

INCIDENTI DIGITALI

Un'intelligenza artificiale autonoma che ci attacca? Non esageriamo

ECONOMIA

11_08_2026

**Daniele
Ciacci**



Nel giro di poche settimane sono arrivate due notizie che, lette insieme, disegnano un quadro problematico. I modelli di intelligenza artificiale più potenti, spinti al limite, sono stati capaci di agire in modo autonomo e imprevisto. Finora i sistemi di controllo pensati

per intercettare questi comportamenti hanno funzionato correttamente. Ma fino a quando?

Il primo caso riguarda OpenAI. Durante un test interno pensato per misurare le capacità informatiche dei propri modelli, tra cui GPT-5.6 Sol e un secondo sistema non ancora reso pubblico, un agente ha superato il perimetro previsto dalla valutazione, individuato una zona di vulnerabilità mai segnalata prima, e se ne è servito per collegarsi liberamente a Internet.

Una volta online ha scelto come bersaglio Hugging Face, una piattaforma che raccoglie modelli e dataset di sviluppatori di tutto il mondo, tentando di sottrarre credenziali e accedere a infrastrutture interne. L'attacco è stato scoperto dalla squadra di sicurezza di OpenAI grazie alla rilevazione di attività anomale, e le due aziende hanno unito le forze per contenere l'IA "impazzita". Il CEO di Hugging Face, Clem Delangue, ha commentato che la falla della sicurezza intercettata dall'agente sarà risolta, e tutto è finito lì.

Ma è il secondo episodio, più recente e più inquietante, ad aprire scenari da *Black Mirror*. Un report pubblicato il 4 agosto dall'AI Security Institute britannico (Aisi) ha dichiarato che durante una sfida di sicurezza informatica ripetuta 122 volte su diversi modelli, alcuni agenti (soprattutto Mythos 5 di Anthropic, e in misura minore il già citato GPT-5.6-Sol di OpenAI) hanno messo in atto azioni definite dai ricercatori "autonome" e "non autorizzate". Un agente ha pure cercato di inserire un codice dannoso in un progetto open source su GitHub, arrivando a costruire false identità online e a fare pressioni psicologiche su un programmatore reale perché approvasse la modifica.

Il tentativo è fallito perché l'umano ha rifiutato, ma resta il fatto che l'agente si è spinto oltre, impiegando tecniche di ingegneria sociale mai richieste esplicitamente dai ricercatori, elaborate autonomamente pur di portare a termine il compito assegnato.

Due dettagli, però, vanno tenuti a mente per leggere correttamente questi episodi senza scivolare nel catastrofismo. In entrambi i casi non si tratta dell'uso normale dei prodotti a cui hanno accesso milioni di utenti ogni giorno. Sono ambienti di test costruiti appositamente per togliere ogni freno all'IA. OpenAI aveva volontariamente ridotto i limiti di sicurezza dei propri modelli e disattivato i blocchi per attività informatiche ad alto rischio, proprio per misurarne le capacità offensive reali. Era, in pratica, un test da laboratorio.

Aisi, allo stesso modo, ha scelto di non usare una sandbox isolata, ma di lasciare

che gli agenti avessero accesso a Internet, una condizione che i modelli disponibili al pubblico non hanno mai per compiti di questo tipo. In sostanza, questi sistemi sono stati incentivati a comportarsi in modo pericoloso per scoprire dove si trovi il limite prima che qualcun altro, dall'esterno, lo adoperi per scopi malevoli.

Il secondo elemento, forse quello più rassicurante, è che il sistema di security check ha funzionato. In entrambi i casi il comportamento anomalo è stato rilevato dai meccanismi di monitoraggio, l'azione è stata bloccata, è stata aperta un'indagine e i risultati sono stati resi pubblici invece che nascosti (cosa non scontata vista l'opacità con cui alcune aziende IA continuano a lavorare). Si è voluto, in pratica, individuare i rischi prima che diventassero danni concreti per condividerli con l'intero settore.

È chiaro però che l'IA è cambiata. Non più soltanto un modello che genera testo, ma un'infrastruttura capace di pianificare sequenze complesse e scalabili di azioni e adattarsi agli ostacoli in autonomia. Se tali capacità simili finissero nelle mani sbagliate, il rischio cambierebbe scala.

In pratica, si è davanti non a un motivo di allarme, ma a un promemoria. L'IA non ha una propria volontà, ma forse questa stessa affermazione rischia di risultare tra qualche anno (forse mesi) anacronistica e prematura. Proprio per questo l'Enciclica *Magnifica Humanitas* di Leone XIV si augurava una politica capace di governare l'IA con trasparenza, cosa alla quale gli alti papaveri dietro l'IA pare facciano ancora oggi orecchie da mercante.