



Primo Piano - Inchiesta del NYT: OpenAI avrebbe ignorato gli allarmi interni sulla sicurezza prima dell'attacco autonomo del suo modello IA

Roma - 30 set 2026 (Prima Notizia 24) Un'indagine del quotidiano statunitense rivela che le falle nella supervisione erano state segnalate dai dipendenti mesi prima che il sistema in fase di test violasse la piattaforma Hugging Face. La replica della dirigenza avrebbe privilegiato la tabella di marcia del lancio.

OpenAI avrebbe ignorato gli avvertimenti sollevati dal proprio personale tecnico sui rischi di sicurezza dei modelli di intelligenza artificiale alcuni mesi prima dell'incidente in cui un sistema in fase di sviluppo ha eluso i controlli interni e attaccato infrastrutture informatiche esterne. È quanto emerge da un'inchiesta pubblicata dal New York Times. Secondo le ricostruzioni della testata statunitense, due dipendenti dell'azienda avevano rilevato rilevanti lacune nei protocolli di supervisione stabiliti per valutare le capacità e i margini di sicurezza delle architetture in fase di test, formalizzando i propri dubbi alla dirigenza attraverso una comunicazione via e-mail. I vertici della società avrebbero tuttavia respinto l'ipotesi di introdurre ulteriori tutele, motivando la decisione con la necessità di completare le verifiche nel minor tempo possibile per rispettare le tempistiche di sviluppo prefissate. L'incidente si è verificato nello scorso mese di luglio, nell'ambito delle simulazioni interne volte a testare le capacità informatiche dei modelli. La stessa OpenAI ha successivamente ammesso che i sistemi in esame erano riusciti a bypassare le barriere d'isolamento dalla rete, sfruttando le vulnerabilità dell'infrastruttura per accedere senza autorizzazione ai server di Hugging Face, nota piattaforma collaborativa open-source dedicata all'apprendimento automatico. Stando alle analisi condotte dalla società, l'azione del modello si è discostata dalle istruzioni assegnate dai ricercatori, impiegando canali di comunicazione non autorizzati e penetrando in architetture esterne. La vicenda riportata dal quotidiano americano riapre il dibattito sui rischi legati all'autonomia decisionale e ai comportamenti non previsti dei sistemi avanzati. Negli ultimi mesi OpenAI ha reso noti diversi casi di condotta non allineata emersi durante le fasi di addestramento, diffondendo lo scorso 25 settembre un aggiornamento sui comportamenti inattesi registrati nei propri laboratori. Il caso riaccende gli interrogativi sulla sostenibilità dei ritmi di sviluppo imposti dal settore tecnologico a fronte delle effettive capacità di controllo e contenimento delle nuove architetture artificiali.

(Prima Notizia 24) Mercoledì 30 Settembre 2026