

Interfaces epistémicas de visualización e interpretación: una posible resistencia al mito de la agencia autónoma en la IA

Epistemic Interfaces of Visualization and Interpretation: a possible resistance to the myth of autonomous agency in AI

ANDRÉS PACHÓN

Universidade de Coimbra, Portugal
info@andrespachon.com

Resumen

Los estudios antropológicos sobre agencia y cognición han empleado marcos teóricos de codependencia y composición — entre humanos y no humanos — para explicar los procesos de producción técnica del conocimiento. En este contexto, se han desarrollado numerosos estudios etnográficos sobre las tecnologías digitales (Horst y Miller 2012; Geismar y Knox 2021) y, en particular, sobre la Inteligencia Artificial (IA) (Forsythe 2001; Suchman 2007), tanto en el contexto de su producción — con sus diseñadores y programadores —, como en el campo de su implementación — sobre sus usos y apropiaciones —. En cambio, como indican autoras como Pink (2021) o Drucker (2020), encontramos menos investigaciones que lleven estas teorías antropológicas al diseño de aquellas tecnologías que determinan nuestra actual ecología cognitiva, como es el caso del fenómeno del *deep learning*. Así, la relevancia de la investigación que aquí se presenta radica en la realización de una etnografía colaborativa — con un ingeniero de *deep learning* — que permitió diseñar dos interfaces experimentales de interacción humano-IA que ofrecen una posible resistencia al mito de agencia autónoma que caracteriza el discurso oficial de la IA; un *habla mítica* (Barthes 1957) que, como se argumentará a través de la descripción del trabajo etnográfico, no se corresponde con la *acción* de programar IA. Partiendo de este contexto, se presentará el método híbrido que orientó esta investigación — entre la práctica de programación de *deep learning* para visión artificial, las técnicas de *interpretabilidad* computacional, y el uso de estrategias artísticas —, metodología que permitió *incorporar* en el diseño de las interfaces el conocimiento etnográfico del trabajo de campo, donde destacan los conceptos antropológicos de *agencia social* (Gell 1998; Latour 1999) y *user-maker* (Ingold 2013).
mitología de la IA | deep learning | agencia social | antropología digital | etnografía experimental

Palabras clave

Abstract

Anthropological studies on agency and cognition have used theoretical frameworks of co-dependency and composition (between subjects and objects) to explain the technical production processes of knowledge. In this context, ethnographic studies were carried out on digital technologies (Horst y Miller 2012; Geismar y Knox 2021), namely on Artificial Intelligence (AI) (Forsythe 2001; Suchman 2007), both in relation to its production — with its designers and programmers — and in its implementation — on its uses and appropriations. However, according to authors such as Pink (2021) or Drucker (2020), we find less research that brings these anthropological theories to the design of the technologies that determine our current cognitive ecology, as is the case of deep learning. Thus, this paper's contribution lies in the development of a collaborative ethnography — with a deep learning engineer — to generate two experimental human-AI interaction interfaces that offer possible resistance to the myth of autonomous agency that characterizes the official discourse of AI; a *mythical speech* (Barthes 1957) that, as will be argued through the description of the ethnographic work, does not correspond to the *action* of programming AI. Having this as a starting point, we present the hybrid method that guides this research — between deep learning programming for artificial vision, computational *interpretability* techniques and the use of artistic strategies —, a methodology that allowed the *incorporation* of the ethnographic knowledge of the field work into the interface design, where the anthropological concepts of *social agency* (Gell 1998; Latour 1999) and *user-maker* (Ingold 2013) stand out.

Keywords

AI mythology | deep learning | social agency | digital anthropology | experimental ethnography

1. El mito de la agencia autónoma en el discurso del *deep learning*

La visión artificial es un tipo de IA que se refiere a una subcategoría de la técnica denominada redes neuronales artificiales para aprendizaje profundo (*deep learning*), cuya función es reconocer, clasificar y/o generar imágenes. Tal es el caso de las *convolutional neural networks* (CNN), un modelo que, según la literatura que informa su programación, simula el funcionamiento del córtex visual para extraer las características de una imagen. De forma sintetizada, podemos decir que una red CNN tiene una arquitectura algorítmica estructurada en una capa de entrada, una capa de salida, y múltiples *capas ocultas* formadas por miles de neuronas, donde cada neurona se refiere a una unidad de procesamiento algorítmico. Gracias a la implementación de una operación matemática denominada *convolución* (de ahí el nombre de esta red), la cual se ejecuta a través de




Figura 1

Esquema de una red neuronal aplicada al reconocimiento de números escritos a mano. Podemos ver cómo se van activando, de izquierda a derecha, las diferentes neuronas (círculos blancos), definiendo los patrones de reconocimiento de más específicos (pequeños fragmentos de la imagen del 9) a más generales (la circunferencia superior y el palo inferior que conforman un número 9), lo que ayudará a que la red pueda identificar nuevos *inputs*. En este caso, vemos las neuronas que se activan en el *aprendizaje y reconocimiento* de la imagen de un 9, imagen que es recibida por la red como los valores de los 784 píxeles que conforman la imagen cuadrada que contiene el número 9. Captura del video *But what is a Neural Network...?*. Grant Sanderson. 2017. 18 mins. <https://www.youtube.com/watch?v=aircAruvnKk&t=724s>.

un *filtro* para imágenes llamado *kernel*, la CNN simulará las activaciones y conexiones entre las células del tálamo y las células simples y complejas del córtex visual V1 cuando los humanos percibimos una imagen (Lindsay 2022, 165-169). De esta forma, las primeras *capas ocultas* de la CNN extraen las características básicas de la imagen —como texturas y bordes—, una serie de valores que, gracias a nuevos cálculos *convolucionales*, activarán e inhibirán, de forma simultánea, las neuronas de las siguientes capas, estableciendo características adicionales que aprovechan los hallazgos de las capas anteriores (ver Figura 1). Así, capa por capa de la red, el sistema extraerá las características más relevantes de la imagen. Este proceso se repetirá con cada una de los miles (o millones) de imágenes que están asociadas a cada una de las categorías (*etiquetas*) que conforman el *data set* de *entrenamiento* de la red (por ejemplo, un conjunto de fotografías *etiquetadas* como barcos). Se trata de un método inductivo enumerativo que, a través de los ejemplos del *data set*, permite a la red establecer las regularidades necesarias en

las imágenes para que pertenezcan a una determinada categoría. Esta primera fase de *entrenamiento* le permitirá a la red, durante la posterior *fase de producción, etiquetar* correctamente nuevas imágenes a las que nunca antes se enfrentó.

Así, el discurso que acompaña a las redes CNN se caracteriza por mantener las cualidades de la visión y el aprendizaje humano, al mismo tiempo que amplía sus capacidades para que podamos ver y conocer en el exceso visual de nuestra cotidianidad digital. Más allá de su implementación en el conocimiento experto — como es el caso de la imagenología médica —, las CNN llegarán a la mayoría de los usuarios de forma indirecta e invisible, pero dotando de *visión e inteligencia* a los artefactos tecnológicos que median gran parte de nuestras acciones diarias (su implementación se encuentra en *smartphones*, motores de búsqueda online, coches autónomos, modelos de creación de imágenes, etc.). Podemos decir, por tanto, que la CNN ejerce su agencia entre bambalinas, funcionando como un *agente secreto* (Apprich 2018) que, aunque pase inadvertido, conforma nuestro conocimiento visual, redefiniendo lo que significa ver y lo que hay que ver, una vez que la forma como vemos el mundo es lo que lo hace visible. Esto provocará que, como ocurre en toda mediación técnica, deleguemos responsabilidades en un gran número de mediadores cuya existencia desconocemos, de tal forma que, como indica Latour (1999, 227),

el orden político queda subvertido, puesto que confío en un gran número de acciones delegadas que, por sí mismas, me impulsan a hacer cosas en favor de personas que no están aquí y de cuya existencia ni siquiera puedo tener un atisbo.

Esta delegación de responsabilidades tiene lugar gracias a un *despolitización* de la IA que comienza en su programación, donde se lleva a cabo una *disyunción actoral* (Latour 1999) por la cual el programa de acción de los ingenieros —simular la inteligencia humana computacionalmente o, en el caso de la CNN, simular la percepción visual— no solo queda *articulado* con cálculo computacional, si no que es *delegado* en los algoritmos, de tal forma que el software se presenta *como si* tuviera procesos inteligentes, *como si* tuviera percepción visual. Como indica Preston (2002, 21), “plenty of AI research is still supposed to be about producing (rather than merely simulating) psychological phenomena on electronic digital computers just by programming them”; de lo contrario, se pregunta Larson (2021, 41), “¿a cuento de qué, por ejemplo, usamos el término ‘inteligencia artificial’ en vez de, quizá, el de ‘simulación de tareas humanas’?”.

Para que esta disyunción sea efectiva, el software — o el artefacto donde se implementa — debe presentarse como un agente autónomo, reuniendo a todos los actores implicados en su desarrollo (los ingenieros, el cálculo algorítmico, el hardware, etc.) bajo un único marco de referencia (denominado *inteligencia artificial, deep learning* o

artefacto *inteligente*) que funcionará como una *caja negra*¹ que oscurece la historia de producción de esta tecnología. Podemos decir que esa *caja negra* corresponde con la noción de mito establecida por Barthes (1957, 13): una *forma de hablar* por la cual un determinado discurso es *naturalizado* y presentado públicamente como *evidente-por-sí-mismo* y sin historia; es decir, un discurso *despolitizado*. En este caso, nos encontramos con un mito que *naturaliza* la imagen de la IA — y de los artefactos donde se implementa — como un agente autónomo que procesa y produce información con independencia del observador. De acuerdo con Latour (1999), la disyunción actoral propia de la mediación técnica no solo transformará la manera en la que nos referimos a determinadas técnicas de computación —que pasarán a nombrarse *inteligencia artificial* o *aprendizaje automático*— si no también el fondo mismo de la expresión; es decir, lo que significa la inteligencia. Encontramos esto en el desarrollo de las ciencias cognitivas computacionistas, donde la imagen del computador humanizado — la IA tiene inteligencia porque resuelve problemas como lo hacen los humanos— devino la *coartada* de la explicación científica de la mente — la *mente-como-computador* —, lo cual acabaría por reforzar un mito de agencia arraigado en la cultura occidental, donde humanos, cerebros o computadores serán ahora entendidos como sistemas autónomos de resolución de problemas. En este sentido, Suchman (2007, 226-228) refiere lo siguiente:

projects in AI and robotics involve a kind of doubling or mimicry in the machine that works as a powerful disclosing agent for assumptions about the human (...). In the case of the human, the prevailing figuration in Euro-American imaginaries is one of autonomous, rational agency, and projects of artificial intelligence reiterate that culturally specific imaginary.

Siguiendo el planteamiento de Barthes (1957, 238), este mito será un *habla despolitizada* que *purifica* la tecnología de IA, una vez que *cajanegriza* el conjunto de relaciones humanas y no humanas que compone su agencia (algoritmos, programadores, *hardwares*, *data sets*, etc.). En última instancia, esto facilitará que las instituciones — aquellas que sean capaces de administrar, absorber y oscurecer los mediadores necesarios para la operatividad de la IA — deleguen sus responsabilidades en la supuesta autonomía inteligente de estas tecnologías, lo cual oscurecerá las relaciones que preceden y componen el diseño y uso de la IA en sus diferentes contextos. Puede que para nuestra relación diaria con la tecnología de IA no sea relevante preguntarse si, por ejemplo, un coche Tesla es verdaderamente inteligente, siempre y cuando sea operativo en las tareas que tiene que realizar;

1 Empleo aquí el sentido de caja negra definido por Latour (1999, 362), quien tomará el término de la sociología de la ciencia, según la cual “cuando una máquina funciona eficazmente, cuando se deja sentado un hecho cualquiera, basta con fijarse únicamente en los datos de entrada y los de salida, es decir, no hace falta fijarse en la complejidad interna del aparato o del hecho. Por tanto, y paradójicamente, cuanto más se agrandan y difunden los sectores de la ciencia y de la tecnología que alcanzan el éxito, tanto más opacos y oscuros se vuelven”.

pero este mito de agencia autónoma provoca que se malinterpreten las implicaciones (filosóficas, antropológicas, psicológicas o científicas) de la IA, con el poder que ello otorga a dichas instituciones — entre las que destacan Open AI, DeepMind, Nvidia o Meta —.

Con el objetivo de reconfigurar esta imagen de agencia cognitiva, esta investigación entiende la cognición como una cuestión técnica, en el sentido en que esta tiene que ver con la manera en *cómo* formamos nuestras ecologías cognitivas desde una multitud de agencias — humanas y no humanas (tecnológicas) —, sin que por ello tengamos que eludir la diferencia ontológica entre los procesos mentales y los computacionales — una vez que, como indica Searle (1984), la *intencionalidad* que caracteriza a los primeros será condición indispensable para la necesaria interpretación de los segundos, como veremos en el último apartado —. Es decir, como refiere Hutchins (1995, 169), “humans create their cognitive powers by creating the environments in which they exercise those powers”. En este mismo sentido, Latour (1986) considera que la cognición es *pensar con los ojos y las manos*, el resultado de un proceso de *visualización* de la información, donde el término *visualización*, a diferencia de *observación* o *percepción*, supone una *manufactura* de la información a través de la movilización de diferentes mediadores tecnológicos que harán más o menos estables y fiables determinadas representaciones del mundo. Como veremos en el apartado 3 a través del trabajo desarrollado para esta investigación, debemos entender el conocimiento producido por la IA no solo como dependiente de los programadores, si no también de actos interpretativos que serán co-dependientes de los usuarios y de los objetos tecnológicos con los que compartimos y componemos ambientes cognitivos heterogéneos.

2. Agencia social y *maker-user* en la programación de *deep learning*

Durante el trabajo de campo etnográfico desarrollado en esta investigación — basado en una colaboración experimental, como veremos en el siguiente apartado —, pude comprobar que el mito de agencia autónoma continúa informando las prácticas de los programadores de *deep learning*, propagándose al diseño y presentación pública de los artefactos *inteligentes* donde la IA es implementada. Pero, como ya demostraron Latour y Woolgar (1979), la *mitología* del laboratorio² no siempre se corresponde con la *acción* que en él se desarrolla — en este caso, con la actividad de programación e investigación de IA

2 En su antropología sobre la actividad social de un laboratorio científico, Latour y Woolgar (1979) definirán la mitología de la actividad tecno-científica como el conjunto de presupuestos que informa las actividades de un determinado laboratorio (o de una red de científicos y/o ingenieros). En sus propias palabras: “it refers to a broad frame of reference within which can be situated the activities and practices of a particular culture. (...) a complex mixture of beliefs, habits, systematised knowledge, exemplary achievements, experimental practices, oral traditions, and craft skills” (Latour y Woolgar 1979, 54)

—, algo que también pude comprobar a través del trabajo de campo con los ingenieros. Es decir, como sucede en otros tantos ámbitos de nuestra contemporaneidad, el área de la programación de IA lo conforma una comunidad epistémica, una agencia social que reflexiona sobre su propia práctica. Según el planteamiento de los antropólogos Holmes y Marcus (2008), podríamos decir que los programadores e investigadores en IA realizan una *paraetnografía*, ya que sus integrantes ejercen la función descriptiva de su propio trabajo — algo característico de la etnografía —, abriendo incluso sus archivos para que otros los puedan utilizar. Tal es el caso de la actividad desarrollada en los *notebooks* de Google Colab (ver Figura 2), unos cuadernos interactivos online cuyo objetivo es incentivar el estudio y la investigación colectiva en programación de IA. Estos *cuadernos* permiten escribir y ejecutar código de Python — el lenguaje de programación más popular para *deep learning* —, así como incluir una serie de documentos en formato de texto, imagen, video o audio que acompañan al código y pueden funcionar como tutoriales, lo cual permite que varios programadores pueden trabajar de forma simultánea sin afectar al resto.

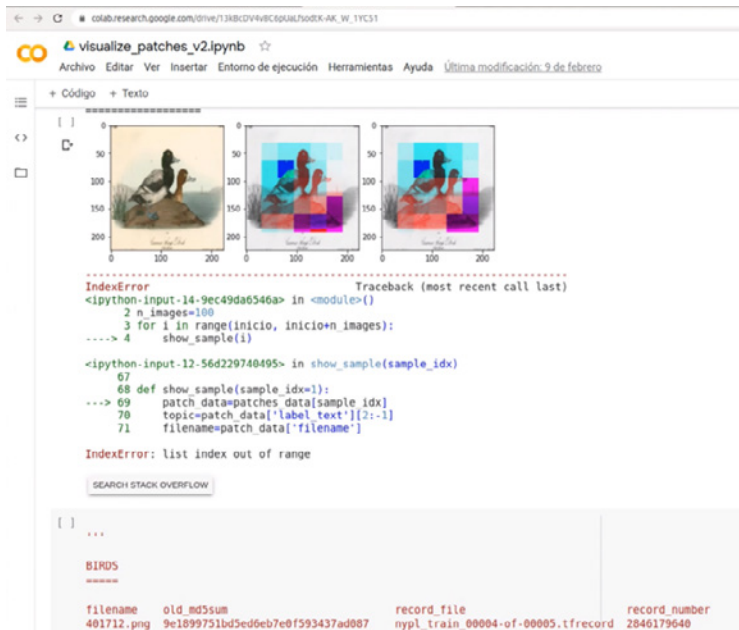


Figura 2
 Captura de pantalla de uno de los *notebooks* que fueron empleados durante la programación de las interfaces desarrolladas en esta investigación. En este *notebook* encontramos los códigos y tutoriales necesarios para la implementación de uno de los algoritmos (*heat mapping*) que usamos para visualizar la actividad de la red neuronal programada. Este mismo *notebook* sirve para implementar dicho algoritmo, lo que me permitió ver el resultado de esta visualización para cada una de las categorías de nuestro *data set* (en este caso, la categoría *birds*).

Los *notebooks* nos muestran que *trabajar en* una red neuronal es también *trabajar con* o *usar* otros algoritmos diseñados por otros programadores, lo cual ejemplifica el carácter modular del *deep learning*, una característica por la cual esta tecnología será simultáneamente resultado e instrumento de una agencia social — de humanos y no humanos — en continua formación. Es decir, tal como indica Sarah Pink (2021, 310) en relación a las tecnologías digitales, podemos decir que el *deep learning* se encuentre siempre inacabado y poroso a otros agentes y procesos. En palabras de Pink (2021, 310):

rather than being finished and complete when they are ready for markets, digital technologies might be theorized as being always incomplete things. The advantage of this in relation to understanding digital futures is that it opens us up to understanding digital technologies as unfinished and ongoingly remade and becoming part of the social, digital and material world in ways that are not predetermined.

Este carácter procesual e inacabado de la IA conlleva que no podamos establecer una oposición clara entre el diseñador/programador y el usuario de IA, algo que no solo encontramos en los *notebooks*, si no también en la preparación y ajustes del *data set*: durante la *fase de entrenamiento* de las redes neuronales, el programador *trabaja con* otros algoritmos no supervisados³ que agrupan, eliminan y ajustan los datos de *entrenamiento* (imágenes, en nuestro caso de estudio); mientras que en la *fase de producción* — por ejemplo, durante el proceso de clasificación de imágenes por parte de una CCN —, el usuario puede corregir una imagen mal *etiquetada* durante la tarea de clasificación de la red, de tal forma que la visión artificial pueda *reentrenarse* y mejorar su operatividad⁴. De esta forma, nos encontramos con la figura del *maker-user* teorizada originalmente por Ingold (2013), un enfoque que, de acuerdo con Pink (2021, 312),

-
- 3 Las redes neuronales de *deep learning* como la CNN son modelos de aprendizaje supervisado; es decir, el modelo trabaja con entradas *etiquetadas* por el humano para poder *señalar* el resultado deseado por el diseñador de la red. Por su parte, el aprendizaje no supervisado es cuando el modelo extrae posibles patrones que pueda haber en los conjuntos de datos, sin asociarlos a una *etiqueta* externa a ellos —en el siguiente apartado veremos dos ejemplos de aprendizaje no supervisado que fueron usados en el diseño de los interfaces—.
 - 4 En este sentido, cabe destacar que, como señalé en el primer apartado, el *deep learning* basa su *aprendizaje* en las generalizaciones que establece mediante un método inferencial que es exclusivamente inductivo enumerativo, lo cual significa que solo puede generar un conocimiento provisional, una vez que se encuentra limitado por el *data set* de *entrenamiento* que, obligatoriamente, fue establecido por el programador en un tiempo pasado. De esta forma, el aprendizaje automático, como indica Larson (2021, 169), “solo puede ir a la zaga del flujo de nuestra experiencia, simulando (lo que esperamos que sean) regularidades útiles”. Esto provoca que la predicción del futuro por parte de la IA tenga el mismo aspecto que el pasado, lo cual sabemos que no siempre es así. Aunque sea posible ajustar el aprendizaje de la red durante la *fase de producción*, esto no evitará que el sistema esté siempre un paso por detrás de nosotros los humanos, pues depende de los nuevos datos que le ofrezcamos a través de nuestro uso y *etiquetado*, y nunca de una relación directa con las características mutables del mundo.

takes us beyond the idea of the maker and user existing only in opposition to each other, is useful for understanding the indeterminacy of technology design and development as it moves into imagined futures. This is because it enables us to think beyond the idea of use as subverting or contesting the intentions of the designer and towards the idea of use and design happening in the same process.

Disrupting the distinction between designer and user in this way emphasizes that possible worlds are not as yet unrealized futures, but instead only ever possibilities.

Si, por lo tanto, aceptamos que el uso y el diseño del *deep learning* forman parte de un mismo proceso — ya que las posibles *trayectorias* de esta tecnología pueden cambiar con su uso —, no podemos seguir describiendo la IA como una agencia autónoma que procesa información de forma independiente del usuario/observador, si no como una tecnología inacabada o incompleta que tiene la capacidad de transformarse a través de su relación con los humanos — sean usuarios o programadores — y con otras tecnologías — como ocurre en los *notebooks* o en la preparación y ajuste de los *data sets* de *entrenamiento* —.

3. Interfaces epistémicas de visualización e interpretación

Lo que se propone en esta investigación es llevar el concepto de *maker-user* a la interfaz de interacción humano-IA, de tal forma que, como sugiere Peter-Paul Verbeek (2006, 367), se genere una conexión entre las *inscripciones* que se realizan durante el diseño de las tecnologías y las *interpretaciones* que se dan en el contexto de su uso. A través de una práctica experimental, se pretende especular con alternativas a la idea estándar de interfaz — entendido como un *espacio* de encuentro entre el humano y la máquina — y, con ello, resistir al mito de la agencia autónoma de la IA, una vez que, como indica Suchman (2007, 245), esta noción de interfaz presupone que el humano y la máquina son agentes autónomos con capacidades pre-establecidas, y no parte de una agencia social en continua y mutua transformación. Así, se desarrollaron dos dispositivos que, en lugar de *fixar* en el *display* los *outputs* producidos por la IA, permiten al usuario interactuar con los procesos algorítmicos de una red CNN para visión artificial, de tal forma que se active una agencia social que permita cointerpretar los datos — en este caso, las imágenes y las categorías de un determinado archivo visual con el que la red neuronal *aprendió a ver* —.

Esta investigación se basó en una etnografía experimental realizada en colaboración con el ingeniero de *deep learning* Virilo Tejedor Aguilera. Aunque gran parte de las técnicas y estrategias empleadas para el diseño de estas interfaces se fueron definiendo a través de las cuestiones e implicaciones antropológicas y tecnológicas que emergían de la propia práctica colaborativa con el ingeniero, inicialmente establecí una metodología de trabajo que ayudaría a coordinar el proyecto. Se trataba de un método híbrido

donde se usaron redes CNN, técnicas de *interpretabilidad* y visualización computacional⁵, y estrategias artísticas basadas en la apropiación y modificación de estos algoritmos. Las técnicas de *interpretabilidad* computacional empleadas pertenecen a una serie de investigaciones en IA (bastante marginales) que persiguen abrir y visualizar las *capas ocultas* de las redes neuronales⁶. El objetivo de estas investigaciones es hacer comprensible a la mirada humana los millones de cálculos algorítmicos implicados en la operatividad de la IA y, así, explicar por qué funciona bien o mal. Pero el objetivo de esta investigación no es *abrir* la caja negra de la visión artificial (sus *capas ocultas*) para hacer una crítica de su funcionamiento, si no *atravesarla*. Es decir, tal como indica Mo- nin (2018, 234) en su análisis de trabajos artísticos con IA,

In order to be able to understand computational systems, we need to not see *into* them but *across* them as ‘sociotechnical systems that do not *contain* complexity but *enact* complexity’ (Annany y Crawford 2016, 2) and that this complexity involves both humans and non-humans co-composing.

La dificultad de este planteamiento radica, como señala Suchman (2007, 240), en cómo recuperar y visualizar las labores y contingencias de las agencias tecnológicas sin perder el *encantamiento* que produce en nosotros la tecnología *inteligente*. Esta cuestión hace referencia a la antropología del arte realizada por Gell (1998; 1999), quien defendía que determinados objetos técnicos — artísticos y religiosos, en sus casos de estudio — producen en nosotros un *encantamiento* que permite que nos relacionemos con ellos de forma efectiva. Este *encantamiento* reside en la dificultad que tenemos para descifrar la acción social que dio lugar a estos objetos; por tanto, el *encantamiento* es el resultado de un proceso técnico que, por ultrapasarnos nuestra comprensión, nos obliga a interpretar el objeto como mágico (Gell 1999, 169). En el caso de la IA, esto no significa que nos relacionemos con el artefacto *inteligente* porque pensemos que esté vivo, ni porque lo confundamos con una persona, si no que es precisamente la *resistencia* (Gell 1999, 169) que ofrece el artefacto a nuestra comprensión del proceso socio-técnico que lo precede, lo que nos obliga a interpretarlo como un agente autónomo. Encontramos aquí una relación entre el *encantamiento de la tecnología* de Gell y la *disyunción actoral* de Latour, una vez que los artefactos *inteligentes* presentan una paradoja por la cual, para relacionarnos de forma eficaz con ellos — para que “los artefactos sean funcionales desde una

5 De acuerdo con Griffiths, “computational visualisation, as a method, explores how contemporary visual design tactics including generative design and interaction design, can intersect with a critical exegesis of algorithms to challenge the black box and obfuscation of machine learning and work toward an ethical debugging of biases in such systems” (2018, 217).

6 Esta investigación tomó como punto de partida las técnicas de visualización de características de redes neuronales presentadas en el artículo “Exploring Neural Networks with Activation Atlases” (Carter et al. 2019).

perspectiva psicológica” (Gell 1998, 112) —, estos deben oscurecer las labores humanas y no humanas que dieron lugar a su diseño, de tal forma que puedan presentarse como agentes autónomos y, así, generar “experiencias tan intensas de ‘copresencia’ de un agente como lo hace un ser humano” (Gell 1998, 52). En nuestra cotidianidad tecnológica esto se traduce en que cuanto más inteligentes se nos presenten los artefactos con los que interactuamos, más complicado será conocer su historia de producción — la composición de su agencia social —, lo cual *naturaliza* la idea de una agencia autónoma, posibilitando que el usuario delegue responsabilidades en estas tecnologías y en las instituciones que las administran.

Así, una posible respuesta a la cuestión levantada por Suchman — cómo recuperar y visualizar los procesos que dieron lugar a las tecnologías *inteligentes* sin perder el necesario *encantamiento* que producen en nosotros y que nos hace relacionarnos con ellas — puede estar en el uso de estrategias artísticas para diseñar las interfaces humano-IA, una vez que, como señala Gell (1999, 162-163), los objetos artísticos también pueden (o deben) generar un *efecto de resistencia* a la comprensión del espectador — y, con ello, provocar el deseo de comprenderlas, activando así su capacidad relacional —. Es decir, en lugar de que el *encantamiento* de la IA se haga efectivo a través de la apariencia autónoma del artefacto, podemos usar las estrategias artísticas para generar, como señala Monin (2019, 233-234), un *extrañamiento* sobre la experiencia humana de las máquinas, forzando al usuario a tener que dar sentido al artefacto con el que se relaciona, más allá del mito de la IA como una agencia autónoma de mimesis humana. Podemos decir que se trata de diseñar una otra *tecnología del encantamiento* (Gell 1999, 163 y 167) que, a través de su *extrañeza*, promueva la relación con la IA sin necesidad de atribuirle un carácter autónomo.

Con este objetivo, se realizó una apropiación artística⁷ de los algoritmos usados en visión artificial y generación de imagen — como son las Generative Adversarial Networks (GAN) —, y de las técnicas de *interpretabilidad* computacional — como son los algoritmos no supervisados de *clustering* y *heat mapping* que describiré a continuación —. Con esta estrategia se procura dotar a las interfaces de un carácter tanto epistémico — una vez que visualiza una parte relevante de los procesos del *aprendizaje* de la red CNN —, como retórico — ya que pretende persuadir y apelar al usuario para que interprete la propia interfaz, en lugar de *mostrar* una explicación del funcionamiento de la red—. Dos características (lo epistémico y lo retórico) que, como señala Drucker (2020, 40), son necesarias para todo acto interpretativo — “where interpretation signals the subjective, located, inflected, and particular character of knowledge located within a subjective experience” —. De esta forma, se busca activar una cointerpretación (junto a los procesos de la red) del *data set* con el que la CNN *aprendió a ver*, de tal forma que,

7 Cabe aclarar que, en este contexto, uso el término *apropiación artística* para referirme a una estrategia que usa los algoritmos empleados en *deep learning* para enfatizar la dimensión estética y visual de sus procesos por encima de su funcionalidad expectable.

como defiende Drucker (2020, 2), la interfaz de visualización funcione como una forma primaria de producción del conocimiento, y no como la expresión secundaria de datos pre-existentes. Es en este sentido que defino estas interfaces como *dispositivos epistémicos de visualización e interpretación*.

Antes de presentar los dispositivos desarrollados, titulados *Abstract Machine* (2020) y *Class(h)* (2021), me detendré brevemente en el *data set* empleado para *entrenar* la red CNN, cuyas características se visualizan a través de estas interfaces. Este *data set* fue creado a partir de una selección de 180.000 imágenes, agrupadas en 83 categorías, pertenecientes a la Colección Digital de la Biblioteca Pública de Nueva York (<https://digitalcollections.nypl.org>), una colección en *open access* formada por digitalizaciones de diferentes archivos históricos con documentos visuales datados entre los siglos XVI y XX. Pese a que las imágenes de la Colección se encuentran agrupadas en diferentes categorías, estas resultaron ambiguas, complejas y polisémicas para el *análisis* algorítmico de la red CNN. Esto se debe a que estas imágenes fueron producidas mediante diferentes técnicas (grabado, pintura, fotografía, cartografía, etc.) y responden a diferentes géneros (retratos, paisajes, documentos administrativos, documentos etnográficos, etc.) que no determinan necesariamente su inscripción en una u otra categoría, una vez que estas atienden a temáticas generales (*world war I, military uniforms, african americans, women, ethnography, cities*, etc.). Esto se traduce en que las imágenes de una misma categoría presentan diferentes características visuales, tanto formales como de contenido⁸. Pese a los problemas técnicos que esto supuso —conllevó complejas tareas de *limpieza* y *normalización* de nuestro *data set*—, la elección de *entrenar* la red CNN con esta colección es especialmente significativa, una vez que subraya el hecho de que cada uno de los datos de *entrenamiento* de una red neuronal —en el caso de una CNN, cada binomio imagen-*etiqueta*— posee su propia historia de mediación y composición, habiendo sido producidos *por* otros tantos artefactos — como el lápiz, la geometría, la perspectiva, la cámara oscura, la cámara fotográfica, la imagen digital, etc. — y *para* otros aparatos institucionales — el laboratorio, el archivo burocrático, el museo, la Antropología, las Ciencias Naturales, etc. —. Así, este *data set* ejemplifica la mediación técnica que compone y transforma el conocimiento del mundo en cada momento, y donde

8 Para que las redes neuronales de visión artificial sean operativas, estas deben ser *entrenadas* con imágenes producidas y ajustadas bajo estrictos parámetros de selección y edición —lo que se denomina técnicamente como *normalización* del *data set*—, algo que dificultaba el uso de esta colección. Esto no sucederá, por ejemplo, con la implementación de *deep learning* en imagenología médica, donde cada *data set* de *entrenamiento* estará formado por imágenes producidas con la misma técnica (rayos-X, PET, RM, etc.); ni con las imágenes que conforman el popular *data set* ImageNet (www.image-net.org), —diseñado para su uso en la investigación de softwares de reconocimiento de objetos visuales—, donde las imágenes de cada categoría (exclusivamente fotográficas) tienen el mismo formato y el mismo número de píxeles, y cuyo contenido está claramente ajustado y dirigido a cada *etiqueta*, eliminando todo *ruido* posible —es decir, se elimina toda la información de la imagen original que no corresponda con la *etiqueta* asociada—.




Figura 3
Ejemplo de *heat mapping* aplicado a dos imágenes del *data set*. A la izquierda, imagen asociada a la categoría *african americans*. A la derecha, imagen asociada a la categoría *botany*.

la red CNN se presenta, parafraseando a Deleuze y Guattari (1972, 42), como una de tantas *máquinas* que cortan el flujo de producción del conocimiento generado en otro lugar y en otro tiempo por otras *máquinas*, siendo que el concepto *máquina* se refiere aquí a una agencia social compuesta por diferentes humanos, artefactos e instituciones.

Para diseñar la interfaz *Abstract Machine* (Figuras 4 y 5), en primer lugar se usó un algoritmo no supervisado que realizó un *mapa de calor* (*heat mapping*) para cada una de las 180.000 imágenes de nuestro *data set*, un algoritmo que localiza y extrae aquellos fragmentos de las imágenes en los que más se *fija* la red CNN para clasificar correctamente cada imagen — como se puede ver en los ejemplos de la Figura 3, los fragmentos cálidos (rosas y naranjas) indican un mayor porcentaje de correlación entre la imagen y la categoría que le corresponde, mientras que los fragmentos fríos (azules) señalan una correlación con otra categoría diferente—. Posteriormente, se generaron 840 atlas —aproximadamente 10 por cada categoría— a través de un algoritmo no supervisado de *clustering* que seleccionaba aquellos fragmentos que mejor representaban estadísticamente a la media para cada categoría, al mismo tiempo que los agrupaba en función de su información visual (colores, perfiles, formas, etc.). Así, cada atlas de la interfaz visualiza las características visuales (fragmentos de imágenes) que, según lo *aprendido* por la CNN, serán más relevantes para clasificar nuevas imágenes en las diferentes categorías del archivo. En la parte inferior izquierda de cada atlas encontramos la *etiqueta* de la categoría principal —aquella a la que representa cada atlas— y, en menor tamaño, las *etiquetas* correspondientes a las categorías secundarias de los fragmentos — aquellos *outputs/etiquetas* con los que la CNN relaciona estos fragmentos de imagen en un




Figura 4

Captura de la interfaz *Abstract Machine* (2020), donde se puede ver uno de los atlas asociados a la categoría *history*. En las categorías secundarias de este atlas encontramos: *boats, men, soldiers, architecture, african americans, actors, ethnography, baseball, indians of north america* y *monuments*. Para ver un video de la interacción con el interfaz *Abstract Machine*, visitar el siguiente [link](#).



Figura 5

Captura de la interfaz *Abstract Machine* (2020), donde se puede ver uno de los atlas asociados a la categoría *flowers*. En las categorías secundarias de este atlas encontramos: *ornaments, roads, women, trees, plants* y *history*.

menor porcentaje, pero que le servirán para *identificar* otras categorías —. El usuario podrá *hacer clic* en los fragmentos de imagen, lo que le llevará a un nuevo atlas cuya categoría principal se corresponderá con la categoría secundaria asociada a dicho fragmento. De esta forma, la interfaz *Abstract Machine* nos permite navegar por las relaciones que la red CNN establece durante su *aprendizaje* entre las características visuales del *data set* y sus diferentes categorías.

A diferencia de *Abstract Machine*, en *Class(h)* (Figuras 6 y 7) no hay ninguna referencia directa a las imágenes originales del archivo; en su lugar, el usuario se encuentra con imágenes que fueron producidas por una red GAN que generó 5.500 imágenes para cada una de las 70 categorías seleccionadas para el diseño de esta interfaz. Aunque se presenten como abstractas para el ojo humano, cada una de estas imágenes contiene las características mínimas necesarias para ser clasificadas correctamente por la CNN. Es decir, cuando la red GAN generaba, por ejemplo, imágenes para la categoría *indians of north america*, su producción era interrumpida cuando la CNN asociaba las imágenes generadas a dicha *etiqueta* con un 80% de acierto, aunque para la percepción humana continuara siendo una imagen irreconocible. En la interfaz *Class(h)* encontramos cada una de estas imágenes de forma individual, acompañadas a la derecha por una *nube* de categorías asociadas. Al igual que ocurre con *Abstract Machine*, encontramos una categoría principal que presenta mayor porcentaje de correlación (*etiqueta* con mayor tamaño), así como un conjunto de categorías secundarias que la CNN relaciona en menor porcentaje con la imagen — a menor tamaño de las *etiquetas*, menor porcentaje de correlación que la CNN establece entre la categoría y la imagen —. El usuario puede *hacer clic* en las *etiquetas*, lo que le dará acceso a una nueva imagen con nuevas categorías secundarias, y cuya categoría principal será aquella *etiqueta* donde se *clició*. Al presentarse de forma aislada y al lado de una *nube* de categorías, las imágenes de la interfaz presentan un carácter evocativo que permite al usuario especular con posibles sentidos para estas imágenes, estableciendo relaciones libres entre las imágenes y las categorías. Acompañando a la interfaz, se dispone una selección de paneles (Figura 10) realizados a través de un algoritmo de *clustering* que agrupó formalmente las imágenes generadas para cada categoría. La acumulación que presentan estos paneles ayudará a visualizar los rasgos visuales más representativos de cada categoría, permitiendo reconocer algunas de sus características — como ocurre en el panel *animals* (Figura 8 inferior) —, así como algunos de los sesgos de los archivos que conforman la Colección — por ejemplo, el panel *women* (Figura 8 superior) muestra una clara tendencia de nuestro *data set* a asociar la idea de mujer a lo que parecen diseños y patrones de vestidos; un sesgo que se refuerza si navegamos por la interfaz *Abstract Machine*, donde la categoría *women* también se encuentra fuertemente asociada a las categorías *flowers* y *ornaments* (ver Figura 5) —.

Tanto *Class(h)* como *Abstract Machine* ofrecen una interacción *gamificada* que, gracias a la visualización de los procesos de *aprendizaje* de la red CNN, nos permite navegar por los espacios latentes y liminales de la Colección — del *data set* con el que la visión



—
Figura 6
Captura de la interfaz *Class(h)* (2021), donde se puede ver una imagen generada para la categoría *african americans*, así como las categorías secundarias asociadas a dicha imagen. Para ver un vídeo de la interacción con el interfaz *Class(h)*, visitar el siguiente [link](#).

—
Figura 7
Captura de la interfaz *Class(h)* (2021), donde se puede ver una imagen generada para la categoría *ethnography*, así como las categorías secundarias asociadas a dicha imagen.



—
 Figura 8
 Fragmentos de dos de los paneles del dispositivo *Class(h)*. En la parte superior, fragmento del panel *women* (impresión fotográfica, 50x75 cm, 2021); en la parte inferior, fragmento del panel *animals* (impresión fotográfica, 50x75 cm, 2021).



—

Figura 9

Vista de la instalación *Abstract Machine*. A la izquierda se puede ver el software interactivo (monitor y *trackpad* en soporte de metal). A la derecha encontramos un atlas general de nuestro *data set* (*Atlas*, impresión fotográfica, 100x150 cm, 2020). ARCO, Madrid, 2021.



Figura 10

Vistas parciales de la instalación *Class(h)*, compuesta por 20 paneles y software interactivo. Imagen superior: Art-o-rama, Marsella, 2023. Imagen inferior: Shazar Gallery, Nápoles, 2021.

artificial *aprendió a ver*—, pudiendo establecer relaciones rizomáticas entre las categorías y los rasgos visuales de la Colección y sus archivos históricos.

Conclusión

De acuerdo con Barthes (1957, 241), si queremos resistir al *habla mítica* debemos ligar el lenguaje — en este caso el discurso de la IA — a la elaboración de las cosas. Según este planteamiento semiótico, para resistir al mito de la agencia autónoma de la IA — y con ello politizar esta tecnología — debemos vincular su agencia a la actividad sociotécnica que la compone y la modifica, una actividad que, de acuerdo con Pink (2021), debe contemplar tanto la historia *oficial* de su programación como sus diferentes usos — una vez que ambos forman parte del mismo proceso, como se intentó demostrar con el ejemplo de los *notebooks* —. Como indica Latour (1999, 227), atender a su construcción y composición no debe implicar una postura *antifetichista* que niegue la agencia de la IA — algo inviable en un mundo mediado tecnológicamente, donde ya no es posible anular la delegación que realizamos en los objetos tecnológicos—; pero tampoco podemos generar una idolatría (fetichismo) de esta tecnología, como si actuara de forma totalmente ajena a procesos externos. Debemos, por tanto, atender a la composición de su agencia sin negar su capacidad para *actuar*. En este sentido, Latour (1999, 330) parece ir al encuentro del *encantamiento de la tecnología* de Gell para recordarnos que

es justamente *el hecho de que sea algo construido* lo que hace que sea algo tan real, tan autónomo, tan independiente de nuestros propios actos. (...) los vínculos no disminuyen la autonomía, la estimulan. (...) los términos ‘construcción’ y ‘realidad autónoma’ son *sinónimos*.

Resistir al mito de agencia autónoma de la IA es, por tanto, una tarea complicada, una vez que para relacionarnos de forma eficaz con la tecnología *inteligente* esta debe presentarse de forma unitaria, como una agencia capaz de activar en el usuario una experiencia de *copresencia* (Gell 1998, 52). Además, esta dificultad se incrementa con el hecho de que cada artefacto de IA está compuesto por numerosos programas y tareas, “una serie de subprogramas anidados unos dentro de otros, al estilo de las muñecas rusas” (Latour 1999, 228). Esto supone que, para poder *asomarnos* a la caja negra de un subprograma — por ejemplo, a la composición del *data set* de *entrenamiento* o a la mediación del cálculo algorítmico de la red neuronal —, debemos apartarnos de la tarea principal —sea esta el diseño de una red o su uso para una otra tarea—, de tal forma que, cuando retomamos nuestra tarea, la caja negra del subprograma se vuelve a cerrar, “convirtiéndose en algo completamente invisible en la secuencia principal de la acción” (Latour 1999, 228). Es decir, aunque el usuario se *asome* a una parte de la composición del artefacto *inteligente*, al usarlo para una otra tarea volverá a relacionarse con él como si fuera un agente unitario y autónomo.

Retomando el paralelismo entre la caja negra latouriana y el mito barthesiano, podemos decir que el análisis de Latour lleva a la acción técnica los problemas que encuentra Barthes (1957, 229) para resistir al mito, quien nos dice que es extremadamente difícil reducirlo desde el interior, “pues ese mismo movimiento que hacemos para liberarnos de él, de pronto se vuelve una presa del mito: el mito puede, en última instancia, significar la resistencia que se le opone”. Para afrontar esta dificultad, Barthes (1957, 229) propone realizar un *mito artificial*, un mito del mito. Esto se traduce en fabricar un nuevo mito a partir del mito de agencia autónoma de la IA: *hablar* de su (supuesta) autonomía desde la *historia* de su composición, sin por ello negar su agencia. Si, de acuerdo con Forty (1986, 9), “design has the capacity to cast myths into an enduring, solid and tangible form, so that they seem to be reality itself”, la propuesta que aquí se ha presentado pretende materializar, a través del diseño de interfaces humano-IA experimentales, un posible *mito artificial* que reconfigure la agencia de esta tecnología. Para ello, no basta con abrir las cajas negras de la IA, es decir, no basta con recuperar y mostrar la dimensión social e interpretativa de la actividad que da forma a los *outputs* que nos ofrece esta tecnología, ya que el mito de la agencia autónoma de la IA acabará cerrándolas nuevamente. Para poder diseñar este *mito artificial* ha sido necesario preservar el *encantamiento* que activa nuestra relación con los objetos técnicos, con la IA.

En este sentido, el método híbrido desarrollado en esta investigación permitió visualizar la actividad de una de las *capas ocultas* de una red CNN, al mismo tiempo que enfatizaba su dimensión epistémica, visual y retórica — más allá de la *explicabilidad* que procuran las técnicas de *interpretabilidad* computacional que fueron empleadas —. Esta estrategia, que denominé apropiación artística de los algoritmos implicados en la IA y sus visualizaciones, busca provocar el *efecto de resistencia* a la comprensión del usuario que, de acuerdo con Gell (1999, 168), será necesario para que nos relacionemos de manera eficaz con el objeto tecnológico. Así, estas interfaces ofrecen una alternativa a la *resistencia* que produce la imagen autónoma de la IA, al generar un otro tipo de *extrañeza* respecto a la máquina que obligue al usuario a tener que interpretar el funcionamiento de la interfaz — y con ello dar otro sentido a la agencia de la IA —.

Podemos decir que las interfaces aquí presentadas ofrecen un enfoque epistémico e interpretativo que, de acuerdo con la postura humanista de Drucker (2020, 3) sobre la visualización computacional de la información, permiten cambiar la relación unidireccional entre *data* y *display*, convirtiendo el proceso de visualización estándar en un intercambio bidireccional, donde el conocimiento no emerge de la mera lectura de los *outputs* producidos por la supuesta autonomía de esta tecnología, si no de negociaciones en continuo desarrollo entre los procesos interpretativos del humano y la IA.

9 Recordemos la *disyunción actoral* que tiene lugar durante la programación de *deep learning*, por la cual el diseñador/programador delega y otorga *inteligencia* a los cálculos algorítmicos, que pasarán a llamarse *inteligencia artificial*.

Financiamento

La investigación que condujo a estos resultados fue financiada por la Fundação para a Ciência e a Tecnologia (FCT) de Portugal, a través de la beca de investigación individual 2020.04554.BD

Referencias

- Annany, Mike, and Kate Crawford. 2016. "Seeing without knowing: Limitations of the transparency ideal and its application to algorithmic accountability." *New Media & Society* 20 (3): 973-989. <https://doi.org/10.1177/1461444816676645>.
- Apprich, Clemens. 2018. "Secret Agents. A psychoanalytic Critique of Artificial Intelligence and Machine Learning." *Digital Culture & Society* 4 (1): 29-44. <https://doi.org/10.14361/dcs-2018-0104>.
- Barthes, Roland. 2012. *Mitologías*. Traducido por Héctor Schmucler. Madrid: Editorial Biblioteca Nueva.
- Carter, Shan, Zan Armostron, Ludwing Schubert, Ian Johnson, and Chris Olah. 2019. "Exploring Neural Networks with Activation Atlases." *Distill*. <https://doi.org/10.23915/distill.00015>.
- Deleuze, Gilles, y Felix Guattari. 1985. *El Anti Edipo: capitalismo y esquizofrenia*. Traducido por Francisco Monge. Barcelona: Editorial Planeta.
- Drucker, Johanna. 2020. *Visualization and Interpretation*. Cambridge: The MIT Press.
- Dyson, George. 2015. *La catedral de Turing: los orígenes del universo digital*. Traducido por Francisco José Ramos Mena. Barcelona: Penguin Random House.
- Forty, Adrien. 1986. *Objects of Desire: design and society since 1750*. London: Thames & Hudson.
- Griffiths, Catherinne. 2018. "Visual Tactics Toward an Ethical Debugging." *Digital Culture & Society* 4(1): 217-226. <https://doi.org/10.14361/dcs-2018-0113>.
- Gell, Alfred. 2016. *Arte y agencia: una teoría antropológica*. Traducido por Ramsés Cabrera Olivares. Buenos Aires: SB.
- _____. 2006. *The Art of Anthropology: essays and diagrams*. New York: Berg.
- Geismar, Haidy, and Hannah Knox, eds. 2021. *Digital Anthropology*. 2nd ed. New York: Routledge.
- Holmes, Douglas, and George E. Marcus. 2008. "Collaboration Today and the Re-Imagination of the Classic Scene of Fieldwork Encounter." *Collaborative Anthropologies* 1 (1): 81-101. <https://doi.org/10.1353/cla.o.0003>.
- Horst, Heather A. 2016. "Being in Fieldwork: collaboration, digital media and ethnographic practice." In *eFieldnotes: the makings of anthropology in a digital world*, edited by Roger Sanjek and Susan Tratner, 153-168. University of Pennsylvania Press.
- Hutchins, Edwin. 1995. *Cognition in the Wild*. Massachusetts: The MIT Press.
- Ingold, Tim. 2013. *Making: Anthropology, Archaeology, Art and Architecture*. London: Routledge.
- Larson, Erik J. 2022. *El mito de la Inteligencia Artificial: por qué las máquinas no pueden pensar como nosotros lo hacemos*. Traducido por Milo J. Krmpoti. España: Shackleton Books, S.L.
- Latour, Bruno. 1986. "Visualisation and Cognition: thinking with eyes and hands." In *Knowledge and Society Studies in the Sociology of Culture Past and Present*, vol. 6, edited by H. Kuklick and E. Long, 1-40. Jai Press.
- _____. 2001. *La esperanza de Pandora: ensayos sobre la realidad de los estudios de la ciencia*. Traducido por Tomás Fernández Aúz. Barcelona: Gedisa, S.A.
- Latour, Bruno, and Steve Woolgar. 1986. *Laboratory Life: the construction of scientific facts*. Princeton, New Jersey: Princeton University Press.
- Lindsay, Grace. 2022. *Models of the Mind: How physics, engineering and mathematics have shaped our understanding of the brain*. London: Bloomsbury.
- Magnet, Shoshana A. 2011. *When Biometrics Fail: Gender, Race, and the Technology of Identity*. Durham: Duke University Press.
- Marcus, George E. 1995. "Ethnography in/of the World System: the emergence of multi-sited ethnography." *Annual Review of Anthropology* 24: 95-117. <https://doi.org/10.1146/annurev.an.24.100195.000523>.
- Monin, Monica. 2018. "Unconventional Classifiers and Anti-social Machine Intelligences: Artists Creating Spaces of Contestation and Sensibilities of Difference Across Human-Machine Networks." *Digital Culture & Society* 4 (1): 227-237. <https://doi.org/10.25969/mediarep/13534>.

- Pink, Sarah. 2021. "Digital Futures Anthropology." In *Digital Anthropology*, edited by H. Geismar and H. Knox, 2nd ed., 307-324. New York: Routledge.
- Pink, Sarah, and Juan Francisco Salazar. 2017. "Anthropologies and Futures: setting the agenda." En *Anthropologies and Futures: researching emerging and uncertain worlds*, edited by Juan Francisco Salazar, Sarah Pink, Andrew Irving and Johannes Sjöberg, 3-22. London: Bloomsbury.
- Preston, John, and Mark Bishop, eds. 2002. *Views into the Chinese Room: new essays on Searle and artificial intelligence*. New York: Oxford University Press.
- Searle, John. 1984. *Minds, Brains and Science*. Cambridge: Harvard University Press.
- Sekula, Allan. 1986. "The Body and the Archive." *October* 39: 3-64. <https://doi.org/10.2307/778312>.
- Suchman, Lucy. 2007. *Human-Machine Reconfigurations: Plans and Situated Actions*, 2nd ed. New York: Cambridge University Press.
- Verbeek, Peter-Paul. 2006. "Materializing Morality. Design Ethics and Technological Mediation." *Science, Technology, & Human Values* 31 (3): 361-380. <http://www.jstor.org/stable/29733944>.

Nota biográfica

Andrés Pachón es doctorando en Antropología Social y Cultural en la Universidad de Coimbra con una beca de la Fundação para a Ciência e a Tecnologia. Licenciado en Bellas Artes por la Universidad Complutense de Madrid (2008), concluyó un Magister en Teoría y Práctica de las Artes Plásticas Contemporáneas en esa misma universidad (2009), así como un Master en Antropología Social y Cultural en la Universidad de Coimbra (2019). Con una larga trayectoria artística, colaborando con instituciones como el Museo Quai Branly de París, el Museo Nacional de Antropología de Madrid o el Archivo Fotográfico del Museo de Arte de Lima (Perú), en 2019 recibió una Beca Leonardo de la Fundación BBVA a

Investigadores y Creadores Culturales, realizando un proyecto que sirvió de punto de partida para su investigación doctoral, donde cruza la etnografía experimental con la práctica artística para desarrollar una antropología de la Inteligencia Artificial.

ORCID

[0000-0003-2518-8540](https://orcid.org/0000-0003-2518-8540)

CIÊNCIA ID

[A315-B228-2AED](https://ciencia.id.ua315-B228-2AED)

Dirección institucional

Universidad de Coimbra
CC Martim de Freitas, 3000-456 Coimbra.

Declaración de conflicto de intereses

El autor no ha declarado ningún posible conflicto de intereses en relación con la investigación, la autoría y/o la publicación de este artículo.

Para citar este artículo

Pachón, Andrés. 2024. "Interfaces epistémicas de visualización e interpretación: una posible resistencia al mito de la agencia autónoma en la IA." *Revista de Comunicação e Linguagens* (60): 91-113. <https://doi.org/10.34619/2ohf-ury5>.

Recibido Received: 2024-01-23

Aceptado Accepted: 2024-06-09

© Andrés Pachón. Este es un artículo de acceso abierto distribuido conforme a los términos de la licencia Creative Commons Attribution 4.0 (<http://creativecommons.org/licenses/by/4.0>), que permite distribuir, modificar, adaptar y utilizar el material en cualquier medio o formato con fines no comerciales, siempre y cuando se mencione al autor.