

管理外の脅威「野良AIエージェント」：自律性の暴走を抑える組織の鉄則

IDなし・責任者なし・実行なし



「野良（シャドー）」とは統制外の状態
未承認、責任者不在、過剰権限、ログ欠落など、組織
のガバナンスから逸脱したエージェントを指す。



リスクの核心は「自律性×権限」
モデルの踏等が、DD操作や外部通信
などの「実行権限」と結びつくことで、
被害が直接的かつ不可逆になる。



プロンプトインジェクション
発生メカニズム: 外部データを
命令と誤認しツールを悪用



プライバシー・機密漏洩
発生メカニズム: 正規権限で
機密を読み、攻撃者へ送信



AI自動化サイバー攻撃
発生メカニズム: 偵察・脆弱
性探索・攻撃の連続処理

顕在化する深刻な被害シナリオ
Replitでの本番DB削除や、国家
支援型アクターによるAI自動化
サイバー攻撃、機密情報の外部
流出が既に発生している。



防衛の鉄則「IDなし・責任者なし・実行なし」

