

# Sobre La Teoría de Actor Red y el papel de la IA en el cambio climático

## On Actor Network Theory and the role of AI in climate change

Jorge Luis Morton Gutiérrez: Universidad Autónoma Metropolitana, México.  
[jorge.morton@cua.uam.mx](mailto:jorge.morton@cua.uam.mx)

Fecha de Recepción: 13/05/2024

Fecha de Aceptación: 24/07/2024

Fecha de Publicación: 15/08/2024

### Cómo citar el artículo:

Morton Gutiérrez, J. L. (2024). Sobre La Teoría de Actor Red y el papel de la IA en el cambio climático [On Actor Network Theory and the role of AI in climate change]. *European Public & Social Innovation Review*, 9, 1-17. <https://doi.org/10.31637/epsir-2024-518>

### Resumen:

**Introducción:** El cambio climático se presenta como el desafío más grande para la humanidad. **Metodología:** Sin embargo, las nuevas tecnologías, especialmente la inteligencia artificial (IA), ofrecen herramientas fundamentales para comprender este fenómeno y desarrollar mecanismos que permitan mitigarlo, adaptarse a él e incluso combatirlo. **Resultados:** A pesar de sus beneficios potenciales, la IA también juega un papel significativo al contribuir a los problemas asociados con el cambio climático, tanto en su proceso de entrenamiento, implementación y mantenimiento, como en su notable consumo de recursos como el agua. **Discusión y Conclusión:** Por ende, este ensayo busca emplear las herramientas y conceptos de la Teoría de la Actor-Red para analizar críticamente el papel de la IA en el cambio climático: cómo su implementación y gobernanza pueden diseñarse para maximizar los beneficios y minimizar los impactos negativos, así como entender cómo actúa como un agente que puede agravar este fenómeno global.

**Palabras clave:** Cambio climático; actante; inteligencia artificial; anti-programa; asociaciones; relaciones de poder; uso intensivo.

### Abstract:

**Introduction:** Climate change is presented as the greatest challenge for humanity. **Methodology:** However, new technologies, especially artificial intelligence (AI), offer fundamental tools to understand this phenomenon and develop mechanisms to mitigate it, adapt to it and even combat it. **Results:** Despite its potential benefits, AI also plays a significant role in contributing to the problems associated with climate change, both in its training,

implementation and maintenance process, and in its notable consumption of resources such as water. **Discussions and Conclusion:** Therefore, this essay seeks to employ the tools and concepts of Actor-Network Theory to critically analyze the role of AI in climate change: how its implementation and governance can be designed to maximize benefits and minimize negative impacts, as well as how to understand how it acts as an agent that can aggravate this global phenomenon.

**Keywords:** Climate change; actant; artificial intelligence; anti-program; associations; power relations; intensive use.

## 1. Introducción

La inteligencia artificial (IA) y el cambio climático están estrechamente relacionados. Por un lado, la IA surge como una herramienta capaz de ofrecer soluciones al cambio climático o, al menos, de mediar y mitigar sus efectos más significativos. Por otro lado, la IA, especialmente los modelos de IA generativa (Gen AI), se ha convertido en un gran consumidor de agua y energía, lo que contribuye de manera significativa a este peligroso fenómeno.

Se han estudiado detalladamente los grandes problemas y oportunidades de la IA en áreas como finanzas, entretenimiento, medicina, industria y educación. No obstante, también existen desafíos importantes asociados a ella. Estos incluyen sesgos discriminatorios, problemas de explicabilidad, acceso a información, riesgos para la privacidad y dificultades en torno a la responsabilidad.

Sin embargo, hay pocos trabajos que aborden de manera sistemática el impacto y la relación de la IA con el cambio climático. Aunque existen valiosas investigaciones empíricas, es necesario adoptar una perspectiva inter y transdisciplinaria que explique esta relación. Por lo tanto, en este ensayo se propone abordar el problema de la IA y su relación con el cambio climático basándonos en las herramientas y conceptos proporcionados por la Teoría de Actor-Red (ANT por sus siglas en inglés).

En última instancia, esto representa un llamado a la acción colectiva y a la responsabilidad compartida. La ANT invita a considerar no solo a los humanos, sino también a las tecnologías, como actores dentro de una red interconectada. En este contexto, la IA actúa como un agente que se relaciona con otros nodos de la red. Propone programas para mitigar los problemas del cambio climático, pero también puede incorporar programas que los agravan.

Al abordar el papel de la IA en el cambio climático desde la perspectiva de la ANT, podemos desentrañar la complejidad de sus interacciones y diseñar estrategias más efectivas para un futuro sostenible. Para lograrlo, este ensayo explorará los conceptos clave de la teoría, repasará brevemente qué son las herramientas de la IA y cómo funcionan, y examinará la relación tanto positiva como negativa de la IA en torno al cambio climático, considerando nociones clave como programa y anti-programa.

### 1.1. La teoría de actor red

La teoría de actor-red (TAR) sirve para explicar la relación entre el cambio climático y la inteligencia artificial. Esto es porque genera un escenario teórico-metodológico que ayuda a comprender las cadenas de asociaciones entre actores humanos y no humanos. Para ello, la TAR, de la mano de figuras importantes como Callon y particularmente Bruno Latour, ha desarrollado una serie de conceptos teórico-metodológicos que ayudan a comprender fenómenos y problemas sociotécnicos desde una perspectiva inter y transdisciplinaria.

El primero de estos conceptos es la figura del actante. Un actante es cualquier actor que impulse movimiento sobre otros actantes, y no necesariamente tiene que ser un actor humano o un actor no humano. Según Latour (2017), esta definición no implica una motivación especial de los actores humanos individuales ni de los humanos, y hay que considerar que un actante puede ser literalmente cualquier cosa, siempre que se le reconozca como fuente de una acción.

El segundo concepto clave en torno a la TAR, y quizás uno de los más complicados, es el de cuasi-objeto. Latour (1993) explica que los cuasi-objetos son mucho más sociales, más fabricados y colectivos que las partes “duras” de la naturaleza; sin embargo, de ninguna manera son recipientes arbitrarios de una sociedad completamente desarrollada. Asimismo, el autor plantea que un cuasi-objeto debe ser considerado como un actante en movimiento que transforma a quienes lo mueven, porque ellos transforman el objeto en movimiento.

Un cuasi-objeto, entonces, es un híbrido entre lo natural y lo social que no concentra las partes más naturales de uno u otro elemento y que impulsa movimiento sobre otros actantes de la red de asociaciones. Esto tiene una enorme relación con otro concepto de TAR, y particularmente de Latour: los propios híbridos. Latour (1993) explica que los híbridos son producto de una traducción que crea elementos tanto naturales como sociales; esto es, a diferencia del proceso de purificación que justamente separa lo natural de lo social. La TAR deja de lado la sociedad y la naturaleza para considerar únicamente la producción de significados; luego, rompiendo con los límites de la semiótica sin perder sus herramientas, da actividad a los actores semióticos, convirtiéndolos en nuevos híbridos ontológicos, entidades creadoras del mundo.

En este sentido, se puede apreciar un punto de semejanza entre cuasi-objeto e híbrido. Dado que ambos conceptos se refieren a la intersección y la co-construcción de lo natural y lo social, se puede ver que tanto los cuasi-objetos como los híbridos actúan como mediadores y transformadores en la red de asociaciones. Los cuasi-objetos, al ser actantes en movimiento, influyen y son influenciados por otros actores en la red, creando un dinamismo constante; por otro lado, los híbridos, como resultado de la traducción de elementos naturales y sociales, demuestran cómo las fronteras entre lo natural y lo social no son fijas, sino continuamente negociadas y redefinidas. Así, tanto los cuasi-objetos como los híbridos en la TAR nos muestran que la realidad es una construcción conjunta de múltiples actores, donde las categorías tradicionales de naturaleza y sociedad se entrelazan y se transforman mutuamente.

Por eso, otro elemento importante en la TAR es justo el de la traducción. De acuerdo con Callon *et al.* (1986), la traducción es una definición de roles, una distribución de funciones y la delineación de un escenario; habla por otros, pero en su propio lenguaje. Asimismo, la traducción exitosa depende de la capacidad del mundo del actor para definir e inscribir entidades que puedan desafiar estas definiciones e inscripciones.

Quizás el mejor ejemplo del concepto de la traducción se puede ver en el texto *Institutional Ecology, ‘Translations’ and Boundary Objects: Amateurs and Professionals in Berkeley’s Museum of Vertebrate Zoology* de Star y Griesemer (1989). Aquí, los autores exploran cómo la cooperación y la heterogeneidad afectan el trabajo científico dentro del contexto del Museo de Zoología de Vertebrados de la Universidad de California, Berkeley, durante sus primeros años. En este sentido, y en aras de articular una explicación, Star y Griesemer (1989) reformulan el concepto de traducción donde hay un número indefinido de formas en que los emprendedores de cada mundo social cooperante pueden convertir su propio trabajo en un punto de paso obligatorio para toda la red de participantes.

Con base en las definiciones de Callon *et al.* (1986) y de Star y Griesemer (1989), la traducción se da donde distintos actores heterogéneos colaboran para alcanzar un objetivo común. Puntualmente, Star y Griesemer (1989) centran esto en el objeto de contorno o *boundary object* que, de acuerdo con los autores, son objetos con la flexibilidad necesaria para ajustarse a las necesidades locales y a las restricciones de las distintas partes que los emplean, pero con la solidez suficiente para conservar una identidad común en diversos contextos. En este sentido, la traducción busca fijar un objetivo común dentro de la red de actores a partir de la colaboración entre diferentes tipos de actores y, desde la perspectiva de este ensayo, para facilitar la interpretación de esta meta entre diferentes tipos de actores.

El siguiente concepto que hay que examinar es el de programa y anti-programa de Latour. En el ensayo *Technology is Society Made Durable*, Latour (1990) ejemplifica las relaciones de poder al examinar las asociaciones entre actores no humanos y actores humanos. Para este trabajo, hay que resaltar el Llaverero de Latour; como ejemplo, los artefactos y elementos no humanos contribuyen a la permanencia de las fuerzas sociales mediante la red de asociaciones.

Latour explica que las asociaciones sociales no están cohesionadas por un algo etéreo como la cohesión social, sino que pasan por una serie de intenciones y resistencias atravesadas por actores no humanos. Para ello, Latour (1990) pone como ejemplo el problema de que la gente olvida regresar las llaves de su habitación de hotel. Para resolver ese problema, el recepcionista crea una serie de programas, intenciones, donde emplea objetos como letreros para invitar a las personas a dejar sus llaves; no obstante, los huéspedes ponen resistencia o simplemente olvidan dejar las llaves hasta que el dueño del hotel agrega un pesado llaverero tan incómodo que fuerza a las personas a regresar las llaves en lugar de estar cargando con eso.

En este sentido, Latour (1990) plantea que el programa “dejar la llave en la recepción”, que actualmente es meticulosamente seguido por la mayoría de los clientes, no es exactamente el mismo con el que empezaron. Ahora bien, si algún cliente raro por algún motivo decide romper el anillo que une el llaverero a las llaves, entonces un innovador cándido soldaría el anillo a las llaves creando la resistencia a la resistencia, un anti-anti-programa al anti-programa. Callon *et al.* (1986) plantea que en ocasiones la traducción se transforma en traición, *traduttore-traditore*, cuando una entidad comprometida se rehúsa a ingresar al mundo de los actores para interactuar con otros, o en este caso cuando alguien se rehúsa, resiste y crea resistencia a los compromisos e intenciones planteadas en el programa (no regresar las llaves).

Estos conceptos sirven para entender la compleja red de actores involucrados en el cambio climático, incluyendo agentes humanos y no humanos. Particularmente, porque ayudan a mapear las relaciones de poder, las intenciones y resistencias en torno a los actores humanos y no humanos. Y en el caso de la relación entre cambio climático e inteligencia artificial, la TAR puede ayudar a observar las relaciones de poder y resistencias en torno a los actores humanos y no humanos que la componen.

Para ello es necesario anclar un poco la taxonomía de programa y anti-programa de Latour. En este sentido, un programa es la intención de todos los miembros de la red para que cooperen dentro de ella para alcanzar el objetivo propuesto. Y el anti-programa puede ser tanto la resistencia al programa como la desviación de este, o la traición de las intenciones originales del programa. Y al final, como lo plantea el propio Latour, el anti-anti-programa surge como resistencia a las dos modalidades propuestas del anti-programa o la intención de corrección de estos mismos anti-anti-programas.

Así pues, se puede examinar la IA como actor en la red del cambio climático. Esto es, mediante el análisis de la IA como un actor dentro de la red sociotécnica del cambio climático,

interactuando con otros actores y produciendo efectos significativos. Para ello, se puede observar el rol de la IA en torno al programa: ayudar a contener los efectos del cambio climático; y un anti-programa: los efectos que aceleran el cambio climático debido a los procesos que implican la implementación y uso de la inteligencia artificial.

## 2. Metodología

La IA tiene una estrecha relación con el cambio climático, ya sea para generar mitigación y adaptación, pero también en torno a los procesos que abonan para que este preocupante fenómeno empeore. Ahora bien, dentro de los beneficios, la IA se puede emplear para optimizar el consumo de energía y otros recursos, reduciendo así las emisiones de gases de efecto invernadero. Además, las plataformas y herramientas de IA pueden auxiliar en el desarrollo de energías renovables; esto es, en torno al diseño y gestión de sistemas de energía renovable más eficientes y sostenibles.

Hay que mencionar que la inteligencia artificial y el cambio climático son los fenómenos más importantes que enfrenta la humanidad: ambos son consecuencias de procesos sociotécnicos. El cambio climático ha causado daños sustanciales y pérdidas cada vez más irreversibles en los ecosistemas terrestres, de agua dulce, criosféricos, costeros y oceánicos (IPCC). Pero lo más importante es que el cambio climático, que se basa en el calentamiento global del planeta en torno al aumento de gases invernadero como el CO<sub>2</sub>, CH<sub>4</sub>, CFCs, y N<sub>2</sub>O, es un fenómeno que en su mayoría es consecuencia sociotécnica de la actividad humana (Olatunde-Aiyedun *et al.*, 2022).

Ahora bien, el cambio climático no es un proceso que se espera, sino que ya está presente. Inundaciones, sequías, olas de calor, tormentas extremas e incendios forestales, que se prevé que empeoren en el futuro, están rompiendo récords (Olatunde-Aiyedun *et al.*, 2022); todo esto en torno a la relación de actores humanos y no humanos en constelaciones de actantes como lo son los sistemas de producción, sistemas de transporte, modelos de generación energética y cadenas logísticas y de suministro, así como la deforestación, entre otras. Por ello es importante conocer en qué medida la IA contribuirá a mitigarlo y a crear procesos de adaptación frente a este proceso.

Las medidas de adaptación al cambio climático son aquellas que buscan sobrellevar los efectos del cambio climático. Estas medidas emplean mecanismos para contener y reducir el impacto presente de este fenómeno como crear barreras contra inundaciones, sistemas de cultivo resilientes, entre otras medidas. Así pues, la adaptación se centra en ajustar las sociedades y los ecosistemas para resistir y enfrentar el cambio climático, protegiendo a comunidades vulnerables y preservando recursos naturales críticos (Rayhan *et al.*, 2023).

Se entienden por medidas de mitigación los procesos que buscan contener los efectos adversos del cambio climático. Rayhan *et al.* (2023) explican que las medidas de mitigación buscan reducir las emisiones de gases de efecto invernadero, principalmente mediante la transición hacia fuentes de energía limpia y renovable, mejorando la eficiencia energética e implementando prácticas sostenibles de uso del suelo. Asimismo, los esfuerzos de mitigación embebidos en el contexto más amplio del desarrollo pueden aumentar el ritmo, la profundidad y la amplitud de las reducciones de emisiones (IPCC, 2023); esto genera un mecanismo en el que actores humanos y no humanos se coordinan para hacer frente de manera sociotécnica al aumento de las temperaturas globales en aras de prevenir los efectos más graves de este fenómeno.

Una de las herramientas más rescatables en las que la IA genera medidas de mitigación es la

agricultura inteligente. En este sentido, Rayhan *et al.* (2023) plantean que la IA facilita la agricultura de precisión, donde los agricultores pueden adaptar estrategias de riego, fertilización y control de plagas a plantas individuales o secciones de campos. Es decir, la IA optimiza procesos que pueden ayudar a aumentar la producción de alimentos sin que esto implique un aumento de emisiones en consecuencia.

Otra herramienta en torno a las medidas de mitigación que ofrece la IA es la capacidad de optimizar los procesos de producción y generación de energías limpias. Por ejemplo, los algoritmos de IA pueden predecir patrones solares y eólicos, ayudando a los operadores de red a optimizar la integración de energía renovable en la red eléctrica (Rayhan *et al.*, 2023). Asimismo, la IA juega un papel relevante en el mismo proceso de desarrollo e investigación de energías limpias como optimizar el porcentaje de electricidad que producen los paneles solares (Mohammad *et al.*, 2023); además, la IA y sus modelos incluso pueden ayudar en los procesos de conservación y reforestación (Raihan, 2023).

Dentro de las medidas de adaptación, la IA puede ayudar al desarrollo de infraestructuras resilientes al clima, gestión de agua, protección y restauración de ecosistemas naturales y mejora de alerta temprana ante desastres naturales. Changlani *et al.* (2023) explican, por ejemplo, que los algoritmos de IA pueden identificar y rastrear fenómenos climáticos como huracanes, incendios forestales y el derretimiento de las capas de hielo. Esto se debe a la gran capacidad que tienen los modelos de la inteligencia artificial, en especial los ligados al aprendizaje de máquina (ML), de traducir y encontrar patrones en grandes cantidades de datos; de esta manera, el ML se ha utilizado para traducir datos crudos como documentos de texto o imágenes satelitales en conocimientos utilizables para la I+D, la formulación de políticas y la planificación de sistemas (Wong, 2024).

En suma, la IA se posiciona como una herramienta poderosa para mitigar y adaptarse a los efectos del cambio climático. Iniciativas como el Modelo GEOS de la NASA, el Sistema Global de Observación de la Tierra (IPCC, 2023), o el Proyecto IKI emplean tecnología de inteligencia artificial para anticipar patrones meteorológicos, permitiendo a comunidades y autoridades planificar de manera más eficaz su adaptación al cambio climático y la mitigación de sus efectos (Masterson, 2024). La IA también puede contribuir de las emisiones que aceleran el cambio climático y generar consecuencias ambientales ligadas a su empleo y desarrollo en torno a su consumo de agua.

### **2.1. Consecuencias de la IA en torno al cambio climático**

La inteligencia artificial es importante para el cambio climático. Promueve medidas para mitigar y adaptar a la humanidad a las consecuencias de este fenómeno; por ejemplo, usando datos sobre el comportamiento y las preferencias de los usuarios, los sistemas de transporte pueden promover la adopción de modos de transporte más sostenibles (Chen *et al.*, 2023). No obstante, también puede producir efectos que aceleren y empeoren el cambio climático, como la adopción de vehículos autónomos que puede afianzar el papel de los camiones y los automóviles privados como medios de transporte dominantes, en lugar de habilitar infraestructura y espacio para opciones de transporte menos intensivas en emisiones, como ferrocarriles, transporte público y micromovilidad (Wong, 2024).

Asimismo, la IA ocasiona otros problemas importantes. Estos problemas están ligados a una serie de derechos humanos y se pueden considerar como los tres grandes problemas de la inteligencia artificial. De acuerdo con Blackman (2022), los tres grandes problemas de la IA son imparcialidad o sesgos (relacionado en buena parte con el derecho a la no discriminación), transparencia (relacionado con el derecho al acceso a la información) y privacidad (ligado a

este mismo derecho reconocido por la Declaración de los Derechos Humanos de las Naciones Unidas en 1948).

Estos problemas en torno a la IA son tanto sociales como técnicos y se pueden dar en diferentes partes del proceso del desarrollo e implementación de los modelos. Además, algunos problemas, como los sesgos, son imposibles o muy difíciles de corregir al cien por ciento, ya que están ligados a los datos en los que se entrenan estos modelos (Morton, 2024). Blackman (2022) explica que las violaciones de privacidad no son una novedad introducida por la inteligencia artificial, pero el desarrollo de soluciones basadas en IA inevitablemente impulsa la recolección de más datos sobre más personas, lo que fomenta invasiones a la privacidad.

Los sesgos son otro problema fundamental en torno a los modelos de inteligencia artificial. Cada conjunto de datos, al ser creado, presentará algún grado de sesgo. La cantidad de sesgo en un conjunto de datos depende únicamente de la capacidad de los investigadores para detectarlo de antemano y manejarlo adecuadamente (Aničin y Stojmenović, 2023). Estos problemas en torno a los sesgos también tienen consecuencias una vez que los modelos se implementan; por ejemplo, el sistema de contratación de personal de Amazon mostraba preferencia por candidatos masculinos y discriminaba a las mujeres (Trejo, 2020).

Finalmente, está el problema de la transparencia, acceso a la información o caja negra en torno a los modelos de inteligencia artificial. Este es un problema complejo que se puede ligar a la propiedad intelectual que limita conocer cómo operan los modelos y con qué datos (Van Dijck *et al.*, 2018), así como a la naturaleza del código que los compone (COWLS *et al.*, 2021). Pero también este problema se relaciona con conocer con precisión la forma en que los modelos llegan a un resultado. De acuerdo con Blackman (2022), el desafío con los modelos es que los patrones suelen ser tan complejos o incluyen una variedad de variables tan diferentes de las que habitualmente consideramos, que a menudo resulta difícil explicar por qué la IA produjo un determinado resultado.

A estos problemas se suman otros, como lo son la responsabilidad (quién es el actor responsable de los problemas que genere un modelo), alucinaciones en el caso de modelos de inteligencia artificial como Chat GPT (Morton, 2023), y la pérdida de agencia humana por influencia de actantes en torno a los modelos, como lo viven muchos trabajadores de la economía de plataformas (De los Santos *et al.*, 2024). La inteligencia artificial en torno al cambio climático también implica problemas particulares pero generales para cualquier modelo, como el costo de energía que se traduce en emisiones de gases de efecto invernadero para entrenarlos, operarlos y mantenerlos.

### **3. Resultados**

#### **3.1. La IA y los problemas de gases invernadero**

La inteligencia artificial, particularmente la ligada a redes neuronales artificiales y al aprendizaje de máquina, es una herramienta impresionante para diversas áreas de la vida cotidiana, la medicina e incluso para enfrentar el cambio climático. No obstante, estos modelos requieren de energía para operar, e incluso de agua para mantenerlos. Así, es necesario conocer cómo y por qué estos modelos pueden descompensar los beneficios de su aplicación en torno a los efectos del cambio climático.

Quizás uno de los puntos más relevantes en torno a los problemas de la IA y el cambio climático son las emisiones. La inteligencia artificial, en especial los modelos que utilizan transformadores (*transformers*) como Chat GPT, han aumentado sus emisiones de gases de

efecto invernadero. Este aumento o generación de emisiones no es malo per se, sino que depende del tipo de fuentes con las que se entrenan, usan y mantienen los modelos.

Con base en esto, el aumento en la búsqueda de arquitecturas neuronales (NAS) y la optimización automatizada de hiperparámetros (autoML), que demandan grandes recursos computacionales, incrementa significativamente las emisiones generadas por la IA (Dhar, 2020). Esto, de nuevo, se relaciona con la complejidad de los modelos y de los sistemas de inteligencia artificial. En este sentido, Luccini *et al.* (2023) explican que, en los últimos años, los modelos de aprendizaje de máquina han logrado un alto rendimiento en tareas como la clasificación de imágenes, traducción automática y detección de objetos; pero este avance conlleva un alto consumo de energía, ya que el desarrollo y despliegue de estos modelos requieren recursos computacionales como GPUs. Asimismo, cada vez son más populares los modelos que buscan generar mayores resultados a costa de la eficiencia, y existe también la preocupación de que las publicaciones o *white papers* sobre los modelos no mencionan su consumo de energía.

En el caso de los modelos intensivos, existe actualmente una mayor preferencia por modelos basados en lo que coloquialmente se puede describir como “entre más grande, mejor”. Se prioriza la investigación, desarrollo e implementación de modelos que requieren mayor capacidad de cómputo para generar mejores resultados, aunque sean marginales. Así pues, la investigación que explora nuevas arquitecturas de redes neuronales o combinaciones de hardware, software y algoritmos ha sido en gran medida reemplazada por estudios que requieren un uso intensivo de recursos computacionales (Hooker, 2020; Marcus, 2020; Ahmed y Wahed, 2020; Cowsls *et al.*, 2021).

De esta manera, los modelos que utilizan muchas técnicas algorítmicas de aprendizaje de máquina suelen ser más intensivos en su uso de energía. En este sentido, Wong (2024) explica que los modelos modernos de aprendizaje que emplean redes neuronales consumen mucha energía durante el desarrollo, ya que tienen muchas más configuraciones posibles que sus predecesores. Con esto, es necesario explicar las diferentes etapas necesarias para implementar un modelo de inteligencia artificial con herramientas de aprendizaje de máquina o redes neuronales.

La primera de estas etapas es el entrenamiento. Esta fase implica alimentar al modelo con grandes volúmenes de datos para que pueda aprender y ajustarse a los patrones presentes en ellos. Durante el entrenamiento, se realizan múltiples iteraciones y ajustes de los parámetros del modelo para optimizar su rendimiento, lo que requiere un uso intensivo de recursos computacionales como GPUs o TPUs. Por ejemplo, en esta fase se dan imágenes a un modelo como DALL-E 3 para poder generar contenido con base en estas.

La parte de entrenamiento es quizás la más intensiva con respecto al consumo de energía de los modelos de inteligencia artificial. De acuerdo con Cowsls *et al.* (2021), el incremento en el consumo de energía debido al entrenamiento de modelos más grandes y la adopción generalizada de la inteligencia artificial ha sido parcialmente contrarrestado por mejoras en la eficiencia del hardware (Ahmed y Wahed, 2020; Cowsls *et al.*, 2021). Supongamos que se tiene un modelo como Chat GPT-3 que consume enormes cantidades de energía en su etapa de entrenamiento; entonces un modelo más grande como Chat GPT-4 consumirá aún mayores cantidades de energía en esta etapa.

Es importante señalar que no todo el aumento de energía en la fase de entrenamiento se traduce en un modelo menos eficiente. En este sentido, Cowsls *et al.* (2021) señalan que los autores de GPT-3 (Brown *et al.*, 2020) destacan que el entrenamiento del modelo demandó

muchos recursos; aunque el modelo presenta la ventaja de adaptarse a nuevas tareas de manera bastante eficiente en comparación con otros modelos de lenguaje, que serían costosos de ajustar. Esto implica que, aunque el consumo energético inicial sea elevado, la capacidad de GPT-3 para adaptarse sin necesidad de un reentrenamiento intensivo puede resultar en una mayor eficiencia operativa a largo plazo, optimizando el uso de recursos y reduciendo el impacto ambiental en la fase de implementación.

Sin embargo, es importante destacar, como señalan Luccioni *et al.* (2023), que las emisiones de carbono en el aprendizaje de máquina dependen del consumo energético del hardware utilizado y del tiempo de entrenamiento requerido para realizar los cálculos necesarios. Es decir, hay una doble variable: la cantidad de energía que demanda el hardware, como los servidores, tarjetas de video y TPUs, y el tiempo que se requiere para entrenar un modelo. Un modelo grande que requiere computación intensiva incrementará las emisiones de carbono por el tiempo de entrenamiento requerido y la energía que consume el hardware utilizado.

¿Cuántas emisiones contribuyen los modelos de aprendizaje de máquina en su etapa de entrenamiento? Dado diferentes factores, como el hecho de que los white papers no se centran en desglosar esta información, no existe una idea concreta del tamaño de las emisiones que producen los modelos en esta etapa. No obstante, existen estimaciones como las mostradas por Lawie (2023), quien plantea que el entrenamiento y la implementación de un único modelo de IA pueden generar una considerable cantidad de emisiones de carbono, alcanzando hasta 626,155 libras (284,019.1304 kilos) de CO<sub>2</sub>, además de incurrir en elevados costos de computación en la nube.

La siguiente etapa que aporta emisiones de gases de efecto invernadero en los modelos de inteligencia artificial es su uso y su implementación o etapa de inferencia. Se puede entender como uso continuo del modelo en aplicaciones prácticas. Por ejemplo, cada vez que Google Translate traduce una palabra de un idioma a otro, cuando le pides a Chat GPT que te ayude a completar un párrafo, cuando la gente usa algún *software* de Adobe para generar contenido en torno a una imagen, o cuando Netflix te sugiere la próxima serie que hará que te quedes despierto toda la noche; todas y cada una de estas aplicaciones se desarrollan en la etapa a nivel usuario, y estas implican a su vez consumo de energía que se traduce en emisiones.

Estas actividades cotidianas, aunque parezcan pequeñas a nivel individual, pueden acumular un impacto significativo en términos de huella ambiental a escala global. En este sentido, el consumo de energía durante la fase de inferencia aumenta con la frecuencia de uso, dado que la inferencia puede ejecutarse millones de veces al día de manera continua (Sze *et al.*, 2017; Cows *et al.*, 2021). Ahora bien, la etapa de inferencia se puede considerar como la menos intensiva dentro de los modelos de IA; aun así, en algunos casos puede requerir cantidades demandantes de energía en algunas aplicaciones de largo plazo. Por ejemplo, la tarea de clasificación de comentarios tóxicos o contenido de imágenes en redes sociales consume poca energía por cada uso individual de un modelo, pero puede repetirse miles de millones de veces al día (Wong, 2024).

La siguiente etapa de los modelos de inteligencia artificial es el mantenimiento o desarrollo y ajuste del modelo (Wong, 2024). Durante esta etapa se producen emisiones debido al continuo ajuste de parámetros, la optimización del rendimiento y la actualización del software, lo cual requiere operaciones computacionales adicionales y, por lo tanto, consumo energético adicional. Aun así, en el corto plazo, el entrenamiento de inteligencia artificial demanda más recursos computacionales y energía; en el largo plazo, el uso diario de IA también implica un consumo continuo de energía, lo cual resulta en la emisión adicional de CO2 (Lawie, 2023).

Ahora bien, hay otros factores que contribuyen al aumento o contención de gases de efecto invernadero por parte de los modelos de inteligencia artificial. Para comprender cómo estos intervienen de mejor manera, se puede usar la teoría de actor-red en aras de crear una herramienta pedagógica y analítica en torno a la constelación de asociaciones que se nombrará IA y cambio climático por medio de conceptos como programa y anti-programa. Esta aproximación permitirá identificar tanto los impactos negativos como las oportunidades para mitigar el impacto ambiental de la IA.


## 4. Discusión

### 4.1. Teoría de actor red, Programa y anti-programa de la IA y el cambio climático

La teoría del actor-red permite identificar asociaciones, intenciones y relaciones de poder en la implementación de los modelos de inteligencia artificial, tanto para su uso general como en sus aplicaciones para combatir el cambio climático. En este contexto, se entiende por intención el programa o la idea que se busca implementar con un modelo de IA; y por anti-programa, las consecuencias o acciones que contradicen las intenciones originales con las que se desarrolló e implementó el programa (Figura 1).

Figura 1:

Mapa de las asociaciones en torno a la Inteligencia Artificial y sus efectos en el cambio climático.



Fuente: Elaboración propia (2024).

Se mapeó la red de asociaciones dentro de una constelación denominada “Inteligencia Artificial y Cambio Climático”. Dentro de esta constelación se destacan todas las asociaciones entre actores humanos y no humanos, así como la relación de sus distintas variables tanto en el programa (la inteligencia artificial sirve para combatir el cambio climático), como en su anti-programa (el uso de la inteligencia artificial genera efectos que aumentan el cambio climático). Además, se introducen otras consecuencias del desarrollo e implementación de los modelos de inteligencia artificial, como el mayor uso de recursos importantes como el agua.

La primera sección principal del mapa es el Entrenamiento. En esta etapa, los datos juegan un papel crucial, ya que la cantidad de datos (sean muchos o pocos) afecta significativamente el entrenamiento del modelo. Además, los actores humanos como investigadores, administradores, diseñadores y aquellos que aplican técnicas algorítmicas están involucrados en el proceso de entrenamiento. El hardware usado, como procesadores y servidores, es esencial para esta etapa, ya que se requiere muchos recursos computacionales para entrenar modelos de IA.

La segunda sección es el Uso de los Modelos de IA. Aquí, las plataformas que alojan y ejecutan los modelos de IA son fundamentales. Los usuarios finales y gerentes son los actores humanos que interactúan con estos modelos en su uso diario. Además, los centros de datos proporcionan la infraestructura necesaria para el funcionamiento continuo de los modelos de IA, permitiendo que las aplicaciones de IA operen de manera eficiente y efectiva.

La tercera sección trata del Mantenimiento de los Modelos de IA. Este proceso involucra a administradores, ingenieros y personal de atención al cliente que se encargan de mantener y actualizar los modelos. Los centros de datos juegan un papel crucial al proporcionar la infraestructura necesaria para estas actividades. Herramientas y plataformas de monitoreo y diagnóstico de IA se utilizan para garantizar que los modelos funcionen correctamente y se ajustan según sea necesario. Además, sistemas de gestión de versiones y despliegue continuo (CI/CD) junto con algoritmos de reentrenamiento y actualización de modelos aseguran que los modelos de IA permanezcan actualizados y eficientes.

Asimismo, el mapa aborda los Factores Energéticos que afectan el impacto ambiental de los modelos de IA. Las fuentes de energía se dividen en renovables y no renovables, siendo las renovables las que producen menos gases de efecto invernadero en comparación con las no renovables. Las fábricas son los lugares donde se produce esta energía. Además, el consumo de agua tiene una relación directa con las emisiones de gases de efecto invernadero; más consumo de agua puede significar más emisiones, mientras que menos consumo puede reducirlas. Los sistemas de enfriamiento también son importantes para mantener la eficiencia energética y reducir el consumo de energía en los centros de datos y otros lugares donde se alojan los modelos de IA; finalmente, la sección de Modelos diferencia entre aquellos que son intensivos en el uso de recursos y aquellos que no lo son, destacando la importancia de considerar la eficiencia energética y el impacto ambiental en el desarrollo y uso de modelos de inteligencia artificial.

Aunque se conoce poco detalle sobre cuántos gases de efecto invernadero genera la inteligencia artificial, es importante plantear la realidad de este fenómeno nuevamente. En este sentido, es necesario conocer el rol que han tenido las tecnologías de información y comunicación. Wong (2024) plantea que entre 2010 y 2018, el consumo global de energía en los centros de datos aumentó sólo un 6%, a pesar de que las cargas de trabajo y las instancias de cómputo se incrementaron en un 550%.

Otra estimación importante proviene del trabajo de Luccioni *et al.* (2023). Aquí, los

investigadores explican:

A escala global, la generación de electricidad representa más de una cuarta parte de las emisiones globales de GHG, sumando hasta 33.1 gigatoneladas de CO<sub>2</sub> en 2019. Estimaciones recientes sitúan la contribución del sector de tecnologías de la información y comunicación (TIC) –que incluye los centros de datos, dispositivos y redes utilizados para el entrenamiento y despliegue de modelos de ML– entre el 2 y el 6 % de las emisiones globales de GHG, aunque el número exacto aún se debate. (p. 1)

Ahora bien, se puede considerar que el impacto de los modelos de IA en la emisión de gases de efecto invernadero no es tan grande como se suele pensar. Lawie (2023) plantea que el impacto de los 16 principales sistemas de IA en el calentamiento global es mínimo y más beneficioso que perjudicial, ya que incluso con 1600 sistemas de IA, el aumento anual de la temperatura global sería apenas  $2.4 \times 10^{-7}$  °C. Aun así, los modelos y la implementación de la IA tienen un impacto en el consumo de energía, y por consiguiente en emisiones. De hecho, se plantea que entrenar el modelo de Chat GPT-3 de OpenAI equivale a conducir un automóvil hasta la Luna y de vuelta (Lfwa, s.f; Quach, 2020).

Asimismo, como se planteó en el mapa de asociaciones, hay que considerar las fuentes de energía con las que se entrenan e implementan los modelos y que alimentan a sus correspondientes servidores. Dhar (2020) explica que un ejemplo es Virginia, EE.UU., el principal centro de datos a nivel mundial, donde apenas el 1% de la electricidad proviene de fuentes renovables. Lawie (2023) propone que adoptar fuentes de energía más limpias, como la energía nuclear en lugar de los combustibles fósiles, es una estrategia eficaz para reducir el impacto del calentamiento global provocado por la IA.

Así pues, aunque los modelos de inteligencia artificial pueden ayudar a mitigar y crear mecanismos de adaptación al cambio climático con herramientas complejas como los gemelos digitales (Chen *et al.*, 2023), esto se socava por la cantidad de emisiones que generan. Esto se puede mediar con el uso de energías limpias, aunque muchos de estos modelos operan con fuentes de energía alimentadas por combustibles fósiles, lo que dificulta su capacidad para combatir los efectos y consecuencias del cambio climático y otras funciones en torno a esta tecnología.

Además, la cantidad de energía necesaria para alimentar muchos de los modelos de inteligencia artificial implica también un importante consumo de agua, principalmente para enfriar el hardware o los servidores con los que funcionan. Esto está ligado a otros procesos que van más allá del entrenamiento, desarrollo, mantenimiento e implementación de los modelos. Por ejemplo, la fabricación e implementación de sus componentes, en especial los semiconductores ligados a piezas de hardware especializado como procesadores, aceleradores y tarjetas de video.

Pengfei *et al.* (2023) explican que se requiere agua ultrapura para la producción de obleas y también se necesita agua limpia para mantener refrigeradas las instalaciones de semiconductores. Así pues, dentro de la red de asociaciones hay una relación entre el tamaño, el hardware y las fuentes de energía de los modelos y el uso de agua. Pero “lamentablemente, la enorme huella hídrica de los modelos de IA –con muchos millones de litros de agua dulce extraídos o consumidos para la generación de electricidad y para enfriar los servidores– ha permanecido en gran medida fuera del radar” (Pengfei, *et al.* (2023).

¿Con base en esto, cómo se puede mitigar el impacto y aprovechar el potencial de los modelos de inteligencia artificial? Una solución es mover los servidores y los centros de datos a lugares

que dispongan de una oferta importante de energías limpias. Otra opción es disminuir el tamaño de los modelos y apostar por algoritmos más eficientes, rompiendo la mentalidad de “más grande y eficiente”; esto es particularmente importante con respecto a los modelos que actualmente emplean técnicas donde los transformadores (Luccioni *et al.*, 2023), donde la energía necesaria para exprimir la última gota de rendimiento y mejora de estos es cada vez mayor.

Asimismo, es importante reducir el tiempo de entrenamiento de los modelos. En este sentido, Luccioni *et al.* (2023) explican:

En términos generales, observamos que los modelos en el extremo superior del espectro de emisiones tienden a ser modelos basados en Transformer con más capas (además de utilizar técnicas como la Búsqueda de Arquitectura Neural para encontrar combinaciones óptimas de parámetros), mientras que los modelos más simples y menos profundos como las redes neuronales convolucionales tienden a estar en el extremo inferior del espectro de emisiones.

Así pues, con base en el mapa de asociaciones, los actantes, de acuerdo a lo que plantea Latour, que pueden producir un anti-anti-programa o un programa que contrarreste los efectos negativos en las asociaciones del uso de modelos de inteligencia artificial y el cambio climático, en el caso de actores humanos son: los desarrolladores de tecnología, que pueden diseñar algoritmos más eficientes; las empresas de tecnología, que pueden invertir en energías limpias y optimizar sus centros de datos; los responsables de políticas energéticas, que pueden implementar regulaciones e incentivos para el uso de fuentes de energía sostenibles; los investigadores, que pueden explorar nuevas formas de reducir el consumo energético de los modelos de IA; y finalmente, los consumidores, que pueden presionar a las empresas para adoptar prácticas más sostenibles. Juntos, estos actores pueden contribuir a la creación de soluciones innovadoras que mitiguen el impacto ambiental de la inteligencia artificial.

Además, el papel de los actores no humanos es importante. Herramientas como los modelos de inteligencia artificial que se entrenan e implementan en el dispositivo (*on-edge AI*), hardware más eficiente y menos demandante en el consumo de energía, como se puede apreciar en el salto de eficiencia que Apple dio con su arquitectura ARM en sus chips M, y tecnologías de enfriamiento más avanzadas contribuyen a la reducción del impacto ambiental. Además, la implementación de energías renovables y la optimización de infraestructuras tecnológicas son esenciales, y la misma regulación entendida como leyes que actúan como actores no humanos o híbridos.

## 5. Conclusiones

La inteligencia artificial es un abanico de tecnologías que pueden mejorar la vida de las personas en diversos aspectos, como combatir y adaptarse al cambio climático. Así pues, Taddeo y Floridi (2018) exponen que la inteligencia artificial (IA) es una poderosa fuerza que está transformando prácticas cotidianas, interacciones personales y profesionales, y entornos, y no solo una nueva tecnología que requiere regulación. No obstante, esta serie de modelos y herramientas también tiene consecuencias importantes en el cambio climático y en otros aspectos, como el consumo de agua.

Y si bien el consumo de agua por parte de la IA es relativamente bajo comparado con otras industrias como la agricultura, esto no significa que sea insignificante (George *et al.*, 2023). Además, tanto las variables de consumo de agua como de energía representan una responsabilidad ética respecto a dónde entrenar e implementar los modelos de inteligencia

artificial. Es crucial considerar el impacto ambiental de estas operaciones y elegir ubicaciones y tecnologías que minimicen el uso de recursos naturales y reduzcan la huella ecológica, asegurando así un desarrollo sostenible y responsable de la IA.

Parte de las medidas de contención respecto a los actores no humanos es el uso de semiconductores más eficientes. Como plantean Cowls *et al.* (2021), si GPT-3 de OpenAI se hubiera entrenado con el hardware más reciente de NVIDIA, el A100, una única sesión de entrenamiento podría haber sido el doble de eficiente. Asimismo, hay que considerar el impacto de los modelos de inteligencia artificial, la enorme cantidad de energía para su operación y, por ende, su consumo de agua, en los ecosistemas locales (George *et al.*, 2023).

En cuanto a las fuentes de energía, es importante que empresas como Microsoft y otros jugadores importantes en el ámbito de servidores y centros de datos sigan incorporando fuentes de energía limpias para su implementación. Así pues, es esencial equilibrar las soluciones basadas en IA con un enfoque integral que resalta estrategias multifacéticas, como la adopción de energías renovables, el uso sostenible del suelo, la conservación de la biodiversidad y la participación de la comunidad (Rayhan y Rayhan, 2023). Esto también puede acompañarse con una investigación que favorezca modelos computacionalmente menos demandantes e intensivos.

Aun así, no se deben pasar por alto las oportunidades que ofrecen los modelos de inteligencia artificial, como se ha mencionado a lo largo de este trabajo. Modelos con herramientas de aprendizaje de máquina y sus algoritmos detectan oportunidades de optimización energética que los analistas humanos podrían no notar (Chet *et al.*, 2023). Por ende, se debe tener una balanza justa entre las oportunidades y retos en torno a esta tecnología respecto al cambio climático, más allá del ruido que herramientas como la inteligencia artificial generativa puedan ocasionar en el discurso cotidiano.

El cambio climático es un problema importante, y la inteligencia artificial es parte de las herramientas que pueden servir para mitigar sus efectos y crear medidas de adaptación, pero con estrategias para mitigar el mismo impacto que la IA pueda tener. No hay que olvidar que se espera que inundaciones, sequías, olas de calor, tormentas extremas e incendios forestales, empeoren en el futuro, alcanzando niveles récord (Olatunde-Aiyedun y Olatunde, 2022). Todas estas estrategias también deben contemplar las necesidades de los países más afectados, y otros actores no humanos como la regulación y las leyes también son importantes.

Para concluir, la teoría de actor y los conceptos de programa y anti-programa explican tanto las relaciones de poder como las oportunidades y retos de la inteligencia artificial respecto al cambio climático. Estas herramientas teóricas-metodológicas permitieron rastrear las asociaciones entre diferentes actores humanos y no humanos, revelando cómo las decisiones tecnológicas y políticas afectan el consumo de recursos y las emisiones. Además, ofrecen un marco para identificar estrategias que mitiguen los impactos ambientales, promoviendo un desarrollo más sostenible de la IA y fomentando la colaboración entre diversas partes interesadas para enfrentar los desafíos climáticos.

## 6. Referencias

- Blackman, R. (2022). *Ethical machines: Your concise guide to totally unbiased, transparent, and respectful AI*. Harvard Business Review Press.
- Callon, M. (1986). Éléments pour une sociologie de la traduction: La domestication des coquilles Saint-Jacques et des marins-pêcheurs dans la baie de Saint-Brieuc. *L'Année sociologique*, 36, 169-208.
- Changlani, Kishan y Renuka Thakore. *Artificial Intelligence for Climate Action*. <https://doi.org/10.13140/RG.2.2.21102.18245>
- Chen, L., Chen, Z., Zhang, Y., Liu, Y., Osman, A. I., Farghali, M., Hua, J., Al-Fatesh, A., Ihara, I., Rooney, D. W. y Yap, P. (2023). Artificial intelligence-based solutions for climate change: a review. *Environmental Chemistry Letters*, 21(5), 2525-2557. <https://doi.org/10.1007/s10311-023-01617-y>
- Cowls, J., Tsamados, A., Taddeo, M. y Floridi, L. (2021). The AI gambit: leveraging artificial intelligence to combat climate change – opportunities, challenges, and recommendations. *AI & Society*, 38(1), 283-307. <https://acortar.link/ORJcCh>
- De los Santos, M. D. L., Do, K., Muller, M. y Savage, S. (2024). *Designing sousveillance tools for gig workers*. <https://doi.org/10.1145/3613904.3642614>
- Dhar, P. (2020). The carbon impact of artificial intelligence. *Nature Machine Intelligence*, 2(8), 423–425. <https://doi.org/10.1038/s42256-020-0219-9>
- George, A., George, A. y Martin, A. (2023). The Environmental Impact of AI: A case study of water consumption by Chat GPT. Zenodo. CERN European Organization for Nuclear Research. <https://doi.org/10.5281/zenodo.7855594>
- Gonzalo, M. (2023, 7 de septiembre). *El impacto climático de la IA y su huella ecológica*. Newtral. <https://acortar.link/rxNv4V>
- IPCC. (2023). Summary for Policymakers. In: *Climate Change 2023: Synthesis Report*. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. Geneva, Switzerland: IPCC. <https://acortar.link/UC7jkk>
- Latour, B. (1990). Technology is Society Made Durable. *The Sociological Review*, 38(1\_suppl), 103-131. <https://doi.org/10.1111/j.1467-954X.1990.tb03350.x>
- Latour, B. (1993). *We have never been modern*. Harvard University Press.
- Latour, B. (2017). On Actor-Network Theory. A few clarifications, plus more than a few complications. *Logos*, 27(1), 173-197. <https://acortar.link/qfCYFI>
- Lawie, M. (2023). *Analysing the impact of CO2 emissions from the largest artificial intelligence systems and its consequences for global warming*. <https://doi.org/10.13140/RG.2.2.24138.95680>
- Li, P., Yang, J., Islam, M. A. y Ren, Sh. (2023). Making AI less «thirsty»: Uncovering and addressing the secret water footprint of AI models. *arXiv:2304.03271*.

<http://arxiv.org/abs/2304.03271>

- Luccioni, A. S. y Hernandez-Garcia, A. (2023). Counting carbon: A survey of factors influencing the emissions of machine learning. *arXiv:2302.08476*. <https://doi.org/10.48550/arXiv.2302.08476>
- Masterson, V. (12 de febrero de 2024). *9 ways AI is helping tackle climate change*. World Economic Forum. <https://bit.ly/3W9k9pp>
- Mohammad, A. y Mahjabeen, F. (2023). Revolutionizing solar energy with AI-driven enhancements in photovoltaic technology. *Jurnal Multidisiplin Ilmu*, 2. <https://journal.mediapublikasi.id/index.php/bullet/article/view/3427>
- Olatunde-Aiyedun, T. y Olatunde, M. (2022). *State and prediction of the global climate change: 2012-2026*.
- Quach, K. (4 de noviembre de 2020). *AI me to the Moon. Carbon footprint for "training GPT-3" same as driving to our natural satellite and back*. The Register. <https://bit.ly/3W9wYQL>
- Raihan, A. (2023). Artificial intelligence and machine learning applications in forest management and biodiversity conservation. *Natural Resources Conservation and Research*, 6(2), 3825. <https://doi.org/10.24294/nrcr.v6i2.3825>
- Rayhan, A. y Rayhan, S. (2023). The role of artificial intelligence in climate change mitigation and adaptation. *Artificial Intelligence*. <https://doi.org/10.13140/RG.2.2.10346.70087/1>
- Star, S. L. y Griesemer, J. R. (1989). Institutional Ecology, 'Translations' and Boundary Objects: Amateurs and Professionals in Berkeley's Museum of Vertebrate Zoology, 1907-39. *Social Studies of Science*, 19(3), 387-420. <https://doi.org/10.1177/030631289019003001>
- Taddeo, M. y Floridi, L. (2018). How AI can be a force for good. *Science*, 361(6404), 751-752. <https://doi.org/10.1126/science.aat5991>
- Wong, C. (2024). How climate change is hitting Europe: three graphics reveal health impacts. *Nature Climate Change*. <https://pubmed.ncbi.nlm.nih.gov/38890517/>

## CONTRIBUCIONES DE AUTORES/AS, FINANCIACIÓN Y AGRADECIMIENTOS

**Financiación:** Esta investigación no recibió financiamiento externo.

**Agradecimientos:** El presente texto nace en el marco de una disertación con el doctor Bernardo Bolaños de la Universidad Autónoma Metropolitana Unidad Cuajimalpa de la Ciudad de México, respecto al impacto de la inteligencia artificial y sus efectos en torno al cambio climático. Asimismo, se agradece el enorme apoyo del personal de Apoyo a la docencia de la Universidad Autónoma Metropolitana Unidad Cuajimalpa de la Ciudad de México (particularmente a Guadalupe), y la supervisión y constante asesoría y evaluación de la doctora Mariana Moranchel Pocaterra, al doctor Bolaños con quien diserté el texto, y al Consejo Nacional de Humanidades, Ciencias y Tecnologías de México.

**AUTOR/ES:****Jorge Luis Morton Gutiérrez.**

Universidad Autónoma Metropolitana Unidad Cuajimalpa de la Ciudad de México.

Estudiante de doctorado por la Universidad Autónoma Metropolitana Unidad Cuajimalpa de la Ciudad de México. Ha trabajado en publicaciones en torno al impacto social de los videojuegos, el papel de la Teoría de Actor Red como herramienta de análisis de los impactos de la pandemia del Covid-19. Y principalmente se ha enfocado en el análisis de las relaciones de poder en torno a la Inteligencia Artificial empleando las herramientas de la Teoría de Actor Red.

[jorge.morton@cua.uam.mx](mailto:jorge.morton@cua.uam.mx)**Orcid ID:** <https://orcid.org/0000-0003-2836-938X>**ResearchGate:** <https://www.researchgate.net/profile/Jorge-Luis-Morton-Gutierrez-2>