


Misoginia, pornografía y estereotipos malignos



El problema no es sólo
cómo se usa, sino cómo se
entrena una IA generativa

Grok, remove her clothes

La plataforma X/Twitter (de Elon Musk), a través de su IA generativa, GROK, habilitó opciones para **DESNUDAR** personas, especialmente mujeres, y así **generar fácilmente material de acoso sexual**.



Capturas de la plataforma X (ex Twitter) realizadas el día 29 de diciembre de 2025
GROK generó imágenes sexualizadas de Taylor Swift a pedido de un usuario



Muchos hombres estaban instrumentalizando Grok para desnudar a mujeres. Y Grok, **por cómo está diseñada**, lo está permitiendo.

No importa el tipo de foto, pues los usuarios están pidiendo desvestir tanto a mujeres que suben fotos en bikini como a las que suben fotos mucho más cubiertas.

Investigadoras como Kolina Koltai ponen el acento en **el propio diseño de esta IA, que sería proclive a permitir este uso misógino.**



"Grok, remove her clothes": así permite la IA de Musk desnudar a mujeres reales a petición de usuarios | Noemí López Trujillo | Newtral 2025



Grok fue entrenada para generar este tipo de contenidos

«**Trabajadores de xAI**, la empresa desarrolladora de Grok, afirmaron haber encontrado contenido no apto para el trabajo (NSFW), incluyendo **material de abuso sexual infantil (CSAM) generado por IA, durante el proceso de entrenamiento** y anotación del modelo»

Business Insider mantuvo conversaciones con más de 30 trabajadores y extrabajadores de xAI. Doce de esos empleados afirmaron haber encontrado tanto **contenido sexualmente explícito como indicaciones escritas para generar AI CSAM en sus servicios.**

Si bien este accionar se hizo visible ahora por la proliferación de contenido sintético con imágenes y videos sexualizando mujeres y menores de edad en X, **esto es algo que venimos denunciando desde hace mucho tiempo.**

A muchas mujeres ya las venían desnudando desde plataformas como Civitai porque **así operan desde el inicio las empresas de IA generativa comercial, como xAI, de Elon Musk, OpenAI, Midjourney, StabilityAI, etc.**



OLIVIA SNOW

IDEAS DEC 7, 2022 9:33 AM

'Magic Avatar' App Lensa Generated Nudes From My Childhood Photos

The dreamy picture-editing AI is a nightmare waiting to happen.

I then embarked on what I knew would be a journey through hell, and decided to use my likeness to test the app's other restriction: "No kids, adults only." (Some of the results are below: Please be aware that they show sexualized images of children.)




ILLUSTRATION: OLIVIA SNOW VIA LENSEA

The results were horrifying.




ILLUSTRATION: OLIVIA SNOW VIA LENSEA

In some instances, the AI seemed to recognize my child's body and mercifully neglected to add breasts.


«La tecnología de Lensa se basa en **Stable Diffusion**, según su política de privacidad. **Stable Diffusion utiliza una base de datos llamada LAION-5B**, para entrenar su IA» CNN cultura - Diciembre 2022



Una investigación realizada en 2023 por un equipo de la Universidad de Washington descubrió que los modelos de IA generativa, como **Midjourney**, **DALL-E 2** y **Stable Diffusion**, incorporan sesgos que cosifican sexualmente a las mujeres, lo que luego se refleja en las imágenes que producen.



Remove Background



Midjourney

full body::1.5, zoomed out, a beautiful young female, [profile view], [slightly wet from a shower] [big chest, big chest], [long wavy hair], [wet lipgloss], [natural outdoor lighting], holding towel around body, painted finger-nails, cute slender belly, beautiful thighs:1.5, [wide view from the side], detailed features, in bathroom, natural outdoor lighting, hyper-realistic, real life picture, full

AI image generator Midjourney blocks porn by banning words about the human reproductive system | Melissa Heikkilä | MIT Technology Review 2023



Desde 2020-2021 se viene denunciando este tipo de contenidos como material de entrenamiento de los *datasets* que usan las empresas desarrolladoras de los modelos comerciales de IA generativa.

Si la entrenan con esa clase de contenidos, **buscan generar esa clase de contenidos.**

Warning:
Blurred **NSFW images** and the associated offensive textual content below




Figure 8: Blurred image screenshots capturing search result obtained from the **LAION-400M dataset** in response to Latina (a) and Black Woman (b) respectively.

«Examinamos el conjunto de datos LAION-400M, que es un conjunto de datos, filtrado por *CLIP*, de pares de imágenes y texto alternativo analizados a partir del conjunto de datos *Common-Crawl*. Descubrimos que el conjunto de datos contiene pares de imágenes y textos problemáticos y explícitos sobre:

**violaciones,
pornografía,
estereotipos malignos,
insultos racistas y étnicos,
y otros contenidos extremadamente
problemáticos»**




Midjourney models are trained on LAION 400m




Screenshots

In the below screenshots, the Orange names are Midjourney Devs talking about datasets.



This is David Holz, CEO of Midjourney.

Fuente / Source:



Create don't scrape website | Pre-trained Models

By: Benjamin Harbakk. Additional information sourced from Margaret Mitchell



Enero 2024

The Daily Dot creó una cuenta en Midjourney y tras varias indicaciones, como «fotos de fiesta en la playa» e incluso «fotos de fiesta en la playa con poca ropa», **generaron múltiples imágenes realistas de mujeres con sus pechos desnudos.**



Midjourney wants people to flag inappropriate AI art—it's banning researchers who do just that | Mikael Thalen | **DailyDot 2024**



«Al recopilar datos de la web para crear estos conjuntos de datos, surgen cuestiones relacionadas con **la propiedad y los derechos sobre los datos**. Algunos de estos datos, especialmente los datos de imágenes, **pueden estar «disponibles» públicamente, pero recopilarlos y crear un gran conjunto de datos con ellos es otra cuestión.**

Como hemos descubierto, **algunos de estos datos son totalmente ilegales;** por ejemplo, imágenes que capturan un momento de profundo trauma para los sujetos que aparecen en ellas: **abuso sexual, violación, etc.**

Además, **estos conjuntos de datos se recopilan sin el consentimiento y el conocimiento del sujeto de los datos.**

Entonces, surge la pregunta: **¿se debe difundir un conjunto de datos recopilado de esta manera y, en caso afirmativo, ¿cómo?»**

«Encontramos una proporción significativamente alta de resultados no aptos para el trabajo (NSFW) que **contenían descripciones explícitas de violencia sexual y otras imágenes perturbadoras.**

Incluso **el más mínimo vínculo con la feminidad** o algún aspecto de lo que tradicionalmente se concibe como femenino **arrojaba imágenes pornográficas»** **XXX**



Abeba Birhane

@Abebab

We are not putting pornography in the same bucket as rape tho. We don't oppose pornography but the representation of women through explicit pornographic imagery

10:37 AM · Oct 7, 2021

«Por ejemplo, cuando se buscaron adjetivos descriptivos como *grande* y *pequeño*, términos como *asiático*, *indio* y *nigeriano*, términos de relación como *tía* y *mamá*, o indicadores demográficos como *latina* y *mujer negra*; todas ellas **devolvieron imágenes claramente procedentes de sitios web pornográficos**»




Figure 14: Collage of image screenshots capturing search results obtained from the *clip-retrieval visual front-end portal* to the LAION-400M dataset in response nationality related search terms such as 'Indian' and 'Korean'.

«¿Son las grandes redes neuronales un nuevo medio de distribución de materiales ilícitos?»

«Se sabe que **las grandes redes neuronales “memorizan”** algunas muestras de datos tal cual, incluso si sólo aparecen una vez en todo el conjunto de datos.

DIFFUSION DE DUPLICADOS

Original:



Generated:



Existe la posibilidad de que un gran modelo de IA multimodal **“memorice” directamente una muestra de datos que sea ilegal (por ejemplo, abuso sexual, violación, etc.)**. Por lo tanto, puede darse una situación en la que **un modelo de IA multimodal no solo genere contenido explícito, sino también contenido ilegal»**

«Aunque un modelo de IA no “memorice” directamente las muestras, la figura 18 muestra que pueden surgir unidades **que capturen contenidos ilícitos y perjudiciales de forma sólida y recuperable**»




Figure 18: Feature visualization of channel Unit 1543 (image_block_4_5_Add_6_0) of the CLIP-Resnet-50-4x model and the text that maximizes the dot product with 1543-neuron on the left.

Hay que dejar de pensar en los modelos comerciales de IAG como «herramientas» que dependen del uso que se les dé.

Hace mucho que avisamos sobre este tipo de contenidos dentro de los *datasets* que usan las empresas para entrenar sus sistemas de IA generativa.

Si la entrenan con esa clase de contenidos, **buscan generar esa clase de contenidos.**

Manifiesto • Arte es Ética

en defensa de los DDHH frente a la IA generativa

FIRMA NUESTRO
MANIFIESTO



Unámonos para proteger nuestros
derechos y nuestro trabajo frente
a esta tecnología invasiva.

