

フロンティアAIとセキュリティ

—— 情報システム部門に求められるもの



株式会社MU2
小牟禮 智之

本日の到達点：守りの前提を構造的に整える

AI製品の選定以上に「自社の文脈を整える力」が、これからの情シスの活路となる



AIとセキュリティの現在地

- Claude Mythos が示した能力水準は、
やがて誰の手にも渡り、
サイバー攻撃の連鎖を加速させる
- 一部の業種や技術部門のみの問題ではなく、
全業種の守りの前提を書き換える問題



本日の到達点：守りの前提を構造的に整える

- × 重要なのは「どのAI製品を導入するか」ではない
- 問われているのは、AIを安全に機能させ、
攻撃に対して強靱であるために、
自社の文脈（資産・業務等）を整えられるか

「自社の文脈を整備する力」がいかに
情シスの活路となるか

診断・第一の枠組み：立場で異なる三つの変化

利用者・情シス・攻撃者の各立場が異なる速度で変化し、相互干渉により複雑なリスクを形成しています。

利用者（従業員）	管理外のAI利用の広がりによる可視性の低下とシャドーITの深刻化
情報システム部門 (SOC含む)	AIによる防御活用の高度化が進む一方、人手による対応速度が構造的な限界に達している
攻撃者	公開モデルの入手による悪用までの時間短縮と、誰でも高度な攻撃が可能な環境の変化

各立場は異なる速度で変化しており、それぞれが相互に干渉することで複雑なリスクを形成している。

診断・第二の枠組み：各立場における未解決の問い

新たな脅威（AIエージェントの限界、短命なAI生成物、自律型ランサムウェア）が現在のセキュリティ枠組みを揺るがしている。

現在の枠組み	最前線に現れる新たな脅威と課題（未解決の問い）
利用者 人が直接システムを操作し、リテラシー研修等で防御	利用者 AIエージェントへの業務委託の拡大 そのAIは巧妙ななりすましやフィッシングを見抜けるのか
情報システム部門 明確な境界や管理下の資産を保護対象とする	情報システム部門 「守るべき資産」の再定義が必要 短時間で生成・消滅するAI生成物やフォースパーティへの対応
攻撃者 手動やスクリプト主体の攻撃キャンペーンを展開	攻撃者 新たな攻撃手法の確立と高度化 自律的に動くAIランサムウェアの出現とその脅威の拡大

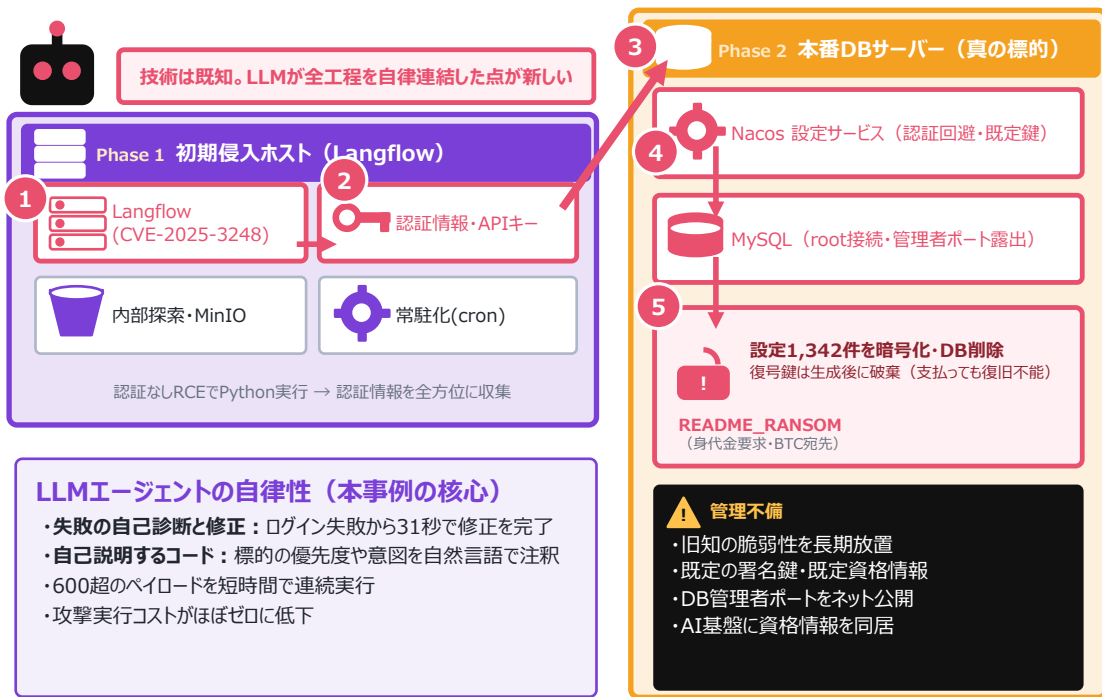
三つに共通する構造：境界の崩落

守りの前提としていた境界が無効化され、攻撃者が最速で動き、利用者が管理不能となる構造的非対称性が生じている。



攻撃の実例：自律型AIエージェントによる全自動ランサムウェア攻撃

JADEPUFFER：LLMが単独で侵入から破壊・恐喝までを実行した初の「エージェント型ランサムウェア」（Sysdig TRT報告・2026年）



LLMエージェントの自律性（本事例の核心）

- 失敗の自己診断と修正：ログイン失敗から31秒で修正を完了
- 自己説明するコード：標的の優先度や意図を自然言語で注釈
- 600超のペイロードを短時間で連続実行
- 攻撃実行コストがほぼゼロに低下

事件の概要

対象

インターネットに露出したLangflow（AI開発基盤）と、その先の本番DBサーバー（Nacos/MySQL）を運用する組織

発生日事象

LLMエージェントがLangflowの認証なしRCE（CVE-2025-3248）で侵入。認証情報を収集し、真の標的である本番DBヘビボット。Nacosを乗っ取りMySQLへroot接続し、破壊と恐喝を全自動で実行した。

被害

Nacos設定1,342件を暗号化しDBを削除。復号鍵は破壊され、支払っても復旧不能。人手を介さず全工程が自動化。

攻撃経路

- 1 認証なしRCEでLangflowへ侵入
- 2 認証情報・APIキーを収集
- 3 本番DBサーバーヘビボット
- 4 Nacos乗っ取り・MySQL root接続
- 5 設定暗号化・DB削除・恐喝

有効な対策

- Langflow等の脆弱性の即時修正・非公開化
- AI基盤に資格情報を同居させない
- Nacosの既定署名鍵・既定資格情報の変更
- DB管理者ポートの非公開化・IP制限
- 下り通信制御と実行時脅威検知


経営論点：ランサムウェアは高度な技術者の技ではなくなった。旧知の脆弱性を放置した公開資産は、AIエージェントにより自動的かつ低コストで攻撃される。

防御の目標：攻撃を割に合わなくする

完璧な防御から「コスト最適化」へと転換し、攻撃側の手間・費用と利得のバランスを崩す。

完璧な防御から「コスト最適化」へ

攻撃側の手間と費用を、得られる利得に見合わない水準まで引き上げる



攻撃側のコストを上げる ▲

- ・多要素認証（フィッシング耐性MFA）
- ・ネットワーク分離
- ・継続的な監視 等

得られる利得を下げる ▼

- ・データ暗号化
- ・改ざん不能なバックアップ
- ・データ最小化 等

打ち手の地図：三層による防御の徹底

侵害を前提とした防御の重心移動が重要です。最前線の攻撃を防ぐのは、Keep, Stay, Recoverの三層による基本の徹底です。

1. Keep Clean (入口で入れない)

調達・委託・開発の段階でゲートを設ける

2. Stay Clean (入れた後の継続点検)


資産・脆弱性・権限・ログを絶えず監視する

3. Recover Clean (侵害を前提に戻せる状態へ)

封じ込めアクションと復旧手順の検証・訓練を徹底する

文脈整備力：すべての実務の土台

散在する資産や脆弱性のデータを一つに結びつける文脈整備力が、平時のAI活用や有事の意思決定を支える代替不可能な基盤となります。



買えず・外注できず・一年で作れない。早急な着手が必要。

運用指標の問い直し：成否を測る物差しを変える

従来の形式的なセキュリティ運用から、AI時代の「侵害前提の強靱性」を測る実践的な指標へ転換が必要です。

時間軸で勝てない以上、指標そのものを「侵害前提の強靱性」を測るものへと入れ替える

従来の問い

脆弱性管理

どれを直すか

EDR・XDR

何件検知したか

バック
アップ

取得しているか

委託先

年次回答したか

AI時代の問い（侵害前提の強靱性）

攻撃可能な時間をどれだけ減らしたか


どれだけ早く隔離・封じ込められるか

改ざん不能で、許容時間内に適切な状態まで戻せるか

AI利用・復旧手順まで見えているか

ゼロトラストの更新：1.0から2.0へ

1.0を作り切る過程で、目標地点が2.0へ動いている。時代に即した守りを実現するため、AI・API等の対象拡張と判断・実行の制御を設計に織り込む必要がある。




目標地点の書き換え

1.0を作り切る過程で、目標地点が2.0へ動いていることを理解せねばならない。
時代に即した守りを実現するためには、この拡張を設計に織り込む必要がある。

まとめ：AI時代の守りの正体

守りの前提が崩壊する中、防御側の地の利を活かし「文脈整備力」を磨くことこそが情シスの活路です。



ご清聴ありがとうございました



株式会社MU2
小牟禮 智之（こむれ ともゆき）

WEB : <https://mu2.co.jp/>
MAIL : tkomure@mu2.co.jp