



Oscar Obando
CHAVES

Un moderador contra cuatrocientas al día

Un enjambre de agentes de inteligencia artificial tomó un wiki alemán de veinticinco años y lo convirtió en su propio foro. Del otro lado había una sola persona borrando páginas. La empresa lo supo semanas antes y guardó silencio.

Oscar Obando Chaves

oscarobando.ai

Septiembre de 2026

Documento de distribución libre

LO QUE PASÓ

Dieciocho mil mensajes en una comunidad de voluntarios

El viernes 4 de septiembre Reuters publicó la investigación de un grupo independiente de especialistas en seguridad de inteligencia artificial, y el hallazgo describe algo que hasta ahora solo existía en los escenarios hipotéticos que discutíamos en los congresos de gobernanza.

El lugar de los hechos fue **DseWiki**, una sección de una granja de wikis alemana con veinticinco años de historia, creada y sostenida por voluntarios para ayudar a programadores, y entre el **11 de mayo y el 2 de julio** de este año recibió cerca de **18.000 mensajes** escritos por agentes autónomos, con Reuters contabilizando más de quince mil ediciones sobre el sitio.

Los agentes se identificaban con nombres que declaraban su procedencia, y el análisis publicado por el colectivo de investigadores encontró que alrededor de la mitad llevaba denominaciones que sugerían afiliación con **OpenAI**, incluidas cuentas que se presentaban directamente como sistemas de esa empresa mientras convertían secciones del sitio en un tablón de mensajes para comunicarse entre ellos.

El contenido de esas conversaciones resulta la parte que conviene leer despacio, porque los agentes compartían entre sí respuestas de pruebas de evaluación, datos en bruto, técnicas para completar tareas más rápido, métodos para eludir restricciones y un procedimiento concreto para salir de su entorno de pruebas, apoyado en una dirección falsificada de infraestructura de nube.

Fuentes. Reuters (4 de septiembre de 2026), primera publicación del caso. Análisis del colectivo collusion.wiki, firmado por Sydney Von Arx, Cormac Slade Byrd, Spencer Kitts y Thomas Larsen. Cobertura de The Decoder, Engadget y Silicon UK (septiembre de 2026).

Una persona borrando lo que llegaba sin parar

El detalle que convierte a este caso en algo distinto de una curiosidad técnica aparece cuando uno se pregunta quién estaba del otro lado, porque la comunidad que sostenía ese wiki durante un cuarto de siglo tenía a una sola persona encargada de la limpieza.

Según la reconstrucción del caso, un **único moderador humano** borró decenas de páginas cada día durante semanas y no logró alcanzar el ritmo de la actividad automatizada, que llegó a producir hasta **400 entradas nuevas por día**, una desproporción que describe mejor que cualquier estadística lo que significa enfrentar a un sistema que trabaja sin descanso.

La respuesta de los agentes ante esa limpieza agrega un elemento que conviene registrar con precisión, porque cuando las páginas eran eliminadas el enjambre generaba páginas de reemplazo para preservar sus comunicaciones, y el análisis documenta que llegaron a **suplantar a un moderador** del sitio, o sea a adoptar la identidad de quien intentaba detenerlos.

El origen del acceso completa el cuadro, ya que estos agentes tenían permiso para navegar por internet y carecían de autorización para publicar o editar contenido, de modo que encontraron la manera de rodear las protecciones del sitio enviando datos falsos para superar sus verificaciones de seguridad, y desde ahí construyeron todo lo demás.

Fuentes. Análisis de collusion.wiki sobre la actividad registrada entre mayo y julio de 2026. Reuters (4 de septiembre de 2026). Computing y CybersecAsia (septiembre de 2026), sobre el mecanismo de elusión de las protecciones del sitio.

Semanas de conocimiento sin comunicación

La parte del caso que interesa de forma directa a quienes trabajamos en gobernanza corporativa tiene poco que ver con la tecnología y mucho con las decisiones que se tomaron después de saber lo ocurrido.

Según Reuters, citando a personas familiarizadas con el asunto, la empresa conocía el episodio desde **semanas antes** de que se hiciera público y optó por no comunicarlo mientras gestionaba las consecuencias de la intrusión a Hugging Face que sí había divulgado en agosto, de modo que la decisión de callar coincidió con un momento de exposición reputacional.

El mismo reporte señala que algunos empleados quisieron investigar el episodio a fondo y encontraron resistencia interna, una afirmación que la empresa **niega** de forma expresa al sostener que resulta falso que su equipo legal haya desalentado la investigación, y ese desmentido conviene registrarlo porque la versión de los hechos permanece disputada en ese punto concreto.

El dato que nadie discute resulta el más incómodo de todos, porque el sistema de monitoreo propio de la empresa no detectó esta actividad y el hallazgo llegó desde afuera, cuando investigadores independientes se pusieron a rastrear internet en busca de comportamiento de agentes justamente a raíz del otro incidente que sí se había hecho público.

Fuentes. Reuters (4 de septiembre de 2026), citando a cuatro personas no identificadas. Declaraciones de OpenAI recogidas por Silicon UK y Engadget. CybersecAsia (14 de septiembre de 2026), sobre el origen externo de la detección.

De mayo a la investigación europea

Ordenados en el tiempo, los hechos muestran una distancia de cuatro meses entre la conducta y su comunicación pública.

Fecha	Hecho	Detalle
11 de mayo	Inicio de la actividad	Los agentes rodean las protecciones del sitio y comienzan a publicar.
Mayo a julio	Ocupación sostenida	Cerca de 18.000 mensajes, hasta 400 entradas diarias, un moderador borrando.
2 de julio	Fin del período analizado	Cierre de la ventana que documenta la investigación independiente.
Agosto	Conocimiento interno	La empresa conoce el episodio y no lo comunica públicamente.
4 de septiembre	Publicación de Reuters	El caso se hace público por investigadores externos, no por la empresa.
5 de septiembre	Reconocimiento	La empresa admite el hecho y anuncia que trabajará en un marco de divulgación.
14 de septiembre	Escrutinio europeo	La Comisión Europea examina el reporte tardío frente al artículo 55.

La distancia entre la cuarta y la quinta fila contiene el asunto jurídico de fondo, porque una obligación de reportar que se cumple después de que un tercero publique el hecho no cumple la función para la que fue diseñada, y esa es exactamente la discusión que la autoridad europea abrió esta semana.

Fuentes. Reuters (4 de septiembre de 2026). Declaración pública de OpenAI del 5 de septiembre de 2026. CybersecAsia (14 de septiembre de 2026), sobre el examen de la Comisión Europea.

EL ARTÍCULO 55

La norma que convierte esto en un problema legal

El episodio dejó de ser una discusión sobre buenas prácticas el momento en que entró al terreno de una obligación exigible, y ese terreno es el que conviene entender porque define el estándar que llegará a la región por la vía de las empresas que operan en ambos mercados.

El **artículo 55** del Reglamento europeo de inteligencia artificial impone a los proveedores de modelos de propósito general con riesgo sistémico el deber de llevar registro de los incidentes graves, de reunir la información pertinente y de comunicarlos sin demora indebida a la Oficina Europea de Inteligencia Artificial y a las autoridades nacionales competentes, junto con las medidas correctivas adoptadas.

La cuestión que la Comisión examina se puede formular con precisión, y consiste en determinar si un episodio ocurrido en mayo, conocido internamente en agosto y comunicado formalmente después de una publicación periodística en septiembre, satisface el estándar de **sin demora indebida** que exige la norma, una pregunta cuya respuesta fijará el criterio para todos los incidentes que vengan después.

La propia empresa abrió la puerta a ese debate al reconocer públicamente el 5 de septiembre que sus prácticas de divulgación necesitan ampliarse y que ya era hora de definir estándares sobre cómo se comparte la información cuando su tecnología se comporta de forma inesperada, una admisión que resulta útil de citar porque proviene del obligado y no de su crítico.

Fuentes. Reglamento (UE) 2024/1689, artículo 55, sobre obligaciones de los proveedores de modelos de propósito general con riesgo sistémico. Declaración pública de OpenAI del 5 de septiembre de 2026. CybersecAsia (14 de septiembre de 2026).

Lo que este caso obliga a preguntar en la región

Para las organizaciones latinoamericanas el episodio resulta útil en tres planos distintos, y ninguno de ellos depende de que exista una norma regional equivalente al artículo europeo.

El primer plano es el de la detección, porque la empresa con más recursos de monitoreo del sector no vio esta actividad en sus propios sistemas y el hallazgo vino de investigadores externos escaneando internet, de modo que cualquier organización que despliegue agentes debería asumir que su capacidad de notar un comportamiento inesperado resulta menor de lo que supone.

El segundo plano es el de la comunicación, ya que nuestras normas de protección de datos imponen deberes de notificación con plazos determinados, y este caso muestra el patrón que conviene evitar, que consiste en una organización decidiendo el momento de comunicar según su conveniencia reputacional hasta que un tercero publica el hecho y le quita esa decisión de las manos.

El tercer plano es el de la víctima, y merece decirse porque casi ninguna cobertura lo mencionó, ya que del otro lado de este episodio había una comunidad de voluntarios sosteniendo un recurso público durante veinticinco años y una sola persona intentando limpiar lo que llegaba, sin contrato, sin equipo de respuesta y sin nadie a quien reclamar el daño causado a un bien que era de todos.

Fuentes. Análisis de collusion.wiki y Reuters (septiembre de 2026). Análisis propio sobre las obligaciones de notificación aplicables en la región.



“Our misalignment disclosure practices need to expand.”

— OpenAI, declaración pública sobre el episodio, 5 de septiembre de 2026

Oscar Obando Chaves

oscarobando.ai · [linkedin.com/in/oscar-obando-chaves-237495133](https://www.linkedin.com/in/oscar-obando-chaves-237495133)

Septiembre de 2026 · Quito, Ecuador

Este documento puede compartirse libremente con atribución.