

教師人工智能入門小冊子


第三章：AI代理與風險管理

協作 數字教育
提示詞 Copyright
教育 權限 Collaboration
Generation 權限
Assistant Computing Power 教育
Assistant 指令
代埋 權限
算力 權限
核對 權限
大綱 Data Learning
Judgement 生成式AI
RAG 生成 Judgement
AI代埋 數據 Cloud
課程 權限
AI 權限
AI Agent 權限
AI代埋 權限
Generative AI 權限
Checking 大綱
DIGITAL EDUCATION
Education 權限
指令 權限
PROPT ENGINEERING
Authorisation 版權
評估 權限
幻覺 權限
外洩 權限
私 權限
WORKFLOW 權限
Leakage 安全
RAG

究竟人工智能現今能做甚麼？



Nothing humbles you like telling your OpenClaw "confirm before acting" and watching it speedrun deleting your inbox. I couldn't stop it from my phone. I had to RUN to my Mac mini like I was defusing a bomb.



11:25 AM · Feb 23, 2026

17.5K Reply Copy link

Read 2.4K replies

來源：yahoo! 新聞

對於專門研究如何讓 AI 聽話的專家來說，最諷刺的事情莫過於被自己信任的系統「背叛」。近日，Meta 超級智能實驗室負責模型對齊 Model Alignment 的專家 Summer Yue，在社交平台 X 上分享了一段令人冷汗直流的經歷：她所使用的 AI 自動化工具 OpenClaw，在完全無視指令的情況下，差點清空了她的電子郵箱。

來源：yahoo! 新聞

為甚麼AI能控制我們的電子郵箱，甚至電腦？



第一章提到人工智能代理能自主傳送電郵

【人工智能代理 (AI Agent)：執行力高的助理】

它具備自主推論及規劃的能力，能根據目標自行決策和調整，執行複雜的任務。



掃描下方的二維碼
重溫第一章的內容




即人工智能代理能在用家的授權下操作電子郵箱。
這不代表它可以自行決定在電腦中執行任何任務。

人工智能代理 (AI Agent) 介紹

人工智能代理有別於聊天機械人，它能像真人般直接操作電腦執行任務。

聊天機械人與人工智能代理的分別：



截至2026年第一季最新人工智能代理的特點

可透過通訊軟件，如WhatsApp、微信、Telegram、QQ 等渠道與人工智能溝通

能記住用家偏好設定及習慣，從對話中持續學習及改善

能夠根據用戶要求，24小時隨時執行任務

用家授權後，能夠直接控制你的電腦

人工智能代理的應用例子

人工智能代理各有不同功能，例如：




管理檔案

新增、刪除、分類檔案、修改檔案內容等



自動化行政工作

傳送電郵、管理行事曆、整理會議紀錄、成為客服人員



整理資訊

搜尋及整理網上資訊、整合不同文件的資料



執行複雜的工作流程

製作及發布帖文到社交媒體，再透過通訊軟件傳送帖文；
閱讀用家的偏好設定及文件，按用家的需要創建程式


人工智能代理的風險

2026年第一季其中一個熱門人工智能代理的例子是「龍蝦」(OpenClaw)，當中曾發生以下事件：

OpenClaw卸裝潮 | 全球瘋傳深圳千人排隊「免費領養龍蝦AI」(AI代理工具OpenClaw)的壯觀場面才發生不足一星期，中國近日竟由「養龍蝦熱」演變成「放生龍蝦移除潮」。不少玩家最初為體驗自動化操作而爭相安裝，甚至不惜付費請人代勞。然而，短短一週內，這隻「龍蝦」便因其驚人的運作成本與資安風險，令用家紛紛急著花\$299人民幣請專人「上門卸載」，形成一場極其諷刺的科技鬧劇。

來源：香港01

人工智能代理的功能相當強大，
那為甚麼用家會爭相卸載？
當中是否隱含了甚麼風險？



人工智能代理的功能及權限越多，相對應的風險亦越高，
以上述的OpenClaw事件為例，用家正面對以下問題：



難以控制成本

設定不當時，簡單任務都會花費大量金錢



網絡安全風險增加

安全設定不當時，可能會
洩露電腦中的敏感資料



執行錯誤行為

有機會忘記用戶的規定或
無視指令，作出錯誤行為



自身能力不足


如對人工智能代理的了解
不足，缺乏操控它的能力，
構成安全風險

安全使用人工智能代理功能的範例

現時有不少可信的聊天機械人能執行簡單而安全的任務，
以下以Google Gemini為例逐步拆解有關操作：

01

授權及開啟新的聊天室



02


輸入提示詞及運行

請在Google Calendar中加入一個新活動：
標題：教師會議
日子：2026年4月1日
時間：16:00-17:30
地點：G01室

+ Tools

03

檢查結果




使用人工智能代理的建議

儘管部分人工智能代理功能強大，有助提升教與學效能，但鑑於其風險及技術門檻較高，故不建議用於一般工作環境或日常生活。

如有意於日常生活中使用人工智能代理相關的功能，用戶應事先充分了解相關的技術設定，包括權限控制、敏感資料保護及結果核對等。

同時，建議循序漸進使用人工智能代理，先從簡單、安全、低風險的功能開始，並優先選用可靠且安全的工具，以降低潛在風險。



參考資料

unwire.hk：香港網絡安全中心警告 OpenClaw 龍蝦風險遠超聊天式 AI 提 5 大安全建議保平安



Yahoo! 新聞：Meta AI 專家慘遭 AI 叛變！OpenClaw 無視指令瘋狂刪除郵件，龍蝦開發者冷回一招「保命秘技」



香港01：OpenClaw爆卸裝龍蝦潮 | 安全成疑外日燒\$150元Token費：養不起！



21經濟網：全民養蝦熱，未來四個展望





Digital Education Teacher Professional Development

數字教育教師專業培訓

EdAcademy

EdCity Fully Supports
AI for Empowering Learning and Teaching
教城全力支持「智」啟學教

研究 與AI互動 Hum
Creating with AI 評估 AI基礎與應用 教學
學習 專業發展 Ethics of AI 數字化意識 管理 數字技術知識與技能

請即掃描下方二維碼瀏覽EdAcademy網頁，獲取更多資訊。內容豐富，包括：

專業人士分享

觀看人工智能專業人士針對香港教育市場的分享，了解人工智能的最新發展。

同儕經驗分享

參考其他教師在各學科應用人工智能的真實經驗，改善你的教學策略，助學生更有效地學習。

免費學習資源

專為教師而設的人工智能網上課程及講座，助你輕鬆掌握應用人工智能。

聯絡資料



EdAcademy

Wilson Wong

☎ 2624 1029

✉ wilson.wong@hkecl.net

Yves Lee

☎ 3527 7112

✉ yves.lee@hkecl.net