

CALEIDOSCOPIO KALEIDOSCOPE

Nace para focalizar la atención del lector en un tema de interés actual mediante una serie de artículos cortos en torno al tema.
Born to focus reader attention on a topic of current interest through a series of short articles on the subject.

EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL EN EL DESCUBRIMIENTO CIENTÍFICO

THE IMPACT ON SCIENTIFIC DISCOVERY ON ARTIFICIAL INTELLIGENCE

Autor correspondiente/ Corresponding author: Javier Jiménez¹; Manuel Aguilar²

1. U. Politécnica de Madrid. Real Academia de Ciencias y Real Academia de Ingeniería

2. Real Academia de Ciencias y Fundación Ramón Areces

Con la colaboración de Alfonso Valencia, La inteligencia artificial en biomedicina; José Manuel Gutiérrez Llorente, La revolución de la inteligencia artificial en el modelado del tiempo y del clima; Petros Koumoutsakos, Pensamiento e inteligencia artificial: mentes, máquinas y datos; Carlos José Delgado Méndez, El uso de la inteligencia artificial en la física y astrofísica de partículas y Juan Lerma, La influencia mutua entre neurociencia e inteligencia artificial.





El nuevo formato “Caleidoscopio” es una colección de artículos cortos, divulgativos, reflejando distintos aspectos de un tema común. Esta colección nació como una sesión de cinco charlas en la Fundación Ramón Areces [1], patrocinada por las Reales Academias Españolas de Ingeniería y de Ciencias, sobre el uso de la inteligencia artificial (IA) en la investigación científica. Los conferenciantes fueron elegidos por su trabajo en campos en los que la IA ya tenía una cierta historia, y que estaban por lo tanto en disposición de juzgar cual había sido su utilidad hasta ahora. En particular, se les preguntó si, en su experiencia, la IA constituía una herramienta incremental con respecto a la utilización de ordenadores que todos conocemos, o si es más bien un instrumento completamente nuevo; es decir, un microscopio mejor, o el primer microscopio. El resultado no fue concluyente: una encuesta final entre los conferenciantes dio tres contra dos (aunque en qué sentido debería ser juzgado por los lectores a partir de los artículos adjuntos.) Los cuatro primeros artículos son historias de éxito en aplicaciones en biomedicina, meteorología, sistemas complejos y astrofísica. El quinto no sólo trata de la aplicación de la IA a las neurociencias, sino que también intenta explicar qué podría aportar al diseño de la IA lo que sabemos de la ‘otra’ inteligencia: la nuestra.

1. <https://www.youtube.com/watch?v=QgL-JmbYRp4>

The new “Caleidoscopio” format is a collection of short informative articles dealing with different aspects of a common theme. The present collection originated as a session of five talks at the Fundación Ramón Areces [1], organised by the Royal Spanish Academies of Engineering and of Sciences, on the use of artificial intelligence (AI) in scientific research. The speakers were chosen for their work in fields in which AI already had a certain history, and who were therefore able to judge how useful had AI been up to now. In particular, they were asked for their opinion on whether AI is an incremental tool with respect to the use of computers that we all know, or a disruptive new way of working; that is, whether it is a better microscope or the first microscope. The result was inconclusive: a final poll among the speakers gave three versus two (although the winner should be judged by the readers from the following articles.) The first four papers are success stories in applications in biomedicine, meteorology, complex systems and astrophysics. The fifth not only deals with the application of AI to the neurosciences, but also tries to explain how the design of AI could be improved from what we know about the ‘other’ intelligence: ours.

1. <https://www.youtube.com/watch?v=2qC-PQGxXU8>

LA INTELIGENCIA ARTIFICIAL EN BIOMEDICINA: UNA REVOLUCIÓN CON TRES PILARES

ARTIFICIAL INTELLIGENCE IN BIOMEDICINE: A REVOLUTION WITH THREE PILLARS

Alfonso Valencia¹

1. Profesor ICREA, Barcelona Supercomputing Center (BSC-CNS)

La inteligencia artificial (IA) está transformando la biomedicina, soportada por tres pilares: la potencia de la supercomputación, la disponibilidad de grandes cantidades de datos y los nuevos algoritmos de IA.

PRIMER PILAR - SUPERCOMPUTACIÓN

La computación de alto rendimiento (HPC), ejemplificada por sistemas como el MareNostrum 5 del BSC-CNS, es crucial para entrenar modelos de IA complejos capaces de analizar enormes conjuntos de datos biomédicos. Puede decirse que la IA sólo ha cobrado relevancia cuando hemos dispuesto de una capacidad computacional relevante. El desarrollo futuro de la IA, hasta donde podemos conocerlo, dependerá críticamente del acceso a potencia de cálculo en condiciones adecuadas para la investigación en términos de facilidad de acceso y operación.

SEGUNDO PILAR - DISPONIBILIDAD DE GRANDES CONJUNTOS DE DATOS

Los datos biomédicos, desde la genómica y la imagen médica hasta los historiales clínicos, son muy heterogéneos y complejos además de intrínsecamente ruidosos. La decisión europea de ir hacia un espacio común de datos (Espacio Europeo de Datos Sanitarios -EHDS) y proyectos nacionales como IMPaCT- buscan mejorar la accesibilidad de los datos, enfrentando retos como la privacidad, estandarizarlos y hacerlos útiles para la investigación biomédica. El acceso a estas fuentes masivas de datos es esencial para la investigación y, especialmente, para el entrenamiento de métodos de IA.

TERCER PILAR - NUEVOS ALGORITMOS DE IA

Los avances en algoritmos, como los modelos de lenguaje (LLMs), están revolucionando la biomedicina. Un ejemplo claro es la predicción de estructuras de proteínas (AlphaFold – merecedor del premio Nobel de Química en 2024) o el diseño de nuevas proteínas para la exploración del universo de proteínas (programas como ESM, ProtT5). Estas herramientas permiten diseñar con creciente efectividad anticuerpos, vacunas y fármacos, o predecir efectos de mutaciones asociadas a enfermedades. Además, la IA generativa – como la que está detrás de los modelos de lenguaje como el popular chatGPT – permite la generación de datos sintéticos, como pueden ser nuevos genomas, con aplicaciones directas en biotecnología.

MODELADO MECANICISTA COMBINADO CON IA

Los modelos basados en leyes biológicas y físicas son herramientas esenciales para traducir los datos biológicos en conocimiento, en aplicaciones como puede ser simulación de la evolución de tumores y la predicción de la respuesta a posibles tratamientos. Herramientas basadas en agentes, redes Booleanas o ecuaciones diferenciales, se combinan en plataformas como PhysiBoSS para la ejecución de este tipo de modelos mecanísticos multiescala. Sin embargo, estos sistemas requieren un conocimiento experto intensivo y son computacionalmente costosos.

El desarrollo de la IA permite ahora explorar la posibilidad de resolver estos problemas integrando IA y modelos mecanísticos. La IA puede mejorar la precisión de las predicciones, mientras que los modelos aportan interpretabilidad y conocimiento científico profundo que puede ser clave para la aprobación regulatoria de fármacos. La sinergia IA/modelos es un área candente para entender enfermedades complejas y acelerar tratamientos.

LIMITACIONES Y POSIBILIDADES

Aunque el potencial de la IA es indiscutible, sigue abierto el debate sobre si será una herramienta más para los científicos o llegará a convertirse en un auténtico sustituto (¿científico asistente?). La respuesta llegará con una nueva generación de sistemas de IA que deben ser capaces de superar las limitaciones ac-

tuales en cuanto a sesgos, alucinaciones, privacidad y origen de los datos, además de mejoras en la explicabilidad de las soluciones.

Si resolvemos estos desafíos, junto a las mayores capacidades computacionales (nuevas factorías de IA en Europa) y una mejora en el acceso a los datos (implementación de la EHDS), seremos capaces de desbloquear todo el potencial de la IA en biomedicina, impulsando la innovación en el diagnóstico, las terapias y en última instancia el tratamiento de los pacientes.

LA REVOLUCIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL MODELADO DEL TIEMPO Y DEL CLIMA

THE ARTIFICIAL INTELLIGENCE REVOLUTION IN WEATHER AND CLIMATE MODELLING

José Manuel Gutiérrez Llorente¹

1. Universidad de Cantabria

La inteligencia artificial (IA) está transformando profundamente las ciencias del clima. En apenas unos años, su irrupción ha impulsado una auténtica revolución, especialmente en el ámbito de la modelización y la predicción meteorológica. Gracias a algoritmos avanzados de redes neuronales profundas, la IA ha logrado resultados que hace tan solo una década parecían inalcanzables. Tradicionalmente, las predicciones del tiempo se han basado en modelos que simulan la dinámica de la atmósfera mediante la resolución numérica de las ecuaciones que describen los procesos físicos de gran escala (conservación del momento lineal, vapor de agua, etc.) y las parametrizaciones de los procesos de pequeña escala como la convección y la formación de nubes (ver Figura 1). Estos modelos permiten predecir el estado de la atmósfera para los próximos días a partir del estado actual conocido por la información que proporcionan los distintos sistemas de observación meteorológica. Estos modelos requieren enormes recursos computacionales y tienen limitaciones para representar ciertos fenómenos locales o extremos con precisión, dada la resolución que alcanzan (decenas de kilómetros) con los recursos computacionales disponibles en la actualidad [1].




Figura 1. Representación esquemática del proceso de modelización y predicción meteorológica: los procesos físicos relevantes definidos por ecuaciones se resuelven con métodos numéricos sobre una versión discretizada de la atmósfera con resolución típica de decenas de kilómetros (imagen generada con la ayuda de IA).




Figura 2. Proceso de aprendizaje de un modelo meteorológico de IA a partir de datos diarios de variables meteorológicas: Z, U, V, T, Q (presión, componentes del viento, temperatura, humedad) en distintos niveles de la atmósfera (500, 700, 850 and 1000 mb).

La IA introduce un enfoque radicalmente distinto. En lugar de partir de ecuaciones físicas, los modelos de IA aprenden patrones directamente de los datos. A partir de millones de observaciones procedentes de estaciones meteorológicas y satélites y de simulaciones y predicciones históricas [2], los algoritmos

aprenden a identificar relaciones complejas entre variables atmosféricas y a simular su dinámica (ver Figura 2). Uno de los avances más notables que han logrado estos modelos IA ha sido superar los resultados de los enfoques tradicionales en predicciones a corto plazo (para los próximos días), tanto en velocidad

como en precisión. Modelos recientes como GraphCast, desarrollado por DeepMind, y Pangu-Weather, de Huawei, han demostrado ser capaces de realizar pronósticos globales en segundos, igualando o incluso superando los resultados de los sistemas operativos actuales utilizados por centros meteorológicos [3]. Gracias a su capacidad de análisis sobre grandes volúmenes de datos, la IA también permite identificar relaciones y estructuras ocultas que los modelos tradicionales a menudo no logran captar. Por ejemplo, se ha mejorado la representación de patrones como los ríos atmosféricos, fenómenos que tienen un impacto directo en eventos extremos como inundaciones. No obstante, la tendencia más prometedora no es abandonar los modelos físicos, sino combinarlos con los modelos de IA. Los llamados modelos híbridos [4] combinan la solidez científica de los modelos físicos con la flexibilidad y eficiencia de los algoritmos de IA, permitiendo resultados más rápidos y detallados.

Uno de los ámbitos donde más se pone a prueba la capacidad predictiva de la IA es en la caracterización de eventos extremos, como olas de calor o lluvias torrenciales, con un alto impacto social y económico. Estos eventos, por su naturaleza poco frecuente, representan un gran desafío para los modelos tradicionales. La IA, al aprovechar conjuntos de datos heterogéneos y técnicas avanzadas de aprendizaje, está empezando a mejorar la detección temprana, la atribución y la predicción de estos fenómenos. Además, la aparición reciente de modelos de IA generativa, como los modelos de difusión o redes generativas adversarias (GANs), abre nuevas posibilidades para simular eventos extremos.

La IA permitirá desarrollar modelos aún más robustos y accesibles. Su rápida ejecución permitirá avanzar hacia predicciones a escala kilométrica y mejorar la caracterización de la incertidumbre. Este avance podría ser especialmente transformador para regiones del mundo que carecen de infraestructura computacional avanzada, facilitando el acceso a predicciones fiables y localizadas.

El futuro apunta hacia modelos más complejos que acoplen diversos componentes del sistema climático (atmósfera, océano, criosfera, litosfera, biosfera) para simular la dinámica del sistema climático a otras escalas temporales, en particular para simular la evolución del clima en las próximas décadas, forzado por distintos escenarios de emisión de gases de efecto invernadero [1]. Las simulaciones numéricas a escalas climáticas requieren mayores recursos computacio-

nes y se realizan a resoluciones típicas de decenas/cientos de kilómetros por lo que su representatividad regional es limitada y, en ocasiones, complementada con otros modelos regionales que permiten simular a mayor resolución sobre regiones geográficas limitadas (proceso denominado *downscaling*). Las técnicas de IA tienen gran potencial para desarrollar modelos que simulen la dinámica del clima a alta resolución a partir de los forzamientos dados por los distintos escenarios, permitiendo llevar a cabo un número de simulaciones adecuado para evaluar el riesgo climático [5].

No obstante, estos avances no están exentos de retos. Uno de los más urgentes es asegurar la calidad y representatividad de los datos utilizados para entrenar los modelos. Otro desafío crucial es garantizar la interpretabilidad y transparencia de los sistemas, evitando que se conviertan en "cajas negras" difíciles de interpretar o justificar, especialmente si sus resultados influyen en decisiones de gran impacto social o económico. También es necesario tener en cuenta las implicaciones éticas del uso automatizado de predicciones en la toma de decisiones, así como los posibles sesgos que puedan derivarse del entrenamiento con datos históricos incompletos o desequilibrados. Para abordar estos retos, es fundamental mantener una estrecha colaboración entre expertos en IA, meteorólogos, climatólogos y actores sociales. La hibridación con modelos físicos no solo mejora la precisión, sino que ofrece una base sólida para explicar y entender los resultados obtenidos por los sistemas de IA, fortaleciendo la confianza en estas herramientas.

En definitiva, la inteligencia artificial representa una oportunidad única para revolucionar nuestra forma de observar, comprender y anticipar la meteorología y el clima. Pero su uso debe estar guiado por principios de rigor científico, ética y responsabilidad social, para asegurar que sus beneficios lleguen a toda la sociedad y contribuyan a enfrentar con eficacia los retos del cambio climático. Es imprescindible fomentar una IA climática explicable, inclusiva y alineada con el bien común.

BIBLIOGRAFÍA

1. IPCC AR6 (2021). Climate Change 2021: The Physical Science Basis. Capítulo 1 para una descripción del estado actual de la modelización climática.



2. Hersbach, H. et al. (2020) The ERA5 global reanalysis. Quarterly Journal of the Royal Meteorological Society 146, 1999–2049.
3. Bi, K. et al. (2022). Accurate medium-range global weather forecasting with 3D neural networks. Nature, 619, 533–538.
4. Kochkov, D. et al. (2024) Neural general circulation models for weather and climate. Nature, 632, 1060–1066.
5. <https://destine.ecmwf.int/news/spains-prediction-to-build-a-climate-emulator-for-destine>

PENSAMIENTO E INTELIGENCIA ARTIFICIAL: MENTES, MÁQUINAS Y DATOS

THOUGHT AND ARTIFICIAL INTELLIGENCE: MINDS, MACHINES AND DATA

Petros Koumoutsakos¹

1. Herbert Winokur Professor for Computing in Science and Engineering, Universidad de Harvard, Cambridge, MA. USA

La búsqueda del conocimiento es un sello distintivo de la humanidad. A lo largo de miles de años, la observación, la teoría y la experimentación han sido nuestros vehículos en esta búsqueda. A su vez, estos modos de indagación han moldeado nuestro pensamiento y la Ciencia misma. Hoy en día, estamos viviendo una revolución en la investigación científica impulsada por las capacidades de la computación. En los últimos treinta años, hemos experimentado un aumento mil millones de veces en las capacidades del hardware y un ritmo vertiginoso en la adquisición, transmisión y procesamiento de enormes cantidades de datos. La computación está transformando nuestra capacidad intelectual para abordar problemas complejos y está alimentando la revolución de la Inteligencia Artificial (IA) que está cambiando nuestro mundo. Aprovechar estas nuevas tecnologías requiere una nueva forma de hacer ciencia: el Pensamiento Computacional. El Pensamiento Computacional es la integración de mentes, datos y máquinas para avanzar la Ciencia más allá de la IA.

La humanidad enfrenta desafíos nuevos y únicos que requieren nuevas formas de pensamiento para abordarlos, así como un nuevo tipo de educación para las generaciones futuras.

COMPUTACIÓN E IA: ROMPIENDO FRONTERAS, FORMANDO ALEACIONES

La alegoría de la caverna de Platón describe nuestras observaciones parciales del mundo y nuestro esfuerzo por comprenderlo. Encadenados dentro de una cueva, observamos sombras en sus paredes, proyecciones de objetos que pasan frente a un fuego encendido detrás de nosotros. Discutimos sobre el objeto de nuestras observaciones y luchamos por liberarnos para buscar la verdad completa. Llevado al terreno de la investigación científica, esto refleja nuestra búsqueda por entender la naturaleza, usando teorías y construyendo herramientas como telescopios y aceleradores de partículas. En años más recientes, nuestros esfuerzos se han acelerado con la llegada de la computación. Hoy, capacidades computacionales sin precedentes nos permiten estudiar fenómenos en escalas de tiempo y espacio que antes eran impensables.

Nunca en la historia la humanidad había tenido la capacidad de explorar con tanto detalle fenómenos complejos que van desde la turbulencia hasta el clima, la estructura del genoma y los nuevos materiales. La computación puede verse como una evolución natural de la teoría. Describimos sistemas físicos mediante ecuaciones modelo y desarrollamos métodos numéricos para resolverlos en computadoras. Un ejemplo emblemático de este esfuerzo ha sido la mecánica de fluidos y las ecuaciones de Navier-Stokes. Hoy en día, calculamos flujos en escalas que eran inimaginables hace apenas una década. Aún más, las ideas desarrolladas para la simulación de flujos son ahora omnipresentes, aplicándose a la predicción de incendios forestales, epidemias, finanzas y dinámica oceánica. Las ecuaciones son herramientas inductivas poderosas, con métodos que se generalizan entre dominios; por ejemplo, los métodos para la turbulencia a través de Navier-Stokes pueden informar modelos financieros como el de Black-Scholes. Sin embargo, este modo de investigación está mostrando sus limitaciones. La ampliación de los métodos existentes se ve limitada por las capacidades del hardware al que se asignan. Nuevos modos de indagación, como los enfoques

basados en datos y en IA, están desafiando nuestra dependencia continua en la predicción basada en ecuaciones. La IA puede definirse como la parte computacional de la capacidad para alcanzar metas en el mundo real. Si bien la comprensión puede ser un objetivo, la IA a menudo la omite para lograr un mejor diseño de un ala o desarrollar un nuevo fármaco. La IA se basa en arquitecturas como las redes neuronales, cuyo tamaño y complejidad son bastante opacos para la mente humana. También depende de cantidades masivas de datos, algo cada vez más accesible en nuestros tiempos, desde las redes sociales hasta la información molecular. Sostengo que esto no es una limitación, sino una reapertura de un camino de pensamiento que había estado cerrado durante mucho tiempo debido a nuestra educación. La educación clásica valora la comprensión basada en la teoría, a menudo codificada en ecuaciones diferenciales parciales, y un aprendizaje guiado por principios fundamentales. Sin embargo, pensar en términos de heurísticas y datos, en lugar de ecuaciones, es mucho más humano de lo que solemos pensar.

Recuerdo llevar a mi hija de tres años sobre mis hombros mientras se detenía a recoger una naranja de un árbol. Le pregunté qué pasaría si la soltaba. Dijo que caería junto a la raíz del árbol. En secreto, esperaba que mencionara la palabra “gravedad” cuando le pregunté por qué. Su respuesta fue que caería ahí porque había otras naranjas allí también. Los enfoques basados en datos parecen estar incrustados en nuestro cerebro mucho antes de que podamos descubrir los principios fundamentales de nuestro mundo. Hoy, marcos de IA como los modelos fundacionales llevan esto un paso más allá. Los modelos fundacionales están diseñados para manejar entradas multimodales y generar salidas diversas en una amplia gama de tareas. Incluyen capacidades como la generación de texto, código, imágenes, video y audio.

Estos modelos pueden funcionar como sistemas autónomos o servir como base para otras aplicaciones. Los ejemplos más destacados hoy son los grandes modelos de lenguaje (LLM), entrenados con vastos conjuntos de datos textuales para realizar tareas relacionadas con el lenguaje como responder preguntas y generar código y contenido. Hacerle la pregunta de la naranja a un LLM produciría una mejor respuesta sobre la causa que la de un niño de tres años. Pero un LLM no puede responder misterios como la estructura de la turbulencia en la super-

ficie del ala de un avión. Obstáculos significativos dificultan el uso amplio y confiable de la IA, como la verificación, validación y cuantificación de incertidumbre. En contextos científicos surgen preocupaciones adicionales: conocimiento limitado de dominios específicos, datos de entrenamiento escasos, dificultades para integrarse con experimentos, falta de comprensión causal y la naturaleza evolutiva del conocimiento científico, que ha estado guiado por la curiosidad – una cualidad aún desconocida para la IA.

Sigo siendo optimista. Existe un gran potencial en la conexión entre modelos basados en ecuaciones y el Aprendizaje Automático. Lo que yo llamo Aleaciones Algorítmicas puede transformar la predicción confiable bajo incertidumbre en sistemas complejos de múltiples escalas. Las metodologías de aprendizaje automático pueden ofrecer los componentes necesarios para resolver ecuaciones diferenciales parciales (EDP) que no son posibles de abordar con los métodos actuales. Mientras la IA puede navegar espacios de alta dimensión, el cerebro humano tiene la capacidad de simplificar. La ley de Newton puede derivarse de millones de interacciones, pero la simplicidad y la belleza son capacidades únicas del intelecto humano.

La IA nos está permitiendo ir más allá de los problemas fundamentales simplificados y abordar problemas importantes de predicción como los relacionados con el cambio climático, la sostenibilidad alimentaria y la escasez de agua. A su vez, podemos comprender mejor y tomar decisiones informadas, ya que una mejor predicción ofrece la capacidad de intervenir. ¿Cómo se recuperaría el clima si apagáramos toda la electricidad durante 2 horas al día? ¿Cómo revivirían los corales si prohibiéramos la pesca de arrastre de fondo? ¿Cómo desarrollar nuevas tecnologías de desalinización de agua para la agricultura costera? También hay un experimento de intervención global en curso, ya que las computadoras y la IA se han vuelto omnipresentes en nuestras vidas. Su desenlace podría determinar el futuro de la humanidad. La pregunta importante no es si las máquinas pueden pensar, sino si los humanos seguirán haciéndolo.

Este artículo fue originalmente escrito por el autor en inglés, y traducido automáticamente al español por el LLM ChatGPTi©. En consonancia con el tema de esta colección, las idiosincrasias estilísticas de la traducción se han respetado.



EL USO DE LA INTELIGENCIA ARTIFICIAL EN LA FÍSICA Y ASTROFÍSICA DE PARTÍCULAS

THE USE OF ARTIFICIAL INTELLIGENCE IN PARTICLE PHYSICS AND ASTROPHYSICS

Carlos José Delgado Méndez¹

1. Centro de Investigaciones Medioambientales Energéticas y Tecnológicas, Madrid

La física y astrofísica experimental de partículas se basan en el estudio de fenómenos fundamentales mediante la detección de partículas elementales y la interpretación de los procesos físicos asociados a ellas. En física de partículas se investiga la naturaleza e interacciones fundamentales de estas partículas, mientras que en astrofísica de partículas se observan fenómenos en contextos naturales como rayos cósmicos, neutrinos astrofísicos y ondas gravitacionales, lo que permite estudiar procesos físicos de gran energía en el universo.

Los detectores utilizados en estas disciplinas son complejos, de gran tamaño, y generan grandes volúmenes de datos. Cuando una partícula interactúa con estos detectores, produce señales —eléctricas u ópticas, dependiendo del principio de detección— que se analizan en tiempo real mediante sistemas de disparo (denominado en inglés trigger) que determinan si deben almacenarse. Si los criterios definidos se cumplen, estas señales se convierten en eventos, que son procesados, almacenados y posteriormente reconstruidos para extraer observables físicos. A partir de estos, se realiza el análisis final con el objetivo de obtener las medidas físicas buscadas.

Toda esta cadena depende de un conocimiento detallado del funcionamiento del detector, el cual se reproduce en simulaciones completas que modelan tanto la interacción de las partículas como la respuesta de los sensores. Estas simulaciones son esenciales para entrenar algoritmos de reconstrucción, validar los análisis y permitir la interpretación rigurosa de los resultados.

Las herramientas de aprendizaje automático —precursores de lo que actualmente se conoce como inteligencia artificial (IA)— se han aplicado durante décadas a tareas de clasificación y regresión en física y astrofísica

de partículas [1]. Modelos como perceptrones, árboles de decisión, random forests y boosted decision trees han sido ampliamente utilizados en las etapas de reconstrucción y análisis. Estos modelos, entrenados con simulaciones detalladas de la respuesta de los detectores, han contribuido a mejorar la eficiencia y precisión de las mediciones, aunque dependen fuertemente de la calidad de fidelidad de las simulaciones.

Con el desarrollo y la expansión del uso de redes neuronales profundas (CNN, RNN, autoencoders, GANs), se ha comenzado a extender el aprendizaje automático a otras etapas de la cadena experimental, incluyendo la reconstrucción directa de señales y el refinado de simulaciones para mejorar su fidelidad. Algunos ejemplos recientes son [2]:

- La reconstrucción de cascadas atmosféricas en el Observatorio Pierre Auger mediante una CNN, que logró estimar observables con mayor precisión que los métodos tradicionales.
- La reconstrucción de señales de ondas gravitacionales con un autoencoder recurrente, que superó en fidelidad a técnicas lineales como el análisis de componentes principales.
- El uso de una arquitectura generativa adversarial (GAN) basada en la distancia de Wasserstein para ajustar simulaciones alteradas, corrigiendo desviaciones en la composición de eventos.

Sin embargo, la adopción de estas técnicas en física de partículas y astropartículas no ha progresado con la misma rapidez que en otras disciplinas. Una razón clave es la dificultad de interpretar los resultados generados por modelos complejos. En particular, un enfoque de tipo caja negra no garantiza que la estructura matemática modelada por el algoritmo refleje de forma fiable la dinámica física real del sistema. Entre las posibles soluciones que un modelo puede aprender, muchas podrían no ser físicamente plausibles o sólo ser válidas en subconjuntos restringidos del espacio de estados.

Generalmente, para que una metodología basada en IA sea aceptada en estas disciplinas, es necesario entender cómo y por qué el modelo produce una predicción. Esta trazabilidad permite distinguir resultados genuinos de coincidencias estadísticas y garantiza que las inferencias estén alineadas con teorías físicas bien establecidas. Aunque existen métodos como SHAP (SHapley Additive exPlanations), LIME (Local



Interpretable Model-agnostic Explanations) y mecanismos de atención, su uso en física requiere validación rigurosa. Estos deben ir acompañados de análisis de sensibilidad, propagación de incertidumbre y pruebas de robustez ante variaciones sistemáticas. La falta de experiencia de integración de estas herramientas en los marcos experimentales constituye uno de los principales obstáculos actuales para una adopción generalizada y fiable de la IA.

En conclusión, las redes neuronales profundas están siendo incorporadas con éxito en tareas críticas de la física de astropartículas, como la reconstrucción de eventos, la eliminación de ruido y la mejora de simulaciones. Las arquitecturas convolucionales y recurrentes son especialmente eficaces debido a las simetrías inherentes de los sistemas de detección. Aunque actualmente no son indispensables, su uso puede optimizar significativamente el análisis de datos experimentales. La explicabilidad de los modelos emerge como el desafío prioritario: garantizarla es esencial para la aceptación plena y responsable de estas herramientas en el marco riguroso de la investigación científica.

BIBLIOGRAFÍA

1. B. Denby, "Neural networks and cellular automata in experimental high energy physics", *Computer Physics Communications*, 49(3), 429-448 (1988)
2. Martin Erdmann, Jonas Glombitza, "Deep Learning based Algorithms in Astroparticle Physics", *J. of Physics: Conf. Series*, 1525, 012112 (2020)

LA INFLUENCIA MUTUA ENTRE NEUROCIENCIA E INTELIGENCIA ARTIFICIAL

THE MUTUAL INFLUENCE BETWEEN NEUROSCIENCE AND ARTIFICIAL INTELLIGENCE

Juan Lerma^{1,2}

1. Instituto de Neurociencias, CSIC-UMH, San Juan de Alicante.
2. Real Academia de Ciencias Exactas, Físicas y Naturales.

NEUROCIENCIA - IA: RELACIÓN SIMBIÓTICA

Históricamente, se asume que existen paralelismos entre la forma de funcionar del cerebro y la inteligencia artificial (IA). Sin embargo, aunque la neurociencia ha aportado conocimientos clave para el desarrollo de la IA, hay otra corriente de pensamiento que sostiene que el funcionamiento del cerebro y la IA tienen poco en común. El hecho es que la neurociencia se esfuerza por encontrar principios que puedan ayudar en IA, y los recientes avances en este campo están influyendo de manera significativa en la investigación neurocientífica. Como excelente ejemplo está la reciente concesión del Premio Nobel de Física a John Hopfield y Geoffrey Hinton (2024), que desarrollaron los fundamentos matemáticos de las redes neuronales artificiales inspirándose en el funcionamiento del cerebro humano. Ahora bien, aunque la IA usa el conocimiento neurocientífico acumulado en los últimos años para su implementación, la complejidad estructural y funcional del cerebro es mucho mayor que cualquiera de las estrategias arquitectónicas usadas por los ingenieros informáticos en la IA. Por ello, es completamente inadecuado hablar de red neuronal artificial. Es artificial, pero no es neuronal. Las redes usadas en el aprendizaje profundo son redes de nodos, no de neuronas. Una neurona, como elemento unitario de una red neuronal biológica, es mucho más compleja que un nodo en una red artificial. A pesar de ello, y para simplificar la terminología, seguiremos denominándolas como redes "neuronales" artificiales.

Por otro lado, hay que admitir que la IA está revolucionando la neurociencia en múltiples áreas, desde la comprensión de la estructura cuantitativa del cerebro y sus conexiones hasta el desarrollo de nuevas tecnologías inspiradas en ella (por ejemplo, ver ref. 1). En este sentido, la IA y la neurociencia empiezan a mantener una relación simbiótica y sacan provecho de una vida en común comenzada no hace tanto tiempo. Efectivamente, la IA bebe de la información disponible sobre cómo aprende el cerebro y, más directamente, de la organización de las redes neuronales, de sus relaciones a través de las sinapsis y de las capacidades plásticas de éstas. El uso de la IA está permitiendo también el análisis masivo de datos neurocientíficos y el modelado y la simulación de fragmentos del cerebro (1) y, más allá, del perfeccionamiento de interfaces cerebro-máquina, que hace posible en algunas circunstancias saltarse los sentidos para experimentar nuestro entorno y a la vez poder mover elementos robóticos que nos permiten




Figura 1. La IA y la neurociencia mantienen en una relación simbiótica: mientras que la IA ayuda a descifrar el cerebro, el cerebro inspira nuevas formas de inteligencia artificial más avanzadas y eficientes. En el futuro, esta interacción podría llevar a desarrollar inteligencias artificiales más similares a la humana, ayudar a la comprensión final de cerebro y mejorar el tratamiento de trastornos neurológicos y psiquiátricos.

interactuar con el mismo a partir de la actividad de nuestro cerebro. Esto está haciendo posible que personas con tetraplejias controlen brazos robóticos o incluso caminen con exoesqueletos (2). Y en general, en el ámbito de la biomedicina, el uso de la IA puede favorecer el diagnóstico temprano y la personalización de los tratamientos.

Uno de los grandes hitos de la ciencia fue la teoría neuronal, enunciada por Cajal a finales del siglo XIX. El siglo XX está trufado de grandes hitos en el área neurocientífica, como la descripción funcional de la sinapsis por Sherrington, el descubrimiento de los neurotransmisores y la explicación mecanicista de la generación del potencial de acción y su conducción a lo largo de las fibras nerviosas, por Hodgking, Huxley y otros. En la segunda mitad de siglo XX, hemos de considerar hitos como el desarrollo de las técnicas de imagen y el descubrimiento de la neuroplasticidad. En este sentido, podríamos considerar la IA como un gran hito del siglo

XXI comparable a los anteriores, que, junto a otros, ha sido posible gracias al espectacular incremento de la capacidad computacional y de cálculo.

DIFERENCIAS Y SIMILITUDES DE LAS REDES NEURONALES BIOLÓGICAS Y ARTIFICIALES

Desde luego, existe una inspiración en la neurociencia y el funcionamiento básico del cerebro para mejorar la IA la neurociencia ha inspirado el desarrollo de las arquitecturas de IA más eficientes. En particular, las redes “neuronales” artificiales y los modelos que usan redes convolucionales (CNNs en sus siglas en inglés) han sido diseñadas con principios inspirados en el funcionamiento del cerebral. Existe un principio general en la forma que fluye y se procesa la información en el cerebro que incluso los dibujos de Cajal ponen de manifiesto con las famosas flechas

estampadas por él sobre sus dibujos (Figura 2A). La información fluye de manera polarizada, siendo integrada por los diversos elementos neuronales que al final exportan la información procesada. Una red “neuronal” artificial sigue los mismos principios: la información confluye sobre los nodos y éstos emiten una información sopesada sobre nodos (“neuronas”) próximos (Figura 2B). Estas redes pueden tener múltiples capas, donde los pesos con los que cada nodo contribuye varían con el entrenamiento al que se somete la red, con el fin de que la salida se adecúe a la esperada. El hecho de que estas redes profundas sean capaces de “aprender” es tremendamente llamativo, pues apoya la actual hipótesis de que el cerebro aprende formando engramas de neuronas cuya relación funcional a través de sinapsis es modificada por la información recibida mediante los procesos de plasticidad sináptica, de tal manera que los recuerdos se pueden evocar al activar los engramas.

Pero existen varios aspectos fundamentales a tener en cuenta al comparar el cerebro biológico con las redes “neurales” artificiales. El primero es la simplificación extrema de la IA. En el cerebro, las sinapsis biológicas son tanto químicas (la mayoría) como eléctricas (en torno al 1%, aunque juegan un papel importante en ciertos contextos), incluyen dinámicas temporales complejas y operan en entornos biológicos no lineales. Por otra parte, está la escala. El cerebro humano contiene unos 86.000 millones de neuronas y 100 billones de sinapsis químicas (varios miles por neurona), mientras que incluso las redes neuronales más avanzadas (como GPT o AlphaZero) sólo operan con una fracción de ese número. En tercer lugar, existe un problema de temporalidad. Las sinapsis biológicas funcionan en tiempo real de manera continua y adaptativa; la mayoría de los modelos de inteligencia artificial se entrenan con bloques discretos de datos. Finalmente, es necesario mencionar el




Figura 2: A, dibujo original de Ramón y Cajal del hipocampo, donde se pone de manifiesto el flujo de información (flechas) a través del circuito trisináptico hipocámpico con el consiguiente procesamiento integrativo en cada estación. La información proveniente de las neuronas de la corteza entorrinal (A y B) converge sobre las neuronas granulares del giro dentado (1ª sinapsis; el inserto a la izda. es una de estas células teñida con un colorante fluorescente rojo), cuyas fibras (D, fibras musgosas) llevan la información hasta las neuronas piramidales de CA3 (2ª sinapsis). De allí, se contacta con las neuronas piramidales de CA1 (el inserto corresponde a una de ellas teñida con un colorante fluorescente verde). Estas neuronas exportan la información a través del fórnix (E en el dibujo) constituyendo la salida final del circuito. B, Esquema de una red “neuronal” artificial, donde la salida de una capa converge sobre la capa siguiente con distintos pesos (esquema superior). Estos pesos se calculan a partir de las entradas de acuerdo a funciones matemáticas específicas (esquema inferior)



problema de sostenibilidad que la IA presenta. Aunque el cerebro es el órgano del cuerpo que más energía consume, éste equivale a una bombilla de 20W (80% debido a la actividad sináptica). Entrenar una sola vez GPT-3 (el sistema de inteligencia artificial usado originalmente por ChatGPT, con unos 175 mil millones de parámetros) consumió 1.287 MWh (3). Esto significa que cada fase de entrenamiento necesita la energía producida por toda una planta nuclear en 1 hora de funcionamiento. Es posible que con la incorporación de la computación cuántica, este consumo se pueda atenuar, en particular al acelerar algunas operaciones complejas, pero de seguir así, la operatividad de las redes artificiales (incluyendo el entrenamiento de modelos de lenguaje natural) será difícilmente sostenible.

BIBLIOGRAFÍA

1. Wang, E.Y., Fahey, P.G., Ding, Z., Papadopoulos, S., Ponder, K., Weis, M.A., Chang, A., Muhammad, T., Patel, S., Ding, Z., et al. (2025). Foundation model of neural activity predicts response to new stimulus types. *Nature* 640, 470–477. <https://doi.org/10.1038/s41586-025-08829-y>.
2. Ann M. Spungen et al. (2024) Exoskeletal-Assisted Walking in Veterans with Paralysis: A Randomized Clinical Trial. *JAMA Network Open* 7(9):e2431501. <https://doi.org/10.1001/jamanetworkopen.2024.31501>
3. E. Domingo et al. (2024) Declaración sobre la financiación y gestión de la investigación científica en España – 2024 Retos y oportunidades de la ciencia española en una sociedad globalizada. Real Academia de Ciencias Exactas, Físicas y Naturales de España. <https://rac.es/ficheros/doc/806e6164ea264fa3.pdf>