

# Módulo 3. Uso avanzado de ChatGPT: Deep Research y modelos razonadores



Sacar el máximo provecho de ChatGPT en entornos laborales implica conocer sus funciones más avanzadas y entender qué modelo o modo usar según la tarea. En este módulo, abordaremos dos de esas capacidades avanzadas que OpenAI ha incorporado a ChatGPT y que son especialmente relevantes para mejorar la empleabilidad y desempeño profesional.

- **Modelos razonadores:** una nueva generación de modelos de IA diseñados para «pensar» con más profundidad antes de responder. Analizaremos qué son estos modelos razonadores, cómo funcionan internamente a grandes rasgos, en qué se diferencian de los modelos estándar, cuáles están disponibles en ChatGPT y en qué situaciones conviene utilizarlos.
- **Deep Research** (o «investigación a fondo»): un agente especializado de ChatGPT capaz de llevar a cabo investigaciones exhaustivas en Internet (y en datos proporcionados por el usuario) para entregar informes detallados con información verificada. Veremos en qué consiste, cómo funciona y cómo usarlo eficazmente, incluyendo su

integración con fuentes propias y ejemplos prácticos en sectores variados.

 1. Modelos razonadores: ChatGPT con pensamiento avanzado

 2. Deep Research: Investigación profunda con ChatGPT

 Referencias

# 1. Modelos razonadores: ChatGPT con pensamiento avanzado

---

## ¿Qué es un modelo razonador y cómo funciona?

Un «modelo razonador» es, en esencia, una versión de los modelos de lenguaje de IA diseñada para invertir más tiempo y pasos en el proceso de llegar a una respuesta, con el objetivo de resolver problemas complejos de manera más precisa y confiable. Mientras que los modelos estándar (como GPT-4o) generan respuestas muy rápidamente basándose en patrones estadísticos aprendidos, los modelos razonadores se detienen a «pensar». OpenAI los describe como modelos entrenados para “pasar más tiempo pensando las respuestas, tal y como lo haría una persona, refinando su proceso de pensamiento, probando distintas estrategias y reconociendo sus errores” (OpenAI, 2024).

Esto significa que, internamente, antes de arrojar la respuesta al usuario, el modelo razonador hace una especie de cadena de razonamiento (*chain-of-thought*) privada:

puede descomponer el problema en subpasos, examinar potenciales soluciones, verificar si la respuesta tentativa tiene coherencia y solo entonces formular la respuesta final. Es como tener a ChatGPT haciendo un monólogo interno lógico y autocorrectivo, en lugar de simplemente completar la frase más probable de una vez.

Técnicamente, estos modelos suelen estar entrenados con métodos especiales de aprendizaje por refuerzo con retroalimentación humana centrados en la deliberación. Por ejemplo, es posible que durante el entrenamiento se les haya recompensado por dar respuestas correctas tras razonamientos largos y penalizado por respuestas rápidas pero incorrectas. El resultado es que aprenden a valorar la precisión sobre la rapidez. Un efecto notable de esto es que un modelo razonador suele reconocer cuándo no está seguro o cuándo una pregunta requiere un análisis cuidadoso, evitando precipitarse.

### **Figura 1: Razonamiento de ChatGPT**

## Pensando

- Obteniendo información del informe interactivo  
Voy a buscar dentro del archivo HTML para extraer datos relevantes usando msearch, con opciones como 'envios', 'Region Norte', y 'data'. La idea es obtener información de la región norte, como tiempos de entrega y tasas de puntualidad. Usaré Python para abrir el archivo y analizar los datos embedded.

☰ Leyendo documentos  
Leyendo documentos

- Obteniendo datos desde la búsqueda de resultados  
Los resultados de búsqueda no contienen toda la información necesaria, solo tienen títulos y configuraciones de ejes. Necesito encontrar los datos reales, que probablemente estén en matrices de fechas y conteos. Abriré más contexto para acceder a las líneas alrededor de la configuración del gráfico y ver si encuentro las matrices de datos.

☰ Leyendo documentos  
Leyendo documentos

☑ Pensó durante 29s  
Listo

Fuente: elaboración propia.

En pruebas internas, demostraron, por ejemplo, que en un examen complejo de matemáticas, el primer modelo

razonador o1 superó abrumadoramente al modelo estándar: GPT-4 original resolvió correctamente solo el 13 % de los problemas de un examen de olimpiada matemática, mientras que o1 acertó el 83 % (Xataka, 2024). Esta diferencia abismal se atribuye a que el modelo razonador puede llevar a cabo demostraciones paso a paso, revisar resultados intermedios y no se rinde ante problemas difíciles, a diferencia de un modelo normal que podría haberse quedado corto en el razonamiento lógico necesario.

**Internamente, los modelos razonadores también tienden a usar más cómputo por respuesta. Es decir, quizás evalúan múltiples trayectorias de respuesta y escogen la mejor (una técnica conocida como *self-consistency* o votación entre varios «hilos de pensamiento»). Todo esto los hace más lentos y costosos en comparación con los modelos estándar. Es algo intencional: sacrifican velocidad por calidad en tareas complejas. Por este motivo, no se recomienda usar estos modelos para todo tipo de tareas; muchas veces necesitamos respuestas rápidas a preguntas simples que, usando un modelo razonador, solo perderíamos tiempo (Xataka, 2024).**

Resumiendo, un modelo razonador de ChatGPT es como un «modo reflexivo» del modelo: busca emular un proceso de pensamiento más profundo y analítico, en contraposición al modo más inmediato y conversacional de los modelos tradicionales. Es un avance hacia IA que no solo responde, sino que razona activamente antes de responder.

### **Diferencias con los modelos convencionales** —

Vistas las características generales, podemos enumerar las principales diferencias entre un modelo razonador y un modelo estándar de ChatGPT.

- **Velocidad de respuesta:** los modelos estándar están optimizados para responder en segundos, ideal para chat fluido. El modelo razonador se toma más tiempo deliberadamente. Puede tardar varios segundos o minutos en preguntas complejas, dado que ejecuta múltiples pasos internos.
- **Estructura interna de la generación:** un modelo estándar genera la respuesta palabra por palabra de una sola pasada (aunque por dentro haya ciertos cálculos de probabilidad, no revisa su respuesta una vez la está dando). Un modelo razonador puede generar soluciones provisionales internamente, revisarlas, desechar algunas y luego dar la final. Es decir, tiene un proceso recursivo o iterativo antes de «hablar». Esto a veces se traduce en respuestas más estructuradas, en las

que se puede observar que claramente siguió una serie de pasos lógicos.

- **Precisión y complejidad manejable:** en problemas fáciles o preguntas de conocimiento general, un modelo estándar suele ser suficiente y muy rápido. Sin embargo, en preguntas que involucran razonamiento lógico, matemático, resolución de problemas nuevos o *multi-step*, los modelos estándar a veces fallan o alucinan respuestas incorrectas. Los modelos razonadores exhiben mucho mayor acierto en estas tareas. Un ejemplo: en programación, se ha medido que los modelos razonadores alcanzan percentiles altísimos en competencias de código; OpenAI reportó que o1 alcanzó el percentil 89 en Codeforces, muy por encima de GPT-4 estándar (OpenAI, 2024). También en preguntas de ciencias, física, química o incluso de cultura general experta, los razonadores tienden a obtener mejores resultados en *benchmarks* exigentes (OpenAI, 2025a).
- **Reducción de alucinaciones y errores:** los modelos razonadores han mostrado menor tendencia a «alucinar» (fabricar datos falsos) en ciertas pruebas, precisamente porque razonan sobre la consistencia. Por ejemplo, OpenAI indicó que con el razonamiento extendido de GPT-5 Pro, el modelo cometió 22 % menos errores graves que la versión normal en temas de salud, ciencia, matemáticas, etcétera (OpenAI, 2025a).

### Modelos razonadores disponibles en ChatGPT —

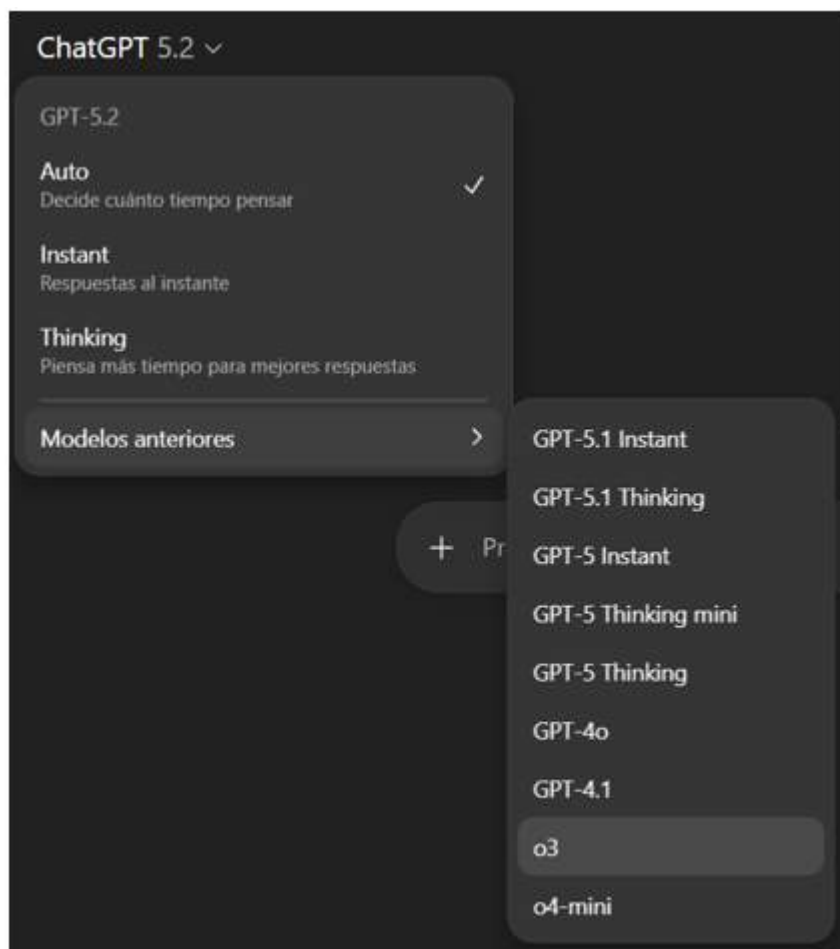
OpenAI ha ido introduciendo gradualmente estos modelos razonadores en su plataforma ChatGPT y en su API desde 2024. Actualmente, los modelos razonadores disponibles (y sus variantes) son los siguientes:

- **OpenAI o1.** Lanzado en septiembre de 2024 como el primer modelo público de la serie razonadora (Xataka, 2025). Está diseñado para resolver problemas difíciles tomándose tiempo y destacó por su rendimiento en tareas científicas, matemáticas y de programación. Como vimos, en pruebas internas superó con creces a GPT-4 en varias disciplinas (Xataka, 2024). En su lanzamiento se aclaró que no era una solución para todos los usuarios por su lentitud, pero sí un gran salto hacia la capacidad de razonamiento similar a la humana (Xataka, 2024). Junto con o1 se lanzó también o1-mini, una variante más ligera y rápida, pensada sobre todo para tareas de programación, con coste más bajo (Xataka, 2024).
- **OpenAI o3:** lanzado en diciembre de 2024, es la segunda versión del modelo de razonamiento de OpenAI (Xataka, 2025). Representó un salto cualitativo notable respecto a o1, lo que mejoró aún más la precisión y capacidad. Junto con o3 apareció o3-mini (enero 2025) como la versión eficiente para facilitar su acceso masivo. A inicios de 2025, OpenAI permitió que usuarios gratuitos de ChatGPT probaran un número limitado de consultas con o3-mini, lo que popularizó más esta función. De hecho, ChatGPT añadió un «modo razonador» en su interfaz gratuita con X consultas limitadas usando o3-mini. Cabe mencionar que la denominación fue un poco confusa; no hubo o2 debido a un conflicto de nombre comercial, por eso OpenAI saltó del nombre o1 al o3 (Xataka, 2025).
- **OpenAI o4-mini:** si bien OpenAI no anunció un «o4» completo públicamente, a mediados de 2025, sí sacó o4-mini como una versión ligera de la siguiente iteración razonadora (OpenAI, 2025a). En abril de 2025, OpenAI comentó que la nueva versión ligera de investigación a fondo estaba “impulsada por una versión de o4-mini diseñada para ser más rentable sin sacrificar alta calidad” (OpenAI, 2025a). A su vez, este modelo está

disponible para chatear en ChatGPT si se prefiere un modelo razonador más veloz, lo que sacrifica poder de pensamiento.

- **GPT-5 Thinking/GPT-5 Pro:** en agosto de 2025, OpenAI lanzó GPT-5, que supuso un cambio de paradigma al integrar los modelos de razonamiento dentro de un sistema unificado (OpenAI, 2025a). Como ya sabemos, GPT-5 y predecesores (GPT-5.1, GPT-5.2) poseen distintas variantes, dentro de las cuales encontramos los modelos razonadores GPT-5 Thinking, GPT-5 Thinking Mini y GPT-5 Pro.

**Figura 2: ChatGPT 5.2**



Fuente: elaboración propia.

## ¿Cuándo conviene usar un modelo razonador? —

Como ya hemos indicado, no todas las tareas ameritan encender el «modo pensador» de ChatGPT. Por eficiencia, reservar los modelos razonadores para los casos que realmente lo requieren ayudará a aprovechar mejor tanto el tiempo de respuesta como posibles cuotas de uso. A continuación, enumeramos situaciones en las que es más conveniente usar un modelo razonador en lugar de uno estándar, y viceversa.

Es recomendable usar un modelo razonador en los siguientes casos:

- cuando el problema es complejo, técnico o multipaso.
- Cuando la precisión y corrección son más importantes que la rapidez.
- Cuando la tarea implica planificación o pasos intermedios.
- Cuando se requiere entender o crear lógica compleja, como en código.

En cambio, **no** es necesario (y puede ser contraproducente) usar un modelo razonador en los siguientes casos:

- cuando la pregunta es sencilla o factual directa.
- Cuando se necesita una respuesta creativa o de estilo libre rápidamente.

- Cuando la tarea depende más de conocimiento actualizado que de razonamiento profundo.

**CONTINUAR**

## 2. Deep Research: Investigación profunda con ChatGPT

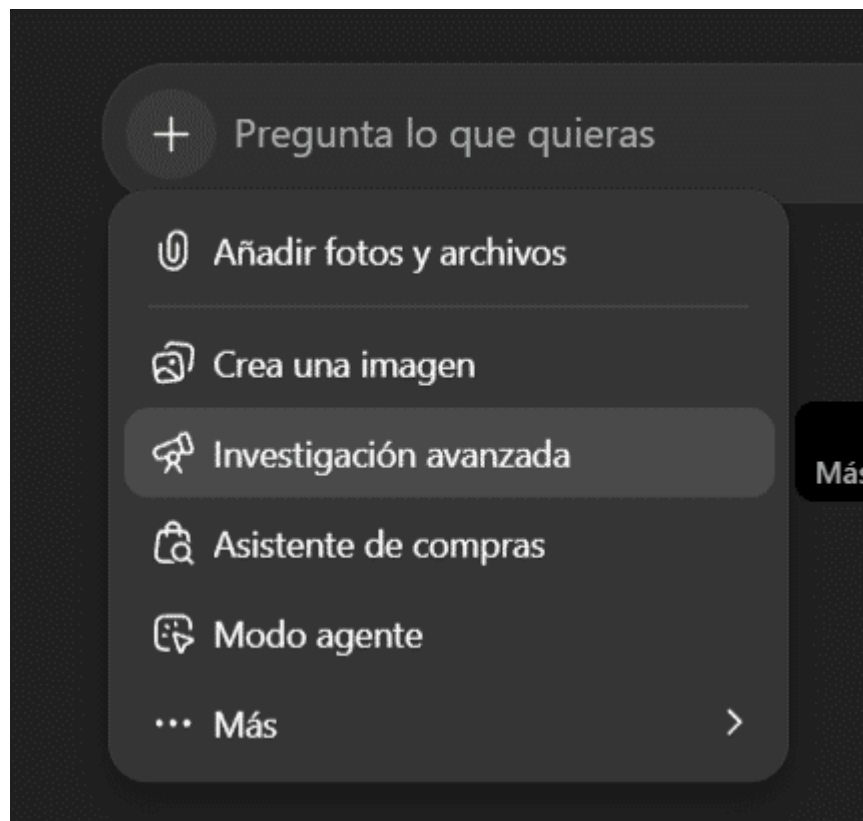
---

Deep Research (en español, investigación a fondo) es un modo o agente especial integrado en ChatGPT que actúa como asistente de investigación autónomo. A diferencia del uso convencional de ChatGPT (en el que el modelo responde con el conocimiento almacenado en su entrenamiento o una rápida búsqueda en internet), al activar Deep Research, el sistema es capaz de navegar por Internet, consultar múltiples fuentes externas y sintetizar grandes cantidades de información para resolver una consulta compleja (OpenAI, 2025b). En palabras de OpenAI, la investigación a fondo permite que ChatGPT “busque, analice y sintetice cientos de fuentes en línea para crear un informe detallado digno de un analista de investigación” (OpenAI, 2025b).

### ¿Qué hace y cómo funciona Deep Research?

Deep Research está diseñado para abordar tareas complejas de investigación que normalmente requerirían horas de un profesional humano. Emplea un enfoque de búsquedas de múltiples pasos (es decir, no se limita a una sola búsqueda superficial, sino que va refinando y profundizando según lo que encuentre) y aplica capacidades de razonamiento avanzadas para analizar la información recopilada (OpenAI, 2025a). De hecho, internamente Deep Research está potenciado por una versión optimizada del modelo de OpenAI o3, la cual ha sido entrenada específicamente para navegar la web y analizar datos. Durante su entrenamiento, se emplearon técnicas de aprendizaje por refuerzo en tareas del mundo real que requerían uso de navegador y herramientas de Python, de modo que aprendiera a planificar y ejecutar secuencias de acciones para encontrar los datos necesarios, retrocediendo y ajustando la estrategia en tiempo real según la información obtenida (OpenAI, 2025b).

### **Figura 3: Investigación avanzada**



Fuente: elaboración propia.

**En términos prácticos, cuando activamos Deep Research y hacemos una pregunta, ChatGPT inicia un proceso autónomo en el que navega por sitios web, lleva a cabo búsquedas relevantes, filtra resultados, lee artículos o documentos completos y extrae datos claves. Todo esto lo hace en su propio «ordenador virtual», alternando entre herramientas de navegación y de ejecución de código según la tarea lo requiera (OpenAI, 2025c). Por ejemplo, puede buscar términos específicos, luego abrir una página web, desplazarse por ella, encontrar la**

sección relevante y resumirla, incluso traducir si está en otro idioma. Si necesita hacer un cálculo o procesar datos estructurados, puede usar una herramienta de Python integrada para hacer análisis más avanzados o generar gráficos. De hecho, el modelo tiene la capacidad de analizar archivos que el usuario haya cargado, generar gráficos a partir de ellos mediante Python y citar fragmentos textuales específicos de sus fuentes en la respuesta final (OpenAI, 2025b). Todo este proceso ocurre de forma transparente: mientras Deep Research trabaja, se muestra una barra lateral o bitácora con los pasos que va siguiendo y las fuentes consultadas en cada paso (OpenAI, 2025b), de manera que el usuario puede seguir el razonamiento y la ruta de búsqueda que se está realizando.

**Figura 4: Ruta de búsqueda**

ChatGPT

Compartir Añadir personas

Actividad 12 fuentes

Perfecto. Comenzaré a desarrollar un informe completo sobre el comportamiento del IPC Córdoba desde 1968 hasta el presente, segmentado por etapas macroeconómicas y vinculado con las políticas nacionales y provinciales. Incluirá gráficos, estadísticas por período, línea de tiempo político-económica, y un script reproducible para replicar el análisis.

Te avisaré cuando el informe esté listo para tu revisión.

Research completed in 21m · 12 fuentes · 106 búsquedas

### Análisis histórico del IPC Córdoba (1968–2025) y su vínculo con políticas económicas en Argentina

#### Resumen Ejecutivo

- 1968–1975 (Pre-inflación acelerada): La inflación en Córdoba se mantuvo moderada pero creciente hasta principios de los 70, aumentando significativamente con la inestabilidad política del país. Tras la caída del régimen de Onganía y la transición

+ Pregunta lo que quieras

ChatGPT puede cometer errores. Considera verificar la información importante.

Estoy revisando Wikipedia para obtener detalles específicos.

Se leyó más de [es.wikipedia.org](https://es.wikipedia.org)

Estoy viendo que Argentina tuvo una inflación anual de alrededor del 131% a principios de 1981, con devaluaciones significativas y una hiperinflación que alcanzó el 433% en 1983.

Buscando información sobre el Plan Austral y la inflación en Argentina 1985-1989

Estoy chequeando el Plan Austral de Wikipedia, que parece prometedor.

Se leyó más de [es.wikipedia.org](https://es.wikipedia.org)

Estoy pensando en cómo el Plan Austral logró contener rápidamente la inflación sin frenar el crecimiento económico, pero finalmente fue abortado por la rebote de inflación en 1988.

Buscando información sobre el Plan Austral y su impacto en la inflación

Estoy observando una notable disminución en la inflación anualizada del Plan Austral

Fuente: elaboración propia.

El resultado final que entrega Deep Research es un informe detallado y ampliamente documentado. Cada afirmación o dato importante viene acompañado de su correspondiente cita bibliográfica, con enlaces a las fuentes originales consultadas. Además, el informe suele incluir explicaciones de la línea de pensamiento seguida: es decir, indicaciones de por qué el agente tomó cierta vía de búsqueda o cómo interpretó la información hallada. Esto aporta transparencia y permite al usuario verificar fácilmente la información por sí mismo, consultando las referencias para confirmar los datos. En otras palabras, Deep Research, además de dar una respuesta, la sustenta con evidencia, algo crucial en entornos

profesionales en los que la confiabilidad de la información es fundamental.

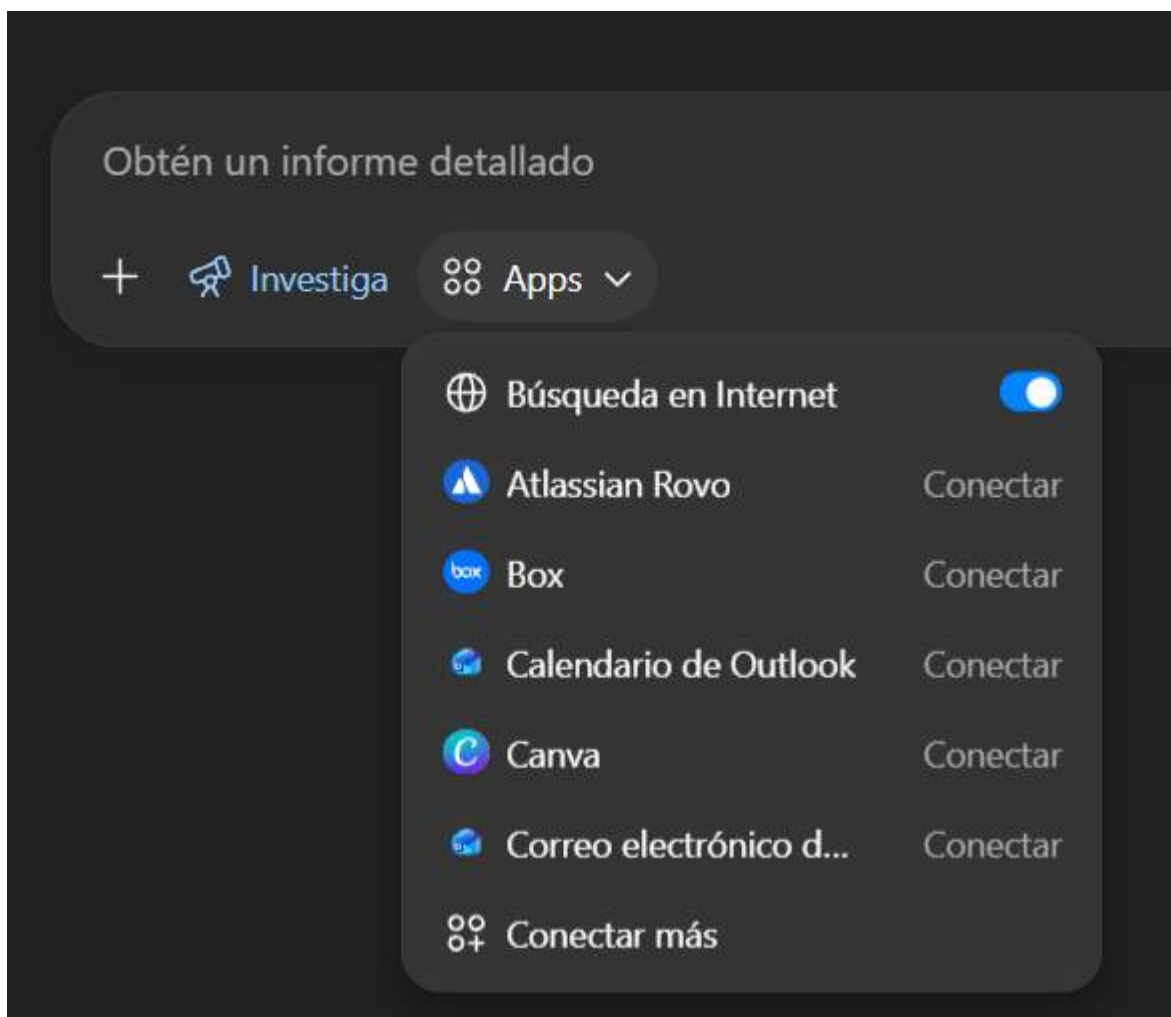
Una de las ventajas más notables de usar Deep Research es la eficiencia. De acuerdo con OpenAI, este agente puede lograr en veinte o treinta minutos lo que a un ser humano le llevaría muchas horas de búsqueda manual (OpenAI, 2025b). El modelo puede ojear cientos de páginas web en poco tiempo, saltando rápidamente a las partes relevantes y resumir objetivamente grandes bloques de texto. Para quien recibe el informe, esto significa un enorme ahorro de tiempo en tareas de investigación intensiva. De hecho, se concibió pensando en personas que hacen trabajo intensivo de conocimiento en campos como finanzas, ciencia, política o ingeniería. También se pensó en aquellos casos en los que la información buscada es especializada o poco intuitiva, que normalmente obligaría a navegar por multitud de sitios web hasta dar con los datos correctos. En lugar de ese esfuerzo manual, Deep Research lo automatiza, lo que le permite al profesional concentrarse luego en analizar el informe y aplicarlo a su problema específico.

## **Uso de Deep Research con fuentes propias y datos externos**

Una funcionalidad muy potente de Deep Research es la posibilidad de incorporar fuentes proporcionadas por el propio usuario en el proceso de investigación. Esto significa que podemos complementar la búsqueda en la web con información propia o específica que tengamos, para obtener resultados aún más relevantes. ChatGPT permite adjuntar archivos (documentos de texto, PDF, hojas de cálculo, etcétera) al momento de hacer nuestra consulta en modo investigación a fondo (OpenAI, 2025b). Si añadimos archivos con contexto adicional, Deep Research los explorará y analizará como parte de su trabajo, integrando sus contenidos con lo que encuentre en Internet. Por ejemplo, un investigador académico podría subir un conjunto de artículos científicos descargados y solicitar al agente que los resuma y los compare con información más reciente obtenida en la web.

Además, OpenAI ha ido ampliando las formas de integrar datos externos en Deep Research. Inicialmente, la herramienta soportaba adjuntar documentos y usar la terminal Python para leer datos estructurados, pero en 2025 se añadieron integraciones directas con distintas aplicaciones de uso popular como Dropbox, Gmail, Google Drive, etcétera. Esto amplía las posibilidades de hacer las investigaciones a fondo basándose en información propia.

**Figura 5: Herramientas**



Fuente: elaboración propia.

**En la práctica, el funcionamiento es sencillo: desde la interfaz de ChatGPT se ofrecen opciones para elegir la fuente de investigación (Internet, Archivos adjuntos, Dropbox, etcétera). Podemos escoger una o varias. Una vez seleccionadas, Deep**

**Research accederá a esos documentos o datos al igual que accede a sitios web públicos y los incorporará al proceso de búsqueda.**

Es importante destacar que la información de fuentes privadas se maneja de manera segura y solo se usa para responder a la consulta del usuario. Además, el usuario siempre tiene el control: puede desconectar en cualquier momento la integración con un servicio externo. Sin embargo, como siempre, recomendamos ser cuidadosos a la hora de cargar información que pueda ser sensible o privada.

#### CONSEJOS TÉCNICOS Y BUENAS PRÁCTICAS DE USO

#### EJEMPLOS PRÁCTICOS DE DEEP RESEARCH EN DISTINTOS SECTORES

Para aprovechar al máximo Deep Research en ChatGPT, es conveniente seguir algunas recomendaciones técnicas y elaborar nuestros *prompts* (instrucciones) de manera efectiva. A continuación, se presentan varios consejos y buenas prácticas.

- **Selecciona el modo adecuado:** antes de escribir la pregunta, asegúrate de haber activado el modo Investigación a fondo en la interfaz de ChatGPT. Este modo suele encontrarse en el menú desplegable de herramientas o modos. Una vez seleccionado «investigación a fondo» (Deep Research), la IA sabrá que debe

hacer búsquedas y análisis autónomos en lugar de dar una respuesta inmediata basada solo en su entrenamiento (OpenAI, 2025b).

- **Formula una pregunta clara y específica:** la calidad del *prompt* es crucial. Instrucciones vagas o demasiado generales pueden llevar a resultados igualmente generales o a que el agente divague (Romero, 2025). Es mejor detallar exactamente qué necesitas. Incluye contexto si es necesario, delimita el alcance y menciona el formato de salida deseado. Por ejemplo, en lugar de preguntar «háblame sobre energías renovables», podrías solicitar «elabora un informe comparando la eficiencia y costos de producción de energía solar vs. eólica en Latinoamérica, citando fuentes recientes (2024-2025) y concluyendo con recomendaciones de inversión». Observa cómo este segundo *prompt* concreta qué comparar, dónde (región), qué tipo de fuentes/*timeframe* y pide un formato de salida (informe con recomendaciones). Esto guía al agente en su investigación.
- **Proporciona palabras claves y pistas de búsqueda:** si ya sospechas qué términos o fuentes pueden ser relevantes, inclúyelos en tu consulta. Por ejemplo: «...basado en datos de la OECD y de la Agencia Internacional de Energía» o «...busca también estadísticas de la UNESCO sobre educación». De esta forma, orientas a Deep Research a iniciar por esas fuentes confiables. Asimismo, puedes indicar si prefieres resultados en cierto idioma (por ejemplo, «incluye fuentes en español si es posible») o de cierta fecha («me interesa información de los últimos dos años»). El agente es capaz de filtrar por fecha y de priorizar determinado dominio de conocimiento si se lo pides.
- **Adjunta archivos o datos pertinentes:** como vimos, si dispones de documentos propios que puedan contribuir, súbelos antes de enviar la pregunta. Asegúrate de referenciarlos en el *prompt* si

vienen al caso, para que el agente los tenga en cuenta. Por ejemplo: «he adjuntado un informe de ventas Q1. Analiza las tendencias allí y compara con el mercado global».

- **Solicita explícitamente citas y verificaciones:** Deep Research por defecto ya proporciona citas, pero no está de más reforzarlo en la instrucción si lo consideras importante. Puedes decir: «por favor, proporciona referencias para cada afirmación clave» o «verifica cada dato con su fuente original y anótala». Esto también le indica que priorice información de fuentes fiables. La herramienta fue diseñada para documentar todo, así que verás citas en el informe final sin necesidad de insistir demasiado, pero esta aclaración puede ser útil en ciertos casos.
- **Ten paciencia y monitorea el proceso:** a diferencia de una respuesta normal de ChatGPT que es casi instantánea, Deep Research puede tardar varios minutos en completar su tarea, dependiendo de la complejidad. Verás en la barra lateral los pasos que va dando (búsquedas, lecturas, análisis). Esto es útil porque puedes monitorear si va por buen camino. Si notas que se desvía (por ejemplo, consultando un sitio irrelevante), puedes interrumpir el proceso en cualquier momento y corregir el rumbo a través del chat (OpenAI, 2025c).
- **Revisa críticamente y aplica juicio humano:** aunque Deep Research es potente, no es infalible. Puede ocurrir que alguna fuente citada no sea del todo confiable, que interprete mal un dato o que se quede corto en el análisis. Es esencial que el profesional actúe como revisor: hay que validar las fuentes citadas, leer alguna de ellas si el dato es crítico y asegurarse de que las conclusiones tengan sentido en el contexto real. La herramienta facilita esto al darte todo servido con referencias, pero la supervisión humana sigue siendo irrenunciable (Romero, 2025). En última instancia, tu criterio profesional debe prevalecer, usando la salida de ChatGPT como apoyo y no como verdad

absoluta. Si encuentras algún punto débil, puedes preguntarle al agente de nuevo o complementar manualmente la investigación.

- **Cuida consideraciones éticas y de privacidad:** si vas a usar datos internos (por ejemplo, listas de empleados, información confidencial), asegúrate de cumplir con la política de tu empresa sobre compartir datos con herramientas de IA. OpenAI afirma proteger la privacidad y seguridad, pero siempre es recomendable no exponer información sensible innecesariamente. Además, recuerda que ChatGPT no tiene criterio ético humano, solo sigue lineamientos; por ello, si la investigación toca temas delicados (por ejemplo, decisiones que afectan personas, sesgos, etcétera), toma con cautela las sugerencias y verifica que cumplan estándares éticos y legales antes de implementarlas.

Siguiendo estas recomendaciones técnicas, podrás obtener resultados más útiles y confiables de Deep Research. La clave es tratar al agente como un asistente inteligente al que hay que dar instrucciones claras, proveerle de la información que necesita y cuyo trabajo uno debe después pulir con juicio profesional. Cuando se usa adecuadamente, Deep Research puede ser un ahorrador de tiempo enorme y un potenciador de la calidad del trabajo, lo que nos libera de la carga de recopilar datos para que podamos centrarnos en la toma de decisiones y la creatividad.

**CONSEJOS TÉCNICOS Y BUENAS PRÁCTICAS  
DE USO**

**EJEMPLOS PRÁCTICOS DE DEEP RESEARCH EN  
DISTINTOS SECTORES**

Para ilustrar cómo se puede aplicar Deep Research en el mundo laboral, veamos casos de uso hipotéticos en varios sectores profesionales. Estos ejemplos muestran la versatilidad de la herramienta:

- **recursos humanos (RR. HH.)**. Un gerente de RR. HH. necesita actualizar la política de beneficios de su empresa y asegurarse de que es competitiva. Con Deep Research, podría solicitar «un informe comparativo de las políticas de beneficios laborales en empresas de tecnología de tamaño similar, incluyendo días de vacaciones, licencias parentales y modalidades de trabajo flexible». El agente buscaría en internet estudios de consultoras de RR. HH., informes de empresas (muchas publican sus beneficios para atraer talento) y quizás artículos de prensa especializados. Si el gerente adjunta además los resultados de una encuesta interna de satisfacción de empleados, el agente podría incorporar ese análisis interno. El informe final podría destacar en qué áreas la empresa está por debajo del promedio del sector (por ejemplo, si ofrece menos días de vacaciones que el promedio) y citar cada dato con su fuente. Con esa información, el gerente tendría evidencia para proponer mejoras. Asimismo, en procesos de reclutamiento, RR. HH. podría emplear Deep Research para filtrar candidatos: por ejemplo, subiendo cien currículums de postulantes a un puesto y pidiendo «analiza estos CV y resume qué candidatos cumplen con los requisitos clave (X, Y, Z) y qué expectativa salarial tienen, comparándolos con datos del mercado». El agente extraería de cada CV la experiencia relevante, podría incluso buscar referencias públicas de los candidatos (por ejemplo, perfil de LinkedIn si se lo indica) y armar un cuadro comparativo, lo que nos ahorra horas de revisión manual. Vale notar que, aunque ChatGPT acelera tareas burocráticas y de análisis en RR. HH., no

reemplaza el juicio humano, sino que lo asiste (Romero, 2025). Los profesionales de personas seguirán tomando las decisiones, pero con información más organizada.

- **Marketing y análisis de mercado:** imaginemos un analista de *marketing* que trabaja para una empresa de productos de consumo masivo y necesita entender las tendencias de mercado y a la competencia para planificar la estrategia del próximo año. Con Deep Research podría plantear: «haz una investigación de mercado sobre el sector de alimentos orgánicos en Córdoba: principales tendencias de consumo en 2024-2025, cuota de mercado de las cinco empresas líderes, estrategias de *marketing* más efectivas reportadas y cualquier cambio regulatorio relevante. Incluye cifras de crecimiento y citas de fuentes (informes Nielsen, prensa especializada, etcétera)». El agente recopilaría datos de fuentes variadas: informes de consultoras, noticias económicas, incluso *posts* de blog confiables o datos de Google Trends si los encuentra. Probablemente enumeraría que el mercado orgánico crece a X % anual (SIS International Research, s. f.), mencionaría que los consumidores buscan sostenibilidad y transparencia, citaría qué empresas lideran con qué cuota, todo con referencias. Este nivel de síntesis permitiría al equipo de *marketing* tomar decisiones informadas rápidamente. Otra aplicación: la inteligencia competitiva. Un *product manager* puede pedir: «investiga a tres competidores clave (A, B, C) y crea un informe con sus puntos fuertes, debilidades, últimas campañas de *marketing* y *reception* del público». ChatGPT podría navegar los sitios web de esos competidores, notas de prensa, redes sociales y armar los puntos para cada uno.

- **Educación y capacitación:** un docente o diseñador instruccional puede emplear Deep Research para preparar contenido de cursos o para actualizar materiales educativos. Supongamos un profesor universitario que quiere elaborar una clase sobre los últimos avances en inteligencia artificial aplicada a la medicina. Él podría pedir: «lleva a cabo una investigación exhaustiva sobre aplicaciones de IA en diagnóstico médico (2022-2025), incluyendo los hallazgos más recientes en revistas científicas (Nature, Lancet, etcétera), proyectos destacados de instituciones como MIT o Stanford y considera también implicaciones éticas señaladas por organismos como UNESCO. Proporciona un informe académico con referencias APA». En este caso, el agente buscaría artículos académicos, informes de la UNESCO sobre IA en educación médica, posicionamientos éticos, etcétera, y devolvería un informe posiblemente estructurado por áreas (diagnóstico por imágenes, análisis genético, telemedicina con IA, etcétera) citando cada estudio.

Adicionalmente, en educación superior, los estudiantes mismos pueden beneficiarse: por ejemplo, un estudiante de historia podría usar Deep Research para recopilar información de múltiples libros y *papers* sobre una temática específica (teniendo en cuenta que debe hacerlo éticamente, como apoyo para su propio trabajo y no para plagiar).

- **Análisis de datos y ciencia de datos:** aunque a primera vista Deep Research parece orientado a texto e informes, no hay que olvidar que incorpora una herramienta de Python. Esto significa que puede hacer cierto análisis de datos programático si se le proveen *datasets* o se encuentran datos tabulares en la web. Por

ejemplo, un analista de datos podría subir un archivo CSV con las ventas mensuales de su empresa y pedir: «analiza este *dataset* de ventas mensuales (adjunto) e identifica patrones estacionales. Luego, contrasta nuestro desempeño con las tendencias de la industria (busca si las ventas en nuestro sector también muestran los mismos picos estacionales). Genera gráficos para ilustrar y cita cualquier dato de la industria que encuentres». El agente en este caso podría leer el CSV con Python, calcular promedios por mes, detectar que, por ejemplo, las ventas suben en verano; luego buscar en la web si hay reportes que mencionen estacionalidad en ese sector. Otro ejemplo, un científico de datos explorando una hipótesis podría usar Deep Research para recolectar fragmentos de código o soluciones similares en línea. Imaginemos que necesita optimizar un algoritmo X; podría pedir: «busca en foros de desarrolladores (StackOverflow, GitHub) y en artículos académicos, métodos recomendados para optimizar algoritmos de búsqueda en grafos grandes, en particular en el contexto de redes sociales. Resume las estrategias más mencionadas y cualquier fragmento de código útil». El agente recorrería probablemente hilos de StackOverflow y papers de arXiv, extrayendo trucos y podría incluso traer código de ejemplo con su referencia. Esta capacidad de síntesis técnica puede acelerar la experimentación y resolución de problemas complejos.

- **Investigación científica y académica:** en este campo, sus aplicaciones son numerosas, principalmente orientadas con la búsqueda y revisión de bibliografía. Deep Research puede usarse por ejemplo para armar rápidamente un estado del arte y detectar vacíos de investigación: supongamos una tesista en ciencias sociales que estudia desinformación electoral y moderación de contenidos puede pedir «reúne evidencia reciente sobre eficacia de *fact-checking*, *prebunking/inoculation* y señales algorítmicas en redes;

compara resultados por región, identifica métricas usadas, limitaciones metodológicas y recomendaciones de política pública» y Deep Research recorrerá *papers*, informes de organismos y documentación técnica, para entregar un informe con citas por afirmación, un mapa de consensos y desacuerdos y una lista de «*gaps*» (poblaciones subestudiadas, problemas de medición, sesgos de selección) que ayuda a formular hipótesis y justificar el diseño metodológico con referencias verificables.

En todos estos ejemplos observamos un patrón: Deep Research permite a profesionales de cualquier ámbito tomar decisiones informadas basadas en evidencia, lo que reduce drásticamente el tiempo de recopilar esa evidencia. Por supuesto, cada dominio deberá adaptar el uso a sus necesidades, pero el potencial está ahí. A medida que las personas se familiarizan con esta herramienta, es de esperar que forme parte del flujo de trabajo estándar en muchas ocupaciones.

## **Nota aclaratoria sobre uso de IA**

Este material fue asistido con herramientas de IA generativa para tareas de borrador, síntesis, reescritura y apoyo en la organización de contenidos. Cada sección fue revisada, editada y validada por el equipo humano, que verificó la precisión conceptual, la coherencia pedagógica y las fuentes citadas. Se invita a contrastar con las referencias bibliográficas incluidas y la documentación oficial. Dado que

los modelos de IA evolucionan con rapidez, ciertas especificaciones técnicas podrían actualizarse; este texto refleja el estado del conocimiento al momento de su elaboración.

**CONTINUAR**

# Referencias

---

**OpenAI.** (2024, 12 de septiembre). Introducing OpenAI o1. OpenAI. <https://openai.com/index/introducing-openai-o1-preview/>.

**OpenAI.** (2025b, 2 de febrero). *Presentamos la investigación a fondo.* OpenAI. <https://openai.com/es-419/index/introducing-deep-research/>.

**OpenAI.** (2025c, 17 de julio). *Presentamos al agente ChatGPT: Un puente entre la investigación y la acción.* OpenAI. <https://openai.com/es-419/index/introducing-chatgpt-agent/>.

**OpenAI.** (2025a, 7 de agosto). *Presentamos GPT-5.* OpenAI. <https://openai.com/es-419/index/introducing-gpt-5/>.

**Romero, V. M.** (2025, 16 de octubre). *ChatGPT en Recursos Humanos: ejemplos, prompts y herramienta.* Factorial. <https://factorial.es/blog/chatgpt-recursos-humanos/>.

**SIS International Research.** (s. f.). *Investigación de mercado de ChatGPT.* SIS International Research. Recuperado el 8 de enero de 2026, de <https://www.sisinternational.com/es/pericia/industrias/investigacion-de-mercado-chatgpt/>.

**Xataka.** (2024, 12 de septiembre). *OpenAI lanza por sorpresa o1, su primer modelo con capacidades de "razonamiento" para resolver problemas difíciles.* Xataka. <https://www.xataka.com/robotica-e-ia/openai-lanza-sorpresa-o1-su-primer-modelo-capacidades-razonamiento-para-resolver-problemas-dificiles>.

**Xataka.** (2025, 4 de febrero). *ChatGPT, o1, o3-mini, GPT-4o: OpenAI tiene un problema muy evidente con sus modelos IA y es su nombre.* Xataka. <https://www.xataka.com/robotica-e-ia/hemos-ordenado-todos-modelos-ia-openai-para-entender-sus-nombres-no-hemos-entendido-nada>.

CONTINUAR