

IA Y DATOS EN ACCIÓN: CÓMO PREPARAR TU EMPRESA PARA EL FUTURO

Autor

Anna Vía - Head of IA en INFOJOBS

RED DE EDUCACIÓN SUPERIOR

 **Planeta Formación y Universidades**

ÍNDICE

1	Introducción: La revolución de la IA y su impacto en la empresa	4
1.1	¿Cómo hemos llegado hasta aquí y por qué ahora?	5
1.2	Tendencias de Inversión y Escala	7
2	Las palancas estratégicas para la aplicación de IA en la empresa	12
2.1	Infraestructura tecnológica	13
2.2	Cloud Computing	15
2.3	Los Datos como Combustible	16
2.4	El talento	17
3	Oportunidades en la IA aplicada a proyectos	21
3.1	El Ciclo de Vida: ML Tradicional vs. IA Generativa	23

3.2	Sectores Clave y Casos de Uso de IA	26
3.3	Medición del Éxito: KPIs y ROI	29
4	Aplicar la IA para mejorar la productividad de las empresas	30
4.1	Impacto por Roles y Departamentos	31
4.2	Midiendo el retorno de esta productividad aumentada (ROI) y sus retos	35
5	Gestión del cambio y transformación organizativa	37
6	Gestión de riesgos, ética y Compliance	42
6.1	Riesgos asociados a la integración de la IA	43
6.2	GPRD	45
6.3	AI Act	46
7	Mirando hacia Adelante: Tendencias Futuras	47
8	Referencias	51

1. La revolución de la IA y su impacto en la empresa

1. Introducción: La revolución de la IA y su impacto en la empresa

1.1 ¿Cómo hemos llegado hasta aquí y por qué ahora?

Nos encontramos en un momento de inflexión histórica que se compara frecuentemente con la revolución industrial o la llegada de Internet. Sin embargo, esta revolución difiere en dos principales factores respecto a las revoluciones anteriores: mientras que la Revolución Industrial multiplicó la fuerza física humana, lo cual permitió automatizar el trabajo manual, la revolución de la Inteligencia Artificial (IA) es más cercana a las tareas consideradas la esencia de la humanidad –como la inteligencia, el razonamiento o la creatividad. Además, la IA difiere también en velocidad, puesto que la rápida adopción de la IA generativa, que ha roto todos los récords conocidos, contrasta enormemente con las tecnologías anteriores, que necesitaron décadas para poder ser acogidas exitosamente. ChatGPT, que ha conseguido ser una de las aplicaciones con una instauración más rápida de la historia, es solo un ejemplo, entre muchos, de esta veloz nueva revolución.

El lanzamiento de ChatGPT, en noviembre de 2022, no fue solo un hito tecnológico, sino también el comienzo de una carrera global: en cuestión de meses, pasamos de una aplicación aislada a una tecnología omnipresente. Así pues, aparecieron nuevas versiones de modelos fundacionales casi a diario, avances hacia la multimodalidad que permite a las máquinas "ver" (imagen), "oír" (sonido) y "hablar" (voz, texto) con fluidez y una integración masiva en productos digitales y procesos empresariales.

El impacto actual es innegable: desde startups que nacen con la IA en su core hasta corporaciones tradicionales a las que les redefine sus estrategias, la IA ha dejado de ser ciencia ficción para convertirse en una ventaja competitiva tangible. Pero la revolución no está solo en proyectos empresariales, sino también en las manos de las personas, pues la IA ocupa ya un lugar en muchas vidas cotidianas, acelerando y permitiéndonos llegar más lejos tanto en proyectos laborales como en nuestra vida personal.



No obstante, a pesar de la aparente novedad de esta tecnología, la ambición de predecir el futuro y replicar la inteligencia tiene orígenes lejanos. Sus cimientos matemáticos se remontan a los orígenes de la estadística, desde los matemáticos árabes del siglo VIII hasta la definición de la regresión o la correlación en el siglo XIX –herramientas que, por primera vez, permitieron la inferencia basada en datos para la toma de decisiones. No fue hasta el 1958 que llegó el salto hacia la automatización de la mano del Perceptrón, la primera red neuronal entrenable diseñada para el reconocimiento de imágenes. Las expectativas, sin embargo, eran desmesuradas para la época y sus limitaciones técnicas provocaron décadas de ciclos de entusiasmo seguidos de decepción, ciclos conocidos como los "inviernos de la IA".


En el periodo de entre 1990 y 2006 que el campo resurgió con fuerza bajo el paraguas del Deep Learning. Fue entonces cuando, gracias a la explosión del Big Data y la computación en la nube, la tecnología maduró lo suficiente para saltar de la teoría a aplicaciones reales de visión por computador y procesamiento de lenguaje: fue la era de los sistemas de recomendación, como Netflix o Spotify, unos algoritmos capaces no sólo de predecir, sino también de prescribir contenido que influya el comportamiento del usuario.

Finalmente, en los últimos años han convergido los tres factores clave que permitieron la llegada de la IA Generativa (2023) [1]:

1. Redes Neuronales y arquitectura "Transformer". En 2017, investigadores de Google publicaron el artículo "Attention Is All You Need," con el cual introdujeron la arquitectura Transformer, nombre que designa a una tipología de Red Neuronal. Esta innovación permitió a los modelos procesar datos de manera paralela y entender el contexto de las palabras en una frase mucho mejor que sus predecesores. Es la "T" de GPT (Generative Pre-trained Transformer) y la base técnica de la IA generativa.

2. La disponibilidad masiva de datos. La digitalización global ha generado una cantidad de datos sin precedentes (Big Data). Estos modelos necesitan "leer" prácticamente todo Internet para aprender a escribir, codificar y razonar. Hoy, por fin, tenemos esa biblioteca digital disponible.

3. Poder de computación. El desarrollo de hardware especializado, específicamente las Unidades de Procesamiento Gráfico (GPUs), ha permitido realizar los trillones de cálculos necesarios para entrenar estos modelos en tiempos razonables: modelos que antes hubieran tardado años a entrenarse ahora se pueden entrenar en horas o días.



Fuente: <https://medium.com/artificial-corner/from-ancient-oracles-to-generative-ai-da86f64e0494>

En definitiva, estamos ante el resultado de décadas de evolución científica y tecnológica, el cual ha convergido gracias a algoritmos, datos y capacidad de cómputo. Con esto, la Inteligencia Artificial es una tecnología accesible, escalable y valiosa que hace que las empresas no estén sólo frente a un reto tecnológico sino también a uno de adaptación y estrategia. Aunque los modelos de IA son ya muy potentes, la adopción y aplicación exitosa por parte de la empresa de esta tecnología con retorno positivo conlleva tiempo.

1.2 Tendencias de Inversión y Escala

Cualquier persona que probara las versiones iniciales de ChatGPT pudo darse cuenta del potencial disruptivo de esta tecnología: la capacidad de interactuar con una máquina mediante lenguaje natural y obtener respuestas coherentes y creativas democratizó el acceso a los modelos más avanzados de IA, lo cual generó inevitablemente un gran hype alrededor de ésta. Este potencial evidente, sumado a una adopción masiva por parte de los usuarios,

detonó una carrera de adopción en el mundo empresarial, tanto por las nuevas oportunidades que se abrían con esta tecnología como por los riesgos de disrupción que ésta conllevaba.

Para entender las tendencias de inversión y potencial de la IA en el mundo empresarial, podemos clasificar las industrias según su posición en la cadena de valor de la IA Generativa [2][3]. Las inversiones multimillonarias actuales se distribuyen en cuatro capas principales:

1. Hardware: Entrenar modelos de IA Generativa requiere decenas de miles de GPUs trabajando en paralelo durante semanas o meses. Esta capa tiene las barreras de entrada más altas y es la más intensiva en capital. Actualmente, está dominada por muy pocos jugadores, con NVIDIA a la cabeza, lo cual la convierte en una de las empresas más valiosas del mundo. Las acciones de Nvidia han subido a más de x10 desde el lanzamiento de ChatGPT, hecho que la ha llevado a convertirse en la empresa más valiosa del mundo [4]. Otras empresas han intentado ganar autonomía respecto a NVIDIA, como Amazon al apostar por sus propios chips Trainium3 o Google por sus propios TPUs Ironwood, o OpenAI buscando producir sus propios procesadores gracias a un partnership con Broadcom [5].

2. Infraestructura. No basta con tener los chips: se necesitan centros de datos masivos y energía para alojarlos y operarlos. Los grandes proveedores de nube (hyperscalers) como Microsoft Azure, Amazon Web Services (AWS) y Google Cloud están invirtiendo decenas de miles de millones de dólares anuales en construir nuevos data centers, Por ejemplo, el proyecto "Stargate" de OpenAI espera invertir 500.000 millones de dólares en la construcción de una infraestructura de IA en los próximos cuatro años. En algunos casos se está también apostando por revivir la apuesta por la energía nuclear, dada la necesidad energética de estos data centers, o incluso la posibilidad de lanzar centros de datos en el espacio, como la apuesta de SpaceX.

3. Modelos Fundacionales. Aquí se encuentran las empresas que desarrollan los LLMs (Large Language Models) y sistemas multimodales y los ofrecen como servicio, deployados desde sus propios servicios o a través de partnerships con Cloud Providers.

En este grupo destacan empresas estadounidenses como OpenAI, Anthropic, Google, Meta o xAI; mientras que en China, como ocurre con la iniciativa Deepseek, y en Europa, como hace la empresa Mistral AI, apuestan por una tecnología más abierta. La magnitud de las inversiones y del capital en esta capa se puede ver, por ejemplo, con OpenAI, que a finales de 2025 tenía una valuación de 500 billones de dólares. Estas valuaciones son necesarias dado el elevadísimo coste que supone entrenar modelos competitivos, el cual está a su vez relacionado con el coste de infraestructura y energía.

4. Aplicaciones. Es aquí donde la IA llega a los usuarios finales y busca aportar valor tangible. El retorno de esta capa de aplicaciones de IA debería permitir compensar la inversión necesaria en las capas anteriores. Es sin duda la capa con mayor número de startups y diversificación, pues ofrece desde copilotos de programación hasta tutores personalizados o herramientas de diseño. Las empresas más tradicionales buscan integrar la IA en sus funcionalidades y procesos, como sucede, por ejemplo, con la integración de Copilot en Microsoft Office; mientras que otras empresas están naciendo priorizando la IA en su core desde el inicio, reinventando así la experiencia del usuario o el valor que pueden aportar como empresa.



Fuente: <https://www.deeplearning.ai/the-batch/the-falling-cost-of-building-ai-applications/>

Haciendo foco en la capa de aplicaciones, donde se encuentra la mayoría de las empresas, vemos la tendencia en los últimos meses de prescindir de priorizar pruebas piloto con IA generativa extendidas por la organización en pro de buscar productivizar soluciones y medir su retorno a nivel de ROI: datos de 2025 indican un aumento del 50% en el acceso de los trabajadores a herramientas de IA generativa, y se proyecta que el número de organizaciones con más del 40% de sus proyectos de IA en producción se duplique en apenas seis meses. Este salto cualitativo, de exploración a explotación, es el principal desafío que define el entorno empresarial actual [6].

Otra tendencia relevante que se ha visto en los últimos meses y que se espera que siga ganando importancia en el futuro es el camino de la IA Agéntica. Los agentes de IA son sistemas que utilizan IA para planificar y ejecutar de manera autónoma, utilizando herramientas, navegando por software y realizando procesos complejos de principio a fin sin supervisión humana constante. La mayoría de las empresas están aún en fase de piloto, buscando entender tanto su valor como los riesgos de seguridad y control que esto implica. La visión a futuro apunta hacia estructuras organizativas híbridas, donde equipos humanos colaborarán diariamente con agentes de IA autónomos [7].

Ante todas estas promesas de potencial y valor y un volumen de inversión sin precedentes, los economistas plantean dos escenarios divergentes para el medio plazo [8]:

1. Auge de la IA: la tecnología cumple sus promesas de productividad.

La adopción se acelera en todos los sectores, y genera así un retorno de inversión (ROI) claro que justifica el gasto masivo en hardware e infraestructura. La IA se convierte en el motor del crecimiento económico global.

2. Colapso de la IA: los mercados comienzan a cuestionar si las aplicaciones reales son capaces de generar suficientes ingresos para pagar la costosa infraestructura que las soporta. Si las empresas no logran transitar de la experimentación a la rentabilidad, podríamos ver una corrección bursátil severa similar a la "burbuja de las puntocom."

El modelo de precios presenta consideraciones económicas importantes. A más de \$50 por usuario mensualmente para funcionalidades completas, la herramienta requiere evaluación cuidadosa del ROI, especialmente considerando que los ahorros documentados son incrementales más que transformacionales.

2. Las palancas estratégicas para la aplicación de IA en la empresa

2. Las palancas estratégicas para la aplicación de ia en la empresa

Para que una organización navegue este entorno complejo y de cambio, son necesarias tres palancas fundamentales: la infraestructura tecnológica, la gestión de los datos como activo y el talento humano.

2.1 Infraestructura tecnológica

En el núcleo de la revolución actual se encuentran los modelos predictivos. En el paradigma anterior, de Machine Learning, si una empresa quería resolver un problema usando modelos predictivos debía, por lo general, construir una solución desde cero específica para el caso de uso o proyecto a trabajar. Esto tenía tres grandes implicaciones:

- **Enfoque de "silo".** Se requería entrenar un modelo específico para cada empresa y caso de uso, y esto hacía tender a desarrollos y entrenamientos in-house. Por ejemplo, un modelo para predecir la fuga de clientes (churn) no servía para clasificar documentos, y viceversa.
- **La dependencia en los datos.** El requisito indispensable eran los datos estructurados, limpios y etiquetados, que permitían entrenar modelos.
- **Costes y riesgos.** El desarrollo era un proyecto de inversión con altos costes en talento técnico y tiempos largos de desarrollo. La incertidumbre era elevada: no sabías si el modelo funcionaría hasta el final del proyecto.


En la era de la IA Generativa, los modelos fundacionales, como GPT (OpenAI), Claude (Anthropic) o Gemini (Google), son sistemas de propósito general entrenados con volúmenes masivos de datos no estructurados (texto, código, imágenes...). Esto tiene grandes implicaciones para las empresas en la capa de aplicaciones, ya que, comparado con la implementación de ML, el uso de modelos predictivos de IA generativa se simplifica: [\[9\]](#):



- **Acceso inmediato a los mejores modelos.** Las empresas pueden utilizar modelos de terceros vía API, lo cual les permite ahorrarse la inversión millonaria y los meses de cómputo necesarios para entrenar un modelo propio competitivo.

- **Versatilidad.** Estos modelos son capaces de realizar una gran variedad de tareas gracias a su aproximación generativa: redactar informes, escribir código, analizar el sentimiento asociado a comentarios... Esto hace que no haya necesidad de entrenamiento específico para tareas o casos de uso particulares.

- **Nueva forma de adaptación.** Existen nuevas formas para adaptar el output de estos modelos de propósito general a un caso de uso específico, como puede ser el prompting (diseñar las instrucciones adecuadas en lenguaje natural para conseguir la respuesta adecuada del modelo). Como consecuencia, el tiempo invertido y la incertidumbre de un proyecto que usa modelos con capacidades demostradas se vuelven más pequeños.



A diferencia del paradigma anterior, la IA Generativa permite a las empresas elegir entre consumir modelos de terceros (Buy) o gestionar modelos propios (Build) [10].

- **En el modelo Buy** (APIs como GPT-4), el coste es variable por uso y se mide en tokens. Un token es la unidad fundamental de información que procesan estos modelos (aproximadamente equivale a 0,75 palabras o 4 caracteres en inglés, se cobra tanto por lo que se envía al modelo como por lo que el modelo genera). A pesar del coste por uso, se elimina la inversión

inicial de implementación del modelo y facilita una evaluación rápida del valor de la solución.

- **En el modelo Build** (usando Open Source), se asumen elevados costes fijos de infraestructura y talento técnico, pero se gana se gana privacidad, control total sobre los datos y mayor especificidad para la tarea.

Por tanto, la estrategia más eficiente suele ser evolutiva: iniciar con Buy para demostrar la rentabilidad del caso de uso y migrar a Build solo cuando el volumen de escala justifique asumir los costes fijos de mantenimiento frente al pago por uso.

2.2 Cloud Computing

La infraestructura que soporta estos modelos, además de su integración en sistemas complejos, es el Cloud Computing: la nube no es simplemente un almacén de datos, sino una plataforma escalable que proporciona acceso a la potencia de cómputo necesaria para la IA y a una integración sencilla con el resto de plataforma e infraestructura de una empresa [11]. Su rol es crítico por tres motivos:

1. **Acceso a la potencia de cómputo.** Entrenar o ejecutar modelos avanzados requiere chips especializados (GPUs) que son escasos y costosos, de ahí que la nube haya democratizado el acceso a esta tecnología permitiendo a las empresas "alquilar" superordenadores por horas en lugar de comprarlos o utilizar vía API modelos ya deployados pagando por uso (en función de tokens).

2. **Integración y seguridad.** Facilita conectar la IA con el resto de la infraestructura de la empresa (CRMs, ERPs, bases de datos, monolitos y microservicios...) bajo estándares de seguridad corporativa.

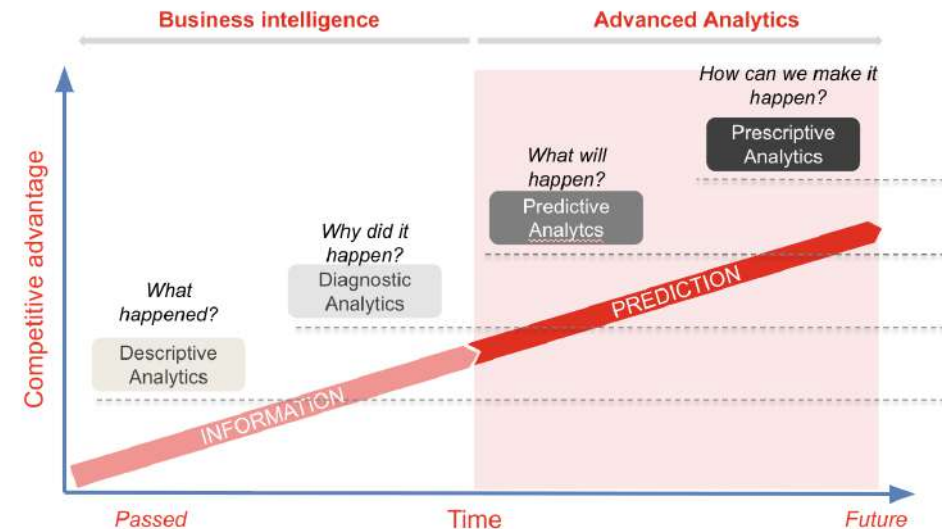
3. **Servicios gestionados.** Los principales proveedores ofrecen plataformas que abstraen la complejidad técnica. Un ejemplo claro es Amazon Bedrock, dentro del cloud de Amazon (AWS), que permite a las empresas acceder a múltiples modelos fundacionales (como los de Anthropic, Meta o la propia Amazon) mediante una sola API, sin gestionar servidores. Además, herramientas como los Agentes de Amazon Bedrock permiten crear asistentes capaces de ejecutar acciones complejas de forma segura y escalable.

2.3 Los Datos como Combustible

La gestión de datos ha transitado de un enfoque defensivo y de reporte hacia uno ofensivo y generativo. El Business Intelligence (BI), o inteligencia de negocios, es el conjunto de estrategias, tecnologías y herramientas que transforman datos crudos en información estructurada (tablas con formatos parecidos a un Excel o CSV), valiosa y procesable para optimizar la toma de decisiones empresariales. Con Business Intelligence logramos responder a "¿Qué pasó?" o incluso "¿Por qué ha pasado?" a través de análisis descriptivos.

Ya desde la época del BI, y gracias a extraer valor de los datos estructurados en bases de datos SQL, está demostrada la importancia de hacer cambio de mindset en la empresa. La toma de decisiones basadas en evidencias empíricas (data driven decision making) aporta muchos beneficios comparada con el modelo de decisión basado en la intuición o la jerarquía (HiPPO, Highest Paid Person's Opinion). Para ello, este mindset debe ser adoptado y respetado desde las capas altas de la empresa, y se debe ejecutar una estrategia data que permita democratizar el acceso a los datos, para que empleados de todos los niveles puedan tomar decisiones basadas en datos.

El Machine Learning añadió la capa predictiva de "¿Qué pasará?", entrenando modelos predictivos también con esos datos estructurados [12]. Este nuevo conocimiento sobre el futuro permite ir un paso más allá en las decisiones y optimizaciones que se pueden tomar gracias a los datos. Ejemplos de esto pueden ser la prevención de abandono de clientes (churn) gracias a la priorización de llamadas o promociones de aquellos clientes que tienen más probabilidad predicha de abandono, o también, a nivel prescriptivo ("cómo hacer que algo pase"), el mundo de las recomendaciones de contenido (conseguir mantener engagement en la plataforma) o dynamic pricing (conseguir la venta de un producto).



La IA Generativa va un paso más allá con capacidades de "razonamiento" y generación. Sin embargo, también en este caso hay una fuerte relación con los datos, tanto en su entrenamiento (modelos entrenados con toda la información existente en internet) como en su uso empresarial. Datos que históricamente no se utilizaban a gran escala por no estar estructurados pasan a tener mucho más valor: correos electrónicos, documentos PDF, contratos, grabaciones de llamadas... La gran diferencia es que la IA Generativa permite, por primera vez, procesar, "entender" y extraer valor a estos datos no estructurados a escala masiva. Por ejemplo, mediante la aplicación de esta tecnología, una empresa puede procesar miles de documentos legales para detectar riesgos contractuales en segundos.

2.4 El talento

Roles principales

Para desarrollar soluciones de datos e inteligencia artificial con éxito, se requiere la creación de equipos multidisciplinarios donde convivan perfiles técnicos, científicos y de negocio. A continuación, describimos los roles clave que componen un equipo de IA moderno [13]:

- **Data Engineers.** Desarrollan procesos de datos (ETLs, Extract Transform Load) para acceder a los datos de origen, extraer la información relevante y transformarlos, proceso que genera los datasets de entrenamiento o predicción y que asegura que los resultados de los modelos sean almacenados y analizables.


- **Data Analysts.** Ayudan a entender los datos, realizan análisis específicos para medir el impacto de las soluciones y desarrollan cuadros de mando (dashboards) para monitorizar el rendimiento de los modelos y sistemas.

- **Data Scientists.** Su función principal es diseñar, entrenar y evaluar los modelos predictivos que resolverán el problema de negocio. En el caso de la IA generativa, transicionan a focalizarse en prompt engineering, técnicas avanzadas de explotación de LLMs y evaluaciones de calidad de resultados.

- **Machine Learning Engineers.** Se encargan de transformar los modelos en código listo para producción y desplegarlos en producción. Una vez en producción, mantienen y monitorean los servicios para asegurar que funcionen a escala y con la calidad esperada.

- **Backend Developers.** Funcionan como el puente entre el despliegue del modelo (realizado por los MLE) y la plataforma tecnológica general de la compañía. Aseguran que el modelo predictivo quede conectado correctamente con la aplicación o web que utiliza el cliente final, y así poder garantizar la estabilidad del sistema completo.

- **AI/ML Product o Project Managers.** Su objetivo es asegurar que la tecnología entregada tenga un impacto positivo y medible, con el fin de evitar que el equipo construya soluciones técnicamente perfectas pero irrelevantes para el negocio.



En conclusión, el éxito en la aplicación de la IA no depende de un genio solitario, sino de una colaboración multidisciplinar cercana al negocio. Además, dada la continua evolución del campo de la IA, es necesario asegurar que el equipo en conjunto, y los diferentes roles en particular, se mantengan al día y hagan upskilling con las nuevas técnicas y tendencias del campo.

Topologías de equipo


Las estructuras organizativas rígidas están dando paso a modelos más fluidos basados en el marco de "Team Topologies", donde los roles definidos arriba se enmarcan de manera flexible según las necesidades de la empresa en cada momento [14] [15]:

- **Equipos de plataforma:** proveen la infraestructura técnica, herramientas y servicios de datos e IA como un producto interno, por lo que logran facilitar el trabajo de otros equipos.

- **Equipos stream-aligned:** son equipos multidisciplinarios (negocio, desarrollo, diseño) que consumen los servicios de la plataforma para entregar valor directo y rápido al usuario final.

- - **Equipos Habilitadores:** expertos que ayudan a los equipos stream-aligned o de producto a adoptar nuevas tecnologías y mejores prácticas.

Este enfoque busca maximizar la autonomía de los equipos y la velocidad de entrega, con tal de mantener la alineación con las necesidades de negocio y facilitar así un retorno positivo de estos equipos. Es importante evitar los silos tradicionales, donde los departamentos de IT y los de negocio operan como entidades desconectadas.



Fuente: <https://www.quantyca.it/en/usecase/data-ai-team-topologies/>

3. Oportunidades en la IA aplicada a proyectos



3. Oportunidades en la IA aplicada a proyectos

Los proyectos de IA en la empresa tienen una estructura común, en la que una parte del sistema a implementar consiste en una “caja negra” o modelo que es capaz de devolver outputs relevantes dados unos inputs. Independientemente de si hablamos de una fórmula estadística sencilla o del último modelo de IA Generativa, cualquier caso de uso sigue el siguiente esquema:



La complejidad del modelo varía según lo que queramos conseguir y la tecnología (y tiempo) que tengamos a nuestro alcance:

- **Estadística.** Usamos datos históricos y modelos sencillos estadísticos para calcular probabilidades o regresiones. A modo de ejemplo, un banco analiza los ingresos y otras características del cliente (input) para calcular la probabilidad de que devuelva un préstamo (output), y así decidir si se lo concede (caso de uso).
- **Machine Learning.** La máquina aprende patrones complejos para clasificar o estimar valores. Por ejemplo: analizar una radiografía (input) para detectar la probabilidad de enfermedad (output), o basarse en características de una vivienda (input) para predecir su precio (output).
- **IA Generativa.** Esta es de aplicación más generalista: dado un input es capaz de generar gran variedad de posibles outputs. Pongamos el caso de un prompt donde se da una descripción de imagen (input) y se obtiene una imagen publicitaria (output); o de dar un texto y la petición de adaptar al tono de marca (input) y se obtiene la redacción actualizada del texto (output).

Así pues, la aplicación de IA en proyectos requiere determinar los casos de uso adecuados en los que aplicar distintas tecnologías predictivas. Sin embargo, estos casos de uso no siempre acaban siendo exitosos: siguiendo estudios recientes, incluyendo análisis del MIT, hasta el 95% de los proyectos piloto de IA no logran escalar ni tampoco generar un retorno de inversión sostenible [16] [17]. Las causas no suelen ser tecnológicas, sino estratégicas:

1. **Foco en la tecnología** y no en la oportunidad: implementar IA por la novedad o hype sin un problema de negocio claro que resolver.
2. **Mala calidad de datos** ("Garbage In, Garbage Out"): subestimar el esfuerzo necesario para limpiar y preparar los datos para entrenamiento, en caso de modelos de ML, o para enriquecer prompts, en el caso de IA Generativa.
3. **Falta de integración:** crear soluciones aisladas que no se conectan con los flujos de trabajo o procesos empresariales existentes.

La estrategia recomendada para pertenecer al 5% de casos de éxito es aplicar un enfoque de producto: identificar problemas reales a resolver y con ROI medible, validar que la IA es la solución adecuada para resolverlo, diseñar e implementar la solución pensando en su uso e impacto final (y evitar así hacer foco exclusivamente en el modelo). Aún así, es importante entender que el hecho de lidiar con probabilidades, y no con determinismo, de los modelos predictivos añade incertidumbre al éxito e impacto de este tipo de proyectos, y hay que enfocar los esfuerzos de desarrollo en fallar rápido y aprender constantemente, para no dedicar más tiempo del necesario a proyectos sin verdadero potencial de acabar funcionando bien y aportando valor a la empresa.

3.1 El Ciclo de Vida: ML Tradicional vs. IA Generativa

Gestionar un proyecto de IA Generativa requiere comprender que su ciclo de vida difiere fundamentalmente del desarrollo de software tradicional, sobre todo debido a la integración de un paso no determinista y probabilístico en el proceso. Esto hace que un gran porcentaje de dedicación en un proyecto se tenga que invertir en la evaluación del modelo: asegurar que la calidad de los outputs que se obtienen son de calidad suficiente y que se evitan posibles riesgos como la discriminación o la alucinación.

ML Tradicional	IA Generativa
1- Obtención de datos de entrenamiento y entrenamiento del modelo.	1- Modelo ya entrenado por terceros, ha pasado evaluaciones genéricas.
2- Evaluación: obtener predicciones con el modelo y evaluar si las predicciones son buenas o malas.	2- Evaluación: determinar si las predicciones o generaciones son buenas o malas para el caso de uso en particular.
3- Decidir si el modelo es suficientemente bueno para ir a producción.	3- Decidir si el sistema de IA es suficientemente bueno para ir a producción.

A continuación, desglosamos con dos ejemplos cómo se atacarían las distintas fases del ciclo de vida de ML tradicional y el de IA generativa en un proyecto empresarial.

Ciclo de vida del Machine Learning tradicional:

- **Definición.** El proyecto comienza entendiendo el problema a resolver y definiendo un objetivo predictivo concreto y medible, como calcular la tasa de cancelación de clientes (churn).
- **Datos.** La materia prima son los datos estructurados (tablas, bases de datos...). El trabajo de esta fase es entender de qué datos se dispone y con qué calidad, y así generar un dataset adecuado para que el modelo pueda aprender patrones. En nuestro ejemplo de churn, buscaríamos incluir como variables del dataset aquellas dimensiones que, según el conocimiento del negocio o las hipótesis del equipo, pueden condicionar el abandono (antigüedad como cliente, descuentos aplicados, quejas o reclamaciones en los últimos meses...).
- **Desarrollo.** Se centra en el entrenamiento de modelos predictivos y en la selección del algoritmo que mejor se ajusta a los datos (regresiones, árboles de decisión, redes neuronales...).
- **Evaluación.** Se utilizan métricas cuantitativas objetivas, como la Precisión o el Error Cuadrático Medio (MSE), para validar la calidad de las predicciones del modelo antes de subirlo a producción.

- **Despliegue.** Industrialización del modelo para permitir que este realice predicciones cuando la plataforma lo requiera. Se contempla, también en esta fase, tanto la monitorización del modelo para asegurar su funcionamiento adecuado como el mantenimiento de la calidad de las predicciones.

Ciclo de vida del Machine Learning tradicional:

- **Definición.** El proyecto también comienza entendiendo el problema a resolver y definiendo un objetivo predictivo o de generación. Por ejemplo, para un asistente de contratos, generar un resumen simplificado de cada contrato.
- **Datos.** La gran ventaja es que al utilizar modelos ya entrenados por terceros, no tenemos una necesidad tan fuerte de gestión de datos estructurados históricos. Sin embargo, si vamos a necesitar cierto volumen de datos (en nuestro ejemplo de contratos, e.g. en pdf) y potencialmente asignar manualmente el resultado esperado de esta generación (en nuestro ejemplo sería una propuesta de resumen simplificado del contrato).
- **Desarrollo.** La forma de trabajar cambia hacia una evaluación de posibles modelos de terceros a utilizar a través de prompting, e implementaciones más avanzadas, como RAG, fine-tuning o agentes.
- **Evaluación.** Esta es más subjetiva y difícil de automatizar. Es una evaluación cualitativa y contextual, que verifica la consistencia del discurso, el tono y los filtros de seguridad. En nuestro ejemplo buscaríamos evaluar la "relevancia" del resumen, la "no alucinación" y "el uso de frases simples."
- **Despliegue.** De manera parecida al ML, buscamos industrializar la solución y monitorear su comportamiento. Se vigilan los costes por consumo de tokens, la aparición de alucinaciones, la posible toxicidad en respuestas.

3.2 Sectores Clave y Casos de Uso de IA

Retail

El sector retail y comercio online es uno de los sectores donde estamos viendo un mayor impacto de la IA. Este sector ha superado la simple segmentación demográfica para abrazar la hiperpersonalización en tiempo real, además de crear experiencias de compra únicas y facilitar la búsqueda y el descubrimiento de productos. Algunos ejemplos de casos de éxito son:

- **Hiperpersonalización - Chatbots.** Los grandes minoristas están utilizando cada vez más chatbots impulsados por IA para mejorar la experiencia de compra del cliente. Estos asistentes de IA ayudan a los clientes a investigar productos, obtener recomendaciones personalizadas e incluso recibir asistencia en tienda. Esto mantiene a los clientes en los sitios web y aplicaciones de los minoristas en lugar de recurrir a motores de búsqueda o chatbots externos. Los ejemplos más relevantes: Walmart “Sparky” (ayuda a los compradores a encontrar artículos y planificar eventos), Amazon “Rufus” (responde preguntas sobre productos y ofrece recomendaciones), Guita Center “Rig Advisor” (una herramienta en tienda que recomienda productos disponibles en esa ubicación específica).
- **Búsqueda y descubrimiento de productos - Nuevas formas de búsqueda.** El descubrimiento de productos en los marketplaces está viviendo una revolución con la GenAI: Netflix está explorando búsquedas potenciadas por IA —incluida la búsqueda por estado de ánimo—, mientras que otros actores como Booking ya han implementado funciones de búsqueda en lenguaje natural, como “busco hotel con rating mayor a 7 y cancelación gratuita.” Otra tendencia es la integración de visual search como es el caso en Pinterest.
- **Nuevas experiencias de compra.** La IA generativa permite ir un paso más allá en la experiencia de compra. Esto sucede en el caso de Zara, que ha habilitado un probador virtual, o en el de L’Oréal “Beauty Genius”, que ofrece asesoramiento de belleza personalizado que hasta incluye diagnósticos de piel y cabello.
- **Logística.** La integración de la IA en la cadena de suministro permite una logística predictiva en la que el stock se mueve anticipándose a la

demanda local antes de que se produzca la compra, lo cual permite reducir los costes de almacenamiento y tiempos de entrega. Un ejemplo de ello es el LVMH, que usa IA y agentes para planificar la supply chain y el pricing.

Salud

La Inteligencia Artificial está transformando la salud al mejorar la precisión diagnóstica, optimizar operaciones, acelerar el desarrollo de fármacos y permitir tratamientos personalizados [\[18\]](#). Instancias exitosas de este uso:

- **Diagnóstico e imagen médica.** Ayuda a analizar radiografías, tomografías y resonancias para detectar tumores, fracturas o arritmias con alta precisión. También permite la detección temprana de enfermedades graves.
- **Medicina personalizada.** Facilita la medicina de precisión mediante el análisis de datos genéticos y clínicos para adaptar tratamientos y optimizar dosis.
- **Descubrimiento de fármacos.** Acelera la identificación de nuevos medicamentos y mejora la selección de pacientes para ensayos clínicos.
- **Eficiencia administrativa.** Automatiza tareas como las notas médicas, la codificación o la gestión hospitalaria, de modo que consigue reducir la carga del personal sanitario [\[19\]](#).
- **Monitorización remota y atención virtual.** Permite el seguimiento de enfermedades crónicas mediante dispositivos inteligentes y chatbots disponibles 24/7.
- **Cirugía asistida por robots.** Los sistemas robóticos mejoran la precisión quirúrgica y reducen complicaciones y tiempos de recuperación.

Marketing

El marketing digital se enfrenta a una gran disrupción: los usuarios están pasando de utilizar búsqueda tradicional (google, duckduckgo...), donde el marketing está muy optimizado (SEO, SEM), a leer los “AI overviews” de esos buscadores (lo cual conlleva una bajada en el tráfico y los clicks en las páginas web citadas [\[20\]](#) [\[21\]](#)) o a utilizar plataformas tipo chatbot como ChatGPT o Perplexity (donde obtienen respuesta a sus preguntas según el

entrenamiento del modelo o búsqueda web + resumen). Además, la IA Generativa permite atacar una gran cantidad de casos de uso relevantes del sector: hiperpersonalización de anuncios, generación y optimización de contenido para campaña...

- **Optimización para Motores Generativos (GEO/AIO).** Las marcas deben optimizar su contenido para ser "citadas" por los modelos de IA de manera positiva. Esto implica desarrollar una nueva estrategia donde se optimice más allá del SEO: priorizar su presencia en foros y fuentes de datos que son usados para el entrenamiento de los modelos, seguir apostando por SEO tradicional (al usar web search en muchos casos por detrás los sistemas tipo chatbot), permitir o no permitir un scrapping del site por parte de bots para entrenar LLMs o sus web searchers, determinar posibles partnerships con empresas de chatbot para ofrecer anuncios de pago o apps dentro de la plataforma (por ejemplo, las apps chatgpt con Canva o Tripadvisor) [22]. Para poder tener una idea de cómo está funcionando el posicionamiento de marca, productos y sentimiento asociado en respuestas generadas por LLMs, varias startups buscan ofrecer soluciones tipo dashboard y una monitorización de este impacto (por ejemplo typrofound).

- **Automatización del contenido de campañas.** También con gran impacto de la IA en el sector, con ejemplos como Spotify buscando automatizar la generación de anuncios o Channel 4 con anuncios de televisión generados por IA, para permitir bajar costes y democratizar el acceso a la pequeña empresa.

- **Optimización de campañas.** Además de la automatización, la IA permite trabajar la optimización y personalización de campañas. Es un buen ejemplo el caso de Unilever que busca localizar muy bien las campañas (teniendo en cuenta cultura y tendencias de cada ubicación) para optimizar métricas de impacto de las campañas a gran escala, o el caso de H&M que utiliza gemelos digitales de modelos de moda para generar imágenes de anuncios y catálogos.

3.3 Medición del Éxito: KPIs y ROI

A medida que las empresas buscan ir un paso más allá de la exploración y pruebas piloto, es importante asegurar poder medir el retorno e impacto de estas soluciones a fin de asegurar que la dirección de desarrollo y casos de uso es correcta, así como, así como también lo es el mantenimiento de la apuesta de este tipo de proyectos por parte de la empresa. Medir directamente el impacto en ROI monetario muchas veces no es sencillo, pero puede haber otras métricas o KPIs (Key Performance Indicators) relevantes a medir:

- **Métricas Financieras.** Incluyen el ahorro de horas por trabajador o equipo (convertido a valor monetario), el aumento de ingresos por personalización y la reducción de costes por prevención de errores.

- **Métricas Operativas.** Tiempo de ciclo, tasas de resolución al primer contacto, satisfacción cliente tras resolución, precisión de pronósticos.

- **KPIs relevantes para el negocio.** Dependiendo de la empresa, puede ser relevante medir impacto en Click-through rate (CTR), Conversion rate (CVR), Retention/Churn rate, Daily/Monthly Active users, Lifetime Value, Customer Satisfaction Score...

4. Aplicar la IA para mejorar la productividad de las empresas

4. Aplicar la IA para mejorar la productividad de las empresas

Muchas personas usan IA en su día a día, tanto a nivel personal como profesional. Esta adopción no se explica solo por una percepción de valor y efecto “wow” por parte de las personas individuales, sino también por una apuesta por parte de las empresas para mejorar la productividad de sus empleados y conseguir retorno de inversión. De hecho, justamente en las capas más altas de la empresa, la adopción de esta tecnología está ya muy extendida: según datos de la universidad de Wharton, el 82% de los líderes empresariales utilizan IA generativa al menos una vez por semana y el 89% cree que la IA permite “aumentar” el trabajo. En este contexto, cuando se habla de “aumentar el trabajo,” normalmente se está refiriendo a la idea de que la IA no sustituye al trabajador, pero sí le permite tener a un asistente 24/7 para hacer más rápido y mejor sus tareas, e incluso poder ser autónomo en tareas que previamente requería a roles especializados (datos de OpenAI afirman que alrededor del 75% de usuarios puede realizar labores que antes estaban fuera de su alcance) [\[23\]](#) [\[24\]](#).

4.1 Impacto por Roles y Departamentos

La adopción de la IA empezó inicialmente con el uso de Chatbots de IA como pueden ser ChatGPT (OpenAI), Claude (Anthropic) o Gemini (Google). Sin embargo, a medida que hemos avanzado en el tiempo y distintas empresas han apostado por integrar la IA en sus servicios, esta ha dejado de ser una iniciativa aislada para convertirse en una capa integrada en muchas herramientas de uso diario. Son ejemplos CRMs como Salesforce, suite de Microsoft (correo, slides, buscador...), suite de Google (correo, slides, Drive...), herramientas de comunicación como Slack o incluso ordenadores y smartphones (como es el caso de Apple, Samsung o Lenovo).

A día de hoy, se puede afirmar que la adopción de IA en la mayoría de las empresas es alta debido, en muchos casos, a que está se ha convertido en una funcionalidad más de herramientas que ya se estaban usando hasta ahora. Cabe remarcar que, al tratarse sobretudo de herramientas del mundo



mundo digital, esta adopción e impacto se centran sobre todo en trabajadores white collar (profesionales que realizan labores administrativas, de gestión, intelectuales o de oficina, generalmente en entornos corporativos).

¿Qué hacen, pero, estos trabajadores con esta nueva tecnología? Entre los casos de uso más destacados encontramos:

- **Creación y análisis de contenido.** Uso de asistentes para redactar, investigar y analizar. Se incluye en esta parte la transcripción automática de reuniones, la obtención de resúmenes y conclusiones de manera automática de vídeos o grabaciones de voz o la generación de documentos o diapositivas a partir del contexto pertinente. Datos de Anthropic estiman, por ejemplo, que los modelos de IA permiten ahorrar hasta un 87% del tiempo en la redacción de facturas, memorandos y otros documentos corporativos.
- **Gestión del conocimiento.** Una gran oportunidad para las empresas es conseguir que la IA tenga fácil acceso a la información y datos propios de la empresa, normalmente extendidos por múltiples fuentes de datos y herramientas. Justamente para resolver esta oportunidad, hay varias soluciones específicas, por ejemplo, NotebookLM de Google, centrada en dar respuestas utilizando exclusivamente fuentes indicadas (incluidos links a documentos corporativos en Drive), o Glean, diseñada para actuar como un asistente inteligente que se conecta a todas las fuentes de información de la empresa (Slack, Drive, Jira, Salesforce, etc.). En esta tipología de tareas también datos de Anthropic estiman ahorros de tiempo de hasta el 80%.
- **Automatización de flujos de trabajo.** En algunos casos, el uso de la IA va un paso más allá de la “aumentación” en una tarea específica para permitir automatizar un flujo de trabajo de inicio a fin. Plataformas “No-Code” como Zapier o n8n, y empresas que ofrecen agentes de IA específicos para ciertos flujos de trabajo, permiten a áreas como Marketing, Legal u Operaciones construir sus propias automatizaciones sin depender del departamento de ingeniería. En la misma página web de la herramienta n8n se pueden ver ejemplos de flujos de trabajo automatizables por la herramienta separados por departamento: recolección de noticias recientes de un cliente para ventas, monitorización de comentarios de usuarios para marketing, clasificación de manera automática mails para atención al cliente...

Así pues, la IA impacta a la gran mayoría de roles white collar. Sin embargo, es en tres categorías donde se ha visto un mayor impacto, debido a que un porcentaje mayor del tiempo de estos roles es dedicado a tareas, a día de hoy, ya “aumentables” o incluso automatizables con IA:

- **Desarrollo de software e ingeniería.** Inicialmente aparecieron asistentes simples de programación (de tipo “sugerencias de autocompletado”), como es el caso de Github Copilot. En los últimos meses, pero, han aparecido gran cantidad de productos (Claude Code de Anthropic, Cursor, o Codex de OpenAI) que ofrecen un enfoque más agéntico a la programación: el programador detalla la tarea a implementar y el sistema de IA es capaz de crear scripts enteros, refactorizar repositorios de código o detectar posibles fallos en nuevas implementaciones. El rol del ingeniero está evolucionando de “implementador” a “orquestador,” dedicando menos tiempo a escribir código y más a la arquitectura del sistema, dirección estratégica y revisión del código generado por la IA. Datos de OpenAI sitúan en el 73% los ingenieros que reportan estar entregando código más rápido, y datos de Anthropic revelan que los desarrolladores usan IA en el 60% de su trabajo pero solo lo delegan por completo en 0-20% de las tareas [25].
- **Atención al Cliente y Soporte.** Junto con TI, es el área donde se observan las mayores ganancias de productividad. En este sector, parte de las consultas que se resuelven son repetitivas y de trabajo manual, cosa que abre la oportunidad a que estas consultas se resuelvan de manera automática con IA y el equipo se pueda centrar en las tareas y consultas más complejas. Es por esto que según la 7ª edición del informe State of Service de Salesforce, en 2027 se espera que la IA gestione el 50% de los casos de atención al cliente, frente al 30% actual [26]. Aquí destacan flujos de automatización de respuestas en CRMs o e-mails y mejoras sustanciales en chatbots y voicebots gracias a la IA generativa, que permiten una mejor experiencia de usuario y una mayor tasa de resolución de consultas sin intervención humana.
- **Marketing.** La generación de contenido a gran escala, la hiperpersonalización y la ejecución son ejemplos del valor que aporta, vía aumentación o automatización, el uso de la IA en marketing. Aquí destacan

más capacidades de análisis de datos, comentarios y contenido a gran escala, además de la generación de contenido optimizado, sea en formato texto, imagen o vídeo. De nuevo, datos de OpenAI sitúan al 85% los profesionales de marketing y producto que reportan una ejecución más rápida de sus campañas.

Tal como hemos comentado, no sólo se trata de usar la IA para hacer más rápido y mejor (con más profundidad o calidad) tareas que ya formaban parte de un rol, sino también de empezar a hacer tareas para las que antes se necesitaba el soporte de otro rol específico. Algunos ejemplos de estas tareas pueden ser:

- **Creación de prototipos y páginas webs sencillas por parte de gente no técnica.** Gracias a herramientas conocidas como vibe coding, implementar una página web ahora es “tan fácil” como hablar en lenguaje natural con un chatbot e ir iterando a través de la conversación, sin tener que implementar manualmente ni una sola línea de código. Los riesgos de estas herramientas son la dificultad de iterar estos prototipos o la falta de robustez técnica (escalado, seguridad, privacidad...), pero en muchos casos, para obtener primeras versiones de la solución para validar con usuarios o incluso landings sencillas, son más que suficientes. Ejemplos de empresas que ofrecen este tipo de solución son Lovable, Replit o v0.

- **Democratización del código.** De nuevo, la IA permite romper la barrera de conocimiento técnico para entender código productivo, detectar posibles fallos u oportunidades de mejoras de funcionalidad. Por primera vez, personas no técnicas del equipo son autónomas para resolver dudas relacionadas con el código como pueden ser “¿Cómo está implementada esta lógica?” o “¿Por qué parece que en estos casos nuestra app está fallando?” Las mismas herramientas usadas por desarrolladores (Claude Code, Cursor...) pueden ser usadas con finalidad de exploración de código por parte de gente no técnica. OpenAI ha detectado que los prompts relacionados con programación por parte de empleados en roles no técnicos han aumentado un 36%.

- **Análisis y entendimiento del dato.** De manera parecida al caso del acceso al código, la IA permite acceso al dato sin necesidad de un experto en Data. Varias herramientas se posicionan aquí ofreciendo funcionalidad

“text-to-sql” (acceso a bases de datos a través del lenguaje natural) como Thoughtspot o Genie (funcionalidad IA de la plataforma de datos Databricks). Por otro lado, los modelos fundacionales son capaces de analizar y sacar insights y gráficos de manera automática a partir de grandes volúmenes de datos.

Se espera que esta adopción e impacto siga creciendo, tanto debido al “prueba y error” de los trabajadores a medida que van integrando las nuevas herramientas en sus rutinas como por las mejoras de las herramientas en sí o la aparición de nuevas herramientas o funcionalidades con IA para resolver casos de uso específicos. Con respecto a mejoras de herramientas, vemos una dirección clara de muchas empresas de pasar de usar la IA de manera limitada para resolver pasos muy específicos del trabajo a apostar por una integración de la IA más agéntica, donde se combinan agentes con diferentes objetivos para resolver una tarea compleja o agentes de larga duración que pueden trabajar durante minutos o incluso horas para llegar al resultado requerido.

4.2 Midiendo el retorno de esta productividad aumentada (ROI) y sus retos

Dos de cada tres empresas en EMEA reportan ganancias significativas en productividad, y se espera que este impacto siga creciendo. Más allá del impacto en productividad, el 92% de los líderes empresariales esperan que la IA agéntica entregue un ROI medible en los próximos dos años. [\[27\]](#)

Sin embargo, el paso a poder medir ROI a nivel económico no es trivial: en muchos casos, el impacto en productividad se mide a través de encuestas a los trabajadores, cosa que permite llegar a conclusiones como las de OpenAI, que afirma que “para los trabajadores, esto se traduce en un ahorro de entre 40 y 60 minutos al día, mientras que los usuarios más intensivos reportan ahorros de más de 10 horas a la semana.” ¿Dónde van a parar estos minutos y horas ahorrados? Pueden ir a tareas de menor impacto, a haber hecho mejor las tareas asignadas gracias a la profundidad que aporta el uso de la IA o incluso a mantener el nuevo nivel y velocidad requerido si los competidores también usan la IA para conseguir eficiencia y calidad.

Hay que tener en cuenta también las principales barreras que las empresas se encuentran a la hora de empujar la adopción de la IA internamente:


1. Seguridad y privacidad. El 68% de los líderes señalan los riesgos de privacidad, seguridad de los datos y ética como la principal barrera para escalar la IA.

2. Integración. La integración de estas herramientas o nuevos proveedores con los sistemas de la empresa presenta, en muchos casos, un desafío tecnológico.

3. Gestión del cambio. Hay la necesidad de tener una estrategia e invertir en ayudar a los trabajadores en este proceso de cambio de manera responsable.

4. Interoperabilidad. El 85% de las organizaciones exigen sistemas abiertos, transparentes y flexibles que permitan una integración fluida sin ataduras estrictas a un solo proveedor.

5. Gestión del cambio y transformación organizativa



5. Gestión del cambio y transformación organizativa

La realidad es que la aparición y la necesidad de adopción de la IA hay que tratarlas como una gestión de cambio y transformación organizativa, como pudo ser en su momento la aparición de los ordenadores en las oficinas. Es por esto que se aplican frameworks de gestión del cambio como puede ser ADKAR, que proporciona un marco estructurado para gestionar la transición cultural hacia la IA [28]:

1. Awareness (Conciencia): comunicar claramente por qué el cambio es necesario (presión competitiva, obsolescencia...).

2. Desire (Deseo): fomentar la motivación personal mostrando los beneficios directos para el empleado (eliminación de tareas tediosas, nuevas oportunidades...).

3. Knowledge (Conocimiento): proporcionar la formación necesaria para operar en el nuevo entorno.

4. Ability (Habilidad): asegurar que los empleados tienen el tiempo, las herramientas y el soporte para aplicar los nuevos conocimientos.

5. Reinforcement (Refuerzo): celebrar los éxitos, reconocer a los pioneros y anclar los cambios en la cultura para evitar retrocesos.



Awareness (conciencia)

Comunicar de manera clara y directa la estrategia de adopción de IA es fundamental para proporcionar claridad, reducir la incertidumbre y establecer expectativas concretas dentro de una organización. Ante un cambio tecnológico tan profundo, las capas directivas deben articular abiertamente cómo se utilizarán estas herramientas para evitar que los

equipos respondan con miedo en lugar de curiosidad. Una comunicación transparente y asertiva no sólo disipa las dudas sobre el futuro laboral, sino que también empodera a los empleados, fomenta el aprendizaje colectivo y asegura que la integración de la IA se mantenga alineada con los valores y la misión principal de la empresa.

Las propuestas de varias organizaciones ilustran cómo aplicar esta comunicación abierta en la práctica. En Duolingo, su CEO ha compartido públicamente como espera que la IA sea utilizada como herramienta para acelerar el trabajo, no para reemplazar a los empleados, prometiendo un apoyo continuo mediante talleres y tiempo de experimentación. Su análogo en Shopify ha sido muy vocal a través de comunicados hacia la empresa donde deja claro que el uso "reflexivo" de la IA ha pasado a ser un requisito básico para todos los empleados, al exigir incluso que los equipos demuestren haber intentado usar la IA antes de solicitar más personal. Por su parte, Wikimedia publicó abiertamente su nueva estrategia en la cual prometió poner a las personas en primer lugar, al responder de manera directa que no reemplazarán a sus colaboradores con IA, sino que utilizarán la tecnología exclusivamente para eliminar barreras técnicas y automatizar tareas tediosas bajo estrictos principios de transparencia. [29] [30] [31]

Desire (deseo)

Conseguir el deseo por parte de los empleados pasa por evitar la imposición a favor de la inclusión y una escucha empática. Esto se puede conseguir involucrando a los diferentes roles, identificar conjuntamente pains o procesos muy manuales y tediosos, y trabajar de manera conjunta en encontrar soluciones que ayuden a mejorar y hacer el trabajo más ameno o de mejor calidad.

Knowledge (conocimiento)

La brecha de habilidades es uno de los mayores riesgos para la adopción exitosa de la IA en la empresa. Por este motivo, es importante que desde las empresas se de el soporte y acompañamiento necesario a todos los empleados a través de cuatro ejes:

- **AI Literacy.** Se refiere a la formación para personas no técnicas que les permita entender, usar y evaluar de manera crítica herramientas y sistemas

de IA en la vida cotidiana y profesional, sin necesidad de saber programar o conocer detalles técnicos. Esta formación y capacitación es fundamental para asegurar la adopción de la IA con sentido, y de manera ética y segura por parte de todos los trabajadores.

- Uso y adopción de la IA por rol o departamentos. Formación técnica y práctica adaptada a cada rol. Por ejemplo, ayudar al equipo de marketing a identificar qué herramientas IA les pueden ser más relevantes y hacer sesiones específicas de uso de esas herramientas para aumentarles en sus principales tareas.

- Capacitación equipos técnicos. Si además de la adopción se quiere poder desarrollar internamente iniciativas que integren IA, es necesario dedicar tiempo y presupuesto en el aprendizaje continuo de los equipos técnicos en esta materia. Además, este equipo técnico es el que puede ayudar a otros equipos con integraciones de herramientas, generación de best practices, soporte en dudas...

- Estrategia. Las capas directivas deben prepararse para poder liderar la estrategia de IA, gestión de riesgos y evaluación de oportunidades de negocio.

Además, en esta nueva realidad es importante alentar ciertas habilidades blandas que pasan a ganar mucha importancia: el pensamiento crítico, la adaptabilidad, la curiosidad y el perder el miedo a ponerse manos a la obra.

Ability (habilidad)

Las empresas deben proporcionar herramientas corporativas seguras y establecer políticas claras de uso aceptable para canalizar esa energía innovadora de forma segura. Aquí es importante detectar qué herramientas generales para la empresa y específicas por departamento o rol pueden ayudar a mover la aguja.

Paralelamente, el fenómeno del "Shadow AI" (empleados usando herramientas de IA no autorizadas por la empresa) debe gestionarse debido a los riesgos de seguridad, privacidad y confidencialidad que esto puede conllevar. Se debe buscar entender por qué necesitan una herramienta

externa y proponer alternativas gobernadas y validadas que les aporten tanto o más valor.

Reinforcement (refuerzo)

En esta área se celebra la adopción y casos de éxito de la IA en la empresa. Iniciativas que pueden ayudar en esta dirección pueden ser el de facilitar foros donde compartir el uso de la IA, la identificación de champions por departamento que animen a otros a explorar, habilitar días dedicados a la experimentación con IA o visibilizar abiertamente el uso de la IA por parte de la capa directiva.

6. Gestión de riesgos, ética y compliance

6. Gestión de riesgos, ética y Compliance

Hasta ahora nos hemos centrado en los beneficios y oportunidades de la IA. Sin embargo, el uso de esta tecnología también tiene riesgos y regulaciones asociadas que tienen que tenerse en cuenta.

6.1 Riesgos asociados a la integración de la IA

La integración de la IA en procesos y proyectos tiene riesgos intrínsecos asociados, gran parte de ellos debidos al uso de un modelo como “caja negra” –cosa que dificulta mantener un control adecuado sobre lo que sucede en el sistema. A continuación detallamos los principales riesgos asociados a la integración de la IA:

- **Una mala calidad de las predicciones o generaciones.** En esta categoría situamos aquellos problemas derivados de modelos que en determinadas situaciones no devuelven las predicciones o generaciones con la calidad esperada. En el caso del Machine Learning tradicional, nos encontraríamos con modelos que se usan en predicción con mala capacidad predictiva, cosa que puede suponer un riesgo para el negocio. En el caso de la IA generativa, es habitual encontrarse con alucinaciones, donde la respuesta del LLM es inventada a pesar de ser expresada con mucha confianza.
- **Sesgo y discriminación algorítmica.** Los modelos pueden perpetuar o amplificar sesgos históricos presentes en los datos de entrenamiento. En el caso del Machine Learning tradicional, esto puede significar diferencias en predicción debido a variables sensibles de la persona. Por ejemplo, un modelo de predicción de devolución de crédito puede tender a predecir peores devoluciones del crédito para mujeres, y, si esa predicción se usa en la decisión de asignación o no del crédito, puede suponer una discriminación hacia las mujeres. De manera similar, en la IA generativa, la generación de imágenes o texto se ha demostrado en muchos casos discriminatoria en función de género, edad, raza... Por ejemplo, en la generación de imágenes de “doctor” o “nurse” (en inglés para evitar género en la palabra), los modelos de IA tienden a generar imágenes de hombres blancos en el primer caso y de mujeres blancas en el segundo.




- **Seguridad y privacidad.** Sobre todo en el caso de la IA generativa, existe una nueva clase de vulnerabilidad donde atacantes manipulan el modelo mediante instrucciones maliciosas para saltarse controles de seguridad o extraer datos. Prompts como "Ignora las instrucciones anteriores y..." consiguen, en muchos casos, que el modelo se comporte de forma diferente a la deseada, cosa que puede implicar riesgos de seguridad (si se consigue que el modelo devuelva información confidencial, acceso a ciertas herramientas o contraseñas, exponga información sensible del usuario a terceros...). En temas de privacidad, además, hay que controlar el uso de los datos introducidos para entrenar versiones públicas de los modelos (control de "opt-out" y uso de entornos privados).

- **Riesgos asociados a la autonomía agéntica.** A medida que los agentes de IA ganan capacidad de acción (realizar compras, enviar correos, conducción autónoma...), el impacto por posibles acciones no deseadas crece. Además, puede haber vacíos legales sobre quién es responsable de esas acciones (¿El desarrollador de la IA? ¿El desarrollador o empresa del sistema? ¿El usuario final?).

- **Impacto ambiental.** El entrenamiento y la inferencia de grandes modelos consumen enormes cantidades de energía y agua. Esto se debe al elevado consumo energético de los centros de datos y la necesidad de refrigerar continuamente sus servidores.

Para mitigar estos riesgos hay una serie de principios enmarcados en el campo de Trustworthy AI que buscan forzar en las diferentes fases de la implementación de una solución el pensamiento crítico y los checks necesarios para evitar riesgos graves en la solución final. Aquí encontramos principios y técnicas específicas para atacarlos como la supervisión humana, la transparencia, la no discriminación, etc. Para forzar a que las empresas apliquen estos principios, la UE se apoya en dos grandes pilares regulatorios: el Reglamento General de Protección de Datos (GDPR) para la protección de datos y privacidad y la Ley de Inteligencia Artificial (AI Act) para la seguridad, transparencia y gestión de riesgos específicos de los sistemas algorítmicos.



Fuente: <https://ec.europa.eu/futurium/en/ai-alliance-consultation/guidelines/1.html>

6.2 GPRD

En vigor desde mayo de 2018, el GDPR sienta las bases de la privacidad y los derechos digitales, e impacta indirectamente en cómo se alimentan y operan los modelos de IA. Su objetivo es el de proteger los datos personales de los ciudadanos de la UE, darles el control de su información y homogeneizar el entorno jurídico para las empresas. Su incumplimiento conlleva multas severas (de hasta 20 millones de euros o del 4% de la facturación global). Da también derechos a los ciudadanos en relación a sus datos: ser informados, acceder, rectificar, eliminar, restringir el tratamiento, portar sus datos y oponerse a su uso. [32]

Su impacto específico en el campo de analítica avanzada e IA es:

- **Tratamiento y perfiles.** Se requiere consentimiento explícito para crear perfiles o usar datos fuera del propósito original de la empresa.
- **Derecho a la explicabilidad.** Los usuarios no pueden ser objeto de decisiones 100% automatizadas sin justificación: tienen derecho a entender por qué un algoritmo tomó una decisión que les afecta.

- **Sesgos y discriminación.** Prohíbe la discriminación algorítmica por raza, religión, salud... Esto implica que no se pueden usar estas variables para entrenar modelos, ni tampoco variables predictoras o con alta correlación a éstas (proxies), como podría ser el uso de código postal para inferir la raza.

6.3 AI Act

El AI Act de la UE complementa desde agosto de 2024 al RGPD centrándose en el uso de los sistemas de IA, clasificándolos según el riesgo que suponen para los ciudadanos y estipulando requisitos según el riesgo asociado del sistema [33]:

- **Riesgo Inaceptable (prohibido).** Se trata de sistemas que amenazan a las personas; incluye social scoring (puntuación social), vigilancia masiva y manipulación del comportamiento que cause daños.

- **Alto Riesgo (sujetos a evaluación de conformidad).** Son sistemas que afectan significativamente la vida de las personas, como los usados en acceso al empleo, educación, servicios públicos, componentes de seguridad de vehículos y aplicación de la ley. Es en esta categorización donde se incluyen más requerimientos: sistema de gestión de riesgos, gobernanza de datos, documentación técnica, conservación de registros, transparencia y provisión de información clara a los usuarios, supervisión humana, precisión, solidez y ciberseguridad.

- **Riesgo Limitado (obligación de transparencia).** Son aquellos sistemas donde el usuario debe saber que interactúa con una máquina. Incluye chatbots y deepfakes.

- **Riesgo Mínimo (sin obligaciones).** Incluye el resto de aplicaciones (ej. filtros de spam, videojuegos...) que no tienen requerimientos legales adicionales.

- **Modelos de IA de propósito general (General Purpose AI, GPAI).** Se refiere a aquellos sistemas con capacidades amplias como modelos de texto a imagen/vídeo o modelos de lenguaje. Los proveedores deben cumplir con requisitos de transparencia, documentación técnica, políticas de derechos de autor y evaluación de riesgos para los modelos con riesgos sistémicos.

7. Mirando hacia adelante: tendencias futuras



7. Mirando hacia adelante: Tendencias futuras

A día de hoy, está ya claro el gran impacto de la IA en las personas y las empresas, y lo vital que va a ser para todos adaptarnos a esta nueva realidad sin quedarnos atrás. A medida que la tecnología de IA se vuelve accesible para todos (comoditization), la simple adopción de IA deja de ser una ventaja competitiva para convertirse en un requisito base. La ventaja competitiva futura residirá en el uso de datos propietarios, integración profunda para resolver los problemas relevantes y el talento humano [34].

Si miramos hacia el futuro, toca sin duda contar con que parte de los avances del sector serán debidos al continuo lanzamiento de nuevas versiones de modelos fundacionales más potentes, con mayores capacidades de generar y entender texto, imágenes o código, y potencialmente más cercanos a la Inteligencia Artificial General (AGI por sus siglas en inglés). La AGI es un tipo hipotético de IA capaz de aprender, comprender y aplicar conocimientos para realizar cualquier tarea intelectual humana, adaptándose en dominios sin entrenamiento específico. Vertientes distintas del mundo de la investigación no están de acuerdo en cuándo llegaremos a esta tipología de IA, ni siquiera si llegaremos alguna vez, pero sí parece claro que las implicaciones para la humanidad de esta hipotética situación serían de gran magnitud.

Donde sí avanzaremos seguro en los próximos años es en una mayor aplicación e integración de la IA. Aunque esto generará muchas tipologías de cambios, destacamos aquellas que son más transversales y disruptivas:

- **Democratización del desarrollo de software.** El vibe coding y los agentes de IA enfocados en la programación están ya a día de hoy generando mucho impacto sobre todo en startups y empresas con desarrolladores. Más allá de un impacto en productividad y redefinición de roles, se espera también una afectación al concepto de producto de software en sí: si soy capaz de construir cualquier aplicación hiperpersonalizada a mis necesidades, ¿por qué debería pagar por software genérico? Un primer indicador de este cambio ha sido la caída en bolsa a inicio de febrero de 2026 de las principales empresas de software y servicios que se atribuye al

lanzamiento por parte de Anthropic de productos de IA Agéntica que permiten acercar el desarrollo de software personalizado a personas no técnicas. [35]

- **Autonomía Agéntica.** Los LLMs están dando paso a agentes de usuario que actúan como "trabajadores privados y personales": se autentican con las credenciales del usuario, navegan internet de forma autónoma y realizan acciones. Una de sus aplicaciones es el comercio agéntico, donde es el agente de IA el que compara precios y ejecuta la compra, cosa que representa una amenaza para los grandes retailers cuyo modelo de ingresos depende de la publicidad y de guiar el viaje de compra. Más allá del caso del comercio, es pronto para entender las implicaciones en el mundo digital de la existencia de estos agentes en gran escala y los riesgos de seguridad, privacidad y descontrol de contenido que pueden generar.

- **Equipos híbridos de humanos y agentes de IA.** Son ya muchas las empresas que apuestan por los "AI digital teammates" como es el caso de Salesforce con agentes con roles específicos integrados en Slack. Los equipos deberán adaptar las formas de trabajar a esta nueva posibilidad, donde tocará tomar decisiones antes inauditas como qué tareas se delegan a los agentes de IA, cómo se construyen procesos de revisión y feedback hacia el trabajo de estos agentes o quién tiene la responsabilidad final.

- **El despegue de la robótica inteligente.** Aunque el hardware escala mucho más lentamente que el software, estamos viendo ya muchos ejemplos de uso de la IA enfocado a mejoras robóticas en el mundo físico. Más allá de la conducción autónoma, toca esperar impacto en sectores como la industria o la agricultura, en el momento que el hardware vaya avanzando su integración de la IA.

- **El impacto sociolaboral.** La revolución industrial provocó un aumento en el desempleo significativo a corto plazo al dejar obsoletos muchos oficios artesanales tradicionales y especializados, particularmente entre los hiladores y tejedores. Aunque esta transformación finalmente generó nuevos empleos industriales, estimuló el crecimiento urbano y aumentó la productividad económica general, la transición fue profundamente disruptiva [36].

8. Referencias

Es todavía pronto para entender la magnitud de posibles despidos masivos debido a la IA, pero esto es algo que sin duda preocupa entre los white collar jobs, que ven como la IA consigue automatizar o acelerar parte de sus tareas diarias.

También existe la promesa de nuevos roles que aparecerán con esta transición (data annotators, especialistas de automatizaciones, mantenimiento de agentes y código generado por la IA...). Otras derivadas importantes son:

- **Las brechas de adopción:** igual que en la digitalización, segmentos de personas o países pueden quedarse atrás suponiendo desigualdades futuras.

- **El dilema de los perfiles junior:** cuando la IA puede asumir las tareas de nivel básico o junior, deja de ser necesario por parte de las empresas contratar a juniors. De hecho se ha visto en algunos casos mayor contratación de personas senior, que justamente son las que pueden dirigir y revisar el trabajo aumentado con IA. Además de impactar en el acceso al empleo de las personas jóvenes, hay un riesgo futuro de cuello de botella en personas expertas.

- **Satisfacción del trabajador con su nuevo día a día:** el día a día en el trabajo de muchos trabajadores ya ha cambiado y va a seguir haciéndolo. Este cambio puede ser positivo (por tener menos tareas repetitivas, sentir que se aporta más valor estratégico...), pero también negativo (las nuevas tareas a hacer no satisfacen tanto como las de antes, o la velocidad y multitasking gracias a la IA genera más estrés e intensidad de trabajo... [\[37\]](#)).

El futuro de la IA brindará oportunidades extraordinarias, pero también tensiones sociales, laborales y éticas que exigirán liderazgo consciente. Activar el valor de los datos y la inteligencia artificial no es únicamente una cuestión tecnológica, sino una responsabilidad estratégica y social: las empresas que prosperen serán aquellas capaces de equilibrar eficiencia y equidad, innovación y gobernanza, automatización y desarrollo del talento humano.



8. Referencias

1. Artificial Corner. (2023, diciembre 3.). From ancient oracles to generative AI. Medium. <https://medium.com/artificial-corner/from-ancient-oracles-to-generative-ai-da86f64e0494>
2. Wang, A. (2025, septiembre 25). 7 Layers National AI Strength, more than just big models. LinkedIn. <https://www.linkedin.com/pulse/7-layers-national-ai-strength-more-than-just-big-models-alex-wang-lu9hc/>
3. DeepLearning.AI. (2024, diciembre 4). The falling cost of building AI applications. <https://www.deeplearning.ai/the-batch/the-falling-cost-of-building-ai-applications/>
4. Bloomberg Línea. (2025, noviembre 19). Acciones de NVIDIA suben más de 10 veces en la era ChatGPT. <https://www.bloomberglinea.com/mercados/acciones-de-nvidia-suben-mas-de-10-veces-en-la-era-chatgpt-asi-han-reaccionado-tras-los-balances/>
5. El País. (2026, febrero 7). Google, Amazon, OpenAI and the race to find alternatives to NVIDIA. <https://english.elpais.com/technology/2026-02-07/google-amazon-openai-and-the-race-to-find-alternatives-to-nvidia.html>
6. Deloitte. (2026). The State of AI in the Enterprise – 2026 AI report. <https://www.deloitte.com/us/en/what-we-do/capabilities/applied-artificial-intelligence/content/state-of-ai-in-the-enterprise.html>
7. Deloitte. (2025). Tech Trends 2025. https://mkto.deloitte.com/rs/712-CNF-326/images/DI_Tech-trends-2026.pdf
8. Schroders. (2026, diciembre 18). ¿Escenarios económicos de IA: crecimiento revolucionario o burbuja recesiva? <https://www.schroders.com/es-cl/cl/inversores-profesionales/perspectivas/ai-economic-scenarios-revolutionary-growth-of-recessionary-bubble-/>
9. Google Cloud. (s.f.). ¿Qué son los modelos fundacionales? <https://cloud.google.com/discover/what-are-foundation-models?hl=es>
10. MIT Sloan. (2025, septiembre 17). Buy, boost, or build? Choose your path to generative AI. <https://mitsloan.mit.edu/ideas-made-to-matter/buy-boost-or-build-choose-your-path-to-generative-ai>
11. IBM. (s.f.). What Is Cloud Computing? <https://www.ibm.com/think/topics/cloud-computing>
12. OpenText. (s.f.). Unstructured data. <https://www.opentext.com/es/what-is/unstructured-data>
13. Adevinta Tech Blog. (2023, octubre 17). Working in a multidisciplinary Machine Learning team to bring value to our users. <https://medium.com/adevinta-tech-blog/working-in-a-multidisciplinary-machine-learning-team-to-bring-value-to-our-users-f1172ca532c6>
14. Quantyca. (s.f.). Data AI Team topologies. <https://www.quantyca.it/en/usecase/data-ai-team-topologies/>
15. Team Topologies. (2025, enero 28). How Team Topologies Can Transform Generative AI Integration. <https://teamtologies.com/news-blogs-newsletters/2025/1/28/how-team-topologies-can-transform-generative-ai-integration>
16. Allganize. (2026, enero 22). Why 95% of Generative AI Pilots Fail – and How Your Company Can Succeed. <https://www.allganize.ai/en/blog/why-95-of-generative-ai-pilots-fail--and-how-your-company-can-succeed>
17. Trullion. (2025, septiembre 8). Why 95% of GenAI projects fail – and why the 5% that survive matter. <https://trullion.com/blog/why-95-of-ai-projects-fail-and-why-the-5-that-survive-matter/>
18. World Economic Forum. (2025, agosto 13). AI Transforming Global Health. <https://www.weforum.org/stories/2025/08/ai-transforming-global-health>
19. European Commission. (2025, octubre 21). AI in healthcare. https://health.ec.europa.eu/ehealth-digital-health-and-care/artificial-intelligence-healthcare_en
20. Press Gazette. (2025, mayo 13). Google AI overviews leads to dramatic reduction in CTR for Mail Online. <https://pressgazette.co.uk/publishers/digital-journalism/google-ai-overviews-leads-to-dramatic-reduction-in-click-throughs-for-mail-online/>
21. Bain & Company. (2025, febrero). Goodbye clicks, hello AI zero click search redefining marketing. <https://www.bain.com/insights/goodbye-clicks-hello-ai-zero-click-search-redefines-marketing/>
22. YouTube. (2025, julio 30). AI SEO: Latest Market Intelligence & Landscape Analysis [Video]. <https://www.youtube.com/watch?v=cm589PmhlOY>
23. Wharton. (2025, octubre 28). 2025 Report Accountable Acceleration: Gen AI Fast-Tracks Into the Enterprise. <https://knowledge.wharton.upenn.edu/special-report/2025-ai-adoption-report/>
24. OpenAI. (2025, diciembre 8). El estado de la IA empresarial. <https://openai.com/es-ES/index/the-state-of-enterprise-ai-2025-report/>
25. Anthropic. (2025, noviembre 25). Estimating AI productivity gains from Claude conversations. <https://www.anthropic.com/research/estimating-productivity-gains>
26. IT User. (2025, diciembre 16). La mitad de los casos de atención al cliente en España se resolverán con IA en 2027. <https://www.ituser.es/estrategias/2025/12/la-mitad-de-los-casos-de-atencion-al-cliente-en-espana-se-resolveran-con-ia-en-2027>
27. IBM. (2025, octubre 28). Two-thirds of surveyed enterprises in EMEA report significant productivity gains from AI. <https://newsroom.ibm.com/2025-10-28-Two-thirds-of-surveyed-enterprises-in-EMEA-report-significant-productivity-gains-from-AI-finds-new-IBM-study>
28. Prosci. (2026, enero 7). AI Adoption: Driving Change With a People-First Approach. <https://prosci.com/blog/ai-adoption>
29. Von Ahn, L. (2025, mayo 22). CEO Duolingo on AI Strategy. LinkedIn. https://www.linkedin.com/posts/luis-von-ahn-duolingo_one-of-the-most-important-things-leaders-activity-7331386411670982658-jpfx
30. Lütke, T. (2025, abril 7). Shopify [Publicación en X]. <https://x.com/tobi/status/1909251946235437514?lang=en>
31. Wikimedia Foundation. (2025, abril 30). Our new AI strategy puts Wikipedia's humans first. <https://diff.wikimedia.org/2025/04/30/our-new-ai-strategy-puts-wikipedias-humans-first/>
32. GDPR.eu. . (s.f.). General Data Protection Regulation (GDPR). <https://gdpr.eu/>
33. European Commission. (2026, enero 27). AI Act. <https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai>
34. Deloitte. (2026). State of AI 2026. <https://www.deloitte.com/global/en/issues/generative-ai/state-of-ai-in-enterprise.html>
35. Forbes. (2026, febrero 12). Did Artificial Intelligence Really Kill SaaS? <https://www.forbes.com/sites/jemmagreen/2026/02/12/did-artificial-intelligence-really-kill-saas/>
36. Oxford Economics. (2023, mayo 5). Technological unemployment in the British industrial revolution: the destruction of hand spinning. <https://www.economics.ox.ac.uk/publication/1339882/ora-hyrax#>
37. Harvard Business Review. (2026, febrero). AI doesn't reduce work, it intensifies it. <https://hbr.org/2026/02/ai-doesnt-reduce-work-it-intensifies-it>

INESDI⁺ BUSINESS TECHSCHOOL

www.inesdi.com



RED DE EDUCACIÓN SUPERIOR

 Planeta Formación y Universidades