



# ¿La IA Generativa infringe los derechos de autor de los artistas?

**Cristian Daniel Avila Montoya**  
**MC Alma E. Martínez Licona**  
*Universidad Autónoma Metropolitana - Iztapalapa*

## Introducción

Imaginemos que surge una idea clara y precisa para una imagen que deseamos crear. Nos acercamos a las fronteras de la tecnología con herramientas como DALL-E 3, una de las innovaciones más destacadas en inteligencia artificial generativa que ha capturado múltiples miradas. Estas herramientas tienen la asombrosa capacidad de transformar conceptos en imágenes en cuestión de segundos. Introducimos una descripción detallada y, casi mágicamente, se genera una imagen que representa visualmente tu idea.

Sin embargo, aquí es donde las cosas se ponen interesantes. ¿Podemos decir realmente que la imagen creada es nuestra? Desde la introducción de DALL-E 2 en abril de 2022, el debate sobre la inteligencia artificial generativa se ha intensificado. Los artistas y diseñadores han expresado su preocupación ante la apropiación de sus obras por parte de corporaciones tecnológicas sin su consentimiento explícito. Dichas empresas han utilizado trabajos publicados para entrenar sus modelos generativos a gran escala, lo que plantea un dilema ético significativo, dado que los resultados de estos modelos generativos entran en competencia directa con los creadores originales en el mercado.

El tema va más allá de si la inteligencia artificial es capaz de producir arte o ser creativa. Actualmente, nos enfrentamos a desafíos legales y éticos más complejos, como la determinación de si el uso de herramientas de IA generativa constituye una forma de plagio. ¿Están las empresas tecnológicas proporcionando a los usuarios obras que en realidad pertenecen a otros artistas? Es un tema complicado que nos lleva a reflexionar sobre qué es la IA gene-

rativa y cómo su uso debe ser ético y legalmente correcto en el mundo del arte.

## ¿Qué es la IA generativa?

La inteligencia artificial generativa es un campo fascinante que va más allá de la simple memorización de datos. Imagina una IA que no solo almacena información, sino que también tiene la habilidad de crear algo completamente nuevo, ya sea un texto, una imagen, un audio, un video o incluso modelos en 3D. Esta capacidad creativa de la IA se basa en el aprendizaje, no en la memorización, lo que significa que puede generar contenido original y valioso (Amazon Web Services, 2023).

A menudo, hay un malentendido común de que la IA simplemente copia y pega fragmentos de datos existentes, como si fuera una base de datos gigante que regurgita patrones previamente vistos. Sin embargo, la realidad es mucho más compleja y emocionante. La IA generativa utiliza principios matemáticos, conocidos como distribuciones probabilísticas (Talin, B, 2023), para predecir la probabilidad de diferentes resultados y crear algo nuevo a partir de esa predicción.

En lugar de copiar directamente, la IA se inspira en ejemplos anteriores para abstraer y combinar conceptos de manera innovadora [Figura 1]. Es similar a cómo un artista puede inspirarse en el mundo que lo rodea (De Mántaras, R. L, 2023), pero luego crea una obra de arte única. De la misma manera, la IA generativa toma referencias y aprende de ellas para producir algo que nunca antes se había visto.

Entender la IA generativa implica reconocer que no se trata solo de tecnología, sino también de creatividad y probabilidad. Es un campo que está cambiando rápidamente y que promete transformar la forma en

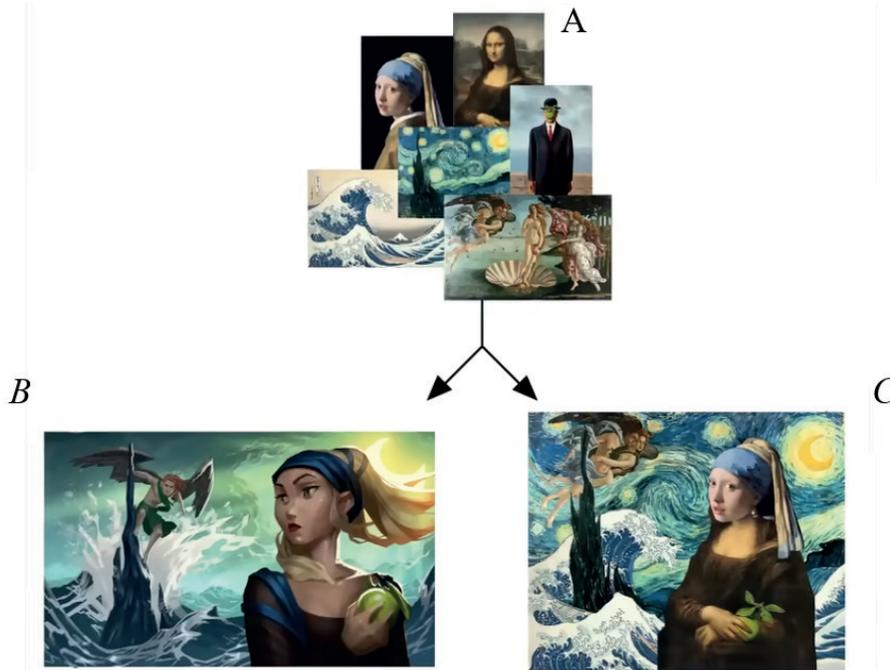


Figura 1. A. Arte como referencias; B. Como los artistas lo usan como inspiración; C. Como la IA lo usa como muestreos.

que interactuamos con el mundo digital. Para poder entender mejor el concepto de ia generativa realmente de lo que tenemos que empezar profundizar es del concepto de distribución probabilística.

**Entendiendo la IA generativa: el salto de datos a distribuciones probabilísticas**

Una distribución de probabilidad es un concepto matemático que asigna a cada posible resultado de un experimento aleatorio una probabilidad específica. Estas distribuciones son fundamentales en la estadística y se utilizan para modelar fenómenos en los que hay incertidumbre (Jhoan Steven, 2019). Existen dos tipos principales:

- **Distribuciones discretas:** Se utilizan cuando el conjunto de posibles resultados es finito o contable. Ejemplos incluyen la distribución binomial y la distribución de Poisson.

- **Distribuciones continuas:** Se aplican cuando los resultados posibles forman un continuo. Ejemplos comunes son la distribución normal y la distribución exponencial.

Las distribuciones de probabilidad se pueden representar mediante fórmulas matemáticas, tablas de probabilidad o gráficamente a través de funciones de densidad o de masa de probabilidad. Por ejemplo, la función de densidad de probabilidad (PDF) para una distribución normal se expresa como:

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Donde mu es la media y sigma<sup>2</sup> es la varianza de la distribución.

Para ilustrar este concepto, consideremos la siguiente pregunta: ¿Cuánto mide un ajolote? No todos tenemos ajolotes en mente

como para estimar su tamaño de inmediato, pero sabemos que no todos los ajolotes son iguales en tamaño. Dado que varían, nuestra pregunta se complica un poco más. La solución es medir una muestra representativa de ajolotes para obtener una estimación aproximada. Al hacerlo, recopilamos diversas medidas que conformarán nuestro conjunto de datos.

Con esta información en mano, estamos listos para analizarla y responder a nuestra pregunta original. Como se puede apreciar en la [Figura 2], las medidas se distribuyen a lo largo del eje horizontal, mostrando una tendencia clara. Hay una mayor acumulación de medidas cerca de un tamaño medio, y a medida que nos alejamos de este punto central, encontramos menos ejemplares de tamaños extremos. Esto nos indica que ciertas longitudes son más comunes que otras. A partir de estos datos, podemos inferir que existe una distribución de probabilidad, es decir, una relación matemática que nos indica la probabilidad de encontrar un ajolote de un tamaño específico.

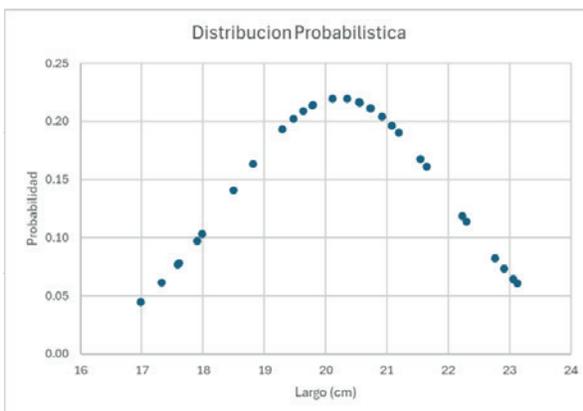


Figura 2. Gráfica de distribución de probabilidad de las medidas de los ajolotes.

Con eso acabamos de crear un modelo generativo que es capaz de generar nuevos

tamaños de ajolotes si ahora quitamos los datos en concreto y solo dejamos la gráfica lineal de distribución [Figura 3] ahora imaginemos que para un nuevo ajolote te inventes un tamaño que sea realista para nuestra distribución de probabilidad, entonces es más probable que se elija un peso que esté alrededor de la media entre 19 y 21 cm, y con mucha menos probabilidad dirías un peso que se encuentre por las zonas más alejadas de la gráfica y si se hiciera esto con un número N de personas el resultado se asemejara a los datos obtenidos antes hasta que poco a poco se irá reproduciendo la distribución de probabilidad original, con esto estamos generando nuevos datos o tamaños de ajolotes que sin ser necesariamente

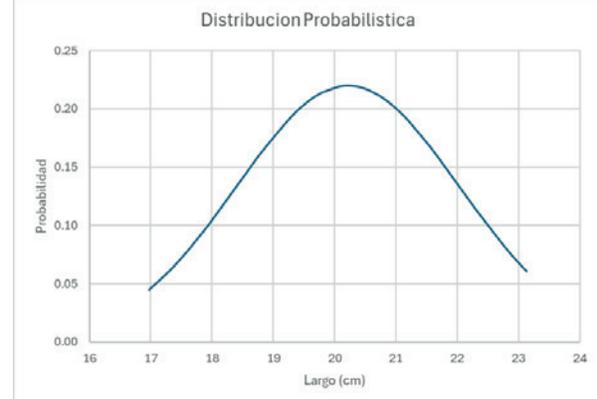


Figura 3. Gráfica de distribución de probabilidad o modelo.

La inteligencia artificial generativa opera mediante la creación de modelos generativos y distribuciones de probabilidad. Estos modelos son capaces de producir nuevos datos sin la necesidad de interactuar directamente con el conjunto de datos original.

### Creación visual AI: de probabilidades a imágenes

Ahora que ya conocemos lo que es una distribución de probabilidad, enfrentamos un nuevo problema con las imágenes. A diferencia de los ajolotes que solamen-

te era un dato, una imagen se compone de millones de píxeles. Cada píxel posee tres valores que pueden variar en las intensidades de los colores rojo, verde y azul (RGB), es decir si antes teníamos una distribución unidimensional (por que solo teníamos una variable) ahora estaríamos hablando de aprender a modelar millones de números en espacios de millones de dimensiones, así que para esto lo vamos a simplificar un poco, vamos a trabajar con el concepto de una imagen muy simplificada donde esta va a ser únicamente de 2px por 2 px y sus valores irán de 0 a 1 para tonalidades de blanco a negro, y además los píxeles están “agrupados” es decir variamos solamente un número y dos píxeles cambiarán de color como en la imagen [Figura 4].

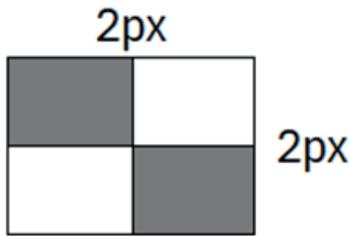


Figura 4. Concepto de imagen simplificada.

Y ahora tenemos 2 variables para controlar el tipo de imágenes que podemos representar y también podemos actuar de forma similar a como hicimos con los ajolotes, pero esta vez representaremos en una gráfica de 2 dimensiones las 2 variables que controlarían los colores de los píxeles, la variable x que variaría los colores de los dos píxeles grises [Figura 4] y una variable y que va a variar los píxeles blancos, ambas pueden ir de 0 a 1, donde 0 es negro y 1 es blanco, pasando por una escala de grises. Esta es la forma en que vamos a representar nuestras imágenes simplificadas [Figura 5].

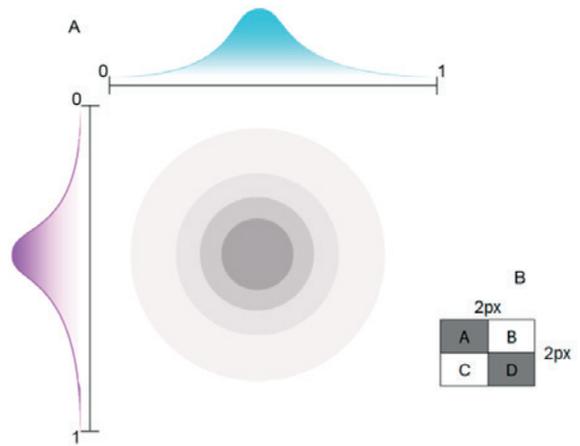


Figura 5. A. Distribución de probabilidad de 2 variables. B. Píxeles agrupados, grupo A {A,D} grupo B {B,C}.

Y ahora podemos proceder de la misma forma en que lo hicimos con los ajolotes lo que es aprender la distribución a partir de datos, para este ejemplo recopilamos varias imágenes ya existentes de un tipo concreto [Figura 6]

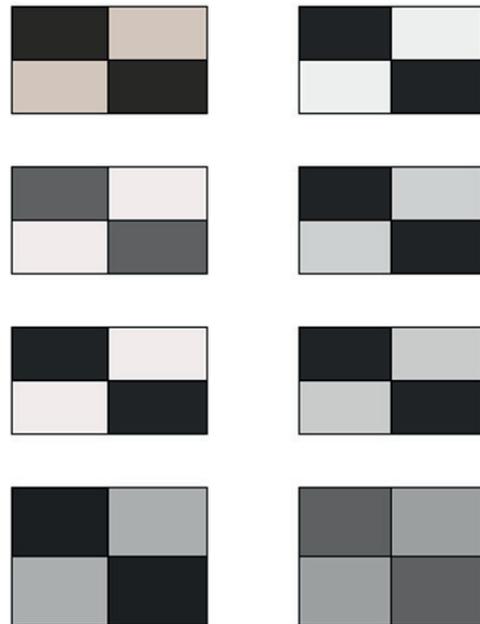


Figura 6. Dataset de entrenamiento para el ejemplo

Este conjunto de imágenes tiene ligeras variaciones pero que si las situamos en nuestra gráfica de distribución se empiezan a acomodar en la región donde los píxeles cuya variable es  $x$  se acomodan cerca del 0, como los píxeles que tienen variable  $y$  y se acomodan cerca del 1 nos queda la distribución [Figura 7] y ahora si generamos una imagen a partir de un valor de la zona con mayor probabilidad obtendremos una imagen similar a las del dataset original.

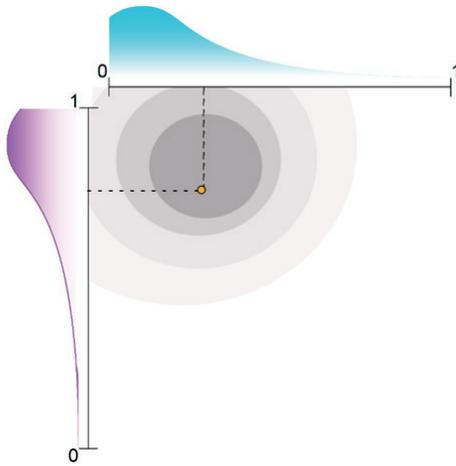


Figura 6. Distribución de probabilidad con el dataset de entreno, se toma una muestra aleatoria del área de mayor probabilidad.

Tenemos imágenes similares en características aunque no exactamente iguales que las del dataset original, y aquí es lo que hace la IA generativa que aprende las distribuciones y no los datos en concreto (Feuerriegel, Hartmann, Janiesch, & Zschech, 2023). Y para este caso en concreto que se usaron imágenes extremadamente simples, se puede llevar el modelo a las imágenes que conocemos con miles y miles de píxeles, como por ejemplo autos los cuales serían nuestros datos y aprender de ellos la distribución de probabilidad donde todas las imágenes de autos existen, y a partir de ella es donde la IA puede generar nuevas imágenes que no tienen porque existir en el dataset de entrenamiento.

Partiendo de esto pueden surgir argumentos para decir que la IA no es creativa ni original ya que no puede crear aquello que le hemos dado como dataset, como se dijo antes si le damos autos puede aprender su distribución y ¿nadamas ¿no?

Ahora vamos a tomar el modelo anterior pero agregamos nuevas imágenes al dataset de entrenamiento [Figura 7]

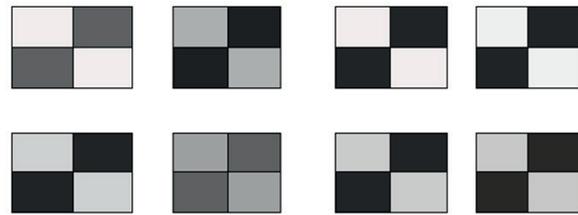


Figura 7. Conjunto nuevo de imágenes para agregar al dataset de entrenamiento

Con forme los vayamos “poniendo” en la grafica se iran cada uno acoplado a su respectivo lugar en funcion de sus valores  $x$  e  $y$ , ahora lo que tenemos seria un modelo generativo [Figura 8] capaz de generar imágenes con las diagonales en negro y blanco alternadamente [Figura 7 y 6] como lo son nuestros datos de entrenamiento.

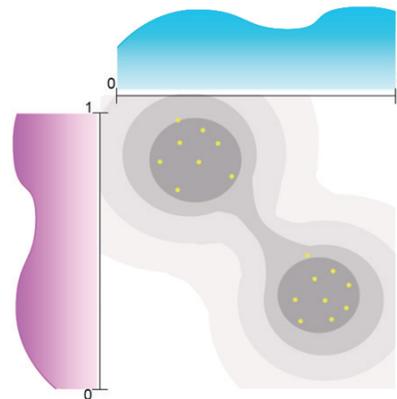


Figura 8. Modelo de probabilidad con los dos conjuntos de datasets

Ahora la capacidad de nuestro modelo de generalizar nos crea una distribución que “conecta” ambos espacios un área que tiene mayor probabilidad entre medias de nuestros datos de entrenamiento lo que nos permite generar un nuevo tipo de imagen, una donde los valores de  $x$  e  $y$  están a 0.5, ahora se creó una imagen donde todos los píxeles son grises, una nueva categoría de imagen que surge de la interpolación entre las 2 categorías aprendidas, y hay que destacar que es una imagen que no se parece en nada a los datos de entrenamiento originales. Es de esta interpolación y de los conceptos que aprende la IA es con lo que se puede aprovechar para hacer creaciones totalmente nuevas, que no vamos a encontrar en el dataset original, como puede ser que se entrenó con imágenes de autos y palomitas pero ahora puede generar imágenes de autos hechos de palomitas [Figura 9], es de esta capacidad que tiene de interpolar de aquellas categorías aprendidas, que podemos decir que la IA puede crear cualquier tipo de dato totalmente nuevo.

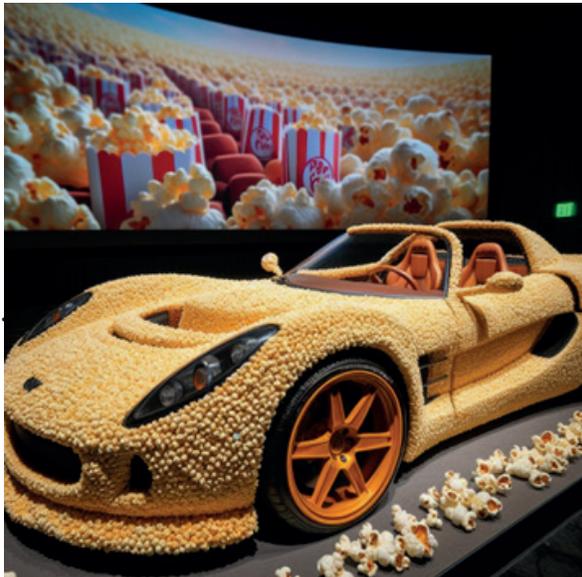


Figura 9. Auto hecho de palomitas generado por DALL-E 3

Siendo así, teniendo los millones de conceptos aprendidos por la IA y sus infinitas combinaciones que surgen de estos, se vuelve muy improbable que un usuario usando la herramienta genera una imagen que termine siendo igual o un plagio de una que estuviera en el dataset original, y sin embargo hay artículos que demuestran que lo que la IA a veces genera son imágenes idénticas [Figura 10]

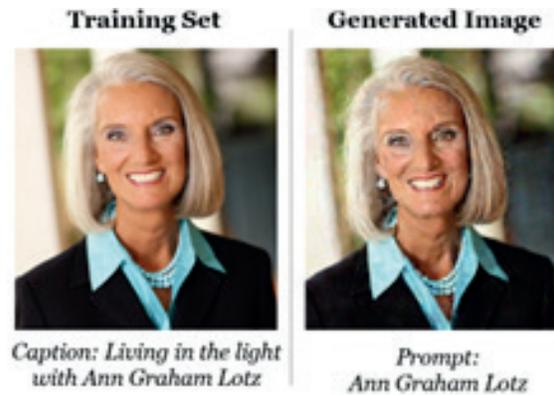


Figura 10. Obtenida del paper: *Extracting Training Data from Diffusion Models*

### Réplicas digitales: el arte de la IA y el overfitting

Ahora que sabemos que la tarea que realiza la IA generativa no es aprender los datos como tal sino aprender su distribución, es cuando podemos abordar 2 de los principales problemas, donde se puede presentar que la distribución y el dato son casi el mismo, donde el resultado que arrojaría la IA sería una imagen plagiada. Abordando el primer problema, la IA no genera contenido aleatorio si no este no tendría sentido, si no que viene condicionada a un prompt el cual está dado por el usuario final, con lo que le podemos indicar al modelo de que parte de la distribución queremos la imagen y así delimitamos de que zonas queremos obtener los datos. A través del prompt o del lengua-



Figura 11. Imagen generada por DALL-E 3 con el prompt “un cuadro al estilo renacentista”

je podemos ir variando las regiones de las distribuciones más específicas y concretas, hasta el punto de que la región represente a una imagen única. Por ejemplo una vez tenemos un modelo que aprendió una distribución podemos darle prompts como “un cuadro al estilo renacentista” [Figura 11]

O también podemos seguir acotando la distribución de donde queremos sacar la imagen y pedirle “una pintura al estilo de Leonardo da Vinci” [Figura 12] o podemos ir directamente a acotar la distribución y con el prompt “la mona lisa” podemos obtenerla ya que solo hay una.

Y ahí es cuando llega el problema ya que solo hay una mona lisa, ya que nuestro prompt acotó tanto la distribución, donde sí pueden haber pequeñas variaciones de textura o color, pero a vista de cualquier persona esta imagen generada es un plagio. ¿Significa esto que si nuestro prompt es tan específico vamos a terminar generando imágenes que son copias del dataset



Figura 12. Imagen generada por DALL-E 3 con el prompt “un cuadro al estilo renacentista”

original? la respuesta es que no, ya que se debe dar otra condición para que el plagio coursera y esta es la sobrerrepresentación, antes se mencionó que mona lisa solamente existe una, sin embargo si buscamos en internet (y por tanto datos que conforman el dataset) nos vamos a encontrar con múltiples versiones de esta, entonces ¿Por que la IA solo plagia la que todos conocemos? pues aquí está la respuesta ya que la IA actúa en muchas ocasiones similar a nosotros, por ejemplo si se le pidiera a un grupo de personas que cierren los ojos y se imaginen a la mona lisa seguramente será la versión original. Si esto ocurre es por que estamos siempre con la idea de este cuadro el cual está sobrerrepresentado y esta nos lleva a memorizar. En el caso de la IA si damos al dataset de entrenamiento imágenes del mismo tipo la distribución se vuelve cada vez más acotada o con menor varianza, donde llega al punto de dejar de ser distribuciones y pasan a ser conceptos memorizados. La sobrerrepresentación también en deep learning nos lleva a la

memorización y está a su vez al overfitting (por sobrerrepresentación) donde esté sumado a un prompt muy específico nos pueda llevar a una situación de plagio, donde generará un dato que está sobrerrepresentado y que por tanto produzca overfitting sumado a un prompt que sea lo suficientemente específico como para inducir a la IA a generar estos conceptos.

Y es esta fórmula que se reproduce en muchas de las acusaciones de plagio contra estos modelos generativos, por ejemplo el paper *Extracting Training Data from Diffusion Models* donde mencionan que estos modelos son capaces de plagiar datos del entrenamiento hasta el punto de generar calcos idénticos, sin embargo lo que no se explica mucho es que esa investigación estaba buscando esto, y para poder investigarlo han usado la fórmula que usamos antes donde en el paper se menciona que están usando imágenes que se encuentran altamente repetidas en el dataset original.

Donde podemos concluir ¿Plagia la IA generativa? la respuesta es Sí pero únicamente en circunstancias muy específicas, como se comentó cuando el dato está sobrerrepresentado en el dataset original y cuando inducimos el modelo con un prompt muy específico.

### **Bibliografía**

Google Cloud. (2023). *¿Qué es la IA generativa y cuáles son sus aplicaciones?* <https://cloud.google.com/use-cases/generative-ai?hl=es>

Amazon Web Services, Inc (2023) *¿Qué es la IA generativa?* <https://aws.amazon.com/es/what-is/generative-ai/>

Talin, B. (2023). *¿Qué es la IA Generativa?* - Todo lo que necesitas saber: significado, modelos y ejemplos. <https://morethandigital.info/es/que-es-la-ia-generativa-significado-modelos-ia-y-ejemplos/>

De Mántaras, R. L. (2023). *La inteligencia artificial y las artes. Hacia una creatividad computacional* <https://www.bbvaopenmind.com/articulos/la-inteligencia-artificial-y-las-artes-hacia-una-creatividad-computacional/>

Jhoan Steven (2019) *¿Qué es la distribución de probabilidad?* <https://www.pragma.co/es/blog/que-es-la-distribucion-de-probabilidad>

Juan Pablo Del Alcazar Ponce (2024) *Inteligencia artificial generativa, discriminativa y otros enfoques relevantes.* <https://blog.formaciongerencial.com/inteligencia-artificial-generativa-discriminativa-y-otros-enfoques-relevantes/>

Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2023). *Generative AI. Business & Information Systems Engineering.*

Carlini, N., Hayes, J., Nasr, M., Jagielski, M., Sehwag, V., Tramèr, F., Balle, B., Ippolito, D., & Wallace, E. (2023). *Extracting Training Data from Diffusion Models.* Editorial/Universidad: Google, DeepMind, ETHZ, Princeton, UC Berkeley.

Dot CSV (2024) *La IA Generativa... ¿Plagia A LOS ARTISTAS? (Explicación Técnica).* <https://www.youtube.com/watch?v=i-bue3mFBh5c>