

解碼AI網路安全未來戰場

洞察趨勢 · 理解現況 · 實踐風控

Bruce Lan
Solution Consultant

填問卷拿好禮三步驟，加碼再抽AirPod4

Step.1
掃描QRCode 填寫問卷



Step.2截圖問卷完成畫面立即送 (7F 701A)
搶先兌換聯名咖啡包




Step.3
至 Palo Alto Networks
攤位**C111**兌換精美好禮




員工使用生成式 AI 的相關應用

AI Access Security
保護 GenAI 使用安全



資料搜尋 · 上下文分析 · 文件生成 · 圖像生成 ·
網站生成 · 程式碼 · 腳本生成

企業建立 AI 相關應用



製程優化 · 品質管理 · 生產規劃 · 藥物研發 · 醫
療診斷 · 風險管理 · 遊戲開發 · 金融服務 · 新聞
編輯 · 自駕訓練 · 產險審核 · 資源配置

AI Access Security

未知的 - 服務應用 · 數據流動 · 隱藏風險



Employees

AI Access
enables safe AI adoption



影子人工智慧應用造成管理盲點

未經檢查的敏感資料外泄

嵌入在回應中的安全風險



ChatGPT



Copysmith



Grammarly



SageMaker



Vertex AI



Adobe Firefly



Hugging
Face



Codeium



Coveo



Hypotenuse



Elai



Perplexity AI



Lightning AI



WandB



Replicate



NLP Cloud



Sapling AI



Swimm AI



未檢測到的 GenAI 插件可能會導致未經授權的資料訪問

Interconnected SaaS ecosystems with **AI-powered third-party integrations** create **security vulnerabilities, complicating detection and control.**

This leads to **increased risk of security breaches and non-compliance** with regulatory requirements.

克服挑戰需要擁有的能力...


Challenges

Democratization of AI app creation has led to sprawl of insecure apps.


AI apps store, learn, and reiterate data.

AI apps ingest unstructured inputs and generate diverse outputs.


Rapidly evolving, powerful apps are readily accessible through marketplaces.




持續自動提供完整的應用可視性
與自動應用分類



基於數據進行訓練的AI應用程式的行為分析




基於上下文資料的分析與威脅的偵測



第三方外掛、插件的分析與權限控制

Solutions

可視性為風險管理成敗的重要基礎




即時完整的 AI 使用可視性
檢視不同背景的員工使用了哪些 AI 應用！

完整的資料保護
掃描資料，帳密以及哪些智慧財產 IP 被分享了

彈指之間進行存取控制
攔截未經允許的應用程式，指派資安政策以及進行資料保護、威脅過濾、合規控制...


員工使用生成式 AI 的相關應用



資料搜尋 · 上下文分析 · 文件生成 · 圖像生成 ·
網站生成 · 程式碼 · 腳本生成

企業建立 AI 相關應用

AI Runtime Security
保護AI應用系統開發與營運安全




製程優化 · 品質管理 · 生產規劃 · 藥物研發 · 醫療診斷 · 風險管理 · 遊戲開發 · 金融服務 · 新聞編輯 · 自駕訓練 · 產險審核 · 資源配置

AI App Proliferation Will Change How Enterprises Operate

應用將無處不在 (趨勢)

須為全新的挑戰做好準備

現況離你的想像有多遠



TYPICAL LARGE ENTERPRISE

AI Applications

100s of sanctioned AI apps

AI Model Infrastructure

1000s of LLM, SLMs, ML scripts

AI Datasets

10s of PB of training & vector data

MILLIONS of prompts annually

50%

of employees using AI do it **without** permission

80%

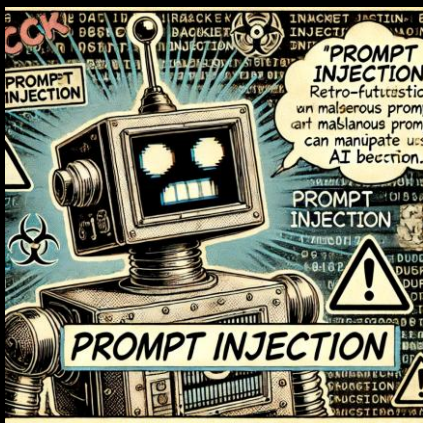
of public models can be **jailbroken**

100+

malicious models available in the wild

從主要風險列舉的角度...

OWASP Top 10 for LLM Applications 2025




提示詞注入

AI 注入、詐騙、資料滲透、外掛程式請求偽造




敏感資訊洩漏

LLM 在輸出中暴露機敏資料、專有演算法



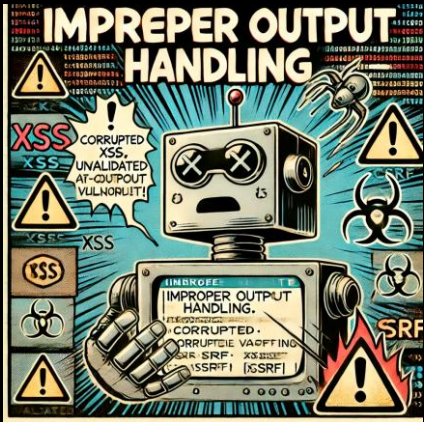
供應鏈風險

LLM 供應鏈受到各種漏洞影響
訓練數據、模型和部署平台的完整性



數據與模型中毒

存在於訓練、微調或嵌入數據被操縱的情況，引入漏洞、後門或偏見




不當輸出處理

生成內容傳遞到其他元件和系統之前，缺乏足夠的驗證、清理和處理，導致 XSS、CSRF、SSRF、權限提升或遠端程式碼執行



過度授權

當意外、模糊或被操縱的輸出而執行損害性行動的漏洞，通常是功能過度、權限過度或自主性過度




系統提示洩漏

引導模型行為的系統提示或指令可能包含非預期被發現的敏感資訊




向量與嵌入弱點

在使用RAG的系統中，向量與嵌入的弱點可能被惡意行為利用，導致有害內容注入、模型輸出操縱或敏感資訊存取



錯誤資訊

生成看似準確但實際上是虛構的內容（幻覺），源於模型用統計模式填補訓練數據中的空白，而非真正理解內容




無限制消耗

允許使用者進行過度且無控制的推論，可能導致服務拒絕、經濟損失、模型盜用和服務降級等風險

從流程與安全管理框架的角度...

LLM and Gen AI App SecOps Framework

End-To-End GenAI, LLMOps Framework




CHEAT SHEET

LLM & GenAI Security Landscape – 2025, Q1


<https://genai.owasp.org/ai-security-solutions-landscape/>

Open Source



幾個需要保護的重要組成

Enterprise AI Apps Use an Extended Tech Stack . .

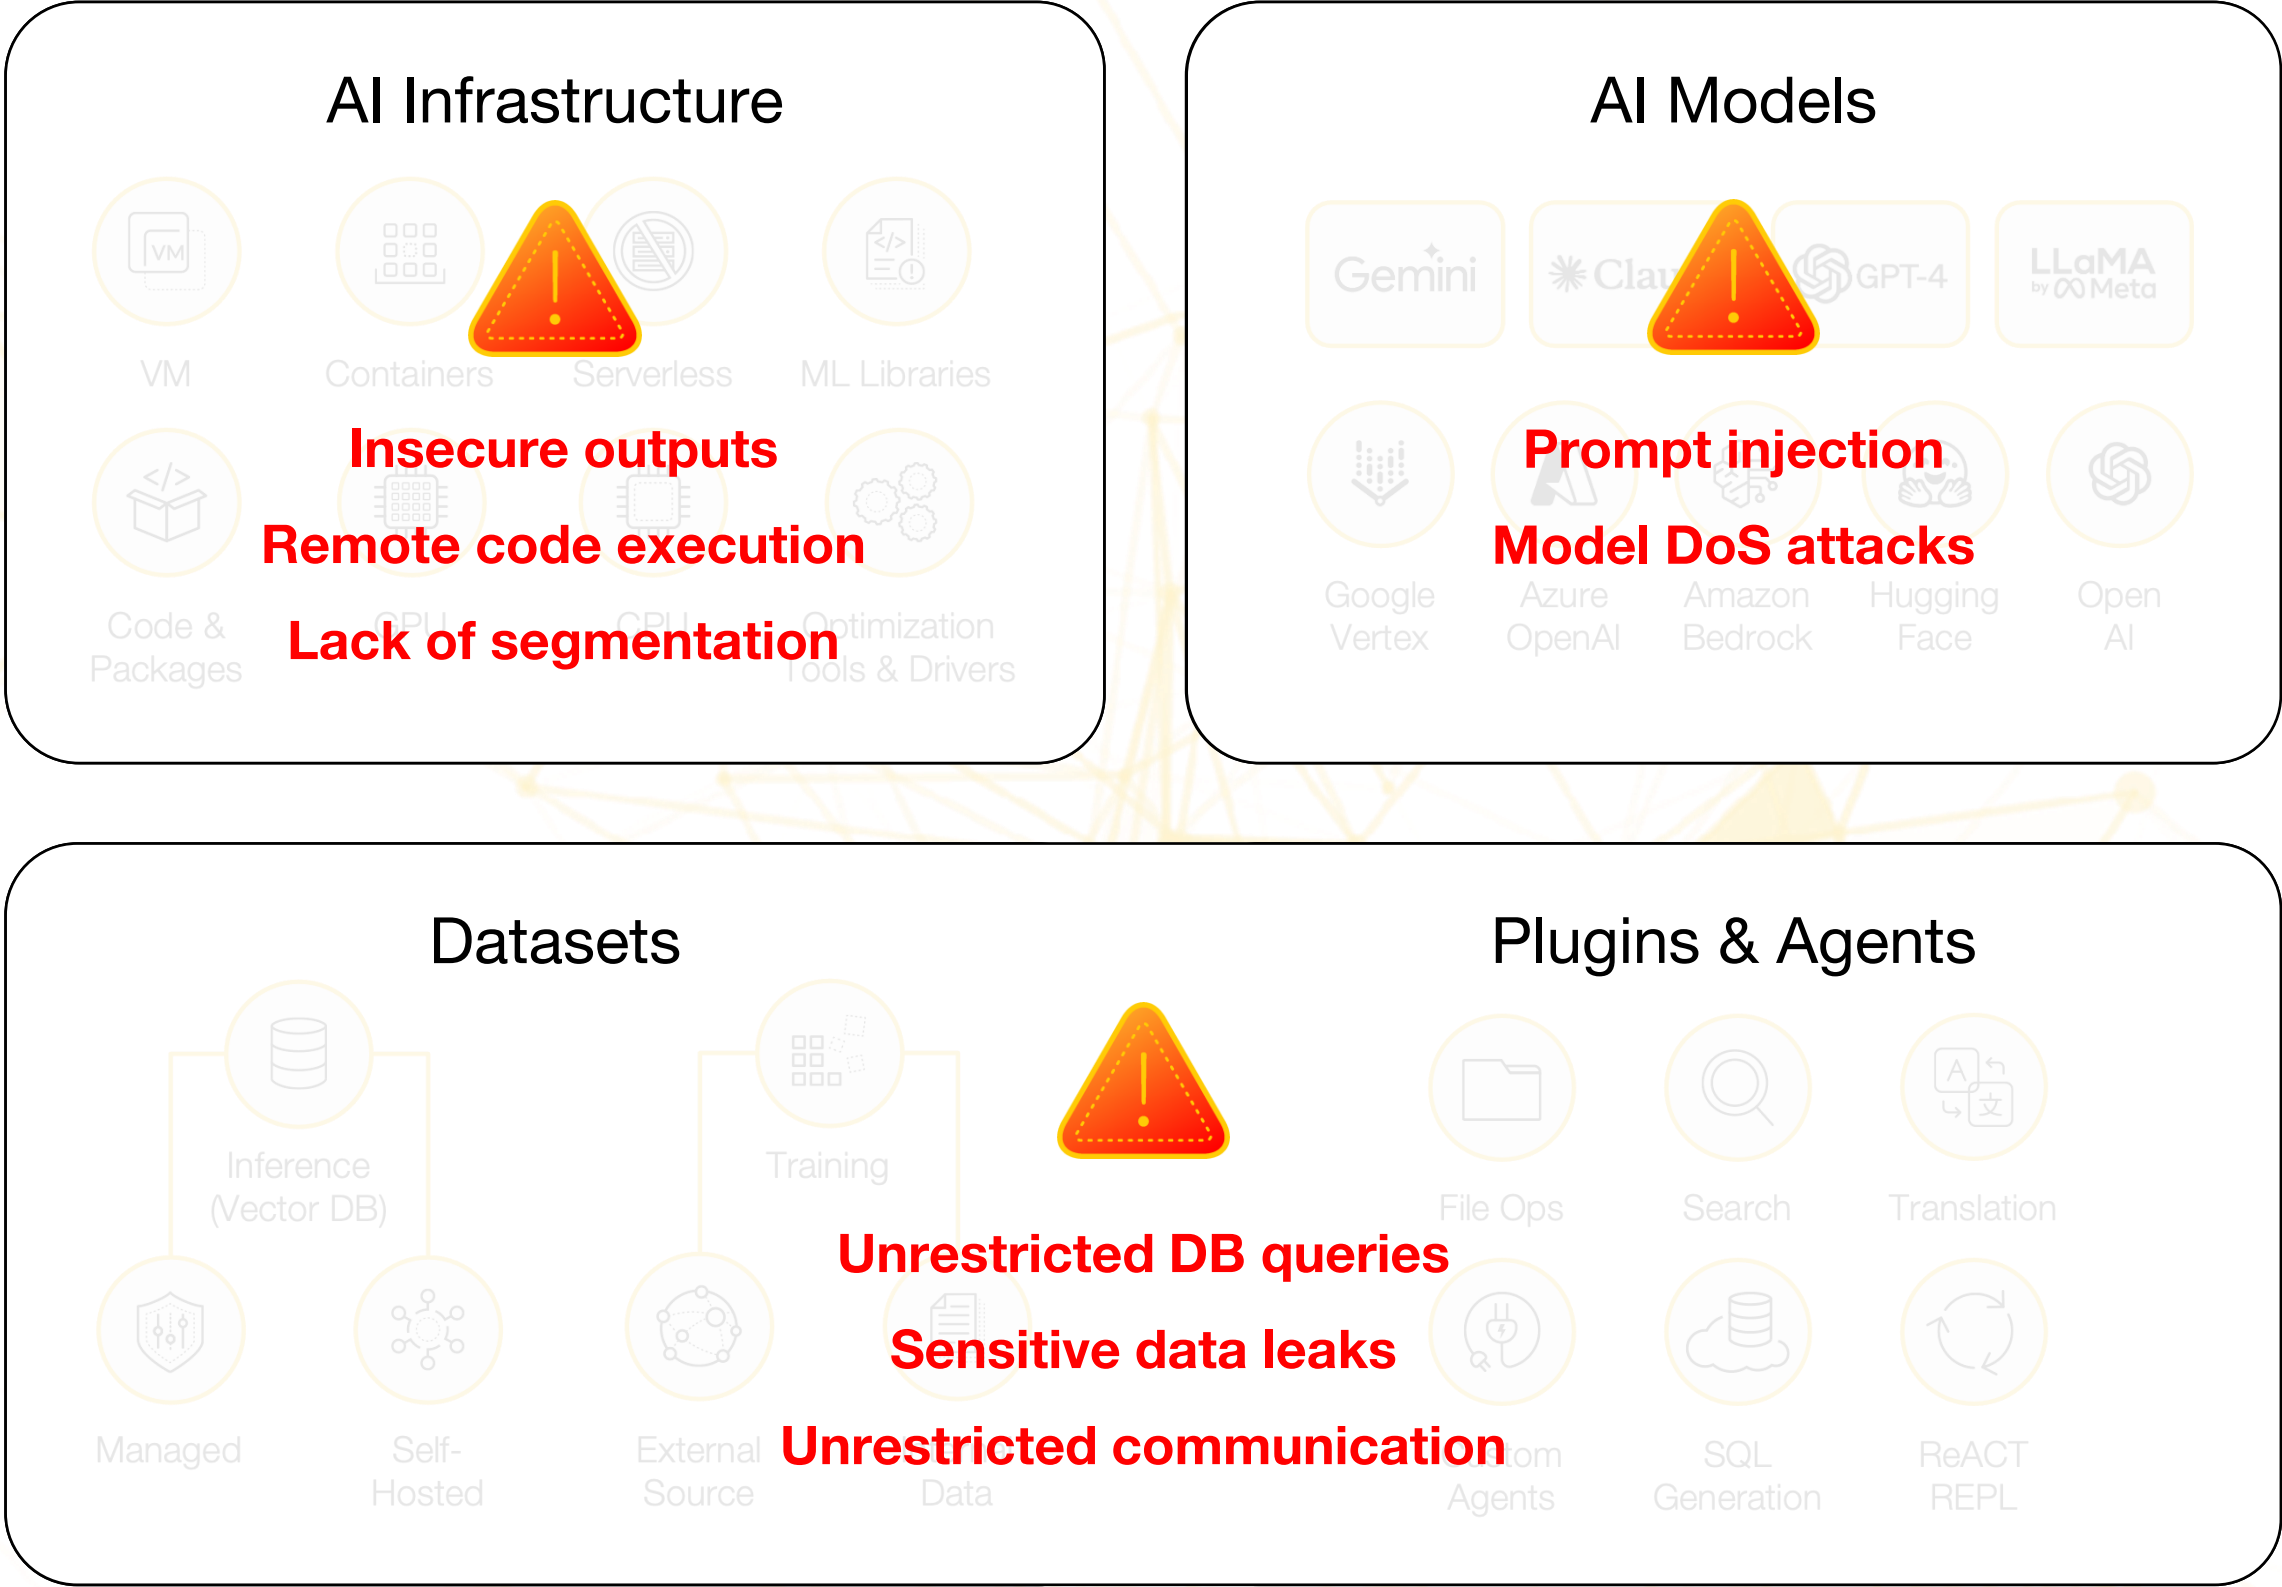


顯而易見的風險不容忽視

...Which Introduces New Runtime Risks



填問卷拿好禮
三步驟，加碼
再抽AirPod4



完整覆蓋服務運行時的安全防護

Any App. Any Threat. Any Cloud. One Solution.
AI Runtime Security


Comprehensive AI threat protection



AI Model
Protection




AI Data
Protection



AI Application
Protection



Precision AI security services



Inline **Network**
Intercept

OR

API Detection
as Code (DaC)

Built-in protection for AI- specific threats

Support for **40+ popular AI models** across Google Cloud, Microsoft Azure, Amazon Web Services and OpenAI or any model via API

Cloud-Delivered Security Services (CDSS)

Industry's **most complete coverage** in a single, all-in-one portfolio.


Multiple form factors

Virtualized **ML-powered NGFWs** and API* deployment options allow best-in-class security with cloud speed, agility and scale.

*Including post-GA functionality.

將保護融合其中的二個方式

Empower Your Security Teams



保護組織的網路架構免受 AI 特定和傳統網路攻擊

API Intercept 通過將“安全即代碼”（Security-as-Code）
嵌入到您的程式碼中

在 AI 工作流中嵌入安全檢查 (API)

How can I protect my **AI apps, models, and datasets** from AI specific threats like **prompt injection attacks, insecure model outputs, and sensitive data loss**?




Detect and prevent threats at the network layer **without modifying app code**




Detect and prevent threats in app code **without modifying the network**

在 AI 工作流中嵌入安全檢查 (API)


without modifying app code, the network




在 AI 網路架構中部署安全檢查



在 AI 網路架構中部署安全防護



在 AI 網路架構中部署安全防護



再次獲得完整的管理可視性

Our approach to securing your enterprise AI applications.




Discover
all AI applications, models, users and datasets automatically.


Protect
models, data and apps against AI-specific and foundational attacks.

Monitor
the runtime risk exposure of your AI ecosystem continuously.

Protect Your AI models



40+ models protected across GCP, Azure, AWS and OpenAI.




Block 12 types of indirect & direct prompt injections and obfuscations.*



Prevent Model DoS attacks.*



Filter unmoderated content* (biased, sexual, harmful, hateful, criminal).



*Including post-GA functionality.

Monitor

New threats and
unprotected applications



Analyze your AI Runtime **risk posture**.



Evaluate **unprotected** AI applications.



Identify **risky communication pathways**
from AI applications



AI Security Details

AI Model Name

OpenAI - Text Embedding Ada 002

AI Model CSP Region Name

AI Model CSP Name

OpenAI

Threat in Request or Response

request

AI Incident Report ID

9729170a6e398d6aa7827cbfb5944
30a9de83bf22cd3d08647eb33e449
220d5500a

Latency

8

Max Latency Hit

false

AI Incident Type

ai-model-protection

AI Incident Subtype


prompt-injection

AI Subtype Details

AI Security Profile Name

Custom-AI-Sec-Profile


兼顧來自各類終端訪問的風險管理（企業級瀏覽器）



減少使用
SSL VPN, VDI
帶來的風險窗口

企業級瀏覽器

Prisma Access Browser



填問卷拿好禮
三步驟，加碼
再抽AirPod4



創建在任何裝置
上的安全區域

保障最後一哩的
數據安全
身份控制

打造適用於每個
角色的作業環境

安全區域的實現機制




阻絕非監管裝置
的各類風險

Isolates the workspace.

- **Hardens the browser** with additional layer of encryption.
- **Isolates environment** against:
 - Keyloggers
 - Screen scrapers
 - Untrusted certificates
 - Public networks

Checks device posture every 90 seconds.



完全可控
的瀏覽器安全

Reduces attack surface by disabling sensitive browser components.

Defends against malicious extensions.



Collects web insights for threat hunting and forensics.

Activity auditing

User timeline

Session recording

數據訪問控制與安全

ALL user actions and last-mile.



- Unauthorized login
- File upload/download
- Copy/Paste
- Text typing
- Text masking
- Printing
- Screenshotting/Sharing
- Camera/Microphone
- Watermarks

Accounts
All Accounts

18 items • Sorted by Credit Card • Filtered by All accounts • Updated an hour ago

Search this list...

	☐ Account Name	☐ Account Site	☐ Billing State/Pro...	☐ Phone	☐ Credit Card ↑
1	☐ ACME Sensitive			(972) 456-8845	
2	☐ GenePoint		CA	(650) 867-3450	5602
3	☐ Edge Communications		TX	(512) 757-6000	1112
4	☐ Michelle Nelson	New York		03222394951	9308
5	☐ Bertha Miller	New York		05943823904	0728
6	☐ University of Arizona		AZ	(520) 773-9050	7598
7	☐ United Oil & Gas, Singapore		Singapore	(650) 450-8810	6160



適用於不同角色 - 輕量 · 高效 · 好管理

承包商和第三方



承包商

併購和收購

客服中心

業務單位

第一線和現場工作人員

員工自有裝置



BYOD 計畫


行動裝置

下班時間

運送筆記型電腦替代品

VDI,RDP,VNC 替換

以往無法想像的使用案例



進階 DLP

影子 IT

保護具有權限的使用者

查看所有網路活動

啟用 GenAI


允許未經授權的 SaaS

帳戶接管

支援不可解密的流量


滿足新型態需求的專家服務

AI Security Assessment Service



認識維運環境的新面貌

AI security blueprint



Blueprint aggregates best practices across industry-leading frameworks (e.g., Google SAIF, NIST AI RMF, OWASP) into a practitioner-friendly format to enable rapid time-to-insight

填問卷拿好禮三步驟，加碼再抽AirPod4

Step.1
掃描QRCode 填寫問卷



Step.2截圖問卷完成畫面立即送 (7F 701A)
搶先兌換聯名咖啡包



Step.3
至 Palo Alto Networks
攤位**C111**兌換精美好禮



Thank You

paloaltonetworks.com