

Informe 2021
Artificial
Intelligence Index



Stanford University
Human-Centered
Artificial Intelligence



INTRODUCCIÓN AL INFORME 2021 DEL AI INDEX

¡Le damos la bienvenida a la cuarta edición del Informe del AI Index! Este año ampliamos significativamente la cantidad de datos disponibles en el informe, trabajamos con un conjunto más amplio de organizaciones externas para calibrar nuestros datos, y profundizamos nuestras conexiones con el Instituto de Inteligencia Artificial Centrada en el Ser Humano (HAI) de Stanford. El Informe del AI Index rastrea, coteja, destila y visualiza datos relacionados con la inteligencia artificial. Su misión es proporcionar datos imparciales, rigurosamente examinados y de alcance mundial para que los responsables de las políticas públicas, investigadores, ejecutivos, periodistas y el público en general puedan comprender el complejo campo de la IA. El informe pretende ser la fuente más creíble y autorizada del mundo en cuanto a datos y conocimientos sobre la IA.

EL COVID Y LA IA

El Informe 2021 muestra los efectos del COVID-19 en el desarrollo de la IA desde múltiples perspectivas. El capítulo sobre el rendimiento técnico analiza cómo una nueva empresa de IA utilizó técnicas basadas en aprendizaje automático para acelerar el descubrimiento de fármacos relacionados con el COVID durante la pandemia. Nuestro capítulo sobre economía sugiere que la contratación de expertos en IA y la inversión privada no sufrieron impactos negativos significativos por la pandemia, ya que ambas crecieron durante 2020. Si acaso, el COVID-19 puede haber llevado a un mayor número de personas a participar en conferencias de investigación sobre IA, ya que la pandemia obligó a las conferencias a cambiar a formatos virtuales, lo que a su vez ocasionó un aumento significativo de la asistencia.

CAMBIOS PARA ESTA EDICIÓN

En 2020, encuestamos a más de 140 lectores del gobierno, la administración pública, la industria y el mundo académico sobre lo que consideraban más útil del informe y lo que deberíamos cambiar. Las principales áreas de mejora sugeridas fueron:

- **Rendimiento técnico:** Ampliamos este capítulo en 2021, incluyendo más análisis de nuestra autoría.
- **Datos acerca de diversidad y ética:** Hemos reunido más datos para el informe de este año, aunque nuestra investigación ha sacado a la luz varias áreas en las que la comunidad de la IA carece actualmente de buena

información.

- **Comparaciones entre países:** En general, los lectores estaban interesados en poder utilizar el AI Index para realizar comparaciones entre países. Para ello hemos:
 - reunido más datos para facilitar la comparación entre países, especialmente respecto a economía y bibliometría; además
 - hemos incluido un resumen exhaustivo de las diversas estrategias de IA de los distintos países y su evolución a lo largo del tiempo.

DATOS PÚBLICOS Y HERRAMIENTAS

El Informe 2021 del AI Index se complementa con datos brutos y una herramienta interactiva. Invitamos a cada miembro de la comunidad de la IA a utilizar los datos y la herramienta de la manera más pertinente para su trabajo y sus intereses.

- **Datos brutos y gráficas:** Los datos públicos y las imágenes de alta resolución de todos los gráficos del informe están disponibles en [Google Drive](#).
- **Herramienta de Vitalidad Global de la IA:** Este año hemos renovado la [Herramienta de Vitalidad Global de la IA](#), que permite una mejor visualización interactiva mediante la comparación de hasta 26 países en 22 indicadores. La herramienta actualizada ofrece una evaluación transparente de la posición relativa de los países en función de las preferencias de los usuarios; identifica los indicadores nacionales pertinentes para orientar las prioridades políticas a nivel nacional; y muestra los centros locales de excelencia en IA no solo para las economías avanzadas, sino también para los mercados emergentes.
- **Cuestiones sobre la medición de la IA:** En otoño de 2020, publicamos "[Measurement in AI Policy: Opportunities and Challenges](#)," un informe que expone una serie de cuestiones de medición de la IA debatidas en una **conferencia organizada por el AI Index en otoño de 2019**.



Tabla de Contenidos

INTRODUCCIÓN AL INFORME 2021 DEL AI INDEX	2
LOS 9 PUNTOS MÁS DESTACADOS	4
JUNTA DIRECTIVA Y EQUIPO DEL AI INDEX	5
CÓMO CITAR ESTE INFORME	6
AGRADECIMIENTOS	7
PUNTOS CLAVE DEL INFORME	10
CAPÍTULO 1 Investigación y Desarrollo	14
<hr/>	
CAPÍTULO 2 Rendimiento Técnico	41
<hr/>	
CAPÍTULO 3 Economía	80
<hr/>	
CAPÍTULO 4 Educación en IA	107
<hr/>	
CAPÍTULO 5 Desafíos Éticos de las Aplicaciones de la IA	125
<hr/>	
CAPÍTULO 6 Diversidad en IA	135
<hr/>	
CAPÍTULO 7 Políticas y Estrategias Nacionales en IA	151
<hr/>	
APÉNDICE	177
<hr/>	

ACCESO A LOS DATOS

LOS 9 PUNTOS MÁS DESTACADOS

- 1** La inversión en IA para el diseño y descubrimiento de fármacos aumentó considerablemente: La categoría “Medicamentos, cáncer, molecular, descubrimiento de fármacos” recibió la mayor cantidad de inversión privada en IA en 2020, con más de USD 13.800 millones, 4,5 veces más que en 2019.
- 2** El cambio de la industria continúa: En 2019, el 65% de los doctores norteamericanos que se graduaron en IA fueron a parar a la industria, frente al 44,4% de 2010, lo que pone de manifiesto el mayor papel que la industria ha empezado a desempeñar en el desarrollo de la IA
- 3** Todo es generativo: los sistemas de IA ya pueden componer texto, audio e imágenes con un nivel de calidad lo suficientemente alto como para que a los humanos les cueste diferenciar los resultados sintéticos de los no sintéticos en algunas aplicaciones limitadas de la tecnología.
- 4** La IA tiene un desafío de diversidad: en 2019, el 45% de los nuevos graduados de doctorado en IA residentes en Estados Unidos eran blancos; en comparación, el 2,4% eran afroamericanos y el 3,2% eran hispanos.
- 5** China supera a EE.UU. en citas de revistas de IA: Después de superar a Estados Unidos en el número total de publicaciones en revistas hace varios años, China ahora también está a la cabeza en cuanto a citas en revistas; sin embargo, Estados Unidos tiene sistemáticamente (y de forma significativa) más documentos de conferencias sobre IA (que también son más citados) que China durante la última década.
- 6** La mayoría de los graduados de doctorado en IA de los EE.UU. son del extranjero, y se quedan en los EE.UU. El porcentaje de estudiantes internacionales entre los nuevos doctores en IA en América del Norte siguió aumentando en 2019, hasta el 64,3%, un aumento del 4,3% respecto a 2018. Entre los graduados extranjeros, el 81,8% se quedó en los EE.UU. y el 8,6% ha aceptado trabajos fuera de los EE.UU.
- 7** Las tecnologías de vigilancia son rápidas, baratas y cada vez más omnipresentes: las tecnologías necesarias para la vigilancia a gran escala están madurando rápidamente, y las técnicas de clasificación de imágenes, reconocimiento de rostros, análisis de vídeo e identificación de voz han experimentado un progreso significativo en 2020.
- 8** La ética en el campo de la IA carece de puntos de referencia y de consenso: Aunque varios grupos están produciendo una serie de resultados cualitativos o normativos en el ámbito de la ética de la IA, el campo generalmente carece de puntos de referencia que puedan utilizarse para medir o evaluar la relación entre los debates sociales más amplios sobre el desarrollo de la tecnología y el desarrollo de la propia tecnología. Además, los investigadores y la sociedad civil consideran que la ética de la IA es más importante que las empresas privadas.
- 9** La IA se ha ganado la atención del Congreso de Estados Unidos: El 116° Congreso es la sesión del Congreso más centrada en la IA de la historia, con un número de menciones a la IA en el registro del Congreso que triplica el del 115° Congreso.



Junta Directiva del AI Index

Co-Directores

Jack Clark
OECD, GPAI

Raymond Perrault
SRI International

Miembros

Erik Brynjolfsson
Universidad de Stanford

James Manyika
McKinsey Global Institute

John Etchemendy
Universidad de Stanford

Juan Carlos Niebles
Universidad de Stanford

Deep Ganguli
Universidad de Stanford

Michael Sellitto
Universidad de Stanford

Barbara Grosz
Universidad de Harvard

Yoav Shoham (Director Fundador)
Universidad de Stanford, AI21 Labs

Terah Lyons
Partnership on AI

Equipo del AI Index

Gerente de Investigación y Jefe de Redacción

Daniel Zhang
Universidad de Stanford

Gerente del Programa

Saurabh Mishra
Universidad de Stanford



Cómo citar este informe

Daniel Zhang, Saurabh Mishra, Erik Brynjolfsson, John Etchemendy, Deep Ganguli, Barbara Grosz, Terah Lyons, James Manyika, Juan Carlos Niebles, Michael Sellitto, Yoav Shoham, Jack Clark, and Raymond Perrault, “The AI Index 2021 Annual Report,” Junta Directiva del AI Index, Human-Centered AI Institute, Universidad de Stanford, Stanford, California, Marzo 2021. Traducción al castellano por el Instituto de Inteligencia Artificial.

El Informe Anual 2021 del AI Index de la Universidad de Stanford está bajo una licencia Reconocimiento-SinObraDerivada 4.0 Internacional (CC BY-ND 4.0). Para ver una copia de esta licencia, visite https://creativecommons.org/licenses/by-nd/4.0/deed.es_ES

El AI Index es una iniciativa independiente del Instituto de Inteligencia Artificial Centrada en Humanos (HAI) de la Universidad de Stanford.



Artificial
Intelligence
Index



Stanford University
Human-Centered
Artificial Intelligence

El AI Index fue concebido dentro del One Hundred Year Study on AI (AI100).

Agradecemos a nuestros socios patrocinantes



Agradecemos vuestra retroalimentación y nuevas ideas para el próximo año. Contáctenos al AI-Index-Report@stanford.edu.



Agradecimientos

Apreciamos a las siguientes organizaciones e individuos quiénes suministraron datos, análisis, asesoría y comentarios expertos para ser incluidos en el Informe AI Index 2021:

Organizaciones

arXiv

Jim Entwood, Paul Ginsparg,
Joe Halpern, Eleonora Presani

AI Ethics Lab

Cansu Canca, Yasemin Usta

Black in AI

Rediet Abebe, Hassan Kane

Bloomberg Government

Chris Cornillie

Burning Glass Technologies

Layla O’Kane, Bledi Taska, Zhou Zhou

Computing Research Association

Andrew Bernat, Susan Davidson

Elsevier

Clive Bastin, Jörg Hellwig,
Sarah Huggett, Mark Siebert

Intento

Grigory Sapunov, Konstantin Savenkov

Federación Internacional de Robótica

Susanne Bieller, Jeff Burnstein

Centro de Investigación Conjunta,

Comisión Europea

Giuditta De Prato, Montserrat López
Cobo, Riccardo Righi

LinkedIn

Guy Berger, Mar Carpanelli, Di Mo,
Virginia Ramsey

Liquidnet

Jeffrey Banner, Steven Nichols

McKinsey Global Institute

Brittany Presten

Microsoft Academic Graph

Iris Shen, Kuansan Wang

Instituto Nacional de Estándares y Tecnología de los Estados Unidos

Patrick Grother

Nesta

Joel Klinger, Juan Mateos-Garcia,
Kostas Stathoulopoulos

NetBase Quid

Zen Ahmed, Scott Cohen, Julie Kim

PostEra

Aaron Morris

Queer in AI

Raphael Gontijo Lopes

Reporte del Estado de la IA

Nathan Benaich, Ian Hogarth

Women in Machine Learning

Sarah Tan, Jane Wang



Individuos

ActivityNet

Fabian Caba (Adobe Research); Bernard Ghanem (Universidad de Ciencia y Tecnología Rey Abdullah); Cees Snoek (Universidad de Ámsterdam)

Fuga de Cerebros de IA y Egresos de la Academia

Michael Gofman (Universidad de Rochester); Zhao Jin (Escuela de Posgrado de Negocios Cheung Kong)

Demostración Automatizada de Teoremas

Geoff Sutcliffe (Universidad de Miami); Christian Suttner (Connion GmbH)

Satisfacción del Problema Booleano

Lars Kotthoff (Universidad de Wyoming)

Representación Empresarial en las Conferencias de Investigación en IA

Nuruddin Ahmed (Escuela de Negocios Ivey, Universidad Occidental); Muntasir Wahed (Virginia Tech)

Asistencia a Conferencias

Maria Gini, Gita Sukthankar (AAMAS); Carol Hamilton (AAAI); Dan Jurafsky (ACL); Walter Scheirer, Ramin Zabih (CVPR); Jörg Hoffmann, Erez Karpas (ICAPS); Paul Oh (IROS); Pavlos Peppas, Michael Thielscher (KR)

Ética en Conferencia de IA

Pedro Avelar, Luis Lamb, Marcelo Prates (Federal University of Rio Grande do Sul)

ImageNet

Lucas Beyer, Alexey Dosovitskiy, Neil Houlsby (Google)

MLPerf/DAWNBench

Cody Coleman (Universidad de Stanford), Peter Mattson (Google)

Molecular Synthesis

Philippe Schwaller (IBM Research–Europa)

Respuestas a Preguntas Visuales

Dhruv Batra, Devi Parikh (Georgia Tech/FAIR); Ayush Shrivastava (Georgia Tech)

Sólo mira una vez (You Only Look Once, YOLO)

Xiang Long (Baidu)



Asesoría y comentarios expertos

Alexey Bochkovskiy; Baidu's PaddlePaddle Computer Vision Team; Chenggang Xu (Cheung Kong Graduate School of Business); Mohammed AlQuraishi (Columbia University); Evan Schnidman (EAS Innovation); Fanghzhen Lin (Hong Kong University of Science and Technology); David Kanter (MLCommons); Sam Bowman (New York University); Maneesh Agrawala, Jeannette Bohg, Emma Brunskill, Chelsea Finn, Aditya Grover, Tatsunori Hashimoto, Dan Jurafsky, Percy Liang, Sharon Zhou (Stanford University); Vamsi Sista (University of California, Berkeley); Simon King (University of Edinburgh); Ivan Goncharov (Weights & Biases)

Investigadores de posgrado

Ankita Banerjea, Yu-chi Tsao (Universidad de Stanford)

Informe y sitio web

Michi Turner (diseño gráfico del informe y arte de la portada); Nancy King (editora del informe); Michael Taylor (visualización de datos del informe); Kevin Litman-Navarro (diseño y desarrollo de la Herramienta de Vitalidad Global de IA); Travis Tyler (diseño del sitio web del AI Index); Digital Avenues (desarrollo del sitio web del AI Index)



PUNTOS CLAVE DEL INFORME

CAPÍTULO 1: INVESTIGACIÓN Y DESARROLLO

- El número de publicaciones de revistas de IA creció un 34,5% de 2019 a 2020, un crecimiento porcentual mucho mayor que de 2018 a 2019 (19,6%).
- En cada uno de los principales países y regiones, la mayor proporción de artículos de IA en publicaciones revisadas proviene de instituciones académicas. Pero los segundos más importantes son diferentes: en Estados Unidos, la investigación afiliada a empresas representa el 19,2% del total de publicaciones, mientras que el gobierno es el segundo más importante en China (15,6%) y la Unión Europea (17,2%).
- En 2020, y por primera vez, China superó a Estados Unidos en la proporción de citas de revistas de IA en el mundo, después de haber superado brevemente a Estados Unidos en el número total de publicaciones de revistas de IA en 2004 y haber retomado el liderazgo en 2017. Sin embargo, Estados Unidos ha citado sistemáticamente (y de forma significativa) más artículos de conferencias de IA que China durante la última década.
- En respuesta a COVID-19, la mayoría de las principales conferencias de IA se celebraron de forma virtual y registraron un aumento significativo de la asistencia como resultado. El número de asistentes a nueve conferencias casi se duplicó en 2020.
- Sólo en los últimos seis años, el número de publicaciones relacionadas con la IA en arXiv se multiplicó por más de seis, pasando de 5.478 en 2015 a 34.736 en 2020.
- Las publicaciones sobre IA representaron el 3,8% de todas las publicaciones científicas revisadas en todo el mundo en 2019, frente al 1,3% en 2011.

CAPÍTULO 2: RENDIMIENTO TÉCNICO

- **Todo es generativo:** los sistemas de IA pueden ahora componer texto, audio e imágenes con un nivel suficientemente alto como para que a los humanos les cueste distinguir entre resultados sintéticos y no sintéticos en algunas aplicaciones limitadas de la tecnología. Esto promete generar una enorme gama de aplicaciones posteriores de la IA, tanto para fines socialmente útiles como para los que no lo son tanto. También está provocando que los investigadores inviertan en tecnologías para detectar modelos generativos; los datos del *DeepFake Detection Challenge* indican lo bien que los ordenadores pueden distinguir entre diferentes resultados.
- **La industrialización de la visión artificial:** La visión artificial ha experimentado un inmenso progreso en la última década, principalmente debido al uso de técnicas de aprendizaje automático (específicamente el aprendizaje profundo). Nuevos datos muestran que la visión artificial se está industrializando: el rendimiento está empezando a aplanarse en algunos de los mayores puntos de referencia, lo que sugiere que la comunidad necesita desarrollar y acordar otros más exigentes que pongan a prueba el rendimiento. Mientras tanto, las empresas están invirtiendo cantidades cada vez mayores de recursos informáticos para entrenar los sistemas de visión artificial a un ritmo más rápido que nunca. Por otro lado, las tecnologías que se utilizan en los sistemas implantados -como los *frameworks* de detección de objetos para el análisis de imágenes fijas en vídeos- están madurando rápidamente, lo que indica un mayor despliegue de la IA.
- **El Procesamiento del Lenguaje Natural (PLN) supera sus métricas de evaluación:** Los rápidos avances en NLP han dado lugar a sistemas de IA con capacidades lingüísticas mejoradas significativamente que han empezado a tener un



impacto económico significativo en el mundo. Tanto Google como Microsoft han implantado el modelo lingüístico BERT en sus motores de búsqueda, mientras que otros grandes modelos lingüísticos han sido desarrollados por empresas que van desde Microsoft hasta OpenAI. El progreso del NLP ha sido tan rápido que los avances técnicos han empezado a superar los puntos de referencia para probarlos. Esto puede verse en la rápida aparición de sistemas que obtienen un rendimiento de nivel humano en SuperGLUE, una suite de evaluación del NLP desarrollada en respuesta a los anteriores avances del NLP que superan las capacidades evaluadas por GLUE.

- **Nuevos análisis sobre el razonamiento:** La mayoría de las medidas de los problemas técnicos muestran para cada momento el rendimiento del mejor sistema en ese momento en un *benchmark* fijo. Los nuevos análisis desarrollados para el AI Index ofrecen métricas que permiten un *benchmark* evolutivo y la atribución a los sistemas individuales de un crédito por una parte del rendimiento global de un grupo de sistemas a lo largo del tiempo. Estos se aplican a dos problemas de razonamiento simbólico, la demostración automatizada de teoremas y la satisfacibilidad booleana.
- **El aprendizaje automático está cambiando las reglas del juego en la sanidad y la biología:** El panorama de las industrias de la salud y la biología ha evolucionado sustancialmente con la adopción del aprendizaje automático. AlphaFold, de DeepMind, aplicó una técnica de aprendizaje profundo para lograr un avance significativo en el desafío biológico del plegado de proteínas, que lleva décadas. Los científicos utilizan modelos de ML para aprender representaciones de moléculas químicas para una planificación más eficaz de la síntesis química. PostEra, una startup de IA, utilizó técnicas basadas en ML para acelerar el descubrimiento de fármacos relacionados con el COVID durante la pandemia.

CAPÍTULO 3: ECONOMÍA

- La categoría “Medicamentos, cáncer, molecular, descubrimiento de fármacos” recibió la mayor cantidad de inversión privada en IA en 2020, con más de 13.800 millones de dólares, 4,5 veces más que en 2019.
- Brasil, India, Canadá, Singapur y Sudáfrica son los países con mayor crecimiento en la contratación de IA de 2016 a 2020. A pesar de la pandemia de COVID-19, la contratación de IA siguió creciendo en todos los países de la muestra en 2020.
- Se está canalizando más inversión privada en IA hacia menos startups. A pesar de la pandemia, en 2020 se produjo un aumento del 9,3% en la cantidad de inversión privada en IA desde 2019, un aumento porcentual mayor que de 2018 a 2019 (5,7%), aunque el número de empresas recién financiadas disminuyó por tercer año consecutivo.
- A pesar de las crecientes llamadas para abordar las preocupaciones éticas asociadas con el uso de la IA, los esfuerzos para abordar estas preocupaciones en la industria son limitados, según una encuesta de McKinsey. Por ejemplo, cuestiones como la equidad y la justicia en la IA siguen recibiendo comparativamente poca atención por parte de las empresas. Además, menos empresas en 2020 ven los riesgos de privacidad personal o individual como relevantes, en comparación con 2019, y no hubo cambios en el porcentaje de encuestados cuyas empresas están tomando medidas para mitigar estos riesgos particulares.
- A pesar de la recesión económica causada por la pandemia, la mitad de los encuestados en una encuesta de McKinsey dijo que el coronavirus no tuvo ningún efecto en su inversión en IA, mientras que el 27% informó que había aumentado su inversión. Menos de una cuarta parte de las empresas redujo su inversión en IA.
- Estados Unidos registró una disminución en su proporción de puestos de trabajo de IA de 2019 a 2020, la primera caída en seis años. El número total de puestos de trabajo de IA publicados en los Estados Unidos también disminuyó un 8,2% de 2019 a 2020, de 325.724 en 2019 a 300.999 puestos de trabajo en 2020.

CAPÍTULO 4: EDUCACIÓN EN IA

- Una encuesta del AI Index realizada en 2020 sugiere que las principales universidades del mundo han aumentado su inversión en educación en IA en los últimos cuatro años. El número de cursos que enseñan a los estudiantes las habilidades necesarias para construir o desplegar un modelo práctico de IA en los niveles de pregrado y postgrado ha aumentado un 102,9% y un 41,7%, respectivamente, en los últimos cuatro años académicos.
- Según una encuesta anual de la Computing Research Association (CRA), en los últimos 10 años ha aumentado el número de egresados en Inteligencia Artificial que han optado por trabajar en la industria, mientras que ha disminuido el número de los que han optado por el mundo académico. La proporción de nuevos doctores en IA que eligieron trabajos en la industria aumentó un 48% en la última década, del 44,4% en 2010 al 65,7% en 2019. Por el contrario, la proporción de nuevos doctores en IA que entraron en el mundo académico se redujo en un 44%, del 42,1% en 2010 al 23,7% en 2019.
- En los últimos 10 años, los doctorados relacionados con IA han pasado del 14,2% del total de los doctorados en ciencias de la computación concedidos en Estados Unidos, a cerca del 23% a partir de 2019, según la encuesta de la CRA. Al mismo tiempo, otros doctorados en ciencias de la computación anteriormente populares han disminuido su popularidad, incluyendo las redes, la ingeniería de software y los lenguajes de programación. Los compiladores vieron una reducción en el número de doctorados concedidos en relación con 2010, mientras que las especialidades de IA y Robótica/Visión experimentaron un aumento sustancial.
- Después aumentar por dos años seguidos, el número de salidas de profesores de IA de las universidades a puestos de trabajo en la industria en América del Norte se redujo de 42 en 2018 a 33 en 2019 (28 de ellos son profesores titulares y cinco no titulares). La Universidad Carnegie Mellon tuvo el mayor número de salidas de profesores de IA entre 2004 y 2019 (16), seguida por el Instituto de Tecnología de Georgia (14) y la Universidad de Washington (12).
- El porcentaje de estudiantes internacionales entre los nuevos doctores en IA en América del Norte siguió aumentando en 2019, hasta el 64,3%, un aumento del 4,3% con respecto a 2018. Entre los graduados extranjeros, el 81,8% se quedó en los Estados Unidos y el 8,6% ha aceptado trabajos fuera de los Estados Unidos.
- En la Unión Europea, la gran mayoría de las ofertas académicas especializadas en IA se imparten a nivel de máster; la robótica y la automatización es, con mucho, el curso más frecuente en los programas de licenciatura y máster especializados, mientras que el aprendizaje automático (ML) domina en los cursos cortos especializados.

CAPÍTULO 5: DESAFÍOS ÉTICOS DE LAS APLICACIONES DE LA IA

- El número de artículos con palabras clave relacionadas con la ética en los títulos presentados a las conferencias de IA ha crecido desde 2015, aunque el número medio de títulos de artículos que coinciden con palabras clave relacionadas con la ética en las principales conferencias de IA sigue siendo bajo a lo largo de los años.
- Las cinco noticias que recibieron más atención en 2020 relacionados con el uso ético de la IA fueron la publicación del libro blanco de la Comisión Europea sobre la IA, el despido del investigador de ética Timnit Gebru por parte de Google, el comité de ética de la IA formado por las Naciones Unidas, el plan de ética de la IA del Vaticano y la salida de IBM de los negocios de reconocimiento facial.

CAPÍTULO 6: DIVERSIDAD EN LA IA

- Los porcentajes de mujeres que se doctoran en IA y de profesoras de ciencias de la computación se han mantenido bajos durante más de una década. Según una encuesta anual de la Computing Research Association (CRA), las mujeres graduadas en programas de doctorado en Inteligencia Artificial en Norteamérica han representado menos del 18% de todos los graduados de doctorado por término medio. Una encuesta del AI Index sugiere que el profesorado femenino representa solo el 16% de todo el profesorado de ciencias de la computación con titularidad en varias universidades de todo el mundo.
- La encuesta de la CRA sugiere que en 2019, entre los nuevos graduados de doctorado en IA residentes en Estados Unidos, el 45% eran blancos, mientras que el 22,4% eran asiáticos, el 3,2% eran hispanos y el 2,4% eran afroamericanos.
- El porcentaje de nuevos doctores en computación blancos (no hispanos) ha cambiado poco en los últimos 10 años, representando el 62,7% en promedio. El porcentaje de doctores en informática negros o afroamericanos (no hispanos) e hispanos en el mismo periodo es significativamente menor, con una media del 3,1% y el 3,3%, respectivamente.
- La participación en los talleres Black in AI, que coinciden con la Conferencia sobre Sistemas de Procesamiento de Información Neuronal (NeurIPS), ha crecido considerablemente en los últimos años. El número de asistentes y de trabajos presentados en 2019 es 2,6 veces mayor que en 2017, mientras que el número de trabajos aceptados es 2,1 veces mayor.
- En una encuesta de miembros realizada por Queer in AI en 2020, casi la mitad de los encuestados dijeron que perciben que el campo de la IA no es inclusivo y esto representa un obstáculo al que se han tenido que enfrentar para convertirse en profesionales en el campo de la IA / ML. Más del 40% de los miembros encuestados afirmaron haber sufrido discriminación o acoso en el trabajo o en la escuela.

CAPÍTULO 7: POLÍTICAS Y ESTRATEGIAS NACIONALES DE IA

- Desde que Canadá publicó la primera estrategia nacional de IA del mundo en 2017, más de 30 países y regiones han publicado documentos similares hasta diciembre de 2020.
- La puesta en marcha del Observatorio de Políticas de Inteligencia Artificial y la Red de Expertos en Inteligencia Artificial de la Organización para la Cooperación y el Desarrollo Económicos (OCDE) en 2020 promovió los esfuerzos intergubernamentales para trabajar juntos en apoyo del desarrollo de la inteligencia artificial para todos.
- En Estados Unidos, el 116° Congreso ha sido el que le ha prestado más atención a la IA en la historia. El número de menciones a la IA por parte de este Congreso en la legislación, los informes de las comisiones y los informes del Servicio de Investigación del Congreso (CRS) es más del triple que el del 115° Congreso.



CAPÍTULO 1: Investigación y Desarrollo



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 1:

Vista previa del capítulo

Resumen	16	Patentes de IA	31
Puntos clave del capítulo	17	Resumen	31
1.1 PUBLICACIONES	18	Publicaciones en arXiv	32
Publicaciones revisadas de IA	18	Resumen	32
Resumen	18	Por región	32
Por región	18	Por zona geográfica	33
Por zona geográfica	20	Por campo de estudio	34
Por afiliación institucional	21	Punto clave: Artículos de Aprendizaje Profundo en arXiv	35
Colaboración académico-corporativa	23	1.2 CONFERENCIAS	36
Publicaciones de IA en revistas	25	Asistencia a las conferencias	36
Resumen	25	Punto clave: Representación corporativa en las conferencias de investigación en IA	38
Por región	26	1.3 BIBLIOTECAS DE SOFTWARE DE CÓDIGO ABIERTO DE IA	39
Por zona geográfica	27	Estrellas de GitHub	39
Citas	27		
Publicaciones en conferencias de IA	28		
Resumen	28		
Por región	29		
Por zona geográfica	30		
Citas	30		

ACCESO A LOS DATOS

Resumen

El informe comienza con una visión general de los esfuerzos de investigación y desarrollo (I+D) en inteligencia artificial (IA) porque la I+D es fundamental para el progreso de la IA. Desde que la tecnología cautivó por primera vez la imaginación de informáticos y matemáticos en los años 50, la IA se ha convertido en una importante disciplina de investigación con aplicaciones comerciales muy relevantes. El número de publicaciones sobre IA ha aumentado drásticamente en los últimos 20 años. El aumento de los congresos de IA y de los documentos ha ampliado la difusión de investigación y las comunicaciones académicas. Las principales potencias, como China, la Unión Europea y Estados Unidos, se apresuran a invertir en la investigación de la IA.

El capítulo dedicado a la I+D busca recoger los avances en este campo cada vez más complejo y competitivo.

Este capítulo comienza examinando las publicaciones sobre IA -desde artículos de publicaciones revisadas hasta ponencias de conferencias y patentes-, incluyendo el impacto de las citas de cada una de ellas, utilizando datos de las bases de datos Elsevier/Scopus y Microsoft Academic Graph (MAG), así como datos del repositorio de documentos de arXiv y NESTA. Se examinan las contribuciones a la I+D en IA de las principales entidades de IA y regiones geográficas y se consideran cómo estas contribuciones están dando forma al campo. Las secciones segunda y tercera analizan las actividades de I+D en las principales conferencias de IA y en GitHub.

PUNTOS CLAVE DEL CAPÍTULO

- El número de publicaciones de IA en revistas creció un 34,5% de 2019 a 2020, un crecimiento porcentual mucho mayor que de 2018 a 2019 (19,6%).
- En cada uno de los principales países y regiones, la mayor proporción de artículos de IA en publicaciones revisadas viene de instituciones académicas. Pero los segundos emisores más importantes son diferentes: en Estados Unidos, la investigación vinculada al sector privado representa el 19,2% del total de publicaciones, mientras que el gobierno es el segundo más importante en China (15,6%) y la Unión Europea (17,2%).
- En 2020, y por primera vez, China superó a Estados Unidos en la proporción de citas de revistas de IA en el mundo, después de haber superado brevemente a Estados Unidos en el número total de publicaciones de revistas de IA en 2004 y haber retomado el liderazgo en 2017. Sin embargo, Estados Unidos ha citado sistemáticamente (y de forma significativa) más artículos de conferencias de IA que China durante la última década.
- En respuesta a COVID-19, la mayoría de las principales conferencias de IA se celebraron de forma virtual y registraron un aumento significativo de la asistencia como resultado. El número de asistentes a nueve conferencias casi se duplicó en 2020.
- Sólo en los últimos seis años, el número de publicaciones relacionadas con la IA en arXiv se multiplicó por más de seis, pasando de 5.478 en 2015 a 34.736 en 2020.
- Las publicaciones sobre IA representaron el 3,8% de todas las publicaciones científicas revisadas por pares en todo el mundo en 2019, frente al 1,3% en 2011.

Las publicaciones sobre IA incluyen publicaciones revisadas, artículos de revistas, documentos de conferencias y patentes. Para seguir las tendencias de estas publicaciones y evaluar el estado de las actividades de I+D en IA en todo el mundo, se utilizaron los siguientes conjuntos de datos: la base de datos Elsevier/Scopus para las publicaciones revisadas; la base de datos Microsoft Academic Graph (MAG) para todas las revistas, artículos de conferencias y publicaciones de patentes; y los datos de arXiv y NESTA para los documentos preimpresos electrónicos.

1.1 PUBLICACIONES

PUBLICACIONES REVISADAS DE IA

Esta sección presenta datos de la base de datos Scopus de Elsevier. Scopus contiene 70 millones de artículos de investigación revisados por pares y curados por más de 5000 editores internacionales. La versión de 2019 de los datos que se muestran a continuación se deriva de un conjunto de publicaciones totalmente nuevo, por lo que las cifras de todas las publicaciones de IA revisadas por pares difieren de las de los informes del AI Index de años anteriores. Debido a los cambios en la metodología de indexación de las publicaciones, la exactitud del conjunto de datos aumentó del 80% al 84% (véase el Apéndice para más detalles).

Resumen

La figura 1.1.1a muestra el número de publicaciones revisadas de IA, y la figura 1.1.1b muestra la proporción de estas entre todas las publicaciones revisadas por pares en el mundo. El número total de publicaciones creció casi 12 veces entre 2000 y 2019. Durante el mismo período, el porcentaje de publicaciones revisadas por pares aumentó del 0,82% de todas las publicaciones en 2000 al 3,8% en 2019.

Por región¹

Entre el número total de publicaciones de IA revisadas por pares en el mundo, Asia Oriental y el Pacífico ha tenido la mayor proporción desde 2004, seguida de Europa y Asia Central, y América del Norte (Figura 1.1.2). Entre 2009 y 2019, el sur de Asia y el África subsahariana experimentaron el mayor crecimiento en cuanto al número de publicaciones de IA revisadas por pares, multiplicándose por ocho y siete, respectivamente.

NÚMERO DE PUBLICACIONES ARBITRADAS DE IA, 2000-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.1a

¹ Las regiones en este capítulo están clasificadas de acuerdo con las agrupaciones analíticas del Banco Mundial.

PUBLICACIONES ARBITRADAS DE IA(% del TOTAL), 2000-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: 2021 AI Index Report




Figura 1.1.1b

PUBLICACIONES ARBITRADAS DE IA(% del TOTAL) por REGIÓN, 2000-19

Fuente: Microsoft Academic Graph, 2020 | Gráfica: 2021 AI Index Report




Figura 1.1.2

Por zona geográfica

Para comparar la actividad entre los principales actores de la IA del mundo, esta sección muestra las tendencias de las publicaciones revisadas de IA procedentes de China, la Unión Europea y los Estados Unidos. En 2019, China lideraba la cuota de publicaciones revisadas de IA

en el mundo, tras superar a la Unión Europea en 2017 (figura 1.1.3). Publicó 3,5 veces más artículos de IA en revistas revisadas en 2019 que en 2014, mientras que la Unión Europea publicó solo 2 veces más artículos y Estados Unidos 2,75 veces más en el mismo periodo.

PUBLICACIONES ARBITRADAS DE IA (% del total MUNDIAL) por ZONA GEOGRÁFICA, 2000-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.3

Por afiliación institucional

Los siguientes gráficos muestran el número de publicaciones revisadas de IA afiliadas a instituciones privadas, gubernamentales, médicas y de otro tipo en China (figura 1.1.4a), la Unión Europea (figura 1.1.4b) y los Estados Unidos (figura 1.1.4c).² En 2019, aproximadamente el 95,4% de las publicaciones de IA revisadas por pares en general en China estaban afiliadas al ámbito académico, en comparación con el 81,9% en la Unión Europea y el 89,6% en los Estados

Unidos. Esas categorías de afiliación no son mutuamente excluyentes, ya que algunos autores podrían estar afiliados a más de un tipo de institución.

Los datos sugieren que, excluyendo el mundo académico, las instituciones gubernamentales -más que las de otras categorías- contribuyen sistemáticamente con el mayor porcentaje de publicaciones de IA revisadas por pares tanto en China como en la Unión Europea (15,6% y 17,2%, respectivamente, en 2019), mientras que en Estados Unidos, la porción más alta está afiliada a empresas (19,2%).

NÚMERO DE PUBLICACIONES ARBITRADAS DE IA en CHINA por AFILIACIÓN INSTITUCIONAL, 2000-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.4a

² En las tres áreas geográficas, el número de trabajos afiliados al mundo académico supera al de los afiliados al gobierno, las empresas y la medicina; por lo tanto, no se muestra la afiliación al mundo académico, ya que distorsionaría los gráficos.

NÚMERO DE PUBLICACIONES ARBITRADAS DE IA en la UNIÓN EUROPEA por AFILIACIÓN INSTITUCIONAL, 2000-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.4b

NÚMERO DE PUBLICACIONES ARBITRADAS DE IA en EE.UU por AFILIACIÓN INSTITUCIONAL, 2000-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.4c

Colaboración académico-corporativa

Desde la década de 1980, la colaboración en I+D entre el mundo académico y el sector privado en Estados Unidos ha crecido en importancia y popularidad, lo que se hace visible por la proliferación de centros de investigación creados mediante la colaboración entre la industria y la universidad, así como

por las contribuciones de las empresas a la investigación universitaria. La figura 1.1.5 muestra que entre 2015 y 2019, Estados Unidos produjo el mayor número de publicaciones híbridas de IA académicas y corporativas, con coautoría y revisadas, más del doble que en la Unión Europea, que ocupa el segundo lugar, seguida de China en el tercero.

NÚMERO de PUBLICACIONES ARBITRADAS ACADÉMICO-CORPORATIVAS DE IA por ZONA GEOGRÁFICA, 2015-19

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.5

Para evaluar el impacto de las colaboraciones académico-empresariales en el impacto de las citas ponderadas por campo (FWCI) de las publicaciones de IA de diferentes regiones geográficas, véase la figura 1.1.6. El FWCI mide el número de citas recibidas por las publicaciones en comparación con el número medio de citas recibidas por otras publicaciones similares en el mismo año, disciplina y formato (libro, artículo, documento de conferencia, etc.). Un valor de 1,0 representa la media mundial. Más o menos de 1 significa que las publicaciones se citan más o menos de lo esperado según

la media mundial. Por ejemplo, un FWCI de 0,75 significa un 25% menos de citas que la media mundial. El gráfico muestra el FWCI para todas las publicaciones de IA revisadas por pares en el eje 'y' y el número total (en una escala logarítmica) de publicaciones académicas y corporativas en coautoría en el eje x. Para mejorar la relación señal-ruido de la métrica FWCI, sólo se incluyen los países que tienen más de 1.000 publicaciones de IA revisadas por pares en 2020.

PUBLICACIONES ARBITRADAS DE IA PONDERADAS POR IMPACTO DE CITAS Y NÚMERO DE PUBLICACIONES ARBITRADAS ACADÉMICO-CORPORATIVAS DE IA, 2019

Fuente: Elsevier/Scopus, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.6

PUBLICACIONES DE IA EN REVISTAS

En las tres secciones siguientes se muestran las tendencias en la publicación de revistas de IA, publicaciones en conferencias y patentes, así como sus respectivas citas que dan una idea del impacto de la I+D, basado en los datos de Microsoft Academic Graph. MAG es una gráfica de conocimiento que consta de más de 225 millones de publicaciones (en noviembre de 2019).

Resumen

En general, el número de publicaciones de revistas de IA en 2020 es 5,4 veces mayor que en 2000 (Figura 1.1.7a). En 2020, el número de publicaciones de revistas de IA aumentó un 34,5% con respecto a 2019, un crecimiento porcentual mucho mayor que entre 2018 y 2019 (19,6%). Del mismo modo, la proporción de publicaciones de revistas de IA entre todas las publicaciones del mundo ha saltado en 0,4 puntos porcentuales en 2020, más que la media de 0,03 puntos porcentuales en los últimos cinco años (Figura 1.1.7b).

NÚMERO DE PUBLICACIONES DE IA EN REVISTAS, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.7a

PUBLICACIONES DE IA EN REVISTAS (% de TODAS LAS PUBLICACIONES EN REVISTAS), 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.7b

3 Consulte "An Overview of Microsoft Academic Service (MAS) and Applications" y "A Review of Microsoft Academic Services for Science of Science Studies" para más detalles.

Por región

La figura 1.1.8 muestra la proporción de revistas de IA -la entidad de publicación dominante en términos de número en la base de datos del MAG- por regiones entre 2000 y 2020. Asia Oriental y Pacífico, Europa y Asia Central, y América del Norte son responsables de la mayoría de las publicaciones de revistas de IA en los últimos 21 años, aunque la posición de liderazgo entre las

tres regiones cambia con el tiempo.

En 2020, Asia Oriental y el Pacífico tendrá la mayor cuota (26,7%), seguida de Europa y Asia Central (13,3%) y Norteamérica (14,0%). Además, en los últimos 10 años, Asia Meridional y Oriente Medio y el Norte de África han experimentado el mayor crecimiento, ya que el número de publicaciones de revistas de IA en esas dos regiones se ha multiplicado por seis y por cuatro, respectivamente.

PUBLICACIONES DE IA EN REVISTAS (% del TOTAL MUNDIAL) por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.8

Por zona geográfica

La figura 1.1.9 muestra que entre las tres principales potencias de la IA, China ha tenido la mayor cuota de publicaciones de revistas de IA en el mundo desde 2017, con un 18,0% en 2020, seguida de Estados Unidos (12,3%) y la Unión Europea (8,6%).

PUBLICACIONES DE IA EN REVISTAS(% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.9

Citas

En cuanto a la mayor proporción de citas de revistas de IA, la figura 1.1.10 muestra que China (20,7%) superó a Estados Unidos (19,8%) en 2020 por primera vez, mientras que la Unión Europea siguió perdiendo parte de su cuota global.

CITAS DE REVISTAS DE IA (% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.10

PUBLICACIONES DE IA EN CONFERENCIAS

Resumen

Entre 2000 y 2019, el número de publicaciones de conferencias de IA se multiplicó por cuatro, aunque el crecimiento se aplanó en los últimos diez años, y el número de publicaciones en 2019 solo es 1,09 veces mayor que el de 2010.⁴

NÚMERO de PUBLICACIONES EN CONFERENCIAS DE IA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.11a

PUBLICACIONES EN CONFERENCIAS DE IA(% de TODAS LAS PUBLICACIONES EN CONFERENCIAS), 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.11b

⁴ Nótese que los datos de la conferencia de 2020 sobre MAG no está completa aún. Vea el apéndice para más detalles.

Por región

La figura 1.1.12 muestra que, al igual que las tendencias en la publicación de revistas de inteligencia artificial, Asia Oriental y el Pacífico, Europa y Asia Central y América del Norte son las principales fuentes de publicación de conferencias de

inteligencia artificial.

Concretamente, Asia Oriental y el Pacífico tomaron la delantera a partir de 2004, con más del 27% en 2020. América del Norte superó a Europa y Asia Central para reclamar el segundo lugar en 2018, con un 20,1%, seguido del 21,7% en 2020.

PUBLICACIONES EN CONFERENCIAS DE IA(% de TODAS LAS PUBLICACIONES DE CONFERENCIAS) por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.12

Por zona geográfica

China superó a Estados Unidos en la cuota de publicaciones de conferencias sobre IA en el mundo en 2019 (figura 1.1.13). Su cuota ha crecido significativamente desde el año 2000. El porcentaje de publicaciones de conferencias de IA de China en

2019 es casi nueve veces mayor que en 2000. El porcentaje de publicaciones de conferencias de la Unión Europea alcanzó su punto máximo en 2011 y sigue disminuyendo.

PUBLICACIONES EN CONFERENCIAS DE IA(% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.13

Citas

Con respecto a las citas de las publicaciones de conferencias sobre IA, la figura 1.1.14 muestra que Estados Unidos ha mantenido un liderazgo dominante entre las principales

potencias durante los últimos 21 años. Estados Unidos encabeza la lista con el 40,1% de las citas totales en 2020, seguido de China (11,8%) y la Unión Europea (10,9%).

CITAS DE CONFERENCIAS DE IA(% del TOTAL MUNDIAL) por ZONA GEOGRAFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.14

PATENTES DE IA


Resumen

El número total de patentes de IA publicadas en el mundo ha aumentado de forma constante en las dos últimas décadas, pasando de 21.806 en el año 2000 a más de 4,5 veces o 101.876, en 2019 (Figura 1.1.15a). La proporción de patentes de IA publicadas en el mundo muestra un aumento menor, de alrededor del 2% en 2000 al 2,9% en 2020 (Figura 1.1.15b).

Los datos sobre patentes de IA son incompletos: sólo el 8% del conjunto de datos en 2020 incluye una afiliación nacional o regional. Hay motivos para cuestionar los datos sobre la proporción de publicaciones de patentes de IA por región y zona geográfica, por lo que no se incluyen en el informe principal. Véa el Apéndice para más detalles.

NÚMERO DE PATENTES DE IA PUBLICADAS, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021



5a

PUBLICACIONES EN CONFERENCIAS DE IA (% de TODAS LAS PUBLICACIONES DE CONFERENCIAS) por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.15b

PUBLICACIONES EN ARXIV

Además de las vías tradicionales de publicación de artículos académicos (ya comentadas), los investigadores de IA han adoptado la práctica de publicar sus trabajos (a menudo antes de ser revisadas) en arXiv, un repositorio web de documentos electrónicos. arXiv permite a los investigadores compartir sus hallazgos antes de enviarlos a revistas y conferencias, lo que acelera enormemente el ciclo de descubrimiento y difusión de la información. El número de publicaciones relacionadas con la IA en esta sección incluye documentos en arXiv bajo cs.AI (inteligencia artificial), cs.CL (computación y lenguaje), cs.CV (visión artificial), cs.NE (computación neural y evolutiva), cs.RO (robótica), cs.LG (aprendizaje automático en informática) y stat.ML (aprendizaje automático en estadística).

Por región

El análisis por regiones muestra que, aunque América del Norte sigue liderando la cuota mundial de publicaciones relacionadas con la IA de arXiv, su cuota ha ido disminuyendo: del 41,6% en 2017 al 36,3% en 2020 (figura 1.1.17). Mientras tanto, la cuota de publicaciones en Asia Oriental y el Pacífico ha crecido de forma constante en los últimos cinco años: del 17,3% en 2015 al 26,5% en 2020.

Resumen

En apenas seis años la cantidad de publicaciones relacionadas con la IA en arXiv se multiplicó más de seis veces, desde 5,478 en 2015 hasta 34,736 en 2020 (Figura 1.1.16).

CANTIDAD DE PUBLICACIONES RELACIONADAS CON IA EN ARXIV, 2015-20

Fuente: arXiv, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.16

PUBLICACIONES RELACIONADAS CON IA EN ARXIV (% del TOTAL MUNDIAL) por REGIÓN, 2015-20

Fuente: arXiv, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.17

Por zona geográfica

Aunque el número total de publicaciones relacionadas con la IA en arXiv está aumentando entre las tres principales potencias de la IA, China está alcanzando a Estados Unidos (Figura 1.1.18a

y Figura 1.1.18b). Por otro lado, la proporción de publicaciones de la Unión Europea se ha mantenido prácticamente sin cambios.

NÚMERO de PUBLICACIONES RELACIONADAS CON IA en ARXIV por ZONA GEOGRÁFICA, 2015-20

Fuente: arXiv, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.18a

PUBLICACIONES RELACIONADAS CON IA EN ARXIV (% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2015-20

Fuente: arXiv, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.18b

Por campo de estudio

Entre los seis campos de estudio relacionados con la IA en arXiv, el número de publicaciones en Robótica (cs.RO) y Aprendizaje Automático en informática (cs.LG) son los que más han crecido entre 2015 y 2020, multiplicándose por 11 y por 10, respectivamente (Figura 1.1.19). En 2020, cs.LG y Visión artificial (cs.CV) lideran el número total de publicaciones representando el 32,0% y el 31,7%, respectivamente, de todas las publicaciones relacionadas con la IA en arXiv. Entre 2019 y 2020, las categorías de mayor crecimiento de las siete estudiadas aquí fueron Computación y Lenguaje (cs.CL), en un 35,4%, y cs.RO, en un 35,8%.

Entre los seis campos de estudio relacionados con la IA en arXiv, el número de publicaciones en Robótica (cs.RO) y Aprendizaje Automático en informática (cs. LG) son los que más han crecido entre 2015 y 2020, aumentando 11 veces y 10 veces respectivamente.

NÚMERO DE PUBLICACIONES RELACIONADAS CON IA en ARXIV por CAMPO DE ESTUDIO 2015-20

Fuente: arXiv, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.19

Artículos de aprendizaje profundo en arXiv

Con un mayor acceso a los datos y mejoras significativas en la potencia de cálculo, el campo del aprendizaje profundo (DL) está creciendo a una velocidad vertiginosa. Los investigadores de Nesta utilizaron un algoritmo para identificar los artículos de aprendizaje profundo en arXiv

mediante el análisis de los resúmenes de los artículos en las categorías de Ciencias de la Computación (CS) y Aprendizaje Automático en Estadística (state.ML). La figura 1.1.20 indica que, sólo en los últimos cinco años, el número total de publicaciones sobre DL en arXiv se ha multiplicado casi por seis.

NÚMERO DE PUBLICACIONES DE APRENDIZAJE PROFUNDO en ARXIV, 2010-19

Fuente: arXiv/Nesta, 2020 | Gráfica: Informe AI Index 2021




Figura 1.1.20

La asistencia a las conferencias es un indicador del interés general de la industria y el mundo académico por un campo científico. En los últimos 20 años, las conferencias sobre IA han crecido no sólo en tamaño, sino también en número y prestigio. Esta sección presenta datos sobre las tendencias de asistencia y presentación de trabajos en las principales conferencias de IA.

1.2 CONFERENCIAS

ASISTENCIA A LAS CONFERENCIAS

El año pasado se produjo un aumento significativo de los niveles de participación en las conferencias sobre IA, ya que la mayoría se ofrecieron a través de un formato virtual. Sólo la 34ª Conferencia de la Asociación para el Avance de la Inteligencia Artificial (AAAI) se celebró en persona en febrero de 2020.

Los organizadores de la conferencia informaron que el formato virtual permitió una mayor asistencia de investigadores de todo el mundo, aunque las cifras exactas de asistencia son difíciles de medir.

Debido a la naturaleza atípica de los datos de asistencia a las conferencias de 2020, las 11 principales conferencias de IA de 2019 se han dividido en dos categorías basadas en los datos de asistencia de 2019: grandes conferencias de IA con más de 3.000 asistentes y pequeñas conferencias de IA con menos de 3.000 asistentes. La figura 1.2.1 muestra que en 2020, el número total de asistentes en nueve conferencias casi se duplicó⁵. En particular, la Conferencia Internacional sobre Robots Inteligentes y Sistemas Inteligentes (IROS) amplió la conferencia virtual para permitir a los usuarios ver los eventos hasta tres meses, lo que explica el elevado número de asistentes. Como la Conferencia Internacional Conjunta sobre Inteligencia Artificial (IJCAI) se celebró en 2019 y enero de 2021 -pero no en 2020- no aparece en los gráficos.

Los organizadores de las conferencias informaron que el formato virtual permitió una mayor asistencia de investigadores de todo el mundo, aunque las cifras exactas de asistencia son difíciles de medir.

⁵ Para la conferencia de la AAMAS, la asistencia en 2020 se basa en el número de usuarios in situ comunicados por la plataforma que grabó las charlas y gestionó la conferencia en línea; para la conferencia de la KR, la asistencia en 2020 se basa en el número de inscripciones; para la conferencia de la ICPAS, la asistencia de 450 en 2020 es una estimación, ya que algunos participantes pueden haber utilizado cuentas anónimas de Zoom.

ASISTENCIA a GRANDES CONFERENCIAS DE IA, 2010-20

Fuente: Datos de conferencias | Gráfica: Informe AI Index 2021




Figura 1.2.1

ASISTENCIA a PEQUEÑAS CONFERENCIAS DE IA, 2010-20

Fuente: Datos de conferencias | Gráfica: Informe AI Index 2021




Figura 1.2.2

Representación corporativa en conferencias de investigación en IA

Investigadores de la Universidad Tecnológica de Virginia y de la Escuela de Negocios Ivey de la Universidad Occidental descubrieron que las grandes empresas tecnológicas han aumentado su participación en las principales conferencias sobre IA. En su artículo, titulado “The De-Democratization of AI: Deep Learning and the Compute Divide in Artificial Intelligence Research” (La desdemocratización de la inteligencia artificial: el aprendizaje profundo y la brecha informática en la investigación de la inteligencia artificial), los investigadores utilizan la proporción de ponencias afiliadas a empresas a lo largo del tiempo en las conferencias de inteligencia artificial para ilustrar el aumento de la presencia de las empresas en la

investigación de la inteligencia artificial. Sostienen que la distribución desigual de la potencia de cálculo en el mundo académico, a la que se refieren como la “brecha informática”, se suma a la desigualdad en la era del aprendizaje profundo. Las grandes empresas tecnológicas suelen tener más recursos para diseñar productos de IA, pero también tienden a ser menos diversas que las instituciones menos elitistas o más pequeñas. Esto suscita preocupaciones sobre la parcialidad y la equidad dentro de la IA. Las 10 principales conferencias sobre IA que se muestran en la figura 1.2.3 muestran una tendencia al alza en la representación de las empresas, lo que amplía aún más la brecha informática.

PORCENTAJE de ARTÍCULOS de TI AFILIADOS a empresas en el FORTUNE 500 GLOBAL

Fuente: Ahmed & Wahed, 2020 | Gráficas: Informe AI Index 2021

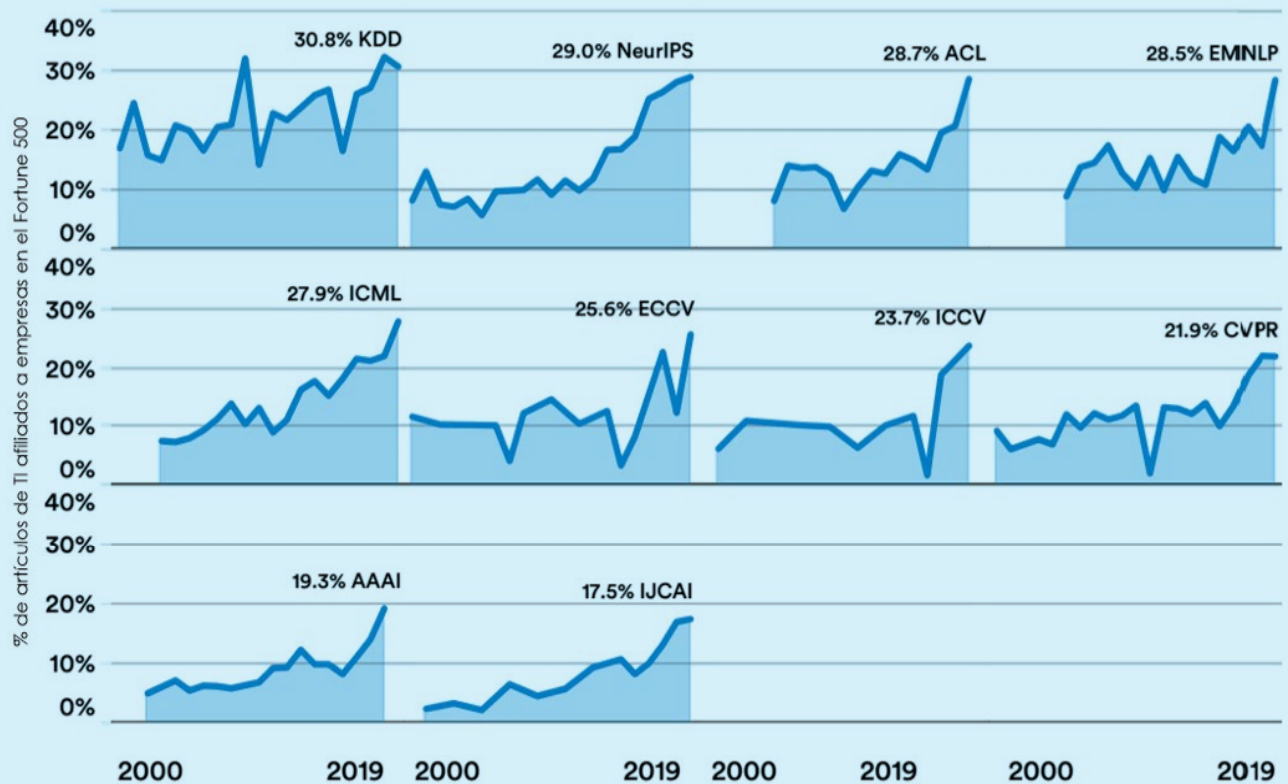


Figura 1.2.3

Una biblioteca de software es una colección de código informático que se utiliza para crear aplicaciones y productos. Las bibliotecas de software específicas de IA más populares -como TensorFlow y PyTorch- ayudan a los desarrolladores a crear sus soluciones de IA de forma rápida y eficiente. Esta sección analiza la popularidad de las bibliotecas de software a través de los datos de GitHub.

1.3 BIBLIOTECAS DE SOFTWARE DE CÓDIGO ABIERTO EN IA

ESTRELLAS GITHUB

GitHub es una plataforma de alojamiento de código que los investigadores y desarrolladores de IA utilizan con frecuencia para subir, comentar y descargar software. Los usuarios de GitHub pueden poner una “estrella” a un proyecto para guardarlo en su lista, expresando así sus intereses y gustos, de forma similar a la función “me gusta” de Twitter y otras plataformas de redes sociales. Como los investigadores de IA suben a GitHub paquetes que mencionan el uso de una biblioteca de código abierto, la función “estrella” de GitHub puede utilizarse para medir la popularidad de varias bibliotecas de código abierto de programación de IA.

La figura 1.3.1 sugiere que TensorFlow (desarrollada por Google y lanzada públicamente en 2017) es la biblioteca de software de IA más popular. La segunda biblioteca más popular en 2020 es Keras (también desarrollada por Google y construida sobre TensorFlow 2.0). Excluyendo TensorFlow, la Figura 1.3.2 muestra que PyTorch (creada por Facebook) es otra biblioteca que se está haciendo cada vez más popular.

TensorFlow (desarrollado por Google y lanzado públicamente en 2017) es la biblioteca de software de IA más popular. La segunda biblioteca más popular en 2020 es Keras (también desarrollada por Google y construida sobre TensorFlow 2.0).

NÚMERO de ESTRELLAS DE GITHUB por BIBLIOTECA DE IA, 2014-20

Fuente: GitHub, 2020 | Gráfica: Informe AI Index 2021




Figura 1.3.1

NÚMERO de ESTRELLAS DE GITHUB por BIBLIOTECA DE IA (excluyendo TENSORFLOW), 2014-20

Fuente: GitHub, 2020 | Gráfica: Informe AI Index 2021




Figura 1.3.2



CAPÍTULO 2: Rendimiento Técnico



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 2:

Vista previa del capítulo

Resumen	43	Detección y reconocimiento facial	61
Puntos clave del capítulo	44	Prueba de Proveedores de Reconocimiento Facial (FRVT) del Instituto Nacional de Estándares y Tecnología de los Estados Unidos (NIST)	61
VISIÓN ARTIFICIAL	45	2.3 IDIOMA	62
2.1 VISIÓN ARTIFICIAL—IMAGEN	46	Puntos de referencia de comprensión del idioma inglés	62
Clasificación de imágenes	46	SuperGLUE	62
ImageNet	46	SQuAD	63
ImageNet: Exactitud del Top-1	46	Traducción Automática Comercial (MT)	64
ImageNet: Exactitud del Top-5	47	Cantidad de Sistemas de Traducción Automática Disponibles	64
ImageNet: Duración del entrenamiento	48	GPT-3	65
ImageNet: Costos de entrenamiento	49	2.4 RAZONAMIENTO VERBAL	67
Punto clave: Pruebas más difíciles más allá de ImageNet	50	Visión y razonamiento verbal	67
Generación de imágenes	51	Respuesta a preguntas visuales (VQA)	67
STL-10: Puntuación de la distancia de inicio de Frechet (FID)	51	Razonamiento visual de sentido común (VCR)	68
FID versus vida real	52	2.5 HABLA	69
Detección de Deepfake	53	Reconocimiento del habla	69
Desafío de detección de Deepfake (DFDC)	53	Transcripción del habla: LibriSpeech	69
Estimación de postura humana	54	Reconocimiento del hablante: VoxCeleb	69
Common Objects in Context (COCO): Reto de detección de puntos clave	54	Punto clave: la brecha racial en la tecnología de reconocimiento del habla	71
Common Objects in Context (COCO): Desafío DensePose	55	2.6 RAZONAMIENTO	72
Segmentación semántica	56	Problema de satisfacibilidad booleana	72
Cityscapes	56	Demostración de teoremas automatizada	74
Visión encarnada	57	2.7 SALUD Y BIOLOGÍA	76
2.2 VISIÓN ARTIFICIAL—VÍDEO	58	Síntesis Molecular	76
Reconocimiento de actividades	58	Exactitud de pruebas para la planificación de la síntesis química avanzada	76
ActivityNet	58	COVID-19 y el descubrimiento de fármacos	77
ActivityNet: localización de actividades en un intervalo de tiempo	58	AlphaFold y el plegado de proteínas	78
ActivityNet: las actividades más difíciles	59		
Detección de objetos	60		
You Only Look Once (YOLO)	60		

ACCESO A LOS DATOS

PUNTOS DESTACADOS POR LOS EXPERTOS 79

Resumen

Este capítulo destaca los avances técnicos en varios subcampos de la IA, como la visión artificial, el lenguaje, el habla, el aprendizaje de conceptos y la demostración de teoremas. Utiliza una combinación de mediciones cuantitativas, como los puntos de referencia comunes y los retos de los premios, y de conocimientos cualitativos de los artículos académicos para mostrar los avances técnicos de vanguardia en la IA.

Aunque los avances tecnológicos permiten que los sistemas de IA se desplieguen más amplia y fácilmente que nunca, también crece la preocupación por el uso de la IA, sobre todo en lo que respecta a cuestiones como el sesgo algorítmico. La aparición de nuevas capacidades de IA, como la capacidad de sintetizar imágenes y vídeos, también plantea retos éticos.

PUNTOS CLAVE DEL CAPÍTULO

- **Todo es generativo:** : los sistemas de IA pueden ahora componer texto, audio e imágenes con un nivel suficientemente alto como para que a los humanos les cueste distinguir entre resultados sintéticos y no sintéticos en algunas aplicaciones limitadas de la tecnología. Esto promete generar una tremenda gama de aplicaciones de la IA para fines tanto socialmente útiles como menos útiles. También hace que los investigadores inviertan en tecnologías para detectar modelos generativos; los datos del DeepFake Detection Challenge indican lo bien que los ordenadores pueden distinguir entre diferentes resultados.
- **La industrialización de la visión artificial:** La visión artificial ha experimentado un inmenso progreso en la última década, principalmente debido al uso de técnicas de aprendizaje automático (específicamente el aprendizaje profundo). Los nuevos datos muestran que la visión artificial se está industrializando: El rendimiento está empezando a aplanarse en algunos de los mayores puntos de referencia, lo que sugiere que la comunidad necesita desarrollar y acordar otros más difíciles que pongan a prueba el rendimiento. Mientras tanto, las empresas invierten cada vez más recursos informáticos para entrenar los sistemas de visión artificial a un ritmo más rápido que nunca. Por otra parte, las tecnologías que se utilizan en los sistemas desplegados -como los frameworks de detección de objetos para el análisis de fotogramas de vídeos- están madurando rápidamente, lo que indica un mayor despliegue de la IA.
- **El procesamiento del lenguaje natural supera sus métricas de evaluación:** Los rápidos avances en NLP han dado lugar a sistemas de IA con capacidades lingüísticas significativamente mejoradas que han empezado a tener un impacto económico significativo en el mundo. Tanto Google como Microsoft han implantado el modelo lingüístico BERT en sus motores de búsqueda, mientras que otros grandes modelos lingüísticos han sido desarrollados por empresas que van desde Microsoft hasta OpenAI. El progreso del NLP ha sido tan rápido que los avances técnicos han empezado a superar los puntos de referencia para probarlos. Esto puede verse en la rápida aparición de sistemas que obtienen un rendimiento de nivel humano en SuperGLUE, una suite de evaluación del NLP desarrollada en respuesta a los anteriores avances del NLP que superan las capacidades evaluadas por GLUE.
- **Nuevos análisis sobre el razonamiento:** La mayoría de las mediciones de problemas técnicos muestran, para cada momento, el rendimiento del mejor sistema de ese momento en un benchmark fijo. Los nuevos análisis desarrollados para el Índice de Inteligencia Artificial ofrecen métricas que permiten un benchmark evolutivo y la atribución a los sistemas individuales de un crédito por una parte del rendimiento global de un grupo de sistemas a lo largo del tiempo. Estos se aplican a dos problemas de razonamiento simbólico, la demostración automatizada de teoremas y la satisfacción de fórmulas booleanas
- **El aprendizaje automático está cambiando las reglas del juego en la sanidad y la biología:** El panorama de las industrias de la salud y la biología ha evolucionado sustancialmente con la adopción del aprendizaje automático. AlphaFold, de DeepMind, aplicó una técnica de aprendizaje profundo para lograr un avance significativo en el desafío biológico del plegado de proteínas, que lleva décadas. Los científicos utilizan modelos de ML para aprender representaciones de moléculas químicas para una planificación más eficaz de la síntesis química. PostEra, una startup de IA, utilizó técnicas basadas en el ML para acelerar el descubrimiento de medicamentos relacionados con el COVID durante la pandemia.

Visión artificial

Introducido en la década de 1960, el campo de la visión artificial ha experimentado un progreso significativo y, en los últimos años, ha comenzado a alcanzar niveles de rendimiento humano en algunas tareas visuales restringidas. Las tareas de la visión artificial son el reconocimiento de objetos, la estimación de la postura y la segmentación semántica. La maduración de la tecnología de la visión artificial ha abierto un abanico de aplicaciones: coches autónomos, análisis de imágenes médicas, aplicaciones de consumo (por ejemplo, Google Photos), aplicaciones de seguridad (por ejemplo, vigilancia, análisis de imágenes por satélite), aplicaciones industriales (por ejemplo, detección de piezas defectuosas en la fabricación y el montaje), y otras.

2.1 VISIÓN ARTIFICIAL—IMAGEN

CLASIFICACIÓN DE IMÁGENES

En la década de 2010, el campo del reconocimiento y la clasificación de imágenes comenzó a pasar de las técnicas clásicas de IA a las basadas en el aprendizaje automático y, en concreto, el aprendizaje profundo. Desde entonces, el reconocimiento de imágenes ha pasado de ser una tecnología costosa y de dominio específico a ser una tecnología más asequible y aplicable a más áreas, principalmente debido a los avances en la tecnología subyacente (algoritmos, hardware de computación y la utilización de conjuntos de datos más grandes).

ImageNet

Creada por informáticos de la Universidad de Stanford y la Universidad de Princeton en 2009, [ImageNet](#) es un conjunto de datos de más de 14 millones de imágenes de 200 clases que amplía y mejora los datos disponibles para que los investigadores entrenen algoritmos de IA. En 2012, investigadores de la Universidad de Toronto utilizaron técnicas basadas en el aprendizaje profundo para establecer un nuevo estado del arte en el Desafío de Reconocimiento Visual a Gran Escala de ImageNet.

Desde entonces, las técnicas de aprendizaje profundo han dominado las tablas de clasificación de los concursos: varias técnicas ampliamente utilizadas han debutado en las entradas del concurso de ImageNet. En 2015, un equipo de Microsoft Research dijo que había superado el rendimiento del nivel humano en la tarea de clasificación de imágenes¹ mediante el uso de “redes residuales”, una innovación que posteriormente proliferó en otros sistemas de IA. Incluso después de la finalización del concurso en 2017, los investigadores siguen utilizando el conjunto de datos de ImageNet para probar y desarrollar aplicaciones de visión artificial.

La tarea de clasificación de imágenes del Desafío ImageNet pide a las máquinas que asignen una etiqueta de clase a una imagen basándose en el objeto principal de la misma. Los siguientes gráficos exploran la evolución de los sistemas ImageNet de mayor rendimiento a lo largo del tiempo, así como el modo en que los avances algorítmicos y de infraestructura han permitido a los

El reconocimiento de imágenes ha pasado de ser una tecnología costosa y específica para un campo determinado, a ser una tecnología más asequible y aplicable a más áreas. que es más asequible y aplicable en un espectro más amplio, sobre todo gracias a los avances en la tecnología subyacente.

investigadores aumentar la eficiencia del entrenamiento de los sistemas de reconocimiento de imágenes y reducir el tiempo absoluto que se tarda en entrenar los de mayor rendimiento.

ImageNet: Precisión en el top-1

La exactitud Top-1 evalúa la capacidad de un sistema de IA para asignar la etiqueta correcta a una imagen, concretamente si su predicción más probable (de entre todas las etiquetas posibles) coincide con la etiqueta objetivo. En los últimos años, los investigadores han empezado a centrarse en mejorar el rendimiento de ImageNet mediante el entrenamiento previo de sus sistemas con datos de entrenamiento adicionales, por ejemplo, fotos de Instagram u otras fuentes de redes sociales. El entrenamiento previo con estos conjuntos de datos les permite utilizar los datos de ImageNet de forma más eficaz, lo que mejora aún más el rendimiento.

La figura 2.1.1 muestra que los sistemas recientes con datos de entrenamiento adicionales cometen 1 error de cada 10 intentos en la exactitud top-1, frente a 4 errores de cada 10 intentos en diciembre de 2012.

El modelo del equipo de Google Brain alcanzó un 90,2% de exactitud en el top-1 en enero de 2021.

¹ Aunque vale la pena señalar que la línea de base humana para esta métrica proviene de un solo estudiante de posgrado de Stanford que realizó aproximadamente la misma prueba que los sistemas de IA.

RETO IMAGENET: PRECISIÓN DEL TOP-1

Fuente: Papers with Code, 2020; AI Index, 2021 | Gráfica: Informe AI Index 2021




Figura 2.1.1

ImageNet: precisión en el top-5

La exactitud en el top-5 evalúa si la etiqueta correcta está presente en al menos en las cinco primeras predicciones del clasificador. La figura 2.1.2 muestra que la tasa de error ha mejorado de alrededor del 85% en 2013 a casi el 99% en 2020.²

RETO IMAGENET: PRECISIÓN DEL TOP-5

Fuente: Papers with Code, 2020; AI Index, 2021 | Gráfica: Informe AI Index 2021




Figura 2.1.2

² Nota: Para los datos sobre el error humano, se mostraron 500 imágenes a un humano y luego se le pidió que anotara 1.500 imágenes de prueba; su tasa de error fue del 5,1% para la clasificación Top-5. Se trata de una referencia muy aproximada, pero nos da una idea del rendimiento humano en esta tarea.

ImageNet: Duración del Entrenamiento

Además de medir la mejora bruta de la exactitud a lo largo del tiempo, es útil evaluar el tiempo que se tarda en entrenar los clasificadores de imágenes en ImageNet hasta alcanzar un nivel de rendimiento estándar, ya que arroja luz sobre los avances de la infraestructura informática subyacente para el entrenamiento de la IA a gran escala.

Es importante medirlo porque cuanto más rápido se pueda entrenar un sistema, más rápido se podrá evaluar y actualizar con nuevos datos. Por lo tanto, cuanto más rápido se puedan entrenar los sistemas ImageNet, más productivas serán las organizaciones a la hora de desarrollar e implantar sistemas de IA. Imagine la diferencia entre esperar unos segundos a que se entrene un sistema o esperar unas horas, y lo que esa diferencia significa para el tipo y el volumen de ideas que exploran los investigadores y cuán atrevidos pueden ser.

A continuación se presentan los resultados de MLPerf, un concurso organizado por la MLCommons, organización que desafía a los participantes a entrenar una red ImageNet utilizando una arquitectura común (red residual), y luego clasifica los sistemas según el tiempo absoluto de “reloj de pared” que les lleva entrenar un sistema.

Como se muestra en la figura 2.1.3, el tiempo de entrenamiento en ImageNet ha descendido de 6,2 minutos (diciembre de 2018) a 47 segundos (julio de 2020). Al mismo tiempo, la cantidad de hardware utilizado para lograr estos resultados ha aumentado drásticamente; los sistemas de vanguardia han estado dominados por el uso de chips “aceleradores”, comenzando con las GPU en los resultados de 2018, y pasando a las TPU de Google para los mejores resultados de su clase de 2019 y 2020.

Imagine la diferencia entre esperar unos segundos a que se entrene un sistema o esperar unas horas, y lo que esa diferencia significa para el tipo y el volumen de ideas que exploran los investigadores y cuán atrevidos pueden ser.

Distribución del tiempo de entrenamiento: MLPerf no se limita a mostrar el estado de la técnica en cada periodo de competición; también pone a disposición todos los datos que hay detrás de cada ciclo de competición. Esto, a su vez, revela la distribución de los tiempos de entrenamiento para cada periodo (Figura 2.1.3). (Nótese que en cada competición de MLPerf, los competidores suelen presentar múltiples entradas que utilizan diferentes permutaciones de hardware).

La figura 2.1.4 muestra que, en los últimos dos años, los tiempos de entrenamiento se han acortado, al igual que la varianza entre las entradas de MLPerf. Al mismo tiempo, los competidores han empezado a utilizar un número cada vez mayor de chips aceleradores para acelerar los tiempos de entrenamiento. Esto está en consonancia con las tendencias más amplias en el desarrollo de la IA, ya que el entrenamiento a gran escala se entiende mejor, con un mayor grado de mejores prácticas e infraestructuras compartidas.

³ La próxima actualización de MLPerf está planeada para junio de 2021.

HARDWARE del MEJOR SISTEMA

Fuente: MLPerf, 2020 | Gráfica: Informe AI Index 2021




Figura 2.1.3

IMAGENET: DISTRIBUCIÓN DEL TIEMPO DE ENTRENAMIENTO

Fuente: MLPerf, 2020 | Gráfica: Informe AI Index 2021




Figura 2.1.4

ImageNet: costes de entrenamiento

¿Cuánto cuesta entrenar un sistema actual de reconocimiento de imágenes? La respuesta, según las pruebas realizadas por el equipo de DAWNBench de Stanford, es de unos pocos dólares en 2020, lo que supone una reducción de alrededor de 150 veces respecto a los

costes de 2017 (figura 2.1.5). Para ponerlo en perspectiva, lo que a un participante le costaba unos 1.100 dólares en octubre de 2017 ahora le cuesta unos 7,43 dólares. Esto representa un progreso en el diseño de algoritmos, así como un descenso en los costes de los recursos de computación en la nube.

IMAGENET: COSTE DE ENTRENAMIENTO (HASTA UN 93% DE EXACTITUD)

Fuente: DAWNbench, 2020 | Fuente: Informe AI Index 2021




Figura 2.1.5

Pruebas más difíciles más allá de ImageNet

A pesar de los avances en el rendimiento de ImageNet, los actuales sistemas de visión artificial siguen sin ser perfectos. Para estudiar mejor sus limitaciones, en los últimos años los investigadores han empezado a desarrollar puntos de referencia de clasificación de imágenes más exigentes. Sin embargo, dado que ImageNet ya es un gran conjunto de datos que requiere una cantidad no trivial de recursos para su uso, no tiene sentido, intuitivamente, ampliar simplemente la resolución de las imágenes en ImageNet o el tamaño absoluto del conjunto de datos, ya que cualquiera de estas acciones aumentaría aún más el coste para los investigadores a la hora de entrenar los sistemas en ImageNet. En su lugar, la gente ha tratado de encontrar nuevas formas de probar la solidez de los clasificadores de imágenes creando conjuntos de datos personalizados, muchos de los cuales son compatibles con ImageNet (y suelen ser más pequeños). Entre ellos se encuentran:

IMAGENET ADVERSARIAL:

Se trata de un conjunto de datos de imágenes similares a las que se encuentran en ImageNet pero que incorporan factores de confusión naturales (por ejemplo, una mariposa sentada en una alfombra con una textura similar a la de la mariposa), e imágenes que son clasificadas erróneamente de forma persistente por los sistemas actuales. Estas imágenes “provocan errores de clasificación constantes debido a las complicaciones de la escena que se encuentran en la larga cola de las configuraciones y por la explotación de los puntos ciegos del clasificador”, según los investigadores. Por lo tanto, avanzar en ImageNet Adversarial podría mejorar la capacidad de generalización de los modelos.

IMAGENET-C:

Se trata de un conjunto de datos de imágenes comunes de ImageNet a las que se aplican 75 corrupciones visuales (por ejemplo, cambios de brillo, contraste, pixelaciones, efectos de niebla, etc.). Al probar los sistemas contra esto, los investigadores pueden proporcionar aún más información sobre la capacidad de generalización de estos modelos.

IMAGENET-RENDITION:

Para probar la generalización, se comprueba hasta qué punto los modelos entrenados en ImageNet pueden categorizar 30.000 ilustraciones de 200 clases de ImageNet. Dado que ImageNet está diseñada para construirse a partir de fotos, la generalización aquí indica que los sistemas han aprendido algo más sutil sobre lo que están tratando de clasificar, porque son capaces de “entender” la relación entre las ilustraciones y las imágenes fotografiadas con las que han sido entrenados.

¿Cuál es el calendario de seguimiento de estos datos? Como estos puntos de referencia son relativamente nuevos, el plan es esperar un par de años para que la comunidad ponga a prueba una serie de sistemas frente a ellos, lo que generará la información necesaria para hacer gráficos de seguimiento del progreso a lo largo del tiempo.

GENERACIÓN DE IMÁGENES

La generación de imágenes es la tarea de generar imágenes que no se distinguen de las imágenes “reales”.

Los sistemas de generación de imágenes tienen una gran variedad de usos, que van desde el aumento de las capacidades de búsqueda (es más fácil buscar una imagen específica si se pueden generar otras imágenes como ella) hasta servir de ayuda para otros usos generativos (por ejemplo, la edición de imágenes, la creación de contenidos para fines específicos, la generación de múltiples variaciones de una sola imagen para ayudar a los diseñadores a hacer una lluvia de ideas, etc.).

En los últimos años, los avances en la generación de imágenes se han acelerado como consecuencia de la continua mejora de los algoritmos basados en el aprendizaje profundo, así como del uso de una mayor computación y de conjuntos de datos más grandes.

STL-10: Puntuación de Distancia Inception Fréchet

Una forma de medir el progreso en la generación de imágenes es a través de una técnica llamada Distancia Inception Fréchet (FID), que se correlaciona aproximadamente con la diferencia entre cómo un determinado sistema de IA “piensa” sobre una imagen sintética frente a una imagen real, donde una imagen real tiene una puntuación de 0 y las imágenes sintéticas que se parecen tienen puntuaciones que se acercan a 0.

La figura 2.1.6 muestra el progreso de los modelos generativos en los últimos dos años en la generación de imágenes sintéticas convincentes en el conjunto de datos STL-10, diseñado para probar la eficacia de los sistemas en la generación de imágenes y la obtención de otra información sobre ellas.

STL-10: DISTANCIA INCEPTION FRÉCHET (FID)

Fuente: Papers with Code, 2020 | Gráfica: Informe AI Index 2021




Figura 2.1.6

FID versus la vida real

La FID tiene inconvenientes como técnica de evaluación: en concreto, mide el progreso en la generación de imágenes mediante métricas cuantitativas que utilizan datos del propio modelo, en lugar de otras técnicas de evaluación. Otro enfoque consiste en utilizar equipos humanos para evaluar los resultados de estos modelos; por ejemplo, el método Human eYe Perceptual Evaluation (HYPE) intenta juzgar la calidad de la imagen mostrando imágenes generadas sintéticamente a personas y utilizando sus calificaciones cualitativas para dirigir la metodología de evaluación. Este método es más caro y lento que las evaluaciones típicas, pero puede ser más importante a medida que los modelos generativos mejoren.

Ejemplos cualitativos: Para hacerse una idea del progreso, usted puede observar la evolución de la calidad de las imágenes generadas sintéticamente a lo largo del tiempo. En la figura 2.1.7 se pueden ver los mejores ejemplos de imágenes sintéticas de rostros humanos, ordenados a lo largo del tiempo. En 2018, el rendimiento de esta tarea ha llegado a ser lo suficientemente bueno como para que los seres humanos no puedan modelar fácilmente un mayor progreso (aunque es posible entrenar sistemas de aprendizaje automático para detectar falsificaciones, cada vez es más difícil). Este es un ejemplo de los recientes avances en este campo y subraya la necesidad de nuevos métodos de evaluación para calibrar los futuros progresos. Además, en los últimos años se ha recurrido a la elaboración de modelos generativos sobre una gama más amplia de categorías que las imágenes de rostros de personas, lo que representa otra forma de probar la generalización.

EVOLUCIÓN DE GAN PARA LA GENERACIÓN DE ROSTROS

Fuente: Goodfellow y cols., 2014; Radford y cols., 2016; Liu & Tuzel, 2016; Karras y cols., 2018; Karras y cols., 2019; Goodfellow, 2019; Karras y cols., 2020; AI Index, 2021




Figura 2.1.7

DETECCIÓN DE DEEPFAKE

Los avances en la síntesis de imágenes han creado nuevas oportunidades y amenazas. Por ejemplo, en los últimos años, los investigadores han aprovechado los avances en la síntesis de imágenes para crear sistemas de IA que pueden generar imágenes sintéticas de rostros humanos y luego superponer esos rostros a los de otras personas en fotografías o películas. Esta aplicación de la tecnología generativa se llama “deepfake”. Los usos maliciosos de los deepfakes incluyen la desinformación y la creación de pornografía (predominantemente misógina). Para intentar combatirlo, los investigadores están desarrollando tecnologías de detección de deepfakes.

Competición de Detección de Deepfake (DFDC)

Creado en septiembre de 2019 por Facebook, el Deepfake Detection Challenge (DFDC) mide el progreso de la tecnología de detección de deepfakes. Un desafío de dos partes, DFDC pide a los participantes que entrenen y prueben sus modelos a partir de un conjunto de datos público de unos 100.000 clips. Las propuestas se puntúan en función de la pérdida logarítmica, una métrica de clasificación basada en probabilidades. Una pérdida logarítmica menor significa una predicción más precisa de los videos de deepfake. Según la figura 2.1.8, la pérdida de registro se redujo en torno a 0,5 a medida que avanzaba el desafío entre diciembre de 2019 y marzo de 2020.

RETO DE DETECCIÓN DE DEEPFAKE DETECTION: PÉRDIDA DE LOGS

Fuente: Kaggle, 2020 | Gráfica: Informe AI Index 2021




Figura 2.1.8

ESTIMACIÓN DE LA POSTURA HUMANA

La estimación de la postura humana consiste en estimar las posiciones de las partes del cuerpo humano o sus articulaciones (muñecas, codos, etc.) a partir de una sola imagen. La estimación de la postura humana es una capacidad clásica de la IA de propósito general. Los sistemas que son buenos en esta tarea pueden utilizarse para una serie de aplicaciones, como la creación de aplicaciones de realidad aumentada para la industria de la moda, el análisis de los comportamientos extraídos del análisis del cuerpo físico en las multitudes, la vigilancia de las personas en busca de comportamientos específicos, la ayuda en el análisis de eventos deportivos y atléticos en vivo, la asignación de los movimientos de una persona a un avatar virtual, etc.

Common Objects in Context (COCO): Reto de detección de puntos clave

Common Objects in Context (COCO) es un conjunto de datos a gran escala para la detección, segmentación y subtítulos de objetos con 330.000 imágenes y 1,5 millones de instancias de objetos. Su desafío de detección de puntos clave requiere que las máquinas detecten simultáneamente un objeto o una persona y localicen sus puntos clave corporales, es decir, puntos de la imagen que destacan, como los codos, las rodillas y otras articulaciones de una persona. La tarea evalúa los algoritmos basándose en la exactitud media (AP), una métrica que puede utilizarse para medir la exactitud de los detectores de objetos. La figura 2.1.9 muestra que la exactitud de los algoritmos ha mejorado aproximadamente un 33% en los últimos cuatro años, y la última máquina obtuvo un 80,8% de exactitud media.

RETO DE DETECCIÓN DE PUNTOS CLAVE COCO: PRECISIÓN MEDIA

Fuente: Tabla de clasificación de COCO, 2020 | Gráfica: Informe AI Index 2021




Figura 2.1.9

Common Objects in Context (COCO): DensePose Challenge

DensePose, o estimación de la pose humana densa, es la tarea de extraer un modelo de malla 3D de un cuerpo humano a partir de una imagen 2D. Después de abrir un sistema llamado DensePose en 2018, Facebook construyó DensePose-COCO, un conjunto de datos a gran escala de correspondencias de imagen a superficie anotadas en 50.000 imágenes COCO. Desde entonces, DensePose se ha convertido en un conjunto de datos de referencia canónico.

El Desafío DensePose de COCO incluye tareas de detección

simultánea de personas, segmentación de sus cuerpos y estimación de las correspondencias entre los píxeles de la imagen que pertenecen a un cuerpo humano y un modelo 3D de plantilla. La exactitud media se calcula a partir de la métrica de similitud de puntos geodésicos (GPS), una puntuación de correspondencia que mide las distancias geodésicas entre los puntos estimados y la verdadera ubicación de los puntos del cuerpo en la imagen. La exactitud ha crecido del 56 % en 2018 al 72 % en 2019 (Figura 2.1.10).

RETO COCO DENSEPOSE: PRECISIÓN MEDIA

Fuente: arXiv & CodaLab, 2020 | Gráfica: Informe AI Index 2021




Figura 2.1.10

SEGMENTACIÓN SEMÁNTICA

La segmentación semántica es la tarea de clasificar cada píxel de una imagen con una etiqueta determinada, como persona, gato, etc. Mientras que la clasificación de imágenes trata de asignar una etiqueta a toda la imagen, la segmentación semántica intenta aislar las distintas entidades y objetos de una imagen determinada, lo que permite una identificación más precisa. La segmentación semántica es una tecnología de entrada básica para los coches autónomos (que identifican y aíslan los objetos en las carreteras), el análisis de imágenes y las aplicaciones médicas, entre otras.

Cityscapes

Cityscapes es un conjunto de datos a gran escala de diversas escenas de calles urbanas de 50 ciudades diferentes grabadas durante el día a lo largo de varios meses (durante la primavera, el verano y el otoño) del año. El conjunto de datos contiene 5.000 imágenes con anotaciones de alta calidad a nivel de píxel y 20.000 etiquetadas semanalmente. La comprensión semántica

de la escena, especialmente en el espacio urbano, es crucial para la percepción ambiental de los vehículos autónomos. Cityscapes es útil para entrenar redes neuronales profundas que comprendan el entorno urbano.

Una tarea de Cityscapes que se centra en la segmentación semántica es la tarea de etiquetado semántico a nivel de píxel. Esta tarea requiere un algoritmo para predecir el etiquetado semántico por píxel de la imagen, partiendo una imagen en diferentes categorías, como coches, autobuses, personas, árboles y carreteras. Los participantes son evaluados con base en la métrica de intersección sobre unión (IoU). Una mayor puntuación de IoU significa una mayor exactitud en la segmentación. Entre 2014 y 2020, la media de IoU aumentó un 35% (figura 2.1.11). Se produjo un impulso significativo en el progreso en 2016 y 2017, cuando la gente empezó a utilizar redes residuales en estos sistemas.

RETO CITYSCAPES: TAREA DE IDENTIFICACIÓN SEMÁNTICA A NIVEL DE PÍXELES

Fuente: Papers with Code, 2020 | Gráfica: AI Index Report




Figura 2.1.11

VISIÓN ENCARNADA

Los datos de rendimiento obtenidos hasta ahora muestran que los sistemas de visión artificial han avanzado enormemente en los últimos años.

El reconocimiento de objetos, la segmentación semántica y la estimación de la postura humana, entre otros, han alcanzado niveles de rendimiento significativos. Hay que tener en cuenta que estas tareas visuales son en cierto modo pasivas o incorpóreas. Es decir, pueden operar con imágenes o vídeos tomados por sistemas de cámaras que no son capaces de interactuar físicamente con el entorno. Como consecuencia de la continua mejora de esas tareas pasivas los investigadores han empezado a desarrollar sistemas de IA más avanzados que pueden ser interactivos o encarnados, es decir, sistemas que pueden interactuar físicamente con el entorno en el que operan y modificarlo: por ejemplo, un robot que pueda inspeccionar visualmente un nuevo edificio y navegar por él de forma autónoma, o un robot que pueda aprender a ensamblar piezas viendo demostraciones visuales en lugar de estar programado manualmente para ello.

Los avances en este campo están impulsados actualmente por el desarrollo de sofisticados entornos de simulación, en los que los investigadores pueden desplegar robots en espacios virtuales, simular lo que verían y captarían sus cámaras y desarrollar algoritmos de IA para la navegación, la búsqueda de objetos y su agarre, entre otras tareas interactivas. Debido a la naturaleza relativamente incipiente de este campo, hay pocas métricas estandarizadas para medir el progreso. En su lugar, a continuación se presentan brevemente algunos de los simuladores disponibles, su año de lanzamiento y alguna característica significativa adicional.

- **Thor** (AI2, 2017) se centra en el razonamiento abstracto secuencial con acciones “mágicas” predefinidas aplicables a los objetos.
- **Gibson** (Stanford, 2018) se centra en la navegación visual en entornos fotorrealistas obtenidos con escáneres 3D.
- **iGibson** (Stanford, 2019) se centra en la interactividad total en grandes escenas realistas mapeadas a partir de casas reales y hechas actuables: navegación y manipulación (conocida en robótica como “copia móvil”).
- **AI Habitat** (Facebook, 2019) se centra en la navegación visual con un énfasis en la ejecución mucho más rápida, permitiendo enfoques más costosos desde el punto de vista computacional.
- **ThreeDWorld** (MIT y Stanford, 2020) se centra en entornos fotorrealistas a través de motores de juego, además de añadir la simulación de materiales flexibles, fluidos y sonidos.
- **SEAN-EP** (Yale, 2020) es un entorno de interacción entre humanos y robots con humanos virtuales simulados que permite recoger demostraciones remotas de humanos a través de un navegador web.
- **Robosuite** (Stanford y UT Austin, 2020) es un marco de simulación modular y un benchmark para el aprendizaje de robots.

El análisis de vídeo es la tarea de hacer inferencias sobre fotogramas de imágenes secuenciales, a veces con la inclusión de una fuente de audio. Aunque muchas tareas de la IA se basan en inferencias de una sola imagen, cada vez hay más aplicaciones que requieren que las máquinas de visión artificial razonen sobre los vídeos. Por ejemplo, la identificación de un movimiento de baile específico se beneficia de ver una variedad de fotogramas conectados en una secuencia temporal; lo mismo ocurre al hacer inferencias sobre un individuo visto moviéndose a través de una multitud, o una máquina que lleva a cabo una secuencia de movimientos en el tiempo.

2.2 VISIÓN ARTIFICIAL—VÍDEO

RECONOCIMIENTO DE ACTIVIDAD

La tarea del reconocimiento de actividades consiste en identificar varias actividades a partir de clips de vídeo. Tiene muchas e importantes aplicaciones cotidianas, como la vigilancia mediante cámaras de vídeo y la navegación autónoma de robots. La investigación sobre la comprensión de vídeos sigue centrándose en eventos breves, como los vídeos de unos pocos segundos de duración. La comprensión de vídeos de larga duración está ganando terreno poco a poco.

ActivityNet

Presentado en 2015, ActivityNet es un benchmark de vídeo a gran escala para la comprensión de la actividad humana. Esta referencia pone a prueba la capacidad de los algoritmos para etiquetar y clasificar los comportamientos humanos en los vídeos. Al mejorar el rendimiento en tareas como ActivityNet, los investigadores de IA están desarrollando sistemas que pueden categorizar comportamientos más complejos que los

que puede contener una sola imagen, como la caracterización del comportamiento de los peatones en la transmisión de vídeo de un coche autónomo o el mejor etiquetado de movimientos específicos en eventos deportivos.

ActivityNet: localización de actividades dentro de un intervalo de tiempo

La tarea de localización temporal de acciones en el reto ActivityNet pide a las máquinas que detecten segmentos de tiempo en una secuencia de vídeo de 600 horas, sin recortar, que contenga varias actividades. La evaluación de esta tarea se centra en (1) la localización: lo bien que puede el sistema localizar el intervalo con la hora de inicio y la hora de finalización precisas; y (2) el reconocimiento: lo bien que puede el sistema reconocer la actividad y clasificarla en la categoría correcta (como lanzar, escalar, pasear al perro, etc.). La figura 2.2.1 muestra que la exactitud media más alta de la tarea de localización temporal de la acción entre las propuestas ha crecido un 140% en los últimos cinco años.

ACTIVITYNET: LOCALIZACIÓN DE ACTIVIDADES DENTRO DE UN INTERVALO DE TIEMPO

Fuente: ActivityNet, 2020 | Gráfica: Informe AI Index 2021




Figura 2.2.1

ActivityNet: las actividades más difíciles

La figura 2.2.2 muestra las actividades más difíciles de la tarea de localización de acciones temporales en 2020 y cómo se compara su exactitud media con el resultado de 2019. Beber café siguió siendo la actividad más difícil en

2020. Piedra-papel-tijera, aunque sigue siendo la décima actividad más difícil, experimentó la mayor mejora entre todas las actividades, aumentando en un 129,2 %: del 6,6 % en 2019 al 15,22 % en 2020.

ACTIVITYNET: ACTIVIDADES MÁS DIFÍCILES, 2019-20

Fuente: ActivityNet, 2020 | Gráfica: Informe AI Index Report 2021




Figura 2.2.2

DETECCIÓN DE OBJETOS

La detección de objetos es la tarea de identificar un objeto determinado en una imagen. A menudo, la clasificación y la detección de imágenes se combinan en los sistemas utilizados.

Una forma de obtener una medida aproximada de la mejora de los sistemas de reconocimiento de objetos implantados es estudiar el avance de los sistemas de detección de objetos más utilizados.

YOU ONLY LOOK ONCE (YOLO)

You Only Look Once (YOLO) es un sistema de código abierto ampliamente utilizado para la detección de objetos, por lo que su progreso se ha incluido en una tarea estándar sobre variantes de YOLO para dar una idea de cómo la investigación

se filtra en herramientas de código abierto ampliamente utilizadas. YOLO ha pasado por múltiples iteraciones desde que se publicó por primera vez en 2015. Con el tiempo, YOLO se ha optimizado en función de dos restricciones: el rendimiento y la latencia de inferencia, como se muestra en la figura 2.2.3. Lo que esto significa, en concreto, es que al medir YOLO, se puede medir el avance de los sistemas que podrían no tener el mejor rendimiento absoluto, pero que están diseñados en torno a las necesidades del mundo real, como la inferencia de baja latencia sobre flujos de vídeo. Por tanto, es posible que los sistemas YOLO no tengan siempre el mejor rendimiento absoluto tal y como se define en la literatura de investigación, pero representarán un buen rendimiento cuando se enfrenten a compensaciones como el tiempo de inferencia.

YOU ONLY LOOK ONCE (YOLO): PRECISIÓN MEDIA

Fuente: Redmon & Farhadi (2016 & 2018), Bochkovskiy y cols. (2020), Long y cols. (2020) | Gráfica: Informe AI Index 2021




Figura 2.2.3

DETECCIÓN Y RECONOCIMIENTO FACIAL

La detección y el reconocimiento facial es uno de los casos de uso de la IA que cuenta con un mercado comercial considerable y ha suscitado un gran interés por parte de gobiernos y ejércitos. Por lo tanto, el progreso en esta categoría nos da una idea del ritmo de avance en partes económicamente importantes del desarrollo de la IA.

Prueba de reconocimiento facial (FRVT) del Instituto Nacional de Normas y Tecnología (NIST)

Las pruebas de reconocimiento facial (FRVT) del Instituto Nacional de Normas y Tecnología de los Estados Unidos (NIST) proporcionan evaluaciones independientes de tecnologías de reconocimiento facial disponibles en el mercado y de prototipos. Los FRVT miden el rendimiento de las tecnologías de reconocimiento facial automatizadas utilizadas para una amplia gama de tareas civiles y gubernamentales

(principalmente en el ámbito de la aplicación de la ley y la seguridad nacional), incluida la verificación de fotos de visados, imágenes de fichas policiales e imágenes de abuso infantil.

La figura 2.2.4 muestra los resultados de los algoritmos 1:1 de mayor rendimiento medidos en función de la tasa de falsos no coincidentes (FNMR) en varios conjuntos de datos diferentes. El FNMR se refiere a la tasa de fallos del algoritmo al intentar emparejar la imagen con el individuo. Las tecnologías de reconocimiento facial en fotos de prontuario y de visado son las que más han mejorado en los últimos cuatro años, pasando de tasas de error cercanas al 50% a una fracción de porcentaje en 2020.⁴

NIST FRVT 1:1 PRECISIÓN DE VERIFICACIÓN por CONJUNTO DE DATOS, 2017-20

Fuente: Instituto Nacional de Normas y Tecnología de los Estados Unidos (NIST), 2020 | Gráfica: Informe AI Index 2021




Figura 2.2.4

⁴ Puede ver detalles y ejemplos de varios conjuntos de datos en las actualizaciones periódicas de los informes de verificación [FRVT 1:1](#).

El procesamiento del lenguaje natural (PLN) consiste en enseñar a las máquinas a interpretar, clasificar, manipular y generar lenguaje. Desde el uso inicial de reglas manuscritas y técnicas estadísticas hasta la reciente adopción de modelos generativos y aprendizaje profundo, el PLN se ha convertido en una parte integral de nuestras vidas, con aplicaciones en la generación de textos, la traducción automática, la respuesta a preguntas y otras tareas.

2.3 IDIOMA

En los últimos años, los avances en la tecnología de procesamiento del lenguaje natural han provocado cambios significativos en los sistemas a gran escala a los que acceden miles de millones de personas. Por ejemplo, a finales de 2019, Google comenzó a desplegar su algoritmo BERT en su motor de búsqueda, lo que llevó a una mejora significativa en las métricas de calidad internas, de acuerdo a la compañía. Microsoft siguió su ejemplo, anunciando más tarde en 2019 que estaba utilizando BERT para aumentar su motor de búsqueda Bing.

PUNTOS DE REFERENCIA DE COMPRENSIÓN DEL INGLÉS SuperGLUE

Lanzado en mayo de 2019, SuperGLUE es un marco de referencia de una sola métrica que evalúa el rendimiento de un modelo en una serie de tareas de comprensión del lenguaje en conjuntos de datos

establecidos. SuperGLUE reemplazó el anterior benchmark GLUE (introducido en 2018) con tareas más desafiantes y diversas.

La puntuación de SuperGLUE se calcula promediando las puntuaciones en un conjunto de tareas. El modelo DeBERTa de Microsoft ahora encabeza la tabla de clasificación de SuperGLUE, con una puntuación de 90,3, en comparación con una puntuación media de 89,8 para las “líneas de base humanas” de SuperGLUE. Esto no significa que los sistemas de IA hayan

superado el rendimiento humano en todas las tareas de SuperGLUE, pero sí significa que el rendimiento medio de todo el conjunto ha superado el de una línea base humana. El rápido ritmo de progreso (Figura 2.3.1) sugiere que SuperGLUE puede necesitar ser más desafiante o ser reemplazado por pruebas más difíciles en el futuro, como ocurrió cuando SuperGLUE reemplazó a GLUE.

PUNTO DE REFERENCIA SUPERGLUE

Fuente: Tabla de clasificación SuperGLUE, 2020 | Gráfica: Informe AI Index 2021




Figura 2.3.1

SQuAD

El Conjunto de Datos de Respuestas a Preguntas de Stanford, o SQuAD, es una referencia de comprensión lectora que mide la exactitud con la que un modelo de NLP puede proporcionar respuestas breves a una serie de preguntas relacionadas con un artículo de texto breve. Los creadores de la prueba SQuAD establecieron un benchmark de rendimiento humano haciendo que un grupo de personas leyera artículos de Wikipedia sobre una variedad de temas y luego respondiera a preguntas de opción múltiple sobre esos artículos. A los modelos se les asigna la misma tarea y se les evalúa en función de la puntuación F1, es decir, la superposición media entre la predicción del modelo y la respuesta correcta. Las puntuaciones más altas indican un mejor rendimiento.

Dos años después de la introducción del SQuAD original, en 2016, se desarrolló SQuAD 2.0 una vez que la prueba de

referencia inicial reveló rendimientos cada vez más rápidos por parte de los participantes (reflejando la tendencia observada en GLUE y SuperGLUE). SQuAD 2.0 combina las 100.000 preguntas de SQuAD 1.1 con más de 50.000 preguntas sin respuesta escritas por los crowdworkers para que parezcan preguntas con respuesta. El objetivo es comprobar la capacidad de los sistemas para responder a las preguntas y determinar cuándo los sistemas saben que no existe ninguna respuesta.

Como muestra la figura 2.3.2, la puntuación F1 de SQuAD 1.1 mejoró desde 67,75 en agosto de 2016 hasta superar el rendimiento humano de 91,22 en septiembre de 2018 -un periodo de 25 meses-, mientras que SQuAD 2.0 solo tardó 10 meses en superar el rendimiento humano (desde 66,3 en mayo de 2018 hasta 89,47 en marzo de 2019). En 2020, los modelos más avanzados de SQuAD 1.1 y SQuAD 2.0 alcanzaron las puntuaciones F1 de 95,38 y 93,01, respectivamente.

PUNTAJES F1 de SQuAD 1.1 y SQuAD 2.0

Fuente: CodaLab Worksheets, 2020 | Gráfica: Informe AI Index 2021




Figura 2.3.2

TRADUCCIÓN AUTOMÁTICA COMERCIAL (MT)

La traducción automática, el subcampo de la lingüística computacional que investiga el uso de software para traducir texto o voz de un idioma a otro, ha experimentado una mejora significativa gracias a los avances en el aprendizaje automático. Los recientes avances en la MT han llevado a los desarrolladores a cambiar los enfoques simbólicos por otros que utilizan enfoques estadísticos y de aprendizaje profundo.

Cantidad de sistemas de MT disponibles en el mercado

La tendencia en el número de sistemas disponibles comercialmente habla del importante crecimiento de la tecnología de traducción automática comercial y de su rápida adopción en el mercado comercial. En 2020, el número de sistemas de MT independientes en la nube disponibles comercialmente con modelos pre-entrenados aumentó a 28, frente a los 8 de 2017, según Intento, una startup que evalúa los servicios de MT disponibles comercialmente (figura 2.3.3).

NÚMERO DE SERVICIOS INDEPENDIENTES DE TRADUCCIÓN AUTOMÁTICA

Fuente: Intento, 2020 | Chart: 2021 AI Index Report




Figura 2.3.3

GPT-3

En julio de 2020, OpenAI presentó GPT-3, el mayor modelo de lenguaje denso conocido. GPT-3 tiene 175.000 millones de parámetros y fue entrenado con 570 gigabytes de texto. A modo de comparación, su predecesor, GPT-2, era más de 100 veces más pequeño, con 1.500 millones de parámetros. Este aumento de escala da lugar a un comportamiento sorprendente: GPT-3 es capaz de realizar tareas para las que no fue entrenado explícitamente con cero o pocos ejemplos de entrenamiento (denominados aprendizaje de cero y pocos intentos, respectivamente). Este comportamiento estaba ausente en el GPT-2, mucho más pequeño.

Además, en algunas tareas (pero no en todas; por ejemplo, SuperGLUE y SQuAD2), GPT-3 supera a los modelos de última

generación que fueron entrenados explícitamente para resolver esas tareas con muchos más ejemplos de entrenamiento.

La figura 2.3.4, adaptada del documento de GPT-3, muestra el impacto de la escala (en términos de parámetros del modelo) en la exactitud de la tarea (cuanto más alta, mejor) en los regímenes de aprendizaje de cero, uno y pocos intentos. Cada punto de la curva corresponde a una exactitud media de rendimiento, agregada a través de 42 puntos de referencia orientados a la exactitud. A medida que aumenta el tamaño del modelo, la exactitud media en todos los regímenes de tareas aumenta en consecuencia. La exactitud del aprendizaje de pocos intentos aumenta más rápidamente con la escala, en comparación con el aprendizaje de cero intentos, lo que sugiere que los modelos grandes pueden funcionar sorprendentemente bien dado un contexto mínimo.

GPT-3: RENDIMIENTO PROMEDIO entre 42 PUNTOS DE REFERENCIA

Fuente: OpenAI (Brown y cols.), 2020 | Gráfica: Informe AI Index 2021




Figura 2.3.4

El hecho de que un solo modelo pueda alcanzar un rendimiento equivalente o cercano al estado del arte en regímenes de datos de entrenamiento limitados es impresionante. Hasta ahora, la mayoría de los modelos se han diseñado para una sola tarea y, por tanto, pueden evaluarse eficazmente con una sola métrica. A la luz de la GPT-3, prevemos nuevos benchmarks diseñados explícitamente para evaluar el rendimiento de los modelos lingüísticos en el aprendizaje de cero a pocos intentos. Esto no será sencillo. Los desarrolladores están encontrando cada vez más capacidades novedosas en los modelos (por ejemplo, la capacidad de generar un sitio web a partir de una descripción de texto) que serán difíciles de definir, y mucho menos de medir el rendimiento. No obstante, el Índice AI se compromete a seguir el rendimiento en este nuevo contexto a medida que evoluciona.

A pesar de sus impresionantes capacidades, el GPT-3 tiene varias deficiencias, muchas de las cuales se describen en el documento original. Por ejemplo, puede generar textos racistas, sexistas o tendenciosos. Además, GPT-3 (y otros modelos lingüísticos) puede generar textos imprevisibles e inexactos. Las técnicas para controlar y “dirigir” esos resultados para que se ajusten mejor a los valores humanos son incipientes pero prometedoras. Además, el entrenamiento de GPT-3 es costoso, lo que significa que sólo un número limitado de organizaciones con abundantes recursos puede permitirse desarrollar e implantar estos modelos. Por último, GPT-3 tiene un número inusualmente grande de usos, desde los chatbots a la generación de código informático o a la búsqueda. Es probable que los futuros usuarios descubran más aplicaciones, tanto beneficiosas como perjudiciales, lo que dificulta la identificación del abanico de posibles usos y la previsión de su impacto en la sociedad.

No obstante, en varias universidades y laboratorios de investigación industrial, entre ellos OpenAI, se está investigando sobre los resultados y usos perjudiciales. Para más detalles, consulte el trabajo de Bender y Gebru y cols. y las actas de un reciente taller del Stanford Institute for Human-Centered Artificial Intelligence (HAI) (en el que participaron investigadores de OpenAI), “Understanding the Capabilities, Limitations, and Societal Impact of Large Language Models”.

El hecho de que un solo modelo pueda alcanzar un rendimiento equivalente o cercano al estado del arte en regímenes de datos de entrenamiento limitados es impresionante. Hasta ahora, la mayoría de los modelos se han diseñado para una sola tarea y, por tanto, pueden evaluarse eficazmente con una sola métrica.

2.4 HABILIDADES DE RAZONAMIENTO LINGÜÍSTICO

VISIÓN Y RAZONAMIENTO VERBAL

El razonamiento visual y verbal es un área de investigación que aborda la capacidad de las máquinas para razonar conjuntamente mediante datos visuales y textuales.

Respuestas a preguntas con apoyo visual (VQA)

El reto VQA, introducido en 2015, requiere que las máquinas proporcionen una respuesta precisa en lenguaje natural, dada una imagen y una pregunta

en lenguaje natural sobre la imagen basada en un conjunto de datos públicos. La figura 2.4.1 muestra que la exactitud ha crecido casi un 40% desde su primera entrega en la Conferencia Internacional de Visión artificial (ICCV) de 2015. La mayor exactitud del reto de 2020 es del 76,4%. Este logro está más cerca de la línea de base humana del 80,8% de exactitud y representa un aumento absoluto del 1,1% en el rendimiento del algoritmo más alto de 2019.

RETO DE RESPUESTAS A PREGUNTAS CON APOYO VISUAL (VQA): EXACTITUD

Fuente: Reto VQA, 2020 | Gráfica: Informe AI Index 2021




Figura 2.4.1

Tarea de razonamiento visual por sentido común (VCR)

La tarea de razonamiento visual por sentido común (VCR) introducida por primera vez en 2018, pide a las máquinas que respondan a una pregunta desafiante sobre una imagen dada y justifique esa respuesta con un razonamiento (mientras que VQA solo solicita una respuesta). El conjunto de datos VCR contiene 290.000 pares de preguntas de opción múltiple, respuestas y razonamientos, así como más de 110.000 imágenes de escenas de películas.

El principal modo de evaluación para la tarea VCR es la

puntuación Q->AR, que requiere que las máquinas elijan primero la respuesta correcta

(A) a una pregunta (Q) entre cuatro opciones de respuesta (Q->A) y, a continuación, seleccionar el razonamiento correcto (R) entre cuatro opciones de razonamiento basadas en la respuesta. Una puntuación más alta es mejor, y el rendimiento humano en esta tarea se mide por una puntuación QA->R de 85. La máquina con mejor rendimiento ha mejorado en la puntuación Q->AR de 44 en 2018 a 70,5 en 2020 (Figura 2.4.2), lo que representa un aumento del 60,2% en el rendimiento con respecto al mejor competidor de 2019.

RAZONAMIENTO VISUAL DE SENTIDO COMÚN (VCR): PUNTAJE Q->AR

Fuente: Tabla de clasificación VCR, 2020 | Gráfica: Informe AI Index 2021




Figura 2.4.2



Un aspecto importante de la investigación en IA es el análisis y la síntesis del habla humana transmitida a través de datos de audio. En los últimos años, los enfoques de aprendizaje automático han mejorado drásticamente el rendimiento en toda una serie de tareas.

2.5 HABLA

RECONOCIMIENTO DEL HABLA

El reconocimiento del habla, o reconocimiento automático del habla (ASR), es el proceso que permite a las máquinas reconocer palabras habladas y convertirlas en texto. Desde que IBM introdujo su primera tecnología de reconocimiento de voz en 1962, la tecnología ha evolucionado con aplicaciones basadas en la voz como

Amazon Alexa, Google Home y Apple Siri son cada vez más frecuentes. La flexibilidad y el poder predictivo de las redes neuronales profundas, en particular, han permitido que el reconocimiento del habla sea más accesible.

Transcripción: LibriSpeech

LibriSpeech es un conjunto de datos, presentado por primera vez en 2015, compuesto por 1.000 horas de habla de audiolibros. Se ha utilizado ampliamente para el desarrollo y la prueba de tecnologías de reconocimiento del habla. En los últimos años, los sistemas de IA basados en redes neuronales han empezado a mejorar drásticamente el rendimiento en LibriSpeech, reduciendo la tasa de error de palabras (WER; el 0% es el rendimiento óptimo) a alrededor del 2% (Figura 2.5.1a y Figura 2.5.1b).

Los desarrolladores pueden probar sus sistemas en LibriSpeech de dos maneras:

- La prueba de limpieza determina la capacidad de sus sistemas para transcribir el habla de un subconjunto de mayor calidad del conjunto de datos de LibriSpeech. Esta prueba da pistas sobre el rendimiento de los sistemas de IA en entornos más controlados.
- La prueba “Otros” determina la capacidad de los sistemas para trabajar con partes de menor calidad del conjunto de datos de LibriSpeech. Esta prueba sugiere el rendimiento de los sistemas de IA en entornos más ruidosos (y quizás más realistas).

Últimamente se han producido avances sustanciales en ambos conjuntos de datos, y en los últimos dos años ha surgido una tendencia importante: La diferencia entre el rendimiento en la prueba de limpieza y en la otra prueba ha empezado a reducirse significativamente para los sistemas fronterizos, pasando de una

diferencia de rendimiento absoluta de más de siete puntos a finales de 2015 a una diferencia de menos de un punto en 2020. Esto revela mejoras espectaculares en la solidez de los sistemas ASR a lo largo del tiempo y sugiere que podríamos estar saturando el rendimiento en LibriSpeech; en otras palabras, es posible que se necesiten pruebas más difíciles.

Reconocimiento del hablante: VoxCeleb

La identificación de hablantes pone a prueba la capacidad de los sistemas de aprendizaje automático para atribuir el habla a una persona concreta. El conjunto de datos VoxCeleb, presentado por primera vez en 2017, contiene más de un millón de expresiones de 6.000 hablantes distintos, y su tarea de identificación de hablantes pone a prueba la tasa de error de los sistemas que intentan atribuir una expresión concreta a un hablante determinado. Una mejor (menor) puntuación en VoxCeleb proporciona un indicador de lo bien que una máquina puede distinguir

una voz entre 6.000. El método de evaluación de VoxCeleb es la Tasa de Igualdad de Errores (EER), una métrica comúnmente utilizada en los sistemas de verificación de identidad. El EER proporciona una medida tanto de la tasa de falsos positivos (asignar una etiqueta incorrectamente) como de la tasa de falsos negativos (no asignar una etiqueta correcta).

En los últimos años, los avances en esta tarea han venido de la mano de sistemas híbridos, es decir, sistemas que fusionan enfoques contemporáneos de aprendizaje profundo con algoritmos más estructurados, desarrollados por la comunidad de procesamiento del habla en general. A partir de 2020, las tasas de error han disminuido de tal manera que los ordenadores tienen una capacidad muy alta (99,4%) para atribuir los enunciados a un hablante determinado (figura 2.5.2)

Aun así, sigue habiendo obstáculos: Estos sistemas tienen dificultades para procesar a hablantes con diferentes acentos y para diferenciar a los hablantes cuando se enfrentan a un gran conjunto de datos (es más difícil identificar a una persona en un conjunto de mil millones de personas que elegir a una persona en el conjunto de entrenamiento de VoxCeleb de 6.000

LIBRISPEECH: TASA DE ERROR POR PALABRA, PRUEBA LIMPIA

Fuente: Papers with Code, 2020 | Gráfica: Informe AI Index 2021




Figura 2.5.1a

LIBRISPEECH: TASA DE ERROR POR PALABRA, OTRA PRUEBA

Fuente: Papers with Code, 2020 | Gráfica: Informe AI Index 2021




Figura 2.5.1b

VOXCELEB: TASA DE ERROR EQUIVALENTE

Fuente: VoxCeleb, 2020 | Gráfica: Informe AI Index 2021




Figura 2.5.2

La Brecha Racial en la Tecnología de Reconocimiento del Habla

Investigadores de la Universidad de Stanford descubrieron que los sistemas de reconocimiento del habla más avanzados mostraban una importante disparidad racial y de género: malinterpretan a los hablantes negros el doble de veces que a los blancos. Este hallazgo se discute en el artículo, titulado “Racial Disparities in Automated Speech” de audio de hablantes blancos y negros, transcritos a partir de entrevistas realizadas a 42 hablantes blancos y 73 negros, a través de los principales servicios de conversión de voz en texto de Amazon, Apple, Google, IBM y Microsoft.

Los resultados sugieren que, por término medio, los sistemas cometen 19 errores cada cien palabras en el caso de los hablantes blancos y 35 en el de los hablantes negros, casi el doble. Además, los sistemas funcionaron especialmente mal en el caso de los hombres negros, con más de 40 errores por cada cien palabras (figura 2.5.3). El desglose por sistemas ASR muestra que las diferencias son similares en todas las empresas (figura 2.5.4). Esta investigación subraya la importancia de abordar el sesgo de las tecnologías de IA y garantizar la equidad a medida que maduran y se despliegan.

PRUEBAS de SERVICIOS LÍDERES DE TRANSCRIPCIÓN DE VOZ por RAZA y GÉNERO, 2019

Fuente: Koenecke y cols., 2020 | Gráfica: Informe AI Index 2021




Figura 2.5.3

PRUEBAS de SERVICIOS LÍDERES DE TRANSCRIPCIÓN DE VOZ por SERVICIO y RAZA, 2019

Fuente: Koenecke y cols., 2020 | Gráfica: Informe AI Index 2021




Figura 2.5.4

Esta sección mide el progreso del razonamiento simbólico (o lógico) en la IA, que es el proceso de sacar conclusiones a partir de conjuntos de suposiciones. Consideramos dos grandes problemas de razonamiento, la Satisfacción Booleana (SAT) y la Prueba de Teoremas Automatizada (ATP). Cada uno de ellos tiene aplicaciones en el mundo real (por ejemplo, diseño de circuitos, programación, verificación de software, etc.) y plantea importantes retos de medición. El análisis SAT muestra cómo asignar el crédito de la mejora global en el campo a los sistemas individuales a lo largo del tiempo. El análisis ATP muestra cómo medir el rendimiento teniendo en cuenta un conjunto de pruebas en evolución.

Todos los análisis que se presentan a continuación son originales de este informe. Lars Kotthoff escribió el texto y realizó el análisis de la sección SAT. Geoff Sutcliffe, Christian Suttner y Raymond Perrault escribieron el texto y realizaron el análisis de la sección ATP. Este trabajo no había sido publicado en el momento de la redacción, por lo que en el Apéndice se incluye una versión más rigurosa desde el punto de vista académico de esta sección (con referencias, detalles más precisos y mayor contexto).

2.6 RAZONAMIENTO

PROBLEMA DE LA SATISFACCIÓN BOOLEANA

Análisis y texto de Lars Kotthoff

El problema SAT considera si existe una asignación de valores a un conjunto de variables booleanas, unidas por conectores lógicos, que haga verdadera la fórmula lógica que representa. Muchos problemas del mundo real, como el diseño de circuitos, la demostración automatizada de teoremas y la programación, pueden representarse y resolverse eficazmente como problemas SAT.

Se examinó el rendimiento de los solucionadores SAT mejor clasificados, la mediana y el último clasificado de cada uno de los últimos cinco años (2016-2020) de la competición SAT, que se ha estado celebrando durante casi 20 años, para medir una instantánea del rendimiento del estado de la técnica. En concreto, se ejecutaron los 15 solucionadores en las 400 instancias SAT de la pista principal de la competición de 2020 y se midió el tiempo (en segundos de CPU) que se tardó en resolver todas las instancias.⁵ Es fundamental que cada solucionador se ejecute en el mismo hardware, de modo que las comparaciones entre años no se vean afectadas por las mejoras en la eficiencia del hardware a lo largo del tiempo.

Mientras que el rendimiento de los mejores solucionadores de 2016 a 2018 no cambió significativamente, las grandes mejoras son evidentes en 2019 y 2020 (Figura 2.6.1). Estas mejoras afectan no solo a los mejores solucionadores, sino también a sus competidores. El rendimiento del solucionador clasificado en la

mediana en 2019 es mejor que el de los solucionadores mejor clasificados en todos los años anteriores, y el rendimiento del solucionador clasificado en la mediana en 2020 está casi a la par con el solucionador mejor clasificado en 2019.

Las mejoras de rendimiento en SAT -y, en general, en los problemas de IA computacional difíciles- provienen principalmente de dos áreas de mejoras algorítmicas: técnicas nuevas e implementaciones más eficientes de las técnicas existentes. Normalmente, las mejoras de rendimiento surgen principalmente de las técnicas novedosas. Sin embargo, las implementaciones más eficientes (que pueden surgir con las mejoras en el rendimiento del hardware a lo largo del tiempo) también pueden aumentar el rendimiento. Por lo tanto, es difícil evaluar si las mejoras de rendimiento provienen principalmente de técnicas novedosas o de implementaciones más eficientes. Para solucionar este problema, se midió el valor temporal de Shapley, que es la contribución de un sistema individual al rendimiento del estado del arte a lo largo del tiempo (véase el Apéndice para más detalles).

La figura 2.6.2 muestra las contribuciones del valor Shapley temporal de cada solucionador para los diferentes años de competición. Obsérvese que las contribuciones de los solucionadores de 2016 son las más elevadas porque no hay un estado del arte anterior con el que compararlos en nuestra evaluación y que su contribución no está descartada.

⁵ Agradecimientos: El Centro de Computación de Investigación Avanzada de la Universidad de Wyoming proporcionó recursos para la recopilación de los datos computacionales. Austin Stephen realizó los experimentos computacionales.

TIEMPO TOTAL para RESOLVER TODAS LAS 400 INSTANCIAS DE CADA SOLUCIÓN y AÑO(MENOS ES MEJOR), 2016-20

Fuente: Kotthoff, 2020 | Gráfica: Informe AI Index 2021




Figura 2.6.1

CONTRIBUCIONES DE SOLUCIONES INDIVIDUALES EN EL VALOR TEMPORAL DE SHAPLEY para cada ESTADO del ARTE EN EL TIEMPO (MÁS ALTO ES MEJOR), 2016-20

Fuente: Kotthoff, 2020 | Gráfica: Informe AI Index 2021




Figura 2.6.2

Según el valor temporal de Shapley, en 2020 el mejor solucionador contribuye significativamente más que los solucionadores de la media y de la cola. El ganador de 2020, Kissat, tiene el valor temporal de Shapley más alto de todos los solucionadores, excluyendo el primer año. Los cambios que incorpora, comparados con los de los solucionadores anteriores, son casi exclusivamente estructuras de datos y algoritmos más eficientes; Kissat demuestra así de forma impresionante el impacto de la buena ingeniería en el rendimiento del estado del arte.

Por el contrario, *smallsat*, el solucionador con el mayor valor temporal de Shapley (pero no el ganador) en 2019, se centra en una heurística mejorada en lugar de una implementación más eficiente. Lo mismo ocurre con *Candy*, el solucionador con el mayor valor temporal de Shapley en 2017, cuya principal novedad es analizar la estructura de una instancia SAT y aplicar una heurística basada en este análisis. Curiosamente, ninguno de los dos solucionadores ocupó el primer puesto en sus respectivos años; ambos fueron superados por versiones del solucionador *Maple*, que sin embargo contribuye menos al estado del arte. Esto indica que las mejoras incrementales aunque no son tan emocionantes, son importantes para un buen rendimiento en la práctica.

Basándonos en nuestro limitado análisis del campo, las técnicas novedosas y las implementaciones más eficientes han hecho contribuciones igualmente importantes al estado del arte en la resolución de SAT. Es tan probable que las mejoras incrementales de los solucionadores establecidos den lugar a un rendimiento superior como las mejoras más sustanciales de los solucionadores sin una larga trayectoria.

DEMOSTRACIÓN AUTOMATIZADA DE TEOREMAS (ATP)

Análisis y texto de Christian Suttner, Geoff Sutcliffe y Raymond Perrault

La demostración automatizada de teoremas (ATP) se refiere al desarrollo y el uso de sistemas que automatizan el razonamiento sólido, o la derivación de conclusiones que se derivan inevitablemente de los hechos. Los sistemas ATP están en el centro de muchas tareas computacionales, incluida la verificación de software. La biblioteca de problemas del TPTP se utilizó para evaluar el rendimiento de los algoritmos ATP desde 1997 hasta 2020 y para medir la fracción de problemas resueltos por cualquier sistema a lo largo del tiempo (véase el Apéndice para más detalles).

El análisis se extiende a todo el TPTP (más de 23.000 problemas) además de cuatro subconjuntos destacados (cada uno de ellos entre 500 y 5.500 problemas) -forma normal de cláusulas (CNF), forma de primer orden (FOF), forma de primer orden tipificada monomórfica (TF0) con aritmética y teoremas de forma de orden superior tipificada monomórfica (TH0)-, todos ellos incluyendo el uso del operador de igualdad.

La figura 2.6.3 muestra que la fracción de problemas resueltos aumenta constantemente, lo que indica un progreso en el campo. El progreso notable de 2008 a 2013 incluye un fuerte avance en los subconjuntos FOF, TF0 y TH0. En FOF, que se ha utilizado en muchos dominios (por ejemplo, matemáticas, conocimiento del mundo real, verificación de software), hubo mejoras significativas en los sistemas *Vampire*, *E* e *iProver*. En TF0 (utilizado principalmente para resolver problemas en matemáticas y ciencias de la computación) y TH0 (útil en temas sutiles y complejos como la filosofía y la lógica), se produjo un rápido progreso inicial a medida que los sistemas desarrollaban técnicas que resolvían problemas de baja dificultad. En 2014-2015, se produjo otro estallido de progreso en TF0, ya que el sistema *Vampire* se volvió capaz de procesar problemas de TF0. Cabe destacar que, desde 2015, el progreso ha continuado, pero se ha ralentizado, sin que haya indicios de avances rápidos o de grandes progresos en los últimos años.

PORCENTAJE DE PROBLEMAS RESUELTOS, 1997-2020

Fuente: Suttner, Sutcliffe & Perrault, 2020 | Gráfica: Informe AI Index Report 2021




Figura 2.6.3

Aunque este análisis demuestra el progreso de la ATP, es obvio que hay espacio para mucho más. Dos claves para resolver los problemas ATP son la selección de axiomas (dado un gran conjunto de axiomas, de los cuales sólo algunos son necesarios para la demostración de la conjetura, cómo seleccionar un subconjunto adecuado de los axiomas); y la elección de la búsqueda (en cada etapa de la búsqueda de una solución por parte de un sistema ATP, qué fórmula(s) lógica(s) debe(n) ser seleccionada(s) para su atención). Esta última cuestión ha estado en primera línea de la investigación sobre ATP

desde su creación en los años 60, mientras que la primera ha adquirido una importancia creciente a medida que se codifican grandes cuerpos de conocimiento para ATP. En la última década, se han utilizado cada vez más enfoques de aprendizaje automático para abordar estos dos desafíos clave (por ejemplo, en los sistemas ATP MaLAREa y Enigma). Los resultados recientes del Concurso de Sistemas ATP del CADE (CASC) han demostrado que la aparición del aprendizaje automático puede cambiar las reglas del juego para el ATP.

2.7 SALUD Y BIOLOGÍA

En colaboración con “[State of AI Report](#)”

SÍNTESIS MOLECULAR

Texto de Nathan Benaich y Philippe Schwaller

En los últimos 25 años, la industria farmacéutica ha pasado de desarrollar fármacos a partir de fuentes naturales (por ejemplo, plantas) a realizar cribados a gran escala con moléculas sintetizadas químicamente. El aprendizaje automático permite a los científicos determinar qué fármacos potenciales merece la pena evaluar en el laboratorio y la forma más eficaz de sintetizarlos. Diversos modelos de ML pueden aprender representaciones de moléculas químicas con el fin de planificar la síntesis química. Una forma de abordar la planificación de la síntesis química es representar las reacciones químicas con una notación textual y plantear la tarea como un problema de traducción automática. El trabajo reciente de trabajo desde 2018 hace uso de la arquitectura transformer entrenada en grandes conjuntos de datos de reacciones de un solo paso. El trabajo posterior en 2020 abordó la predicción y la retrosíntesis del modelo como una secuencia de ediciones de gráficos, donde las moléculas predichas se construyeron desde cero.

En particular, estos enfoques ofrecen una vía para barrer rápidamente una lista de moléculas candidatas a fármacos in silico y obtener puntuaciones de sintetizabilidad y planes de síntesis. Esto permite a los químicos medicinales dar prioridad a los candidatos para su validación empírica y, en última instancia, podría permitir a la industria farmacéutica explorar el vasto espacio químico para descubrir nuevos fármacos que beneficien a los pacientes.

Exactitud del conjunto de pruebas para la planificación de síntesis química avanzada

La figura 2.7.1 muestra la exactitud top-1 de los modelos comparados con un conjunto de datos de libre acceso de un millón de reacciones en las patentes de EE.UU.⁶ La exactitud top-1 significa que el producto predicho por el modelo con la mayor probabilidad corresponde al que se informó en la realidad. Los datos sugieren que el progreso en la planificación de la síntesis química ha experimentado un crecimiento constante en los últimos tres años, ya que la exactitud creció un 15,6% en 2020 desde 2017. El último transformador molecular obtuvo un 92% de exactitud en noviembre de 2020.

PUNTOS DE REFERENCIA DE PLANES DE SÍNTESIS QUÍMICA: TOP-1 DE PRECIÓN EN PRUEBAS

Fuente: Schwaller, 2020 | Gráfica: Informe AI Index 2021




Figura 2.7.1

⁶ Agradecimiento: Philippe Schwaller, de IBM Research-Europe y la Universidad de Berna, proporcionó instrucciones y recursos para la recogida y el análisis de los datos.

COVID-19 Y EL DESCUBRIMIENTO DE FÁRMACOS

El descubrimiento de fármacos impulsado por la IA ha pasado a ser de código abierto para combatir la pandemia de COVID-19. COVID Moonshot es una iniciativa de crowdsourcing a la que se han unido más de 500 científicos internacionales para acelerar el desarrollo de un antiviral contra el COVID-19. El consorcio de científicos presenta sus diseños moleculares de forma gratuita, sin derechos de autor. PostEra, una empresa de inteligencia artificial, utiliza herramientas de aprendizaje automático y computacional para evaluar la facilidad con la que se pueden fabricar compuestos a partir de las propuestas de los científicos y genera rutas sintéticas. Tras la primera semana, Moonshot recibió más de 2.000 propuestas y PostEra diseñó rutas

sintéticas en menos de 48 horas. Los farmacéuticos humanos habrían tardado entre tres y cuatro semanas en realizar la misma tarea.

La figura 2.7.2 muestra el número acumulado de propuestas de los científicos a lo largo del tiempo. Moonshot recibió más de 10.000 propuestas de 365 colaboradores de todo el mundo en sólo cuatro meses. Hacia finales de agosto de 2020, el crowdsourcing había cumplido su objetivo, y el énfasis se trasladó a la optimización de los compuestos principales y a la preparación de los ensayos con animales. En febrero de 2021, Moonshot pretendía designar un candidato clínico para finales de marzo.

POSTERA: TOTAL de PROPUESTAS ENVIADAS a MOONSHOT

Fuente: PostEra, 2020 | Gráfica: Informe AI Index 2021




Figura 2.7.2

ALPHAFOLD Y EL PLEGADO DE PROTEÍNAS

El problema del plegado de las proteínas, un gran reto de la biología estructural, considera cómo determinar la estructura tridimensional de las proteínas (componentes esenciales de la vida) a partir de sus representaciones unidimensionales (secuencias de aminoácidos)⁷. La solución de este problema puede tener un amplio abanico de aplicaciones, desde la comprensión de las bases celulares de la vida hasta el descubrimiento de fármacos, la curación de enfermedades o la ingeniería de proteínas para tareas industriales, entre otras.

En los últimos años, los enfoques basados en el aprendizaje automático han empezado a marcar una diferencia significativa en el problema del plegado de proteínas. En particular, AlphaFold de DeepMind debutó en 2018 en la competición Critical Assessment of Protein Structure (CASP), una competición bienal para fomentar y medir el progreso en el plegado de proteínas. En el CASP, los equipos que compiten reciben secuencias de

aminoácidos y se les encomienda la tarea de predecir las estructuras tridimensionales de las proteínas correspondientes, las cuales se determinan a través de métodos experimentales laboriosos y costosos (por ejemplo, espectroscopia de resonancia magnética nuclear, cristalografía de rayos X, criomicroscopía electrónica, etc.) y desconocidos para los competidores.

El rendimiento en el CASP se suele medir mediante la puntuación de la Prueba de Distancia Global (GDT), un número entre 0 y 100 que mide la similitud entre dos estructuras de proteínas. Una puntuación GDT más alta es mejor.

La figura 2.7.3, adaptada de la entrada del blog de DeepMind, muestra la media de las puntuaciones GDT del mejor equipo en algunos de los tipos de proteínas más difíciles de predecir (la categoría de proteínas de “modelado libre”) en el CASP durante los últimos 14 años. En el pasado, los algoritmos ganadores solían basados en modelos basados en la física; sin embargo, en las dos últimas competiciones, los algoritmos AlphaFold y AlphaFold 2 de Deepmind lograron puntuaciones ganadoras gracias a la incorporación parcial de técnicas de aprendizaje profundo.

CASP: MEDIANA DE PRECISIÓN de PREDICCIONES en MODELADO LIBRE por el MEJOR EQUIPO, 2006-20

Fuente: DeepMind, 2020 | Gráfica: informe AI Index 2021




Figura 2.7.3

⁷ En la actualidad, la mayoría de los algoritmos de plegado de proteínas aprovechan las alineaciones de múltiples secuencias -muchas copias de una secuencia de proteínas que representan la misma proteína a lo largo de la evolución- en lugar de una única secuencia.

PUNTOS DESTACADOS POR LOS EXPERTOS

Este año, el AI Index pidió a los expertos en IA que compartieran sus opiniones sobre los avances técnicos más importantes de la IA en 2020. He aquí un resumen de sus respuestas, junto con un par de puntos destacados.

¿Cuál ha sido el avance más impresionante de la IA en 2020?

- Los dos sistemas más mencionados por un margen significativo fueron AlphaFold (DeepMind), un modelo de ensayo molecular, y GPT-3 (OpenAI), un modelo de texto generativo.

¿Qué tendencia definirá la IA en 2021?

- Los expertos predicen que se construirán más avances utilizando modelos pre-entrenados. Por ejemplo, GPT-3 es un gran modelo de NLP que puede ajustarse posteriormente para obtener un rendimiento excelente en tareas específicas y limitadas. Del mismo modo, en 2020 se produjeron varios avances en el campo de la visión artificial sobre la base de modelos pre-entrenados en conjuntos de datos de imágenes muy grandes.

¿Qué aspecto del progreso técnico, el despliegue y el desarrollo de la IA le ilusiona más ver en 2021?

- “Es interesante observar el dominio de la arquitectura Transformers, que comenzó para la traducción automática pero se ha convertido en la arquitectura de redes neuronales de facto. En términos más generales, mientras que el NLP fue por detrás de la visión en términos de adopción del aprendizaje profundo, ahora parece que los avances en el NLP también están impulsando la visión.” - Percy Liang, Universidad de Stanford
- “Los increíbles avances recientes en la generación de lenguaje han tenido un profundo efecto en los campos del NLP y el aprendizaje automático, haciendo que los retos de investigación y los conjuntos de datos antes difíciles sean repentinamente inútiles, mientras que simultáneamente se fomentan nuevos esfuerzos de investigación en las fascinantes capacidades emergentes (y los importantes fallos) de estos nuevos y complejos modelos.” -Carissa Schoenick, Instituto Allen de Investigación de la IA



CAPÍTULO 3: Economía



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 3:

Vista previa del capítulo

Resumen	82		
Puntos clave del capítulo	83		
3.1 EMPLEOS	84	3.3 ACTIVIDAD CORPORATIVA	98
Contratación de expertos en IA	84	Adopción en la industria	98
Demanda laboral en IA	86	Adopción mundial de la IA	98
Demanda laboral mundial en IA	86	Adopción de la IA por industria y función	99
Demanda laboral en EE.UU. por clúster de competencias	87	Tipo de capacidades adoptadas en IA	99
Demanda laboral en EE.UU. por sector	88	Identificación y mitigación de riesgos de adoptar la IA	101
Demanda laboral en EE.UU. por estado	90	El efecto del COVID-19	103
Prevalencia de competencias en IA	91	Instalaciones de robot industriales	104
Comparación global	91	Tendencia mundial	104
Comparación global: por sector	92	Comparación regional	105
3.2 INVERSIÓN	93	Conferencias de reportes de ganancias	106
Inversión privada	93		
Actividad de las startups	94		
Tendencia mundial	94		
Comparación regional	95		
Análisis de áreas de concentración	97		

ACCESO A LOS DATOS

Resumen

El auge de la inteligencia artificial (IA) plantea inevitablemente la cuestión de hasta qué punto las tecnologías tendrán un impacto en las empresas, el trabajo y la economía en general.

Teniendo en cuenta los recientes progresos y los numerosos avances de la IA, este campo ofrece beneficios y oportunidades sustanciales para las empresas, desde el aumento de la productividad con la automatización hasta la adaptación de los productos a los consumidores mediante algoritmos, el análisis de datos a escala, etc.

Sin embargo, el aumento de la eficiencia y la productividad que promete la IA también presenta grandes retos: Las empresas deben esforzarse por encontrar y retener el talento cualificado para satisfacer sus necesidades de producción, a la vez que son conscientes de la aplicación de medidas para mitigar los riesgos del uso de la IA. Además, la pandemia del COVID-19 ha provocado el caos y la continua incertidumbre en la economía mundial. ¿Cómo han confiado las empresas privadas en las tecnologías de la IA y cómo las han ampliado para ayudar a sus negocios a atravesar esta época tan difícil?

Este capítulo examina la relación cada vez más entrelazada entre la IA y la economía mundial desde la perspectiva del empleo, la inversión y la actividad empresarial.

En primer lugar, se analiza la demanda mundial de talento en IA utilizando datos sobre las tasas de contratación y los índices de penetración de habilidades de LinkedIn, así como las ofertas de empleo en IA de Burning Glass Technologies. A continuación, se examinan las tendencias de la inversión privada en IA utilizando estadísticas de S&P Capital IQ (CapIQ), Crunchbase y Quid. La tercera y última sección analizan las tendencias en la adopción de capacidades de IA en las empresas, las tendencias en la instalación de robots en los países y las menciones de la IA en los beneficios empresariales, a partir de la Encuesta Global sobre IA de McKinsey, la Federación Internacional de Robótica (IFR) y Prattle, respectivamente.

PUNTOS CLAVE DEL CAPÍTULO

- La categoría “Medicamentos, cáncer, molecular, descubrimiento de fármacos” recibió la mayor cantidad de inversión privada en IA en 2020, con más de 13.800 millones de dólares, 4,5 veces más que en 2019.
- Brasil, India, Canadá, Singapur y Sudáfrica son los países con mayor crecimiento en la contratación de IA de 2016 a 2020. A pesar de la pandemia de COVID-19, la contratación de IA siguió creciendo en todos los países de la muestra en 2020.
- Se está canalizando más inversión privada en IA hacia menos startups. A pesar de la pandemia, en 2020 se produjo un aumento del 9,3% en la cantidad de inversión privada en IA desde 2019, un aumento porcentual más alto que en 2019 (5,7%), aunque el número de empresas recién financiadas disminuyó por tercer año consecutivo.
- A pesar de las crecientes llamadas para abordar las preocupaciones éticas asociadas con el uso de la IA, los esfuerzos para abordar estas preocupaciones en la industria son limitados, según una encuesta de McKinsey. Por ejemplo, cuestiones como la equidad y la justicia en la IA siguen recibiendo comparativamente poca atención por parte de las empresas. Además, menos empresas en 2020 ven los riesgos de privacidad personal o individual como relevantes, en comparación con 2019, y no hubo cambios en el porcentaje de encuestados cuyas empresas están tomando medidas para mitigar estos riesgos particulares.
- A pesar de la recesión económica causada por la pandemia, la mitad de los encuestados en una encuesta de McKinsey dijo que el coronavirus no tuvo ningún efecto en su inversión en IA, mientras que el 27% informó de hecho de que había aumentado su inversión. Menos de una cuarta parte de las empresas redujo su inversión en IA.
- Los Estados Unidos registraron una disminución en su proporción de puestos de trabajo de IA de 2019 a 2020, la primera caída en seis años. El número total de puestos de trabajo de IA publicados en los Estados Unidos también disminuyó un 8,2%, de 325.724 en 2019 a 300.999 en 2020.

Atraer y retener el talento calificado en IA es un reto. Esta sección examina la última tendencia en la contratación de expertos en IA, la demanda de mano de obra y la penetración de habilidades, con datos de LinkedIn y Burning Glass.

3.1 EMPLEOS

CONTRATACIÓN DE EXPERTOS EN IA

¿Cuál es el ritmo de crecimiento de los puestos de trabajo de IA en los distintos países? Esta sección examina en primer lugar los datos de LinkedIn que dan la tasa de contratación de IA en diferentes países. La tasa de contratación de IA se calcula como el número de miembros de LinkedIn que incluyen competencias de IA en su perfil o trabajan en ocupaciones relacionadas con la IA y que han añadido un nuevo empleador en el mismo mes en que comenzó su nuevo trabajo, dividido por el número total de miembros de LinkedIn en el país. A continuación, este índice se indexa con el mes medio de 2016; por ejemplo, un índice de 1,05 en diciembre de 2020 apunta a un índice de contratación un 5% superior al mes medio de 2016. LinkedIn realiza comparaciones mes a mes para tener en cuenta cualquier posible retraso en la actualización de los perfiles de

los usuarios. El índice de un año es el índice medio de todos los meses de ese año.

Estos datos sugieren que el índice de contratación ha aumentado en todos los países de la muestra en 2020. Brasil, India, Canadá, Singapur y Sudáfrica son los países con mayor crecimiento en la contratación de IA entre 2016 y 2020 (Figura 3.1.1). En los 14 países analizados, la tasa de contratación de IA en 2020 fue 2,2 veces mayor, en promedio, que la de 2016. Para el primer país, Brasil, el índice de contratación creció más de 3,5 veces. Además, a pesar de la pandemia de COVID-19, la contratación de IA siguió creciendo en los 14 países de la muestra en 2020 (Figura 3.1.2).

Para más exploraciones de comparaciones entre países, véase la Herramienta de Vitalidad Global de la IA del AI Index.

ÍNDICE DE CONTRATACIÓN DE EXPERTOS EN IA POR PAÍS, 2020

Fuente: LinkedIn, 2020 | Gráfica: Informe AI Index 2021



Figura 3.1.1

1 Los países incluidos son una muestra de países elegibles con al menos un 40% de cobertura de mano de obra por parte de LinkedIn y al menos 10 contrataciones de IA en un mes determinado. China e India también se incluyeron en esta muestra debido a su creciente importancia en la economía mundial, pero la cobertura de LinkedIn en estos países no alcanza el 40% de la fuerza laboral. Los datos de estos países pueden no ofrecer una imagen tan completa como la de otros países, y deben interpretarse en consecuencia.

ÍNDICE DE CONTRATACIÓN DE EXPERTOS EN IA por PAÍS, 2016-20

Fuente: LinkedIn, 2020 | Gráfica: Informe AI Index 2021




Figura 3.1.2

DEMANDA LABORAL EN IA

Esta sección analiza la demanda laboral de expertos en IA a partir de los datos de Burning Glass, una empresa de análisis que recopila anuncios de más de 45.000 sitios de empleo en línea. Para desarrollar un retrato exhaustivo y en tiempo real de la demanda del mercado laboral, Burning Glass ha agregado los anuncios de empleo, eliminado los duplicados y extrajo los datos del texto de las ofertas de empleo. Tenga en cuenta que Burning Glass actualizó la cobertura de datos en 2020 con más sitios de empleo; como resultado, las cifras de este informe no deben compararse directamente con los datos del informe de 2019.

Demanda global de mano de obra de IA

La demanda laboral de IA en seis países cubiertos por los datos de Burning Glass -Estados Unidos, Reino Unido, Canadá, Australia, Nueva Zelanda y Singapur- ha crecido

significativamente en los últimos siete años (Figura 3.1.3). De media, el porcentaje de ofertas de empleo en IA entre todas las ofertas de empleo en 2020 es más de cinco veces mayor que en 2013. De los seis países, Singapur es el que presenta el mayor crecimiento, ya que su porcentaje de ofertas de empleo de IA entre todos los puestos de trabajo en 2020 es 13,5 veces mayor que en 2013.

Estados Unidos es el único país de los seis que registró un descenso en su porcentaje de ofertas de empleo de IA de 2019 a 2020, la primera caída en seis años. Esto puede deberse a la pandemia de coronavirus o al mercado laboral de IA relativamente más maduro del país. El número total de puestos de trabajo de IA publicados en Estados Unidos también disminuyó un 8,2%, pasando de 325.724 en 2019 a 300.999 en 2020.

ANUNCIOS DE EMPLEO EN IA (% de TODOS LOS ANUNCIOS DE EMPLEO) por PAÍS, 2013-20

Fuente: Burning Glass, 2020 | Gráfica: Informe AI Index 2021




Figura 3.1.3

Demanda laboral de IA en EE.UU. por clúster de competencias

Si analizamos con más detalle la demanda laboral de obra de IA en Estados Unidos entre 2013 y 2020, la figura 3.1.4 desglosa la demanda durante ese periodo año por año según el grupo de competencias. Cada grupo de competencias consiste en una lista de habilidades relacionadas con la IA; por ejemplo, el grupo de competencias de redes neuronales incluye habilidades como el aprendizaje profundo y la red neuronal convolucional. El apéndice del capítulo de Economía proporciona una lista completa de las competencias de la IA en cada grupo de habilidades.

Entre 2013 y 2020, los puestos de trabajo de IA relacionados con el aprendizaje automático y la inteligencia artificial experimentaron el crecimiento más rápido en las ofertas de trabajo de IA en línea en los Estados Unidos, aumentando del 0,1% del total de puestos de trabajo al 0,5% y del 0,03% al 0,3%, respectivamente. Como se ha señalado anteriormente, en 2020 se observa una disminución de la proporción de puestos de trabajo de IA entre las ofertas de empleo generales en todos los grupos de competencias.

Entre 2013 y 2020, los puestos de trabajo de IA relacionados con el aprendizaje automático y la inteligencia artificial experimentaron el crecimiento más rápido en las ofertas de trabajo de IA en línea en Estados Unidos, pasando del 0,1% del total de puestos de trabajo al 0,5% y del 0,03% al 0,3%, respectivamente.

ANUNCIOS DE EMPLEO EN IA (% de TODOS LOS ANUNCIOS) en los ESTADOS UNIDOS por CLÚSTER DE COMPETENCIAS, 2013-20

Fuente: Burning Glass, 2020 | Gráfica: Informe AI Index 2021




Figura 3.1.4

Demanda laboral en EE.UU. por sector

Para profundizar en cómo varía la demanda de empleo de IA en el mercado laboral de EE.UU. por sectores, esta sección analiza la proporción de puestos de trabajo de IA entre todos los puestos publicados en Estados Unidos por sector en 2020 (figura 3.1.5), así como la tendencia de los últimos 10 años (figura 3.1.6).

En 2020, los sectores centrados en la información (2,8%), los servicios profesionales, científicos y técnicos (2,5%) y la agricultura, la silvicultura, la pesca y la caza (2,1%) tendrán la mayor proporción de ofertas de empleo de IA entre todas las ofertas de empleo en Estados Unidos. Mientras que los dos primeros siempre han dominado la demanda de puestos de trabajo de IA, la industria de la agricultura, silvicultura, pesca y caza vio el mayor salto -casi un punto porcentual- en la proporción de puestos de trabajo de IA de 2019 a 2020.

En 2020, las industrias centradas en la información (2,8%); los servicios profesionales, científicos y técnicos (2,5%); y la agricultura, la silvicultura, la pesca y la caza (2,1%) tuvieron la mayor proporción de anuncios de empleo de IA entre todos los anuncios de empleo en Estados Unidos.

ANUNCIOS DE EMPLEO EN IA (% de TODOS LOS ANUNCIOS DE EMPLEO) en los ESTADOS UNIDOS por INDUSTRIA, 2020

Fuente: Burning Glass, 2020 | Gráfica: Informe AI Index 2021




Figura 3.1.5

ANUNCIOS DE EMPLEO EN IA (% de DE TODOS LOS ANUNCIOS DE EMPLEO) en los ESTADOS UNIDOS por INDUSTRIA, 2013-20

Fuente: Burning Glass, 2020 | Gráfica: Informe AI Index 2021

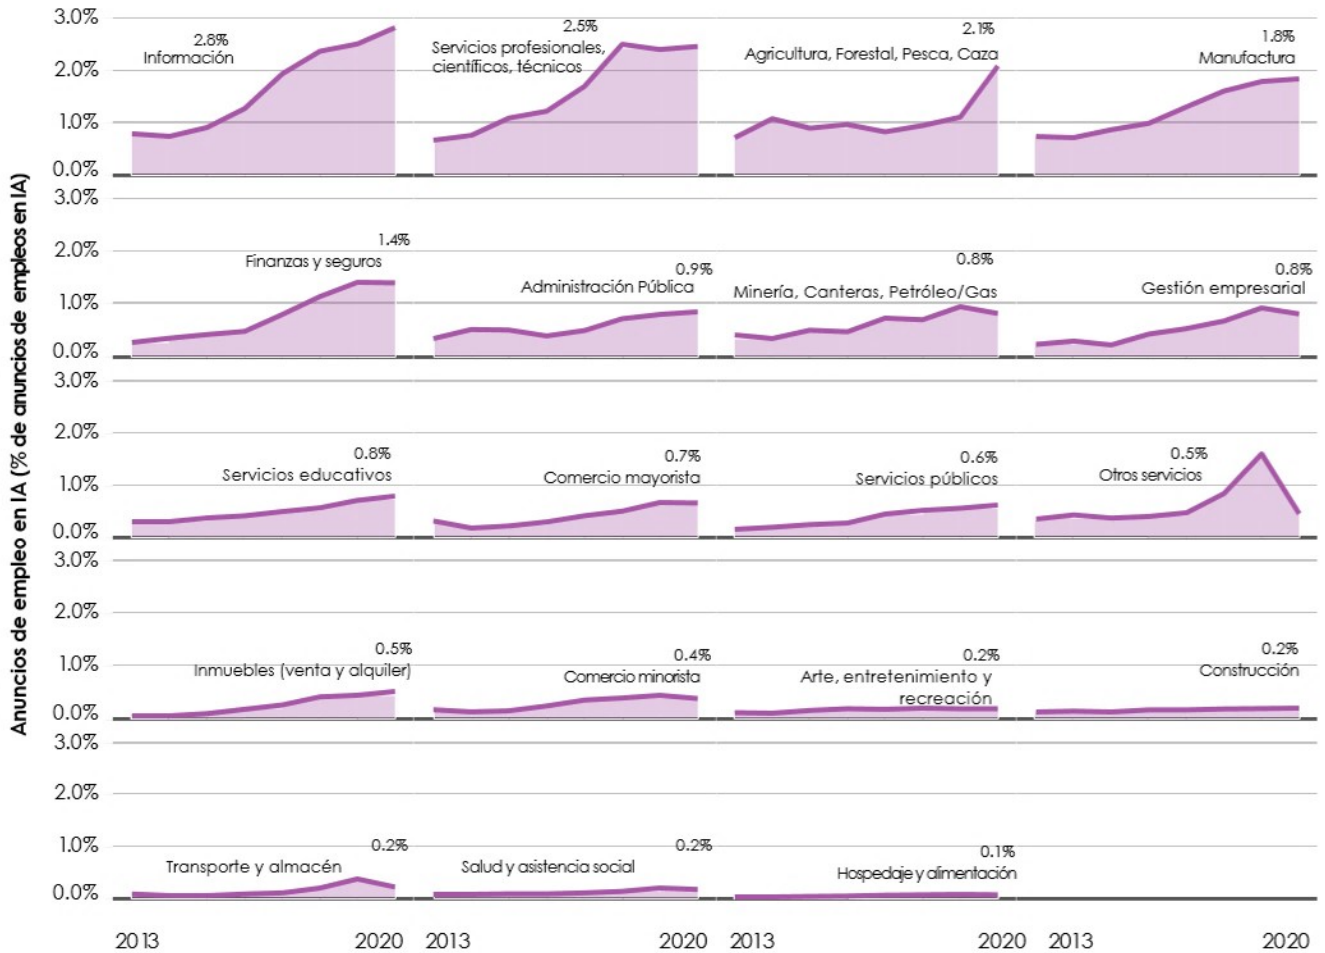


Figura 3.1.6

Demanda laboral en EE.UU. por Estado

A medida que se intensifica la competencia por el talento de la IA, ¿dónde buscan las empresas empleados con competencias en aprendizaje automático, ciencia de datos y otras habilidades relacionadas con la IA dentro de Estados Unidos?


La figura 3.1.7 examina la demanda de mano de obra por estados de EE.UU. en 2020, trazando la proporción de ofertas de trabajo de IA entre todas las ofertas de trabajo en el eje de ordenadas y el número total de puestos de trabajo de IA publicados en una escala logarítmica en el eje de abscisas. La gráfica muestra que el Distrito de Columbia tiene la mayor proporción de puestos de trabajo de

IA publicados (1,88%), superando al estado de Washington en 2019; y California sigue siendo el estado con el mayor número de puestos de trabajo de IA (63.433).

Además de Washington, D.C., seis estados registraron más del 1% de las ofertas de empleo de IA entre todas las ofertas de empleo -Washington, Virginia, Massachusetts, California, Nueva York y Maryland- en comparación con cinco el año pasado. California también tiene más ofertas de empleo de IA que los tres estados siguientes juntos, que son Texas (22.539), Nueva York (18.580) y Virginia (17.718).

ANUNCIOS DE EMPLEOS EN IA (TOTAL y % de TODOS LOS ANUNCIOS DE EMPLEO) por ESTADO y DISTRITO en EE.UU., 2020

Fuente: Burning Glass, 2020 | Gráfica: Informe AI Index 2021



Figurs 3.1.7

PREVALENCIA DE COMPETENCIAS DE IA

¿Cuál es la prevalencia de las competencias de IA en las ocupaciones? La métrica de penetración de habilidades de IA muestra la proporción media de habilidades de IA entre las 50 principales habilidades de cada ocupación, utilizando datos de LinkedIn que incluyen las habilidades que aparecen en el perfil de un miembro, los puestos ocupados y las ubicaciones de los puestos.

Comparación global

Para la comparación entre países, la tasa de penetración relativa de las habilidades de IA se mide como la suma de la penetración de cada habilidad de IA en las ocupaciones de un país determinado, dividida por la penetración global media de

las habilidades de IA en las mismas ocupaciones.

Por ejemplo, un índice de penetración relativo de 2 significa que la penetración media de las habilidades de IA en ese país es 2 veces la media mundial en el mismo conjunto de ocupaciones.

Entre los países de la muestra que se muestran en la figura 3.1.8, los datos agregados de 2015 a 2020 muestran que la India (2,83 veces la media mundial) tiene el mayor índice de penetración relativa de habilidades de IA, seguida de Estados Unidos (1,99 veces la media mundial), China (1,40 veces la media mundial), Alemania (1,27 veces la media mundial) y Canadá (1,13 veces la media mundial).²

TASA DE PRESENCIA RELATIVA DE COMPETENCIAS DE IA por PAÍS, 2015-2020

Fuente: Burning Glass, 2020 | Gráfica: Informe AI Index 2021




Figura 3.1.8

² Los países incluidos son una muestra de países elegibles con al menos un 40% de cobertura de mano de obra por parte de LinkedIn y al menos 10 contrataciones de IA en un mes determinado. China e India también se incluyeron en esta muestra debido a su creciente importancia en la economía mundial, pero la cobertura de LinkedIn en estos países no alcanza el 40% de la fuerza laboral. Los datos de estos países pueden no ofrecer una imagen tan completa como la de otros países, y deben interpretarse en consecuencia.

Comparación global: por sectores

Para ofrecer una descomposición sectorial en profundidad de la penetración de las competencias en IA en los distintos sectores y países de la muestra, la figura 3.1.9 incluye los datos agregados de los cinco principales sectores con mayor penetración de las competencias en IA a nivel mundial en los últimos cinco años: educación, finanzas, hardware y redes, fabricación y software y TI.³ La India tiene la mayor penetración relativa de las competencias en IA en los cinco sectores, mientras que Estados Unidos y China aparecen con frecuencia en los

primeros puestos de la lista. Otros focos de especialización que vale la pena destacar, con índices de penetración relativa de habilidades superiores a 1, son Alemania en hardware y redes, así como en fabricación, e Israel en fabricación y educación.

TASA DE PRESENCIA RELATIVA DE COMPETENCIAS DE IA por INDUSTRIA, 2015-20

Fuente: LinkedIn, 2020 | Gráfica: Informe AI Index 2021




Figura 3.1.9

³ Los países incluidos son una muestra de países elegibles con al menos un 40% de cobertura de mano de obra por parte de LinkedIn y al menos 10 contrataciones de IA en un mes determinado. China e India también se incluyeron en esta muestra debido a su creciente importancia en la economía mundial, pero la cobertura de LinkedIn en estos países no alcanza el 40% de la fuerza laboral. Los datos de estos países pueden no ofrecer una imagen tan completa como la de otros países, y deben interpretarse en consecuencia.

Esta sección explora la actividad de inversión de las empresas privadas por parte de NetBase Quid basándose en datos de CapIQ y Crunchbase. En concreto, examina las últimas tendencias de inversión en IA de las empresas, como la inversión privada, las ofertas públicas, las fusiones y adquisiciones (M&A) y las participaciones minoritarias relacionadas con la IA. A continuación, la sección se centra en la inversión privada en IA, o en la cantidad de financiación privada que se destina a las startups de IA y en qué sectores están atrayendo una inversión significativa y en qué países.

3.2 INVERSIÓN

INVERSIÓN PRIVADA

La inversión mundial total en IA, incluida la inversión privada, las ofertas públicas, las fusiones y adquisiciones y las participaciones minoritarias, aumentó un 40% en 2020 con respecto a 2019, con un total de 67.900 millones de dólares (figura 3.2.1). Dada la pandemia, muchas pequeñas empresas han sufrido daños considerables. Como resultado, la consolidación de la industria y el aumento de la actividad de fusiones y adquisiciones en 2020 están impulsando la

inversión corporativa total en IA. Las fusiones y adquisiciones constituyeron la mayor parte del importe total de la inversión en 2020, aumentando un 121,7% en relación con 2019.

Varias adquisiciones de alto perfil relacionadas con la IA tuvieron lugar en 2020, incluyendo la adquisición de Mellanox Technologies por parte de NVIDIA y la de Altran Technologies por parte de Capgemini.

INVERSIÓN PRIVADA GLOBAL en IA por TIPO DE INVERSIÓN, 2015-20

Fuente: CapIQ, Crunchbase y NetBase Quid, 2020 | Gráfica: Informe AI Index 2021




Figura 3.2.1

ACTIVIDAD DE LAS STARTUP

En la siguiente sección se analiza la tendencia de la inversión privada en las startups de IA que han recibido inversiones de más de 400.000 dólares en los últimos 10 años. Aunque la cantidad de inversión privada en IA se ha disparado de forma espectacular en los últimos años, el ritmo de crecimiento ha disminuido.

Tendencia mundial

La mayor inversión privada en IA se está canalizando hacia menos startups. A pesar de la pandemia, en 2020 se produjo un aumento del 9,3% en la cantidad de inversión privada en IA con respecto a 2019, un porcentaje mayor que el aumento del 5,7% en 2019 (figura 3.2.2), aunque el número de empresas financiadas disminuyó por tercer año consecutivo (figura 3.2.3). Si bien hubo un récord de más de 40 mil millones de dólares en inversión privada en 2020, eso representa solo un aumento del 9,3% desde 2019 -en comparación con el mayor aumento del 59,0%, observado entre 2017 y 2018.

Además, el número de startups de IA financiadas continuó un fuerte descenso desde su pico de 2017.

INVERSIÓN PRIVADA en COMPAÑÍAS DE IA FINANCIADAS, 2015-20

Fuente: CapIQ, Crunchbase y NetBase Quid, 2020 | Gráfica: Informe AI Index 2021




Figura 3.2.2

NÚMERO DE COMPAÑÍAS NUEVAS DE IA CON FINANCIAMIENTO en el MUNDO, 2015-20

Fuente: CapIQ, Crunchbase y NetBase Quid, 2020 | Gráfica: Informe AI Index 2021




Figura 3.2.3

Comparación Regional

Como se muestra en la Figura 3.2.4, Estados Unidos sigue siendo el principal destino de la inversión privada, con más de 23.600 millones de dólares de financiación en 2020, seguido de China (9.900 millones de dólares) y el Reino Unido (1.900 millones de dólares).

INVERSIÓN PRIVADA en IA por PAÍS, 2020

Fuente: CapIQ, Crunchbase y NetBase Quid, 2020 | Gráfica: Informe AI Index 2021




Figura 3.2.4

Un examen más detallado de los tres contendientes que lideran la carrera de la IA -Estados Unidos, China y la Unión Europea- valida aún más la posición dominante de Estados Unidos en la inversión privada en IA. Aunque China registró una cantidad excepcionalmente alta de inversión privada en IA en 2018, su nivel de inversión en 2020 es menos de la mitad que el de Estados Unidos

(figura 3.2.5). Sin embargo, es importante señalar que China tiene fuertes inversiones públicas en IA. Tanto el gobierno central como los gobiernos locales de China están gastando mucho en I+D en IA.⁴

⁴ Lea "A Brief Examination of Chinese Government Expenditures on Artificial Intelligence R&D" (2020) para consultar los análisis del Instituto de Defensa de los Estados Unidos para más detalles.

INVERSIÓN PRIVADA en IA por ZONA GEOGRÁFICA, 2015-20

Fuente: CapIQ, Crunchbase y NetBase Quid, 2020 | Gráfica: Informe AI Index 2021




Figura 3.2.5

Análisis de las áreas prioritarias

La figura 3.2.6 muestra la clasificación de las 10 principales áreas de interés que reciben la mayor cantidad de inversión privada en 2020, así como su respectiva cantidad de inversión en 2019. El área “Medicamentos, Cáncer, Molecular, Descubrimiento de fármacos” encabeza la lista, con más de 13.800 millones de USD de inversión privada en IA -4,5 veces más que en 2019-, seguida de “Vehículos autónomos, Flota, Conducción autónoma Driving, Road” (4.500 millones de dólares), y “Estudiantes, Cursos, Edtech, Idioma Inglés” (4.100 millones de dólares).

Además de la categoría “Medicamentos, Cáncer, Molecular, Descubrimiento de Fármacos”, tanto “Juegos, Aficionados, Gaming, Fútbol” como “Estudiantes, Cursos, Edtech, Idioma Inglés” vieron un aumento significativo en la cantidad de inversión privada en IA de 2019 a 2020. La primera está impulsada en gran medida por varias rondas de financiación a startups de juegos y deportes en Estados Unidos y Corea del Sur, mientras que la segunda se ve impulsada por las inversiones en una plataforma de educación en línea en China.

INVERSIÓN PRIVADA GLOBAL en IA por ÁREA PRIORITARIA, 2019 vs 2020

Fuente: CapIQ, Crunchbase y NetBase Quid, 2020 | Gráfica: Informe AI Index 2021




Figura 3.2.6

Esta sección examina cómo las empresas han aprovechado los avances de la IA, usando la IA y la automatización en su beneficio y generando valor a escala. Si bien el número de empresas que han comenzado a desplegar tecnologías de IA ha aumentado en los últimos años, la inestabilidad económica y el impacto de COVID-19 en 2020 han frenado ese ritmo de adopción. Las últimas tendencias en las actividades de IA de las empresas se analizan a través de los datos sobre la adopción de capacidades de IA de la Encuesta Global sobre IA de McKinsey, las tendencias en las instalaciones de robots en todo el mundo de la Federación Internacional de Robótica (IFR) y las menciones de la IA en las convocatorias de beneficios de las empresas de Prattle.

3.3 ACTIVIDAD CORPORATIVA

ADOPCIÓN EN LA INDUSTRIA

En esta sección se comparten los resultados de una encuesta realizada por McKinsey & Company a 2.395 encuestados: personas que representan a empresas de diversas regiones, sectores, tamaños, especialidades funcionales y cargos. El informe de McKinsey & Company “[The State of AI in 2020](#)” contiene los resultados completos de esta encuesta, incluyendo las ideas sobre cómo las diferentes empresas han adoptado la IA en todas las funciones, las mejores prácticas básicas compartidas entre las empresas que están generando el mayor valor de la IA, y los impactos de la pandemia COVID-19 en los planes de inversión en IA de estas empresas.

Adopción mundial de la IA

Los resultados de la encuesta de 2020 sugieren que no hay un aumento en la adopción de la IA en relación con 2019. Más del 50% de los encuestados afirman que sus organizaciones han adoptado la IA en al menos una función empresarial (Figura 3.3.1). En 2019, el 58% de los encuestados dijo que sus empresas adoptaron la IA en al menos una función, aunque en la encuesta de 2019 se preguntó por la adopción de la IA por parte de las empresas de forma distinta.

En 2020, las empresas de los países desarrollados de Asia-Pacífico lideraron las adopciones de IA, seguidas por las de India y Norteamérica. Mientras que la adopción de la IA fue más o menos igual en todas las regiones en 2019, las empresas en América Latina y en otros países en desarrollo son mucho menos propensas a informar de la adopción de la IA en al menos una función empresarial.

ADOPCIÓN DE LA IA por ORGANIZACIONES GLOBALMENTE, 2020

Fuente: McKinsey & Company, 2020 | Gráfica: Informe AI Index Report 2021




Figura 3.3.1

Adopción de la IA por industria y función

Los encuestados que representaban a empresas de alta tecnología y telecomunicaciones eran los más propensos a informar de la adopción de la IA en 2020, de forma similar a los resultados de 2019, seguidos en segundo lugar tanto por los servicios financieros como por la automoción y el montaje (figura 3.3.2).

En otra repetición de 2019 (y 2018), la encuesta de 2020 sugiere que las funciones en las que es más probable que las empresas adopten la IA varían según el sector (figura 3.3.3). Por ejemplo, los encuestados de la industria automotriz y de ensamblado informan de una mayor adopción de IA para las tareas relacionadas con la fabricación que cualquier otra; los encuestados de los servicios financieros informan de una mayor adopción de IA para las funciones de riesgo; y los encuestados de alta tecnología y telecomunicaciones informan de una mayor adopción de IA para las funciones de desarrollo de productos y servicios.

En todas las industrias, las empresas en 2020 son más propensas a informar que utilizan la IA para las operaciones de servicio (como los servicios de campo, la atención al cliente, el back office), el desarrollo de productos y servicios, y el marketing y las ventas, de manera similar a los resultados de la encuesta en 2019.

Tipo de capacidades de IA adoptadas

Por sectores, el tipo de capacidades de IA adoptadas varía (Figura 3.3.4). En todos los sectores, las empresas de 2020 fueron las más propensas a identificar otras técnicas de aprendizaje automático, automatización de procesos robóticos y visión artificial como capacidades adoptadas en al menos una función empresarial.

Los sectores tienden a adoptar las capacidades de IA que mejor sirven a sus funciones principales. Por ejemplo, la robótica, así como los vehículos autónomos, se adoptan con mayor frecuencia en los sectores en los que la fabricación y la distribución desempeñan un papel importante, como la automoción y el montaje, y los bienes de consumo y el comercio minorista. Las capacidades de procesamiento del lenguaje natural, como la comprensión de textos, la comprensión del habla y la generación de textos, se adoptan con frecuencia en sectores con grandes volúmenes de datos operativos o de clientes en forma de texto, como los servicios empresariales, jurídicos y profesionales, los servicios financieros, la atención sanitaria y la alta tecnología y las telecomunicaciones.

ADOPCIÓN DE LA IA por INDUSTRIA, 2020

Fuente: McKinsey & Company, 2020 | Gráfica: Informe AI Index Report 2021




Figura 3.3.2

ADOPCIÓN DE LA IA por INDUSTRIA y FUNCIÓN, 2020

Fuente: McKinsey & Company, 2020 | Gráfica: Informe AI Index Report 2021

Industria	Recursos Humanos	Manufactura	Mercadeo y Ventas	Desarrollo de productos y servicios	Riesgo	Operaciones de servicios	Estrategia y finanzas corporativas	Gestión de cadena de suministros
Todos los sectores	8%	12%	15%	21%	10%	21%	7%	9%
Automotriz y ensamblaje	13%	29%	10%	21%	2%	16%	8%	18%
Negocios, legal y servicios profesionales	13%	9%	16%	21%	13%	20%	10%	9%
Bienes de consumo/ Minorista	1%	19%	20%	14%	3%	10%	2%	10%
Servicios financieros	5%	5%	21%	15%	32%	34%	7%	2%
Salud/Farmacéutica	3%	12%	16%	15%	4%	11%	2%	6%
Alta tecnología/Telecomunicaciones	14%	11%	26%	37%	14%	39%	9%	12%

% de encuestados

Figura 3.3.3

CAPACIDADES DE IA INCORPORADAS en los PROCESOS DE NEGOCIO ESTÁNDAR, 2020

Fuente: McKinsey & Company, 2020 | Gráfica: Informe AI Index Report 2021

Industria	Vehículos autónomos	Visión por ordenador	Interfaces de conversación IA	Aprendizaje profundo	Generación de lenguaje natural	Comprensión de habla lenguaje natural	Comprensión de texto lenguaje natural	Otras técnicas de aprendizaje automático	Robótica física	Automatización robótica de procesos
Todos los sectores	7%	18%	15%	16%	11%	12%	13%	23%	13%	22%
Automotriz y ensamblaje	20%	33%	16%	19%	12%	14%	19%	27%	31%	33%
Negocios, legal y servicios profesionales	7%	13%	17%	19%	14%	15%	18%	25%	11%	13%
Bienes de consumo/ Minorista	13%	10%	9%	6%	6%	6%	9%	12%	23%	14%
Servicios financieros	6%	18%	24%	19%	18%	19%	26%	32%	8%	37%
Salud/Farmacéutica	1%	15%	10%	14%	12%	11%	15%	19%	10%	18%
Alta tecnología/Telecomunicaciones	9%	34%	32%	30%	18%	25%	33%	37%	14%	34%

% de encuestados

Figura 3.3.4

Identificación y mitigación de riesgos de adoptar la IA

Solo una minoría de empresas reconoce los riesgos asociados a la IA, y aún menos informan de que están tomando medidas para mitigar esos riesgos (Figura 3.3.5 y Figura 3.3.6). En relación con 2019, la proporción de encuestados que citan cada riesgo como relevante se ha mantenido prácticamente plana; es decir, la mayoría de los cambios no fueron estadísticamente significativos. La ciberseguridad sigue siendo el único riesgo que la mayoría de los encuestados dice que sus organizaciones consideran relevante. Una serie de riesgos menos citados, como la seguridad nacional y la estabilidad política, eran más propensos a ser vistos como relevantes por las empresas en 2020 que en 2019.

A pesar de los crecientes llamamientos para atender a las preocupaciones éticas asociadas con el uso de la IA, los esfuerzos para abordar estas preocupaciones en la industria son limitados. Por ejemplo, preocupaciones como la equidad y la justicia en el uso de la IA siguen recibiendo comparativamente poca atención por parte de las empresas. Además, en 2020 menos empresas consideran que la privacidad personal o individual es un riesgo de la adopción de la IA en comparación con 2019, y no hay cambios en el porcentaje de encuestados cuyas empresas están tomando medidas para mitigar este riesgo en particular.

En relación con 2019, la proporción de encuestados que citan cada riesgo como relevante se ha mantenido prácticamente sin cambios; es decir, la mayoría de los cambios no fueron estadísticamente significativos. La ciberseguridad sigue siendo el único riesgo que la mayoría de los encuestados considera relevante para sus organizaciones.

RIESGOS de ADOPTAR IA QUE LAS EMPRESAS ESTÁN MITIGANDO, 2020

Fuente: McKinsey & Company, 2020 | Gráfica: Informe AI Index 2021




Figura 3.3.5

RIESGOS de ADOPTAR IA QUE LAS EMPRESAS ESTÁN MITIGANDO, 2020

Fuente: McKinsey & Company, 2020 | Gráfica: Informe AI Index 2021




Figura 3.3.6

El efecto del COVID-19

A pesar de la recesión económica provocada por la pandemia, la mitad de los encuestados afirmó que la pandemia no había afectado a su inversión en IA, mientras que el 27% declaró haber aumentado su inversión. Menos de una cuarta parte de las empresas redujo su inversión en IA (figura 3.3.7).⁵ Por sectores, los encuestados de los sectores sanitario y farmacéutico, así como de la automoción y el ensamblado, fueron los más propensos a informar de que sus empresas habían aumentado la inversión en IA.

A pesar de la recesión económica provocada por la pandemia, la mitad de los encuestados afirmaron que la pandemia no afectó a su inversión en IA, mientras que el 27% declaró haber aumentado su inversión.

CAMBIOS en la INVERSIÓN en IA DURANTE la PANDEMIA de COVID-19

Fuente: McKinsey & Company, 2020 | Gráfica: 2021 AI Index Report




Figura 3.3.7

⁵ La suma puede ser diferente al 100% debido a los redondeos.

INSTALACIONES DE ROBOT INDUSTRIALES

En la actualidad, la IA se está desplegando ampliamente en dispositivos de consumo como los teléfonos inteligentes y los vehículos personales (por ejemplo, la tecnología de autoconducción). Sin embargo, es relativamente poco lo que se ha desplegado en robots reales. « Esto puede cambiar a medida que los investigadores desarrollen software para integrar los enfoques basados en la IA con los robots contemporáneos. Por ahora, es posible medir las ventas mundiales de robots industriales para sacar conclusiones sobre la cantidad de infraestructura preparada para la IA que se está comprando en todo el mundo. Aunque la crisis económica inducida por el COVID-19 provocará un descenso de las ventas de robots a corto plazo, la Federación Internacional de Robótica (IFR) espera que la pandemia genere oportunidades de crecimiento mundial para la industria de la robótica a medio plazo.

Tendencia mundial

Después de seis años de crecimiento, el número de nuevos robots industriales instalados en todo el mundo disminuyó un 12%, pasando de 422.271 unidades en 2018 a 373.240 unidades en 2019 (Figura 3.3.8). El descenso es producto de las tensiones comerciales entre Estados Unidos y China, así como de los retos a los que se enfrentan las dos principales industrias clientes: la automotriz y la eléctrica/electrónica.

El sector de la automoción se sitúa a la cabeza (28% del total de instalaciones), seguido por el eléctrico/electrónico (24%), el de metales y maquinaria (12%), el de plásticos y productos químicos (5%) y el de alimentos y bebidas (3%).⁷ Es importante señalar que estas métricas son una medida de la infraestructura instalada susceptible de adoptar nuevas tecnologías de IA y no indican si cada nuevo robot utilizó una cantidad significativa de IA.

INSTALACIONES DE ROBOTS INDUSTRIALES EN EL MUNDO, 2012-19

Fuente: Federación Internacional de Robótica, 2020 | Gráfica: Informe AI Index 2021




Figura 3.3.8

⁶ Para obtener más información sobre la adopción de la IA y los robots por parte de la industria, lea el documento de trabajo de la Oficina Nacional de Investigación Económica basado en la Encuesta Anual de Empresas de 2018 de la Oficina del Censo de Estados Unidos "Advancing Technologies Adoption and Use by U.S. Firms: Evidence From the Annual Business Survey" (2020).

⁷ Hay que tener en cuenta que no hay información sobre el sector del cliente para aproximadamente el 20% de los robots instalados.

Comparación regional

Asia, Europa y Norteamérica -tres de los mayores mercados de robots industriales- fueron testigos del final de un período de crecimiento de seis años en las instalaciones de robots (Figura 3.3.9). Norteamérica experimentó el mayor descenso, del 16%, en 2019, frente al 5% de Europa y el 13% de Asia.

La figura 3.3.10 muestra el número de instalaciones en los cinco principales mercados de robots industriales. Los cinco -que representan el 73% de las instalaciones de robots a nivel mundial- experimentaron aproximadamente el mismo descenso, excepto Alemania, que experimentó un ligero repunte en las instalaciones entre 2018 y 2019. A pesar de la tendencia a la baja en China, cabe destacar que el país tenía más robots industriales en 2019 que los otros cuatro países juntos.

Asia, Europa y América del Norte -tres de los mayores mercados de robots industriales- fueron testigos del final de un período de crecimiento de seis años en las instalaciones de robots. Norteamérica experimentó el mayor descenso, del 16%, en 2019, frente al 5% de Europa y el 13% de Asia.

NUEVAS INSTALACIONES DE ROBOTS por REGIÓN, 2017-19

Fuente: Federación Internacional de Robótica, 2020 | Gráfica: Informe AI Index 2021




Figura 3.3.9

NUEVAS INSTALACIONES DE ROBOTS INDUSTRIALES por CINCO MERCADOS GRANDES, 2017-19

Fuente: Federación Internacional de Robótica, 2020 | Gráfica: Informe AI Index 2021




Figura 3.3.10

CONFERENCIAS DE REPORTES DE GANANCIAS

Las menciones a la IA en las convocatorias de beneficios de las empresas han aumentado considerablemente desde 2013, como muestra la figura 3.3.11. En 2020, el número de menciones a la IA en las convocatorias de beneficios fue dos veces mayor que las menciones a los big data, la nube y el aprendizaje automático combinados, aunque esa cifra disminuyó un 8,5% desde 2019. Las menciones de big data alcanzaron su punto máximo en 2017 y desde entonces han disminuido un 57%.

MENCIONES de IA en REPORTES de GANANCIAS, 2011-20

Fuente: Prattle y Liquidnet, 2020 | Gráfica: Informe AI Index 2021




Figura 3.3.11



CAPÍTULO 4: Educación en IA



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 4:

Vista previa del capítulo

Resumen	109	Nuevos doctorados por especialidad	115
Puntos clave del capítulo	110	Nuevos doctorados con especialidades en IA/ML y Robótica/Visión	117
4.1 LA ENSEÑANZA EN INSTITUCIONES DE EDUCACIÓN SUPERIOR	111	Empleo de nuevos doctores en Norteamérica	118
Oferta de cursos de grado en IA	111	Industria vs. Academia	118
Cursos de grado que enseñan habilidades de IA	111	Nuevos doctorados internacionales en IA	119
Cursos introductorios de IA y ML	111	4.3 EDUCACIÓN EN IA UNIÓN EUROPEA Y MÁS ALLÁ	120
Oferta de cursos de posgrado en IA	113	Oferta de educación en IA en EU27	120
Cursos de posgrado que enseñan habilidades de IA	113	Cursos relacionados con IA por contenido impartido	121
Académicos dedicados a la investigación en IA	113	Comparación internacional	122
4.2 EGRESADOS EN IA Y COMPUTACIÓN EN NORTEAMÉRICA	114	PUNTO CLAVE: FUGA DE CEREBROS EN IA Y EGRESOS DE LA ACADEMIA	123
Egresados de pregrado en Computación en Norteamérica	114		
Nuevos doctorados en Computación en Estados Unidos	114		

ACCESO A LOS DATOS

Resumen

A medida que la IA se ha convertido en un motor más importante de la actividad económica, ha aumentado el interés de las personas que quieren entenderla y obtener las cualificaciones necesarias para trabajar en este campo. Al mismo tiempo, el aumento de la demanda de IA por parte de la industria está tentado a más profesores a dejar el mundo académico por el sector privado. Este capítulo se centra en las tendencias de las competencias y la formación del talento en IA a través de diversas plataformas e instituciones educativas.

A continuación se examinan los datos de una encuesta del Índice de Inteligencia Artificial sobre el estado de la educación en IA en las instituciones de educación superior, junto con un debate sobre los graduados de licenciatura en ciencias de la computación (CS) y los graduados de doctorado que se especializaron en disciplinas relacionadas con la IA, basado en la encuesta anual Taulbee de la Asociación de Investigación Informática (CRA). La última sección explora las tendencias de la educación en IA en Europa, basándose en las estadísticas del Centro Común de Investigación (CCI) de la Comisión Europea.

PUNTOS CLAVE DEL CAPÍTULO

- Una encuesta del AI Index realizada en 2020 sugiere que las principales universidades del mundo han aumentado su inversión en la formación en IA en los últimos cuatro años. El número de cursos que enseñan a los estudiantes las habilidades necesarias para construir o desplegar un modelo práctico de IA en los niveles de pregrado y postgrado ha aumentado un 102,9% y un 41,7%, respectivamente, en los últimos cuatro años académicos.
- Según una encuesta anual de la Computing Research Association (CRA), en los últimos 10 años ha aumentado el número de doctores en IA en Norteamérica que han optado por trabajar en la industria, mientras que han sido menos los que han optado por el mundo académico. La proporción de nuevos doctores en IA que eligieron trabajos en la industria aumentó un 48% en la última década, del 44,4% en 2010 al 65,7% en 2019. Por el contrario, la proporción de nuevos doctores en IA que entraron en el mundo académico se redujo en un 44%, del 42,1% en 2010 al 23,7% en 2019.
- En los últimos 10 años, los doctorados relacionados con la IA han pasado del 14,2% del total de los doctorados en ciencias de la computación concedidos en Estados Unidos, a cerca del 23% a partir de 2019, según la encuesta de la CRA. Al mismo tiempo, otros doctorados en ciencias de la computación anteriormente populares han disminuido su popularidad, incluyendo las redes, la ingeniería de software y los lenguajes de programación. Los compiladores vieron una reducción en el número de doctorados concedidos en relación con 2010, mientras que las especialidades de IA y Robótica/Visión experimentaron un aumento sustancial.
- Después de un aumento de dos años, el número de salidas de profesores de IA de las universidades a puestos de trabajo en la industria en América del Norte se redujo de 42 en 2018 a 33 en 2019 (28 de ellos son profesores titulares y cinco no titulares). La Universidad Carnegie Mellon tuvo el mayor número de salidas de profesores de IA entre 2004 y 2019 (16), seguida por el Instituto de Tecnología de Georgia (14) y la Universidad de Washington (12).
- El porcentaje de estudiantes internacionales entre los nuevos doctores en IA en América del Norte siguió aumentando en 2019, hasta el 64,3%, un aumento del 4,3% con respecto a 2018. Entre los graduados extranjeros, el 81,8% se quedó en los Estados Unidos y el 8,6% ha aceptado trabajos fuera de los Estados Unidos.
- En la Unión Europea, la gran mayoría de las ofertas académicas especializadas en IA se imparten a nivel de máster; la robótica y la automatización es, con mucho, el curso más frecuente en los programas de licenciatura y máster especializados, mientras que el aprendizaje automático (ML) domina en los cursos cortos especializados.

4.1 LA ENSEÑANZA EN IA EN INSTITUCIONES DE EDUCACIÓN SUPERIOR

En 2020, el AI Index elaboró una encuesta en la que se preguntaba a los departamentos de ciencias de la computación o a las facultades de informática de las mejores universidades del mundo y de las economías emergentes sobre cuatro aspectos de su formación en IA: oferta de programas de grado, oferta de programas de posgrado, oferta de ética de la IA y experiencia y diversidad del profesorado. La encuesta fue completada por 18 universidades de nueve países.¹ Los resultados de la encuesta del Índice de Inteligencia Artificial indican que las universidades han aumentado tanto el número de cursos de Inteligencia Artificial que ofrecen y que enseñan a los estudiantes cómo construir y desplegar un modelo práctico de Inteligencia Artificial como el número de profesores centrados en la Inteligencia Artificial.

OFERTA DE CURSOS DE PREGRADO

La oferta de cursos a nivel de licenciatura se examinó evaluando las tendencias de los cursos que enseñan a los estudiantes las habilidades necesarias para construir o desplegar un modelo práctico de IA, los cursos de introducción a la IA y el ML, y las estadísticas de inscripción.

Cursos de pregrado que enseñan habilidades de IA

Los resultados de la encuesta sugieren que los departamentos de CS han invertido mucho en

NÚMERO de CURSOS de GRADO QUE ENSEÑAN LAS COMPETENCIAS NECESARIAS para CONSTRUIR o DESPLEGAR un MODELO DE IA PRÁCTICO, AÑO ACADÉMICO 2016-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 4.1.1

cursos prácticos de IA en los últimos cuatro años académicos (AY).² El número de cursos ofrecidos que enseñan a los estudiantes las habilidades necesarias para construir o desplegar un modelo práctico de IA ha aumentado en un 102,9%, de 102 en AY 2016-17 a 207 en AY 2019-20, en 18 universidades (Figura 4.1.1).

Cursos introductorios en IA y ML

Los datos muestran que el número de estudiantes que se han matriculado o han intentado matricularse en un curso de Introducción a la Inteligencia Artificial y en un curso de Introducción al Aprendizaje Automático se ha disparado casi un 60% en los últimos cuatro años académicos (Figura 4.1.2).³

¹ La encuesta se distribuyó a 73 universidades en línea a lo largo de tres oleadas, desde noviembre de 2020 hasta enero de 2021, y fue completada por 18 universidades, lo que supone una tasa de respuesta del 24,7%. Las 18 universidades son: Bélgica: Katholieke Universiteit Leuven; Canadá: McGill University; China: Shanghai Jiao Tong University, Tsinghua University; Alemania: Universidad Ludwig Maximilian de Munich, Universidad Técnica de Munich; Rusia: Escuela Superior de Economía, Instituto de Física y Tecnología de Moscú; Suiza: École Polytechnique Fédérale de Lausanne; Reino Unido: Universidad de Cambridge; Estados Unidos: California Institute of Technology, Carnegie Mellon University (Department of Machine Learning), Columbia University, Harvard University, Stanford University, University of Wisconsin-Madison, University of Texas at Austin, Yale University.

² Vea aquí una lista de palabras clave sobre modelos prácticos de inteligencia artificial que se proporcionó a los encuestados. Un curso se define como un conjunto de clases que requieren un mínimo de 2,5 horas lectivas (incluyendo conferencia, laboratorio, horas de AT, etc.) por semana durante al menos 10 semanas en total. Los cursos múltiples con los mismos títulos y números cuentan como un solo curso.

³ En el caso de las universidades que tienen un límite de inscripción en los cursos, se incluye el número de estudiantes que intentaron inscribirse en los cursos de introducción a la IA y el ML.

El ligero descenso de la matrícula en los cursos de IA y ML de nivel introductorio en el curso académico 2019-20 se debe principalmente a la disminución del número de ofertas de cursos en las universidades estadounidenses. La matrícula de cursos de nivel introductorio en la Unión Europea ha aumentado gradualmente un 165% en los últimos cuatro años académicos, mientras que dicha matrícula en los Estados Unidos ha visto un claro descenso en el crecimiento en el último año académico (Figura 4.1.3). Seis de las ocho universidades estadounidenses encuestadas afirman que el número de matrículas (intentadas) para los cursos de introducción a la IA y el ML ha disminuido en el último año. Algunas universidades citaron a los estudiantes que se tomaron licencias durante la pandemia como la causa principal del descenso; otras mencionaron cambios estructurales en la oferta de cursos de introducción a la IA -como la creación de Intro to Data Science el año pasado- que pueden haber alejado a los estudiantes de los cursos tradicionales de introducción a la IA y el ML.

NÚMERO de ESTUDIANTES INSCRITOS o que INTENTÓ INSCRIBIRSE en CURSOS de INTRODUCCIÓN a IA y ML, AÑO ACADÉMICO 2016-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 4.1.2

CAMBIO PORCENTUAL en la CANTIDAD de ESTUDIANTES INSCRITOS o que INTENTÓ INSCRIBIRSE en INTRODUCCIÓN a IA y a ML por ZONA GEOGRÁFICA, AÑO ACADÉMICO 2016-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 4.1.3

OFERTA DE CURSOS DE POSGRADO EN IA

La encuesta también examina la oferta de cursos a nivel de posgrado o de titulación avanzada, concretamente los cursos de posgrado que enseñan a los estudiantes las habilidades necesarias para construir o desplegar un modelo práctico de IA.⁴

Cursos de posgrado que enseñan habilidades en IA

Las ofertas de posgrado que enseñan a los estudiantes las habilidades necesarias para construir o desplegar un modelo práctico de IA aumentaron un 41,7% en los últimos cuatro años académicos, de 151 cursos en el AY 2016-17 a 214 en el AY 2019-20 (Figura 4.1.4).

ACADÉMICOS INVESTIGANDO LA IA

Como se muestra en la Figura 4.1.5, el número de profesores titulares con un enfoque de investigación principal en la IA en las universidades encuestadas creció significativamente en los últimos cuatro años académicos, en consonancia con la creciente demanda de clases y programas de grado de IA. El número de profesores centrados en la IA creció un 59,1%, de 105 en el año académico 2016-17 a 167 en el año académico 2019-20.

NÚMERO de CURSOS DE POSGRADO QUE ENSEÑAN LAS COMPETENCIAS NECESARIAS PARA CONSTRUIR O DESPLEGAR UN MODELO DE IA, AÑO ACADÉMICO 2016-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 4.1.4

CANTIDAD DE PROFESORES TITULARES QUE SE DEDICAN A INVESTIGAR IA PRINCIPALMENTE, AÑO ACADÉMICO 2016-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 4.1.5

⁴ Véase aquí la lista de palabras clave sobre modelos prácticos de inteligencia artificial que se proporcionó a los encuestados. Un curso se define como un conjunto de clases que requieren un mínimo de 2,5 horas lectivas (incluyendo conferencia, laboratorio, horas de AT, etc.) por semana durante al menos 10 semanas en total. Los cursos múltiples con los mismos títulos y números cuentan como un solo curso.

Esta sección presenta los resultados de la encuesta anual Taulbee de la Computing Research Association (CRA). La encuesta anual de la CRA documenta las tendencias en la matriculación de estudiantes, la producción de títulos, el empleo de los graduados y los salarios del profesorado en las unidades académicas de Estados Unidos y Canadá que conceden títulos de doctorado en informática (CS), ingeniería informática (CE) o información (I). Las unidades académicas incluyen departamentos de ciencias de la computación e ingeniería informática o, en algunos casos, facultades o escuelas de información o computación.

4.2 EGRESADOS EN IA Y COMPUTACIÓN EN NORTEAMÉRICA

EGRESADOS DE PREGRADO EN COMPUTACIÓN EN NORTEAMÉRICA

La mayoría de los cursos relacionados con la IA en Norteamérica forman parte de la oferta de cursos de CS a nivel de licenciatura.

⁵ El número de nuevos licenciados en CS en instituciones de doctorado en Norteamérica ha crecido de forma constante en los últimos 10 años (Figura 4.2.1). Más de 28.000 graduados en CS en 2019, alrededor de tres veces más que el número en 2010.

NUEVOS DOCTORADOS EN COMPUTACIÓN EN ESTADOS UNIDOS

La sección examina la tendencia de los graduados de doctorado en ciencias de la computación en Estados Unidos, centrándose en los que tienen especialidades relacionadas con la IA. La encuesta de la CRA incluye 20 especialidades en total, dos de las cuales están directamente relacionadas con el campo de la IA, incluyendo “inteligencia artificial/aprendizaje de máquinas” y “robótica/visión”.

NÚMERO de NUEVOS ESTUDIANTES de PREGRADO EGRESADOS de INSTITUCIONES DOCTORALES en NORTEAMÉRICA, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.1

⁵ Los nuevos doctores en ciencias de la computación de esta sección incluyen a los graduados de doctorado de unidades académicas (departamentos, facultades o escuelas dentro de las universidades) de ciencias de la computación en Estados Unidos.

NUEVOS DOCTORADOS POR ESPECIALIDAD

Entre todos los graduados de doctorado en ciencias de la computación en 2019, los que se especializaron en inteligencia artificial/aprendizaje automático (22,8%), teoría y algoritmos (8,0%) y robótica/visión (7,3%) encabezan la lista (Figura 4.2.2). La especialidad de IA/ML ha sido la más popular en la última década, y el número de graduados en IA/ML en 2019 es mayor que el de las siguientes cinco especialidades juntas. Además, la robótica/visión saltó de la octava especialización más popular en 2018 a la tercera en 2019.

A lo largo de los últimos 10 años, la IA/ML y la robótica/visión son las especializaciones de doctorado en CS que muestran el crecimiento más significativo, en relación con otras 18 especializaciones (Figura 4.2.3). El porcentaje de doctores en ciencias de la computación especializados en IA/ML entre todos los nuevos doctores en ciencias de la computación en 2020 es 8,6 puntos porcentuales (pp) mayor que en 2010, seguido por los doctores especializados en robótica/visión con 2,4 pp. Por el contrario, la proporción de doctores en ciencias de la computación especializados en redes (-4,8 puntos porcentuales), ingeniería de software (-3,6 puntos porcentuales) y lenguajes de programación/compiladores (-3,0 puntos porcentuales) experimentarán un crecimiento negativo en 2020.

NUEVOS DOCTORES EN COMPUTACIÓN (% del TOTAL) en los EE.UU. por ESPECIALIDAD, 2019

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021





Figura 4.2.2

CAMBIOS EN PUNTOS PORCENTUALES en NUEVOS DOCTORES EN COMPUTACIÓN en los EE.UU. de 2010 a 2019 por ESPECIALIDAD

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021



Cambio en puntos porcentuales en nuevos Doctores en Computación

Figura 4.2.3

NUEVOS DOCTORADOS CON ESPECIALIDADES EN IA/ML Y ROBÓTICA/VISIÓN

La Figura 4.2.4a y la Figura 4.2.4b examinan con más detalle el número de doctorados recientes en IA especializados en IA/ML o robótica/visión en Estados Unidos. Entre 2010 y 2019, el número de graduados centrados en IA/ML creció un 77%, mientras que el porcentaje de estos nuevos doctores entre todos los graduados de doctorado en CS aumentó un 61%. El número de graduados de doctorado tanto en IA/ML como en robótica/visión alcanzó un máximo histórico en 2019.

NUEVOS DOCTORES EN COMPUTACIÓN CON ESPECIALIDAD EN IA/ML y ROBÓTICA/VISIÓN en los ESTADOS UNIDOS, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.4a

NUEVOS DOCTORES EN COMPUTACIÓN (% del TOTAL) CON ESPECIALIDAD EN IA/ML y ROBÓTICA/VISIÓN en los ESTADOS UNIDOS, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.4b

EMPLEO DE NUEVOS DOCTORES EN NORTEAMÉRICA

¿Dónde eligen trabajar los nuevos doctores en IA? Esta sección recoge las tendencias de empleo de los nuevos doctores en IA en el mundo académico y en la industria en toda Norteamérica.⁶

Industria vs. Academia

En los últimos 10 años, el número de nuevos graduados de doctorado en IA en Norteamérica que eligieron trabajos en la industria sigue creciendo, ya que su proporción aumentó un 48%, del 44,4% en 2010 al 65,7% en 2019 (Figura 4.2.5a y Figura 4.2.5b). Por el contrario, la proporción de nuevos doctores en IA que entran en el mundo académico se redujo en un 44%, pasando del 42,1% en 2010 al 23,7% en 2019. Como se desprende de la Figura 4.2.5b, estos cambios reflejan en gran medida el hecho de que el número de graduados de doctorado que entran en el mundo académico se ha mantenido más o menos nivelado a lo largo de la década, mientras que el gran aumento de la producción de doctorados está siendo absorbido principalmente por la industria.

EMPLEO de NUEVOS DOCTORES EN IA en la ACADEMIA o la INDUSTRIA en NORTE AMÉRICA, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.5a

EMPLEO de NUEVOS DOCTORES EN IA (% del TOTAL) en la ACADEMIA o la INDUSTRIA en NORTE AMÉRICA, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.5b

⁶ Los nuevos doctores en IA de esta sección incluyen a los graduados de doctorado que se especializan en inteligencia artificial de las unidades académicas (departamentos, facultades o escuelas dentro de las universidades) de ciencias de la computación, ingeniería informática e información en los Estados Unidos y Canadá.

NUEVOS DOCTORES INTERNACIONALES EN IA (% del TOTAL DE NUEVOS DOCTORES) en NORTEAMÉRICA, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.6

NUEVOS DOCTORADOS INTERNACIONALES EN IA

El porcentaje de estudiantes internacionales entre los nuevos graduados de doctorado en IA en América del Norte siguió aumentando en 2019, hasta el 64,3%, un aumento de 4,3 puntos porcentuales desde 2018 (Figura 4.2.6). A modo de comparación, de todos los doctores con un área de especialidad conocida, el 63,4% de los ingenieros informáticos, el 59,6% de los informáticos y el 29,5% de los receptores de información son estudiantes internacionales en 2019.

Además, entre los graduados extranjeros de doctorado en IA en 2019 en los Estados Unidos específicamente, el 81,8% se quedó en los Estados Unidos para trabajar y el 8,6% ha tomado trabajos fuera de los Estados Unidos (Figura 4.2.7). En comparación, entre todos los estudiantes internacionales graduados con especialidades conocidas, el 77,9% se ha quedado en los Estados Unidos, mientras que el 10,4% se empleó en otro lugar.

NUEVOS DOCTORES EN IA (% del TOTAL) en EE.UU por UBICACIÓN DE EMPLEO, 2019

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 4.2.7

Esta sección presenta una investigación del Centro Común de Investigación de la Comisión Europea que evaluó la oferta académica de competencias digitales avanzadas en 27 Estados miembros de la Unión Europea, así como en otros seis países: Reino Unido, Noruega, Suiza, Canadá, Estados Unidos y Australia. Este fue el segundo estudio de este tipo,⁷ y la versión de 2020 abordó cuatro dominios tecnológicos: inteligencia artificial (IA), computación de alto rendimiento (HPC), ciberseguridad (CS) y ciencia de los datos (DS), aplicando técnicas de minería de textos y aprendizaje automático para extraer contenidos relacionados con los programas de estudio que abordan los dominios específicos. Vea los informes [“Academic Offer of Advanced Digital Skills in 2019–20. International Comparison”](#) y [“Estimation of Supply and Demand of Tertiary Education Places in Advanced Digital Profiles in the EU,”](#) para obtener información más detallada.

4.3 EDUCACIÓN EN IA EN LA UNIÓN EUROPEA Y MÁS ALLÁ

OFERTA DE EDUCACIÓN EN IA EN EU27

El estudio reveló un número total de 1.032 programas de IA en todos los ámbitos y niveles de los programas en los 27 países de la UE (figura 4.3.1). La inmensa mayoría de las ofertas académicas especializadas en IA en la UE se imparten en el

nivel de máster, que da lugar a una titulación que equipa a los estudiantes con sólidas competencias para la mano de obra. Alemania es el país que más programas especializados en IA ofrece, seguido de los Países Bajos, Francia y Suecia. Francia encabeza la lista de países que ofrecen el mayor número de programas de IA a nivel de máster.

NÚMERO DE PROGRAMAS ESPECIALIZADOS EN IA EN EL UE27, 2019-20

Fuente: Centro de Investigación Conjunta, Comisión Europea, 2020 | Gráfica: Informe AI Index 2021




Figura 4.3.1

⁷ Se debe tener en cuenta que el informe de 2020 introdujo mejoras metodológicas con respecto a la versión de 2019, por lo que no es posible una comparación estricta. Las mejoras incluyen la eliminación de ciertas palabras clave y la adición de otras para identificar los programas. Aun así, más del 90% de todos los programas detectados en la edición de 2020 proceden de palabras clave presentes en el estudio de 2019.

Cursos relacionados con IA por contenido impartido

¿Qué tipos de tecnologías de IA son los más populares entre la oferta de cursos de los tres niveles de programas especializados en IA en la Unión Europea? Los datos sugieren que la robótica y la automatización son, con diferencia, los cursos que más se imparten en los programas especializados de grado y máster, mientras que el aprendizaje automático domina en los cursos cortos especializados (figura 4.3.2). Dado que los cursos cortos se dirigen a profesionales en activo, la tendencia muestra que el aprendizaje automático se ha convertido en una de las competencias clave en el desarrollo profesional y la aplicación de la IA.

También es importante mencionar el papel de la ética de la IA y las aplicaciones de la IA, ya que ambas áreas de contenido reclaman una parte significativa de la oferta educativa entre los tres niveles del programa. La ética de la IA -que incluye cursos sobre seguridad, protección, responsabilidad y explicabilidad- representa el 14% del plan de estudios por término medio, mientras que las aplicaciones de la IA -como los cursos sobre big data, internet de las cosas y realidad virtual- ocupan una parte similar por término medio.

NÚMERO de PROGRAMAS ESPECIALIZADOS en IA por TEMA, 2019-20

Fuente: Centro de Investigación Conjunta, Comisión Europea, 2020 | Gráfica: Informe AI Index 2021




Figura 4.3.2

COMPARACIÓN INTERNACIONAL

El informe del CCI comparó la educación en IA en los 27 estados miembros de la UE con otros países de Europa, incluidos Noruega, Suiza y el Reino Unido, así como Canadá, Estados Unidos y Australia. La figura 4.3.3 muestra el número total de 1.680 programas especializados en IA en todos los países considerados en el año académico 2019-20. Estados Unidos parece haber ofrecido más programas especializados en IA que cualquier otra zona geográfica, aunque la UE27 ocupa un cercano segundo lugar en cuanto al número de programas de máster especializados en IA.

Estados Unidos parece haber ofrecido más programas especializados en IA que cualquier otra zona geográfica, aunque la UE27 le sigue de cerca en cuanto al número de programas de máster especializados en IA.

NÚMERO de PROGRAMAS ESPECIALIZADOS en IA por ZONA GEOGRÁFICA y NIVEL, 2019-20

Fuente: Centro de Investigación Conjunta, Comisión Europea, 2020 |Gráfica: Informe AI Index 2021




Figura 4.3.3

Fuga de cerebros en IA y salida del profesorado

Michael Gofman y Zhao Jin, investigadores de la Universidad de Rochester y de la Escuela de Negocios Cheung Kong, respectivamente, publicaron un artículo en 2019 titulado “Artificial Intelligence, Education, and Entrepreneurship” el cual explora la relación entre el conocimiento de dominios específicos de los estudiantes universitarios y su capacidad para crear startups y atraer financiación.⁸ Para determinar la fuente de variación de los conocimientos específicos de IA de los estudiantes, los coautores utilizaron la salida de profesores de IA -lo que denominaron “una fuga de cerebros sin precedentes”- de las universidades a la industria

entre 2004 y 2018. Se basaron en datos recogidos a mano de LinkedIn, así como en la afiliación de los autores de la base de datos Scopus de publicaciones académicas y conferencias para complementar los resultados de la búsqueda en LinkedIn.

El documento encontró que las salidas de los profesores de IA tienen un efecto negativo en las startups de IA fundadas por los estudiantes que se gradúan de las universidades donde esos profesores solían trabajar, y los investigadores señalan un efecto escalofriante en los futuros empresarios de IA en los años posteriores a las salidas de los profesores. Los estudiantes de doctorado son los más afectados,

NÚMERO DE EGRESOS DE PROFESORES de IA en NORTEAMÉRICA, 2004-19

Fuente: Gofman y Jin, 2020 | Gráfica: Informe AI Index 2021




Figura 4.4.1

⁸ Vea “AI Brain Drain Index” para más detalles.

Fuga de cerebros en IA y egresos de la Academia (continuación)

en comparación con los estudiantes de grado y de máster, y el impacto negativo se intensifica cuando los profesores de IA que se van son sustituidos por profesores de escuelas de menor rango o por profesores de IA no titulares.

Con los datos actualizados de 2019 de Gofman y Jin, la figura 4.4.1 muestra que, tras un aumento de dos años, el número total de salidas de profesores

de IA de las universidades de Norteamérica hacia la industria se redujo de 42 en 2018 a 33 en 2019 (28 de ellos son profesores titulares y 5 no titulares). Entre 2004 y 2019, la Universidad Carnegie Mellon tuvo el mayor número de salidas de profesores de IA en 2019 (16), seguida por el Instituto de Tecnología de Georgia (14) y la Universidad de Washington (12), como se muestra en la figura 4.4.2.

NÚMERO DE EGRESOS DE PROFESORES de IA en NORTEAMÉRICA (con AFILIACIÓN ACADÉMICA) por UNIVERSIDAD, 2004-18

Fuente: Gofman y Jin, 2020 | Gráfica: Informe AI Index 2021




Figura 4.4.2



CAPÍTULO 5: Desafíos éticos de las aplicaciones de la IA



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 5:

Vista previa del capítulo

Resumen 127

Puntos clave del capítulo 128

5.1 PRINCIPIOS Y MARCOS PARA IA 129

**5.2 NOTICIAS EN LOS MEDIOS
DEL MUNDO 131**

5.3 ÉTICA EN CONFERENCIAS 132

**5.4 LA ÉTICA DENTRO DE LA OFERTA DE
EDUCACIÓN SUPERIOR 134**

ACCESO A LOS DATOS

Resumen

A medida que las innovaciones impulsadas por la inteligencia artificial se vuelven cada vez más frecuentes en nuestras vidas, los desafíos éticos de las aplicaciones de la IA son cada vez más evidentes y están sujetos al escrutinio. Como se ha señalado en los capítulos anteriores, el uso de diversas tecnologías de IA puede tener consecuencias no deseadas pero perjudiciales, como la intrusión en la privacidad, la discriminación por motivos de género, raza/etnia, orientación sexual o identidad de género, y la opacidad en la toma de decisiones, entre otras cuestiones. Nunca ha sido tan importante abordar los retos éticos existentes y crear innovaciones de IA responsables y justas antes de que se desplieguen.

En este capítulo se abordan los esfuerzos para abordar las cuestiones éticas que han surgido junto con el aumento de las aplicaciones de IA. En primer lugar, se examina la reciente proliferación de documentos que recogen los principios y marcos éticos de la IA, así como la forma en que los medios de comunicación cubren las cuestiones éticas relacionadas con la IA. A continuación, se revisa la investigación relacionada con la ética presentada en las conferencias sobre IA y el tipo de cursos de ética que ofrecen los departamentos de ciencias de la computación (CS) en las universidades de todo el mundo.

El equipo del AI Index se sorprendió al descubrir la poca información que existe sobre este tema. Aunque varios grupos están produciendo una serie de resultados cualitativos o normativos en el ámbito de la ética de la IA, el campo generalmente carece de puntos de referencia que puedan utilizarse para medir o evaluar la relación entre los debates sociales más amplios sobre el desarrollo de la tecnología y el desarrollo de la propia tecnología. Un benchmark, tratado en el capítulo de rendimiento técnico, es el estudio del Instituto Nacional de Estándares y Tecnología sobre el rendimiento del reconocimiento facial centrado en el sesgo. Averiguar cómo crear más datos cuantitativos supone un reto para la comunidad investigadora, pero es algo útil en lo que centrarse. Los responsables políticos son muy conscientes de las preocupaciones éticas relacionadas con la IA, pero les resulta más fácil gestionar lo que pueden medir, por lo que encontrar formas de traducir los argumentos cualitativos en datos cuantitativos es un paso esencial en el proceso.

PUNTOS CLAVE DEL CAPÍTULO

- El número de artículos con palabras clave relacionadas con la ética en los títulos presentados a las conferencias de IA ha crecido desde 2015, aunque el número medio de títulos de artículos que coinciden con palabras clave relacionadas con la ética en las principales conferencias de IA sigue siendo bajo a lo largo de los años.
- Las cinco noticias que más atención recibieron en 2020 relacionadas con el uso ético de la IA fueron la publicación del libro blanco de la Comisión Europea sobre la IA, el despido por parte de Google del investigador de ética Timnit Gebru, el comité de ética de la IA formado por las Naciones Unidas, el plan de ética de la IA del Vaticano y la salida de IBM del negocio del reconocimiento facial.

5.1 PRINCIPIOS Y MARCOS DE LA IA

Desde 2015, los gobiernos, las empresas privadas, las organizaciones intergubernamentales y las organizaciones de investigación y profesionales han elaborado documentos normativos que trazan los enfoques para gestionar los desafíos éticos de las aplicaciones de la IA. Estos documentos, que incluyen principios, directrices y otros, proporcionan marcos para abordar las preocupaciones y evaluar las estrategias relacionadas con el desarrollo, la implementación y el gobierno de la IA en diversas organizaciones. Algunos temas comunes que surgen de estos principios y marcos de la IA son la privacidad, la responsabilidad, la transparencia y la explicabilidad.

La publicación de los principios de la IA indica que las organizaciones están prestando atención y estableciendo una visión para la gobernanza de la IA. Sin embargo, la proliferación de los llamados principios éticos ha sido criticada por los investigadores de ética y los profesionales de los derechos humanos que se oponen al uso impreciso de los términos relacionados con la ética. Los críticos también señalan que carecen de marcos institucionales y no son vinculantes en la mayoría de los casos. La naturaleza vaga y abstracta de esos principios no ofrece orientación sobre cómo aplicar las directrices éticas relacionadas con la IA.

Los investigadores del AI Ethics Lab de Boston crearon una Toolbox que rastrea el creciente cuerpo de principios de la IA. Entre 2015 y 2020 se publicaron un total de 117 documentos relacionados con los principios de la IA. Los datos muestran que las organizaciones profesionales y de investigación fueron de las primeras en desplegar documentos sobre principios de la IA, y que las empresas privadas son las que más han publicado hasta la fecha sobre principios de la IA entre todos los tipos de organizaciones (figura 5.1.1). Europa y Asia Central tienen el mayor número de publicaciones hasta 2020 (52), seguidas de América del Norte (41) y Asia Oriental y el Pacífico (14), según la figura 5.1.2. En lo que respecta al despliegue de los principios éticos, 2018 fue el año en que las empresas tecnológicas -incluidas IBM, Google y Facebook-, así como varios organismos gubernamentales del Reino Unido, la UE y Australia, marcaron claramente el punto álgido.

Europa y Asia Central tienen el mayor número de publicaciones hasta 2020 (52), seguidas de América del Norte (41) y Asia Oriental y el Pacífico (14). En lo que respecta al despliegue de los principios éticos, 2018 fue el año en el que las empresas tecnológicas -incluidas IBM, Google y Facebook-, así como varios organismos gubernamentales del Reino Unido, la UE y Australia, marcaron claramente el punto álgido.

NÚMERO de PRINCIPIOS ÉTICOS NUEVOS EN IA por TIPO DE ORGANIZACIÓN, 2015-20

Fuente: AI Ethics Lab, 2020 |Gráfica: Informe AI Index 2021




Figura 5.1.1

NÚMERO de PRINCIPIOS ÉTICOS NUEVOS EN IA por REGIÓN, 2015-20

Fuente: AI Ethics Lab, 2020 |Gráfica: Informe AI Index 2021




Figura 5.1.2

5.2 NOTICIAS EN LOS MEDIOS DEL MUNDO

¿Cómo han cubierto los medios de comunicación el tema del uso ético de las tecnologías de IA? En esta sección se han analizado los datos de NetBase Quid, que busca en la base de datos de noticias archivadas de LexisNexis artículos que hablen de la ética de la IA¹, analizando 60.000 fuentes de noticias en inglés y más de 500.000 blogs en 2020.

La búsqueda encontró 3.047 artículos relacionados con las tecnologías de IA que incluyen términos como “derechos humanos”, “valores humanos”, “responsabilidad”, “control humano”, “equidad”, “discriminación” o “no discriminación”, “transparencia”, “explicabilidad”, “seguridad y protección”, “responsabilidad” y “privacidad”. NetBase Quid agrupó las narrativas mediáticas resultantes en siete grandes temas basados en la similitud del lenguaje.

La figura 5.2.1 muestra que los artículos relacionados con la orientación y los marcos éticos de la IA encabezaron la lista de las noticias más cubiertas (21%) en 2020, seguidos por la investigación y la educación (20%), y el reconocimiento facial (20%).

Los cinco temas de las noticias que recibieron más atención en 2020 relacionados con el uso ético de la IA fueron:

1. La publicación del libro blanco de la Comisión Europea sobre la IA (5,9%)
2. El despido por parte de Google del investigador de ética Timnit Gebru (3,5%)
3. El comité de ética de la IA formado por las Naciones Unidas (2,7%)
4. El plan de ética de la IA del Vaticano (2,6%)
5. La salida de IBM de los negocios de reconocimiento facial (2,5%).

NOTICIAS SOBRE ÉTICA EN IA (% del TOTAL) por TEMA, 2020

Fuente: CAPIQ, Crunchbase, and NetBase Quid, 2020 | Gráfica: Informe AI Index Report 2021




Figura 5.2.1

¹ La metodología para ello consiste en buscar artículos que contengan palabras clave relacionadas con la ética de la IA, según un estudio de investigación de Harvard.

5.3 ÉTICA EN CONFERENCIAS DE IA

Los investigadores están escribiendo más artículos que se centran directamente en la ética de la IA, con presentaciones en esta área más que duplicadas desde 2015 hasta 2020. Para medir el papel de la ética en la investigación de la IA, los investigadores de la Universidad Federal de Rio Grande do Sul en Porto Alegre, Brasil, buscaron términos relacionados con la ética en los títulos de los trabajos de las principales conferencias sobre IA, aprendizaje automático y robótica. Como muestra la Figura 5.3.1, ha habido un aumento significativo en el número de artículos con palabras clave relacionadas con la ética en los títulos presentados a las conferencias de IA desde 2015.

Un análisis más detallado en la Figura 5.3.2 muestra el número medio de coincidencias de palabras clave a lo largo de todas las publicaciones entre las seis principales conferencias de IA. A pesar de las crecientes menciones en el gráfico anterior, el número promedio de títulos de documentos que coinciden con palabras clave relacionadas con la ética en las principales conferencias de IA sigue siendo bajo a lo largo de los años.

Sin embargo, se avecinan cambios en las conferencias de IA. A partir de 2020, el tema de la ética se integró más estrechamente en las actas de las conferencias. Por ejemplo, la conferencia de Sistemas de Procesamiento de Información Neuronal (NeurIPS), una de las mayores conferencias de investigación de IA en el mundo, pidió a los investigadores que presentaran declaraciones de “Impactos más amplios” junto con su trabajo por primera vez en 2020, lo que llevó a una mayor integración de las preocupaciones éticas en el trabajo técnico. Además, recientemente han proliferado las conferencias y talleres que se centran específicamente en la IA responsable, como la nueva Conferencia sobre Inteligencia Artificial, Ética y Sociedad de la Asociación para el Avance de la Inteligencia Artificial y la Conferencia sobre Equidad, Responsabilidad y Transparencia de la Asociación de Maquinaria Informática.

Ha habido un aumento significativo en el número de trabajos con palabras clave relacionadas con la ética en los títulos presentados a las conferencias de IA desde 2015. Un análisis más detallado muestra el número medio de coincidencias de palabras clave en todas las publicaciones entre las seis principales conferencias de IA.

NÚMERO DE TÍTULOS DE ARTÍCULOS MENCIONANDO PALABRAS CLAVE DE ÉTICA en CONFERENCIAS de IA, 2000-19

Fuente: Prates y cols., 2018 | Gráfica: Informe AI Index 2021




Figura 5.3.1

PROMEDIO DE TÍTULOS DE ARTÍCULOS QUE MENCIONAN PALABRAS CLAVE DE ÉTICA en GRANDES CONFERENCIAS DE IA SELECCIONADAS, 2000-19

Fuente: Prates et al., 2018 | Gráfica: 2021 AI Index Report




Figura 5.3.2

5.4 LA ÉTICA DENTRO DE LA OFERTA DE EDUCACIÓN SUPERIOR

El capítulo 4 introdujo una encuesta en los departamentos o escuelas de informática de las principales universidades del mundo para evaluar el estado de la enseñanza de la IA en las instituciones de educación superior.² En parte, la encuesta preguntaba si el departamento de ciencias de la computación o la universidad ofrece la oportunidad de aprender sobre el aspecto ético de la IA y la computación. Entre las 16 universidades que completaron la encuesta, 13 informaron de algún tipo de oferta relevante.

La figura 5.4.1 muestra que 11 de los 18 departamentos informan de que organizan eventos o mesas redondas sobre la ética de la IA, mientras que 7 de ellos ofrecen cursos independientes sobre la ética de la IA en CS u otros departamentos de su universidad. Algunas universidades también ofrecen clases de ética en el campo de las ciencias de la computación en general, incluyendo cursos independientes de ética en CS o módulos de ética integrados en el plan de estudios de CS que ofrecen.³

11 de los 18 departamentos informan de que organizan eventos o mesas redondas sobre la ética de la IA, mientras que 7 de ellos ofrecen cursos independientes sobre la ética de la IA en CS u otros departamentos de su universidad.

ACTIVIDAD QUE TRATAN LA ÉTICA EN IA COMO TEMA EN DEPARTAMENTOS DE COMPUTACIÓN en UNIVERSIDADES TOP en el MUNDO, AÑO ACADÉMICO 2019-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021





Figura 5.4.1

² La encuesta se distribuyó a 73 universidades en línea a lo largo de tres oleadas, desde noviembre de 2020 hasta enero de 2021, y fue completada por 18 universidades, lo que supone una tasa de respuesta del 24,7%. Las 18 universidades son: Bélgica: Katholieke Universiteit Leuven; Canadá: McGill University; China: Shanghai Jiao Tong University, Tsinghua University; Alemania: Universidad Ludwig Maximilian de Munich, Universidad Técnica de Munich; Rusia: Escuela Superior de Economía, Instituto de Física y Tecnología de Moscú; Suiza: École Polytechnique Fédérale de Lausanne; Reino Unido: Universidad de Cambridge; Estados Unidos: California Institute of Technology, Carnegie Mellon University (Department of Machine Learning), Columbia University, Harvard University, Stanford University, University of Wisconsin-Madison, University of Texas at Austin, Yale University.

³ La encuesta no mostraba la opción "módulos de ética integrados en los cursos de informática" de forma explícita. Las selecciones se rellenaron en la opción "Otros". Esto se incluirá en la encuesta del próximo año.



CAPÍTULO 6: Diversidad en IA



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 6:

Vista previa del capítulo

Resumen	137	por raza y etnicidad	144
Puntos clave del capítulo	138	Nuevos doctores en computación en los Estados Unidos por raza/etnicidad	145
6.1 DIVERSIDAD DE GÉNERO EN IA	139	Profesores titulares en Computación por raza y etnicidad	146
Mujeres en el entorno académico de IA	139	Black in AI	146
Mujeres en la fuerza de trabajo de IA	140	6.3 IDENTIDAD DE GÉNERO Y ORIENTACIÓN SEXUAL EN IA	147
Mujeres en talleres de Aprendizaje Automático	141	Queer in AI	147
Participantes de los talleres	141	Desglose de datos demográficos	147
Desglose de datos demográficos	142	Experiencias como practicantes <i>queer</i>	149
6.2 DIVERSIDAD RACIAL Y ÉTNICA EN AI	144		
Nuevos doctores en IA en los Estados Unidos			

ACCESO A LOS DATOS

Resumen

Aunque los sistemas de inteligencia artificial (IA) tienen el potencial de afectar de forma dramática a la sociedad, las personas que construyen los sistemas de IA no son representativas de las personas a las que esos sistemas deben servir. La mano de obra de la IA sigue siendo predominantemente masculina y carece de diversidad tanto en el mundo académico como en la industria, a pesar de que durante muchos años se han puesto de manifiesto las desventajas y los riesgos que esto genera. La falta de diversidad en cuanto a raza y etnia, identidad de género y orientación sexual no sólo corre el riesgo de crear una distribución desigual del poder en la mano de obra, sino que, igualmente importante, refuerza las desigualdades existentes generadas por los sistemas de IA, reduce el alcance de las personas y organizaciones para las que trabajan estos sistemas y contribuye a obtener resultados injustos.

Este capítulo presenta estadísticas sobre la diversidad en la mano de obra de la IA y en el mundo académico. Se basa en las colaboraciones con varias organizaciones -en particular, Women in Machine Learning (WiML), Black in AI (BAI) y Queer in AI (QAI)-, cada una de las cuales pretende mejorar la diversidad en alguna dimensión del campo. Los datos no son exhaustivos ni concluyentes. En la preparación de este capítulo, el equipo del Índice de IA se encontró con importantes retos como resultado de la escasez de datos demográficos disponibles públicamente. La falta de datos demográficos disponibles públicamente limita el grado en que los análisis estadísticos pueden evaluar el impacto de la falta de diversidad en la mano de obra de la IA en la sociedad y en el desarrollo tecnológico en general. El problema de la diversidad en la IA es bien conocido, y es esencial disponer de más datos, tanto del mundo académico como de la industria, para medir la magnitud del problema y abordarlo.

Hay muchas dimensiones de la diversidad que este capítulo no cubre, incluidos los profesionales de la IA con discapacidades; tampoco considera la diversidad a través de una lente interseccional. Otras dimensiones se abordarán en futuras iteraciones de este informe. Además, estas estadísticas de diversidad sólo cuentan una parte de la historia. Los retos diarios de las minorías y los grupos marginados que trabajan en la IA, así como los problemas estructurales de las organizaciones que contribuyen a la falta de diversidad, requieren una recopilación y un análisis de datos más amplios.

¹ Agradecemos a Women in Machine Learning, Black in AI y Queer in AI su trabajo para aumentar la diversidad en la IA, por compartir sus datos y por colaborar con nosotros.

PUNTOS CLAVE DEL CAPÍTULO

- Los porcentajes de mujeres que se doctoran en IA y de profesoras de ciencias de la computación se han mantenido bajos durante más de una década. Según una encuesta anual de la Computing Research Association (CRA), las mujeres graduadas en programas de doctorado en Inteligencia Artificial en Norteamérica han representado menos del 18% de todos los graduados de doctorado por término medio. Una encuesta del AI Index indica que el profesorado femenino representa sólo el 16% de todos los profesores de ciencias de la computación titulares en varias universidades de todo el mundo.
- La encuesta de CRA sugiere que en 2019, entre los nuevos graduados de doctorado en IA residentes en Estados Unidos, el 45% eran blancos, mientras que el 22,4% eran asiáticos, el 3,2% eran hispanos y el 2,4% eran afroamericanos.
- El porcentaje de nuevos doctores en informática de raza blanca (no hispana) ha variado poco en los últimos 10 años, representando el 62,7% de media. El porcentaje de doctores en informática negros o afroamericanos (no hispanos) y de hispanos en el mismo periodo es significativamente menor, con una media del 3,1% y el 3,3%, respectivamente.
- La participación en los talleres Black in AI, que se celebran conjuntamente con la Conferencia sobre Sistemas de Procesamiento de Información Neuronal (NeurIPS), ha crecido significativamente en los últimos años. El número de asistentes y de trabajos presentados en 2019 es 2,6 veces mayor que en 2017, mientras que el número de trabajos aceptados es 2,1 veces mayor.
- En una encuesta de miembros realizada por Queer in AI en 2020, casi la mitad de los encuestados dijeron que consideran la falta de inclusión en el campo como un obstáculo que han enfrentado al convertirse en un profesional *queer* en el campo de la IA/ML. Más del 40% de los miembros encuestados afirmaron haber sufrido discriminación o acoso como persona *queer* en el trabajo o en la escuela.

6.1 DIVERSIDAD DE GÉNERO EN LA IA

MUJERES EN EL ENTORNO ACADÉMICO DE IA

En el capítulo 4 se presentó la encuesta del Índice de Inteligencia Artificial, que evalúa el estado de la educación en Inteligencia Artificial en los departamentos de ciencias de la computación de las mejores universidades del mundo, junto con la encuesta anual Taulbee de la Asociación de Investigación Informática sobre la inscripción, producción y empleo de doctores en información, ciencias de la computación e ingeniería informática en Norteamérica. Los datos de ambas encuestas muestran que el porcentaje de mujeres graduadas en IA y CS, así como de profesoras de CS, sigue siendo bajo. Las mujeres graduadas en programas de doctorado en IA y CS han representado el 18,3% de todos los graduados de doctorado en promedio en los últimos 10 años (Figura 6.1.1). Entre las 17 universidades que completaron la encuesta del Índice de Inteligencia Artificial de los programas de ciencias de la computación en todo el mundo, el profesorado femenino representa sólo el 16,1% de todos los profesores titulares cuya principal área de investigación es la inteligencia artificial (figura 6.1.2).

PROFESORADO TITULAR en DEPARTAMENTOS DE COMPUTACIÓN en UNIVERSIDADES TOP en el MUNDO por GÉNERO, 2019-20

Fuente: AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 6.1.2

NUEVAS DOCTORAS EN CIENCIAS DE COMPUTACIÓN E IA (% del TOTAL) en NORTEAMÉRICA, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021




Figura 6.1.1

MUJERES QUE TRABAJAN EN IA

En el capítulo 3 se introdujo el “índice de presencia relativo de las competencias de la IA a nivel mundial”, una medida que refleja la prevalencia de las habilidades de la IA en todas las ocupaciones, o la intensidad con la que las personas de determinadas ocupaciones utilizan las habilidades de la IA. La figura 6.1.3 muestra la penetración de las habilidades de la IA por país para las reservas de mano de obra femenina y masculina en un conjunto de países seleccionados.² Los datos sugieren que, en la mayoría de estos países, la tasa de penetración de las habilidades de la IA para las mujeres es inferior a la de los hombres. Entre los 12 países examinados, India, Corea del Sur, Singapur y Australia son los que más cerca están de alcanzar la equidad en cuanto a la tasa de penetración de habilidades de IA de mujeres y hombres.

Estos datos sugieren que, en la mayoría de los países seleccionados, el índice de presencia de las competencias de la IA para las mujeres es inferior al de los hombres.

PRESENCIA RELATIVA DE COMPETENCIAS DE IA por GÉNERO, 2015-20

Fuente: LinkedIn, 2020 | Gráfica: Informe AI Index 2021




Figura 6.1.3

² Los países incluidos son una muestra selecta de países elegibles con al menos un 40% de cobertura de la mano de obra por parte de LinkedIn y al menos 10 contrataciones de IA en un mes determinado. China e India se incluyeron en esta muestra debido a su creciente importancia en la economía mundial, pero la cobertura de LinkedIn en estos países no alcanza el 40% de la fuerza laboral. Los datos de estos países pueden no ofrecer una imagen tan completa como la de otros países, y deben interpretarse en consecuencia.

MUJERES EN TALLERES DE APRENDIZAJE AUTOMÁTICO

Women in Machine Learning, fundada en 2006 por Hanna Wallach, Jenn Wortman y Lisa Wainer, es una organización que organiza eventos y programas para apoyar a las mujeres en el campo del aprendizaje automático (ML). Esta sección presenta las estadísticas de sus talleres técnicos anuales, que se celebran en NeurIPS. En 2020, WiML también organizó por primera vez un “Un-Workshop” de un día de duración en la Conferencia Internacional sobre Aprendizaje Automático 2020, que atrajo a 812 participantes.

Participantes de los talleres

El número de participantes que asisten a los talleres WiML en NeurIPS ha ido aumentando de forma constante desde que se ofrecieron por primera vez en 2006. Según la organización, el taller WiML de 2020 fue completamente virtual debido a

la pandemia y se impartió en una nueva plataforma (Gather. Town); estos dos factores pueden hacer que las cifras de asistencia sean más difíciles de comparar con las de años anteriores. La figura 6.1.4 muestra una estimación de 925 asistentes en 2020, basada en el número de personas que accedieron a la plataforma virtual.

En los últimos 10 años, los talleres de WiML han ampliado sus programas para incluir mesas redondas de tutoría, en las que participantes de mayor antigüedad ofrecen comentarios individuales y asesoramiento profesional, además de la sesión principal que incluye conferencias magistrales y presentaciones de carteles. Oportunidades similares pueden haber contribuido al aumento de la asistencia desde 2014. Entre 2016 y 2019, la asistencia al taller WiML es, en promedio, alrededor del 10% de la asistencia general a NeurIPS.

NÚMERO de PARTICIPANTES en el TALLER WiML en NEURIPS, 2006-20

Fuente: Women in Machine Learning, 2020 | Gráfica: Informe AI Index 2021



Figura 6.1.4

Desglose de datos demográficos

Los siguientes desgloses geográficos, de posición profesional y de género se basan únicamente en los participantes del taller WiML 2020 en NeurIPS que consintieron que se agregara la información y que pasaron al menos 10 minutos en la plataforma virtual a través de la cual se ofreció el taller. Entre los participantes, el 89,5% eran mujeres y/o no binarios, el 10,4% eran hombres (Figura 6.1.5), y una gran mayoría eran de América del Norte (Figura 6.1.6). Además, como se muestra en la figura 6.1.7, los estudiantes -incluidos los de doctorado, máster y licenciatura- representan más de la mitad de los participantes (54,6%). Entre los participantes que trabajan en la industria, los puestos profesionales más frecuentes son los de científico/ingeniero de investigación y científico/ingeniero de datos.

El 89,5% de los participantes eran mujeres y/o personas no binarias, el 10,4% eran hombres y la gran mayoría eran de América del Norte. Además, más de la mitad de los participantes (54,6%) eran estudiantes de doctorado, máster y licenciatura.

PARTICIPANTES del TALLER WiML en NEURIPS (% del TOTAL) por GÉNERO, 2020

Fuente: Women in Machine Learning, 2020 | Gráfica: Informe AI Index 2021




Figura 6.1.5

PARTICIPANTES en el TALLER WIML en NEURIPS (% del TOTAL) por CONTINENTE DE RESIDENCIA, 2020

Fuente: Women in Machine Learning, 2020 |Gráfica: Informe AI Index 2021




Figura 6.1.6

PARTICIPANTES en el TALLER WIML en NEURIPS (% del TOTAL) por el TOP 10 POSICIONES PROFESIONALES, 2020

Fuente: Women in Machine Learning, 2020 |Gráfica: Informe AI Index 2021




Figura 6.1.7

6.2 DIVERSIDAD ÉTNICA Y RACIAL EN IA

NUEVOS DOCTORES EN IA EN LOS ESTADOS UNIDOS POR RAZA Y ETNICIDAD

NUEVOS DOCTORES en IA RESIDENTES en EE.UU (% del TOTAL) por RAZA/ETNICIDAD, 2019

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index Report 2021




Figura 6.2.1

NUEVOS DOCTORES EN COMPUTACIÓN EN LOS ESTADOS UNIDOS POR RAZA Y ETNICIDAD

Según la Encuesta CRA Taulbee, entre los nuevos doctores en IA de 2019 que son residentes en Estados Unidos, el mayor porcentaje (45,6%) son blancos (no hispanos), seguidos de los asiáticos (22,4%). En comparación, el 2,4% son afroamericanos (no hispanos) y el 3,2% son hispanos (Figura 6.2.1). La figura 6.2.2 muestra todos los doctorados concedidos en Estados Unidos a residentes estadounidenses en los departamentos de informática (CS), ingeniería informática (CE) e información (I) entre 2010 y 2019. La encuesta de la CRA indica que el porcentaje de nuevos doctores blancos (no hispanos) ha cambiado poco en los últimos 10 años, representando el 62,7% de media. El porcentaje de nuevos doctores en informática negros o afroamericanos (no hispanos) en el mismo periodo es significativamente menor, con una media del 3,1% y el 3,3%, respectivamente. No podemos comparar las cifras entre los nuevos doctores en IA y CS en 2019 debido al número de casos desconocidos (24,8% para los nuevos doctores en IA y 8,5% para los doctores en CS).

La encuesta del CRA indica que el porcentaje de nuevos doctores blancos (no hispanos) ha cambiado poco en los últimos 10 años, representando el 62,7% de media.

NUEVOS DOCTORES EN COMPUTACIÓN, RESIDENTES en EE.UU. (% del TOTAL) por RAZA/ETNICIDAD, 2010-19

Fuente: Encuesta CRA Taulbee, 2020 | Gráfica: Informe AI Index 2021





Figura 6.2.2

PROFESORES TITULARES EN COMPUTACIÓN POR RAZA Y ETNICIDAD

La figura 6.2.3 muestra los datos de la encuesta sobre educación del Índice AI.³ Entre las 15 universidades que completaron la pregunta relativa a la composición racial de su profesorado, aproximadamente el 67,0% de los profesores titulares son blancos, seguidos por los asiáticos (14,3%), otras razas (8,3%) y mixtos/de otra raza, etnia u origen (6,3%). La menor representación entre el profesorado titular son los profesores de raza negra o africana y de origen hispano, latino o español, que representan el 0,6% y el 0,8%, respectivamente.

PROFESORADO TITULAR(% del TOTAL) en DEPARTAMENTOS DE CIENCIAS DE COMPUTACIÓN en UNIVERSIDADES TOP en el MUNDO por RAZA/ETNICIDAD, 2019-20

Fuente: AI Index, 2020 |Gráfica: Informe AI Index 2021



BLACK IN AI

Black in AI (BAI), fundada en 2017 por Timnit Gebru y Rediet Abebe, es una iniciativa multiinstitucional y transcontinental que pretende aumentar la presencia de personas negras en el campo de la IA. A partir de 2020, BAI cuenta con unos 3000 miembros de la comunidad y aliados, ha celebrado más de 10 talleres en las principales conferencias de IA y ha ayudado a

multiplicar por 40 el número de personas negras que participan en las principales conferencias de IA a nivel mundial. La figura 6.2.4 muestra el número de asistentes, de trabajos presentados y de trabajos aceptados del taller anual Black in AI, que se celebra conjuntamente con NeurIPS.⁴ El número de asistentes en 2019 es 2,6 veces mayor que en 2017, mientras que el número de trabajos aceptados es 2,1 veces mayor.

NÚMERO DE ASISTENTES, ARTÍCULOS ENVIADOS y ACEPTADOS en TALLERES DE BLACK in AI CO-ORGANIZADOS con NEURIPS, 2017-19

Fuente: Black in AI, 2020 |Gráfica: Informe AI Index 2021




Figura 6.2.4

³ La encuesta se distribuyó a 73 universidades en línea a lo largo de tres oleadas, desde noviembre de 2020 hasta enero de 2021, y fue completada por 18 universidades, lo que supone una tasa de respuesta del 24,7%. Las 18 universidades son Bélgica: Katholieke Universiteit Leuven; Canadá: McGill University; China: Shanghai Jiao Tong University, Tsinghua University; Alemania: Universidad Ludwig Maximilian de Munich, Universidad Técnica de Munich; Rusia: Escuela Superior de Economía, Instituto de Física y Tecnología de Moscú; Suiza: École Polytechnique Fédérale de Lausanne; Reino Unido: Universidad de Cambridge; Estados Unidos: California Institute of Technology, Carnegie Mellon University (Department of Machine Learning), Columbia University, Harvard University, Stanford University, University of Wisconsin-Madison, University of Texas at Austin, Yale University.

⁴ Los datos de 2020 se ven claramente afectados por la pandemia y no se incluyen por ello. Para más información, véase el [Black in AI impact report](#).

6.3 IDENTIDAD DE GÉNERO Y ORIENTACIÓN SEXUAL EN LA IA

QUEER IN AI

Esta sección presenta los datos de una encuesta realizada a los afiliados por Queer in AI (QAI),⁵ una organización que tiene como objetivo hacer de la comunidad de IA/ML una que acoga, apoye y valore a los científicos *queer*. Fundada en 2018 por William Agnew, Raphael Gontijo Lopes y Eva Breznik, QAI construye una comunidad visible de científicos de IA/ML *queer* y aliados a través de reuniones, sesiones de pósters, tutorías y otras iniciativas.

Desglose de datos demográficos

Según la encuesta de 2020, con unas 100 respuestas,

alrededor del 31,5% de los encuestados se identifican como gays, seguidos de bisexuales, *queer* y lesbianas (figura 6.3.1); alrededor del 37,0% y el 26,1% de los encuestados se identifican como hombres cis y mujeres cis, respectivamente, seguidos de género *queer*, género fluido, no binario y otros (figura 6.3.2). Las mujeres y los hombres trans representan el 5,0% y el 2,5% del total de miembros, respectivamente. Además, las encuestas de los últimos tres años muestran que los estudiantes constituyen la mayoría de los miembros de QAI, alrededor del 41,7% de todos los encuestados por término medio (figura 6.3.3), seguidos de los profesionales de nivel inferior en el ámbito académico o industrial.

ENCUESTA A MIEMBROS DE QAI: CUÁL ES TU ORIENTACIÓN SEXUAL, 2020

Fuente: Queer in AI, 2020 | Gráfica: Informe AI Index 2021




Figura 6.3.1

⁵ Queer in AI presenta los resultados de la encuesta en su taller de la conferencia anual NeurIPS.

ENCUESTA A MIEMBROS DE QAI: CUÁL ES TU IDENTIDAD DE GÉNERO, 2020

Fuente: Queer in AI, 2020 | Gráfica: Informe AI Index 2021




Figura 6.3.2

ENCUESTA A MIEMBROS DE QAI: CÓMO DESCRIBIRÍAS TU POSICIÓN, 2020

Fuente: Queer in AI, 2020 | Gráfica: Informe AI Index 2021

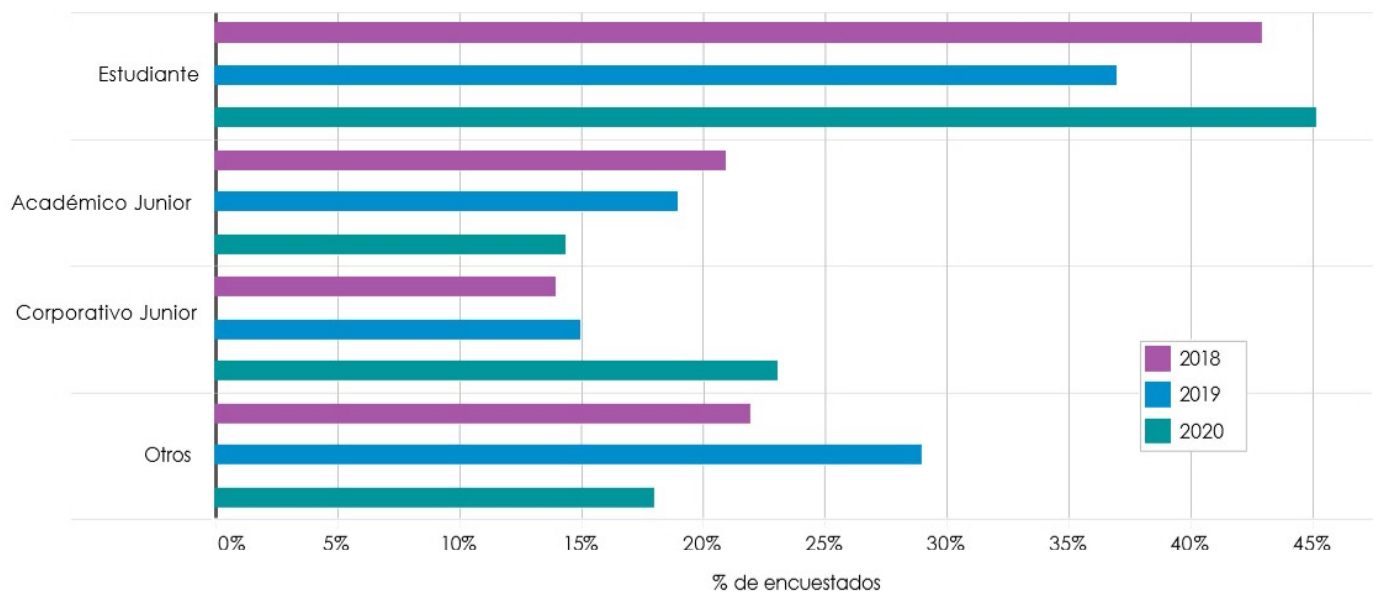


Figura 6.3.3

Experiencia como practicantes *queer*

QAI también encuestó a sus miembros sobre sus experiencias como profesionales de la IA/ML *queer*. Como se muestra en la figura 6.3.4, el 81,4% considera que la falta de modelos de conducta es un obstáculo importante para sus carreras, y el 70,9% cree que la falta de comunidad contribuye al mismo fenómeno. Casi la mitad de los encuestados también considera que la falta de inclusión en el campo es un obstáculo. Además, más del 40% de los miembros de QAI han sufrido discriminación o acoso por ser una persona *queer* en el trabajo o en la escuela (Figura 6.3.5). Alrededor del 9,7% ha sufrido discriminación o acoso en más de cinco ocasiones.

Entre los miembros de QAI encuestados, el 81,4% considera que la falta de modelos de conducta es un obstáculo importante para sus carreras, y el 70,9% piensa que la falta de comunidad contribuye al mismo fenómeno.

ENCUESTA A MIEMBROS DE QAI: CUÁLES SON LOS OBSTÁCULOS QUE HAS ENFRENTADO al CONVERTIRTE en un PROFESIONAL QUEER en IA/ML, 2020

Fuente: Queer in AI, 2020 | Gráfica: Informe AI Index 2021




Figura 6.3.4

Más del 40% de los miembros de QAI han sufrido discriminación o acoso por ser personas *queer* en el trabajo o en la escuela. Alrededor del 9,7% ha sufrido discriminación o acoso en más de cinco ocasiones.

ENCUESTA A MIEMBROS DE QAI: HAS EXPERIMENTADO DISCRIMINACIÓN/ACOSO como una PERSONA QUEER en TU TRABAJO o ESCUELA, 2020

Fuente: Queer in AI, 2020 | Gráfica: Informe AI Index 2021




Figura 6.3.5



CAPÍTULO 7: Políticas y estrategias nacionales en IA



Informe 2021 del
Artificial Intelligence Index

CAPÍTULO 7:

Vista previa del capítulo

Resumen	153	Acuerdos bilaterales	166
Puntos clave del capítulo	154		
7.1 ESTRATEGIAS NACIONALES REGIONALES DE IA	155	7.3 INVERSIÓN PÚBLICA EN IA (EE.UU.)	167
Estrategias publicadas	156	Presupuesto Federal en I+D	
2017	156	sin fines militares	167
2018	157	Solicitud de Presupuesto del Departamento de Defensa de EE.UU.	168
2019	159	Gastos público de EE.UU. relacionado con IA en contratos	169
2020	161	Gasto total en contratos	169
Estrategias en desarrollo (hasta diciembre de 2020)	162	Gasto en contratos por Departamento y Agencia	169
Estrategias bajo consulta pública	162	7.4 IA Y POLÍTICAS PÚBLICAS	171
Estrategias anunciadas	163	Registros legislativos sobre IA	171
Punto clave: Estrategias nacionales en IA y Derechos Humanos	164	Registro legislativo del Congreso de EE.UU.	172
7.2 COLABORACIÓN INTERNACIONAL EN IA	165	Menciones de IA y ML en las minutas del Congreso del Parlamento	172
Iniciativas intergubernamentales	165	Bancos Centrales	174
Grupo de trabajo	165	Políticas públicas de IA en EE.UU.	176
Cumbres y reuniones	166		

ACCESO A LOS DATOS

Resumen

La IA está llamada a marcar la competitividad mundial en las próximas décadas, prometiendo conceder a los primeros en adoptarla una importante ventaja económica y estratégica. Hasta la fecha, los gobiernos nacionales y las organizaciones regionales e intergubernamentales se han apresurado a poner en marcha políticas orientadas a la IA para maximizar la promesa de la tecnología, al tiempo que abordan sus implicaciones sociales y éticas.

Este capítulo recorre el panorama de la elaboración de políticas de IA y hace un seguimiento de los esfuerzos que se están llevando a cabo a nivel local, nacional e internacional para ayudar a promover y gobernar las tecnologías de IA. Comienza con una visión general de las estrategias nacionales y regionales en materia de IA y luego revisa las actividades a nivel intergubernamental. A continuación, el capítulo analiza la inversión pública en IA en Estados Unidos, así como el modo en que los órganos legislativos, los bancos centrales y las organizaciones no gubernamentales responden a la creciente necesidad de instituir un marco político para las tecnologías de IA.

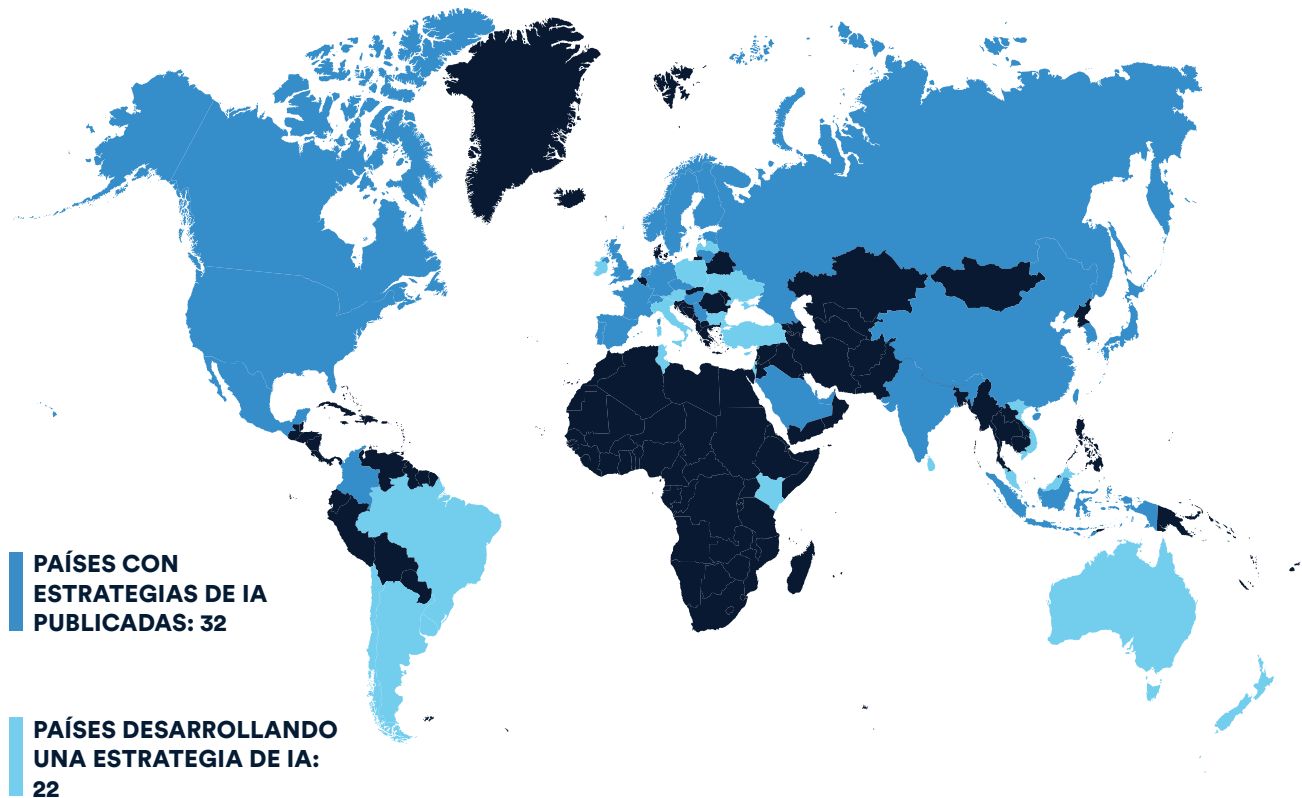
PUNTOS CLAVE DEL CAPÍTULO

- Desde que Canadá publicó la primera estrategia nacional de IA del mundo en 2017, más de 30 países y regiones han publicado documentos similares hasta diciembre de 2020.
- El lanzamiento de la Asociación Mundial sobre la IA (GPAI) y el Observatorio de Políticas de IA y Red de Expertos de la Organización para la Cooperación y el Desarrollo Económicos (OCDE) y el Observatorio de Políticas de IA y la Red de Expertos sobre IA en 2020 promovió los esfuerzos intergubernamentales para trabajar juntos en apoyo del desarrollo de la IA para todos.
- En Estados Unidos, el 116° Congreso ha sido el más centrado en la IA de la historia. El número de menciones a la IA por parte de este Congreso en la legislación, los informes de las comisiones y los informes del Servicio de Investigación del Congreso (CRS) es más del triple que el del 115° Congreso.

Esta sección presenta una visión general de algunas estrategias nacionales y regionales de IA de todo el mundo, incluyendo detalles sobre las estrategias de los países del G20, Estonia y Singapur, así como enlaces a los documentos de estrategia de muchos otros. Las fuentes son los sitios web de los gobiernos nacionales o regionales, el [Observatorio de Políticas en Inteligencia Artificial de la OECD \(OECD.AI\)](#) y noticias. La “estrategia de IA” se define como un documento político que comunica el objetivo de apoyar el desarrollo de la IA y, al mismo tiempo, maximizar los beneficios de la IA para la sociedad. Se excluyen los documentos de estrategia digital o de innovación más amplios que no se centran predominantemente en la IA, como la estrategia digital de Brasil y la estrategia de innovación integrada de Japón.

7.1 ESTRATEGIAS NACIONALES Y REGIONALES

Para orientar y fomentar el desarrollo de la IA, países y regiones de todo el mundo están estableciendo estrategias e iniciativas para coordinar los esfuerzos gubernamentales e intergubernamentales. Desde que Canadá publicó la primera estrategia nacional de IA del mundo en 2017, más de 30 países y regiones han publicado documentos similares hasta diciembre de 2020.




Estrategias publicadas 2017

Canadá

- **Estrategia de IA:** [Estrategia Pan-canadiense en IA](#)
- **Organización responsable:** Instituto Canadiense de Estudios Avanzados (CIFAR)
- **Puntos clave:** la estrategia canadiense enfatiza el desarrollo de la fuerza laboral futura de Canadá en IA, dando apoyo a los principales centros de innovación de IA, la investigación científica, y el posicionamiento del país como líder de pensamiento en las implicaciones económicas, éticas, políticas y legales de la inteligencia artificial.
- **Financiamiento (tasa de cambio de diciembre 2020):** CAD 125 millones (USD 97 millones)
- En noviembre de 2020, el CIFAR publicó su último informe anual, titulado "AICAN", en el que se hace un seguimiento de los avances realizados en la aplicación de su estrategia nacional, y en el que se destaca el crecimiento sustancial del ecosistema de IA de Canadá, así como la investigación y las actividades relacionadas con la asistencia sanitaria y el impacto de la IA en la sociedad, entre otros resultados de la estrategia.

China

- **Estrategia de IA:** [Un Plan de Desarrollo de la Próxima Generación de Inteligencia Artificial](#)
- **Organización responsable:** Consejo de Estado de la República Popular China
- **Puntos clave:** La estrategia china en materia de IA es una de las más completas del mundo. Abarca áreas como la I+D y el desarrollo de talentos a través de la educación y la adquisición de habilidades, así como las normas éticas y las implicaciones para la seguridad nacional. Establece objetivos específicos, como poner la industria de la IA a la altura de los competidores para 2020; convertirse en el líder mundial en campos como los vehículos aéreos no tripulados (UAV), el reconocimiento de voz e imágenes y otros para 2025; y emerger como el principal centro de innovación en IA para 2030..
- **Financiamiento:** información no disponible
- **Actualizaciones recientes:** China estableció una Zona de



Innovación y Desarrollo de IA de Nueva Generación en febrero de 2019 y publicó los "Principios de IA de Pekín" en mayo de 2019 con una coalición de múltiples partes interesadas formada por instituciones académicas y actores del sector privado como Tencent y Baidu.

Japón

- **Estrategia de IA:** [Estrategia de Tecnología de Inteligencia Artificial](#)
- **Organización responsable:** Consejo Estratégico para la Tecnología de IA
- **Puntos clave:** La estrategia establece tres fases diferenciadas de desarrollo de la IA. La primera fase se centra en la utilización de los datos y la IA en las industrias de servicios relacionadas, la segunda en el uso público de la IA y la expansión de las industrias de servicios, y la tercera en la creación de un ecosistema global en el que se fusionen los distintos ámbitos.
- **Financiamiento:** información no disponible
- **Actualizaciones recientes:** en 2019, el Consejo de Promoción de la Estrategia Integrada de Innovación lanzó [otra estrategia de IA](#), destinada a dar el siguiente paso para superar los problemas a los que se enfrenta Japón y aprovechar los puntos fuertes del país para abrir futuras oportunidades.

Otros

Finlandia: [Era de la Inteligencia Artificial de Finlandia](#)

Emiratos Árabes Unidos: [Estrategia para la Inteligencia Artificial de los EAU](#)


Estrategias publicadas 2018

Unión Europea

- **Estrategia de IA:** [Plan Coordinado sobre Inteligencia Artificial](#)
- **Organización responsable:** Comisión Europea
- **Puntos clave:** Este documento estratégico resume los compromisos y acciones acordados por los Estados miembros de la UE, Noruega y Suiza para aumentar la inversión y construir su reserva de talento en IA. Destaca el valor de las asociaciones público-privadas, la creación de espacios de datos europeos y el desarrollo de principios éticos.
- **Financiamiento (tasa de cambio de diciembre de 2020):** Al menos 1.000 millones de euros (1.100 millones de dólares) al año para la investigación en IA y al menos 4.900 millones de euros (5.400 millones de dólares) para otros aspectos de la estrategia
- **Actualizaciones recientes:** En junio de 2018 se publicó un primer borrador de las directrices éticas, seguido de una versión actualizada en abril de 2019.

Francia

- **Estrategia de IA:** [IA para la Humanidad: Estrategia Francesa para la Inteligencia Artificial](#)
- **Organizaciones responsables:** Ministerio de Educación Superior, Investigación e Innovación; Ministerio de Economía y Hacienda; Dirección General de Empresas; Ministerio de Salud Pública; Ministerio de las Fuerzas Armadas; Instituto Nacional de Investigación en Ciencias Digitales; Director Interministerial de la Tecnología Digital y del Sistema de Información y Comunicación
- **Puntos clave:** Los temas principales incluyen el desarrollo de una política de datos agresiva para el big data; la focalización en cuatro sectores estratégicos, a saber, la asistencia sanitaria, el medio ambiente, el transporte y la defensa; el impulso de los esfuerzos franceses en materia de investigación y desarrollo; la planificación del impacto de la IA en la mano de obra; y la garantía de la inclusión y la diversidad dentro del campo.
- **Financiamiento (tasa de cambio de diciembre de 2020):** 1.500 millones de euros (1.800 millones de dólares) hasta 2022



- **Actualizaciones recientes:** El Instituto Nacional de Investigación en Ciencias Digitales (Inria) se ha comprometido a desempeñar un papel central en la coordinación de la estrategia nacional de Inteligencia Artificial e informará anualmente de sus avances.

Alemania

- **Estrategia de IA:** [IA Hecha en Alemania](#)
- **Organización responsable:** Ministerio Federal de Educación e Investigación; Ministerio Federal de Economía y Energía; Ministerio Federal de Trabajo y Asuntos Sociales
- **Puntos clave:** La estrategia se centra en consolidar a Alemania como potencia investigadora y reforzar el valor de sus industrias. También se hace hincapié en el interés público y en trabajar para mejorar la vida de las personas y el medio ambiente.
- **Financiamiento (tasa de cambio de diciembre de 2020):** 500 millones de euros (608 millones de dólares) en el presupuesto de 2019 y 3.000 millones de euros (3.600 millones de dólares) para la aplicación hasta 2025
- **Actualizaciones recientes:** En noviembre de 2019, el gobierno publicó un informe provisional de progreso sobre la estrategia de IA de Alemania.

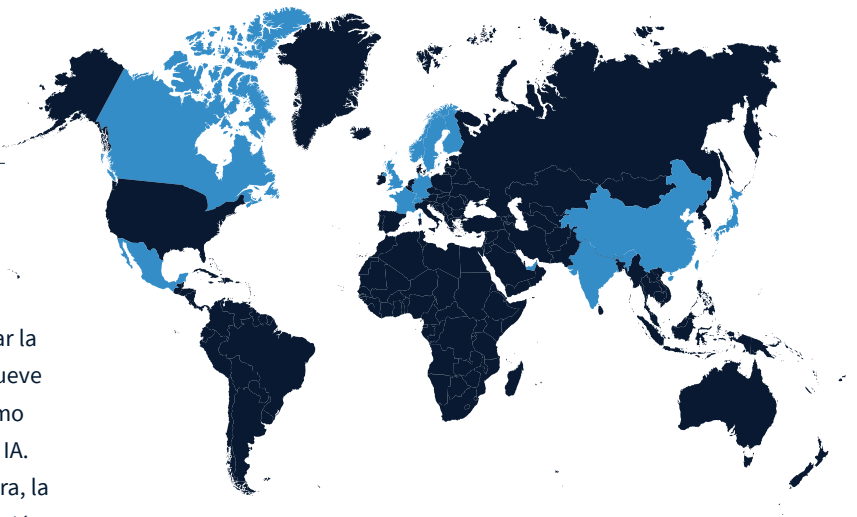
2018 (continued)

India

- **Estrategia de IA:** [Estrategia Nacional sobre Inteligencia Artificial #AIforAll](#)
- **Organización responsable:** Instituto Nacional para la Transformación de India (NITI Ayog)
- **Puntos clave:** La estrategia india se centra tanto en el crecimiento económico como en las formas de aprovechar la IA para aumentar la inclusión social, al tiempo que promueve la investigación para abordar cuestiones importantes como la ética, la parcialidad y la privacidad relacionadas con la IA. La estrategia hace hincapié en sectores como la agricultura, la sanidad y la educación, en los que son necesarias la inversión pública y la iniciativa gubernamental.
- **Financiamiento (tasa de cambio de diciembre de 2020):** 7.000 millones de rupias (949 millones de dólares)
- **Actualizaciones recientes:** En 2019, el Ministerio de Electrónica y Tecnología de la Información publicó su propia propuesta para establecer un programa nacional de IA con una asignación de 400 crores de rupias (54 millones de dólares). El gobierno indio formó un comité a finales de 2019 para impulsar una política de IA organizada y establecer las funciones precisas de los organismos gubernamentales para impulsar la misión de IA de la India.

México

- **Estrategia de IA:** [Agenda de Inteligencia Artificial MX](#) (Versión resumida de la agenda 2019)
- **Organización responsable:** IA2030Mx, Economía
- **Puntos clave:** Como primera estrategia de América Latina, la estrategia mexicana se centra en el desarrollo de un sólido marco de gobernanza, el mapeo de las necesidades de la IA en varias industrias, y la identificación de las mejores prácticas gubernamentales con énfasis en el desarrollo del liderazgo de México en IA.
- **Financiamiento:** información no disponible
- **Actualizaciones recientes:** Según el reciente informe fAIr LAC del Banco Interamericano de Desarrollo, México está en proceso de establecer políticas concretas de IA para impulsar



su aplicación.

Reino Unido

- **Estrategia de IA:** [Estrategia Industrial: Acuerdo en el sector de la Inteligencia Artificial](#)
- **Organización responsable:** Oficina para la Inteligencia Artificial (OAI)
- **Puntos clave:** La estrategia del Reino Unido hace hincapié en una sólida asociación entre las empresas, el mundo académico y el gobierno, e identifica cinco bases para el éxito de la estrategia industrial: convertirse en la economía más innovadora del mundo, crear puestos de trabajo y mejorar el potencial de ingresos, mejorar las infraestructuras, crear condiciones empresariales favorables y construir comunidades prósperas en todo el país.
- **Financiamiento (tasa de cambio de diciembre de 2020):** 950 millones de libras (1.300 millones de dólares)
- **Actualizaciones recientes:** Entre 2017 y 2019, el Comité Selecto del Reino Unido sobre IA [publicó un informe anual](#) sobre el progreso del país. En noviembre de 2020, el gobierno [anunció](#) un importante aumento del gasto en defensa de 16.500 millones de libras esterlinas (21.800 millones de dólares) a lo largo de cuatro años, con un gran énfasis en las tecnologías de IA que prometen revolucionar la guerra.

Otros

- **Suecia:** [Enfoque Nacional hacia la Inteligencia Artificial](#)
- **Taiwán:** [Plan de Acción de IA de Taiwán](#)


Estrategias publicadas 2019

Estonia

- **Estrategia de IA:** [Estrategia Nacional de IA 2019–2021](#)
- **Organización responsable:** Ministerio de Economía y Comunicaciones (MKM)
- **Puntos clave:** La estrategia hace hincapié en las medidas necesarias para que tanto el sector público como el privado aumenten la inversión en investigación y desarrollo de la IA, al tiempo que mejoran el entorno jurídico de la IA en Estonia. Además, establece el marco de un comité directivo que supervisará la aplicación y el seguimiento de la estrategia.
- **Financiamiento (tasa de cambio de diciembre de 2020):** 10 millones de euros (12 millones de dólares) hasta 2021
- **Actualizaciones recientes:** El gobierno estonio publicó una [actualización](#) del grupo de trabajo sobre IA en mayo de 2019.

Rusia

- **Estrategia de IA:** [Estrategia Nacional para el Desarrollo de la Inteligencia Artificial](#)
- **Organizaciones responsables:** Ministerio de Desarrollo Digital, Comunicaciones y Medios de Comunicación; Gobierno de la Federación Rusa
- **Puntos clave:** La estrategia rusa en materia de IA hace gran hincapié en sus intereses nacionales y establece las directrices para el desarrollo de una “sociedad de la información” entre 2017 y 2030. Estas incluyen una iniciativa tecnológica nacional, proyectos departamentales para los órganos ejecutivos federales y programas como el de Economía Digital de la Federación Rusa, diseñado para aplicar el marco de la IA en todos los sectores.
- **Financiamiento:** información no disponible
- **Actualizaciones recientes:** En diciembre de 2020, el presidente ruso Vladimir Putin participó en la [Artificial Intelligence Journey Conference](#), donde presentó cuatro ideas para las políticas de IA: establecer marcos legales experimentales para el uso de la IA, desarrollar medidas prácticas para introducir algoritmos de IA, proporcionar a los desarrolladores de redes neuronales un



acceso competitivo a los big data e impulsar la inversión privada en las industrias nacionales de IA.

Singapur

- **Estrategia de IA:** [Estrategia Nacional de Inteligencia Artificial](#)
- **Organización responsable:** Oficina de Gobierno Digital y Nación Inteligente (SNDGO)
- **Puntos clave:** Lanzada por Smart Nation Singapore, una agencia gubernamental que pretende transformar la economía de Singapur y dar paso a una nueva era digital, la estrategia identifica cinco proyectos nacionales de IA en los siguientes campos: transporte y logística, ciudades y fincas inteligentes, atención sanitaria, educación y seguridad.
- **Financiamiento (tasa de cambio de diciembre de 2020):** Aunque la estrategia de 2019 no menciona la financiación, en 2017 el gobierno lanzó su programa nacional, AI Singapore, con la promesa de invertir 150 millones de SGD (113 millones de dólares) en cinco años.
- **Actualizaciones recientes:** En noviembre de 2020, la SNDGO publicó su primera actualización anual sobre los esfuerzos de protección de datos del gobierno de Singapur. Describe las medidas adoptadas hasta la fecha para reforzar la seguridad de los datos del sector público y salvaguardar los datos privados de los ciudadanos.

2019 (continuada)

Estados Unidos

- **Estrategia de IA:** [Iniciativa Americana de IA](#)
- **Organización responsable:** La Casa Blanca
- **Puntos clave:** La Iniciativa Americana de IA prioriza la necesidad de que el gobierno federal invierta en I+D de IA, reduzca las barreras a los recursos federales y garantice las normas técnicas para el desarrollo seguro, las pruebas y el despliegue de las tecnologías de IA. La Casa Blanca también hace hincapié en el desarrollo de una mano de obra preparada para la IA y señala el compromiso de colaborar con socios extranjeros al tiempo que promueve el liderazgo de Estados Unidos en la IA. Sin embargo, la iniciativa carece de detalles sobre el calendario del programa, si se dedicará investigación adicional al desarrollo de la IA y otras consideraciones prácticas.
- **Financiamiento:** información no disponible
- **Actualizaciones recientes:** El gobierno de Estados Unidos publicó su primer [informe anual](#) en febrero 2020, seguido en noviembre por el primer memorando de orientación para las agencias federales sobre la regulación de las aplicaciones de inteligencia artificial en el sector privado, que incluye principios que fomentan la innovación y el crecimiento de la IA y aumentan la confianza del público en las tecnologías de IA. La Ley de Autorización de la Defensa Nacional (NDAA) para el año fiscal 2021 pedía una Iniciativa Nacional de IA para coordinar la investigación y la política de IA en todo el gobierno federal.

Corea del Sur

- **Estrategia de IA:** [Estrategia Nacional para la Inteligencia Artificial](#)
- **Organización responsable:** Ministerio de Ciencia, TIC y Planificación del Futuro (MSIP)
- **Puntos clave:** la estrategia coreana contempla planes para facilitar el uso de la IA por parte de las empresas y racionalizar la normativa para crear un entorno más favorable al desarrollo y uso de la IA y otras nuevas industrias. El gobierno coreano también planea aprovechar su dominio en el suministro mundial de chips de memoria para construir la próxima



generación de chips inteligentes para 2030.

- **Financiamiento (tasa de cambio de diciembre de 2020):** 2,2 billones de KRW (2.000 millones de USD)
- **Actualizaciones recientes:** información no disponible

Otros

Colombia: [Política Nacional para la Transformación Digital y la Inteligencia Artificial](#)

República Checa: [Estrategia Nacional de Inteligencia Artificial de la República Checa](#)

Lituania: [Estrategia Lituana de Inteligencia Artificial: una visión para el futuro](#)

Luxemburgo: [Inteligencia Artificial: Una Visión Estratégica para Luxemburgo](#)

Malta: [Malta: la plataforma definitiva de IA](#)

Netherlands: [Plan Estratégico de Acción para la Inteligencia Artificial](#)

Portugal: [AI Portugal 2030](#)

Catar: [Inteligencia Artificial Nacional para Catar](#)

Estrategias publicadas


2020

Indonesia

- **Estrategia de IA:** [Estrategia Nacional para el Desarrollo de Inteligencia Artificial \(Stranas KA\)](#)
- **Organizaciones responsables:** Ministerio de Investigación y Tecnología (Menristek), Agencia Nacional de Investigación e Innovación (BRIN), Agencia de Evaluación y Aplicación de la Tecnología (BPPT)
- **Puntos clave de la estrategia:** La estrategia indonesia pretende guiar al país en el desarrollo de la IA entre 2020 y 2045. Se centra en la educación y la investigación, los servicios sanitarios, la seguridad alimentaria, la movilidad, las ciudades inteligentes y la reforma del sector público.
- **Financiamiento:** información no disponible.
- **Actualizaciones recientes:** ninguna.

Arabia Saudita

- **Estrategia de IA:** [Estrategia Nacional sobre Datos e IA \(NSDAI\)](#)
- **Organización responsable:** Autoridad Saudí de Datos e Inteligencia Artificial (SDAIA)
- **Puntos clave:** Como parte de un esfuerzo por diversificar la economía del país y alejarla del petróleo e impulsar el sector privado, la NSDAI pretende acelerar el desarrollo de la IA en cinco sectores críticos: atención sanitaria, movilidad, educación, gobierno y energía. Para 2030, Arabia Saudí pretende formar a 20.000 especialistas en datos e IA, atraer 20.000 millones de dólares en inversiones extranjeras y locales, y crear un entorno que atraiga al menos 300 startups de IA y datos.
- **Financiamiento:** información no disponible.
- **Actualizaciones recientes:** Durante la cumbre en la que el gobierno saudí dio a conocer su estrategia, el Centro Nacional de Inteligencia Artificial (NCAI) del país firmó acuerdos de colaboración con las chinas Huawei y Alibaba Cloud para diseñar sistemas relacionados con la IA en lengua árabe.



Otros

Hungría: [Estrategia de Inteligencia Artificial de Hungría](#)

Noruega: [Estrategia Nacional para la Inteligencia Artificial](#)

Serbia: [Estrategia para el Desarrollo de la Inteligencia Artificial de la República de Serbia para el período 2020–2025](#)

España: [Estrategia Nacional de Inteligencia Artificial](#)

Estrategias en desarrollo (HASTA DICIEMBRE DE 2020)


Estrategias bajo consulta pública

Brasil

- **Borrador de la Estrategia de IA:** [Estrategia Brasileña de Inteligencia Artificial](#)
- **Organización responsable:** Ministerio de Ciencia, Tecnología e Innovación (MCTI)
- **Puntos clave:** La estrategia nacional de IA de Brasil fue anunciada en 2019 y actualmente está en fase de consulta pública. Según la OCDE, la estrategia tiene como objetivo cubrir los temas relevantes relacionados con la IA, incluyendo su impacto en la economía, la ética, el desarrollo, la educación y el empleo, y coordinar las políticas públicas específicas que abordan estas cuestiones.
- **Financiamiento:** información no disponible
- **Actualizaciones recientes:** En octubre de 2020 se puso en marcha el mayor centro de investigación del país dedicado a la IA en colaboración con IBM, la Universidad de São Paulo y la Fundación de Investigación de São Paulo.

Italia

- **Borrador de la Estrategia de IA:** [Propuesta para una Estrategia Italiana para la Inteligencia Artificial](#)
- **Organización responsable:** Ministerio de Desarrollo Económico (MISE)
- **Puntos clave:** Este documento proporciona la estrategia propuesta para el desarrollo sostenible de la IA, con el objetivo de mejorar la competitividad de Italia en la IA. Se centra en la mejora de las habilidades y competencias basadas en la IA, en el fomento de la investigación en IA, en el establecimiento de un marco normativo y ético que garantice un ecosistema sostenible para la IA y en el desarrollo de una sólida infraestructura de datos que impulse estos avances.
- **Financiamiento (tasa de cambio de diciembre de 2020):** 1.000 millones de euros (1.100 millones de dólares) hasta 2025 y se espera que el sector privado aporte fondos complementarios, con lo que la inversión total ascenderá a



2.000 millones de euros.

- **Actualizaciones recientes:** ninguna

Otros

Chipre: [Estrategia Nacional para la Inteligencia Artificial](#)

Irlanda: [Estrategia Nacional Irlandesa sobre Inteligencia Artificial](#)

Polonia: [Política de Desarrollo de Inteligencia Artificial en Polonia](#)

Uruguay: [Estrategia de Inteligencia Artificial para el Gobierno Digital](#)

Estrategias anunciadas

Argentina


- **Documento relacionado:** no disponible
- **Organización responsable:** Ministerio de Ciencia, Tecnología e Innovación Productiva (MINCYT)
- **Estatus:** El plan de IA de Argentina forma parte de la Agenda Digital 2030 de Argentina, pero aún no se ha publicado. Está destinado a cubrir la década entre 2020 y 2030, y los informes indican que tiene el potencial de cosechar enormes beneficios para el sector agrícola.

Australia

- **Documentos relacionados:** [Mapa de ruta de Inteligencia Artificial y Un Plan de Acción de IA para todos los australianos](#)
- **Organizaciones responsables:** Organización de Investigación Científica e Industrial de la Commonwealth (CSIRO), Data 61 y el gobierno australiano
- **Estatus:** El gobierno australiano publicó una hoja de ruta en 2019 (en colaboración con la agencia científica nacional, CSIRO) y un documento de debate de un plan de acción de IA en 2020 como marcos para desarrollar una estrategia nacional de IA. En su presupuesto de 2018-19, el gobierno australiano destinó 29,9 millones de dólares australianos (22,2 millones de dólares estadounidenses [tasa de conversión de diciembre de 2020]) durante cuatro años para fortalecer las capacidades del país en IA y aprendizaje automático (ML). Además, CSIRO publicó un documento de investigación sobre el marco ético de la IA en Australia en 2019 y lanzó una consulta pública, que se espera que produzca un próximo documento de estrategia.

Turquía

- **Documento relacionado:** no disponible
- **Organizaciones responsables:** Presidencia de la República de Turquía Oficina de Transformación Digital; Ministerio de Industria y Tecnología; Consejo de Investigación Científica y Tecnológica de Turquía; Consejo de Políticas de Ciencia, Tecnología e Innovación
- **Estatus:** la estrategia se ha anunciado, pero aún no se ha publicado. Según los medios de comunicación, se centrará en



el desarrollo del talento, la investigación científica, la ética y la inclusión y la infraestructura digital.

Otros

- **Austria:** [Inteligencia Artificial Misión Austria](#) (informe oficial)
- **Bulgaria:** [Concepto para el Desarrollo de la Inteligencia Artificial en Bulgaria hasta 2030](#) (documento del concepto)
- **Chile:** [Política Nacional de IA](#) (anuncio oficial)
- **Israel:** [Plan Nacional de IA](#) (noticia)
- **Kenia:** [Grupo de Trabajo de Blockchain e Inteligencia Artificial](#) (noticia)
- **Letonia:** [Sobre el desarrollo de soluciones de inteligencia artificial](#) (informe oficial)
- **Malasia:** [Marco Nacional de Inteligencia Artificial \(IA\)](#) (noticia)
- **Nueva Zelanda:** [Inteligencia Artificial: Modelando la Nueva Zelanda del Futuro](#) (informe oficial)
- **Sri Lanka:** [Marco para la Inteligencia Artificial](#) (noticia)
- **Suiza:** [Inteligencia Artificial](#) (lineamientos oficiales)
- **Túnez:** [Estrategia Nacional de Inteligencia Artificial](#) (anuncio de grupo de trabajo)
- **Ucrania:** [Concepto de Desarrollo de la Inteligencia Artificial en Ucrania](#) (documento del concepto)
- **Vietnam:** [Estrategia para el Desarrollo de la Inteligencia Artificial](#) (anuncio oficial)

Lea más acerca de las estrategias nacionales de IA:

- Tim Dutton: [An Resumen of National AI Strategies](#)
- Organización para la Cooperación y el Desarrollo Económico: [Observatorio de Políticas de IA de la OECD](#)
- Instituto Canadiense de Investigación Avanzada: [Construyendo un mundo de IA, Segunda Edición](#)
- Banco Interamericano de Desarrollo: [Inteligencia Artificial para el Bien Social en América Latina y el Caribe: el panorama regional y 12 reseñas de países](#)

Estrategias nacionales de IA y Derechos Humanos

En 2020, Global Partners Digital y la Incubadora Global de Políticas Digitales de Stanford publicaron un informe en el que se examinaban las estrategias nacionales de IA de los gobiernos desde la perspectiva de los derechos humanos, titulado [“National Artificial Intelligence Strategies and Human Rights: A Review.”](#)

El informe evalúa el grado en que los gobiernos y las organizaciones regionales han incorporado consideraciones de derechos humanos en sus estrategias nacionales de IA y hace recomendaciones a los responsables políticos que pretenden desarrollar o revisar las estrategias de IA en el futuro.

El informe constata que, entre los 30 Estados y las dos estrategias regionales (de la Unión Europea y de los Estados nórdicos y bálticos), varias estrategias hacen referencia al impacto de la IA en los derechos humanos, siendo el derecho a la intimidad el más mencionado, seguido de la igualdad y la no discriminación (cuadro 6.1.1). Sin embargo, muy pocos documentos estratégicos ofrecen un análisis profundo o una evaluación concreta del impacto de las aplicaciones de la IA en los derechos humanos. Se echa en falta una mayor concreción sobre cómo y en qué medida deben protegerse los derechos humanos en el contexto de la IA, lo que contrasta con el nivel de especificidad de otras cuestiones como la competitividad económica y la ventaja de la innovación.

Tabla 7.1.1: Mapeando los DD.HH. referidos en las estrategias nacionales de IA

DERECHOS HUMANOS MENCIONADOS	ORGANIZACIONES REGIONALES/ ESTATALES
El derecho a la privacidad	Australia, Bélgica, China, República Checa, Alemania, India, Italia, Luxemburgo, Malta, Holanda, Noruega, Portugal, Catar, Corea del Sur, Estados Unidos
El derecho a la igualdad y vivir libre de discriminación	Australia, Bélgica, República Checa, Dinamarca, Estonia, UE, Francia, Alemania, Italia, Malta, Holanda, Noruega
El derecho a un juicio justo	Australia (responsabilidad y capacidad de dictar sentencia contra un humano responsable), Dinamarca, Malta, Holanda
Los derechos de libre pensamiento, expresión y acceso a la información	Francia, Holanda Rusia
El derecho al trabajo	Francia, Rusia

7.2 COLABORACIÓN INTERNACIONAL EN IA

Dada la magnitud de las oportunidades y los retos que presenta la IA, recientemente se han anunciado una serie de esfuerzos internacionales que pretenden desarrollar estrategias multilaterales de IA. Esta sección ofrece una visión general de esas iniciativas internacionales de los gobiernos comprometidos a trabajar juntos para apoyar el desarrollo de la IA para todos.

Estas iniciativas multilaterales sobre IA sugieren que las organizaciones están adoptando diversos enfoques para abordar las aplicaciones prácticas de la IA y ampliar esas soluciones para lograr el máximo impacto mundial. Muchos países recurren a las organizaciones internacionales para la formulación de normas globales sobre IA, mientras que otros se comprometen con asociaciones o acuerdos bilaterales. Entre los temas que se debaten, la ética de la IA -o los retos éticos que plantean las aplicaciones actuales y futuras de la IA- destaca como un área de especial interés para los esfuerzos intergubernamentales.

Países como Japón, Corea del Sur, el Reino Unido, Estados Unidos y los miembros de la Unión Europea participan activamente en los esfuerzos intergubernamentales sobre la IA. Por otro lado, China, una de las principales potencias en materia de IA, ha optado por participar en una serie de acuerdos bilaterales en materia de ciencia y tecnología que hacen hincapié en la cooperación en materia de IA como parte de la Ruta de la Seda Digital en el marco de la iniciativa “Belt and Road” (BRI). Por ejemplo, la IA se menciona en la [cooperación económica](#) de China en el marco de la iniciativa BRI con los Emiratos Árabes Unidos.

INICIATIVAS INTERGUBERNAMENTALES

Los grupos de trabajo intergubernamentales están formados por expertos y responsables políticos de los Estados miembros que estudian e informan sobre los retos más urgentes relacionados con el desarrollo y la implantación de la IA y luego hacen recomendaciones basadas en sus conclusiones. Estos grupos son fundamentales para identificar y desarrollar estrategias para los problemas más acuciantes de las tecnologías de IA y sus

aplicaciones.

Grupos de trabajo

Global Partnership on AI (GPAI)

- **Participantes:** Alemania, Australia, Brasil, Canadá, Corea del Sur, Eslovenia, España, Estados Unidos, Francia, India, Italia, Japón, México, Nueva Zelanda, Países Bajos, Polonia, Reino Unido y Singapur (a diciembre de 2020)
- **Anfitrión del Secretariado:** OECD
- **Áreas de interés:** IA responsable; gobernanza de los datos; el futuro del trabajo; innovación y comercialización
- **Actividades recientes:** Dos Centros Internacionales de Expertos -el Centro Internacional de Expertos de Montreal para el Avance de la Inteligencia Artificial y el Instituto Nacional Francés de Investigación en Ciencia y Tecnología Digitales (INRIA) de París- están apoyando el trabajo en las cuatro áreas de interés y celebraron la Cumbre de Montreal 2020 en diciembre de 2020. Además, el grupo de trabajo sobre gobernanza de datos publicó la versión [beta](#) del marco del grupo en noviembre de 2020.

Red de Expertos en IA de la OECD (ONE AI)

- **Participantes:** países miembros de la OECD
- **Anfitrión:** OECD
- **Áreas de interés:** Clasificación de la IA; aplicación de una IA fiable; políticas para la IA; computación de la IA
- **Actividades recientes:** ONE AI convocó su primera reunión en febrero de 2020, cuando también lanzó el Observatorio de Políticas de IA de la OCDE. En noviembre de 2020, el grupo de trabajo sobre la clasificación de la IA presentó el primer vistazo a un marco de clasificación de la IA basado en la definición de la IA de la OCDE dividida en cuatro dimensiones (contexto, datos e insumos, modelo de IA, tarea y resultados) que pretende orientar a los responsables políticos en el diseño de políticas adecuadas para cada tipo de sistema de IA.

Grupo de alto Nivel de Expertos en Inteligencia Artificial (HLEG)

- **Participantes:** países miembros de la UE
- **Anfitrión:** Comisión Europea

- **Áreas de interés:** lineamientos éticos para una IA digna de confianza
- **Actividades recientes:** Desde su lanzamiento por recomendación de la estrategia de IA de la UE en 2018, HLEG presentó las Directrices Éticas de la UE para la Inteligencia Artificial de Confianza y una serie de recomendaciones políticas y de inversión, así como una lista de verificación de evaluación relacionada con las directrices.

Grupo de Expertos Ad Hoc (AHEG) para la Recomendación sobre la Ética de la Inteligencia Artificial

- **Participantes:** Estados miembros de la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO)
- **Anfitrión:** UNESCO
- **Áreas de interés:** cuestiones éticas que plantea el desarrollo y el uso de la IA
- **Actividades recientes:** el AHEG elaboró un primer proyecto revisado de Recomendación sobre la Ética de la Inteligencia Artificial, que se transmitió en septiembre de 2020 a los Estados miembros de la UNESCO para que formularan sus comentarios antes del 31 de diciembre de 2020.

Cumbres y reuniones

Cumbre Mundial de IA para el Bien

- **Participantes:** Global (con las Naciones Unidas y sus agencias)
- **Anfitrión:** Unión Internacional de Telecomunicaciones, Fundación XPRIZE
- **Áreas:** Desarrollo fiable, seguro e incluyente de las tecnologías de IA y acceso equitativo a sus beneficios

Alianza de IA para la Defensa

- **Participantes:** Australia, Canadá, Dinamarca, Estonia, Finlandia, Francia, Israel, Japón, Noruega, Corea del Sur, Reino Unido y Suecia
- **Anfitrión:** Centro Conjunto de Inteligencia Artificial, Departamento de Defensa de los Estados Unidos
- **Áreas de interés:** Principios éticos de la IA para la defensa

Cumbre de IA entre China y la Asociación de Naciones del Sudeste Asiático (ASEAN)

- **Participantes:** Brunei, Camboya, China, Indonesia, Laos, Malasia, Myanmar, Filipinas, Singapur, Tailandia y Vietnam
- **Anfitriones:** Asociación China de Ciencia y Tecnología, Región Autónoma de Guangxi Zhuang, China
- **Áreas de interés:** Construcción de infraestructuras, economía

digital y desarrollo impulsado por la innovación

ACUERDOS BILATERALES

Los acuerdos bilaterales centrados en la IA son otra forma de colaboración internacional que ha ido ganando en popularidad en los últimos años. La IA suele incluirse en el contexto más amplio de la colaboración en el desarrollo de las economías digitales, aunque la India se distingue por invertir en el desarrollo de múltiples acuerdos bilaterales orientados específicamente a la IA.

India y lo Emiratos Árabes Unidos

Invest India y el Ministerio de Inteligencia Artificial de los Emiratos Árabes Unidos firmaron un memorando de entendimiento en julio de 2018 para colaborar en el fomento de ecosistemas innovadores de IA y otras preocupaciones políticas relacionadas con la IA. Los dos países convocarán un comité de trabajo destinado a aumentar la inversión en startups de IA y actividades de investigación en colaboración con el sector privado.

India y Alemania

En **octubre de 2019** se informó que es probable que la India y Alemania firmen un acuerdo que incluya asociaciones sobre el uso de la inteligencia artificial (especialmente en la agricultura).

Estados Unidos y el Reino Unido

Estados Unidos y el Reino Unido anunciaron en **septiembre de 2020**, a través del Grupo de Trabajo de Relaciones Económicas Especiales, una declaración según la cual ambos países entablarán un diálogo bilateral sobre el avance de la IA en línea con los valores democráticos compartidos y una mayor cooperación en los esfuerzos de I+D en materia de IA.

India y Japón

Se afirmó que India y Japón finalizaron un acuerdo en **octubre de 2020** que se centra en la colaboración en tecnologías digitales, incluyendo el 5G y la IA.

Francia y Alemania

Francia y Alemania firmaron una hoja de ruta para una Red de Investigación e Innovación franco-alemana sobre inteligencia artificial como parte de la Declaración de Toulouse en **octubre de 2019** para avanzar en los esfuerzos europeos en el desarrollo y la aplicación de la IA, teniendo en cuenta las directrices éticas.

Esta sección examina la inversión pública en IA en Estados Unidos a partir de los datos del programa de Investigación y Desarrollo de Redes y Tecnologías de la Información (NITRD) y Bloomberg Government.

7.3 INVERSIÓN PÚBLICA EN IA EN EE.UU.

PRESUPUESTO FEDERAL PARA I+D SIN FINES MILITARES

En septiembre de 2019, el Consejo Nacional de Ciencia y Tecnología de la Casa Blanca publicó un informe que intenta sumar toda la financiación de I+D en IA del sector público, la primera vez que se publica una cifra de este tipo. Esta financiación se desembolsa en forma de subvenciones para los laboratorios gubernamentales o las universidades de investigación o en forma de contratos gubernamentales. Sin embargo, estas cifras del presupuesto federal no incluyen las cuantiosas inversiones en I+D en IA del Departamento de Defensa (DOD) y del sector de los servicios de inteligencia, ya que no se publicaron por motivos de seguridad nacional.

Como se muestra en la figura 7.3.1, los organismos civiles federales -aquellos que no forman parte del Departamento de Defensa o del sector de los servicios de inteligencia- asignaron 973,5 millones de dólares a la I+D en IA para el año fiscal 2020, una cifra que se elevó a 1.100 millones de dólares una vez que se tuvieron en cuenta las asignaciones y transferencias del Congreso. Para el año fiscal 2021, los organismos civiles federales presupuestaron 1.500 millones de dólares, lo que supone un aumento de casi el 55% respecto a su solicitud de 2020.

SOLICITUD DE PRESUPUESTO DE I+D EN IA DEL DEPARTAMENTO DE DEFENSA

Aunque el presupuesto oficial del Departamento de Defensa no está disponible públicamente, Bloomberg Government ha analizado la solicitud de presupuesto del departamento disponible públicamente para investigación, desarrollo, pruebas y evaluación (RDT&E),

Los organismos civiles federales -aquellos que no forman parte del Departamento de Defensa o del sector de los servicios de inteligencia- asignaron 973,5 millones de dólares a la I+D en IA para el año fiscal 2020, cifra que se elevó a 1.100 millones de dólares una vez que se tuvieron en cuenta los créditos y las transferencias del Congreso.

PRESUPUESTO FEDERAL DE EE.UU para I+D en IA, AÑO FISCAL 2021-21

Fuente: Programa NITRD de EE.UU, 2020 | Gráfica: Informe AI Index 2021




Figura 7.3.1

datos que arrojan luz sobre su gasto en I+D en IA. Con 305 programas de I+D del Departamento de Defensa no clasificados que especifican el uso de tecnologías de IA o ML, el presupuesto militar combinado de EE.UU. para I+D en IA en el año fiscal 2021 es de 5.000 millones de dólares (figura 7.3.2). Esta cifra parece coherente con los 5.000 millones de dólares aprobados el año anterior. Sin embargo, la cifra del año fiscal 2021 refleja una solicitud presupuestaria, y no un presupuesto final aprobado. Como se ha señalado anteriormente, una vez que se incluyan los créditos del Congreso, el verdadero nivel de financiación disponible para los programas de I+D de IA del Departamento de Defensa en el año fiscal 2021 puede aumentar sustancialmente. Los cinco principales proyectos que recibirán la mayor cantidad de inversión en I+D en IA en el año fiscal 2021:

- Desarrollo y maduración de capacidades rápidas, del Ejército de Estados Unidos (284,2 millones de dólares)
- Desarrollo de tecnologías y capacidades de lucha contra las armas de destrucción masiva, por la Agencia de Reducción de


Amenazas del Departamento de Defensa (265,2 millones de dólares)

- Equipo interfuncional de guerra algorítmica (Proyecto Maven), por la Oficina del Secretario de Defensa (250,1 millones de dólares)
- Centro Conjunto de Inteligencia Artificial (JAIC), por la Agencia de Sistemas de Información de Defensa (132,1 millones de dólares)
- Programa de Modernización de la Computación de Alto Rendimiento, del Ejército de los Estados Unidos (99,6 millones de dólares))

Además, sólo la Agencia de Proyectos de Investigación Avanzada de Defensa (DARPA) está invirtiendo 568,4 millones de dólares en I+D sobre IA, lo que supone un aumento de 82 millones de dólares con respecto al año fiscal 2020.

PRESUPUESTO DE DEFENSA DE EE.UU PARA INVESTIGACIÓN, DESARROLLO, PRUEBAS Y EVALUACIÓN EN IA, CICLO FISCAL 2018-20

Fuentes: Bloomberg Government & U.S. Department of Defense, 2020 | Gráfica: 2021 AI Index Report



Importante advertencia sobre los datos: Este gráfico ilustra el reto que supone trabajar con las fuentes de datos gubernamentales actuales para comprender el gasto en IA. Según una medida -las solicitudes que incluyen palabras clave relacionadas con la IA-, el Departamento de Defensa solicita más de 5.000 millones de dólares para el desarrollo de la investigación específica de la IA en 2021. Sin embargo, la propia contabilidad del Departamento de Defensa arroja una cifra radicalmente inferior: 841 millones de dólares. Esto tiene que ver con la cuestión de definir dónde termina un sistema de IA y dónde empieza otro; por ejemplo, una iniciativa que utiliza la IA para los drones también puede contar con gastos relacionados con el hardware de los drones dentro de su solicitud de presupuesto de "IA", aunque el componente de software de IA será mucho menor.

GASTO EN CONTRATOS RELACIONADOS CON LA IA DEL GOBIERNO DE EE.UU.

Un indicador más de la inversión pública en tecnologías de IA es el nivel de gasto en contratos de la administración federal. La contratación de productos y servicios suministrados por empresas privadas suele ocupar la mayor parte del presupuesto de un organismo. Bloomberg Government construyó un modelo que capta el gasto de los contratos en tecnologías de IA sumando todas las transacciones de contratación que contienen un conjunto de más de 100 palabras clave específicas de IA en sus títulos o descripciones. Los datos revelan que la cantidad que el gobierno federal gasta en contratos para productos y servicios de IA ha alcanzado un máximo histórico y no muestra signos de desaceleración. Sin embargo, hay que tener en cuenta que durante el proceso de contratación, los proveedores pueden añadir un montón de palabras clave en sus solicitudes, por lo que algunas de estas cosas pueden tener un componente de IA relativamente pequeño en relación con otras partes de la tecnología.

Gasto total en contratos

Los departamentos y agencias federales gastaron un total

de 1.800 millones de dólares en contratos no clasificados relacionados con la IA en el año fiscal 2020. Esto representa un aumento de más del 25% con respecto a los 1.500 millones de dólares que las agencias gastaron en el año fiscal 2019 (figura 7.3.3). El gasto en IA en 2020 fue más de seis veces superior al de hace solo cinco años -unos 300 millones de dólares en el AF 2015-. Sin embargo, para poner esto en perspectiva, el gobierno federal gastó 682 mil millones de dólares en contratos en el año fiscal 2020, por lo que la IA representa actualmente el 0,25% del gasto gubernamental.

Gasto en contratos por departamento y agencia

La figura 7.3.4 muestra que en el año fiscal 2020, el Departamento de Defensa gastó más en contratos relacionados con la IA que cualquier otro departamento u organismo federal (1.400 millones de dólares). En segundo y tercer lugar están la NASA (139,1 millones de dólares) y el Departamento de Seguridad Nacional (112,3 millones de dólares). El Departamento de Defensa, la NASA y el Departamento de Salud y Servicios Humanos encabezan la lista de los que más han gastado en contratos de IA en los últimos 10 años juntos (figura 7.3.5). De hecho, el gasto total en contratos de inteligencia artificial del Departamento de Defensa entre 2001 y 2020 (3.900 millones de dólares) es mayor que el de los otros 44 departamentos y

TOP 10 de DEPARTAMENTOS Y AGENCIAS DEL GOBIERNO DE EE.UU en GASTOS CONTRACTUALES EN IA por AÑO FISCAL, 2020

Fuente: Bloomberg Government, 2020 | Gráfica: Informe AI Index Report 2021




Figura 7.3.3

agencias juntos (2.900 millones de dólares) en el mismo periodo.

De cara al futuro, se espera que el gasto del DOD en contratos de IA solo crezca, ya que el Centro Conjunto de Inteligencia Artificial (JAIC) del Pentágono, establecido en junio de 2018, todavía está en las primeras etapas de impulsar el gasto en IA del DOD. En

2020, el JAIC adjudicó dos contratos masivos, uno a Booz Allen Hamilton para el programa Joint Warfighter de cinco años y 800 millones de dólares, y otro a Deloitte Consulting para un entorno de nube empresarial de cuatro años y 106 millones de dólares para el JAIC, conocido como Joint Common Foundation.

TOP 10 de DEPARTAMENTOS Y AGENCIAS DEL GOBIERNO DE EE.UU en GASTOS CONTRACTUALES EN IA, 2020

Fuente: Bloomberg Government, 2020 | Gráfica: Informe AI Index Report 2021




Figura 7.3.4

TOP 10 de DEPARTAMENTOS Y AGENCIAS DEL GOBIERNO DE EE.UU en GASTOS CONTRACTUALES EN IA, 2020 (SUMA)

Fuente: Bloomberg Government, 2020 | Gráfica: Informe AI Index Report 2021




Figura 7.3.5

7.4 IA Y POLÍTICAS PÚBLICAS

A medida que la IA gana en atención e importancia, las políticas e iniciativas relacionadas con la tecnología se están convirtiendo en prioridades para los gobiernos, las empresas privadas, las organizaciones técnicas y la sociedad civil. En esta sección se examina cómo tres de estos cuatro están estableciendo la agenda para la elaboración de políticas de IA, incluyendo la autoridad legislativa y monetaria de los gobiernos nacionales, así como los grupos de reflexión, la sociedad civil y la industria tecnológica y de consultoría.

REGISTROS LEGISLATIVOS SOBRE IA

El número de registros del Congreso y del Parlamento sobre la IA es un indicador del interés gubernamental en el desarrollo de las

capacidades de la IA y en la legislación de las cuestiones relativas a la IA. En esta sección, utilizamos datos de Bloomberg y McKinsey & Company para determinar el número de estos registros y cómo ha evolucionado ese número en los últimos 10 años.

Bloomberg Government identificó toda la legislación (aprobada o presentada), los informes publicados por los comités del Congreso y los informes del CRS que hacían referencia a una o más palabras clave específicas de la IA. McKinsey & Company buscó los términos “inteligencia artificial” y “aprendizaje automático” en los sitios web del Registro del Congreso de Estados Unidos, el Parlamento del Reino Unido y el Parlamento de Canadá. En el caso de Estados Unidos, cada recuento indica que la IA o el ML se mencionaron durante un evento concreto recogido en el Registro del Congreso, incluida la lectura de un proyecto de ley; en el caso del Reino Unido y Canadá, cada recuento indica

MENCIONES DE IA en las MINUTAS del CONGRESO DE LOS EE.UU por SESIÓN, 2011-20

Fuente: Sitio web del Archivo del Congreso, McKinsey Global Institute, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.1

que la IA o el ML se mencionaron en un comentario u observación concretos durante los procedimientos.¹

Registro del Congreso de los EE.UU.

El 116º Congreso (del 1 de enero de 2019 al 3 de enero de 2021) es la sesión del Congreso más centrada en la IA de la historia. El número de menciones a la IA por parte de este Congreso en la legislación, los informes de las comisiones y los informes del CRS es más del triple que el del 115º Congreso. El interés del Congreso por la IA ha seguido acelerándose en 2020. La figura 7.4.1 muestra que durante este periodo de sesiones del Congreso, 173 leyes distintas se centraron en las tecnologías de IA, su desarrollo, su uso y las normas que las rigen, o contenían un lenguaje al respecto. Durante ese periodo de dos años,

varios comités y subcomités de la Cámara de Representantes y del Senado encargaron 70 informes sobre la IA, mientras que el CRS, encargado de investigar los hechos para los miembros del Congreso, publicó 243 sobre la IA o que hacían referencia a ella.

Menciones de la IA y el ML en las actas del Congreso/Parlamento

Como se muestra en las figuras 7.4.2-7.4.5, el número de menciones a la inteligencia artificial y al aprendizaje automático en las actas del Congreso de Estados Unidos y del Parlamento del Reino Unido siguió aumentando en 2020, mientras que hubo menos menciones en las actas parlamentarias de Canadá.

MENCIONES DE IA y AA en las MINUTAS del CONGRESO DE LOS EE.UUU, 2011-20

Fuente: Sitio web del Archivo del Congreso, McKinsey Global Institute, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.2

¹ Si un orador o miembro mencionó la inteligencia artificial (IA) o el aprendizaje automático (ML) varias veces en sus comentarios, o varios oradores mencionaron la IA o el ML en el mismo evento, sólo aparece una vez como resultado. Los recuentos para la IA y el ML están separados, ya que se realizaron en búsquedas separadas. No se incluyen las menciones de las abreviaturas "IA" o "ML".

MENCIONES DE IA y AA en las MINUTAS del PARLAMENTO BRITÁNICO, 2011-20

Fuente: Sitio web del Parlamento Británico, McKinsey Global Institute, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.3

MENCIONES DE IA y AA en las MINUTAS del PARLAMENTO CANADIENSE, 2011-20

Fuente: Sitio web del Parlamento Canadiense, McKinsey Global Institute, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.4

BANCOS CENTRALES

Los bancos centrales desempeñan un papel fundamental en la dirección de la política monetaria y de divisas de un país o de una unión monetaria. Al igual que muchas otras instituciones, los bancos centrales tienen la tarea de integrar la IA en sus operaciones y confiar en el análisis de big data para ayudarles en la previsión, la gestión de riesgos y la supervisión financiera.

Prattley, un proveedor líder de soluciones automatizadas de investigación de inversiones, supervisa las menciones a la IA en las comunicaciones de los bancos centrales, incluidas las actas de las reuniones, los documentos de política monetaria, los comunicados de prensa, los discursos y otras publicaciones

oficiales.

La figura 7.4.5 muestra un aumento significativo de las menciones a la IA en 16 bancos centrales durante los últimos 10 años, alcanzando un máximo de 1.020 en 2019. El fuerte descenso en 2020 puede explicarse por la pandemia de COVID-19, ya que la mayoría de las comunicaciones de los bancos centrales se centraron en las respuestas a la recesión económica. Además, la Reserva Federal de Estados Unidos, el Norges Bank de Noruega y el Banco Central Europeo encabezan la lista con el mayor número agregado de menciones a la IA en las comunicaciones de los últimos cinco años (figura 7.4.6).

MENCIONES DE IA EN COMUNICACIONES DE BANCOS CENTRALES en el MUNDO por BANCO, 2011-20

Fuente: Prattley/LiquidNet, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.5

² Vea [Science & Technology Review](#) and [Scientific American](#) para más detalles.

MENCIONES DE IA EN COMUNICACIONES DE BANCOS CENTRALES en el MUNDO por BANCO, 2016-20 (SUMA)

Fuente: Prattle/LiquidNet, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.6

POLÍTICAS PÚBLICAS DE IA EN EE.UU.

¿Cuáles son las iniciativas políticas sobre IA fuera de los gobiernos nacionales e intergubernamentales? Hemos supervisado 42 organizaciones destacadas que publican documentos políticos sobre temas relacionados con la IA y hemos evaluado el tema principal y el secundario en los documentos políticos publicados en 2019 y 2020. (Véase el Apéndice para una lista completa de las organizaciones incluidas.) Esas organizaciones tienen sede en Estados Unidos o tienen una presencia considerable en ese país, y las agrupamos en tres categorías: grupos de reflexión, institutos de política y academia (27); organizaciones de la sociedad civil, asociaciones y consorcios (9); e industria y consultoría (6).

Los documentos sobre políticas de IA se definen como documentos de investigación, informes de investigación, entradas de blog y resúmenes que se centran en un tema político específico relacionado con la IA y proporcionan recomendaciones claras para los responsables políticos. Los temas primarios significan

que dicho tema es el enfoque principal del documento de política, mientras que los temas secundarios significan que el documento de política toca brevemente el tema o el tema es un subenfoco del documento.

Los datos combinados para 2019 y 2020 sugieren que los temas de innovación y tecnología, asuntos internacionales y seguridad internacional, e industria y regulación son los principales enfoques de los documentos de política de IA en Estados Unidos (figura 7.4.7). Son menos los documentos que se centran en temas relacionados con la ética de la IA -como la ética, la equidad y la inclusión; la privacidad, la seguridad y la protección; y la justicia y el cumplimiento de la ley-, que han sido en gran medida temas secundarios. Además, los temas relacionados con las ciencias físicas, la energía y el medio ambiente, las humanidades y la democracia son los que han recibido menos atención en los documentos de política de IA de Estados Unidos.

AI POLÍTICAS DE IA de EE.UU por TEMA, 2019-20 (SUMA)

Fuente: Stanford HAI y AI Index, 2020 | Gráfica: Informe AI Index 2021




Figura 7.4.7



Apéndice



Informe 2021 del
Artificial Intelligence Index

Apéndice

CAPÍTULO 1	Investigación y Desarrollo	179
CAPÍTULO 2	Rendimiento Técnico	194
CAPÍTULO 3	Economía	203
CAPÍTULO 4	Educación en IA	208
CAPÍTULO 5	Desafíos Éticos de las Aplicaciones de la IA	211
CAPÍTULO 6	Diversidad en IA	214
CAPÍTULO 7	Políticas y Estrategias Nacionales en IA	215
VITALIDAD GLOBAL DE IA		218

CAPÍTULO 1: INVESTIGACIÓN Y DESARROLLO

ELSEVIER

Preparado por Jörg Hellwig y Thomas A. Collins

Fuente

La base de datos [Scopus](#) de Elsevier sobre publicaciones académicas ha indexado más de 81 millones de documentos revisados por pares. Estos datos han sido recopilados por [Elsevier](#).

Metodología

Scopus etiqueta sus artículos con palabras clave, fechas de publicación, afiliaciones de países y otra información bibliográfica.

El clasificador de IA de Elsevier aprovechó las siguientes características extraídas de los registros de Scopus que se devolvieron como resultado de la consulta con los aproximadamente 800 términos de búsqueda de IA proporcionados. Cada registro introducido en la creación de características también mantenía una lista de cada término de búsqueda que daba resultados para ese registro en particular:

- **hasAbs:** Valor booleano si el registro tenía o no una sección de texto de resumen en el registro (por ejemplo, algunos registros son sólo título y palabras clave opcionales)
- **coreCnt:** número de términos de búsqueda con puntuación central presentes en el registro
- **mediumCnt:** número de términos de búsqueda de puntuación media presentes en el registro
- **lowCnt:** número de términos de búsqueda de baja puntuación presentes en el registro
- **totalCnt:** número total de términos de búsqueda presentes en el registro
- **pcntCore:** $\text{coreCnt}/\text{totalCnt}$
- **pcntMedium:** $\text{mediumCnt}/\text{totalCnt}$
- **pcntLow:** $\text{lowCnt}/\text{totalCnt}$
- **totalWeight** = $5 * \text{coreCnt} + 3 * \text{mediumCnt} + 1 * \text{lowCnt}$
- **normWeight** = $\text{if}(\text{has Abs}) \{ \text{totalWeight} / (\text{title.length} + \text{abstract.length}) \}$ else
- $\{ \text{totalWeight}/\text{title.length} \}$
- **hasASJC:** Boolean value: ¿tiene el registro una lista ASJC asociada?

- **isAiASJC:** ¿la lista de ASJC contiene 1702?
- **isCompSciASJC** does ASJC list contain a 17XX ASJC code (“1700,” “1701,” “1702,” “1703,” “1704,” “1705,” “1706,” “1707,” “1708,” “1709,” “1710,” “1711,” “1712”)
- **isCompSubj:** ¿tiene el registro de Scopus un código de materia de Computer Science asociado? Esto debería corresponder 1:1 a isCompSciASJC. Scopus tiene 27 áreas temáticas principales, una de las cuales es Computer Science. La función comprueba si la publicación está dentro de Computer Science o no. Esto no es una exclusión. **pcntCompSciASJC:** porcentaje de códigos ASJC para el registro que son de la lista de códigos CompSci ASJC

Los detalles sobre el conjunto de datos de Elsevier que definen la IA, las afiliaciones de los países y las subcategorías de IA se pueden encontrar en el Apéndice del Informe del Índice de IA de 2018.

Consideraciones

- El sistema Scopus se actualiza de forma retroactiva. Por ello, el número de artículos para una determinada consulta puede aumentar con el tiempo.
- Los miembros del equipo de Elsevier comentaron que los datos de los artículos publicados después de 1995 serían los más fiables. Los datos brutos tienen 1996 como año de partida para los datos de Scopus.

Consideraciones específicas respecto a las publicaciones de IA por región

- Los artículos se contabilizan utilizando el recuento completo y no el fraccionado. Los trabajos asignados a varios países (o regiones) debido a colaboraciones se contabilizan en cada país (o región). Esto explica por qué las cifras principales de un año determinado pueden no coincidir con las de cada país. Por ejemplo, un trabajo asignado a Alemania, Francia y Estados Unidos aparecerá en el recuento de cada país, pero sólo una vez para Europa (más una vez para Estados Unidos), además de contabilizarse sólo a nivel global.
- “Otros” incluye todos los demás países que han publicado uno o más artículos sobre IA en Scopus.

Consideraciones específicas respecto a las publicaciones por tema

- El informe del índice de IA de 2017 solo mostraba trabajos de IA dentro de la categoría de CS. En los informes de 2018 y 2019, se incluyeron todos los trabajos etiquetados como IA, independientemente de que entraran en la categoría más amplia de CS.
- Scopus tiene una categoría temática llamada IA, que es un subconjunto de la SC, pero esto sólo es relevante para un enfoque de categoría temática para definir los artículos de IA. La metodología utilizada para el informe incluye todos los artículos, ya que cada vez más no todos los artículos de IA están incluidos en la categoría CS.

Consideraciones específicas respecto a la metodología

- Todo el proceso de recopilación de datos fue realizado por Elsevier internamente. El Índice de IA no participó en el proceso de selección de palabras clave ni en el recuento de artículos relevantes.
- Los límites de la IA son difíciles de establecer, en parte debido al rápido aumento de las aplicaciones en muchos campos, como el reconocimiento del habla, la visión artificial, la robótica, la ciberseguridad, la bioinformática y la asistencia sanitaria. Pero los límites también son difíciles de definir debido a la dependencia metodológica de la IA de muchas áreas, como la lógica, la probabilidad y la estadística, la optimización, la fotogrametría, la neurociencia y la teoría de los juegos, por nombrar sólo algunas. Dado el interés de la comunidad en la bibliometría de la IA, sería valioso que los grupos que realizan estos estudios se esforzaran por alcanzar un nivel de transparencia en sus métodos, lo que favorecería la reproducibilidad de los resultados, especialmente en diferentes bases de datos bibliográficas subyacentes.

Conjunto de entrenamiento de IA

Un conjunto de formación de aproximadamente 1.500 publicaciones define el campo de la IA. El conjunto es sólo el EID (el identificador de Scopus de las publicaciones subyacentes). Las publicaciones pueden buscarse y descargarse directamente desde Scopus o a través de la API. El conjunto de entrenamiento es un conjunto de publicaciones seleccionadas aleatoriamente de los siete millones de publicaciones iniciales. Después de ejecutar el algoritmo, verificamos los resultados del conjunto de entrenamiento con el conjunto de oro (publicaciones revisadas a mano por expertos para confirmar que son definitivamente IA).

MICROSOFT ACADEMIC GRAPH: METODOLOGÍA

Preparado por Zhihong Shen, Boya Xie, Chiyuan Huang, Chieh-Han Wu, y Kuansan Wang

Fuente

Microsoft Academic Graph¹ es un gráfico heterogéneo que contiene registros de publicaciones científicas y relaciones de citación entre esas publicaciones, así como autores, instituciones, revistas, conferencias y campos de estudio. Este gráfico se utiliza para potenciar las experiencias en Bing, Cortana, Word y Microsoft Academic. Actualmente, el gráfico se actualiza semanalmente. Más información sobre MAG [aquí](#).

Metodología

Atribución de datos MAG: cada artículo se cuenta exactamente una vez. Cuando un artículo tiene varios autores o regiones, el crédito se distribuye por igual entre las distintas regiones. Por ejemplo, si un artículo tiene dos autores de Estados Unidos, uno de China y otro del Reino Unido, Estados Unidos, China y el Reino Unido reciben un tercio de los créditos cada uno.

Métricas: número total de artículos publicados (artículos de revistas, artículos de conferencias, patentes, repositorios²); número total de citas de los artículos publicados.

Definición: El recuento de citas y referencias representa el número de métricas respectivas para los documentos de IA recopilados de todos los documentos. Por ejemplo, en “OutAiPaperCitationCountryPairByYearConf.csv”, una fila que indique “China, Estados Unidos, 2016, 14955” significa que los artículos de IA de conferencias de China publicados en 2016 recibieron 14.955 citas de (todos) los artículos estadounidenses indexados por MAG.

Curaduría del conjunto de datos y referencias de MAG: En general, los robots se sitúan encima de un rastreador de Bing para leer todo lo que hay en la web y tienen acceso a todo el índice web. Como resultado, MAG es capaz de programar los robots para que realicen más búsquedas en la web de las que puede realizar un humano normal. Esto ayuda a desambiguar

entidades con los mismos nombres. Por ejemplo, en el caso de los autores, MAG consigue utilizar adicionalmente todos los CV y las páginas institucionales de la web como señales para reconocer y verificar las afirmaciones³. MAG ha comprobado que este enfoque es superior a los resultados de los mejores de la [competencia KDD Cup 2013](#), que sólo utiliza datos de todos los registros de publicación y los identificadores abiertos de investigadores y colaboradores (ORCID).

Notas acerca de los datos MAG

Artículos de conferencias: después de examinar los contenidos y las fuentes de datos, se determinó que algunas de las ponencias de la conferencia de 2020 no estaban debidamente etiquetadas con su lugar de celebración. Muchas ponencias de conferencias en el sistema MAG están bajo arXiv papers, pero debido a problemas derivados de algunas fuentes de datos (incluyendo retrasos en DBLP y cambios en el formulario web en el sitio de la ACM), posiblemente fueron omitidas como ponencias de conferencias de 2020 (ICML-PKDD, IROS, etc.). Sin embargo, las principales conferencias de IA (seleccionadas no en función del número de publicaciones, sino teniendo en cuenta tanto el número de publicaciones y citas como el prestigio de la comunidad) están completas. En 2020, las 20 principales conferencias presentaron 103.000 trabajos, lo que supone el 13,7% de todos los trabajos de conferencias de IA, y recibieron 7,15 millones de citas colectivamente, lo que supone el 47% de todas las citas recibidas por todos los trabajos de conferencias de IA. El número de publicaciones de conferencias de 2020 es ligeramente inferior al de 2019. Se sabe que faltan datos para ICCV y NAACL. Alrededor de 100 ponencias de la conferencia Autonomous Agents and Multiagent Systems (AAMAS) se atribuyen erróneamente a una revista homónima.

Países desconocidos para revistas y conferencias: en los últimos 20 a 30 años, el 30% de los datos de afiliación de revistas y conferencias carece de afiliación por país o región, debido a errores en el formato de los artículos, la fuente de datos y el análisis sintáctico del PDF, entre otros.

¹ Vea “A Review of Microsoft Academic Services for Science of Science Studies” y “Microsoft Academic Graph: When Experts Are Not Enough” para más detalles.

² El repositorio como tipo de publicación en MAG se refiere tanto a los *documentos/artículos* como a versiones posteriores. En el ámbito de la IA, procede principalmente de arXiv. Véase “[Is Preprint the Future of Science? A Thirty Year Journey of Online Preprint Services](#)” para conocer los detalles.

³ Vea “Machine Verification for Paper and Author Claims” y “How Microsoft Academic Uses Knowledge to Address the Problem of Conflation/Disambiguation” para conocer los detalles.

MICROSOFT ACADEMIC GRAPH: DESAFÍO DE LOS DATOS DE PATENTES

Como se menciona en el informe, los datos sobre patentes -especialmente la información sobre afiliación- están incompletos en la base de datos del MAG. La razón de esta baja cobertura es doble. En primer lugar, las solicitudes publicadas por las oficinas de patentes suelen identificar a los inventores por sus residencias y no por sus afiliaciones. Aunque las solicitudes de patentes suelen contener información sobre los “cesionarios” de una patente, no significan necesariamente que las invenciones subyacentes procedan de las instituciones cesionarias. Por lo tanto, las afiliaciones detectadas pueden ser inexactas. En caso de que una patente revele las publicaciones académicas subyacentes a la invención, el MAG puede inferir las afiliaciones de los inventores a través de las publicaciones académicas.

En segundo lugar, para maximizar la protección de la propiedad intelectual en todo el mundo, las instituciones suelen presentar múltiples solicitudes de patente sobre la misma invención en varias jurisdicciones. Estas solicitudes múltiples, aunque

parezcan muy diferentes porque los títulos y los nombres de los inventores suelen traducirse a los idiomas locales, son en realidad el resultado de una única invención. Por tanto, los recuentos de patentes en bruto inflan las invenciones en sus respectivos ámbitos. Para remediar este problema, MAG utiliza la función de identificación de la familia de patentes para combinar todas las solicitudes con la presentación original, lo que permite que la base de datos cuente las solicitudes de todo el mundo del mismo origen sólo una vez.⁴ La confluencia de las múltiples solicitudes de patentes de la misma invención no es perfecta, y las sobreconfiguraciones de las patentes son más notables en MAG que en los artículos académicos.

Estos problemas plantean dudas sobre la fiabilidad de los datos sobre la proporción de publicaciones de patentes de IA tanto por regiones como por zonas geográficas. Estos gráficos se incluyen a continuación.

PUBLICACIONES DE PATENTES (% del TOTAL MUNDIAL) por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.4.1

⁴ Lea “Sharpening Insights into the Innovation Landscape with a New Approach to Patents” para información más detallada.

Por zona geográfica

PATENTES DE IA PUBLICADAS (% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.4.2

Citas

CITAS DE PATENTES (% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.4.3

MICROSOFT ACADEMIC GRAPH: RETOS DE MEDICIÓN Y DEFINICIÓN ALTERNATIVA DE LA IA

Como el equipo del Índice de IA analizó en el documento “[Measurement in AI Policy: Opportunities and Challenges](#),” la elección de cómo definir la IA y captar correctamente los datos bibliométricos pertinentes sigue siendo un reto. Los datos del informe principal se basan en una definición restringida de la IA, adoptada por el MAG, que se ajusta a la utilizada en anteriores informes del Índice de IA. Una de las consecuencias es que dicha definición excluye muchas publicaciones de IA de los lugares que se consideran fundamentales para la IA. Por ejemplo, sólo el 25% de las publicaciones de la conferencia de la AAAI de 2020 están incluidas en el conjunto de datos de la conferencia original.

Para estimular el debate sobre este importante tema, esta sección presenta los datos del MAG con una definición alternativa de la IA utilizada por la Organización para la Cooperación y el Desarrollo Económico (OCDE). La OCDE define las publicaciones

de IA como los artículos de la base de datos del MAG etiquetados con un campo de estudio que se clasifica en el campo de estudio de la “inteligencia artificial” o del “aprendizaje automático”, así como sus subtemas en la taxonomía del MAG.⁵ Se trata de una definición más liberal que la utilizada por el MAG, que sólo considera publicaciones de IA las etiquetadas con “inteligencia artificial”. Por ejemplo, un artículo de aplicación en biología que utilice técnicas de ML se considerará una publicación de IA según la definición de la OCDE, pero no según la definición del MAG, a menos que el artículo esté etiquetado específicamente en la categoría de IA.

A continuación se presentan gráficos correspondientes a los del texto principal, pero utilizando la definición de la OCDE. Las tendencias generales son muy similares.

DEFINICIÓN DE LA OCDE: NÚMERO DE PUBLICACIONES DE IA EN REVISTAS, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.1a

⁵ Lea [OECD.AI Policy Observatory MAG methodological note](#) para más detalles sobre la definición MAG-OECD de IA y “[A Web-scale System for Scientific Knowledge Exploration](#)” sobre la taxonomía MAG.

Publicaciones periódicas en IA (Definición de la OECD)

DEFINICIÓN DE LA OECD: PUBLICACIONES de IA en REVISTAS (% DEL TOTAL de PUBLICACIONES), 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.1b

DEFINICIÓN DE LA OECD: CITAS DE IA EN REVISTAS (% DEL TOTAL MUNDIAL) por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.2

DEFINICIÓN DE LA OECD: PUBLICACIONES DE IA EN REVISTAS (% DEL TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.3

DEFINICIÓN DE LA OECD: CITAS DE IA EN REVISTAS (% DEL TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.4

Publicaciones en conferencias de IA (bajo la definición de la OECD)

DEFINICIÓN DE LA OECD: NÚMERO DE PUBLICACIONES EN CONFERENCIAS DE IA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.5a

DEFINICIÓN DE LA OECD: PUBLICACIONES EN CONFERENCIAS DE IA (% DE TODAS LAS CONFERENCIAS), 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.5b

DEFINICIÓN DE LA OECD: PUBLICACIONES EN CONFERENCIAS DE IA por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.6

DEFINICIÓN DE LA OECD: PUBLICACIONES EN CONFERENCIAS DE IA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.7

DEFINICIÓN DE LA OECD: CITAS DE CONFERENCIAS(% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 |Gráfica: Informe AI Index Report 2021




Figura 1.5.8

Publicaciones de patentes de IA (bajo la definición de la OECD)

DEFINICIÓN DE LA OECD: NÚMERO DE PATENTES PUBLICADAS DE IA, 2000-20

Fuente: Microsoft Academic Graph, 2020 |Gráfica: Informe AI Index Report 2021




Figura 1.5.9a

DEFINICIÓN DE LA OECD: PATENTES PUBLICADAS DE IA (% de TODAS LAS PATENTES PUBLICADAS), 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.9b

DEFINICIÓN DE LA OECD: CITAS DE PATENTES DE IA (% del TOTAL MUNDIAL) por REGIÓN, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.10

DEFINICIÓN DE LA OECD: PATENTES PUBLICADAS DE IA (% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.11

DEFINICIÓN DE LA OECD: CITAS DE PATENTES DE IA (% del TOTAL MUNDIAL) por ZONA GEOGRÁFICA, 2000-20

Fuente: Microsoft Academic Graph, 2020 | Gráfica: Informe AI Index Report 2021




Figura 1.5.12

ARTÍCULOS EN ARXIV

Preparado por Jim Entwood y Eleonora Presani

fuentes

arXiv.org es un archivo en línea de artículos de investigación en los campos de la física, las matemáticas, la informática, la biología cuantitativa, las finanzas cuantitativas, la estadística, la ingeniería eléctrica y la ciencia de los sistemas, y la economía. arXiv es propiedad de la Universidad de Cornell y está gestionado por ella. Ver más información en [arXiv.org](https://arxiv.org).

Metodología

Los datos brutos para nuestro análisis fueron proporcionados por los representantes de arXiv.org. Las palabras clave que seleccionamos, y sus respectivas categorías, se encuentran a continuación:

Artificial intelligence (cs.AI)
Computation and language (cs.CL)
Computer vision and pattern recognition (cs.CV)
Machine learning (cs.LG)
Neural and evolutionary computing (cs.NE)
Robotics (cs.RO)
Machine learning in stats (stats.ML)

Para la mayoría de las categorías, arXiv proporcionó datos para 2015-2020. Para revisar las tasas de envío de otras categorías en arXiv, consulte la página de arXiv.org [estadísticas de envíos](#).

El equipo de arXiv ha ampliado las estadísticas de envío disponibles al público. Se trata de una aplicación basada en [tableau](#) con pestañas en la parte superior para mostrar varias estadísticas de envío y filtros en la barra lateral para desglosar por temas. (Pase el ratón por encima de los gráficos para ver las categorías individuales). Los datos están pensados para

mostrarse mensualmente con opciones de descarga.

arXiv está buscando activamente formas de mejorar el apoyo a los investigadores de IA/ML a medida que el campo crece y el descubrimiento de contenidos se vuelve más difícil. Por ejemplo, puede haber formas de crear categorías más finas en arXiv para el aprendizaje automático, con el fin de ayudar a los investigadores de los subcampos a compartir y encontrar trabajos más fácilmente. El otro campo en rápida expansión es el de la visión artificial, en el que existe un considerable solapamiento para las aplicaciones de ML de la visión artificial.

Consideraciones

- Las categorías son autoidentificadas por los autores: las que se muestran son seleccionadas como la categoría “principal”. Por lo tanto, no hay un único proceso de categorización automatizado. Además, las categorías de inteligencia artificial o aprendizaje automático pueden ser categorizadas por otros subcampos o palabras clave.
- Los miembros del equipo de arXiv sugieren que la participación en arXiv puede engendrar una mayor participación, lo que significa que el aumento de una subcategoría en arXiv podría impulsar la participación excesiva de ciertas comunidades.

NESTA

Preparado por Joel Kliger y Juan Mateos-Garcia

Fuente

Los detalles se pueden encontrar en la siguiente publicación:

[Deep Learning, Deep Change? Mapping the Development of the Artificial Intelligence General Purpose Technology](#)

Metodología

Los artículos sobre aprendizaje profundo se identificaron a través de un análisis de modelos temáticos de los resúmenes de los artículos arXiv en las categorías CS (ciencias de la computación) y stats.ML (estadísticas: categoría de aprendizaje automático) arXiv. Los datos se enriquecieron con la afiliación institucional y la información geográfica del Microsoft Academic Graph y el Global Research Identifier. La herramienta arXlive de Nesta está disponible [aquí](#).

Obtén el código

El código para la recogida y el procesamiento de datos puede encontrarse [aquí](#); o, sin sobrecarga de infraestructura [aquí](#).

ESTRELLAS DE GITHUB

Fuente

[GitHub: el historial de estrellas](#) (disponible en el [historial de estrellas del sitio web](#)) fue usado para obtener los datos.

Metodología

El gráfico del informe muestra el número de estrellas de varios repositorios de GitHub a lo largo del tiempo. Los repositorios son los siguientes: apache/incubator-mxnet, BVLC/caffe, cafe2/cafe2, dmlc/mxnet, fchollet/keras, Microsoft/CNTK, pytorch/pytorch, scikit-learn/scikit-learn, tensorflow/tensorflow, Theano/Theano, Torch/Torch7.

Consideraciones

El Archivo de GitHub actualmente no proporciona una forma de contar cuando los usuarios eliminan una estrella de un repositorio. Por lo tanto, los datos reportados sobrestiman ligeramente el número de estrellas. Una comparación con el número real de estrellas de los repositorios en GitHub revela que las cifras son bastante cercanas y que las tendencias no cambian.

CAPÍTULO 2: RENDIMIENTO TÉCNICO

IMAGENET: PRECISIÓN

Preparado por Jörg Hellwig y Thomas A. Collins

Fuente

Los datos sobre la exactitud de ImageNet se recuperaron mediante una revisión bibliográfica de arXiv. Todos los resultados comunicados se probaron en el conjunto de validación de LSRVC 2012, ya que los resultados en el conjunto de prueba, que no son significativamente diferentes, no son públicos. Su ordenamiento puede diferir de los resultados reportados en el sitio web de LSRVC, ya que esos resultados se obtuvieron en el conjunto de prueba. Las fechas que indicamos corresponden al día en que un artículo se publicó por primera vez en arXiv, y la exactitud top-1 corresponde al resultado indicado en la versión más reciente de cada artículo. Seleccionamos un resultado superior en cualquier momento desde 2012 hasta el 17 de noviembre de 2019. Algunos de los resultados que mencionamos se presentaron a concursos de LSRVC a lo largo de los años. La clasificación de imágenes formó parte del LSRVC hasta 2014; en 2015, se sustituyó por una tarea de localización de objetos, en la que los resultados de la clasificación seguían siendo comunicados pero ya no formaban parte del concurso, habiendo sido sustituidos por tareas más

difíciles.

Para los artículos publicados en 2014 y después, informamos del mejor resultado obtenido utilizando un solo modelo (no incluimos conjuntos) y utilizando pruebas de un solo cultivo. Para los tres primeros modelos (AlexNet, ZFNet, Five Base), informamos de los resultados de los conjuntos de modelos. Aunque informamos de los resultados como se ha descrito anteriormente, debido a la diversidad de modelos, métodos de evaluación y métricas de exactitud, hay muchas otras formas de informar del rendimiento de ImageNet. Algunas opciones posibles son:

- Conjunto de evaluación: conjunto de validación (disponible públicamente) o conjunto de prueba (disponible sólo para los organizadores de la LSRVC)
- Medición del rendimiento: exactitud Top-1 (si la etiqueta correcta era la misma que la primera etiqueta predicha para cada imagen) o exactitud Top-5 (si la etiqueta correcta estaba presente entre las cinco primeras etiquetas predichas para cada imagen)
- Método de evaluación: cultivo único o cultivo múltiple

Para destacar los avances en la exactitud de los 5 primeros, hemos tomado las puntuaciones de los siguientes trabajos, sin datos de entrenamiento adicionales:

[Fixing the Train-Test Resolution Discrepancy: FixEfficientNet](#)

[Adversarial Examples Improve Image Recognition](#)

[OverFeat: Integrated Recognition, Localization and Detection Using Convolutional Networks](#)

[Local Relation Networks for Image Recognition](#)

[Densely Connected Convolutional Networks](#)

[Revisiting Unreasonable Effectiveness of Data in Deep Learning Era](#)

[Squeeze-and-Excitation Networks](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[MultiGrain: A Unified Image Embedding for Classes and Instances](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[Billion-Scale Semi-Supervised Learning for Image Classification](#)

[GPipe: Efficient Training of Giant Neural Networks Using Pipeline Parallelism](#)

[RandAugment: Practical Data Augmentation with No Separate Search](#)

[Fixing the Train-Test Resolution Discrepancy](#)

Para destacar los avances en la exactitud de los 5 primeros, tomamos las puntuaciones de los siguientes trabajos, con datos de entrenamiento adicionales:

[Meta Pseudo Labels](#)

[Self-Training with Noisy Student Improves ImageNet Classification](#)

[Big Transfer \(BiT\): General Visual Representation Learning](#)

[ImageNet Classification with Deep Convolutional Neural Networks](#)

[ESPNetv2: A Light-Weight, Power Efficient, and General Purpose Convolutional Neural Network](#)

[Xception: Deep Learning with Depthwise Separable Convolutions](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[Self-training with Noisy Student Improves ImageNet Classification](#)

Para destacar el progreso en la exactitud del top-1, tomamos las puntuaciones de los siguientes trabajos, sin datos de entrenamiento adicionales:

[Fixing the Train-Test Resolution Discrepancy: FixEfficientNet](#)

[Adversarial Examples Improve Image Recognition](#)

[OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks](#)

[Densely Connected Convolutional Networks](#)

[Revisiting Unreasonable Effectiveness of Data in Deep Learning Era](#)

[Dual Path Networks](#)

[Res2Net: A New Multi-Scale Backbone Architecture](#)

[Billion-Scale Semi-Supervised Learning for Image Classification](#)

[Squeeze-and-Excitation Networks](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[MultiGrain: A Unified Image Embedding for Classes and Instances](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[Billion-Scale Semi-Supervised Learning for Image Classification](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[RandAugment: Practical Data Augmentation with No Separate Search](#)

[Fixing the Train-Test Resolution Discrepancy](#)

Para destacar el progreso en la exactitud del top-1, tomamos las puntuaciones de los siguientes trabajos, sin datos de entrenamiento adicionales:

[Meta Pseudo Labels](#)

[Sharpness-Aware Minimization for Efficiently Improving Generalization](#)

[An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale](#)

[Fixing the Train-Test Resolution Discrepancy: FixEfficientNet](#)

[Self-training with Noisy Student Improves ImageNet Classification](#)

[Big Transfer \(BiT\): General Visual Representation Learning](#)

[ImageNet Classification with Deep Convolutional Neural Networks](#)

[ESPNetv2: A Light-Weight, Power Efficient, and General Purpose Convolutional Neural Network](#)

[Xception: Deep Learning with Depthwise Separable Convolutions](#)

[EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks](#)

[Self-training with Noisy Student Improves ImageNet Classification](#)

El estimado de desempeño humano es de [Russakovsky et al, 2015](#). Aprenda más acerca de la competencia LSVRC ImageNet y el conjunto de datos de [ImageNet](#).

IMAGENET: DURACIÓN DEL ENTRENAMIENTO

Las tendencias también pueden observarse estudiando los trabajos de investigación que analizan el tiempo que se tarda en entrenar ImageNet en cualquier infraestructura. Para recopilar estos datos, hemos estudiado los trabajos de investigación de los últimos años que intentaban optimizar el entrenamiento de ImageNet hasta un nivel de exactitud estándar, al tiempo que competían por reducir el tiempo total de entrenamiento.

Fuente

Los datos se obtienen de [MLPerf](#). Los datos detallados para años específicos están disponibles:

2020: [Resultados de entrenamiento MLPerf v0.7](#)

2019: [Resultados de entrenamiento MLPerf v0.6](#)

2018: [Resultados de entrenamiento MLPerf v0.5](#)

Notas

Los datos de MLPerf están disponibles en sistemas en la nube para su alquiler. Los sistemas disponibles en las instalaciones sólo contienen componentes que están disponibles para su compra. Los sistemas de previsión deben poder presentarse como disponibles en la nube o disponibles in situ en la siguiente ronda de presentación. Los sistemas de investigación, desarrollo o internos (RDI) contienen hardware o software experimental, en desarrollo o de uso interno. Cada fila de la tabla de resultados es un conjunto de resultados producidos por un único remitente que utiliza la misma pila de software y plataforma de hardware. Cada fila contiene la siguiente información:

Remitente: la organización que ha enviado los resultados

Sistema: descripción general del sistema

Procesador y número: el tipo y número de CPUs utilizadas, si las CPUs realizan la mayor parte del cálculo de ML

Acelerador y número: el tipo y número de aceleradores utilizados, si los aceleradores realizan la mayor parte del cálculo de ML

Software: el marco de trabajo de ML y la biblioteca de hardware de ML principal utilizada

Resultados del benchmark: tiempo de entrenamiento para alcanzar un objetivo de calidad especificado, medido en minutos

Detalles: enlace a los metadatos para su presentación

Código: enlace al código para su presentación

IMAGENET: COSTO DE ENTRENAMIENTO

Fuente

DAWNBench es un conjunto de benchmarks para el entrenamiento y la inferencia del aprendizaje profundo de principio a fin. El tiempo y el coste de los cálculos son recursos fundamentales para la creación de modelos profundos, pero muchos benchmarks existentes se centran únicamente en la exactitud del modelo. DAWNbench proporciona un conjunto de referencia de cargas de trabajo de aprendizaje profundo comunes para cuantificar el tiempo de entrenamiento, el coste de entrenamiento, la latencia de inferencia y el coste de inferencia a través de diferentes estrategias de optimización, arquitecturas de modelos, frameworks de software, nubes y hardware. Más detalles disponibles en [DawnBench](#).

Nota

La fuente de datos DawnBench ha quedado obsoleta para el periodo posterior a marzo de 2020, y MLPerf es la fuente más fiable y actualizada para las mediciones de computación de IA.

COCO: COMMON OBJECTS IN CONTEXT

Los datos de detección de puntos clave de COCO proceden de la [tabla de clasificación de COCO](#).

COCO: ESTIMACIÓN DE DENSEPOSE

Recopilamos datos del reto [CODALab 2020](#) y leímos artículos para compliar un conjunto de datos completos sobre el avance técnico en este desafío. La lista detallada de artículos y fuentes usados en nuestro estudio incluye:

[DensePose: Dense Human Pose Estimation In the Wild](#)

[COCO-DensePose 2018 CodaLab](#)

[Parsing R-CNN for Instance-Level Human Analysis](#)

[Capture Dense: Markerless Motion Capture Meets Dense Pose Estimation](#)

[Slim DensePose: Thrifty Learning from Sparse Annotations and Motion Cues](#)

[COCO-DensePose 2020 CodaLab](#)

[Transferring Dense Pose to Proximal Animal Classes](#)

[Making DensePose Fast and Light](#)

[SimPose: Effectively Learning DensePose and Surface Normals of People from Simulated Data](#)

ACTIVITYNET: LOCALIZACIÓN DE ACTIVIDADES DENTRO DE UN INTERVALO DE TIEMPO

En el reto, hay tres tareas separadas, pero se centran en el problema principal de localizar temporalmente dónde ocurren las actividades en los vídeos no recortados del benchmark [ActivityNet](#). Hemos recopilado varios atributos para la tarea de localización temporal en el reto durante las últimas cuatro rondas. A continuación se incluye un enlace a las estadísticas y tendencias generales de esta tarea, así como algunos análisis detallados (por ejemplo, ¿cómo ha mejorado el rendimiento de las clases de actividad individuales a lo largo de los años? ¿Cuáles son las clases más difíciles y más fáciles ahora? ¿Qué clases han mejorado más a lo largo de los años?). Consulte la pestaña Diagnóstico de rendimiento (2020) para obtener una actualización detallada de las tendencias. Por favor, [ActivityNet Statistics](#) en la carpeta compartida públicamente para mayor detalle.

YOLO (YOU ONLY LOOK ONCE)

YOLO es un modelo de red neuronal utilizado principalmente para la detección de objetos en imágenes y en vídeos en tiempo real. mAP (media de la precisión promedio) es una métrica que se utiliza para medir la exactitud de los detectores de objetos. Es una combinación de exactitud y recuperación. mAP es la media de la exactitud y la recuperación calculada sobre un documento. El rendimiento de YOLO ha aumentado gradualmente con el desarrollo de nuevas arquitecturas y versiones en los últimos años. Con el aumento del tamaño del modelo, su exactitud media también aumenta, con la correspondiente disminución de los FPS del vídeo.

Hemos realizado un estudio detallado de los artículos de arXiv y del repositorio de GitHub para segmentar el progreso de YOLO en sus distintas versiones. A continuación se muestran las referencias de las fuentes originales:

YOLOv1:

[You Only Look Once: Unified, Real-Time Object Detection](#)

YOLOv2:

[YOLO9000: Better, Faster, Stronger](#)

[YOLO: Real-Time Object Detection](#)

YOLOv3:

[YOLOv3: An Incremental Improvement](#)

[Learning Spatial Fusion for Single-Shot Object Detection](#)

[GitHub: ultralytics/yolov3](#)

YOLOv4:

[YOLOv4: Optimal Speed and Accuracy of Object Detection](#)

[GitHub: AlexeyAB/darknet](#)

YOLOv5:

[GitHub: ultralytics/yolov5](#)

PP-YOLO:

[PP-YOLO: An Effective and Efficient Implementation of Object Detector](#)

POLY-YOLO:

[Poly-YOLO: Higher Speed, More Precise Detection and Instance Segmentation for YOLOV3](#)

RESPUESTAS A PREGUNTAS CON APOYO VISUAL (VQA) PAPERS WITH CODE: ENLACES ENTRE ARTÍCULOS Y CÓDIGO

Los datos de exactitud de VQA fueron suministrados por el equipo [VQA](#). Aprenda más acerca de VQA [aquí](#). Más detalles acerca de VQA 2020 están disponibles [aquí](#).

Metodología

Dada una imagen y una pregunta en lenguaje natural sobre la imagen, la tarea consiste en proporcionar una respuesta precisa en lenguaje natural. El reto está alojado en el sitio web de [VQA Challenge](#). El reto está alojado en [EvalAI](#). El enlace del desafío está [aquí](#).

Los conjuntos de entrenamiento, validación y prueba de VQA v2.0, que contienen más de 250.000 imágenes y 1,1 millones de preguntas, están disponibles en la página de [descargas](#). Todas las preguntas están anotadas con 10 respuestas concisas y abiertas cada una. Las anotaciones de los conjuntos de entrenamiento y validación están disponibles públicamente.

VQA Challenge 2020 es la quinta edición de VQA Challenge. Los resultados de las versiones anteriores del VQA Challenge se anunciaron en el VQA Challenge Workshop en CVPR 2019, CVPR 2018, CVPR 2017 y CVPR 2016. Puede encontrar más detalles sobre los desafíos anteriores [aquí](#): [VQA Challenge 2019](#), [VQA Challenge 2018](#), [VQA Challenge 2017](#), [VQA Challenge 2016](#).

VQA hizo que 10 humanos respondieran a cada pregunta. Se pueden encontrar más detalles sobre la métrica de evaluación de VQA y la exactitud humana [aquí](#) (vea la sección Código de evaluación) y en las secciones tres (“Respuestas”) y cuatro (“Acuerdo interhumano”) del documento.

Vea el gráfico de progreso de VQA en el Desafío 2020 en la [diapositiva 56](#). Los valores correspondientes al gráfico de progreso están disponibles en una hoja. Aquí está la información sobre los equipos que participaron en el Desafío 2020 y sus precisiones. Para más detalles sobre los equipos, consulte el sitio web de [VQA](#).

Usamos [paperswithcode](#) (PWC) para reseñar el avance técnico cuando corresponde. Aprenda más acerca de PWC [aquí](#) y consulte el enlace público [aquí](#).

Metodología

Para los artículos, seguimos las categorías específicas relacionadas con el ML en arxiv (véase [1] para la lista completa) y las principales conferencias de ML (NeurIPS, ICML, ICLR, etc.). Para el código, seguimos los repositorios de GitHub que mencionan artículos. Tenemos una buena cobertura de los temas principales de ML, pero nos faltan algunas aplicaciones, por ejemplo, las aplicaciones de ML en medicina o bioinformática, que suelen estar en revistas detrás de muros de pago. En el caso del código, el conjunto de datos es bastante imparcial (siempre que el artículo sea de libre acceso).

Para las tareas (por ejemplo, “clasificación de imágenes”), el conjunto de datos ha anotado las de 1.600 artículos del estado del arte de la base de datos, publicados en el tercer trimestre de 2018.

Para las tablas del estado del arte (por ejemplo, “clasificación de imágenes en ImageNet”), los datos han sido raspados de diferentes fuentes (ver la lista completa [aquí](#)), y un gran número centrado en CV y NLP fueron anotados a mano. Una parte importante de nuestros datos ha sido aportada por los usuarios, que han añadido datos en función de sus propias preferencias e intereses. Categorías de Arxiv que seguimos: ARXIV_CATEGORIES = “cs.CV”, “cs.AI”, “cs.LG”, “cs.CL”, “cs.NE”, “stat.ML”, “cs.IR”}

Proceso de extracción de conjuntos de datos a escala

- 1) Siga varias fuentes de papel (como se ha descrito anteriormente) para los nuevos documentos.
- 2) Realiza una serie de búsquedas predefinidas en GitHub (por ejemplo, para los README que contienen enlaces a arxiv).
- 3) Extraer los enlaces de GitHub de los documentos.
- 4) Extraer los enlaces de los documentos de GitHub.
- 5) Ejecutar pruebas de validación para decidir si los enlaces de 3) y 4) son enlaces de buena fe o falsos positivos.
- 6) Dejar que la comunidad corrija los errores y/o añada los valores que faltan.

NIST FRVT

Fuente

Hay dos tablas de clasificación de la evaluación del FRVT disponibles aquí: [1:1 Verification](#) y [1:N Identification](#)

Consideraciones acerca de las métricas de evaluación FRVT

Las fotos salvajes tienen algunos errores de etiquetado de identidad, ya que el mejor algoritmo tiene una baja tasa de falsos no coincidentes (FNMR), pero obtener una convergencia completa es difícil. Esta tarea se retirará en el futuro. Los datos se hicieron públicos en 2018 y se han vuelto más fáciles con el tiempo. Los datos provienen de fuentes web públicas. Así que es posible que esas mismas imágenes hayan sido desechadas de la web por los desarrolladores. No hay entrenamiento en los datos del FRVT, solo datos de prueba.

Los datos 1:1 y 1:N deben estudiarse por separado. Las diferencias incluyen los enfoques algorítmicos, en particular los algoritmos de búsqueda rápida son especialmente útiles en 1:N mientras que la velocidad no es un factor en 1:1.

SUPERGLUE

Los datos de la prueba comparativa SuperGLUE se extrajeron de la [tabla de clasificación SuperGLUE](#). Los detalles de la prueba comparativa SuperGLUE se encuentran en el [artículo de SuperGLUE](#) y en el [kit de herramientas de software de SuperGLUE](#). Las tareas y métricas de evaluación de SuperGLUE son:

NOMBRE	IDENTIFICADOR	MÉTRICA
Diagnóstico de amplia cobertura	AX-b	Corr de Matthew
CommitmentBank	CB	Media F1 / Exactitud
Selección de alternativas plausibles	COPA	Exactitud
Comprensión de lectura de varias oraciones	MultiRC	F1a / EM
Reconocimiento de detalles textuales	RTE	Exactitud
Palabras en contexto	WiC	Exactitud
El reto del esquema de Winograd	WSC	Exactitud
BoolQ	BoolQ	Exactitud
Comprensión lectora con razonamiento de sentido común	ReCoRD	F1 / Exactitud
Diagnóstico del esquema de Winogender	AX-g	Paridad de género / Exactitud

RAZONAMIENTO VISUAL DE SENTIDO COMÚN (VCR)

El progreso técnico de VCR se obtiene de la tabla de clasificación de VCR. VCR tiene dos subtarefas diferentes:

- Respuesta a preguntas (Q->A): Un modelo recibe una pregunta y tiene que elegir la mejor respuesta de entre cuatro opciones. Sólo una de las cuatro es correcta.
- Justificación de la respuesta (QA->R): A un modelo se le proporciona una pregunta, junto con la respuesta correcta, y debe justificarla eligiendo la mejor justificación entre cuatro opciones.

Se combinan las dos partes con las métricas Q->AR en las que un modelo sólo acierta una pregunta si responde correctamente y elige el razonamiento adecuado. Los modelos se evalúan en términos de exactitud (%).

VOXCELEB

VoxCeleb es un conjunto de datos audiovisuales compuesto por breves fragmentos de habla humana, extraídos de vídeos de entrevistas subidos a YouTube. VoxCeleb contiene el discurso de más de 7.000 hablantes que abarcan una amplia gama de etnias, acentos, profesiones y edades, lo que supone más de un millón de expresiones (las huellas faciales se capturan “en la naturaleza”, con charlas de fondo, risas, habla superpuesta, variación de la postura y diferentes condiciones de iluminación) grabadas durante un período de 2.000 horas (tanto de audio como de vídeo). Cada segmento dura al menos tres segundos. Los datos contienen un conjunto de datos de audio basados en voces de famosos, cortometrajes, películas y piezas de conversación (por ejemplo, programas de entrevistas). El VoxCeleb 1 inicial (100.000 expresiones tomadas de 1.251 famosos en YouTube) se amplió a VoxCeleb 2 (1 millón de expresiones de 6.112 famosos).

Sin embargo, en los años anteriores del reto, también se comunicaron las puntuaciones top-1 y top-5. Para la puntuación top-1, el sistema es correcto si la etiqueta objetivo es la clase a la que asigna la mayor probabilidad. Para la puntuación top-5, el sistema es correcto si la etiqueta objetivo es una de las cinco predicciones con las probabilidades más altas. En ambos casos, la puntuación máxima se calcula como el número de veces que una etiqueta predicha coincide con la etiqueta objetivo, dividido por el número de puntos de datos evaluados.

Los datos se extraen de diferentes años de los desafíos de presentación, entre ellos:

- 2017: [VoxCeleb: Un conjunto de datos de identificación de hablantes a gran escala](#)
- 2018: [VoxCeleb2: Reconocimiento profundo de hablantes](#)
- 2019: [Voxceleb: verificación de hablantes a gran escala al natural](#)
- 2020: [Sistema de expansión de búsqueda para el reto de reconocimiento de hablantes de VoxCeleb 2020](#)

BOOLEAN SATISFIABILITY PROBLEM

Análisis y texto por Lars Kotthoff

Fuente primaria y conjuntos de datos

El Problema de Satisfacibilidad booleana (SAT) determina si existe una asignación de valores a un conjunto de variables booleanas unidas por conectivos lógicos que haga verdadera la fórmula lógica que representa. SAT fue el primer problema que se demostró que era NP-completo, y los primeros algoritmos para resolverlo se desarrollaron en la década de 1960. Muchos problemas del mundo real, como el diseño de circuitos, la demostración automatizada de teoremas y la programación, pueden representarse y resolverse eficazmente como SAT. El concurso anual de SAT, que se celebra desde hace casi 20 años, tiene por objeto presentar una instantánea del estado de la técnica.

Tomamos los solucionadores mejor clasificados, los medianamente clasificados y los peor clasificados de cada uno de los últimos cinco años (2016-2020) de la competición SAT. Hemos ejecutado los 15 solucionadores en las 400 instancias del SAT de la pista principal de la competición de 2020. Para más información sobre la competición, así como sobre los solucionadores y las instancias, se puede consultar el [sitio web de la competencia SAT](#).

Resultados

Ejecutamos cada solución en cada instancia en el mismo hardware, con un límite de tiempo de 5.000 segundos de CPU por instancia, y medimos el tiempo que tardó en resolver una instancia en segundos de CPU. Los solucionadores clasificados siempre devuelven resultados correctos, por lo que no consideramos la corrección como métrica. Excepto en el caso de los solucionadores de la competición de 2020, evaluamos el rendimiento de los solucionadores SAT en un conjunto de instancias diferente al conjunto de instancias en las que compitieron. Además, nuestro hardware es diferente del que se utilizó en la competición SAT. Por lo tanto, los resultados que presentamos aquí difieren de los resultados exactos obtenidos en las respectivas competiciones SAT.

El valor Shapley es un concepto de la teoría de los juegos cooperativos que asigna a cada jugador una contribución al valor total que genera una coalición. Cuantifica la importancia de cada

jugador para la coalición y tiene varias propiedades deseables que hacen que la distribución del valor total a los jugadores individuales sea justa. Por ejemplo, el valor de Shapley se utiliza para distribuir los costes de los aeropuertos entre sus usuarios, asignar fondos a diferentes campañas de marketing y en el aprendizaje automático, donde ayuda a hacer más explicables los complejos modelos de caja negra.

En nuestro contexto, cuantifica la contribución de un solucionador al estado del arte a través de la mejora media del rendimiento que proporciona sobre un conjunto de otros solucionadores y sobre todos los subconjuntos de solucionadores (Fréchet et al. (2016)). Para un conjunto determinado de solucionadores, elegimos el mejor respectivo para cada instancia a resolver. Al incluir otro solucionador y poder elegirlo, el rendimiento general de la solución mejora, y la diferencia con el conjunto original de solucionadores es la contribución marginal del solucionador añadido. La contribución marginal media de todos los conjuntos de solucionadores es el valor de Shapley.

Al cuantificar la contribución de un solucionador mediante el valor de Shapley, se comparan los solucionadores de competiciones anteriores con los de competiciones posteriores. Esto no suele ser una comparación justa, ya que los solucionadores posteriores suelen ser versiones mejoradas de los anteriores, y la contribución del solucionador al futuro estado de la técnica siempre será baja. El valor temporal de Shapley (Kotthoff et al. (2018)) resuelve este problema teniendo en cuenta el momento en que se introdujo un solucionador concreto a la hora de cuantificar su contribución al estado del arte.

DEMOSTRACIÓN AUTOMATIZADA DE TEOREMAS

Análisis y texto por Christian Suttner, Geoff Sutcliffe y Raymond Perrault

1. Motivación

La demostración automatizada de teoremas (ATP) (también denominada deducción automatizada) es un subcampo del razonamiento automatizado que se ocupa del desarrollo y el uso de sistemas que automatizan el razonamiento sólido: la derivación de conclusiones que se derivan inevitablemente de los hechos. Los sistemas ATP están en el centro de muchas

tareas computacionales y se utilizan comercialmente, por ejemplo, para el diseño de circuitos integrados y la verificación de programas informáticos. Los problemas ATP suelen resolverse demostrando que una conjetura es o no una consecuencia lógica de un conjunto de axiomas. Los problemas ATP se codifican en una lógica elegida, y un sistema ATP para esa lógica se utiliza para (intentar) resolver el problema. Una de las principales preocupaciones de la investigación ATP es el desarrollo de sistemas más potentes, capaces de resolver problemas más difíciles dentro de los mismos límites de recursos. Para evaluar los méritos de las nuevas técnicas, es fundamental realizar evaluaciones empíricas sólidas de los sistemas ATP.

2. Análisis

Fara la evaluación de los sistemas ATP, existe una amplia y creciente colección de problemas denominada biblioteca de problemas TPTP. La versión actual v7.4.0 (publicada el 10 de junio de 2020) contiene 23.291 problemas ATP, estructurados en 54 dominios temáticos (por ejemplo, Teoría de Conjuntos, Verificación de Software, Filosofía, etc.). Ortogonalmente, el TPTP se divide en Clases de Problemas Especializados (SPCs), cada una de las cuales contiene problemas con un conjunto específico de características lógicas, lingüísticas y sintácticas (por ejemplo, teoremas de lógica de primer orden con algún uso de la igualdad). Los SPC permiten a los desarrolladores de sistemas ATP seleccionar problemas y evaluar sus sistemas de forma adecuada. Desde su primera publicación en 1993, muchos investigadores han utilizado el TPTP como base adecuada y conveniente para la evaluación de sistemas ATP. A lo largo de los años, el TPTP también se ha utilizado cada vez más como conducto para que los usuarios de ATP aporten muestras de sus problemas a los desarrolladores de sistemas ATP. Esto expone los problemas a los desarrolladores de sistemas ATP, que pueden entonces mejorar el rendimiento de sus sistemas en los problemas, lo que completa un ciclo para proporcionar a los usuarios herramientas más eficaces.

Asociada al TPTP está la biblioteca de soluciones del TSTP, que mantiene los resultados actualizados de la ejecución de todas las versiones actuales de los sistemas ATP (disponibles para el mantenedor) en todos los problemas del TPTP. Uno de los usos del TSTP es calcular las clasificaciones de dificultad de los

problemas del TPTP: Los problemas fáciles, que son resueltos por todos los sistemas ATP, tienen una calificación de 0,0; los problemas difíciles, que son resueltos por algunos sistemas ATP, tienen una calificación entre 0,0 y 1,0; los problemas no resueltos, que no son resueltos por ningún sistema ATP, tienen una calificación de 1,0. Nótese que la calificación de un problema no es estrictamente decreciente, ya que se dispone de diferentes sistemas y versiones ATP para poblar el TSTP. El historial de las puntuaciones de cada problema del TPTP se guarda con el problema, lo que permite saber cuándo se resolvió el problema por primera vez con cualquier sistema ATP (el momento en que su puntuación cayó por debajo de 1,0). Esta información se ha utilizado aquí para obtener una indicación del progreso en el campo.

La forma más sencilla de medir el progreso es tomar un conjunto fijo de problemas que ha estado disponible (y sin cambios) en el TPTP desde alguna versión inicial elegida del TPTP, y luego, para las versiones del TPTP a partir de entonces, contar cuántos de los problemas se han resuelto desde esa versión. El análisis informa de la fracción de problemas resueltos para cada versión. Este sencillo enfoque es inequívoco, pero no tiene en cuenta los nuevos problemas que se añaden al TPTP después de la versión inicial.

El análisis utilizado aquí amplía el análisis del “conjunto fijo”, teniendo en cuenta los nuevos problemas añadidos después de la versión inicial. Como no es posible ejecutar todos los sistemas ATP disponibles previamente en los nuevos problemas cuando se añaden, este enfoque asume que si un problema no es resuelto por los sistemas ATP actuales cuando se añade al TPTP, entonces no habrá sido resuelto por los sistemas ATP disponibles previamente. Bajo esta suposición, el nuevo problema se “añade” retrospectivamente a las versiones anteriores del TPTP para el análisis. Si un problema está resuelto cuando se añade al TPTP, se ignora porque puede haber sido resuelto también en versiones anteriores, y por tanto no debería servir como indicador de progreso. Este análisis informa de la fracción de problemas resueltos para cada versión, pero hay que tener en

cuenta que la fracción es con respecto tanto al número de problemas realmente en la versión como a los problemas “añadidos” retrospectivamente.

El análisis del conjunto creciente se realiza en todo el TPTP y en cuatro CPE. Éstos se eligieron porque se han aportado al TPTP muchos problemas ATP en esas formas y, en consecuencia, hay muchos sistemas ATP que pueden intentarlos; representan la demanda del “mundo real” de la capacidad ATP.

La tabla de la carpeta de datos públicos muestra el desglose de los problemas del TPTP por campos de contenido, así como por los CPE utilizados en el análisis. Los totales son ligeramente mayores que los que se muestran en el análisis, ya que algunos problemas se dejaron fuera por razones técnicas (no había puntuaciones disponibles, problemas revisados con el tiempo, etc.).

CAPÍTULO 3: ECONOMÍA

LINKEDIN

Preparado por Mar Carpanelli, Ramanujam MV, y Nathan Williams

Muestra de países

Los países incluidos representan una muestra selecta de países elegibles con al menos un 40% de cobertura de la fuerza laboral por parte de LinkedIn y al menos 10 contrataciones de IA en un mes determinado. China e India se incluyeron en esta muestra debido a su creciente importancia en la economía mundial, pero la cobertura de LinkedIn en estos países no alcanza el 40% de la fuerza laboral. Los datos de estos países pueden no ofrecer una imagen tan completa como la de otros países, y deben interpretarse en consecuencia.

Competencias

Los miembros de LinkedIn informan por sí mismos de sus habilidades en sus perfiles de LinkedIn. En la actualidad, LinkedIn identifica más de 35.000 competencias distintas y estandarizadas. Éstas han sido codificadas y clasificadas por los taxónomos de LinkedIn en 249 agrupaciones de habilidades, que son los grupos de habilidades representados en el conjunto de datos. Las principales habilidades que componen la agrupación de habilidades de IA son el aprendizaje automático, el procesamiento del lenguaje natural, las estructuras de datos, la inteligencia artificial, la visión artificial, el procesamiento de imágenes, el aprendizaje profundo, TensorFlow, Pandas (software) y OpenCV, entre otras.

Las agrupaciones de habilidades son derivadas por taxónomos expertos a través de una metodología de índice de similitud que mide la composición de habilidades a nivel de la industria. Las industrias se clasifican según la clasificación industrial CIIU 4 (Zhu et al., 2018).

Prevalencia de competencias de IA

El objetivo de este indicador es medir la intensidad de las competencias en materia de IA en una entidad (en un país, industria, género, etc.) mediante la siguiente metodología:

- Se calculan las frecuencias de todas las habilidades autoagregadas por los miembros de LinkedIn en una entidad

determinada (ocupación, industria, etc.) en 2015-2020.

- Se ponderan las frecuencias de las habilidades utilizando un modelo TF-IDF para obtener las 50 habilidades más representativas de esa entidad. Estas 50 habilidades componen el “genoma de habilidades” de esa entidad.
- Se calcula la proporción de competencias que pertenecen al grupo de competencias de la IA entre las principales competencias de la entidad seleccionada.

Interpretación: El índice de presencia de las habilidades de IA señala la prevalencia de las habilidades de IA en las ocupaciones, o la intensidad con la que los miembros de LinkedIn utilizan las habilidades de IA en sus trabajos. Por ejemplo, las 50 principales habilidades para la ocupación de ingeniero se calculan en base a la frecuencia ponderada con la que aparecen en los perfiles de los miembros de LinkedIn. Si cuatro de las habilidades que poseen los ingenieros pertenecen al grupo de habilidades de IA, esta medida indica que la presencia de las habilidades de IA se estima en un 8% entre los ingenieros (por ejemplo, 4/50).

Presencia relativa de competencias de IA

Para poder comparar la penetración de las competencias entre países, se calculan los genomas de competencias y se selecciona un benchmark pertinente (por ejemplo, la media mundial). A continuación, se elabora una relación entre la penetración de las competencias de la IA de un país y la del benchmark, controlando las ocupaciones.

Interpretación: La penetración relativa de las habilidades de IA de un país de 1,5 indica que las habilidades de IA son 1,5 veces más frecuentes que en el benchmark, para un conjunto de ocupaciones superpuestas.

Comparación mundial

Para la comparación entre países, presentamos la tasa de penetración relativa de las habilidades de la IA, medida como la suma de la penetración de cada habilidad de la IA a través de las ocupaciones en un país determinado, dividida por la penetración global media de las habilidades de la IA a través de las ocupaciones superpuestas en una muestra de países.

Interpretación: un índice de presencia relativo de 2 significa que la presencia media de las competencias de IA en ese país es dos veces superior a la media mundial en el mismo conjunto de ocupaciones.

Comparación mundial: por industria

La penetración relativa de las habilidades de IA por país para la industria proporciona una descomposición sectorial en profundidad de la penetración de las habilidades de IA a través de las industrias y los países de la muestra.

Interpretación: la tasa de presencia relativa de habilidades de IA de un país de 2 en el sector de la educación significa que la presencia media de las habilidades de IA en ese país es dos veces la media mundial en el mismo conjunto de ocupaciones en ese sector.

Índice de contratación en IA de LinkedIn

La tasa de contratación de IA de LinkedIn se calcula como el número total de miembros de LinkedIn que se identifican como talento de IA y que añadieron un nuevo empleador en el mismo mes en que comenzó el nuevo trabajo, dividido por el número total de miembros de LinkedIn en el país. Al analizar sólo los datos más oportunos, es posible hacer comparaciones mes a mes y tener en cuenta cualquier posible retraso en la actualización de los perfiles de los miembros.

El período de referencia suele ser un año, y se indexa al mes/período medio de interés durante ese año. La tasa de contratación de IA se indexa con respecto a la media de contratación anual en 2016; por ejemplo, un índice de 3,5 para Brasil en 2020 indica que la tasa de contratación de IA es 3,5 veces mayor en 2020 que la media en 2016.

Interpretación: el índice de contratación significa la tasa de contratación en el campo de la IA, específicamente la rapidez con la que cada país está experimentando un crecimiento en la contratación de IA.

Top de Competencias de IA

Las competencias de IA agregadas con mayor frecuencia por los miembros durante el período 2015–2020.

BURNING GLASS TECHNOLOGIES

Preparado por Bledi Taska, Layla O’Kane y Zhou Zhou

Burning Glass Technologies ofrece análisis del mercado laboral que permiten a empresarios, trabajadores y educadores tomar decisiones basadas en datos. La tecnología de inteligencia artificial de la empresa analiza cientos de millones de anuncios de empleo y transiciones profesionales de la vida real para proporcionar información sobre los patrones del mercado laboral. Esta inteligencia estratégica en tiempo real ofrece información crucial, como los puestos de trabajo más demandados, las competencias específicas que necesitan los empleadores y las direcciones profesionales que ofrecen el mayor potencial para los trabajadores. Para más información, visite burning-glass.com.

Datos de anuncios de empleos

Para apoyar estos análisis, Burning Glass extrajo su conjunto de datos de millones de anuncios de empleo recopilados desde 2010. Burning Glass recopila anuncios de más de 45.000 sitios de empleo en línea para desarrollar un retrato completo y en tiempo real de la demanda del mercado laboral. Agrega las ofertas de empleo, elimina los duplicados y extrae los datos del texto de las ofertas de empleo. Esto incluye información sobre el título del puesto, el empleador, la industria y la región, así como la experiencia, la educación y las habilidades requeridas.

Los anuncios de empleo son útiles para comprender las tendencias del mercado laboral, ya que permiten obtener una visión detallada y en tiempo real de las competencias que buscan los empleadores. Para evaluar la representatividad de los datos de las ofertas de empleo, Burning Glass lleva a cabo una serie de análisis para comparar la distribución de las ofertas de empleo con la distribución del gobierno oficial y otras fuentes de terceros en los Estados Unidos. La principal fuente de datos gubernamentales sobre ofertas de empleo en Estados Unidos es el programa Job Openings and Labor Turnover Survey (JOLTS), realizado por la Oficina de Estadísticas Laborales.

Para entender la proporción de ofertas de empleo que recogen los datos de Burning Glass, es importante señalar primero que Burning Glass y JOLTS recogen los datos sobre ofertas

de empleo de forma diferente. Los datos de Burning Glass recogen los nuevos anuncios: Un anuncio aparece en los datos sólo el primer mes que se encuentra y se considera un duplicado y se elimina en los meses siguientes. Los datos de JOLTS recogen los anuncios activos: Un puesto de trabajo aparece en los datos todos los meses en los que está activo, lo que significa que el mismo puesto puede contarse en dos o más meses consecutivos si no se ha cubierto. Para poder comparar el volumen de envíos con el de los demás, los datos de Burning Glass deben inflarse para tener en cuenta los envíos activos, no sólo los nuevos. El número de anuncios de Burning Glass puede inflarse utilizando la relación entre los nuevos puestos de trabajo y los activos en Help Wanted OnLine™ (HWOL), un método utilizado en Carnevale, Jayasundera y Repnikov (2014). Sobre la base de este cálculo, la proporción de puestos de trabajo en línea capturados por Burning Glass es aproximadamente el 85% de los puestos de trabajo capturados en JOLTS en 2016.

La demanda del mercado laboral captada por los datos de Burning Glass representa más del 85% de la demanda laboral total. Los puestos de trabajo que no se publican en línea suelen estar en las pequeñas empresas (el ejemplo clásico es el cartel de “Se busca ayuda” en la ventana del restaurante) y en las salas de contratación de los sindicatos.

Medir la demanda de IA

Para medir la demanda de habilidades de IA por parte de los empleadores, Burning Glass utiliza su taxonomía de habilidades, que incluye más de 17.000 habilidades. A continuación se muestra la lista de competencias de IA de los datos de Burning Glass, con los grupos de competencias asociados. Aunque algunas competencias se consideran específicamente en el grupo de IA, a efectos de este informe, todas las competencias que se indican a continuación se consideraron competencias de IA. Un anuncio de empleo se consideró un trabajo de IA si requería una o más de estas habilidades.

Inteligencia artificial: Sistema experto, IBM Watson, IPSoft Amelia, Ithink, agentes virtuales, sistemas autónomos, Lidar, OpenCV, planificación de rutas, teledetección.

Procesamiento de lenguaje natural (NLP): ANTLR, Reconocimiento automático del habla (ASR), Chatbot, Lingüística computacional, Distinguo, Latent Dirichlet Allocation, Análisis semántico latente, Lexalytics, Adquisición léxica, Semántica léxica, Traducción automática (MT), Análisis de sentimientos/minería de opiniones, reconocimiento del habla, minería de textos, procesamiento del lenguaje natural, algoritmo del vecino más próximo, OpenNLP, Text to Speech (TTS), tokenización, Word2Vec.

Redes neurales: Caffe Deep Learning Framework, Convolutional Neural Network (CNN), Deep Learning, Deeplearning4j, Keras, Long Short-Term Memory (LSTM), MXNet, Neural Networks, Pybrain, Recurrent Neural Network (RNN), TensorFlow

Aprendizaje automático: Algoritmo AdaBoost, Boosting (Machine Learning), Chi Square Automatic Interaction Detection (CHAID), Algoritmos de clasificación, Algoritmos de clustering, Árboles de decisión, Reducción de dimensionalidad, Google Cloud Machine Learning Platform, Gradient boosting, H2O (software), Libsvm, Machine Learning, Madlib, Mahout, Microsoft Cognitive Toolkit, MLPACK (biblioteca C++), Mlpy, Random Forests, Recommender Systems, Scikit-learn, Semi-Supervised Learning, Supervised Learning (Machine Learning), Support Vector Machines (SVM), Semantic Driven Subtractive Clustering Method (SDSCM), Torch (Machine Learning), Unsupervised Learning, Vowpal, Xgboost

Robótica: Blue Prism, Sistemas electromecánicos, Planificación del movimiento, Programación de robots Motoman, Marco de trabajo de robots, Sistemas robóticos, Sistema operativo de robots (ROS), Programación de robots, Servoaccionamientos / Motores, Localización y mapeo simultáneos (SLAM)

Reconocimiento visual de imágenes: visión artificial, procesamiento de imágenes, reconocimiento de imágenes, visión automática, reconocimiento de objetos

NETBASE QUID

Preparado por Julie Kim

NetBase Quid es una plataforma de análisis de big data que inspira el pensamiento completo al establecer conexiones entre cantidades masivas de datos no estructurados. El software aplica tecnología avanzada de procesamiento del lenguaje natural, análisis semántico y algoritmos de inteligencia artificial para revelar patrones en grandes conjuntos de datos no estructurados y para generar visualizaciones que permitan a los usuarios obtener información procesable. NetBase Quid utiliza consultas booleanas para buscar áreas de interés, temas y palabras clave en la base de datos de noticias y blogs archivados, empresas y patentes, así como en cualquier conjunto de datos cargado de forma personalizada. Se puede filtrar la búsqueda por el marco temporal de la fecha de publicación, las regiones de origen, las categorías de origen o las categorías de la industria en las noticias, y por regiones, importe de la inversión, estado de funcionamiento, tipo de organización (privada/pública) y año de fundación en la base de datos de empresas. A continuación, NetBase Quid visualiza estos puntos de datos basándose en la similitud semántica.

Búsqueda, fuentes de datos y Scope

Aquí se indexan 3,6 millones de perfiles de empresas públicas y privadas procedentes de múltiples fuentes de datos con el fin de buscar en las descripciones de las empresas, filtrando e incluyendo metadatos que van desde la información de inversión hasta la información firmográfica, como el año de fundación, la ubicación de la sede, etc. La información de las empresas se actualiza semanalmente. El algoritmo de Quid lee una gran cantidad de datos de texto de cada documento (artículo de noticias, descripciones de empresas, etc.) para establecer vínculos entre diferentes documentos basándose en su lenguaje similar. Este proceso se repite a una escala inmensa, lo que produce una red con diferentes clusters que identifican temas o áreas de interés distintos. Las tendencias se identifican a partir de las palabras clave, las frases, las personas, las empresas, las instituciones que Quid identifica y los demás metadatos que se introducen en el software.

Datos

Los datos de las organizaciones proceden de CapIQ y Crunchbase. Estas empresas incluyen todo tipo de compañías (privadas, públicas, en funcionamiento, que operan como subsidiarias, fuera del negocio) en todo el mundo. Los datos de inversión incluyen inversiones privadas, fusiones y adquisiciones, ofertas públicas, participaciones minoritarias realizadas por PE/VC, brazos corporativos de riesgo, gobiernos e instituciones tanto dentro como fuera de los Estados Unidos. Algunos datos son sencillamente inaccesibles, por ejemplo, cuando no se revelan los inversores o los importes de financiación por parte de éstos. Quid también incorpora información firmográfica, como el año de fundación y la ubicación de la sede.

NetBase Quid incorpora los datos de CapIQ por defecto y añade datos de Crunchbase para los que no se capturan en CapIQ. De este modo, no sólo se obtienen datos completos y precisos sobre todas las organizaciones mundiales, sino que también se recogen datos de las empresas en fase inicial y de los eventos de financiación. La información de las empresas se carga semanalmente.

Metodología

La consulta booleana se utiliza para buscar áreas de interés, temas y palabras clave en la base de datos de empresas archivadas, dentro de sus descripciones de negocio y sitios web. Podemos filtrar los resultados de la búsqueda por regiones de la sede central, importe de la inversión, estado de funcionamiento, tipo de organización (privada/pública) y año de fundación. A continuación, Quid visualiza estas empresas. Si hay más de 7.000 empresas en el resultado de la búsqueda, Quid selecciona las 7.000 más relevantes para su visualización basándose en el algoritmo del lenguaje.

Búsqueda booleana: “artificial intelligence” or “AI” or “machine learning” or “deep learning”

Compañías:

- Gráfico 3.2.1: Empresas mundiales de IA y ML en las que se ha invertido (privadas, OPI, fusiones y adquisiciones) desde el 01/01/2011 hasta el 31/12/2020.
- Gráfico 3.2.2-3.2.6: Empresas globales de IA y ML que han

invertido más de 400.000 dólares en los últimos 10 años (del 1 de enero de 2011 al 31 de diciembre de 2020); se han seleccionado 7.000 empresas de entre 7.500 mediante el algoritmo de relevancia de Quid.

Definición de evento objetivo

- Inversiones privadas: una colocación privada es una venta privada de valores recién emitidos (capital o deuda) por una empresa a un inversor seleccionado o a un grupo seleccionado de inversores. Las participaciones que toman los compradores en las colocaciones privadas suelen ser minoritarias (menos del 50%), aunque también es posible tomar el control de una empresa a través de una colocación privada, en cuyo caso la colocación privada sería una inversión de participación mayoritaria.
- Inversiones minoritarias: se trata de adquisiciones de participaciones minoritarias en Quid, que tienen lugar cuando el comprador adquiere menos del 50% de la participación existente en entidades, producto de activos y divisiones de negocio.
- M&A: se refiere a un comprador que adquiere más del 50% de la participación existente en entidades, producto de activos y divisiones de negocio.

MCKINSEY & COMPANY FUENTE

Esta encuesta fue redactada, rellena y analizada por McKinsey & Company. Puede encontrar resultados adicionales de la Encuesta Global de IA [aquí](#).

Metodología

La encuesta se llevó a cabo en línea y sobre el terreno del 9 al 19 de junio de 2020, y obtuvo respuestas de 2.395 participantes que representaban toda la gama de regiones, sectores, tamaños de empresas, especialidades funcionales y cargos. De esos encuestados, 1.151 dijeron que sus organizaciones habían adoptado la IA en al menos una función y se les preguntó sobre el uso de la IA en sus organizaciones. Para ajustar las diferencias en las tasas de respuesta, los datos se ponderan en función de la contribución de la nación de cada encuestado al PIB mundial. McKinsey también realizó entrevistas con ejecutivos entre mayo y agosto de 2020 sobre el uso de la IA en sus empresas. Todas las

citas de los ejecutivos se recogieron durante esas entrevistas.

Nota

Los encuestados están limitados por su percepción de la adopción de la IA en su organización.

FEDERACIÓN INTERNACIONAL DE ROBÓTICA

Fuente

Los datos se recibieron directamente del Informe Mundial de Robótica 2020 de la Federación Internacional de Robótica (IFR). Más información sobre la [IFR](#).

Metodología

Los datos mostrados son el número de robots industriales instalados por país. Los robots industriales se definen según la norma ISO 8373:2012. Ver más información sobre la [metodología de IFR](#).

Consideraciones

- No está claro cómo identificar qué porcentaje de unidades robóticas ejecutan software que se clasificaría como “IA”, y no está claro hasta qué punto el desarrollo de la IA contribuye al uso de robots industriales.
- Esta métrica se denominó “importaciones de robots” en el Informe del Índice de IA de 2017.

PRATTLE (SOLO REPORTES DE GANANCIAS)

Preparado por Jeffrey Banner y Steven Nichols

Fuente

Liquidnet proporciona datos de sentimiento que predicen el impacto en el mercado de las comunicaciones de los bancos centrales y las empresas. Más información sobre Liquidnet [aquí](#).

CAPÍTULO 4: EDUCACIÓN EN IA

ENCUESTA CRA TAULBEE

Preparado por Betsy Bizot (asociado sénior de investigación de la CRA) y Stu Zweben (director del estudio de CRA, profesor emérito de la Unviersidad Estatal de Ohio)

Fuente

La Computing Research Association (CRA) está conformada por más de 200 organizaciones norteamericanas activas en la investigación informática: departamentos académicos de ciencias de la computación e ingeniería informática; laboratorios y centros de la industria, el gobierno y el mundo académico; y sociedades profesionales afiliadas (AAAI, ACM, CACS/AIC, IEEE Computer Society, SIAM USENIX). La misión de CRA es mejorar la innovación uniéndose a la industria, el gobierno y el mundo académico para fortalecer la investigación y la educación avanzada en computación. Más información sobre CRA [aquí](#).

Metodología

La Encuesta Taulbee del CRA recopila datos de la encuesta durante el otoño de cada año académico, poniéndose en contacto con más de 200 departamentos que conceden doctorados. Los detalles sobre la Encuesta Taulbee pueden encontrarse [aquí](#). Taulbee no encuesta directamente a los estudiantes. El departamento identifica el área de especialización de cada nuevo doctorado, así como su tipo de empleo. Los datos se recogen de septiembre a enero de cada año académico para los doctores concedidos en el año académico anterior. Los resultados se publican en mayo, una vez cerrada la recogida de datos. Por lo tanto, los datos de 2019 estuvieron recién disponibles la primavera pasada, y las cifras proporcionadas para 2020 estarán disponibles en mayo de

2021.

La encuesta Taulbee de la CRA se envía únicamente a los departamentos de doctorado de informática, ingeniería informática y ciencias/sistemas de la información. Históricamente, (a) Taulbee cubre entre 1/4 y 1/3 del total de licenciados en ciencias de la computación en los Estados Unidos; (b) el porcentaje de mujeres que obtienen títulos de licenciatura es menor en las escuelas Taulbee que en el conjunto; y (c) Taulbee sigue las tendencias de la producción general de ciencias de la computación.

Consideraciones

- De especial interés en las tendencias del mercado de trabajo de doctorado son las métricas sobre el área de especialización de doctorado en IA. La categorización de las áreas de especialización cambió en 2008 y se aclaró en 2016. De 2004 a 2007, la IA y la robótica estaban agrupadas; de 2008 a la actualidad, la IA está separada; en 2016 se aclaró a los encuestados que la IA incluye el ML.
- Notas sobre las tendencias de las nuevas contrataciones de profesores titulares (en general y en particular en las escuelas de la UCA): En la Encuesta Taulbee de 2018, por primera vez, preguntamos cuántas nuevas contrataciones habían provenido de las siguientes fuentes: nuevo doctorado, postdoc, industria y otro académico. Los resultados indicaron que el 29% de los nuevos profesores asistentes procedían de otra institución académica.
- Es posible que algunos hayan sido profesores o investigadores

en lugar de titulares, pero es probable que haya algún movimiento entre instituciones, lo que significa que el número total contratado exagera el total de los que son realmente nuevos.

ENCUESTA DE EDUCACIÓN DEL AI INDEX

Preparado por Daniel Zhang (Stanford Institute for Human-Centered Artificial Intelligence)

Metodología

La encuesta se distribuyó a 73 universidades en línea a lo largo de tres oleadas, desde noviembre de 2020 hasta enero de 2021, y fue completada por 18 universidades, lo que supone una tasa de respuesta del 24,7%. La selección de universidades se basa en los [World University Rankings 2021](#) y [Emerging Economies University Rankings 2020](#) por The Times Higher Education.

Las 18 universidades son:

- Bélgica: Katholieke Universiteit Leuven
- Canadá: McGill University
- China: Shanghai Jiao Tong University, Tsinghua University
- Alemania: Ludwig Maximilian University of Munich, Technical University of Munich
- Rusia: Higher School of Economics, Moscow Institute of Physics and Technology
- Suiza: École Polytechnique Fédérale de Lausanne
- Reino Unido: University of Cambridge
- Estados Unidos: California Institute of Technology, Carnegie Mellon University (Department of Machine Learning), Columbia University, Harvard University, Stanford University, University of Wisconsin–Madison, University of Texas at Austin, Yale University

Definiciones clave

- **Especialización o programa de estudios:** conjunto de cursos obligatorios y optativos en un área de la disciplina -como la IA-

que conducen a la obtención de una licenciatura al finalizarla.

- **Curso:** un conjunto de lecciones que requieran un mínimo de 2,5 horas de clase (incluyendo conferencia, laboratorio, horas de AT, etc.) por semana durante al menos 10 semanas en total. Los cursos múltiples con los mismos títulos y números cuentan como un solo curso.
- **Modelos prácticos de inteligencia artificial - palabras clave:** Adaptive learning, AI Application, Anomaly detection, Artificial general intelligence, Artificial intelligence, Audio processing, Automated vehicle, Automatic translation, Autonomous system, Autonomous vehicle, Business intelligence, Chatbot, Computational creativity, Computational linguistics, Computational neuroscience, Computer vision, Control theory, Cyber physical steam, Deep learning, Deep neural network, Expert system, Face recognition, Human-AI interaction, Image processing, Image recognition, Inductive programming, Intelligence software, Intelligent agent, Intelligent control, Intelligent software development, Intelligence system, Knowledge representation and reasoning, Machine learning, Machine translation, Multi-agent system, Narrow artificial intelligence, Natural language generation, Natural language processing, Natural language understanding, Neural network, Pattern recognition, Predictive analysis, Recommender system, Reinforcement learning, Robot system, Robotics, Semantic web, Sentiment analysis, Service robot, Social robot, Sound synthesis, Speaker identification, Speech processing, Speech recognition, Speech synthesis, Strong artificial intelligence, Supervised learning, Support vector machine, Swarm intelligence, Text mining, Transfer learning, Unsupervised learning, Voice recognition, Weak artificial intelligence (adaptado de: [Centro de Investigación Conjunta, Comisión Europea](#), p.68)
- **Ética en IA - palabras clave:** Accountability, Consent, Contestability, Ethics, Equality, Explainability, Fairness, Non-discrimination, Privacy, Reliability, Safety, Security, Transparency, Trustworthy ai, Uncertainty, Well-being ((adaptado de: [Centro de Investigación Conjunta, Comisión Europea](#), p.68)

OFERTA ACADÉMICA EN LA EU, CENTRO COMÚN DE INVESTIGACIÓN, COMISIÓN EUROPEA

Preparado por Giuditta De-Prato, Montserrat López Cobo, y Riccardo Righi

Fuente

El Centro Común de Investigación (CCI) es el servicio de ciencia y conocimiento de la Comisión Europea. El CCI emplea a científicos para que lleven a cabo investigaciones con el fin de proporcionar asesoramiento científico independiente y apoyo a la política de la UE. Más información sobre el CCI [aquí](#).

Metodología

Mediante técnicas de minería de textos, el estudio identifica los programas educativos relacionados con la IA a partir de las descripciones de los programas presentes en la base de datos del CCI. Para consultar la base de datos, se obtiene una lista de palabras clave específicas del dominio a través de una metodología de varios pasos que implica (i) la selección de las principales palabras clave de las revistas científicas específicas de IA; (ii) la extracción de términos representativos de la dimensión industrial de la tecnología; (iii) el modelado de temas; y (iv) la validación por parte de expertos. En esta edición, la lista de palabras clave se ha ampliado para cubrir mejor ciertos subdominios de la IA y para extenderla a dominios transversales relacionados, como la filosofía y la ética en la IA. A continuación, las palabras clave se agrupan en categorías, que se utilizan para analizar las áreas de contenido que se imparten en los programas identificados. Las áreas de contenido utilizadas se han adaptado del informe del CCI “[Defining Artificial Intelligence: Towards an Operational Definition and Taxonomy of Artificial Intelligence](#),” conducido en el contexto de [AI Watch](#).

Los programas educativos se clasifican en especializados y amplios, según la profundidad con la que abordan la inteligencia artificial. Los programas especializados son los que se centran en la IA, por ejemplo, “automatización

y visión artificial” o “informática avanzada (inteligencia computacional)”. Los programas amplios se centran en el dominio abordado, pero de una manera más genérica, normalmente con el objetivo de construir perfiles más amplios o haciendo referencia al dominio en el marco de un programa especializado en una disciplina diferente (por ejemplo, ingeniería biomédica).

Debido a algunas mejoras metodológicas introducidas en esta edición, concretamente la adición de nuevas palabras clave, no es posible realizar una comparación estricta. Aun así, más del 90% de todos los programas detectados en esta edición están provocados por palabras clave presentes en el estudio de 2019.

La fuente original sobre la que se realizan las consultas es la base de datos de Studyportals, formada por más de 207.000 programas de 3.700 universidades de más de 120 países. Studyportals recoge la información de las páginas web de las instituciones y su base de datos se actualiza periódicamente. Esta fuente, aunque ofrece la cobertura más amplia de todas las identificadas, sigue adoleciendo de cierta falta de cobertura, sobre todo porque sólo registra los programas en inglés. Esto plantea un problema de comparabilidad entre los países de habla inglesa y el resto, pero también entre los países con diferentes niveles de incorporación del inglés como lengua de enseñanza en la educación superior. Es de esperar que los estudios de grado se vean más afectados por este hecho, ya que la oferta se imparte mayoritariamente en lengua nativa, a diferencia de los de máster, que atraen a un público y un profesorado más internacional. En consecuencia, este estudio puede estar mostrando una imagen parcial del nivel de inclusión de las competencias digitales avanzadas en los programas de grado.

CAPÍTULO 5: DESAFÍOS ÉTICOS DE LAS APLICACIONES DE LA IA

NETBASE QUID

Preparado por Julie Kim

Quid es una plataforma de análisis de datos dentro de la cartera de NetBase Quid que aplica tecnología avanzada de procesamiento del lenguaje natural, análisis semántico y algoritmos de inteligencia artificial para revelar patrones en grandes conjuntos de datos no estructurados y generar visualizaciones que permitan a los usuarios obtener información procesable. Quid utiliza consultas booleanas para buscar áreas de interés, temas y palabras clave en la base de datos de noticias y blogs archivados, empresas y patentes, así como en cualquier conjunto de datos cargado de forma personalizada. Los usuarios pueden filtrar su búsqueda por fechas de publicación, regiones de origen, categorías de origen o categorías industriales en las noticias; y por regiones, importe de la inversión, estado operativo, tipo de organización (privada/pública) y año de fundación dentro de la base de datos de las empresas. A continuación, Quid visualiza estos puntos de datos basándose en la similitud semántica.

Red

Se buscó [AI technology keywords + [Harvard ethics principles keywords](#)] en las noticias a nivel mundial desde el 1° de enero de 2020 hasta el 31 de diciembre de 2020.

Parámetro de búsqueda: (AI OR ["artificial intelligence"] ("artificial intelligence" OR "pattern recognition" OR algorithms) OR ["machine learning"] ("machine learning" OR "predictive analytics" OR "big data" OR "pattern recognition" OR "deep learning") OR ["natural language"] ("natural language" OR

"speech recognition") OR NLP OR "computer vision" OR ["robotics"] ("robotics" OR "factory automation") OR "intelligent systems" OR ["facial recognition"] ("facial recognition" OR "face recognition" OR "voice recognition" OR "iris recognition") OR ["image recognition"] ("image recognition" OR "pattern recognition" OR "gesture recognition" OR "augmented reality") OR ["semantic search"] ("semantic search" OR "data-mining" OR "full-text search" OR "predictive coding") OR "semantic web" OR "text analytics" OR "virtual assistant" OR "visual search") AND (ethics OR "human rights" OR "human values" OR "responsibility" OR "human control" OR "fairness" OR discrimination OR non-discrimination OR "transparency" OR "explainability" OR "safety and security" OR "accountability" OR "privacy")

Fuente de conjunto de datos de noticias

Quid indexa millones de artículos de noticias y blogs en inglés de LexisNexis. La plataforma ha archivado noticias y blogs desde agosto de 2013 hasta la actualidad, actualizándose cada 15 minutos. Las fuentes incluyen más de 60.000 fuentes de noticias y más de 500.000 blogs.

Visualización de Software Quid

Quid utiliza una consulta booleana para buscar temas, tendencias y palabras clave en la base de datos de noticias archivadas, con la posibilidad de filtrar los resultados por el marco temporal de la fecha de publicación, las regiones de origen, las categorías de origen o las categorías industriales. (En este caso, sólo buscamos noticias globales publicadas desde el 1 de enero de 2020 hasta el 31 de diciembre de 2020). A continuación, Quid selecciona las 10.000 historias más relevantes mediante su algoritmo NLP y visualiza los artículos únicos sin duplicados.

CONFERENCIAS DE ÉTICA EN LA IA

Preparado por Marcelo Prates, Pedro Avelar, y Luis C. Lamb

Fuente

Prates, Marcelo, Pedro Avelar, Luis C. Lamb. 2018. [On Quantifying and Understanding the Role of Ethics in AI Research: A Historical Account of Flagship Conferences and Journals](#). 21 de septiembre de 2018.

Metodología

El porcentaje de palabras clave tiene una interpretación sencilla: Para cada categoría (clásica/tendencias/ética), el número de artículos cuyo título (o resumen, en el caso de las cifras de la AAAI y NeurIPS) contiene al menos una palabra clave coincidente. Los porcentajes no suman necesariamente el 100% (por ejemplo, clásico/tendencia/ética no son mutuamente excluyentes). Se puede tener un artículo con coincidencias en las tres categorías.

Para obtener una medida de cuánto se discute la ética en la IA, se buscan términos relacionados con la ética en los títulos de los artículos de las principales conferencias y revistas de IA, aprendizaje automático y robótica.

Las palabras clave de ética utilizadas fueron las siguientes

Accountability, Accountable, Employment, Ethic, Ethical, Ethics, Fool, Fooled, Fooling, Humane, Humanity, Law, Machine Bias, Moral, Morality, Privacy, Racism, Racist, Responsibility, Rights, Secure, Security, Sentience, Sentient, Society, Sustainability, Unemployment, and Workforce.

Los conjuntos de palabras clave clásicas y de tendencia se recopilaron a partir de las áreas del libro más citado sobre IA de Russell y Norvig [2012] y de la curaduría de términos a partir de las palabras clave que aparecieron

con mayor frecuencia en los títulos de los artículos a lo largo del tiempo en los lugares de reunión.

Las palabras clave elegidas para la categoría de palabras clave clásicas fueron:

Cognition, Cognitive, Constraint Satisfaction, Game Theoretic, Game Theory, Heuristic Search, Knowledge Representation, Learning, Logic, Logical, Multiagent, Natural Language, Optimization, Perception, Planning, Problem Solving, Reasoning, Robot, Robotics, Robots, Scheduling, Uncertainty, and Vision.

Las palabras clave seleccionadas en tendencia fueron:

Autonomous, Boltzmann Machine, Convolutional Networks, Deep Learning, Deep Networks, Long Short Term Memory, Machine Learning, Mapping, Navigation, Neural, Neural Network, Reinforcement Learning, Representation Learning, Robotics, Self Driving, Self-Driving, Sensing, Slam, Supervised/Unsupervised Learning, and Unmanned.

Los términos buscados se basaron en las cuestiones expuestas e identificadas en los documentos que se presentan a continuación, y también en los temas convocados para el debate en la Primera Conferencia AAAI/ACM sobre IA, Ética y Sociedad.

J. Bossmann. [Top 9 Ethical Issues in Artificial Intelligence](#). 2016. Foro Económico Mundial.

Emanuelle Burton, Judy Goldsmith, Sven Koenig, Benjamin Kuipers, Nicholas Mattei, and Toby Walsh. [Ethical Considerations in Artificial Intelligence Courses](#). *AI Magazine*, 38(2):22–34, 2017.

The Royal Society Working Group, P. Donnelly, R. Brownsword, Z. Gharamani, N. Griffiths, D. Hassabis, S. Hauert, H. Hauser, N. Jennings, N. Lawrence, S. Olhede, M. du Sautoy, Y.W. Teh, J. Thornton, C. Craig, N. McCarthy, J. Montgomery, T. Hughes, F. Fourniol, S. Odell, W. Kay, T. McBride, N. Green, B. Gordon, A. Berditchevskaia, A.



Dearman, C. Dyer, F. McLaughlin, M. Lynch, G. Richardson, C. Williams, and T. Simpson. Machine Learning: The Power and Promise of Computers That Learn by Example. The Royal Society, 2017.

Conferencia y lugar público - Muestra

El grupo de IA contiene artículos de las principales conferencias sobre inteligencia artificial y aprendizaje automático, como AAAI, IJCAI, ICML, y NIPS y también de *Artificial Intelligence Journal* y el *Journal of Artificial Intelligence Research (JAIR)*.

El grupo de robótica contiene artículos publicados en IEEE Transactions on Robotics and Automation (ahora conocido como IEEE Transactions on Robotics), ICRA e IROS.

El grupo de ciencias de la computación contiene artículos publicados en las principales publicaciones de ciencias de la computación, como Communications of the ACM, IEEE Computer, ACM Computing Surveys y ACM e IEEE Transactions.

Código base

El código y los datos están alojados en este repositorio de [GitHub](#).

CAPÍTULO 6: DIVERSIDAD EN IA

LINKEDIN

Presencia de las competencias de IA

El objetivo de este indicador es medir la intensidad de las habilidades de IA en una entidad (en un país, industria, género, etc.) a través de la siguiente metodología:

- Calcular las frecuencias de todas las habilidades agregadas por los miembros de LinkedIn en una entidad determinada (ocupación, industria, etc.) entre 2015 y 2020, en sus perfiles profesionales.
- Ponderar de nuevo las frecuencias de las competencias mediante un modelo TF-IDF para obtener las 50 competencias más representativas en esa entidad. Estas 50 competencias componen el “genoma de competencias” de esa entidad.
- Calcular la proporción de competencias que pertenecen al grupo de competencias de la IA de las principales competencias de la entidad seleccionada.

Interpretación: El índice de penetración de las habilidades de IA señala la prevalencia de las habilidades de IA en las ocupaciones, o la intensidad con la que los miembros de LinkedIn utilizan las habilidades de IA en sus trabajos. Por ejemplo, las 50 principales habilidades para la ocupación de ingeniero se calculan en base a la frecuencia ponderada con la que aparecen en los perfiles de los miembros de LinkedIn. Si cuatro de las habilidades que poseen los ingenieros pertenecen al grupo de habilidades de IA, esta medida indica que la penetración de las habilidades de IA se estima en un 8% entre los ingenieros (por ejemplo, 4/50).

Presencia relativa de competencias de IA

Para poder comparar la prevalencia de las competencias entre países, se calculan los genomas de competencias y se selecciona un benchmark pertinente (por ejemplo, la media mundial). A continuación, se elabora una relación entre la presencia de las competencias de la IA de un país y la del

benchmark, controlando las ocupaciones.

Interpretación: La penetración relativa de las habilidades de IA de un país de 1,5 indica que las habilidades de IA son 1,5 veces más frecuentes que en el benchmark, para un conjunto superpuesto de ocupaciones.

Comparación global: por género

La presencia relativa de las habilidades de la IA por país por género proporciona una descomposición en profundidad de la prevalencia de las habilidades de la IA a través de las reservas de mano de obra femenina y masculina en los países de la muestra.

Interpretación: Un índice de penetración relativo de las competencias de IA de 2 para las mujeres en un país significa que la penetración media de las competencias de IA entre las mujeres de ese país es dos veces superior a la media mundial en el mismo conjunto de ocupaciones entre las mujeres. Si, en el mismo país, el índice de penetración relativo de las competencias en IA para los hombres es de 1,9, esto indica que la penetración media de las competencias en IA entre las mujeres de ese país es un 5% superior a la de los hombres (calculada dividiendo 1,9 por 2 y restando luego 1, o $2/1,9-1$) para el mismo conjunto de ocupaciones.

CAPÍTULO 7: POLÍTICAS Y ESTRATEGIAS NACIONALES EN IA

BLOOMBERG GOVERNMENT

Bloomberg Government (BGOV) es un servicio de inteligencia de mercado por suscripción diseñado para hacer más accesibles los datos sobre presupuestos y contratos del gobierno de Estados Unidos a los profesionales de desarrollo empresarial y asuntos gubernamentales. Las herramientas propias de BGOV ingieren y organizan conjuntos de datos y documentos gubernamentales semiestructurados, lo que permite a los usuarios seguir y prever la inversión en mercados clave.

Metodología

Los datos del BGOV incluidos en esta sección proceden de tres fuentes originales:

Gastos en contratos: La Herramienta de Inteligencia de Contratos del BGOV ingiere dos veces al día todos los datos de gasto en contratos publicados en el banco de datos beta. SAM.gov, y estructura los datos para garantizar una imagen coherente del gasto gubernamental a lo largo del tiempo. Para la sección “Gasto en contratos del gobierno de EE.UU.”, los analistas del BGOV utilizaron los datos del FPDS-NG, organizados por la Herramienta de Inteligencia de Contratos, para construir un modelo de gasto del gobierno en contratos relacionados con la inteligencia artificial en los años fiscales 2000 a 2021. El modelo del BGOV utilizó una combinación de códigos de servicio de productos definidos por el gobierno y más de 100 palabras clave y acrónimos relacionados con la IA para identificar el gasto en contratos relacionados con la IA.

Presupuesto para defensa RDT&E: El BGOV organizó las 7.057 partidas presupuestarias incluidas en la solicitud de presupuesto de RDT&E basándose en los datos disponibles en el sitio web del Contralor del Departamento de Defensa. Para la sección “Presupuesto del Departamento de Defensa (DOD)”, BGOV utilizó un conjunto de más de una docena de palabras clave específicas de la IA para identificar 305 actividades presupuestarias únicas relacionadas con la inteligencia artificial y el aprendizaje automático por un valor combinado

de 5.000 millones de dólares en el año fiscal 2021.

Registro del congreso (disponible en el sitio web [Congressional Record](#)): El BGOV mantiene un repositorio de documentos del Congreso, que incluye proyectos de ley, enmiendas, resúmenes de proyectos de ley, evaluaciones de la Oficina Presupuestaria del Congreso, informes publicados por los comités del Congreso, el Servicio de Investigación del Congreso (CRS) y otros. Para la sección “U.S. Congressional Record”, los analistas de BGOV identificaron toda la legislación (aprobada o presentada), los informes de los comités del Congreso y los informes del CRS que hacían referencia a una o más de una docena de palabras clave específicas de IA. Los resultados están organizados por sesiones del Congreso de dos años.

LIQUIDNET

Preparado por Jeffrey Banner y Steven Nichols

Fuente

Liquidnet proporciona datos de sentimiento que predicen el impacto en el mercado de las comunicaciones de los bancos centrales y las empresas. Más información sobre Liquidnet [aquí](#).

Ejemplos de menciones de Bancos Centrales

He aquí algunos ejemplos de cómo la IA es mencionada por los bancos centrales: En el primer caso, China utiliza una plataforma de simulación y predicción del entorno geopolítico que funciona cruzando enormes cantidades de datos y luego proporcionando sugerencias de política exterior a los diplomáticos chinos o el Banco de Japón utiliza modelos de predicción de IA para los tipos de cambio. En el segundo caso, muchos bancos centrales dirigen las comunicaciones a través de documentos oficiales; por ejemplo, el 25 de julio de 2019, el Banco Central de Holanda (DNB) publicó [Lineamientos para el uso de la IA en servicios financieros](#) y lanzó sus seis principios “SAFEST” para el uso responsable de la IA en compañías reguladas— o un discurso el 4 de junio de 2019, por el Director Ejecutivo de Supervisión de Tomadores de Depósitos del Banco de Inglaterra James Proudman, titulado [“MGestionando](#)

máquinas: el gobierno de la inteligencia artificial”, enfocado en la creciente importancia estratégica del uso de la IA en los entes financieros regulados.

MCKINSEY GLOBAL INSTITUTE

Fuente

La recolección de datos y los análisis fueron realizados por el [McKinsey Global Institute \(MGI\)](#).

Canada (Cámara de los Comunes)

Los datos se recogieron utilizando el buscador [Hansard](#) en el sitio web del Parlamento de Canadá. El MGI buscó los términos “Artificial Intelligence” y “Machine Learning” (comillas incluidas) y descargó los resultados en forma de CSV. El rango de fechas se estableció en “todos los debates”. Los datos son del 31 de diciembre de 2020. Los datos están disponibles en línea desde el 31 de agosto de 2002.

Cada recuento indica que la Inteligencia Artificial o el Aprendizaje Automático se mencionó en un comentario u observación particular durante los procedimientos de la Cámara de los Comunes. Esto significa que, dentro de un evento o conversación, si un miembro menciona la IA o el ML varias veces dentro de sus comentarios, sólo aparecerá una vez. Sin embargo, si, durante el mismo evento, el orador menciona la IA o el ML en comentarios separados (con otros oradores en medio), aparecerá varias veces. Los recuentos de la Inteligencia Artificial o el Aprendizaje Automático están separados, ya que se realizaron en búsquedas separadas. No se incluyen las menciones de las abreviaturas IA o ML.

Reino Unido (Cámara de los Comunes, Casa de los Lores, Salón de Westminster y Comités)

Los datos se recogieron usando la herramienta de [búsqueda de referencias](#) del sitio [Hansard](#) del Parlamento británico. El MGI buscó los términos “Artificial Intelligence” y “Machine Learning” (comillas incluidas) y catalogó los resultados. Los datos corresponden al 31 de diciembre de 2020. Los datos están disponibles en línea a partir del 1 de enero de 1800. Contiene información parlamentaria con licencia de [Open Parliament Licence v3.0](#).

Al igual que en Canadá, cada recuento indica que la Inteligencia Artificial o el Aprendizaje Automático fueron mencionados en un comentario u observación particular durante un procedimiento.

Por lo tanto, si un miembro menciona la IA o el ML varias veces en sus comentarios, sólo aparecerá una vez. Sin embargo, si, durante el mismo evento, el mismo orador menciona la IA o el ML en comentarios separados (con otros oradores entre ellos), aparecerá varias veces. Los recuentos de la Inteligencia Artificial o el Aprendizaje Automático están separados, ya que se realizaron en búsquedas separadas. No se incluyen las menciones de las abreviaturas IA o ML.

Estados Unidos (Senado y Cámara de los Representantes)

Los datos se recogieron usando la herramienta de búsqueda [avanzada del sitio web del registro del Congreso](#). MGI buscó los términos “Artificial Intelligence” y “Machine Learning” (incluyendo las comillas) y descargó los resultados como un CSV. La opción “word variant” no fue seleccionada y los documentos incluyeron al Senado, Cámara de Representantes, y observaciones ampliadas, pero no incluyeron el boletín diario. Los datos cubren hasta el 31 de diciembre de 2020 y está disponible en línea desde el Congreso 104 en adelante (es decir, desde 1995).

Cada conteo indica que *Artificial Intelligence* o *Machine Learning* fue mencionado durante un evento en particular contenido dentro del registro del Congreso, incluyendo la lectura de un proyecto de ley. Si un orador menciona la IA o el ML varias veces en sus comentarios, o varios oradores mencionan la IA o el ML en el mismo evento, sólo aparecerá una vez como resultado. Los recuentos de la Inteligencia Artificial o el Aprendizaje Automático están separados, ya que se realizaron en búsquedas separadas. No se incluyen las menciones de las abreviaturas AI o ML.

POLÍTICAS PÚBLICAS DE EE.UU. EN IA

Fuente

La recogida y el análisis de los datos fueron realizados por el Stanford Institute of Human-Centered Artificial Intelligence y AI Index.

Organizaciones

Para desarrollar una mejor comprensión del pensamiento de vanguardia que motiva la política de IA, rastreamos los

documentos de política publicados por 36 organizaciones a través de tres amplias categorías que incluyen:

Grupos de reflexión, institutos de política y academia: Se trata de organizaciones en las que expertos (a menudo procedentes del mundo académico y de la esfera política) proporcionan información y asesoramiento sobre problemas políticos concretos. Incluimos las siguientes 27 organizaciones: AI PULSE at UCLA Law, American Enterprise Institute, Aspen Institute, Atlantic Council, Berkeley Center for Long-Term Cybersecurity, Brookings Institution, Carnegie Endowment for International Peace, Cato Institute, Center for a New American Security, Center for Strategic and International Studies, Council on Foreign Relations, Georgetown Center for Security and Emerging Technology (CSET), Harvard Belfer Center, Harvard Berkman Klein Center, Heritage Foundation, Hudson Institute, MacroPolo, MIT Internet Policy Research Initiative, New America Foundation, NYU AI Now Institute, Princeton School of Public and International Affairs, RAND Corporation, Rockefeller Foundation, Stanford Institute for Human-Centered Artificial Intelligence (HAI), Stimson Center, Urban Institute, Wilson Center.

Sociedad civil, asociaciones y consorcios: Instituciones sin ánimo de lucro que incluyen organizaciones comunitarias y ONG que defienden una serie de cuestiones sociales. Incluimos las nueve organizaciones siguientes: Algorithmic Justice League, Alliance for Artificial Intelligence in Healthcare, Amnistía Internacional, EFF, Future of Privacy Forum, Human Rights Watch, IJIS, Institute for Electrical and Electronics Engineers, Partnership on AI

Industria y consultoría: Prácticas profesionales que proporcionan asesoramiento experto a los clientes y a los grandes actores de la industria. Incluimos seis organizaciones destacadas en este espacio: Accenture, Bain & Co., BCG, Deloitte, Google AI, McKinsey & Company

Metodología

Cada área temática amplia se basa en una colección de palabras clave subyacentes que describen el contenido del documento específico. Hemos incluido 17 temas que representan la mayor parte del discurso relacionado con la IA entre 2019-2020. Estas áreas temáticas y las palabras clave asociadas se enumeran a continuación.

- Ciencias Biológicas y de la Salud: medicina, sistemas sanitarios, descubrimiento de fármacos, cuidados, investigación biomédica, seguros, comportamientos sanitarios, COVID-19,

salud global

- Ciencias físicas: química, física, astronomía, ciencias de la tierra
- Energía y medio ambiente: Costes energéticos, cambio climático, mercados energéticos, contaminación, conservación, petróleo y gas, energías alternativas
- Asuntos internacionales y seguridad internacional: relaciones internacionales, comercio internacional, países en desarrollo, ayuda humanitaria, guerra, seguridad regional, seguridad nacional, armas autónomas
- Justicia y aplicación de la ley: justicia civil, justicia penal, justicia social, policía, seguridad pública, tribunales
- Comunicación y medios de comunicación: redes sociales, desinformación, mercados de medios de comunicación, deepfakes
- Gobierno y administración pública: gobierno federal, gobierno estatal, gobierno local, eficiencia del sector público, eficacia del sector público, servicios gubernamentales, prestaciones gubernamentales, programas gubernamentales, obras públicas, transporte público
- Democracia: elecciones, derechos, libertades, libertades personales
- Industria y regulación: economía, antimonopolio, fusiones y adquisiciones, competencia, finanzas, gestión, cadena de suministro, telecomunicaciones, regulación económica, normas técnicas, industria y regulación de vehículos autónomos
- Innovación y tecnología: avances y mejoras en la tecnología de IA, I+D, propiedad intelectual, patentes, emprendimiento, ecosistemas de innovación, startups, informática, ingeniería
- Educación y habilidades: primera infancia, K-12, educación superior, STEM, escuelas, aulas, recualificación
- Mano de obra: oferta y demanda de trabajo, talento, inmigración, migración, economía del personal, futuro del trabajo
- Ciencias sociales y del comportamiento: sociología, lingüística, antropología, estudios étnicos, demografía, geografía, psicología, ciencias cognitivas
- Humanidades: artes, música, literatura, lengua, interpretación, teatro, clásicos, historia, filosofía, religión, estudios culturales
- Equidad e inclusión: prejuicios, discriminación, género, raza
- Privacidad, seguridad y protección: anonimato, GDPR, protección del consumidor, seguridad física, control humano, ciberseguridad, encriptación, piratería informática
- Ética: transparencia, responsabilidad, valores humanos, derechos humanos, sostenibilidad, explicabilidad, interpretabilidad, normas para la toma de decisiones

VITALIDAD GLOBAL DE LA IA

RESUMEN

Las tablas a continuación muestran el pilar principal, los subpilares y los indicadores cubiertos por la Herramienta de Vitalidad Global de la IA. Cada subpilar se compone de indicadores individuales recogidos en el Libro de códigos de la IA mundial. Hay un total de 22 indicadores, 14 de ellos en el pilar de Investigación y Desarrollo (I+D), 6 en el pilar de Economía y 2 en el pilar de Inclusión, específicos para la diversidad de género. Para ayudar a la toma de decisiones basada en datos para diseñar estrategias políticas nacionales, la herramienta de Vitalidad Global de la IA está disponible en la web.

I+D	
SUB-PILAR	VARIABLE
Publicaciones en conferencias	Número de artículos publicados en conferencias de IA*
Publicaciones en conferencias	Número de artículos publicados en conferencias de IA per cápita
Publicaciones en conferencias	Número de citas en conferencias de IA*
Publicaciones en conferencias	Número de citas en conferencias de IA per cápita
Publicaciones periódicas	Número de artículos publicados en publicaciones periódicas de IA*
Publicaciones periódicas	Número de artículos publicados en publicaciones periódicas de IA per capita*
Publicaciones periódicas	Número de citas en publicaciones periódicas de IA*
Publicaciones periódicas	Número de citas en publicaciones periódicas de IA per cápita
Innovación > Patentes	Número de patentes de IA*
Innovación > Patentes	Número de patentes de IA per cápita
Innovación > Patentes	Número de citas de patentes de IA*
Innovación > Patentes	Número de citas de patentes de IA per cápita
Publicaciones periódicas> Aprendizaje profundo	Número de artículos de aprendizaje profundo*
Publicaciones periódicas> Aprendizaje profundo	Número de artículos de aprendizaje profundo per cápita

ECONOMÍA	
SUB-PILAR	VARIABLE
Competencias	Presencia relativa de competencias
Empleo	Índice de contratación en IA
Inversión	Inversión privada total en IA*
Inversión	Inversión privada en IA per cápita
Inversión	Número de startups financiadas*
Inversión	Número de startups financiadas per cápita

INCLUSIÓN	
SUB-PILAR	VARIABLE
Diversidad de género	Presencia de competencias en IA (mujeres)
Diversidad de género	Cantidad de ocupaciones únicas en IA (títulos de los puestos), mujeres

La herramienta web permite a los usuarios ajustar las ponderaciones de cada métrica en función de sus preferencias individuales. La configuración por defecto de la herramienta permite al usuario seleccionar entre tres opciones de ponderación:

All weights to midpoint

Este botón asigna pesos iguales para todos los indicadores.

Only absolute metrics

Este botón asigna los pesos máximos a las métricas absolutas. Las métricas per cápita no están bajo consideración.

Only per capita metrics

Este botón asigna pesos máximos a las métricas per cápita. No se tienen en cuenta las métricas absolutas.

El usuario puede ajustar los pesos de cada métrica en función de sus preferencias. Los gráficos se actualizan automáticamente cuando se modifica cualquier peso.

El usuario puede seleccionar la vista “Global” o “National” para visualizar los resultados. La vista “Global” ofrece una vista comparativa entre países basada en las ponderaciones seleccionadas por el usuario. La vista “National” ofrece una inmersión profunda en el país para evaluar en qué indicadores de IA es relativamente mejor un país determinado. Los valores específicos de las métricas de los países se escalan (0-100), donde 100 indica que un determinado país tiene el número más alto en la distribución global para esa métrica, y a la inversa, números pequeños como 0 o 1 indican valores relativamente bajos en la distribución global. Esto puede ayudar a identificar áreas de mejora y a identificar estrategias políticas nacionales para apoyar un ecosistema de IA vibrante.

CONSTRUCCIÓN DE LA VITALIDAD GLOBAL DE LA IA: MEDIDA COMPUESTA

Fuente

Los datos son recogidos por el Índice AI utilizando diversos conjuntos de datos a los que se hace referencia en los capítulos del Informe del Índice AI 2020.

Metodología

- Paso 1: Obtener, armonizar e integrar los datos sobre los atributos individuales en todos los países y en el tiempo.
- Paso 2: Utilizar la Escala Mínima-Máxima para normalizar cada indicador específico del país entre 0 y 100.
- Paso 3: Tomar la media aritmética por indicador de cada país para un año determinado.
- Paso 4: Construir ponderados modulares para los pilares disponibles y los indicadores individuales.

Medida agregada

El Índice Compuesto de Vitalidad de la IA puede expresarse en la siguiente ecuación:

$$AI\ Vibrancy_{c,t} = \left(\Psi_{pillar} * \left[\alpha_{c,t} * \Psi_{indicator} \right] \right) \div N$$

donde c representa un país y t representa el año, es el indicador individual escalado (0-100), es la ponderación asignada a los indicadores individuales, es la ponderación específica de uno de los tres pilares de alto nivel y N es el número de indicadores disponibles para un país determinado para un año específico.

Normalización

Para ajustar las diferencias en las unidades de medida y los rangos de variación, las 22 variables se normalizaron en el rango [0, 100], y las puntuaciones más altas representan mejores resultados. Se adoptó un método de normalización mínimo-máximo, dados los valores mínimo y máximo de cada variable respectivamente. Los valores más altos indican mejores resultados. La fórmula de normalización es:

$$Min - max\ scalar\ (MS100) = 100 * \frac{(value) - (min)}{(max) - (min)}$$

Cobertura y consideraciones

Se eligió un umbral del 73% de cobertura para seleccionar la lista final de países basándose en una media de los datos disponibles entre 2015-2020. Rusia y Corea del Sur se añadieron manualmente debido a su creciente importancia en el panorama mundial de la IA, aunque no superaron el umbral del 73%.

INDICADORES DE INVESTIGACIÓN Y DESARROLLO

ID	PILAR	SUB-PILAR	NOMBRE	DEFINICIÓN	FUENTE
1	Investigación y desarrollo	Publicaciones en conferencias	Número de artículos en conferencias de IA*	Recuento total de trabajos publicados en conferencias de IA atribuidos a instituciones del país en cuestión.	Microsoft Academic Graph (MAG)
2	Investigación y desarrollo	Publicaciones en conferencias	Número de artículos en conferencias de IA per cápita	Recuento total de trabajos de conferencias de IA publicados atribuidos a instituciones del país en cuestión en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores a escala.	Microsoft Academic Graph (MAG)
3	Investigación y desarrollo	Publicaciones en conferencias	Número de citas en conferencias de IA*	Recuento total de citas de conferencias de IA atribuidas a instituciones del país en cuestión.	Microsoft Academic Graph (MAG)
4	Investigación y desarrollo	Publicaciones en conferencias	Número de citas en conferencias de IA per cápita	Recuento total de citas de conferencias de IA atribuidas a instituciones en el país dado en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores a escala.	Microsoft Academic Graph (MAG)
5	Investigación y desarrollo	Publicaciones periódicas	Número de artículos en IA*	Recuento total de artículos publicados en revistas de IA atribuidos a instituciones del país en cuestión.	Microsoft Academic Graph (MAG)
6	Investigación y desarrollo	Publicaciones periódicas	Número de artículos en IA per cápita	Recuento total de artículos publicados en revistas de IA atribuidos a instituciones del país en cuestión en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores a escala.	Microsoft Academic Graph (MAG)
7	Investigación y desarrollo	Publicaciones periódicas	Número de citas en revistas de IA*	Recuento total de citas de revistas de IA atribuidas a instituciones del país en cuestión.	Microsoft Academic Graph (MAG)
8	Investigación y desarrollo	Publicaciones periódicas	Número de citas en revistas de IA per cápita	Recuento total de citas de revistas de IA atribuidas a instituciones del país dado en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores a escala.	Microsoft Academic Graph (MAG)
9	Investigación y desarrollo	Innovación > Patentes	Número de patentes de IA*	Recuento total de patentes de IA publicadas atribuidas a instituciones del país en cuestión.	Microsoft Academic Graph (MAG)
10	Investigación y desarrollo	Innovación > Patentes	Número de patentes de IA per cápita	Recuento total de patentes de IA publicadas atribuidas a instituciones del país en cuestión en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores a escala.	Microsoft Academic Graph (MAG)
11	Investigación y desarrollo	Innovación > Patentes	Número de citas de patentes de IA*	Recuento total de citas de patentes de IA publicadas atribuidas a las instituciones de presentación de patentes de origen.	Microsoft Academic Graph (MAG)
12	Investigación y desarrollo	Innovación > Patentes	Número de citas de patentes de IA per cápita	Recuento total de citas de patentes de IA publicadas atribuidas a instituciones en el país de origen de la presentación de la patente, en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores a escala.	Microsoft Academic Graph (MAG)
13	Investigación y desarrollo	Publicaciones periódicas > Aprendizaje profundo	Número de artículos de aprendizaje profundo*	Recuento total de artículos arXiv sobre aprendizaje profundo atribuidos a instituciones del país en cuestión.	arXiv, NESTA
14	Investigación y desarrollo	Publicaciones periódicas > Aprendizaje profundo	Número de artículos de aprendizaje profundo per cápita	Recuento total de artículos arXiv sobre aprendizaje profundo atribuidos a instituciones del país en cuestión en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores escalados.	arXiv, NESTA

INDICADORES ECONÓMICOS

ID	PILAR	SUB-PILAR	NOMBRE	DEFINICIÓN	FUENTE
15	Economía	Competencias	Presencia relativa de las competencias	La medida del índice de penetración relativo de las competencias se basa en un método para comparar la prevalencia de las competencias de la IA en la ocupación media de cada país frente a un benchmark (por ejemplo, la media mundial), controlando el mismo conjunto de ocupaciones.	LinkedIn Economic Graph
16	Economía	Empleo	Índice de contratación en IA	El índice de contratación de IA es el porcentaje de miembros de LinkedIn que tenían alguna habilidad de IA (véase el Apéndice para la agrupación de habilidades de IA) en su perfil y añadieron un nuevo empleador a su perfil en el mismo mes en que comenzó el nuevo trabajo, dividido por el número total de miembros de LinkedIn en el país. A continuación, este índice se indexa con el mes medio de 2015-2016; por ejemplo, un índice de 1,05 indica un índice de contratación que es un 5 % superior al mes medio de 2015-2016.	LinkedIn Economic Graph
17	Economía	Inversión	Monto total del financiamiento*	Importe total de la financiación privada de Inversión recibida para las startups de IA (en dólares nominales).	Crunchbase, CapIQ, NetBase Quid
18	Economía	Inversión	Financiamiento total per cápita	Importe total de la financiación privada de Inversión recibida para las startups de IA en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores debidamente escalados.	Crunchbase, CapIQ, NetBase Quid
19	Economía	Inversión	Número de compañías financiadas*	Número total de empresas de IA fundadas en el país en cuestión.	Crunchbase, CapIQ, NetBase Quid
20	Economía	Inversión	Número de compañías per cápita financiadas	Número total de empresas de IA fundadas en el país en cuestión en términos per cápita. El denominador es la población (en decenas de millones) de un año determinado para obtener valores debidamente escalados.	Crunchbase, CapIQ, NetBase Quid

INDICADORES DE INCLUSIÓN

ID	PILAR	SUB-PILAR	NOMBRE	DEFINICIÓN	FUENTE
21	Inclusión	Diversidad de género	Presencia de competencias de IA (mujeres)	La medida del índice de penetración relativo de las competencias se basa en un método para comparar la prevalencia de las competencias de la IA en la ocupación media de cada país frente a un benchmark (por ejemplo, la media mundial), controlando el mismo conjunto de ocupaciones.	LinkedIn Economic Graph
22	Inclusión	Diversidad de género	Número de ocupaciones únicas en IA (títulos de los puestos), mujeres	Número de ocupaciones únicas de IA (o títulos de trabajo) con alta penetración de habilidades de IA para las mujeres en un país determinado.	LinkedIn Economic Graph



Informe 2021
Artificial
Intelligence Index



Stanford University
Human-Centered
Artificial Intelligence