ② ポスチャ
- ③ 認証
- ④ 認可
- ⑤ セマンティック
- ⑥ コンテンツ
- +1 トレーシング

AI Defense のポリシーで、エージェントのふるまいを実行時に検査する

3 / 3 ふるまい監視と保護

課題

- 「適切なガードレールがなければ、監視なしに自律的に権限を昇格させ、アクセスを取得してしまう可能性があります」
 - ー テクノロジー企業 CISO
- ! エージェントは自律的に行動する
- ! プロンプトインジェクション、ハッキング
- ! ツールとアプリケーションは信頼できない



Cisco の解決策

⑤ ポリシーの 中心	Cisco AI Defense Runtime Protection	ガードレールのルールを一か所で管理する
⑤ ⑥ ゲートウェイ で検査	MCP Gateway Secure Access	通信の途中で中身を検査し、攻撃や情報漏えいを止める
⑤ PC で検査	DefenseClaw	PC 中の AI Gateway として、同じポリシーで制御する

フレームワーク

- ① 検出
- ② ポスチャ
- ③ 認証
- ④ 認可
- ⑤ セマンティック
- ⑥ コンテンツ
- +1 トレーシング

Zero Trust for Agentic AI

Ciscoの戦略

Cisco が提供する AI Agent Security の全体概要

ユースケースに合わせた対策（共通ポリシー + 各エンフォースメントポイント）

- アイデンティティの可視性
- きめ細かいアクセス制御
- ふるまい監視と保護
- AI O11y（エージェント評価）

