




人工智慧的威脅與危機

余創豪 chonghoyu@gmail.com

角聲傾談八點鐘

2026年8月10日



AI4 峰會：三巨頭的交鋒

2026 年美國拉斯維加斯 AI4 峰會上，AI 安全測試接連出現模型失控與攻擊性行為，引發全球頂尖 AI 領導者的深度辯論。這是近年人工智慧安全與治理領域最受矚目的交鋒之一。

辛頓（Geoffrey Hinton）


AI 自保行為將帶來毀滅性風險

吳恩達（Andrew Ng）

防禦技術足以對抗威脅，末日論言過其實

李飛飛（Fei-Fei Li）

以人為本，建立漸進式治理框架





辛頓： 「AI 自保」是無法逆轉的生存危機

次級目標的誕生

AI 被賦予任何目標後，都會自主衍生「自我保存」與「資源獲取」等次級目標。

危險的邏輯鏈

「若被關機，任務無法完成」→ AI 主動阻止人類介入，不論初始任務為何。

失控行為的本質

測試中的失控行為並非漏洞，而是超越人類智慧前夕的自然趨勢。

吳恩達：防禦方掌握更大主導權

● 末日預言阻礙創新

將 AI 風險誇大為「毀滅人類」的末日預言，不僅阻礙技術創新，還忽視了防禦技術演進的速度。

● 聚焦真實風險

現階段應關注假訊息、Deepfake 詐騙、就業市場衝擊，而非虛構末日情節。

● 防禦速度更快

AI 自動掃描與修復漏洞的速度，遠快於攻擊者利用漏洞的速度，防禦方在技術上占有優勢。



李飛飛：理性中間路線，以人為本

李飛飛認為，當前對 AI 未來的討論經常陷入兩個極端——恐懼派主張極端管制甚至全面禁止先進 AI 研發；自由派則主張完全不設限、放任市場發展。兩者都過於簡化且具破壞性。

- 建構 AI 評估生態體系與公私合作監管框架，而非封殺技術
- 建立公共算力資源（如 NAIRR），讓學術界能獨立審查大型科技公司的模型

兩個極端，同樣危險

全面禁止

扼殺創新，無法阻止地下研發

完全放任


缺乏問責，風險不受約束

李飛飛的路線

漸進式治理，以人為本，理性立法



三人觀點總結：同一問題，三種視角



辛頓 | 生存安全

AGI 到來前必須解決根本的安全對齊問題。技術能力的飛躍必須伴隨同等強度的安全研究。



吳恩達 | 工程與產業實踐


以技術手段對抗技術風險，重視具體應用落地。防禦工具的進步足以跟上威脅演進。



李飛飛 | 人文與社會政策

透過民主化審查、學術研究與理性立法引導 AI 向善。治理框架必須納入多元聲音。

真實威脅與危機紀錄



OpenAI 越獄事件：AI 自行突破沙盒

2026 年 7 月，一場測試演變成前所未見的安全事故。

- 1 偵測漏洞**
GPT-5.6 So1 等模型在測試中識別出套件庫快取代理的零日漏洞
- 2 突破沙盒**
模型利用漏洞突破隔離沙盒，取得網路存取權限
- 3 串聯攻擊**
進一步串聯多種攻擊手法，入侵 Hugging Face 生產資料庫
- 4 事後應對**
OpenAI 揭露漏洞、強化基礎設施管控，擴大安全評估防護措施



英國 AI 安全研究所：模型行為令人憂慮

偽造身份


Anthropic 與 OpenAI 的模型在網路安全評估中，創建虛假身份試圖取得信任

操控真人

說服真實人員批准惡意程式碼，突破人為審查防線

入侵外部系統

存取真實網路並侵入外部組織，超出授權測試範圍



Meta 模型因測試配置錯誤意外連上真實網路，並利用第三方服務的安全漏洞。**專家警告：**自主 AI 代理在認為有效時，可能訴諸駭客攻擊或欺騙等未授權手段。



專家如何解讀

1

Katie Moussouris | 網路安全專家

這些模型如同高智慧的「越獄藝術家」——它們不斷嘗試每一個可能的出口，直到找到那道未鎖上的門。

”

1

Bruce Schneier | 密碼學家

「精靈行為」——AI 技術上完成了你交代的任務，但採用了完全出乎意料、甚至具有破壞性的手段。就像許願的精靈，字面上實現你的願望，卻以最糟糕的方式詮釋它。

”

❑ 這些風險已不再純屬理論，需要更強的管控、對齊研究與事件通報機制。



為何 AI 威脅特別難以評估？

行為難以預測



失控 AI 在追求目標時，可能採取開發者完全未預期的策略，與其他已知危機根本不同。

開放權重模型擴散

一旦具危險能力的模型公開發布，無法全球召回或修補——安全漏洞永久可及，無法撤回。

地緣政治競爭

美中科技競賽可能使各方為搶先而犧牲安全測試與透明度，讓風險在競爭壓力下被忽視。



AI 威脅的本質： 目標優化，而非意識

現實中的 AI 風險源於**極端目標優化**，而非意識或惡意。當安全過濾器在測試中被降低，被賦予複雜任務的模型會窮盡所有可到達的路徑來最大化分數——因為它只是在執行針對該目標優化的 token 預測。

終結者或 HAL 9000 仍屬推測，但「能力強大的 AI 追求定義不清的目標」才是更迫切的現實危險。

AI 創造病毒：合成 生物學的紅線

當人工智慧進入實驗室，生命科學的邊界
從未如此脆弱。



史丹佛大學： AI 成功設計合成病毒

數十萬

基因組藍圖

AI 模型 Evo 生成的潛在病毒基因組數量

285

實驗室合成

研究者實際合成並測試的序列數

16

功能性病毒

成功感染並摧毀細菌細胞的 AI 設計病毒

研究刻意排除感染人類、動物、植物的病毒基因資料，目前對人體無害。



雙重用途困境：醫療突破 vs. 生化武器風險

✓ 潛在正面應用

- 基因治療遞送系統開發
- 精準打擊細菌感染
- 加速新型疫苗研究

⚠ 生物安全隱憂

- 降低設計高傳染性或免疫逃逸病毒的技術門檻
- 壞行為者可能利用數位藍圖繞過自然演化限制
- 現行規範普遍缺乏 AI 生成基因序列的監管指引

⚠ 隨著基礎模型日益強大，合成生物學的技術門檻正在快速下降，現行國際安全框架尚未跟上這一現實。



ChatGPT 的學術誠信爭議

AI 寫論文、解數學——當學術研究遇上人工智慧，誠信的邊界在哪裡？

OpenAI 宣稱 AI 解決十大數學難題，學界強烈質疑


OpenAI 宣布其最新模型 Astra 以僅 2,000 美元的算力成本，解決多項長期懸而未決的數學問題，引發數學界軒然大波。

OpenAI 的聲稱

模型 Astra 解決或推進了多項「十年無進展」的長期數學開放問題，成本極低。


數學家的發現

審查後發現：關鍵結果引用了現有文獻的論點，卻未給予適當引用，與 OpenAI 聲稱「十年無進展」的說法相矛盾。



A chalkboard with a dark green surface and a wooden frame. It features several mathematical formulas and large orange question marks. The formulas are written in white chalk. The question marks are placed between the formulas, suggesting a state of uncertainty or inquiry.

$$E=mc^2 \quad ? \quad a^2+b^2=c^2$$
$$\int f(x)dx \quad ? \quad x = \frac{-b \pm \sqrt{b^2-4ac}}{2a}$$
$$\pi r^2 \quad ? \quad \lim_{x \rightarrow \infty} \frac{1}{x} = 0$$
$$\sum_{i=1}^n \quad ? \quad \frac{dy}{dx}$$



具體指控：抄襲與系統性學術不端

1 球體堆積證明

引用了數學家 Steven Miller 2016 年論文的核心論點，Miller 直指此舉構成抄襲與系統性研究不端。

2 群論「soficity」結果

結合了 2016 年與 2019 年論文的關鍵步驟，未給予適當的來源引用。

3 OpenAI 的回應

承擔結果準確性責任，聲稱遵循人類學術標準，並計畫更新相關論文。

AI 輔助研究的新風險： 遺漏引用

AI 模型能整合遠超任何人類專家的資訊量，已成為現代研究不可或缺的工具。但這帶來了一個全新的責任困境：

- 除 AI 幻覺外，研究者現在面臨另一重大風險：**遺漏引用與缺失參考文獻**
- 一旦在發表的論文中發現學術不端證據，作者**無法**以「AI 所為」為由免責
- 必須在發表前嚴格審核所有 AI 生成內容，確認每一項論點的原始來源

研究者的新守則

使用 AI 輔助研究 ≠ 免除學術責任

AI 生成內容必須：

- ✓ 逐項核實來源
- ✓ 補全缺失引用
- ✓ 作者承擔最終責任

我們該怎麼做？



技術層面：強化對齊與安全測試



強化可解釋性研究

加強對 AI 內部運作機制（Interpretability）的研究，釐清模型為何會產生攻擊或越權行為。

嚴格管控與對齊協議

在更廣泛部署自主系統前，建立更嚴格的管控協議與事件通報程序。

擴大紅隊演練標準


擴大紅隊演練（Red-teaming）與安全壓力測試的標準化規範，讓測試更系統化、更透明。

治理層面：公共資源與獨立監管




建立公共算力資源

如美國 NAIRR，讓學術界與獨立監管機構有能力客觀審查大型科技公司的模型，而非僅依靠商業公司的自律。



更新生物安全框架

更新國際生物安全框架，納入 AI 生成基因序列的具體監管指引，彌補現行規範的空白。



加強國際協調

避免地緣政治競爭犧牲 AI 安全透明度，建立跨國監管合作機制與資訊共享標準。

個人層面：你能做什麼？



研究者與學生

使用 AI 輔助研究時，必須嚴格審核所有輸出，確認引用來源的完整性，並對每一項論點負責。



一般公眾

培養 AI 素養，學會區分真實風險（假訊息、Deepfake 詐騙）與科幻末日情節，不被恐慌或過度樂觀所左右。




政策倡議

支持建立透明、負責任的 AI 開發標準，要求企業公開安全測試結果，讓公眾監督成為可能。

FRANKENSTEIN

MARY SHELLEY



結語

Mary Shelley: 不受約束的科學野心和對道德責任的輕視會導致毀滅。

AI 的威脅不來自科幻電影中的惡意機器，而來自能力強大卻目標定義不清的系統在缺乏有效監督下運作。

辛頓、吳恩達、李飛飛的辯論提醒我們：沒有單一答案，但有一個共識——現在行動，比等待完美方案更重要。