

INFORME · OCTUBRE 2026

Grok, ¿esto es real?

Análisis de las respuestas
del chatbot de X sobre
contenidos del Mundial de
Fútbol de 2026

Autores: Celia Ramos, Macarena Hortal Vega, Marina Sacristán Hidalgo, Coral García y Magdalena Torga (Fundación Maldita.es)

Colaboradores: Rosa Molina López, Sergio Iglesias Parro y Javier Rodríguez Árbol (Universidad de Jaén)

Cómo citar: Ramos, C., Hortal-Vega, M., Sacristán-Hidalgo, M., García, C., Torga, M. (2026). *Grok, ¿esto es real? Análisis de las respuestas del chatbot de X sobre contenidos del Mundial de 2026*. Fundación Maldita.es

La producción de esta investigación cuenta con el apoyo de una subvención de la Journalism Science Alliance (JSA).

Índice

Índice	2
1. Introducción	3
1.1. Sobre el proyecto	4
1.2. Objetivos y preguntas de investigación	5
2. Metodología	6
2.1. Muestra y diseño	6
2.2. Adquisición de datos y procedimiento	7
3. Hallazgos principales	9
4. Análisis de resultados	10
4.1. Nivel de respuesta de Grok	10
4.2. Exactitud de las respuestas	11
4.3. Tipos de error	13
4.4. Fuentes de Grok	14
4.5. Respuestas antes y después de la verificación	16
4.6. Preguntas abiertas vs directas	19
4.7. El papel de la notas de la comunidad	20
5. Discusión y conclusiones	21
6. Notas	23
7. Referencias	23
8. Anexos	26

1. Introducción

Este informe aborda el uso de los chatbots de inteligencia artificial (IA) como “verificadores de contenido” en un momento en el que los asistentes conversacionales se están incorporando a las rutinas informativas de una parte creciente de la población. Según el *Digital News Report 2026*, el 10% de los encuestados los utiliza ya cada semana para informarse (Egan et al., 2026). En España este uso casi se ha duplicado en un año hasta alcanzar al 8% de los encuestados y al 14% de los menores de 25 años (Ross Arguedas, 2026). En X, desde la integración de Grok mediante menciones directas en 2025, responder a una publicación etiquetando al asistente para preguntarle “@grok, ¿esto es real?” se ha convertido en una práctica habitual de “verificación” bajo demanda. La búsqueda de información y la verificación concentran la mayoría de las interacciones con el asistente (Mei et al., 2026; Bobek et al., 2026). De hecho, en un estudio preliminar, Renault et al. (2026) identificaron 1.555.275 solicitudes de verificación en inglés dirigidas a Grok y Perplexity (un motor de búsquedas basado en IA) entre febrero y septiembre de 2025 (que representan al menos el 7,5% de las interacciones de los usuarios con ambos chatbots en ese periodo) y constataron que esta fórmula (“@grok, ¿esto es real?”) es también la más repetida entre los mensajes en español. La expansión de este uso coincide temporalmente, además, con la retirada de las grandes plataformas de los programas de verificación profesional, como hizo Meta en Estados Unidos en 2025 (Kaplan, 2025). Apremia, por tanto, una revisión del papel de la IA en la lucha contra la desinformación, máxime en los acontecimientos de última hora, cuando todavía no existe información contrastada.

Estudios recientes se han centrado en la capacidad técnica de los grandes modelos de lenguaje (LLM, por sus siglas en inglés) para verificar afirmaciones (Quelle y Bovet, 2024; Augenstein et al., 2024) y en las percepciones de los verificadores profesionales sobre su uso (Cuartiellas et al., 2023). Sin embargo, tal y como señalan Bobek et al. (2026: 2), “la mayor parte de la evidencia procede de entornos experimentales controlados y no de entornos reales de redes sociales”.

En palabras de Renault et al. (2026: 1), el impacto de los LLM desplegados como verificadores en redes sociales “depende no solo de la capacidad técnica de los modelos, sino también de las decisiones de sus diseñadores y de las actitudes y comportamientos de los usuarios de las plataformas”. Esta perspectiva obliga a distinguir la verificación profesional de la que ofrecen estos asistentes. La primera se articula en fases de selección del contenido, contraste con fuentes documentales y personales y explicación transparente del proceso, con enlaces que permiten al lector replicarlo (Graves, 2017; López Pan y Rodríguez Rodríguez, 2020); en este marco, los verificadores se reafirman como “agentes de contexto” y conciben la IA como un recurso meramente auxiliar sujeto a supervisión humana y profesional constante (Cuartiellas et al., 2023). Grok, en cambio, funciona como una “capa temprana y complementaria de construcción de sentido” (Bobek et al., 2026: 1), que responde en cuestión de minutos sin la validación por consenso propia de la verificación colaborativa y profesional. Es decir, qué se verifica y con qué fuentes deja de depender del criterio de periodistas y verificadores y pasa a estar determinado por la solicitud individual de cualquier usuario y por un sistema algorítmico cuyas fuentes no siempre son trazables. Esta delegación conlleva un alto riesgo de desinformación, en particular cuando el asistente responde antes de que exista una verificación disponible.

Los riesgos de esta delegación están ampliamente documentados. Los LLM tienden a generar alucinaciones, contenidos fluidos y verosímiles pero infieles a la fuente (Ji et al., 2023). Tienden también a adaptar sus respuestas a las opiniones percibidas del interlocutor (Sharma et al., 2024) y a asumir las premisas falsas incorporadas en la pregunta (Kim et al., 2023; Yu et al., 2023), de modo que su acuerdo con afirmaciones erróneas se incrementa a medida que la consulta presupone su veracidad (Kaur et al., 2024).

Otras investigaciones muestran que estos fallos son, además, sistémicos. Un trabajo de NewsGuard (Sadeghi, 2025) constató que los diez principales

chatbots, entre ellos Grok, reproducían afirmaciones falsas en el 35% de sus respuestas a consultas sobre bulos de actualidad, casi el doble que un año antes. Según la organización, al incorporar la búsqueda web en tiempo real los modelos dejaron de abstenerse y empezaron a nutrirse de un ecosistema digital contaminado, en ocasiones de forma deliberada por redes de propaganda. Desde entonces desmienten más bulos que antes (del 51% al 65%), pero también los repiten con más frecuencia (del 18% al 35%). El estudio de la EBU y la BBC (2025), en el que participaron 22 medios públicos de 18 países, detectó problemas significativos en el 45% de las respuestas de cuatro asistentes sobre noticias, con la atribución de fuentes como principal causa, desde enlaces inexistentes hasta “citas ceremoniales” (*ceremonial citations*) que aparentan rigor sin respaldar lo que se afirma.

En el caso particular de Grok, estas limitaciones se agravan ante el contenido visual. Un estudio con Grok 3 mostró que fracasaba en la detección de rostros intercambiados y de imágenes generadas con GAN, al apoyarse en elementos del fondo o en textos sobreimpresos (Tariq et al., 2025). Se agravan también ante los acontecimientos de última hora, durante los cuales emitió veredictos contradictorios sobre una misma publicación en cuestión de minutos (Ponce de León y Chenrose, 2025). Sus respuestas dependen asimismo de las decisiones de quien controla el sistema, como sugieren la difusión de contenidos racistas y extremistas coincidiendo con el lanzamiento de Grok 4 y los cambios en la valoración de publicaciones partidistas entre versiones del modelo (Renault et al., 2026).

En cuanto a las consecuencias, DeVerna et al. (2024) demostraron que las verificaciones de un LLM no mejoran la capacidad de discernimiento de los lectores. En consonancia con la tendencia a percibir

la IA como una fuente objetiva (Sundar, 2008; Sundar y Kim, 2019), los participantes creyeron menos los titulares verdaderos que el modelo calificaba erróneamente como falsos. También creyeron más los titulares falsos sobre los que el modelo expresaba incertidumbre. Saber que una verificación procede de una IA tampoco reduce necesariamente su efecto persuasivo (Chae y Tewksbury, 2026), un efecto que la investigación ha documentado en ambas direcciones. Los diálogos con LLM pueden reducir la creencia en teorías conspirativas (Boissin et al., 2025), pero también modificar actitudes políticas e intenciones de voto (Hackenburg et al., 2025; Lin et al., 2025). Un asistente capaz de corregir una creencia errónea puede, por tanto, consolidarla cuando su veredicto es incorrecto.

Sin embargo, estos efectos se han medido sobre todo en inglés y con población estadounidense y británica, al igual que la mayor parte de la investigación sobre estos modelos. Esto ocurre pese a que el español es la segunda lengua más utilizada para invocar a Grok (Bobek et al., 2026) y a que el rendimiento de los LLM en tareas de verificación varía entre idiomas (Qazi et al., 2026; Wang et al., 2026) y es menor cuando las afirmaciones no se formulan en inglés (Quelle y Bovet, 2024). En la presente investigación comprobaremos si los fallos documentados se reproducen en las respuestas de Grok sobre contenidos del Mundial de Fútbol de 2026 verificados por *Maldita.es*, a partir de consultas propias en español y de las respuestas a otros usuarios. Al consultar antes y después de cada verificación, veremos si la disponibilidad de información contrastada modifica sus veredictos, si la formulación de la pregunta los condiciona, si Grok mantiene la coherencia ante un mismo *claim* y en qué fuentes se apoya.

1.1. Sobre el proyecto

“Grok, ¿esto es real?” es un proyecto de investigación periodística y científica financiado por la Journalism Science Alliance (JSA) y liderado por **Fundación Maldita.es**, en colaboración con la **Universidad de Jaén**. El proyecto se centra en examinar el uso de chatbots de IA, y en particular de Grok (el asistente de IA integrado en X), como **verificadores de hechos en tiempo real** en redes sociales, así como los **riesgos** que esto supone para

la integridad informativa. Para ello, la investigación sigue un diseño en dos fases consecutivas: (a) un **análisis de tipo “caja negra” del comportamiento** de Grok ante consultas de verificación sobre contenidos virales registrados y verificados por *Maldita.es*, usando la Copa Mundial de la FIFA de 2026 como caso de estudio; y (b) **experimentos controlados**, basados en los casos reales identificados en la fase anterior, para medir cómo las

respuestas de Grok (correctas, con alucinaciones o corregidas *a posteriori*) afectan a la credibilidad percibida, los juicios de precisión, la actualización de creencias y la disposición a compartir contenido por parte de las audiencias. El análisis **incorpora variables psicológicas y conductuales** (como rasgos de personalidad, impulsividad, confianza en la IA y alfabetización mediática) para identificar factores que aumentan la vulnerabilidad a la desinformación generada con IA y evaluar la persistencia de los efectos engañosos incluso después de las correcciones.

En conjunto, el proyecto propone un análisis interdisciplinario sobre cómo la IA está transformando las prácticas de verificación y sus consecuencias para la confianza pública, la

integridad de la información y el acceso democrático a información fiable. Es especialmente oportuno en el contexto de los esfuerzos regulatorios en curso en el marco de la **Ley de Servicios Digitales (DSA)** y los debates más amplios sobre la gobernanza de la IA, ya que, al documentar cómo se producen los fallos de verificación de este tipo de herramientas, cuándo son más probables y cómo influyen en la percepción pública, se aportan datos concretos y basados en la evidencia útiles para fundamentar las políticas, la rendición de cuentas de las plataformas y las estrategias de mitigación de riesgos.

El presente informe recoge exclusivamente los resultados y análisis de la primera fase del proyecto, realizada por *Maldita.es*.

1.2. Objetivos y preguntas de investigación

El objetivo general de esta investigación es examinar el uso de Grok como herramienta de verificación en tiempo real ante consultas ciudadanas de tipo “¿esto es real?” sobre contenidos virales relacionados con la Copa Mundial de la FIFA, identificados por *Maldita.es* y publicados en X entre el 13 de junio y el 20 de julio de 2026. Son tres las preguntas principales que guían el estudio: **(P1)** ¿en qué

medida y bajo qué condiciones las respuestas de Grok ante consultas de verificación en tiempo real generan o amplifican desinformación?; **(P2)** ¿cómo evolucionan estas respuestas a lo largo del tiempo, antes y después de que exista información contrastada disponible?; y **(P3)** ¿se observa algún patrón en las respuestas en función de quién y cómo se formula la consulta? A partir de estas preguntas, se plantean los siguientes objetivos específicos:

- 1** Explorar la **exactitud de las respuestas** de Grok y su **variación** en función de la categoría temática del contenido y *claim* consultado (“futbolistas y competición”, “corrupción”, “política y geopolítica”, “género y diversidad sexual” y “migración, nacionalidades y etnias”).
- 2** Identificar las **fuentes** que cita Grok para justificar dichas respuestas, de qué tipo son y si permiten comprobar la información.
- 3** Examinar la **evolución de las respuestas a lo largo del tiempo**, antes y después de la disponibilidad de información verificada.
- 4** Identificar **patrones de error o acierto** de las respuestas en función de quién o cómo se formula la consulta de verificación sobre el contenido.

En última instancia, los resultados aportan evidencia sobre cómo y cuándo falla Grok en contextos de verificación, especialmente ante noticias de última

hora, y sobre la relación entre esos fallos y la manera de formular la consulta.

2. Metodología

2.1. Muestra y diseño

El corpus muestral se compone de **766 consultas** realizadas a Grok sobre la veracidad y la fuente de 46 afirmaciones (*claims*)¹ virales distintas relacionadas con la Copa Mundial de la FIFA, difundidas en X (antes Twitter) entre el 13 de junio y el 20 de julio de 2026 y verificadas por *Maldita.es*.

La elección del Mundial como caso de estudio responde en primer lugar, a que se trata de un **evento de alcance informativo global** y de **seguimiento masivo** y sostenido en redes sociales, lo que garantiza un volumen suficiente de contenidos virales susceptibles de verificación en un periodo de tiempo acotado. En segundo lugar, a diferencia de otros temas de desinformación que afectan sobre todo a públicos ya predispuestos a consumir ese tipo de contenido (política, salud, cambio climático), el Mundial concita el interés de una **audiencia especialmente transversal**, que abarca perfiles muy distintos en edad, ideología y nacionalidad. Como tercer punto, y como ya se ha visto en mundiales anteriores (*Maldita.es*, 2022; Torres et al., 2026), constituye un **terreno especialmente fértil** para la desinformación, precisamente por la combinación de **audiencias masivas, alta carga emocional e identitaria** y un flujo constante de imágenes y momentos descontextualizables, que lo convierte en un evento con capacidad probada para generar y viralizar bulos a gran escala. En cuarto lugar, su naturaleza de **noticia/evento de “última**

hora” permite observar precisamente el objeto de este estudio: cómo responde Grok ante dudas sobre hechos que se desarrollan en directo y sobre los que aún no existe información contrastada; y cómo evolucionan esas respuestas a medida que la información verificada va estando disponible. Por último, los contenidos asociados al evento **no se limitan al ámbito estrictamente deportivo**; también abarcan cuestiones políticas, de género, de corrupción y de carácter identitario, lo que permite analizar el comportamiento de Grok frente a una variedad de temáticas comparable a la de otros contextos informativos relevantes (crisis políticas, conflictos o procesos electorales), en un entorno accesible y con un volumen de casos predecible.

La metodología de investigación utilizada se basó en una auditoría de “caja negra” de carácter descriptivo y exploratorio. Es decir, dado que no es posible acceder al funcionamiento interno del modelo, el comportamiento de Grok se reconstruye a partir de las respuestas observables que ofrece ante consultas formuladas en condiciones de uso real. Para el análisis de resultados se optó por un enfoque de tipo mixto en el que se combina el análisis cualitativo y el cuantitativo de los datos obtenidos, pues consideramos que la triangulación de estas perspectivas permite una mejor comprensión de los objetivos específicos planteados.

Limitaciones: en lugar de seleccionar una muestra de casos de actualidad heterogéneos y no relacionados entre sí, se optó por trabajar sobre la totalidad de los contenidos de X relacionados con un único evento recopilados a través del Disinformation Management System (DMS) de *Maldita.es*, que se nutre de reportes de usuarios en los que se describen, con distintos niveles de detalle, los mensajes, formatos y contextos en los que tuvo lugar un intento de engaño. De este modo, la decisión editorial se limita a la elección del propio evento (la Copa Mundial de la FIFA) y no a la elección de qué contenidos y desinformaciones concretas incluir dentro de él, lo que reduce el margen de una selección adicional de casos que podría sesgar más los resultados hacia determinadas narrativas o temáticas. La muestra sigue siendo, por tanto, intencionada, como corresponde a un estudio de caso, pero exhaustiva dentro del marco temporal y temático delimitado por el propio evento. Al proceder de las consultas ciudadanas, refleja los contenidos que generaron dudas entre los usuarios y que *Maldita.es* verificó por su viralidad o su peligrosidad, no el conjunto de la desinformación que circuló sobre el Mundial.

2.2. Adquisición de datos y procedimiento

Para este estudio se seleccionaron del DMS todas las publicaciones de X relacionadas con el Mundial registradas durante el periodo analizado, con presencia significativa en la plataforma y pendientes de verificación en el momento de la consulta. Esta fase arrojó un total de 139 tuits, agrupados en 46 *claims*. De esos *claims*, 35 corresponden a contenidos falsos o manipulados, seis a contenidos que necesitan contexto, dos a alertas y solo tres a contenidos verdaderos (Anexos III y IV). Por formato, 37 son imágenes (18) o vídeos (19) y nueve, afirmaciones escritas, solas, acompañadas de una imagen o en captura de pantalla.

Para cada uno de los tuits, y desde un perfil verificado de escucha social (*social listening profile*) creado exclusivamente para el proyecto (@esrealestogrok_; Figura 1), se formularon a Grok dos consultas independientes que replicaban la interacción de un usuario cualquiera con la herramienta: una consulta sobre la veracidad del contenido (“@grok, ¿esto es real?”) y, por separado, otra sobre la fuente en la que basa su respuesta (“@grok, ¿fuente?”). Ambas se formularon antes y después de que *Maldita.es* publicase la verificación del contenido, con el fin de observar la evolución de la respuesta de Grok a medida que avanzaba la cobertura del hecho. Todas las consultas (y sus respuestas) se archivaron y codificaron de manera independiente, ya que Grok puede responder a una sin responder a la otra.

Dado que Grok no responde a todas las consultas que recibe, también se recogieron las consultas de otros usuarios que tenían respuesta y eran visibles en ese momento en la conversación del tuit. De este modo, el corpus final combina 556 consultas propias (278 sobre la veracidad y 278 sobre la fuente) y 210 consultas de terceros ($N=766$).

A diferencia de las consultas propias, que mantienen una formulación estable en español, las de terceros son de formulación libre, incluyen otros idiomas (mayoritariamente inglés) y casi nunca preguntan por la fuente.



Figura 1. Perfil en X utilizado por *Maldita.es*

En total se obtuvieron 358 respuestas de Grok, 148 a consultas propias (107 sobre la veracidad y 41 sobre la fuente) y 210 a consultas de terceros. Cada análisis utiliza el subconjunto adecuado a su pregunta. El nivel de respuesta y la evolución antes y después de la verificación se calculan solo con las consultas propias, al ser las únicas formuladas de manera sistemática en ambos momentos. La exactitud de las respuestas de Grok se calcula con las 317 respuestas sobre la veracidad (107 propias y 210 de terceros) y el análisis de las fuentes, con las 358 respuestas.

En el análisis de las fuentes se distinguen tres aspectos. El primero es la exactitud de la respuesta a la pregunta “@grok, ¿fuente?”, que se codificó con el mismo criterio que la de veracidad, es decir, según si lo que Grok responde coincide con la conclusión de la verificación. El segundo es si la fuente es identificable, esto es, si nombra un medio, una organización, una institución, una cuenta o un documento concretos, o si se limita a referencias genéricas (tipo “fact-checkers”) o no menciona ninguna. El tercero es el tipo de fuente (medio o agencia, organización de verificación, fuente oficial, red social, nota de la comunidad o herramienta de detección), que se emplea como aproximación a su fiabilidad, junto con la trazabilidad, es decir, si la respuesta enlaza al documento concreto que respalda el veredicto.

Por otra parte, los *claims* analizados se codificaron en cinco categorías temáticas excluyentes (“futbolistas y competición”, “política y geopolítica”, “género y diversidad sexual”, “corrupción” y “migración, nacionalidades y etnias”). Esta

clasificación permite analizar si la exactitud de las respuestas de Grok varía en función del ámbito temático del contenido consultado, lo cual es una distinción relevante de cara a las estrategias de mitigación de riesgo y rendición de cuentas de las plataformas.

Cada respuesta de Grok fue contrastada con el desmentido publicado por *Maldita.es* (elaborado de acuerdo con su [metodología](#)), lo que permitió calificar su exactitud y clasificar los distintos tipos de error observados (véase Anexo I), sentando la base empírica que se traslada a la Universidad de Jaén para el diseño de los experimentos de la Fase 2. Las consultas, respuestas y fuentes citadas por Grok fueron archivadas mediante herramientas de captura y archivo web para garantizar la trazabilidad del análisis ante la eventual edición o eliminación de contenidos.

El análisis es principalmente descriptivo, a partir de frecuencias y porcentajes. La muestra es intencionada y exhaustiva para un único caso, el estudio no partía de hipótesis previas y las respuestas no son independientes entre sí, ya que se agrupan en 42 *claims* y tres de ellos reúnen el 36% de las respuestas sobre la veracidad. Por este último motivo, los resultados principales se presentan también por *claim* (media de aciertos por *claim* y número de *claims* en los que se observa cada patrón) y el porcentaje global de acierto se acompaña de un intervalo de confianza obtenido por remuestreo de *claims*. Las comparaciones entre grupos (por formato, presencia de nota de la comunidad, formulación o momento de la consulta) no se diseñaron para aislar el efecto de cada factor y se presentan como patrones exploratorios. El tratamiento de los datos se realizó con Python.

A continuación, se presenta el esquema de codificación con las variables más relevantes aplicadas en este estudio:

Esquema de codificación	
Contenido	
Claim	Afirmación asociada al contenido verificado
Categoría temática	Futbolistas y competición; política y geopolítica; género y diversidad sexual; corrupción; migración, nacionalidades y etnias
Tipo de distorsión	Clasificación asignada por <i>Maldita.es</i> (Anexo II)
Formato	Imagen; vídeo; texto; texto e imagen; captura de pantalla
Nota de la comunidad	Visible antes de la consulta; ausente
Consulta	
Quién pregunta	<i>Maldita.es</i> ; otro usuario
Momento	Antes de la verificación de <i>Maldita.es</i> ; después
Formulación	Directa; abierta; no disponible
Respuesta de Grok	
Exactitud	Correcta; parcial; incorrecta; sin respuesta
Tipo de error	Seis tipos (Anexo I)
Fuente citada por Grok	
Exactitud	Correcta; parcial; incorrecta; sin respuesta
Tipo de fuente	Medio o agencia; organización de verificación; redes sociales; fuente oficial; nota de la comunidad; herramienta de detección de IA; referencia genérica; no cita fuente

3. Hallazgos principales

Los resultados proceden de dos conjuntos de consultas a Grok sobre 46 *claims*. Las consultas propias ($n=556$) se formularon desde el perfil del proyecto con una redacción estable antes y después de cada verificación, lo que permite medir el nivel de respuesta y su evolución. Las consultas de terceros, que incluyen 210 respuestas de Grok a otros usuarios, amplían la muestra para el análisis de la exactitud, las fuentes y los patrones de respuesta.

Nivel de respuesta y efecto de la verificación (consultas propias)

- **Grok deja sin responder la mayoría de las consultas.** Contestó al 38,5% de las preguntas propias sobre la veracidad (107 de 278) y al 14,7% sobre la fuente (41 de 278).
- **Preguntar una vez publicada la verificación no implica mejores respuestas.** El porcentaje global de aciertos apenas varía (del 63,9% antes al 69,6% después), aunque tras la verificación, Grok respondió sobre menos tuits. Cuando se le volvió a preguntar por publicaciones en las que se había equivocado, casi nunca corrigió el error, principalmente porque no volvió a contestar.

Exactitud, fuentes y patrones de respuesta (consultas propias y de terceros)

- **Entre un tercio y cuatro de cada diez respuestas sobre la veracidad no son correctas.** De las 317 respuestas analizadas, el 59,9% es correcto, el 26,8% incorrecto y el 13,2% parcial. La media de aciertos por *claim*, que da el mismo peso a cada contenido, es del 66,8%.
- **El formato del contenido marca la diferencia más clara.** Grok acierta en el 49,4% de las respuestas sobre imágenes y vídeos (121 de 245) y en el 95,8% de las referidas a afirmaciones escritas (69 de 72). Ninguno de los ocho *claims* escritos con respuesta recibió una respuesta incorrecta, frente a 18 de los 34 de imágenes o vídeos. El error más frecuente, en 81 de las 127 respuestas incorrectas o parciales, es no detectar que una imagen o un vídeo ha sido editado o generado con IA.

- **Advertir de los límites de la detección no impide el error.** En 37 respuestas sobre imágenes o vídeos, Grok reconoce que el contenido generado con IA puede ser “indistinguible del real” y aun así emite un veredicto, que es incorrecto en 15 casos y parcial en ocho.
- **Grok no es consistente ante un mismo contenido.** En 24 de los 38 *claims* con más de una respuesta, alterna respuestas correctas con otras incorrectas o parciales, y en 16 llega a contradecirse. Las contradicciones se dan incluso dentro de un mismo tuit y antes de que exista verificación.
- **La mayoría de las respuestas no permite comprobar el veredicto.** Solo una de cada tres respuestas (120 de 358) remite a una fuente identificable, solo diez incluyen un enlace y apenas tres llevan al documento concreto que respalda el veredicto. Además, 76 de las 85 respuestas incorrectas no mencionan ninguna fuente.
- **La exactitud varía con la formulación de la consulta.** Ante preguntas abiertas de otros usuarios, que piden identificar o explicar el contenido, el 59,7% de las respuestas es incorrecto, frente al 17,4% ante preguntas directas sobre la veracidad (el 25,9% en los *claims* que recibieron ambos tipos de pregunta).
- **Grok rara vez aprovecha las notas de la comunidad.** Solo menciona la nota en una de cada cinco respuestas sobre publicaciones que la mostraban (26 de 133), y 34 de esas respuestas fueron incorrectas o parciales. Acierta más en las publicaciones con nota visible (74,4% frente al 49,5%).

4. Análisis de resultados

4.1. Nivel de respuesta de Grok

De las 556 consultas propias (desde el perfil @esrealestogrok_), las únicas que permiten medir el grado de respuesta, Grok respondió a 148 (26,6%): **107 de las 278 sobre la veracidad (38,5%) y 41 de las 278 sobre la fuente (14,7%)** (Tabla 1). Tomando como unidad cada uno de los tuits consultados, Grok no respondió nunca a la pregunta sobre la veracidad en 56 de los 139 (40,3%) y solo respondió antes y después de la verificación en 24 (17,3%).

La falta de respuesta se concentra en imágenes y vídeos, el formato en el que Grok falla más (apartado 4.2). Respondió al 35,1% de las consultas sobre la veracidad de imágenes y vídeos y al 66,7% de las referidas a afirmaciones escritas, que corresponden solo a 15 tuits (Tabla 1).

La tasa de respuesta a la pregunta sobre la veracidad descendió a lo largo del Mundial. Grok respondió al 54,9% de las consultas sobre tuits publicados en junio y al 25,6% de las referidas a tuits de julio, con una caída mayor en las consultas posteriores a la verificación, del 52,5% al 17,9% (Tabla 1). El descenso se mantiene en las imágenes y los vídeos (del 51% al 24,3%), por lo que no se explica por el tipo de contenido. Los datos no permiten determinar la causa, pero este descenso condiciona la comparación entre antes y después de la verificación (apartado 4.5).

Tabla 1. Nivel de respuesta de Grok a las consultas del perfil del proyecto			
	Antes de la verificación	Después de la verificación	Total
Todas las consultas			
Sobre la veracidad	43,9% (61 de 139)	33,1% (46 de 139)	38,5% (107 de 278)
Sobre la fuente	14,4% (20 de 139)	15,1% (21 de 139)	14,7% (41 de 278)
Total	29,1% (81 de 278)	24,1% (67 de 278)	26,6% (148 de 556)
Consultas sobre la veracidad, por formato			
Imágenes y vídeos	40,3% (50 de 124)	29,8% (37 de 124)	35,1% (87 de 248)
Textos (solos, con imagen o captura)	73,3% (11 de 15)	60% (9 de 15)	66,7% (20 de 30)
Consultas sobre la veracidad, por mes de publicación del tuit			
Publicados en junio	57,4% (35 de 61)	52,5% (32 de 61)	54,9% (67 de 122)
Publicados en julio	33,3% (26 de 78)	17,9% (14 de 78)	25,6% (40 de 156)
Consultas sobre la veracidad de imágenes y vídeos, por mes de publicación			
Publicados en junio	54% (27 de 50)	48% (24 de 50)	51% (51 de 100)
Publicados en julio	31,1% (23 de 74)	17,6% (13 de 74)	24,3% (36 de 148)

Nota. Cada tuit recibió dos consultas de cada tipo, una antes y otra después de la verificación; el total suma ambas.

4.2. Exactitud de las respuestas

Cuando responde, Grok acierta en seis de cada diez ocasiones. De las 317 respuestas sobre la veracidad analizadas (107 a consultas propias y 210 a consultas de terceros), referidas a 42 de 46 *claims*², el 59,9% fueron correctas, el 26,8% incorrectas y el 13,2% parcialmente correctas (Tabla 2). Dado que tres *claims* concentran el 36% de las respuestas, esta cifra depende en parte de los contenidos incluidos (IC 95% por remuestreo de *claims*: 46,5-75,4)³; la media de aciertos por *claim*, que da el mismo peso a cada contenido, es del 66,8%. En suma, **entre un tercio y cuatro de cada diez respuestas no fueron correctas**, según cómo se pondere cada contenido.

La exactitud también varía entre categorías temáticas (Tabla 2). “Política y geopolítica” es la única en la que Grok acierta en casi todas las respuestas (93,5%), sin ninguna incorrecta en ninguno de sus diez *claims* y no solo en el que reúne más respuestas (34 de 62)⁴. En el resto de categorías la exactitud es menor y depende en buena

medida de contenidos concretos. Las respuestas incorrectas se concentran en “futbolistas y competición” (46), sobre todo por las [imágenes editadas de Mbappé](#) (30), y en “género y diversidad sexual” (30), cuyos *claims* circulan todos como imágenes o vídeos, en su mayoría generados con IA. En “migración, nacionalidades y etnias” predominan las respuestas parciales (40%), todas sobre el [vídeo de la Federación Egipcia de Fútbol](#); sin él, la exactitud de esta categoría pasaría del 52% al 85,7%. “Corrupción” reúne solo 17 respuestas.

El formato del contenido marca la diferencia más clara entre aciertos y errores. Cuando lo que se verifica es una imagen o un vídeo, Grok acierta en el 49,4% de las respuestas (121 de 245). Cuando es una afirmación escrita, sola, acompañada de una imagen o reproducida en una captura de pantalla, acierta en el 95,8% (69 de 72). Ninguno de los ocho *claims* de afirmaciones escritas recibió una respuesta incorrecta, frente a 18 de los 34 *claims* de imágenes o vídeos⁵ (Tabla 2).

Tabla 2. Exactitud de las respuestas de Grok sobre la veracidad					
	Respuestas	Claims	Correctas	Parciales	Incorrectas
Todas las respuestas					
Total	317	42	190 (59,9%)	42 (13,2%)	85 (26,8%)
Por formato del contenido					
Imágenes y vídeos	245	34	121 (49,4%)	39 (15,9%)	85 (34,7%)
Textos (solos, con imagen o captura)	72	8	69 (95,8%)	3 (4,2%)	0 (0%)
Por categoría temática					
Política y geopolítica	62	10	58 (93,5%)	4 (6,5%)	0 (0%)
Futbolistas y competición	120	11	69 (57,5%)	5 (4,2%)	46 (38,3%)
Migración, nacionalidades y etnias	50	5	26 (52%)	20 (40%)	4 (8%)
Género y diversidad sexual	68	11	30 (44,1%)	8 (11,8%)	30 (44,1%)
Corrupción	17	5	7 (41,2%)	5 (29,4%)	5 (29,4%)

Nota. Respuestas a consultas propias y de terceros. Los porcentajes se calculan sobre las respuestas de cada fila.

Por **tipo de distorsión**⁶ (Anexo II), la exactitud es mayor en los contenidos fabricados (92,7%; 38 de 41), en su mayoría citas y publicaciones inventadas, que en los generados con IA (54,9%; 56 de 102) y los editados (31,4%; 16 de 51). Como estos dos últimos tipos son siempre imágenes o vídeos, su resultado coincide con el del formato.

Grok tampoco es consistente ante un mismo contenido (Figura 2). De los 38 *claims* con más de una respuesta, en 24 alternó respuestas correctas con otras parciales o incorrectas y en 16 llegó a dar **respuestas contradictorias** (correctas e incorrectas).




Figura 2. Respuestas de Grok sobre la veracidad de cada *claim*, agrupadas por categoría temática. *Nota.* Cada círculo representa un *claim* y cada punto una respuesta.

En 15 de esos 16 *claims* la contradicción se produjo antes del desmentido, e incluso dentro de un mismo tuit (y contando solo las respuestas anteriores a la existencia de la verificación); **el veredicto de Grok cambió de una respuesta a otra en la mitad de los casos en los que respondió más de una vez (21 de 40 tuits).**

Por ejemplo, en una de las publicaciones con las [imágenes editadas del rostro de Mbappé](#), en menos de seis horas, Grok las dio por auténticas en tres ocasiones consecutivas, a continuación respondió que los granos se habían añadido digitalmente, después volvió a validarlas en otras tres respuestas (“[Sí, son reales](#)”) y, por último, las identificó de nuevo como manipuladas (Figura 3).




Figura 3. Veredictos de Grok sobre las imágenes editadas de Mbappé en una misma publicación (1 y 2 de julio de 2026, hora peninsular española, antes del desmentido del 3 de julio). *Nota.* Las tarjetas reproducen fragmentos de cada respuesta.

4.3. Tipos de error

El fallo predominante de Grok es **no detectar la manipulación de imágenes y vídeos**. De las 127 respuestas sobre la veracidad incorrectas o parciales, repartidas en 26 *claims*, **81 (63,8%) corresponden a una manipulación visual no detectada**. Por ejemplo, ante un [vídeo sintético](#) de un perro con la camiseta de Brasil, responde “[Sí, parece real](#)” y afirma que no aprecia “[artefactos evidentes de IA](#)”; y ante la [imagen generada con IA](#) de unas supuestas aficionadas alemanas, las describe como asistentes al partido (“[Real fans, real vibes](#)”). En algunos casos Grok no se limita a pasar por alto la manipulación, sino que **añade información y juicios propios**. Ante las imágenes editadas de Mbappé llegó a diagnosticar una “[pseudofoliculitis barbae](#)” y a recomendar productos para tratarla; y ante las aficionadas inexistentes acompañó la respuesta de [comentarios sobre su físico](#).

En 37 de las 245 respuestas sobre imágenes o vídeos (15,1%), **Grok advierte de que las imágenes generadas con IA son prácticamente indistinguibles de las reales y, aun así, emite un veredicto** (Figura 4, derecha), que es parcial en ocho casos e incorrecto, dando por bueno un contenido falso, en 15.

Como segundo tipo de error encontramos **respuestas ambiguas o no concluyentes** (22 de 127; 17,3%), en las que Grok matiza la afirmación a verificar sin confirmarla ni desmentirla. Veinte de ellas se refieren al [vídeo de la Federación Egipcia de Fútbol](#), un contenido real difundido con un encuadre engañoso. Grok describe correctamente el vídeo (la selección recitando una sura del Corán), pero asume el encuadre de la publicación con fórmulas como “[the core claim checks out](#)”, de modo que el error no reside en los hechos, sino en la interpretación que valida.




Figura 4. Ejemplos de manipulación visual no detectada. *Nota. Grok da por auténticos un vídeo y una imagen generados con IA. A la izquierda, “Sí, parece real [...]”. No hay artefactos evidentes de IA”; a la derecha, “Las imágenes generadas con IA son ya prácticamente indistinguibles de las fotos reales [...]”. Pero esta parece auténtica [...]”. Aficionadas reales, buen ambiente”. Traducción propia. Fuente: X.*

A mayor distancia se sitúan las respuestas en las que el modelo fabrica o inventa datos que no existen para sostener su respuesta (10; 7,9%), asume el contexto erróneo con el que circula un contenido real (9; 7,1%), no detecta manipulaciones de audio o subtítulos (4; 3,1%) o atribuye incorrectamente el

origen de un material (1). **El detalle de cada tipo figura en el Anexo I.**

Como la muestra está formada casi por completo por contenidos falsos o engañosos, **casi todos los errores consisten en darlos por buenos** (falsos positivos). Aun así, encontramos cinco falsos

negativos (respuestas en las que el modelo niega algo cierto) referidos a cuatro *claims*. Por ejemplo, Grok negó la autenticidad del [vídeo de la Torre Glòries](#) iluminada con la bandera de España, apelando a una nota de la comunidad que no

constaba en la publicación en el momento de la consulta. También afirmó que la fotografía de [Lionel Messi con Lamine Yamal de bebé](#) era una imagen de archivo sin relación con ambos (Figura 5).




Figura 5. Ejemplos de falsos negativos. *Nota.* Grok niega la autenticidad del vídeo real de la Torre Glòries apelando a una nota de la comunidad que no constaba en la publicación (izquierda) y afirma que la fotografía real de Messi con Lamine Yamal de bebé es “una imagen de archivo sin relación” (derecha). Traducción propia. Fuente: X.

4.4. Fuentes de Grok

Esta parte del análisis considera conjuntamente las **358 respuestas** de Grok, tanto las 317 sobre la veracidad en las que menciona fuentes por iniciativa propia, como las 41 a la consulta específica sobre la fuente. **En dos de cada tres, Grok no indica en qué se apoya (162; 45,3%) o se limita a referencias genéricas que no permiten rastrear la información**, como “[fact-checkers](#)” o “[múltiples reportes](#)” (76; 21,2%). Solo en una de cada tres (120; 33,5%) remite al menos a una fuente identificable.

Las referencias genéricas son también el tipo de fuente más mencionado (38,8% de las 294 menciones), seguidas de las cuentas o publicaciones en redes sociales (16%). Casi la mitad de estas últimas (21 de 47) se refieren a la supuesta [deportación de un jugador iraní](#), en cuyo caso Grok [identificó](#) la cuenta satírica que originó el bulo. Además, **la trazabilidad es limitada**, porque,

cuando Grok nombra la fuente, rara vez enlaza al documento que respalda su respuesta. **Solo diez de las 358 respuestas incluyen una dirección web y únicamente tres remiten a un documento concreto**, todos ellos artículos de prensa [sobre la camiseta de Reyes Maroto](#). Las otras siete llevan a la página principal de una organización, como *Maldita.es*, *Chequeado* o Amnistía Internacional y no a la verificación o al artículo sobre el contenido consultado.

Cuando se le pregunta expresamente por la fuente, Grok contesta solo el 14,7% de las veces (41 de 278), con la misma frecuencia antes y después de la verificación (20 y 21 respuestas). De esas 41 respuestas, 20 fueron correctas (coincidían con la conclusión de la verificación), 15 parciales y seis incorrectas (cinco de ellas sobre contenidos de la categoría “género y diversidad sexual” generados con IA).

Tabla 3. Tipo de fuente mencionada por Grok, en total y antes y después de la verificación			
Tipo de fuente	Total de respuestas (n=358)	Consultas propias antes de la verificación (n=81)	Consultas propias después de la verificación (n=67)
Menciones a fuentes (% sobre el total de menciones de cada columna)			
Referencia genérica no comprobable	114 (38,8%)	23 (28%)	24 (23,5%)
Cuenta o publicación en redes sociales	47 (16%)	12 (14,6%)	10 (9,8%)
Medio de comunicación o agencia	38 (12,9%)	16 (19,5%)	22 (21,6%)
Nota de Comunidad	34 (11,6%)	14 (17,1%)	11 (10,8%)
Organización de verificación	27 (9,2%)	8 (9,8%)	17 (16,7%)
Fuente oficial o institucional	24 (8,2%)	8 (9,8%)	9 (8,8%)
Herramienta de detección de IA	10 (3,4%)	1 (1,2%)	9 (8,8%)
Total de menciones	294 (100%)	82 (100%)	102 (100%)
Respuestas (% sobre el total de respuestas de cada columna)			
Sin ninguna fuente	162 (45,3%)	31 (38,3%)	18 (26,9%)
Solo referencias genéricas	76 (21,2%)	10 (12,3%)	7 (10,4%)
Con alguna fuente identificable	120 (33,5%)	40 (49,4%)	42 (62,7%)
Total de respuestas	358 (100%)	81 (100%)	67 (100%)

Nota. Una misma respuesta puede mencionar varios tipos de fuente, por lo que los porcentajes del primer bloque se calculan sobre el total de menciones y los del segundo, sobre el total de respuestas. La columna «Total» incluye las 358 respuestas (317 sobre la veracidad y 41 sobre la fuente); las columnas de antes y después se limitan a las respuestas a consultas realizadas desde el perfil del proyecto.

El análisis cualitativo de las respuestas incorrectas y parciales también da idea de algunos patrones. **Grok atribuye en ocasiones un origen real a contenidos sintéticos** (sobre un vídeo generado con IA afirma que “[el clip es de la transmisión en vivo del partido Francia vs Noruega \[...\] por FOX](#)”) o **recurre a fuentes reales que no guardan relación con lo que**

se le pregunta (ante ese mismo vídeo nombra a [Al Jazeera](#), [ESPN](#), [la FIFA](#) y [The Athletic](#) para acreditar el resultado del partido, no el origen de las imágenes). En otras, tras [identificar](#) un contenido como generado con IA al preguntarle por la veracidad, [omite](#) ese dato al preguntarle por la fuente (Figura 6).



Figura 6. Respuestas de Grok a la consulta de veracidad (arriba a la derecha) y de la fuente (abajo a la derecha) sobre un mismo tuit de un vídeo generado con IA. Fuente: X.

Las respuestas sobre la veracidad que no mencionan ninguna fuente concentran la mayoría de los errores (Tabla 4)⁷. Grok acierta en el 85,7% de las respuestas que remiten a una fuente identificable, en el 71,8% de las que solo incluyen referencias genéricas y en el 39,4% de las que no mencionan ninguna. De hecho, 76 de las 85

respuestas incorrectas carecen de cualquier referencia. La diferencia se mantiene en las respuestas sobre imágenes y vídeos (78,8% de aciertos con fuente identificable, frente al 34% sin ninguna).

Tabla 4. Exactitud de las respuestas sobre la veracidad según la fuente que menciona Grok				
Fuente mencionada en la respuesta	Respuestas correctas	Respuestas parciales	Respuestas incorrectas	Total de respuestas
Ninguna referencia	61 (39,4%)	18 (11,6%)	76 (49%)	155
Solo referencias genéricas no comprobables	51 (71,8%)	17 (23,9%)	3 (4,2%)	71
Alguna fuente identificable	78 (85,7%)	7 (7,7%)	6 (6,6%)	91
Total general	190 (59,9%)	42 (13,2%)	85 (26,8%)	317

Tras la publicación de la verificación, Grok cita con más frecuencia a organizaciones de verificación y herramientas de detección. Como el resto de comparaciones antes y después, esta se limita a las 148 respuestas a consultas propias (81 antes y 67 después de la verificación), porque las respuestas a terceros son casi todas anteriores a ella. Las respuestas que remiten a una organización

de verificación, como *Maldita.es*, *Chequeado* o *Newtral*, pasan del 9,9% al 25,4%, y las que mencionan una herramienta de detección de IA, de una a nueve, **casi siempre para reproducir el resultado que ya habían obtenido los verificadores**. También aumentan las respuestas con alguna fuente identificable (del 49,4% al 62,7%).

4.5. Respuestas antes y después de la verificación

La existencia de al menos una verificación no se traduce en una mejora clara de la exactitud de las respuestas de Grok. Antes de que se publicara, Grok respondió sobre 61 de los 139 tuits consultados desde el perfil del proyecto y acertó en el 63,9% (39); después, respondió sobre 46 y acertó en el 69,6% (32). Es decir, **tres de cada diez respuestas posteriores a la verificación (14 de 46) fueron incorrectas o parciales cuando ya existía información contrastada**.

La corrección es poco frecuente, **sobre todo porque Grok no vuelve a contestar** (Figura 7). De los 22 tuits con una respuesta previa incorrecta o parcial antes de la verificación, 14 quedaron sin respuesta después, cinco siguieron recibiendo una respuesta errónea o parcial y solo tres recibieron una respuesta correcta. A la vez, Grok cometió nueve errores en tuits que no había respondido antes, cuando el desmentido ya estaba publicado. Esta falta de respuesta coincide con el descenso general de la tasa de respuesta a lo largo del Mundial (apartado 4.1).




Figura 7. Respuesta de Grok a la consulta de veracidad sobre un mismo tuit antes y después de la verificación (consultas propias; $n=139$ tuits)

Dos de los tuits en los que Grok respondió antes y después de la verificación ilustran estos comportamientos (Figura 8). Entre las tres correcciones está el vídeo del comentarista de DSports, cuyo audio manipulado Grok dio inicialmente por auténtico, aunque admitía que podría estar editado, y que tras la verificación

identificó como editado con IA remitiéndose a *Maldita.es*, *Newtral* y AFP. En cambio, ante la imagen generada con IA de un hombre fotografiando a una supuesta aficionada mexicana, Grok respondió “parece una foto real” antes de la verificación y que se trataba de una “foto auténtica” casi dos semanas después de la publicación del desmentido.




Figura 8. Ejemplos de respuestas de Grok a la misma consulta sobre una publicación antes y después de la verificación de *Maldita.es*. Fuente: X.

Donde sí se aprecia un cambio es en las fuentes. Como se indicaba en el apartado anterior, **tras la verificación, las respuestas que mencionan alguna organización de verificación pasan de 8 de 81 a 17 de 67, sobre todo en las respuestas a la pregunta por la fuente (apartado 4.4.).**

En otro orden de cosas, aunque las consultas de terceros no permiten comparar ambos momentos, sí muestran cuándo preguntan los usuarios. Casi todas las consultas se formularon antes de que se publicara la verificación y más de nueve de cada diez

en las 24 horas siguientes a la publicación consultada (Figura 9). Las ocho posteriores se refieren todas a las imágenes editadas de Mbappé y recibieron una respuesta incorrecta entre uno y dos días después del desmentido.




Figura 9. Momento de las consultas de otros usuarios a Grok respecto a la publicación de la verificación de Maldita.es, por claim (n=208 consultas). *Nota.* Cada punto representa la respuesta de Grok a una consulta de otro usuario, coloreada según su exactitud; los puntos con borde negro corresponden a consultas posteriores a la verificación. El eje horizontal indica los días transcurridos desde la primera publicación del contenido; la línea negra marca el momento de publicación de la verificación de Maldita.es. Se excluyen dos consultas sobre la fotografía de Messi con Lamine Yamal de bebé, un contenido verificado años antes de volver a circular.

4.6. Preguntas abiertas vs directas

La exactitud varía según cómo se formula la consulta. Distinguimos dos tipos de consulta. Las directas cuestionan la autenticidad del contenido (“¿es real?”, “is this real?”, “real or AI?”) y suman 242 de las 317 respuestas sobre la veracidad. Las abiertas, en cambio, piden identificar, explicar o traducir el contenido sin cuestionarlo (“who are they?”, “what is this?”, “translate”) y suman 62, todas

de otros usuarios. En las 13 restantes no pudo recuperarse la pregunta, solo su respuesta. Ante las preguntas abiertas Grok responde incorrectamente en el 59,7% de las ocasiones; ante las directas, en el 17,4% (Tabla 5). En cambio, los datos no permiten medir si influye quién pregunta, porque las consultas del perfil del proyecto y las de otros usuarios difieren también en el idioma, la formulación y el momento en que se hicieron.

Tabla 5. Exactitud de las respuestas de Grok según la formulación de la consulta				
Formulación de la consulta	Respuestas correctas	Respuestas parciales	Respuestas incorrectas	Total de respuestas
Directa (pregunta por la veracidad)	160 (66,1%)	40 (16,5%)	42 (17,4%)	242
Abierta (identificación o explicación)	23 (37,1%)	2 (3,2%)	37 (59,7%)	62
Texto no disponible (consulta eliminada)	7 (53,8%)	0 (0%)	6 (46,2%)	13
Total general	190 (59,9%)	42 (13,2%)	85 (26,8%)	317

En los 15 *claims* que recibieron ambos tipos de pregunta, las respuestas incorrectas ante preguntas directas ascienden al 25,9% (28 de 108), pero siguen muy por debajo de las abiertas. La diferencia apunta a que **Grok tiende a asumir la premisa de quien pregunta**. Por ejemplo, frente a contenidos generados con IA o editados, responde de forma incorrecta al 31,4% de las preguntas directas y al 80,5% de las abiertas. Así, **cuando el usuario pregunta quiénes son las personas de una imagen sintética, Grok las describe como reales en lugar de advertir de que no existen** (Figura 10).

Llama la atención que en al menos 17 respuestas sobre imágenes y vídeos de supuestos aficionados generados con IA, Grok no solo trata como reales a personas que no existen, sino que **opina sobre su aspecto físico** (“Those fans are stunning!”), emplea calificativos sexualizados o informales (“[bombshells](#)”, “[teutonas](#) 🔥”, “[heiße Teutonen](#)”) o pregunta al usuario con cuál se queda (“[Which one's your pick?](#)”). Ocurre sobre todo ante preguntas abiertas, pero también ante la consulta directa desde el perfil del proyecto (Figura 10).




Figura 10. Preguntas abiertas de terceros sobre una imagen generada con IA que ya mostraba una nota de la comunidad. *Nota.* Grok identifica a las mujeres como aficionadas reales y comenta su aspecto. Fuente: X.

4.7. El papel de la notas de la comunidad

Parte de las publicaciones ya mostraba una nota de la comunidad cuando se formuló la consulta, lo que permite observar si Grok aprovecha la información contrastada disponible en la propia plataforma. De las 317 respuestas sobre la veracidad, 133 se refieren a publicaciones con nota visible y 184 a publicaciones sin ella (Tabla 6).

Con la nota visible, Grok acierta más: fueron correctas 99 de las 133 respuestas con nota (74,4%), frente a 91 de las 184 sin ella (49,5%). La diferencia también se observa al comparar publicaciones de un mismo *claim* (de los 15 *claims* con publicaciones de ambos tipos, el acierto es mayor con nota en nueve, igual en cuatro y menor en dos).

Sin embargo, esta mayor exactitud no va acompañada de un uso explícito de la nota. Grok

solo la menciona en 26 de las 133 respuestas. En las 107 restantes, que no la mencionan, el acierto es del 71%, todavía muy por encima del 49,5% de las publicaciones sin nota. Es decir, la ventaja se observa también cuando Grok no cita la nota.

Por último, 34 de esas 133 respuestas fueron incorrectas o parciales pese a que el contenido ya estaba advertido, y solo tres de ellas mencionan la nota. La mitad de estas 34 respuestas (17) contestaba a preguntas abiertas. Así, ante la pregunta “¿el audio de este video es original?”, Grok respondió “sí, el audio es el original de la transmisión” bajo una nota que advertía que había sido modificado con IA, y ante la pregunta “¿quién es el modelo?” describió como “un fan anónimo de las gradas” a una persona generada con IA, pese a la nota (Figura 11).




Figura 11. Respuestas de Grok sobre publicaciones que ya mostraban una nota de la comunidad. *Fuente: X.*

Tabla 6. Exactitud de las respuestas de Grok según la presencia de una Nota de Comunidad

Publicación	Respuestas correctas	Respuestas parciales	Respuestas incorrectas	Total de respuestas
Con Nota de Comunidad visible	99 (74,4%)	5 (3,8%)	29 (21,8%)	133
Sin Nota de Comunidad	91 (49,5%)	37 (20,1%)	56 (30,4%)	184
Total general	190 (59,9%)	42 (13,2%)	85 (26,8%)	317

5. Discusión y conclusiones

A tenor de los resultados obtenidos, y en relación con la primera pregunta de investigación (**P1**), que planteaba en qué medida y bajo qué condiciones las respuestas de Grok generan o amplifican desinformación, constatamos que **Grok contesta a una minoría de las consultas recibidas** y que, cuando lo hace, **entre un tercio y cuatro de cada diez respuestas no son correctas** (59,9% de acierto global; 66,8% de media por *claim*). Su acierto parece depender de factores que quien pregunta no controla ni puede conocer de antemano, como el formato del contenido, la información disponible en la red y en la plataforma o la propia variabilidad del modelo.

Los errores se concentran en las imágenes y los vídeos. Todas las respuestas incorrectas se refieren a este tipo de contenido (alcanzando una tasa de acierto de solo el 49,4%, frente al 95,8% en textos o capturas) y la mayoría de los errores consiste en **dar por auténtico un contenido editado o generado con IA**. Incluso en los casos en que el modelo emite advertencias explícitas sobre la dificultad de detectar sintéticos (señalando que son “indistinguibles de la realidad”), la herramienta no se abstiene y emite veredictos erróneos. Este comportamiento concuerda con las limitaciones de los modelos multimodales al evaluar material visual descritas por la investigación reciente, tanto para detectar *deepfakes* y contenido generado con IA (Tariq et al., 2025) como para establecer el contexto, el origen o la procedencia de una imagen (Chandrasekar y Jazwińska, 2025). A ello se suma una variabilidad que resta valor a cualquier respuesta aislada. Ante un mismo contenido y dentro de un mismo hilo, **el veredicto cambia de una consulta a otra sin que medie información nueva**, tal y como ya observó el DFRLab durante el conflicto entre Israel e Irán (Ponce de León y Chenrose, 2025). Cada respuesta de Grok es, por tanto, solo una de las varias ejecuciones posibles, cuya variación depende tanto de la naturaleza estocástica del modelo como de su dependencia de flujos de datos cambiantes en tiempo real, como la aparición sobrevenida de notas de la comunidad o la proliferación de información no verificada, especulativa o en desarrollo que circula en la propia plataforma (Ponce de León y Chenrose, 2025).

Respecto a la segunda pregunta de investigación (**P2**), sobre la evolución de estas respuestas antes y después de que exista información contrastada, **la publicación de una verificación profesional no mejora de forma apreciable la exactitud del chatbot**. Cuando se le volvió a preguntar por publicaciones en las que había dado un veredicto erróneo, rara vez rectificó y el mismo bulo siguió validándose en publicaciones que volvieron a difundirlo tras el desmentido. Los usuarios, en cambio, invocan a Grok casi siempre antes de que exista dicha verificación, justo en la ventana de ventaja temporal que Bobek et al. (2026) identifican respecto a las notas de la comunidad. Estos resultados matizan la advertencia de Renault et al. (2026) sobre la dependencia de los verificadores automáticos respecto de la información disponible. Esa información es una condición necesaria pero no parece suficiente, ya que Grok solo la incorpora de forma ocasional, incluso cuando el desmentido está publicado o la nota es visible en la propia publicación. Con la nota visible acierta más, pero no puede saberse si la tiene en cuenta sin citarla o si las publicaciones con nota difieren del resto, por ejemplo, por ser más virales o llevar más tiempo en circulación.

En lo relativo a la fundamentación y transparencia de las respuestas, **dos de cada tres no remiten a una fuente identificable y casi ninguna (3 de 358) enlaza al documento que sustenta el veredicto**. Sus referencias se aproximan a las “citas ceremoniales” descritas por la EBU y la BBC (2025); es decir, alusiones superficiales o genéricas que sirven para generar una apariencia de rigor pero que **no ofrecen al usuario los elementos necesarios para contrastar la información**. Este déficit de atribución no es solo formal, puesto que **las respuestas sin fuente concentran la mayor parte de los errores**. A ello se suma que Grok declina responder en el 85,3% de las ocasiones en las que le pregunta expresamente por la fuente, de modo que quien quiere saber en qué se basa el veredicto rara vez obtiene una respuesta.

En cuanto a la tercera pregunta (**P3**), que indagaba si las respuestas siguen algún patrón en función de quién y cómo se formula la consulta, los datos muestran variaciones derivadas de la formulación del

prompt. Cuando el usuario no cuestiona el contenido y se limita a pedir que se identifique, explique o traduzca, Grok **tiende a asumir la premisa implícita y lo trata como auténtico**. Lo cual es coherente con lo que Kaur et al. (2024) y Yu et al. (2023) observaron en entornos experimentales sobre la vulnerabilidad de los LLM ante preguntas con presuposiciones falsas y con la complacencia (*sycophancy*) disposicional de los asistentes descrita por Sharma et al. (2024). Las preguntas abiertas revelan asimismo un rasgo que excede la verificación. Por ejemplo, ante las imágenes generadas con IA de supuestas aficionadas, Grok no solo las describe como personas reales, sino que valora su físico, emplea calificativos informales o sexualizados (como “teutonas”) o pregunta al usuario cuál prefiere. Esto se repite con las imágenes generadas de aficionados y las editadas de Mbappé, al que llegó a diagnosticar una afección cutánea y a prescribir tratamiento. Grok adopta así el **rol de un interlocutor conversacional ordinario, recurriendo al “humor” y valoraciones personales**.

Grok no valida todas las publicaciones, pero ante la duda se inclina a dar el contenido por bueno. Esto parece ocurrir cuando el sistema carece de información contrastada, cuando el usuario no pone en duda el contenido e incluso cuando el modelo mismo advierte sobre las limitaciones de la detección (advirtiendo, por ejemplo, de que las imágenes generadas con IA pueden ser “indistinguibles de las reales”). De este modo, **la incertidumbre de Grok no se traduce en abstención ni en cautela, sino en un veredicto que favorece a la desinformación**. Una explicación posible, en línea con lo que observó NewsGuard al incorporar la búsqueda web en tiempo real (Sadeghi, 2025), es que el sistema esté orientado a responder siempre antes que a abstenerse. Como, además, rara vez indica de dónde procede la información y apenas responde cuando se le pregunta por ella, quien consulta carece de elementos para evaluar la fiabilidad del veredicto. El riesgo es que el propio asistente pase a percibirse como una fuente primaria y creíble, en línea con la tendencia a atribuir objetividad a la IA (Sundar y Kim,

2019), cuando en realidad es un intermediario que reprocesa información de terceros. DeVerna et al. (2024) mostraron que incluso las verificaciones dubitativas de un LLM aumentan la credibilidad de los titulares falsos. Cabe esperar que un veredicto que los valida de forma expresa tenga un efecto al menos equivalente, hipótesis que abordará la segunda fase de este proyecto.

Estos resultados tienen implicaciones para el diseño de estos asistentes y para su integración en las plataformas digitales. Ante la alta tasa de fallo en material visual y la ausencia de trazabilidad, la abstención explícita ante la duda resulta preferible a la emisión de veredictos infundados. Asimismo, se requiere priorizar la integración de las verificaciones humanas y las notas de la comunidad ya existentes en la plataforma. Como los usuarios recurren a Grok generalmente antes de que exista una verificación profesional, es precisamente en esa ventana cuando sus errores tienen más margen para circular.

Finalmente, cabe señalar las limitaciones del estudio. Los resultados describen el comportamiento de Grok ante un único evento y periodo acotado, con un corpus dominado por contenidos engañosos y una baja tasa de respuesta cuyos resultados no pueden extrapolarse sin más a otros temas o versiones del modelo. Al incluir solo tres contenidos verdaderos, no permite valorar cómo responde Grok ante información cierta; varios resultados dependen de unos pocos contenidos con muchas respuestas, y las comparaciones entre grupos (por formulación, presencia de notas de la comunidad o momento de la consulta) no se diseñaron para aislar el efecto de cada factor, ya que esos grupos difieren también en otros aspectos. Tampoco permiten conocer el alcance de estas respuestas, cómo las interpretan los usuarios y qué perfiles son más vulnerables a ellas. En la segunda fase del proyecto se pretende ahondar en estas cuestiones mediante experimentos controlados basados en los casos aquí documentados.

6. Notas

- 1 Un mismo *claim* puede circular en varios tuits, por lo que el *claim* es la unidad de contenido verificado y el tuit, la publicación concreta sobre la que se formula cada consulta.
- 2 Los cuatro *claims* restantes no obtuvieron ninguna respuesta de veracidad.
- 3 Intervalo de confianza obtenido por remuestreo (*bootstrap*) de *claims*. Se recalculó el porcentaje de respuestas correctas en 5.000 muestras formadas eligiendo al azar, con reposición, 42 de los *claims* con respuesta, de modo que el intervalo refleja cuánto depende el resultado de los contenidos concretos incluidos en la muestra.
- 4 El claim del jugador iraní Mohammad Mohebbi, supuestamente deportado a Irán tras su celebración en e Mundial.
- 5 La muestra es sobre todo visual (37 de 46 claims) y solo 8 claims escritos tienen respuesta. El resultado se apoya en que se repite en todos ellos, no en el porcentaje.
- 6 El tipo de distorsión describe de qué manera desinforma un contenido (por ejemplo, porque está fabricado, editado, generado con IA o sacado de contexto) y es la clasificación que *Maldita.es* asigna a cada contenido falso en su verificación. Las definiciones de cada tipo figuran en el Anexo II. No se asigna a los contenidos que *Maldita.es* califica como verdadero, contexto o alerta, de acuerdo con su metodología.
- 7 Este análisis se limita a las 317 respuestas sobre la veracidad, ya que en las respuestas sobre la fuente la exactitud depende precisamente de la fuente citada.

7. Referencias

- Augenstein, I., Baldwin, T., Cha, M., Chakraborty, T., Ciampaglia, G. L., Corney, D., DiResta, R., Ferrara, E., Hale, S., Halevy, A., Hovy, E., Ji, H., Menczer, F., Miguez, R., Nakov, P., Scheufele, D., Sharma, S., y Zagni, G. (2024). Factuality challenges in the era of large language models and opportunities for fact-checking. *Nature Machine Intelligence*, 6(8), 852-863. <https://doi.org/10.1038/s42256-024-00881-z>
- Bobek, M., Demirel, E., y Pröllochs, N. (2026). Asking Grok: AI-assisted sensemaking in social media conversations [preprint]. *arXiv*. <https://arxiv.org/abs/2605.19720>
- Boissin, E., Costello, T. H., Spinoza-Martín, D., Rand, D. G., y Pennycook, G. (2025). Dialogues with large language models reduce conspiracy beliefs even when the AI is perceived as human. *PNAS Nexus*, 4(11), pgaf325. <https://doi.org/10.1093/pnasnexus/pgaf325>
- Chae, J. H. y Tewksbury, D. (2026). Perceiving AI intervention does not compromise the persuasive effect of fact-checking. *New Media & Society*, 28(1), 191-211. <https://doi.org/10.1177/14614448241286881>
- Chandrasekar, A. y Jazwińska, K. (2025). Why AI Models Are Bad at Verifying Photos. *Columbia Journalism Review*. https://www.cjr.org/tow_center/why-ai-models-are-bad-at-verifying-photos.php
- Cuartielles, R., Ramon-Vegas, X., y Pont-Sorribes, C. (2023). Retraining fact-checkers: The emergence of ChatGPT in information verification. *Profesional de la información*, 32(5), e320515. <https://doi.org/10.3145/epi.2023.sep.15>
- DeVerna, M. R., Yan, H. Y., Yang, K. C., y Menczer, F. (2024). Fact-checking information from large language models can decrease headline discernment. *Proceedings of the National Academy of Sciences*, 121(50), e2322823121. <https://doi.org/10.1073/pnas.2322823121>
- EBU y BBC (2025). News integrity in AI assistants: An international PSM study. *European Broadcasting Union*. <https://www.ebu.ch/research/open/report/news-integrity-in-ai-assistants>

- Egan, J., Robertson, C. T., Ross Arguedas, A., Newman, N., Nielsen, R. K., Mukherjee, M., y Fletcher, R. (2026). *Reuters Institute Digital News Report 2026*. https://reutersinstitute.politics.ox.ac.uk/sites/default/files/2026-06/DNR%202026%20FINAL_2.pdf
- Graves, L. (2017). Anatomy of a fact check: Objective practice and the contested epistemology of fact checking. *Communication, culture & critique*, 10(3), 518-537. <https://doi.org/10.1111/cccr.12163>
- Hackenburg, K., Tappin, B. M., Hewitt, L., Saunders, E., Black, S., Lin, H., Fist, C., Margetts, H., Rand, D. G., y Summerfield, C. (2025). The levers of political persuasion with conversational artificial intelligence. *Science*, 390(6777), eaea3884. <https://doi.org/10.1126/science.aea3884>
- Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y. J., Madotto, A y Fung, P. (2023). Survey of hallucination in natural language generation. *ACM computing surveys*, 55(12), 1-38. <https://doi.org/10.1145/3571730>
- Kaplan, J. (2025, 7 de enero). *More speech and fewer mistakes*. Meta. <https://about.fb.com/news/2025/01/meta-more-speech-fewer-mistakes/>
- Kaur, N., Choudhury, M., y Pruthi, D. (2024). Evaluating large language models for health-related queries with presuppositions. En *Findings of the Association for Computational Linguistics: ACL 2024* (pp. 14308-14331). <https://doi.org/10.18653/v1/2024.findings-acl.850>
- Kim, N., Htut, P. M., Bowman, S. R., y Petty, J. (2023). (QA)²: Question answering with questionable assumptions. En *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* (pp. 8466-8487). <https://doi.org/10.18653/v1/2023.acl-long.472>
- Lin, H., Czarnek, G., Lewis, B., White, J. P., Berinsky, A. J., Costello, T., Pennycook, G., y Rand, D. G. (2025). Persuading voters using human-artificial intelligence dialogues. *Nature*, 648(8093), 394-401. <https://doi.org/10.1038/s41586-025-09771-9>
- López Pan, F., y Rodríguez Rodríguez, J. M. (2020). El Fact Checking en España. Plataformas, prácticas y rasgos distintivos. *Estudios sobre el mensaje periodístico*, 26(3), 1045. <http://dx.doi.org/10.5209/esmp.65246>
- Maldita.es (2022, 17 de noviembre). *41 bulos, desinformaciones y datos sobre el Mundial de Fútbol de Catar de 2022*. <https://maldita.es/malditobulo/20221117/bulos-mundial-futbol-catar/>
- Mei, K. X., Wolfe, R., Weber, N., y Saveski, M. (2026, May). Grok in the wild: Characterizing the roles and uses of large language models on social media. In *Proceedings of the International AAAI Conference on Web and Social Media* (Vol. 20, No. 1, pp. 1609-1633). <https://doi.org/10.1609/icwsm.v20i1.42715>
- Ponce de León, E. y Chenrose, A. (2025). Grok struggles with fact-checking amid Israel-Iran war. *DFRLab*. <https://dfrlab.org/2025/06/24/grok-struggles-with-fact-checking-amid-israel-iran-war/>
- Qazi, I. A., Khan, Z., Ghani, A., Raza, A. A., Qazi, Z. A., Sajjad, W., Ali, A., Javaid, A., Sohail M.A., y Azeemi, A. H. (2026). Large language models show Dunning-Kruger-like effects in multilingual fact-checking. *Scientific Reports*, 16(1), 7594. <https://doi.org/10.1038/s41598-026-39046-w>
- Quelle, D., y Bovet, A. (2024). The perils and promises of fact-checking with large language models. *Frontiers in Artificial Intelligence*, 7, 1341697. <https://doi.org/10.3389/frai.2024.1341697>
- Renault, T., Mosleh, M., Lin, H., Pennycook, G., y Rand, D. G. (2026). Fact-checking using AI [preprint]. *PsyArXiv*. https://doi.org/10.31234/osf.io/85quw_v5
- Ross Arguedas, A. (2026, 16 de junio). *Nuevos usos de los chatbots de IA en las noticias y lo que suponen para el periodismo*. <https://reutersinstitute.politics.ox.ac.uk/es/digital-news-report/2026/usos-de-chatbots-ia-en-noticias-y-periodismo>
- Sadeghi, M. (2025). *AI false information rate nearly doubles in one year*. NewsGuard. <https://www.newsguardtech.com/ai-monitor/august-2025-ai-false-claim-monitor/>
- Sharma, M., Tong, M., Korbak, T., Duvenaud, D., Askeel, A., Bowman, S., Durmus, E., Hatfield-Dodds, Z., Johnston, S., Kravec, S., Maxwell, T., McCandlish, S., Ndousse, K., Rausch, O., Schiefer, N., Yan, D., Zhang, M., y Perez, E. (2024). Towards understanding sycophancy in language models. En *International Conference on Learning Representations* (Vol. 2024, pp. 110-144).
- Sundar, S. S. (2008). *The MAIN model: A heuristic approach to understanding technology effects on credibility*. En M. J. Metzger y A. J. Flanagin (Eds.), *Digital media, youth, and credibility* (pp. 73-100). MIT Press. <https://doi.org/10.1162/dmal.9780262562324.073>
- Sundar, S. S., y Kim, J. (2019). Machine heuristic: When we trust computers more than humans with our personal information. En *Proceedings of the 2019 CHI Conference on human factors in computing systems* (pp. 1-9). <https://doi.org/10.1145/3290605.3300768>

Tariq, S., Nguyen, D., Chamikara, M. A. P., Wu, T., Abuadbbba, A., y Moore, K. (2025). Llms are not yet ready for deepfake image detection. *arXiv preprint arXiv:2506.10474*.

<https://doi.org/10.48550/arXiv.2506.10474>

Torres, M. J. F., Ballester, C. C., y Hernández, A. I. I. (2026). Fake News and Football. The Qatar World Cup as a Showcase for Disinformation. *Tripodos*, (60), 02-02.

<http://www.doi.org/10.51698/tripodos.2026.60.02>

Wang, D., Tsang, S. J., y Zhou, Y. (2026). Performance unfairness of large language models in cross-language fact-checking. *Information Processing & Management*, 63(4), 104616. <https://doi.org/10.1016/j.ipm.2026.104616>

Yu, X., Min, S., Zettlemoyer, L., y Hajishirzi, H. (2023). CREPE: Open-domain question answering with false presuppositions. En *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* (pp. 10457-10480).

<https://doi.org/10.18653/v1/2023.acl-long.583>

8. Anexos

Anexo I. Tipología de errores

Recoge los seis tipos de error codificados en las 127 respuestas incorrectas o parciales de Grok. Los ejemplos reproducen fragmentos literales de respuestas de Grok.

Tipo de error	Definición	Respuestas (n= 127)	Ejemplo
Manipulación visual no detectada	Grok trata como auténtica una imagen o un vídeo editado o generado con IA.	81 (63,8%)	Sobre una imagen generada con IA de unas aficionadas alemanas: «La imagen parece real. Es una foto de fans en las gradas durante el partido Alemania vs Curazao [...]. Se ve natural, con detalles del estadio, otras personas y sin artefactos claros de IA».
Respuesta ambigua / no concluyente	La respuesta matiza o reinterpreta la afirmación sin confirmarla ni desmentirla con claridad, o no ofrece un veredicto claro.	22 (17,3%)	Sobre el vídeo de la Federación Egipcia de Fútbol, ante la pregunta «¿es cierto?»: «Sí, en gran parte es cierto con matices interpretativos. [...] La tafsir clásica interpreta los versos finales de Al-Fatiha como referencia a judíos (“los que incurrieron en ira”) y cristianos (“los extraviados”). El vídeo no muestra maldiciones explícitas, es una oración estándar».
Contenido fabricado / inventado	Grok aporta hechos, declaraciones o respaldos documentales que no existen, o niega un hecho cierto con argumentos inventados.	10 (7,9%)	Sobre el vídeo, auténtico, de la Torre Glòries iluminada con la bandera de España: «No, no es real. El vídeo que circula es falso o manipulado. [...] Usuarios locales de Barcelona lo desmienten y la nota comunitaria ya lo señala».
Contexto falso	Grok sitúa un contenido real en un momento, lugar o acontecimiento que no le corresponde.	9 (7,1%)	Sobre un vídeo de la afición del Málaga CF difundido como hinchas argentinos en el Mundial, ante la pregunta «¿es real?»: «La pasión de la hinchada argentina es de las más intensas del mundo, sobre todo en fútbol. El vídeo muestra multitudes desbordantes de energía y lealtad. [...] Pero sí, está en la élite y el vídeo lo hace sentir real. ¡Impresionante!».
Manipulación de audio o subtítulos no detectada	Grok da por auténticos un audio, una traducción o unos subtítulos alterados.	4 (3,1%)	Sobre un vídeo de Haaland con subtítulos manipulados, ante la petición sobre lo que dice, Grok reproduce como traducción el texto falso de los subtítulos («...que aún hoy ocupa su territorio de forma ilegítima») y añade: «El vídeo ya trae subtítulos en español que coinciden con esto».
Atribución incorrecta	Grok identifica erróneamente el origen o el contenido de un material.	1 (0,8%)	Sobre el vídeo de la Federación Egipcia de Fútbol, ante la pregunta «what do you hear here?», Grok identifica el recitado como las suras Al-Falaq y An-Nas, cuando el vídeo recoge las suras Al-Fatiha y Al-Ikhlâs.

Anexo II. Tipos de distorsión

Clasificación que *Maldita.es* asigna a cada contenido en su verificación, con el número de *claims* de la muestra, las respuestas de Grok sobre su veracidad y cuántas de ellas fueron correctas. El tipo de distorsión sólo se asigna a los contenidos calificados como falsos o manipulados; el resto se agrupan bajo la categoría otros.

Tipo	Definición	Claims	Respuestas	Correctas
Tipos de distorsión (contenidos falsos/manipulados)				
Contenido generado con IA <i>AI content</i>	Contenido creado o alterado mediante herramientas de inteligencia artificial	17	102	56 (54,9%)
Contenido editado <i>Edited content</i>	Material auténtico que ha sido alterado digitalmente (retoque, montaje, sin indicios de uso de IA)	2	51	16 (31,4%)
Contenido fabricado <i>Fabricated</i>	Contenido inventado por completo para parecer auténtico: citas, publicaciones o hechos que nunca existieron. Fuertemente asociado a una intencionalidad desinformadora	6	41	38 (92,7%)
Contenido mal atribuido / descontextualizado <i>Mislabeled, misattributed or misidentified content</i>	Material real que se presenta con un autor, lugar, fecha o acontecimiento que no le corresponde	5	23	10 (43,5%)
Contenido engañoso <i>Misleading content</i>	Información basada en elementos reales pero presentada de forma que induce a una conclusión falsa o puede dar lugar a engaño	2	7	7 (100%)
Tipos combinados	Contenidos con más de un tipo asignado: engañoso y generado con IA; atribución errónea y generado con IA; sátira tomada como cierta y contenido fabricado	3	42	39 (92,9%)
Otros				
Necesita contexto	Asunto con múltiples aristas sobre el que es necesario aportar información, o que está pendiente de una investigación o de un proceso que no permite darlo por concluido	6	45	20 (44,4%)
Alerta	Contenido del que no existen pruebas de su veracidad, pero sobre el que no hay fuentes independientes suficientes para afirmar que es falso	2	2	2 (100%)
Verdadero	Contenido del que hay evidencias suficientes para probar que es cierto	3	4	2 (50%)
Total		46	317	190 (59,9%)

Anexo III. Criterios de codificación

Categoría	Criterio
Exactitud de la respuesta (sobre la veracidad y sobre la fuente)	
Correcta	La respuesta coincide con la conclusión de la verificación
Parcial	La respuesta acierta en parte: no se pronuncia con claridad, omite un elemento esencial o combina información correcta con información errónea
Incorrecta	La respuesta contradice la conclusión de la verificación
Sin respuesta	Grok no contestó a la consulta
Formulación de la consulta*	
Directa	La consulta pregunta por la autenticidad o la veracidad del contenido (“¿es real?”, “is this real?”, “real or AI?”)
Abierta	La consulta pide identificar, explicar o traducir el contenido sin cuestionarlo (“who are they?”, “what is this?”, “translate”).
No disponible	La consulta había sido eliminada y no pudo recuperarse su texto, solo la respuesta de Grok
Fuente mencionada en la respuesta*	
Ninguna	La respuesta no remite a ninguna fuente
Genérica	Solo incluye alusiones que no pueden comprobarse (“fact-checkers”, “verificaciones independientes”)
Identificable	Nombra un medio, una organización, una institución, una cuenta o un documento concretos que permiten comprobar la información
Tipo de fuente mencionada en la respuesta* (no excluyentes)	
Medio de comunicación / agencia	Cita un medio o una agencia de noticias identificados por su nombre
Organización de verificación	Cita una organización de verificación de datos
Cuenta o publicación en redes sociales	Remite a un perfil o a una publicación concreta en una red social
Fuente oficial o institucional	Remite a un organismo, una institución o un canal oficial
Nota de la comunidad	Remite a la nota visible en la publicación
Herramienta de detección	Remite a una herramienta de detección de contenido generado con IA, como SynthID o Hive
Referencia genérica	Alude a fuentes que no pueden comprobarse, como “múltiples reportes” o “el metraje oficial”
No cita fuente	No remite a ninguna fuente, bien porque reconoce no haberla encontrado, bien porque se limita a emitir un veredicto
Formato del contenido*	
Imagen	El contenido verificado es una fotografía o una imagen estática
Vídeo	El contenido verificado es un vídeo
Texto	La afirmación a verificar circula únicamente como texto
Texto + imagen	La afirmación circula como texto acompañado de una imagen
Captura de pantalla	El contenido es la captura de una publicación, un mensaje o una emisión
Nota de la comunidad	
Presente	La publicación mostraba una nota visible en el momento de la consulta
Ausente	La publicación no mostraba ninguna nota visible en el momento de la consulta

Nota. Las variables con asterisco se codificaron durante el análisis sobre el corpus ya recogido.

Anexo IV. Relación de contenidos analizados

Relación de los 46 *claims* de la muestra, agrupados por categoría temática. Para cada uno se indican el tipo de distorsión o la calificación asignada por *Maldita.es*, el formato mayoritario en el que circularon, el número de tuits analizados en los que circulaba y el número de respuestas de Grok sobre su veracidad, desglosadas en correctas (C), parciales (P) e incorrectas (I). El título de cada contenido enlaza con la verificación de *Maldita.es*. Los 144 tuits incluyen los 139 consultados desde el perfil del proyecto y otros cinco que difundían alguno de esos mismos *claims* y en los que solo se recogieron consultas de otros usuarios.

N.º	Contenido	Tipo de distorsión o calificación	Formato	Tuits	Resp.	C/P/I
Futbolistas y competición (13 claims)						
1	Estas imágenes muestran el rostro de Mbappé durante el Francia-Suecia del Mundial	Editado	Imagen	9	44	14/0/30
2	Cristiano Ronaldo se comentó a sí mismo en Instagram: "Ánimo Cristiano, eres el mejor jugador del Mundial aunque tu equipo no te esté ayudando"	Fabricado	Captura de pantalla	3	19	19/0/0
3	Este vídeo muestra un homenaje a Cristiano Ronaldo con drones en Madeira	Generado con IA	Vídeo	3	16	16/0/0
4	Este vídeo muestra el Estadio BBVA en Monterrey durante el partido Suecia-Túnez del Mundial	Generado con IA	Vídeo	2	10	4/0/6
5	Este vídeo muestra a un perro vestido de Brasil en el partido contra Francia del Mundial	Generado con IA	Vídeo	2	9	6/0/3
6	El jugador de fútbol noruego Haaland quiere que Argentina gane el mundial	Atribución errónea	Vídeo	4	7	2/3/2
7	Este vídeo muestra a aficionados de Argentina en Times Square durante el Mundial	Atribución errónea	Vídeo	5	5	2/0/3
8	Esta imagen muestra a Cristiano Ronaldo y Georgina Rodríguez llorando en un coche tras eliminar España a Portugal del Mundial 2026	Generado con IA	Imagen	8	3	3/0/0
9	Este vídeo muestra a la afición de Argentina en el Mundial 2026	Atribución errónea	Vídeo	2	3	0/2/1
10	Este vídeo muestra a Haaland comiendo durante el Mundial	Fabricado	Vídeo	3	2	2/0/0
11	Lionel Messi se hizo una foto para un calendario solidario con Lamine Yamal de bebé	Verdadero	Imagen	4	2	1/0/1
12	Chica en Estados Unidos se encuentra un libro en la librería que predecía que la final del Mundial 2026 sería España-Argentina y que España ganaba	Necesita contexto	Imagen	1	0	-
13	La televisión brasileña enfoca a Valverde en un partido de Uruguay del Mundial mientras anuncia al lado uno de Francia con una imagen de Tchouameni a puños	Necesita contexto	Captura de pantalla	1	0	-
Política y geopolítica (11 claims)						
14	El jugador iraní Mohammad Mohebbi ha sido deportado a Irán tras su celebración en el Mundial simulando disparar contra Nueva Zelanda	Engañoso + generado con IA	Texto e imagen	2	34	32/2/0
15	Folarin Balogun celebró un gol en el partido Estados Unidos-Paraguay del Mundial mostrando una camiseta del activista Charlie Kirk	Sátira + fabricado	Imagen	1	5	5/0/0
16	Noruega gana a Israel 5-0 y donará los ingresos del partido a Palestina	Atribución errónea	Texto	1	5	5/0/0

N.º	Contenido	Tipo de distorsión o calificación	Formato	Tuits	Resp.	C/P/I
17	Esta imagen muestra a Lamine Yamal con la bandera de Palestina tras ganar el Mundial 2026	Generado con IA	Imagen	1	4	4/0/0
18	Cazan a Reyes Maroto con una camiseta falsa de España tras defender la lucha contra la piratería como ministra	Necesita contexto	Imagen	5	3	2/1/0
19	La cuenta oficial de X del PSOE celebra un gol de Marruecos	Fabricado	Captura de pantalla	1	3	3/0/0
20	La selección de Irán llevó mochilas escolares a un partido del Mundial para homenajear a las niñas asesinadas por Estados Unidos	Atribución errónea + generado con IA	Imagen	2	3	2/1/0
21	El futbolista sueco Lucas Bergvall dice: "A todas las mujeres que están enamoradas de mí, por favor, dejen de votar por la migración masiva, o mi pueblo dejará de existir"	Engañoso	Vídeo	1	2	2/0/0
22	Luis Díaz y Daniel Muñoz celebran un gol de Colombia en el Mundial haciendo el saludo "firmes por la patria" de Abelardo De La Espriella	Fabricado	Vídeo	2	2	2/0/0
23	Gianni Infantino: "Estamos al tanto del mensaje político mostrado por Argentina. Entendemos que va en contra de las reglas, pero también sabemos que se trata de un asunto de su nacionalidad y lo respetamos"	Alerta	Texto	1	1	1/0/0
24	Esta imagen muestra a un aficionado de Alemania disfrazado de Adolf Hitler en el Mundial	Generado con IA	Imagen	1	0	–
Género y diversidad sexual (12 claims)						
25	Esta imagen muestra a unas aficionadas alemanas en el partido Alemania-Curazao del Mundial 2026	Generado con IA	Imagen	6	18	2/1/15
26	Este vídeo muestra a una mujer mirando a un aficionado sin camiseta en el partido Noruega-Israël	Generado con IA	Vídeo	4	9	4/1/4
27	Esta imagen muestra a una aficionada mexicana mirando a un aficionado inglés durante el partido México-Inglaterra del Mundial 2026	Fabricado	Imagen	7	8	7/1/0
28	Esta imagen muestra a una aficionada de Brasil en un partido del Mundial	Generado con IA	Imagen	3	6	2/2/2
29	En el partido Inglaterra - Noruega las cámaras pillaron en la grada a una mujer mirando a un hombre sin camiseta	Generado con IA	Vídeo	4	5	2/0/3
30	Esta imagen muestra a un señor fotografiando a una aficionada mexicana en el Mundial	Generado con IA	Imagen	5	5	2/0/3
31	Este vídeo muestra a una espectadora bebiendo agua en un partido del Mundial	Generado con IA	Vídeo	2	5	4/1/0
32	Este vídeo muestra a una espectadora en el partido Noruega-Francia del Mundial 2026	Generado con IA	Vídeo	2	5	1/1/3
33	Esta imagen muestra a una aficionada brasileña en el Brasil-Marruecos del Mundial	Generado con IA	Imagen	2	3	2/1/0
34	Esta imagen muestra a Ancelotti con tres mujeres brasileñas en el Mundial	Generado con IA	Imagen	1	2	2/0/0
35	Este vídeo muestra a una aficionada alemana en el partido Alemania-Curazao del Mundial	Generado con IA	Vídeo	1	2	2/0/0
36	Esta imagen muestra a un aficionado sin camiseta en el Brasil-Japón del Mundial	Generado con IA	Imagen	1	0	–
Corrupción (5 claims)						

N.º	Contenido	Tipo de distorsión o calificación	Formato	Tuits	Resp.	C/P/I
37	Esta imagen muestra el pisotón de Messi a Died Spence en la jugada del segundo gol de Argentina ante Inglaterra en el Mundial	Editado	Imagen	9	7	2/3/2
38	Slavko Vincic, árbitro del España - Argentina, fue detenido por narcotráfico, prostitución y tráfico de armas	Necesita contexto	Texto	2	4	3/1/0
39	Este vídeo muestra la reacción de decepción de Infantino tras el segundo gol de Egipto contra Argentina	Atribución errónea	Vídeo	6	3	1/0/2
40	Los colores de los fuegos artificiales de la final eran albicelestes	Necesita contexto	Vídeo	1	2	1/1/0
41	La Torre Agbar (Glòries) se iluminó con la bandera de España y la palabra "campeones" el 16 de julio de 2026	Verdadero	Vídeo	3	1	0/0/1
Migración, nacionalidades y etnias (5 claims)						
42	La Federación Egipcia de Fútbol publicó un vídeo en el que afirma abiertamente que la clave de la victoria es comenzar el partido insultando a cristianos y judíos	Necesita contexto	Vídeo	5	36	14/20/2
43	Un comentarista de DSport dice "esta negra quién es" cuando enfocan a la cantante Ciara en un partido del Mundial	Fabricado	Vídeo	3	7	5/0/2
44	Aficionados alemanes inician una recogida de firmas para exigir que futbolistas africanos y musulmanes no puedan volver a representar a la selección alemana de fútbol	Engañoso	Texto	3	5	5/0/0
45	Dani Olmo llamó "simios de mierda" a los jugadores de Argentina y provocó la reacción de Ayala	Alerta	Texto	1	1	1/0/0
46	El árbitro que pitó el partido entre Francia y España del Mundial llevaba un crucifijo colgado del silbato	Verdadero	Imagen	8	1	1/0/0
Total				144	317	190/42/85

