

Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Juvenal Yosa Reyes, PhD

Yosa Reyes, Juvenal

Hablando con máquinas / Juvenal Yosa Reyes -- Barranquilla: Ediciones Universidad Simón Bolívar, 2025.

248 páginas: imágenes a color

ISBN: 978-628-7852-09-9 (Versión digital)

1. Inteligencia artificial 2. Interacción hombre-computador 3. Procesamiento electrónico de datos 4. Análisis sintáctico (Gramática computacional) 5. Sistemas de procesamiento de la voz 6. Aprendizaje automático (Inteligencia artificial) I. Yosa Reyes, Juvenal, Autor II. Título

CDD 629.892 Y654 2025 edición 22

Universidad Simón Bolívar – Sistema de Bibliotecas

DOI: <https://doi.org/10.17081/r.book.2025.10.17031>

Hablando con Máquinas

Autor: Juvenal Yosa Reyes

El Fondo Editorial Ediciones Universidad Simón Bolívar se adhiere a la filosofía del acceso abierto y permite libremente la consulta, descarga, reproducción o enlace para uso de sus contenidos, bajo una licencia Creative Commons Atribución 4.0 Internacional. <https://creativecommons.org/licenses/by/4.0/>



Ediciones Universidad Simón Bolívar

Carrera 54 No. 64-223 sede posgrados

Barranquilla - Cúcuta

<https://www.unisimon.edu.co/iie/index/sello-editorial-unisimon/1664>

Contacto: dptopublicaciones@unisimon.edu.co



Producción:

Corrección y formación: Julián Hernández Rosas

Ediciones Carrera 7.a SAS.

Diseño y diagramación: Nathalia A. López Ramírez

gerentecarrera7@hotmail.com

Teléfono: 3106665525

Bogotá-Colombia

Octubre de 2025

Barranquilla-Colombia

*A mi hermana Sandra Yosa, quien me
ayudó a iniciar este viaje.*

Te extrañamos todos los días.

Tabla de contenido

Descripción	5
Prefacio	6
Introducción.....	10
Los modelos de lenguaje.....	30
¿Qué es un <i>transformer</i> y por qué se está hablando tanto del tema?	45
¿Qué son los modelos fundacionales?	54
Prompts.....	89
Cómo mejorar los <i>prompts</i>	138
ChatGPT: cómo ajustar las respuestas con prompts inteligentes.....	142
Técnicas más avanzadas.....	149
GPT	191
Nuevos modelos, mejores respuestas pensamiento en cadena y seguridad.....	196
RAG generación aumentada con recuperación	204
Agentes autónomos con LLM.....	212
A manera de conclusión	241
Acerca del autor	245
Referencias	246

Descripción

¿Listo para conversar con el futuro? *Hablando con máquinas* te sumerge en el universo de la inteligencia artificial (IA), la tecnología que está cambiando la forma en que trabajamos, aprendemos y vivimos. Con explicaciones claras y ejemplos prácticos, este libro derriba barreras y elimina la complejidad que rodea al tema, de modo que cualquier persona, sin importar su formación previa, pueda explorar cómo funcionan los modelos de IA más avanzados.

Te enseñará a interactuar con asistentes como ChatGPT, Gemini y Claude, y a descubrir el fascinante arte de crear *prompts* efectivos, que te permitirán liberar todo el poder creativo y analítico de estos sistemas. Te invitará también a viajar por la historia de la IA, explicará cómo se entrenan los modelos fundacionales y revelará el intrigante fenómeno de las “alucinaciones” que a veces surgen en los LLM, para que puedas reconocerlas de inmediato.

Profundizarás en las redes neuronales y los *transformers* mientras aprendes a perfeccionar tus *prompts* usando técnicas como el aprovechamiento del historial de conversación, lo que hará que tus preguntas sean aún más claras y potentes. Además, descubrirás cómo estos métodos pueden estimular tu creatividad en la escritura, el diseño o la resolución de problemas, y de qué manera la IA está moldeando el futuro de la sociedad.

Hablando con máquinas te convertirá en un usuario seguro y creativo en el mundo de la IA, mostrándote cómo estas herramientas pueden potenciar tu productividad, despertar tu ingenio y transformar tu forma de aprender. Prepárate para un futuro en el que hablar con máquinas será parte de la vida cotidiana, y únete a la revolución digital con esta guía esencial que te muestra cómo sacarle el máximo provecho a la tecnología que lo está cambiando todo.



Prefacio

Hace unos años, la inteligencia artificial (IA) comenzó a captar la atención de la población general, especialmente con el lanzamiento de asistentes virtuales como ChatGPT. Aunque los modelos GPT existían desde antes para desarrolladores –algunos utilizábamos versiones anteriores como GPT-2 para generar *embeddings* en secuencias de ADN y proteínas– no fue hasta finales de 2022 que el interés masivo se volcó hacia la IA generativa. Por primera vez, una máquina podía generar texto con reglas sintácticas y semánticas similares a las humanas, en varios idiomas y con una riqueza que antes solo atribuíamos a la comunicación humana. Esto marcó un avance significativo que, además, democratizó el acceso a una tecnología que antes era exclusiva de especialistas, permitiendo que personas de todos los campos descubrieran su potencial.

En el camino hacia este hito, también hubo intentos fallidos que dejaron lecciones importantes. Por ejemplo, Meta lanzó Galactica, un asistente científico entrenado con millones de publicaciones académicas. Aunque prometía que sería como tener el conocimiento científico humano al alcance, pronto quedó claro que generaba muchas “alucinaciones” –respuestas que parecían creíbles, pero eran incorrectas, irrelevantes o inventadas–. Esto se debe a que los modelos de lenguaje están diseñados para predecir la próxima palabra o secuencia basándose en patrones de su entrenamiento, pero no siempre entienden el contexto completo ni pueden verificar la veracidad de la información. Como resultado, Galactica fue retirado solo tres días después de su lanzamiento. Este episodio subrayó la importancia de desarrollar mecanismos más robustos para mitigar los errores en sistemas de IA, especialmente aquellos destinados a usos críticos como la investigación científica, donde un error puede tener implicaciones graves.

Por su parte, OpenAI logró un éxito meteórico con ChatGPT, superando modelos como BERT de Google. Si bien la versión inicial de GPT-3 tenía problemas con alucinaciones, esto no detuvo su adopción masiva. Como alguna vez dijo el escritor de ciencia ficción Arthur C. Clarke: “Cualquier tecnología lo suficientemente avanzada es indistinguible de la magia”. Y eso fue exactamente lo que ocurrió: la tecnología avanzó tan rápido que mucha gente no tuvo tiempo de estudiarla y entenderla. Sin embargo, comprender cómo funcionan las cosas facilita su uso y reduce errores, algo esencial en este nuevo contexto. Por ejemplo, aunque los primeros usuarios reportaron confusión al interactuar con los modelos, pronto surgieron guías y estrategias para maximizar su efectividad, incluyendo el uso de *prompts* más claros y específicos.

Vimos abogados y jueces consultando sus casos con estas herramientas, medios de comunicación usándolas para generar titulares sensacionalistas como “Así será el fin del mundo según la IA” y maestros preocupados porque sus estudiantes producían trabajos impecables de la noche a la mañana. Todo esto ocurrió con una versión de ChatGPT que ni siquiera era tan avanzada como los modelos actuales. Esto también desató debates sobre la regulación de la IA, con predicciones fatalistas de un futuro apocalíptico digno de Hollywood. Sin embargo, a pesar de las preocupaciones, también surgieron usos innovadores en la educación, la medicina y los negocios. Por ejemplo, estudiantes que antes tenían dificultades para expresarse en ensayos encontraron en la IA una herramienta para mejorar su escritura, mientras que profesionales en medicina comenzaron a explorar su potencial para analizar datos complejos en tiempo récord. Empresas pequeñas y grandes también adoptaron estas herramientas para optimizar procesos internos, mejorar el servicio al cliente y acelerar la investigación y el desarrollo.

A pesar de estas controversias, la tecnología continúa evolucionando. Las redes neuronales profundas que sustentan los transformadores, junto con los circuitos integrados (*chips*) más avanzados para cálculos matriciales, han permitido avances impresionantes. Hoy tenemos modelos multimodales que no solo generan texto, sino también imágenes, voz y



videos. Además, estos modelos han sido potenciados con mecanismos que les permiten “razonar”, reduciendo las alucinaciones y produciendo respuestas más precisas. Estas capacidades han abierto nuevas puertas en campos como la atención médica, donde modelos multimodales son capaces de analizar imágenes diagnósticas y correlacionar datos médicos para proporcionar diagnósticos preliminares que complementan el trabajo de los profesionales de la salud. También se está investigando su aplicación en el diseño de medicamentos, acelerando los procesos que antes tomaban años.

Grandes tecnologías como las de ChatGTP de OpenAI, LLAMA de Meta, Gemini de Google, Grok de X, Claude de Anthropic lideran este campo. También se ha renovado el interés en los agentes, una tecnología antigua ahora combinada con modelos de lenguaje para automatizar procesos que antes requerían equipos humanos. Por ejemplo, es posible analizar miles de páginas de documentos en minutos usando técnicas como RAG (generación aumentada por recuperación) y modelos como Gemini, que poseen una ventana de contexto más amplia que otros modelos. De manera similar, los modelos multimodales pueden analizar imágenes diagnósticas y correlacionar información de maneras que a un equipo humano le tomaría semanas. Estos avances también están facilitando la adopción de nuevas tecnologías en industrias tradicionales, permitiendo a las empresas reducir costos y aumentar la eficiencia. En sectores como la agricultura, los modelos de IA están ayudando a monitorear cultivos, predecir rendimientos y optimizar el uso de recursos como el agua y los fertilizantes.

La tecnología avanza rápidamente, mientras el resto del mundo trata de mantenerse al día. Universidades, colegios, empresas y profesionales de todas las áreas pueden optimizar su tiempo y ser más precisos al usar estas herramientas. Pero, para aprovecharlas correctamente, es fundamental aprender cómo comunicarse con estos modelos. Una comunicación efectiva con los modelos de IA no solo mejora los resultados, sino que también permite a los usuarios adaptarse a un entorno tecnológico en constante cambio, creando oportunidades para la innovación. En la

educación, por ejemplo, profesores están comenzando a integrar la IA en sus aulas para personalizar la enseñanza y brindar retroalimentación más rápida y precisa a los estudiantes.

Este libro tiene como objetivo ayudar a cualquier persona, sin importar su nivel de conocimiento previo, a entender y a utilizar esta tecnología para mejorar su vida y adquirir “superpoderes”. A través de ejemplos prácticos, explicaciones claras y consejos útiles, espero que este texto se convierta en una herramienta indispensable para quienes deseen explorar el fascinante mundo de la IA. Espero que disfruten leyéndolo tanto como yo disfruté escribiéndolo, y que encuentren en estas páginas no solo información, sino inspiración para aprovechar al máximo el poder de la tecnología.



Introducción

Un poco de historia



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

La trayectoria de la inteligencia artificial (IA) ha marcado una transformación paradigmática en la relación entre la cognición humana y las capacidades computacionales. Este avance tecnológico ha surgido de la confluencia entre la innovación algorítmica y el deseo humano de expandir los límites del intelecto artificial. La conceptualización inicial de la IA, impulsada por figuras visionarias como Alan Turing, sentó las bases teóricas para una revolución computacional que sigue transformando nuestro mundo.

Un hito clave en la historia de la IA fue el encuentro en Dartmouth College en 1956, donde John McCarthy acuñó el término “inteligencia artificial”. Este evento marcó el inicio formal de una disciplina interdisciplinaria que combina matemáticas, computación y ciencias cognitivas. Las primeras aplicaciones de la IA, aunque prometedoras, también revelaron las limitaciones de la tecnología emergente. Proyectos como la traducción automática evidenciaron la complejidad de emular procesos cognitivos humanos, destacando los desafíos técnicos y conceptuales por superar.

Los denominados “inviernos de la IA” durante las décadas de 1970 y 1980 representaron períodos de estancamiento, donde las expectativas no cumplidas y la reducción de financiamiento llevaron a una reevaluación de los paradigmas existentes. En particular, los sistemas basados en reglas predeterminadas mostraron ser insuficientes para abordar problemas complejos como el procesamiento del lenguaje natural. Sin embargo, estas dificultades impulsaron una evolución metodológica, sentando las bases para futuros avances.

El renacimiento de la IA en las décadas de 1990 y 2000 trajo consigo un cambio de paradigma con la adopción del aprendizaje automático. Este enfoque permitió la creación de sistemas capaces de aprender y mejorar a través de la retroalimentación iterativa, para marcar una ruptura significativa respecto a los modelos anteriores. La década de 2010 vio la consolidación del aprendizaje profundo, con el desarrollo de redes neuronales profundas que impulsaron avances en procesamiento visual, comprensión del lenguaje y estrategias complejas, como las aplicadas en el juego Go.

Hoy en día, la IA está integrada en nuestra sociedad de maneras diversas y transformadoras. Desde la automatización en servicios profesionales y la optimización en sistemas de salud hasta la personalización educativa y las predicciones en infraestructuras de transporte, su impacto es evidente en casi todos los aspectos de la vida moderna. A pesar de estos avances, la búsqueda de una inteligencia artificial general (AGI) sigue

siendo un objetivo distante pero inspirador, que motiva investigaciones en redes neuronales escalables, aprendizaje multimodal, interfaces adaptativas y razonamiento abstracto.

Las proyecciones actuales sugieren una innovación acelerada, con la convergencia entre unas capacidades computacionales avanzadas y una comprensión contextual sofisticada. Esta evolución reconfigura constantemente las interacciones entre humanos y máquinas, ampliando las posibilidades de la cognición artificial y la automatización inteligente.

Los albores de la inteligencia artificial

El surgimiento de la IA representa una confluencia extraordinaria de innovación conceptual y avances tecnológicos fundamentales que definieron los cimientos de esta disciplina. Esta fase inicial se caracterizó por una convergencia entre el optimismo visionario y la rigurosa investigación científica en torno a la emulación computacional del pensamiento humano.

La trayectoria evolutiva de la IA encuentra su génesis en 1936, cuando Alan Turing, matemático británico de excepcional perspicacia, propuso su revolucionario modelo de computación abstracta, posteriormente denominado Máquina de Turing. Su conceptualización trascendió significativamente el ámbito de la informática teórica, estableciendo el marco conceptual para la investigación posterior en sistemas inteligentes. La visión de Turing anticipó sistemas computacionales capaces no solo de realizar operaciones aritméticas, sino de exhibir capacidades cognitivas análogas al razonamiento humano.

La contribución paradigmática de Turing al campo emergente de la computación y la IA merece un análisis particular. Su trabajo criptográfico durante la Segunda Guerra Mundial, específicamente en la decodificación del sistema Enigma, no solo tuvo implicaciones geopolíticas significativas, sino que estableció precedentes metodológicos fundamentales para la informática contemporánea. Sin embargo, la

trayectoria profesional de Turing se vio truncada por la persecución institucional debido a su orientación sexual, culminando en su trágico fallecimiento en 1954, un evento que privó al campo de uno de sus más brillantes teóricos.

El punto de inflexión definitivo en la institucionalización de la IA como disciplina académica se materializó en el ya mentado encuentro de 1956 con el histórico Taller de Verano de Dartmouth. Este evento seminal, organizado por figuras prominentes como John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude Shannon, estableció no solo la nomenclatura formal del campo sino también su marco metodológico fundamental. McCarthy, al acuñar el término “inteligencia artificial”, catalizó la consolidación de una comunidad académica dedicada a la exploración sistemática del potencial computacional.

Las implementaciones iniciales en IA se centraron en la automatización de procesos cognitivos específicos. Un ejemplo paradigmático fue la Máquina de Aprendizaje de Arthur Samuel (1952), la cual demostró capacidades de aprendizaje iterativo en el contexto del juego de damas, representando una de las primeras manifestaciones tangibles del aprendizaje automático. Paralelamente, el Programa de Lógica Teórica desarrollado por Allen Newell y Herbert A. Simon en 1955 estableció precedentes significativos en la automatización del razonamiento matemático.

Esta evolución inicial de la IA refleja una transformación fundamental en nuestra conceptualización de la inteligencia y la computación, estableciendo las bases para los desarrollos tecnológicos contemporáneos que continúan redefiniendo los paradigmas de interacción humano-máquina y las fronteras del conocimiento computacional.

Del perceptrón a los sistemas cognitivos avanzados

La introducción del perceptrón por Frank Rosenblatt en 1957 marcó un punto de inflexión fundamental en la evolución de los sistemas



computacionales cognitivos. Este modelo biomimético, inspirado en la arquitectura neuronal del cerebro humano, estableció los fundamentos matemáticos y conceptuales para el desarrollo posterior de arquitecturas de aprendizaje profundo y reconocimiento de patrones. No obstante, la significancia del perceptrón trasciende su implementación técnica inicial, representando una transformación paradigmática en nuestra comprensión de la capacidad de las máquinas para emular procesos cognitivos fundamentales.

Esta fase inicial de innovación tecnológica se caracterizó por una dinámica dual de optimismo y restricciones técnicas significativas, en términos generales, esta etapa se distinguió por la aparición de computadores con la capacidad de ejecutar un elevado volumen de operaciones matemáticas en intervalos de tiempo relativamente breves, lo que representó un avance significativo en el procesamiento de datos. Los investigadores pioneros enfrentaron limitaciones sustanciales en infraestructura computacional y estructuras o entornos de trabajo que permitieran diseñar, implementar y reutilizar algoritmos de manera sistemática, operando en un contexto de recursos tecnológicos restringidos que acotaban la complejidad de las implementaciones prácticas. No obstante, estas restricciones catalizaron innovaciones metodológicas fundamentales que continúan influyendo en el desarrollo contemporáneo de sistemas de IA.

La denominada “Edad Dorada” de la IA, que se extendió desde finales de los años 50 hasta principios de los 70 del siglo pasado, representa una convergencia extraordinaria de avances teóricos y aplicaciones prácticas. Este período presenció una aceleración sin precedentes en la investigación y desarrollo de sistemas autónomos de resolución de problemas, marcando el inicio de una transformación tecnológica fundamental.

La creación del Logic Theorist por Newell, Simon y Shaw en 1956 estableció un precedente significativo en la automatización del razonamiento matemáticoⁱⁱⁱ. Este sistema, pionero en su capacidad para

abordar problemas abstractos mediante métodos heurísticos sofisticados (técnicas de búsqueda o resolución de problemas que no garantizan una solución óptima, pero que suelen encontrar buenas soluciones en un tiempo razonable), demostró la viabilidad de implementar procesos cognitivos complejos en sistemas computacionales.

La evolución subsecuente hacia el General Problem Solver (GPS) en 1957 representó un avance metodológico fundamental en la conceptualización de sistemas de resolución de problemas. El GPS introdujo principios de descomposición jerárquica y heurística adaptativa que revolucionaron nuestra comprensión de la automatización cognitiva. Esta aproximación sistemática a la resolución de problemas estableció paradigmas fundamentales que continúan informando el desarrollo de sistemas de IA contemporáneos. Paralelamente, los avances en procesamiento del lenguaje natural y traducción automática durante este período ilustran la complejidad inherente a la implementación de capacidades cognitivas avanzadas en sistemas computacionales. Aunque las limitaciones técnicas de la época restringieron la efectividad práctica de estas implementaciones iniciales, establecieron metodologías esenciales para el desarrollo posterior de sistemas de procesamiento lingüístico más sofisticados.

Esta convergencia de innovaciones metodológicas y avances técnicos durante la Edad Dorada estableció las bases para la revolución tecnológica contemporánea en IA, lo cual ilustra la naturaleza transformativa de la investigación pionera en sistemas cognitivos artificiales.

La introducción de ELIZA por Joseph Weizenbaum en 1966 representa un avance fundamental en la evolución de los sistemas de procesamiento del lenguaje natural. Este sistema, aunque estaba fundamentado en mecanismos relativamente básicos de correspondencia de patrones, estableció precedentes significativos en la conceptualización de interfaces conversacionales humano-máquina. La aparente sofisticación de ELIZA en la simulación de interacciones terapéuticas ilustra la compleja intersección entre percepción humana y capacidad computacional real.



La denominada Edad Dorada de la IA también se caracterizó por una transformación paradigmática que combinó un avance tecnológico acelerado con limitaciones estructurales significativas. Durante esta fase se manifestaron varios patrones clave en la evolución de los sistemas cognitivos artificiales. Por un lado, hubo una aceleración exponencial en las expectativas tecnológicas, que contrastaba con una creciente complejidad en la implementación de sistemas adaptativos. Asimismo, emergieron brechas significativas entre la visión teórica y las capacidades técnicas reales, lo que llevó a una transformación fundamental en los paradigmas de desarrollo.

La transición hacia los llamados “inviernos de la IA” marcó un punto de inflexión crítico en la trayectoria evolutiva del campo. El primer periodo de desaceleración, que como se mencionó comenzó en la década de 1970, surgió como resultado de varias limitaciones fundamentales. Entre ellas se destacaron la insuficiente capacidad computacional disponible en ese momento y la complejidad no anticipada del procesamiento lingüístico. Además, se observó una divergencia creciente entre las altas expectativas generadas y los resultados tangibles obtenidos, lo que motivó una reevaluación crítica de los paradigmas metodológicos establecidos.

Dos eventos académicos relevantes catalizaron esta reevaluación: el informe ALPAC de 1966 y la publicación de *Perceptrons* en 1969. Ambos documentos pusieron de manifiesto las limitaciones estructurales inherentes a las aproximaciones predominantes en la IA de la época. Estas limitaciones incluyeron deficiencias en la capacidad de procesamiento lingüístico, restricciones en las arquitecturas de redes neuronales tempranas, problemas con los paradigmas de reconocimiento de patrones y fallos en los *frameworks* metodológicos vigentes.

El segundo invierno de la IA, ocurrido en la década de 1980, emergió en un contexto de complejidad creciente en el desarrollo de sistemas expertos. Este periodo ilustró desafíos fundamentales:

- Costos elevados de desarrollo y mantenimiento.
- Limitaciones en adaptabilidad y generalización.
- Necesidad de reconfiguración metodológica.
- Imperativos de innovación tecnológica.

Estos periodos de desaceleración, aunque aparentemente restrictivos, facilitaron una transformación fundamental en la conceptualización y desarrollo de sistemas de IA. La reevaluación crítica de paradigmas establecidos y la identificación de limitaciones estructurales establecieron las bases metodológicas para las innovaciones subsecuentes en el campo.

Esta trayectoria histórica ilustra patrones recurrentes en la evolución tecnológica: ciclos de optimismo inicial, reconocimiento de limitaciones estructurales, y subsecuente recalibración de aproximaciones metodológicas. La comprensión de estos patrones resulta fundamental para anticipar y navegar transformaciones tecnológicas contemporáneas en IA.

La transformación del aprendizaje automático

La evolución de la IA experimentó una transformación radical durante las décadas de 1980 y 1990, un periodo que marcó el resurgimiento de esta disciplina tras sus inviernos más oscuros. Este renacimiento tecnológico, catalizado por la emergencia del aprendizaje automático, representó mucho más que una simple evolución técnica, constituyó una reconceptualización fundamental de nuestra comprensión sobre la capacidad de las máquinas para aprender y adaptarse.

El paradigma del aprendizaje automático introdujo una perspectiva revolucionaria, a saber: la posibilidad de que los sistemas computacionales desarrollaran capacidades adaptativas sin necesidad de programación explícita para cada tarea. Esta transformación metodológica permitió superar las limitaciones estructurales que habían caracterizado las



aproximaciones anteriores, lo cual inauguró una nueva era en el desarrollo de sistemas inteligentes.

Un momento fundamental en esta trayectoria evolutiva fue la introducción del algoritmo de retropropagación en 1986 por Rumelhart, Hinton y Williams (premio Nobel 2024). Este avance revolucionó el campo de las redes neuronales artificiales, permitiendo ajustes dinámicos en sus estructuras internas mediante procesos de optimización iterativa. La capacidad de estas redes para minimizar errores predictivos de manera autónoma representó un salto enorme en la sofisticación de los sistemas de aprendizaje.

La década de 1990 presenció una proliferación extraordinaria de innovaciones metodológicas. La introducción de las máquinas de soporte vectorial por Vladimir Vapnik ejemplifica la profundidad de esta transformación técnica. Estos avances coincidieron con una expansión significativa en capacidad computacional y disponibilidad de datos, creando un ecosistema propicio para el desarrollo de sistemas cada vez más sofisticados.

La manifestación más emblemática de esta revolución tecnológica se materializó en el sistema IBM Watson. Su triunfo en *Jeopardy!* en 2011 no solo representó una victoria en un concurso televisivo, sino que demostró la maduración de capacidades fundamentales en el procesamiento de lenguaje natural y el análisis contextual complejo. Watson ejemplificó la convergencia de múltiples avances en aprendizaje automático, por lo que se establecieron nuevos paradigmas en la interacción entre sistemas artificiales y conocimiento humano.

La transición subsecuente hacia arquitecturas de aprendizaje profundo representa una evolución natural de estos fundamentos. Esta nueva generación de sistemas, caracterizada por redes neuronales de múltiples capas, ha expandido dramáticamente los horizontes de la IA. Su capacidad para procesar y abstraer patrones complejos en diversos dominios ha catalizado una nueva ola de innovaciones, desde el reconocimiento visual

hasta la comprensión lingüística avanzada. Esta trayectoria evolutiva ilustra patrones recurrentes en la transformación tecnológica: ciclos de innovación metodológica seguidos por expansiones exponenciales en capacidad aplicativa. La convergencia entre disponibilidad de datos masivos, poder computacional aumentado y *frameworks* algorítmicos sofisticados ha establecido las bases para una nueva era en el desarrollo de sistemas inteligentes.

El resurgimiento del aprendizaje automático no solo revitalizó el campo de la inteligencia artificial, sino que redefinió fundamentalmente nuestra comprensión sobre las posibilidades y limitaciones de los sistemas cognitivos artificiales. Esta transformación continúa resonando en el desarrollo contemporáneo de tecnologías inteligentes, sugiriendo trayectorias evolutivas cada vez más sofisticadas en la intersección entre capacidad computacional y cognición artificial.

El panorama de la inteligencia artificial ha experimentado una transformación radical con el surgimiento del aprendizaje automático y, posteriormente, el aprendizaje profundo, catalizando una revolución tecnológica sin precedentes. Esta evolución ha permeado diversos sectores industriales, desde la atención médica personalizada hasta los sistemas educativos adaptativos, reconfigurando fundamentalmente nuestros modelos de trabajo y vida cotidiana.

La era contemporánea de la IA, caracterizada por el dominio del aprendizaje profundo, representa un salto en nuestra capacidad para abordar desafíos complejos. Las arquitecturas neuronales avanzadas, particularmente los modelos *transformer*, han revolucionado nuestra comprensión de las capacidades cognitivas artificiales. Esta nueva frontera tecnológica no solo ha superado las limitaciones históricas en el procesamiento del lenguaje natural y la visión por computadora, sino que ha establecido nuevos paradigmas en la toma de decisiones algorítmica.



El núcleo de esta revolución reside en la sofisticada arquitectura del aprendizaje profundo, fundamentada en redes neuronales multicapa que emulan, de manera abstracta, los procesos cognitivos biológicos. La convergencia de estos avances con la proliferación de unidades de procesamiento gráfico de alta potencia ha catalizado un progreso exponencial en el campo, permitiendo el entrenamiento de modelos cada vez más complejos y capaces. Este desarrollo tecnológico representa no solo un avance técnico, sino una reconfiguración fundamental de las posibilidades en la interacción humano-máquina y la automatización inteligente.

El rol de las GPU

Las unidades de procesamiento gráfico (GPU, por sus siglas en inglés) han jugado un papel fundamental en el resurgimiento de la IA moderna. Originalmente diseñadas para el procesamiento de gráficos en videojuegos y aplicaciones 3D, las GPU son coprocesadores altamente especializados que manejan operaciones de punto flotante y paralelizan el procesamiento de datos. En sistemas informáticos, el punto flotante es un formato usado para representar números reales (con decimales) de manera eficiente. Funciona dividiendo un número en tres partes: el signo (positivo o negativo), la mantisa (la parte significativa del número) y el exponente (que indica la escala o posición del punto decimal). Este formato permite representar números muy grandes o muy pequeños, como 3.14 o 0.00000123 utilizando un espacio limitado en la memoria.

Esta capacidad de procesamiento paralelo permite a las GPU ejecutar múltiples operaciones simultáneamente, lo que es esencial para el entrenamiento de grandes modelos de aprendizaje profundo. En comparación con las unidades centrales de procesamiento (CPU), las GPU están optimizadas para manejar tareas de cálculo intensivo, como las que se encuentran en el aprendizaje profundo. Mientras que las CPU son excelentes para una amplia variedad de tareas, las GPU sobresalen en el procesamiento de grandes volúmenes de datos gráficos y numéricos debido a su arquitectura segmentada y su capacidad para ejecutar

cálculos en paralelo. Esto ha permitido a los investigadores entrenar modelos más grandes y complejos en menos tiempo, acelerando el ritmo de la innovación en IA.

El *transformer*: un cambio de paradigma

En los métodos tradicionales de IA, como las redes neuronales recurrentes (RNN), se procesaban las palabras una por una, de izquierda a derecha, como si leyeras la frase lentamente. Este enfoque parecía lógico, pero tenía una gran limitación, a medida que el modelo avanzaba en la frase, iba olvidando detalles importantes del principio. Por otro lado, existían las redes neuronales convolucionales (CNN), que funcionan muy bien para analizar imágenes porque procesan información en pequeños bloques. Sin embargo, cuando se aplicaban al texto, estas redes solo podían analizar fragmentos pequeños, perdiéndose las conexiones entre palabras que estaban lejos unas de otras.

Aquí es donde entra el *transformer* que revolucionó todo. Este modelo no procesa el texto palabra por palabra ni por bloques pequeños, sino que mira toda la oración o párrafo al mismo tiempo y decide cuáles son las partes más importantes. Lo hace utilizando un mecanismo llamado “atención”. Para entender mejor, se puede imaginar estar viendo una obra de teatro donde varios actores están en el escenario. No se puede mirar a todos al mismo tiempo, pero se decide enfocarse en los actores más relevantes para entender la historia. El *transformer* hace algo similar, analiza todas las palabras de una oración y calcula cuánto deberían influir unas palabras en otras. Por ejemplo, si está procesando la palabra *comió* en la frase “El gato que atrapó el ratón comió su premio”, el modelo puede identificar que *comió* está relacionado con *gato*, y no con *ratón*, porque entiende las conexiones gramaticales y contextuales.

El *transformer* lleva esta idea aún más lejos con algo llamado “múltiples cabezas de atención”^{xii}. Volviendo al ejemplo del teatro, se tienen varias linternas, y cada una se enfoca en un aspecto diferente: una podría observar el actor principal, otra los detalles del vestuario y otra

los movimientos en el fondo del escenario. De manera similar, en el *transformer*, cada cabeza de atención se encarga de analizar diferentes aspectos del texto. Una puede enfocarse en los sujetos, otra en los tiempos verbales y otra en las palabras que dan contexto adicional. Al combinar toda esta información, el modelo construye una comprensión mucho más rica de lo que está procesando.

Además, una de las grandes ventajas del *transformer* es que no tiene que leer el texto palabra por palabra. En lugar de eso, analiza todo simultáneamente, lo que lo hace mucho más rápido. Esta capacidad de procesar el texto en paralelo es crucial para entrenar modelos enormes, que son los que permiten aplicaciones como la traducción automática, la generación de texto o, incluso, las herramientas que completan tus correos electrónicos.

Para llevar esto a un ejemplo práctico, se piensa en Google Translate. Antes del *transformer*, los traductores automáticos solían traducir palabra por palabra, y el resultado a menudo no tenía mucho sentido. Con el *transformer*, el sistema entiende todo el contexto de la oración o incluso del párrafo antes de generar la traducción, lo que hace que el resultado sea mucho más natural y preciso. Esto también se aplica a modelos como ChatGTP, que pueden generar texto coherente porque analizan toda la conversación para decidir qué es relevante en cada momento.

Si seguimos con las metáforas, el *transformer* es como una orquesta donde cada músico representa una palabra y el director tiene la capacidad de prestar atención a los instrumentos más importantes según lo que se esté tocando. Mientras que en los métodos antiguos el director solo podía escuchar a un músico a la vez o en pequeños grupos, el *transformer* permite que escuche a toda la orquesta al mismo tiempo y ajuste su enfoque según lo que sea más relevante en cada instante.

Con estas capacidades, el *transformer* no solo mejora las tareas de procesamiento del lenguaje, sino que también está empezando a usarse en áreas como análisis de imágenes o reconocimiento de voz, donde encontrar patrones complejos es igual de importante.

El impacto en el procesamiento del lenguaje natural

El *transformer* ha revolucionado el campo del procesamiento del lenguaje natural (NLP, por sus siglas en inglés), estableciendo nuevos estándares en tareas como la traducción automática, la generación de texto y la respuesta a preguntas. Su capacidad para manejar dependencias a largo plazo y su eficiencia computacional han permitido avances significativos en la calidad de los modelos de lenguaje.

El uso de modelos basados en el *transformer* ha llevado a la creación de modelos de lenguaje como BERT (*Bidirectional Encoder Representations from Transformers*) y GPT (Generative Pre-trained Transformer). Estos modelos han demostrado ser extremadamente efectivos en una amplia gama de tareas de NLP, desde la clasificación de texto hasta la generación de contenido coherente y relevante.

Generación de imágenes con modelos de difusión

Además del procesamiento del lenguaje, la era moderna de la IA ha visto avances impresionantes en la generación de imágenes. Los modelos de difusión, como Stable Diffusion y DALL-E, han revolucionado la manera en que las máquinas pueden crear imágenes a partir de descripciones textuales. Estos modelos utilizan procesos de difusión que gradualmente transforman ruido aleatorio en imágenes coherentes y detalladas, siguiendo las especificaciones proporcionadas por el usuario. Stable Diffusion y DALL-E emplean redes neuronales profundas que han sido entrenadas en enormes conjuntos de datos de imágenes y texto. Estos modelos pueden generar imágenes de alta calidad que reflejan con precisión las descripciones textuales, abriendo nuevas posibilidades en campos como el arte, el diseño gráfico y la publicidad.



Generación de video y música

La IA también ha avanzado en la generación de video y música. Modelos como Sora pueden crear videos realistas a partir de guiones o descripciones textuales, mientras que otros sistemas son capaces de componer música original en diversos estilos y géneros. Estas tecnologías están transformando la industria del entretenimiento, permitiendo la creación de contenido audiovisual de manera más rápida y eficiente. La generación de video implica la utilización de técnicas de aprendizaje profundo que pueden producir secuencias de imágenes que forman un video coherente. En la música, modelos como OpenAI's Jukebox y Magenta utilizan redes neuronales para analizar patrones en la música y generar nuevas composiciones que son de manera sorprendente creativas y variadas.

Modelos multimodales

Los modelos multimodales representan otro avance crucial en la IA moderna. Estos modelos pueden procesar y generar datos en múltiples formatos simultáneamente, como texto, imágenes, audio y video. Al integrar información de diferentes modalidades, estos modelos pueden comprender contextos más ricos y ofrecer respuestas y soluciones más precisas.

Por ejemplo, un modelo multimodal puede interpretar una descripción textual, generar una imagen basada en esa descripción y, luego, crear un video que narre una historia a partir de la imagen. Esta capacidad para cruzar y combinar diferentes tipos de datos está ampliando las aplicaciones de la IA en áreas como la educación, la investigación científica y la atención médica.

Modelos de expertos mixtos (MoEs)

Los modelos de expertos mixtos (MoEs, por sus siglas en inglés) son otro avance significativo en la IA. Estos modelos dividen tareas

complejas entre diferentes submodelos especializados, conocidos como “expertos”. Cada experto se enfoca en una parte específica del problema, y un “enrutador” decide qué expertos deben abordar cada tarea.

Esta arquitectura permite una escalabilidad eficiente y puede mejorar significativamente el rendimiento en tareas complejas. Los MoEs son especialmente útiles en aplicaciones que requieren una combinación de habilidades especializadas, como el análisis de grandes volúmenes de datos, la predicción de tendencias en mercados financieros o la interpretación de imágenes médicas.

El futuro de la IA: un horizonte de posibilidades

A medida que avanzamos en el desarrollo de la IA, nos enfrentamos a un futuro lleno de posibilidades emocionantes y desafíos profundos. La IA ha recorrido un largo camino desde sus inicios, y aunque se inspira en el cerebro humano, la inteligencia artificial y la inteligencia humana son conceptos fundamentalmente diferentes. Esta diferencia se vuelve evidente cuando consideramos tanto las limitaciones actuales de nuestra comprensión del cerebro como las propiedades emergentes que observamos en los sistemas de IA.

El cerebro humano ha sido una fuente de inspiración para el desarrollo de la IA. Las redes neuronales, los mecanismos de atención y otros algoritmos de aprendizaje profundo están diseñados para imitar ciertos aspectos del funcionamiento cerebral. Sin embargo, hay muchas cosas sobre el cerebro que todavía no entendemos completamente. La manera en que emergen la conciencia, la intuición y otras funciones superiores sigue siendo un misterio en gran medida. De manera similar, los sistemas de IA también presentan propiedades emergentes que no comprendemos completamente. Por ejemplo, los modelos de lenguaje como GPT, entrenados exclusivamente en grandes volúmenes de texto, pueden realizar tareas para las que no fueron explícitamente programados. Pueden traducir textos, analizar sentimientos y mostrar un tipo primigenio de razonamiento, todo a partir de su entrenamiento



inicial. Estas capacidades emergentes desafían nuestras expectativas y nos muestran que la IA puede desarrollar habilidades de maneras que no anticipamos.

La singularidad y la evolución de la IA

Un gran número de expertos en IA discuten la posibilidad de alcanzar una AGI, una forma de IA que iguale o supere la inteligencia humana en todos los aspectos. Sin embargo, predecir la naturaleza exacta de una futura AGI es como tratar de prever la siguiente rama en la evolución de los pulpos o delfines. ¿Serán estas futuras inteligencias artificiales tan inteligentes como los humanos modernos? La verdad es que no podemos saberlo con certeza.

La IA aprende a partir de datos y utiliza algoritmos avanzados que modelan funciones complejas dentro de lo que llamamos una “caja negra”. Al final del día, lo que resulta de este proceso puede ser algo completamente inesperado y fuera de nuestra imaginación actual. Este fenómeno es conocido como la singularidad, un punto en el cual los sistemas de IA evolucionarán y se adaptarán de maneras que no podemos prever. Así como en biología la adaptación y evolución han permitido innumerables formas de vida, la singularidad en la IA permitirá una evolución futura de estos sistemas hacia nuevas formas de inteligencia.

La idea de la singularidad tiene su origen en las Matemáticas y describe algo que se comporta de manera extraña o impredecible. Por ejemplo, imagina una función que explota, que se va a infinito, como si el sistema se rompiera en ese punto. Eso pasa en las matemáticas cuando ciertas fórmulas dejan de tener sentido en algunos momentos específicos. Esta idea también se usa en Física, como en los agujeros negros, donde la gravedad es tan fuerte que las leyes normales de la naturaleza ya no funcionan como esperamos.

Cuando se habla de singularidad en inteligencia artificial, es diferente, pero la idea sigue siendo similar. Aquí nos referimos a un momento

hipotético en el futuro donde las máquinas serían tan inteligentes que superarían la capacidad de los seres humanos. A partir de ahí, todo lo que conocemos podría cambiar de forma tan rápida y radical que no seríamos capaces de entender ni controlar lo que vendría después. Es como si el sistema del mundo, tal como lo conocemos, “explotara” hacia un estado completamente nuevo. Algunos ven esto como algo positivo, una oportunidad para resolver grandes problemas, como enfermedades o la contaminación global, porque esas máquinas súperinteligentes podrían encontrar soluciones que nosotros no hemos podido. Otros, sin embargo, tienen miedo de lo que pasaría si las máquinas actúan de forma que no podamos manejar, porque podrían tomar decisiones que no necesariamente serían buenas para nosotros. En ambos casos, la singularidad, tanto en matemáticas como en IA, representa un punto donde las cosas dejan de comportarse como estamos acostumbrados. Es como una barrera que, al cruzarla, nos lleva a un territorio desconocido. Por eso es un tema tan fascinante, pero también tan polémico.

Pero y ¿de qué va este libro?

Interactuar con modelos de IA puede resultar frustrante en ocasiones, ya que muchos de estos modelos dependen del contexto proporcionado para generar respuestas, sean estos en forma de imágenes, textos, melodías, etc. Este contexto se denomina “*prompts*” o instrucciones. La ingeniería de *prompts* consiste en diseñar consultas o instrucciones adecuadas y específicas para que los modelos de IA proporcionen respuestas precisas y relevantes, manteniendo a la vez su capacidad para informar y ser creativos.

La ingeniería de *prompts* es una disciplina emergente en el campo de la IA que se centra en la creación y optimización de instrucciones o *prompts* para guiar el comportamiento de modelos de lenguaje avanzados. Estos modelos, como ChatGPT, generan respuestas basadas en las indicaciones que reciben; por lo tanto, la formulación precisa de estas instrucciones es esencial para obtener resultados coherentes y relevantes. La ingeniería de *prompts* no solo implica la redacción de preguntas claras, sino también



la estructuración de contextos y ejemplos que orienten adecuadamente al modelo en la tarea solicitada. Esta práctica se utiliza en una amplia gama de aplicaciones. En el ámbito educativo, permite a los estudiantes interactuar con sistemas de IA para obtener explicaciones detalladas sobre diversos temas, facilitando el aprendizaje autónomo. En el sector empresarial, se emplea para automatizar la generación de informes, resúmenes y análisis de datos, optimizando procesos y reduciendo tiempos de respuesta. Además, en el desarrollo de *chatbots* y asistentes virtuales la ingeniería de *prompts* es fundamental para mejorar la calidad de las interacciones, proporcionando respuestas más precisas y contextualmente adecuadas.

La importancia de la ingeniería de *prompts* radica en su capacidad para maximizar el potencial de los modelos de lenguaje. Una instrucción bien diseñada puede transformar una respuesta genérica en una solución específica y útil.

Esto es especialmente relevante en contextos donde la precisión es crítica, como en el ámbito médico o legal, donde una interpretación errónea puede tener consecuencias significativas. Además, una ingeniería de *prompts* efectiva contribuye a minimizar las “alucinaciones” de la IA, es decir, respuestas incorrectas o inventadas que los modelos pueden generar debido a instrucciones ambiguas o mal formuladas.

Comprender la ingeniería de *prompts* es esencial para interactuar eficazmente con tecnologías basadas en IA. Al aprender a formular preguntas claras y específicas, se puede obtener información más precisa y relevante, ya sea para tareas escolares, proyectos personales o simplemente para satisfacer su curiosidad. Esta habilidad también fomenta el pensamiento crítico, ya que implica analizar qué información se necesita y cómo solicitarla de manera efectiva. En un mundo cada vez más digitalizado, la capacidad de comunicarse con sistemas de IA se convierte en una competencia valiosa.

En resumen, la ingeniería de *prompts* es una herramienta poderosa que permite a los usuarios aprovechar al máximo las capacidades de los modelos de lenguaje de IA. Su aplicación adecuada facilita la obtención de respuestas precisas, mejora la eficiencia en diversas tareas y promueve una interacción más natural entre humanos y máquinas. A medida que la IA continúa integrándose en nuestra vida cotidiana, desarrollar habilidades en ingeniería de *prompts* se vuelve cada vez más relevante para todos, independientemente de su edad o formación técnica.



Los modelos de lenguaje

Los modelos de lenguaje son sistemas de IA diseñados para comprender y generar texto similar al que usamos los humanos. Imagina tener una conversación con una máquina que puede responder preguntas, contar historias o traducir idiomas; todo esto es posible gracias a estos modelos. Se entrenan con enormes cantidades de texto para aprender patrones y estructuras del lenguaje, permitiéndoles predecir palabras o frases y generar contenido coherente.

Redes neuronales

Imagínate que las redes neuronales son como un equipo gigante de pequeñas “calculadoras” que trabajan juntas para resolver problemas. Cada una de estas calculadoras, o neuronas, toma decisiones altamente simples, pero al conectarse con otras neuronas, forman una red capaz de entender cosas mucho más complejas. No están vivas, ni piensan como nosotros, pero sí pueden procesar información y reconocer patrones. Estas redes son modelos matemáticos inspirados en el cerebro. En el cerebro, las neuronas se conectan y se pasan información. En las redes neuronales artificiales, se simula ese proceso, aunque de forma más básica. La información entra en la red por una capa que reciben los datos, los procesan y, luego, pasan lo que encuentran importante a otras capas. Al final, la red da una respuesta basada en lo que aprendió.

Para que una red funcione bien, necesita entrenamiento. Se le da una cantidad inmensa de ejemplos y se le dice qué es correcto y qué no. La red va aprendiendo a partir de esos ejemplos y ajusta sus “conexiones” para mejorar cada vez que recibe nueva información. Es como cuando

estás aprendiendo algo: repites y ajustas, repites y ajustas una y otra vez hasta que logras hacerlo bien.

Un ejemplo sencillo: piensa en una red entrenada para reconocer fotos de gatos. Al principio, cuando no sabe nada, se equivoca bastante, pero después de ver miles de fotos, empieza a notar detalles importantes (orejas, bigotes, etc.). Cada vez que identifica un gato correctamente, se ajusta para ser más precisa. Al final, puede decir con bastante seguridad si una imagen tiene o no un gato, aunque sea un gato que nunca ha visto.

Cada red neuronal está estructurada en “capas” o niveles de procesamiento, que funcionan como filtros que refinan la información paso a paso. Puedes imaginar cada capa como una serie de pasos que un detective sigue para resolver un caso. La primera capa toma toda la información disponible de golpe, sin filtrar nada, y se encarga de procesar lo básico. Por ejemplo, si hablamos de una imagen, la primera capa solo ve los píxeles: puntitos de color o de luz en bruto que, sin un contexto, no dicen mucho. En una grabación de voz, esta capa solo escucharía sonidos sin entender las palabras o el significado. A medida que avanzamos en la red, las capas intermedias van “aprendiendo” a identificar patrones más complejos. En una imagen, las capas siguientes combinan los puntos básicos y empiezan a detectar líneas, bordes, formas o colores más definidos (el proceso de aprendizaje en las máquinas es diferente al de los animales superiores, incluidos los humanos; tal vez el error está en intentar entender la IA a cómo aprendemos nosotros, cuando en realidad son procesos completamente distintos. Las máquinas no tienen la misma estructura que los seres vivos, por lo que el aprendizaje en ellas debe entenderse en su propio contexto, distinto al de los organismos biológicos). Poco a poco, estas capas intermedias aprenden a identificar estructuras específicas como ojos, oídos o incluso la silueta de un animal si la red se está entrenando para reconocer gatos o perros. Aquí, la red empieza a “darse cuenta” de los detalles y a identificar qué elementos son más importantes y cuáles no tanto. En términos técnicos, esto se llama extracción de características, porque la red toma partes de la imagen que considera relevantes y deja fuera lo que no aporta mucho.



Cada capa profundiza más y hace un análisis más complejo de la información. Estas capas intermedias son como personas especializadas en diferentes tareas. Una capa puede ser buena reconociendo curvas, otra identifica patrones repetitivos y otra más entiende mejor los colores. Al pasar la información de capa en capa, la red va “entendiendo” mejor la imagen o los datos que está procesando. Cada vez que la información pasa por una capa, se filtra lo irrelevante y se enfoca más en las características importantes que permiten hacer una identificación más precisa.

Finalmente, tenemos la capa de salida, que es como el jefe del equipo de detectives que recibe toda la información procesada y decide el resultado final. En una red que identifica fotos de gatos, esta capa de salida es la que finalmente dirá: “sí, esto es un gato” o “no, esto no es un gato”. Esta capa está diseñada para dar una respuesta concreta basándose en todo el análisis que hicieron las capas anteriores. Cada capa tiene una función específica, y al trabajar en conjunto, logran que la red sea capaz de realizar tareas complejas como clasificar imágenes, reconocer palabras en una grabación o incluso predecir comportamientos. La estructura de capas es una de las razones por las que las redes neuronales son tan poderosas: cada capa tiene su especialidad y juntas crean un proceso de análisis que va de lo más simple a lo más detallado y específico.

Ahora, esto no es magia ni intuición. Cada neurona en la red es solo una ecuación matemática, y cuando todas están conectadas, forman un sistema complejo que, con suficiente entrenamiento, puede resolver problemas específicos. Empero, una red neuronal no va a pensar o tener ideas propias y tampoco transformará a los humanos en esclavos. Solo va a responder bien en lo que fue entrenada, siempre y cuando los datos que vea no sean muy diferentes de los ejemplos. Un detalle importante es que las redes neuronales pueden cometer errores, y en ocasiones cometen muchos errores, especialmente si los datos con los que fueron entrenadas son limitados o tienen ciertos sesgos. Por ejemplo, si entrenas una red con puras fotos de perros grandes, puede que luego tenga problemas identificando perros pequeños. Es algo



que los científicos están trabajando para mejorar, porque esos errores pueden ser graves cuando las redes se usan en cosas importantes como diagnóstico médico.

Las redes neuronales han pasado de ser una teoría matemática a una tecnología que nos rodea en la vida cotidiana, y tienen una enorme variedad de aplicaciones prácticas que nos facilitan el día a día. Una de sus aplicaciones más comunes es en el reconocimiento de voz en los teléfonos. Cuando dictas un mensaje de texto en tu celular, una red neuronal “escucha” y convierte tus palabras en texto escrito. ¿Cómo lo hace? La red ha sido entrenada con miles de horas de grabaciones de voz, lo que le permite entender patrones en los sonidos y asociarlos a palabras, incluso si tenemos distintos acentos, maneras de hablar o tonos de voz. Es una tarea compleja porque debe diferenciar palabras parecidas, entender el contexto y hasta captar el ritmo en el que hablamos, pero las redes neuronales lo han hecho posible.

Otro uso que seguramente reconoces está relacionado con las recomendaciones de contenido. Piensa en Netflix o YouTube, es decir: cada vez que ves una película o un video, el sistema registra tus gustos. Una red neuronal analiza esa información para buscar patrones en tus preferencias y compararlos con otros usuarios similares. Así, la red puede sugerirte contenido que, basándose en esos patrones, probablemente te interese. No es magia, es pura estadística: la red encuentra relaciones entre lo que ya has visto y lo que otros usuarios con gustos parecidos han disfrutado, y usa esa información para “adivinar” qué podría gustarte a ti.



REDES NEURONALES



Cálculos simples

Cada neurona toma decisiones simples



Entrenamiento

Se ajustan a partir de ejemplos

Inspiradas en el cerebro

Similan la forma en que las neuronas están conectadas

Entrenamiento

Se ajustan a partir de ejemplos

Capas de procesamiento

Refinan la información paso a paso



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Las redes neuronales también están presentes en los autos que se manejan solos. En este caso, la tecnología es incluso más impresionante porque el carro necesita “ver” el mundo a su alrededor. Para lograr esto, el auto tiene cámaras y sensores que capturan todo lo que sucede en su entorno, desde la carretera y las señales de tráfico hasta los peatones y otros vehículos. Aquí es donde entra la red neuronal: recibe esa enorme cantidad de datos en tiempo real, los procesa y reconoce patrones. Por ejemplo, puede identificar que una forma en movimiento es un peatón o que una luz roja es una señal de alto. Basándose en toda esa información, la red ayuda al sistema del automóvil a tomar decisiones: frenar, girar, acelerar o ceder el paso. Este proceso es increíblemente rápido y preciso, ya que un automóvil autónomo debe reaccionar en fracciones de segundo para mantener la seguridad.

Además de estos ejemplos, las redes neuronales también se utilizan en otros campos como la medicina, la seguridad y las finanzas. En la medicina, por ejemplo, se usan para analizar imágenes de radiografías

o resonancias magnéticas y detectar signos tempranos de enfermedades como el cáncer. La red neuronal ha sido entrenada para reconocer patrones específicos en las imágenes que pueden pasar desapercibidos para el ojo humano, y de este modo, ayuda a los médicos a realizar diagnósticos más rápidos y precisos.

En el ámbito de la seguridad, las redes neuronales permiten desarrollar sistemas de reconocimiento facial que se utilizan en aeropuertos, oficinas y hasta en algunos celulares. Aunque estas aplicaciones, por ejemplo, en Europa solo serán permitidas en casos muy extraordinarios, debido a que la IA también debe ser regulada para que en lugar de ser utilizada en aplicaciones que afecten a las personas, sean usadas en aplicaciones con intenciones más próximas al desarrollo y crecimiento de la sociedad y la integridad humana. Estos sistemas escanean el rostro de una persona y, en cuestión de segundos, pueden verificar su identidad comparando los patrones faciales con una base de datos. Este tipo de tecnología ayuda a mejorar la seguridad y la privacidad, aunque también plantea ciertos debates éticos sobre la privacidad de las personas.

Por último, en el sector financiero, las redes neuronales son herramientas poderosas para detectar fraudes. Las transacciones bancarias de cada usuario siguen ciertos patrones, y cuando la red neuronal detecta algo inusual, como un cargo en un país donde el usuario nunca ha estado, envía una alerta para proteger su cuenta. También se utilizan para analizar el comportamiento del mercado y predecir cambios en los precios de las acciones, lo que ayuda a los inversionistas a tomar decisiones más informadas. Cada uno de estos ejemplos demuestra cómo las redes neuronales se han convertido en una tecnología fundamental que nos permite realizar tareas complejas de manera más eficiente y rápida.

Si bien las redes neuronales parecen casi mágicas, no todo es tan perfecto como se podría pensar. Uno de los principales retos es la enorme cantidad de datos que estos modelos necesitan para aprender a hacer bien su trabajo. A diferencia de los humanos, que podemos aprender algo nuevo con pocos ejemplos, las redes neuronales necesitan



ver miles, sino millones, de ejemplos para captar patrones y mejorar. Imagina que tienes que enseñarle a una red neuronal a distinguir entre gatos y perros. Para lograrlo, tendrías que mostrarle una cantidad inmensa de fotos de gatos y perros, en diferentes posiciones, tamaños y contextos, para que la red realmente aprenda a diferenciarlos. Y no se trata solo de cantidad: la calidad de los datos también es crucial. Si los datos tienen errores o están sesgados, la red neuronal va a aprender esos mismos errores, lo cual puede causar problemas en el mundo real. Además de los datos, las redes neuronales requieren mucho poder de cómputo para funcionar. Cada “neurona” en la red realiza cálculos, y en una red grande, estos cálculos se multiplican por millones. Si intentas entrenar una red neuronal grande en una computadora común y corriente, el proceso puede tardar semanas, meses o incluso años, o simplemente no es posible. Por eso, se necesitan equipos especializados, como las GPU, que pueden realizar muchos cálculos en paralelo y acelerar el entrenamiento. Las GPU fueron inicialmente diseñadas para videojuegos, pero resultaron ser perfectas para redes neuronales porque manejan operaciones matemáticas de manera extremadamente rápida. Esto ha permitido que la inteligencia artificial dé un salto enorme en los últimos años.



AUNQUE LAS REDES NEURONALES PARECEN CASI MÁGICAS...

NO TODO ES TAN PERFECTO COMO SE PODRÍA PENSAR


DATOS

Para aprender a diferenciar entre gatos y perros, una red neuronal necesita ver miles de ejemplos de diversas combinaciones y calidades.



PODER DE CÓMPUTO

Entrenar una red neuronal grande requiere mucho poder de cómputo, el cual no está disponible en computadoras comunes.



Entrenar una red neuronal grande requiere mucho poder de cómputo, el cual no está disponible en computadoras comunes

Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).


De hecho, uno de los grandes motivos por los cuales las redes neuronales no se usaban tanto antes es porque simplemente no había suficientes recursos de cómputo para que fueran eficientes. Aunque la teoría de las redes neuronales existe desde hace décadas, durante mucho tiempo fue solo eso, una teoría. Los investigadores sabían que estos modelos tenían potencial, pero no podían aprovecharlo completamente porque las computadoras de esa época no tenían la potencia para procesar tantos datos tan rápido. En los últimos 20 años, aproximadamente, los avances en *hardware* permitieron que las redes neuronales empezaran a usarse en aplicaciones prácticas. Las mejoras en las GPU y la creación de procesadores especializados, como las TPU (unidades de procesamiento de tensores, por sus siglas en inglés) desarrolladas por Google, hicieron posible entrenar redes mucho más grandes en un menor tiempo. Esto, combinado con el aumento en la cantidad de datos digitales disponibles (gracias a la internet y a la digitalización masiva), permitió que las



redes neuronales dejaran de ser algo experimental y se convirtieran en herramientas útiles en nuestra vida diaria.

Incluso hoy en día, entrenar redes neuronales muy grandes puede ser costoso y requiere una infraestructura considerable. Empresas como Google, Amazon y Microsoft tienen centros de datos gigantes donde miles de GPU trabajan en conjunto para entrenar los modelos de inteligencia artificial que utilizamos, desde asistentes de voz hasta sistemas de recomendación. Este acceso a recursos de cómputo avanzado es una ventaja enorme para grandes empresas, pero para investigadores y desarrolladores independientes, el costo de entrenar una red neuronal a gran escala sigue siendo un obstáculo.

El cerebro humano y las redes neuronales: ¿Cuánto se parecen?



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Imagina que sostienes el mapa del universo más complejo que conocemos: el cerebro humano. Ahora, imagina que alguien trata de crear una versión artificial de este mapa utilizando matemáticas y

códigos informáticos. Este intento, aunque no es un duplicado perfecto, nos lleva a las redes neuronales artificiales.

Por otro lado, el cerebro humano es una estructura biológica impresionante, tanto por su complejidad como por su capacidad para adaptarse. Consta de más de 86.000 millones de neuronas, cada una de las cuales puede conectarse con hasta 10.000 neuronas diferentes mediante sinapsis. Estas conexiones forman redes dinámicas que son responsables de todas nuestras capacidades: desde percibir el mundo hasta imaginar un futuro.

Cada neurona transmite señales a través de impulsos eléctricos llamados potenciales de acción. Estas señales viajan a lo largo de un axón y se comunican con otras neuronas mediante neurotransmisores liberados en las sinapsis. A diferencia de las conexiones en las redes neuronales artificiales, las sinapsis biológicas no solo transmiten información; también la modulan dependiendo de factores como la experiencia previa, la atención o incluso las emociones. Este fenómeno, conocido como plasticidad sináptica, es clave para el aprendizaje y la memoria.

El cerebro no es solo un sistema eléctrico, también es químico. Los neurotransmisores como la dopamina, serotonina y el glutamato son mensajeros que influyen en el estado de ánimo, el aprendizaje y las respuestas al entorno. Cada neurona y cada sinapsis participan en una orquesta compleja, ajustando cómo la información fluye en función de las necesidades.

El cerebro está dividido en diferentes regiones, cada una especializada en funciones específicas. Las siguientes son algunas de las funciones por regiones:

Lóbulo occipital: procesa la información visual. Cuando vemos algo, las señales viajan desde los ojos hasta esta región para interpretar colores, formas y movimientos.



Lóbulo temporal: es esencial para el procesamiento del sonido y el lenguaje, así como para la memoria. Aquí reconocemos voces y recordamos experiencias.

Lóbulo parietal: integra información sensorial ayudándonos a comprender el espacio y la orientación.

Lóbulo frontal: responsable de funciones más complejas como la toma de decisiones, el razonamiento y el control de impulsos. Es aquí donde planeamos, imaginamos y resolvemos problemas.

Una característica fascinante del cerebro es su organización jerárquica. Por ejemplo, en el sistema visual, las señales comienzan en la corteza visual primaria (V1), donde se procesan los detalles más básicos como las líneas y bordes. Luego, esta información se envía a áreas superiores, como V2 y V4, donde se combinan patrones más complejos hasta llegar al área IT (corteza temporal inferior), donde finalmente reconocemos objetos como rostros o edificios.

El cerebro también funciona como un integrador multisensorial. Esto significa que no procesa la información de cada sentido de forma aislada; en cambio, combina datos de diferentes sentidos para crear una percepción coherente del mundo. Por ejemplo, cuando ves y escuchas a una persona hablar, tu cerebro integra ambas fuentes de información para comprender mejor lo que está ocurriendo.

Por otra parte, la plasticidad del cerebro se refiere a su capacidad para adaptarse y reorganizarse. Por ejemplo, cuando aprendes una nueva habilidad, como tocar un instrumento, tu cerebro crea nuevas conexiones y fortalece las existentes para mejorar tu desempeño. Esta plasticidad también es crucial para la recuperación de lesiones cerebrales, permitiendo que otras áreas asuman funciones perdidas.

Por último, el cerebro opera a través de patrones temporales. Algunas regiones responden rápidamente a cambios en el entorno, mientras que otras, como las involucradas en la planificación, mantienen información

activa durante períodos más largos. Esta organización temporal permite al cerebro equilibrar tareas inmediatas y de largo plazo, desde esquivar un obstáculo hasta planear unas vacaciones.

Redes neuronales artificiales: inspiradas por el cerebro

Las redes neuronales artificiales (ANN, por sus siglas en inglés) intentan imitar este proceso, como ya lo hemos tratado en unos apartados anteriores. Cada “neurona” artificial es una simple unidad matemática que recibe datos, los procesa y envía una salida a otras neuronas. Estas conexiones entre neuronas artificiales no tienen la misma flexibilidad que las sinapsis biológicas. En las ANN, las conexiones se definen por “pesos”, que son valores numéricos que determinan cuánta importancia tiene la información que pasa de una unidad a otra.

El entrenamiento de una ANN consiste en ajustar estos pesos utilizando algoritmos como la retropropagación^x. Este proceso es un ciclo de prueba y error, se compara la salida de la red con la respuesta esperada (*output*) y se corrigen los pesos para reducir el error. En contraste, en el cerebro, el aprendizaje se basa en la modificación de las conexiones sinápticas a través de mecanismos como la potenciación a largo plazo (LTP) o la depresión a largo plazo (LTD).

En las ANN, los datos de entrada (*input*) podrían ser imágenes, texto o señales de audio. Estos datos atraviesan las capas de la red, donde cada capa extrae características más complejas hasta producir un resultado final (*output*), como clasificar una imagen o traducir un texto. En el cerebro, el *input* podría ser una señal visual que pasa desde la retina a través de las jerarquías neuronales hasta que reconocemos lo que estamos viendo. Aunque ambos sistemas procesan información jerárquicamente, el cerebro lo hace de manera mucho más paralela y distribuida y con muchísima menos energía. De hecho, el cerebro humano es una maravilla de la eficiencia energética. Aunque representa apenas el 2 % del peso corporal, consume alrededor del 20 % de la energía total del cuerpo, lo que equivale a unas 500 kilocalorías diarias



o aproximadamente 24 vatios de potencia. Para ponerlo en perspectiva, 24 vatios son suficientes para alimentar una pequeña bombilla LED de escritorio durante todo el día. Esto destaca la capacidad del cerebro para realizar tareas complejas con un consumo relativamente bajo de recursos.

Por otro lado, uno de los usos más ampliamente conocidos de las redes neuronales profundas son los modelos de lenguaje a gran escala (LLM, por sus siglas en inglés), como ChatGPT; estos requieren cantidades masivas de energía para funcionar. Se estima que ChatGPT, por ejemplo, consume unos 564 megavatios-hora (MWh) al día, suficiente para abastecer a 18.000 hogares. Esta comparación resalta la brecha entre la eficiencia del cerebro humano y la potencia requerida por las tecnologías de inteligencia artificial actuales, subrayando tanto los avances como los desafíos en el desarrollo de estas herramientas.

Comparando niveles: neuronas, capas y redes

Podemos analizar las similitudes entre el cerebro y las ANN en varios niveles:

A nivel de neuronas (nodo): cada neurona en el cerebro o nodo en una ANN es una unidad básica de procesamiento. Mientras que las neuronas biológicas utilizan neurotransmisores para transmitir información, las neuronas artificiales usan funciones matemáticas que combinan los datos de entrada con los pesos de sus conexiones.

A nivel de capas (regiones): las capas de una ANN se asemejan a las jerarquías del cerebro. Por ejemplo, las capas iniciales de una ANN pueden imitar el comportamiento de la corteza visual primaria, mientras que las capas más profundas reflejan regiones cerebrales superiores. Sin embargo, las capas de las ANN tienden a ser estáticas, mientras que las jerarquías cerebrales son flexibles y adaptativas.

A nivel de redes: tanto el cerebro como las ANN comparten una organización en redes jerárquicas que procesan información de manera secuencial y simultánea. Sin embargo, el cerebro también incluye conexiones de retroalimentación que influyen en la interpretación del *input* y que son difíciles de replicar en modelos artificiales.

Lo que aprendemos del paralelismo

Aunque las redes neuronales no son un duplicado perfecto, esta comparación nos ayudan a entender cómo procesa información el cerebro. Por ejemplo, modelos de aprendizaje profundo han revelado que las capas más profundas de las ANN se corresponden con regiones cerebrales implicadas en la interpretación de conceptos abstractos. Esto sugiere que nuestras propias capacidades cognitivas también están organizadas jerárquicamente.

Sin embargo, también hay limitaciones. Las ANN no poseen la conciencia, las emociones ni la flexibilidad adaptativa del cerebro. Por otro lado, estas redes han superado nuestras expectativas en tareas específicas como la clasificación de imágenes o la generación de texto.

El futuro: cooperación entre naturaleza y tecnología

A medida que las redes neuronales avanzan, también lo hace nuestra comprensión del cerebro. Este ciclo de retroalimentación podría llevarnos a modelos artificiales más avanzados que no solo imiten, sino que también complementen nuestras capacidades cognitivas. Por ejemplo, integrar aspectos como la conectividad dinámica y las jerarquías globales podría crear sistemas más robustos y eficientes.

Es posible que en el futuro las ANN no solo se inspiren en el cerebro, sino que también lo ayuden a descubrir sus secretos. Por ejemplo, podrían contribuir a descifrar cómo emergen cualidades humanas como la creatividad o la intuición. Este conocimiento podría revolucionar no solo la inteligencia artificial, sino también nuestra comprensión de



nosotros mismos, en cuyo caso, explorar la relación entre el cerebro y las redes neuronales no solo nos acerca a comprender mejor nuestra propia mente, sino que también abre nuevas posibilidades para la tecnología y la ciencia. Ambos mundos, el biológico y el artificial, tienen mucho que aprender el uno del otro, y este viaje apenas comienza.

¿Qué es un *transformer* y por qué se está hablando tanto del tema?

Vamos a hablar de algo que, aunque suena complicado, está mucho más cerca de lo que imaginas: los *transformers*. No, no me refiero a los robots que se convierten en carros y aviones (aunque eso también sería muy chévere). Estoy hablando de un tipo de tecnología que les permite a las computadoras entender y trabajar con textos, imágenes, sonidos y más, ¡como si fueran expertos en todo eso! ¿Te imaginas tener un amigo que te entiende en cualquier idioma, que completa tus frases y hasta te responde preguntas complicadas? Pues ese amigo es un *transformer*.

Para empezar, imagínate que quieres explicarle a alguien cómo hacer una receta de empanadas. En cambio de contarle paso por paso, con todo y detalles — mezclar la harina con agua, agregar el relleno, formar las empanadas y freírlas— simplemente le das el inicio: “Primero, mezcla los ingredientes secos...” y, sin decirle nada más, esta persona adivina que después tiene que agregar el agua, amasar, rellenar y freír. ¡Eso sería casi mágico! Pues bien, los *transformers* trabajan de una forma similar cuando procesan información. Pero, ¿cómo logran hacer esto? La clave está en un truco llamado mecanismo de atención^{xiii}. Te lo explico: cuando un *transformer* recibe una gran cantidad de información —como una receta completa o hasta un capítulo de un libro—, no intenta aprenderse cada palabra al pie de la letra. En cambio, se enfoca en las partes que realmente son importantes para entender el contexto. Así como tú pondrías más atención en los ingredientes o en el tiempo de cocción en una receta, el *transformer* detecta las palabras que le van a ayudar a entender de qué se trata la frase o el texto completo.



Este mecanismo de atención hace algo muy especial: calcula el “peso” o la importancia de cada palabra en la frase. Por ejemplo, en la frase “Primero, mezcla los ingredientes secos y luego añade agua”, el *transformer* puede darse cuenta de que “mezcla”, “ingredientes secos” y “agua” son palabras clave para entender los pasos iniciales de la receta. Así que, cuando se enfrenta a más frases de otras recetas, puede relacionar automáticamente conceptos similares, adivinando la estructura y los pasos sin que le digan exactamente qué tiene que hacer en cada momento. Algo así como si fuera una fiesta. Si tienes a varias personas hablando a la vez, ¿cómo decides a quién escuchar? Probablemente te enfocas en lo que dice alguien que menciona algo importante, como el chisme más bueno o una anécdota interesante. En una frase, el *transformer* decide “escuchar” las palabras que le parecen más importantes y “pone menos atención” a las que son de relleno, como “el”, “y” o “entonces”. Así, sin perderse en palabras innecesarias, capta la idea general. Y este “poder” de poner atención en lo importante es lo que hace que los *transformers* sean tan buenos para entender cosas largas y complicadas. Es como si leyeran con el ojo entrenado, seleccionando solo lo que realmente les ayuda a entender de qué va el texto, una canción, o incluso una conversación completa. Por eso los usamos para tareas como traducir textos largos, resumir documentos o responder preguntas basadas en montones de información, porque pueden “poner atención” en lo esencial y darnos una respuesta que tiene sentido, ¿como si entendieran todo el contexto!

Piénsalo como cuando estás leyendo un libro o viendo una publicación en TikTok y un personaje que te gusta aparece en una parte de la historia o el video. Cuando ese personaje hace algo, tú “pones atención” y entiendes mejor qué pasa en la historia porque te importa. El *transformer* hace algo parecido con el texto. Si le das una frase, primero analiza cada palabra y decide cuáles son importantes para entender el contexto. Es como si cada palabra en la frase tuviera una nota al pie diciendo lo siguiente: “Yo soy importante para entender de qué va esta frase”. A esto se le llama auto-atención (*self-attention*), una idea clave en los *transformers*. Así pueden leer y entender frases largas, o incluso historias enteras, “poniendo atención” a las palabras o ideas que más

importan. Imagínate que le dices al *transformer* otra oración: “Ayer fui al parque y vi a mi amigo Juan”. El *transformer* sabe que *fui*, *parque* y *Juan* son palabras importantes para entender que hubo una salida y alguien importante en esa salida. Lo interesante es que, gracias a la auto-atención, el *transformer* no necesita que le expliques cada detalle. Puede adivinar, basado en las palabras clave, que probablemente fuiste a pasear y que *Juan* es alguien importante para entender lo que pasó en tu día.

Para lograr esto, el *transformer* usa un truco matemático: le asigna un “peso” a cada palabra, dependiendo de cuán relevante sea en relación con las otras. Si sigue con la historia y aparece algo como el siguiente enunciado: “Juan trajo una pelota y jugamos fútbol”, ahora el *transformer* “ve” que palabras como *pelota* y *jugamos* son clave para entender lo que hicieron. Así, en vez de tener que recordar toda la oración exacta, el *transformer* se queda con las palabras que más “pesan” y usa esa información para entender de qué va la historia. Este proceso de auto-atención es lo que le permite al *transformer* leer textos largos sin perderse en detalles insignificantes. Puede ver cada palabra en relación con las demás y así crear una especie de “mapa” mental que le permite saber qué partes son cruciales para entender el mensaje general. Es como si estuviera armando un rompecabezas, donde cada pieza tiene un tamaño distinto según lo importante que sea. Al final, el *transformer* entiende no solo la frase, sino cómo encaja cada palabra en el contexto completo.

¿Y por qué es tan útil el *transformer*? Antes de que se inventaran los *transformers*, los programas que intentaban hacer esto tenían que ir paso por paso, palabra por palabra, como si estuvieran leyendo cada letra de un mensaje en vez de ver la oración completa de una vez. Esto hacía que se tardaran muchísimo y que, además, perdieran el contexto al enfocarse solo en un pedacito a la vez. Imagínate leer un libro palabra por palabra sin ver la página completa, ¡terminarías agotado! Los *transformers* son distintos porque pueden analizar todas las palabras de una sola vez, como si tuvieran un “superpoder” para entender la relación entre las palabras en una misma frase sin hacer pausa. Este enfoque en paralelo no solo ahorra tiempo, sino que permite que puedan trabajar con textos,



sonidos o imágenes enormes sin problema, sacando de inmediato la información clave de cada parte. Gracias a esta rapidez y capacidad para captar contextos largos, los *transformers* se han convertido en una herramienta increíblemente útil en muchas áreas. Antes, traducir un párrafo, resumir un artículo o analizar una conversación completa llevaba mucho tiempo y esfuerzo. Ahora, con los *transformers*, estas tareas se pueden hacer en segundos, y con una precisión que antes solo podíamos soñar. Por eso, los *transformers* ahora son usados en cosas como:

Traductores de idiomas: si alguna vez has usado el traductor de Google o has visto las traducciones automáticas en redes sociales, eso es un *transformer* en acción. Este modelo lee lo que escribes, pone atención en las palabras clave y, de inmediato, te lo convierte en otro idioma. Incluso puede adaptar expresiones o frases que tienen diferentes significados según el contexto, haciendo que la traducción suene mucho más natural. Antes, traducir algo complicado, como un artículo de noticias, requería ajustes manuales; hoy, un *transformer* puede hacer todo esto al vuelo.

Sistemas que completan texto: seguro has visto en el celular que cuando empiezas a escribir algo como lo siguiente: “Hola, ¿cómo e...”, te sugiere *estás*. Esto es un *transformer* prediciendo lo que probablemente quieres escribir. Estos sistemas son entrenados con millones de ejemplos de cómo la gente suele hablar y escribir, así que cuando comienzas una frase, el *transformer* ya tiene una buena idea de cómo terminarla. Esto facilita muchísimo la escritura porque te ayuda a ahorrar tiempo al no tener que escribir cada palabra completa.

Asistentes virtuales: te responden preguntas y hasta te hacen recomendaciones. Ellos usan *transformers* para entender lo que les estás diciendo. Cuando preguntas: “¿qué tiempo hará hoy?” o “¿cuál es la pizzería más cercana?”, el *transformer* procesa rápidamente las palabras, capta el sentido de la pregunta y encuentra la información más útil para darte una respuesta. Incluso puede recordar información previa



de la conversación, como cuando le pides “pon mi música favorita” y entiende a qué te refieres sin que le des más detalles.

Análisis de sentimientos: los *transformers* también se usan para analizar comentarios en redes sociales, reseñas de productos o incluso encuestas de opinión. Gracias a su capacidad para captar el contexto y el tono de las palabras, pueden determinar si alguien está hablando de manera positiva, negativa o neutral. Esto es útil para empresas que quieren saber cómo se sienten sus clientes o para saber qué opinan los usuarios de un tema en tendencia.

Generación de texto y creación de contenido: hoy en día, los *transformers* también ayudan a generar contenido. Por ejemplo, si una empresa necesita escribir descripciones de productos o un resumen de noticias, un *transformer* puede generar esos textos basado en lo que ha aprendido de millones de ejemplos. A veces, solo necesitan una pequeña frase como “El celular más nuevo de la marca XYZ...” y el *transformer* es capaz de completar todo el párrafo, ¡casi como si fuera un escritor profesional!

Automatización de tareas: en los correos electrónicos, cuando Gmail te sugiere respuestas rápidas o completa tu frase, esto también es obra de los *transformers*. Estos modelos han sido entrenados con millones de mensajes y pueden predecir cómo podrías responder basándose en el contexto de la conversación. Imagina el tiempo que se ahorra el tener sugerencias automáticas o respuestas prediseñadas.

Gracias a estas aplicaciones, los *transformers* no solo nos ayudan a comunicarnos mejor, sino que también facilitan tareas cotidianas y nos ahorran tiempo en muchas actividades. Son como un asistente silencioso en el fondo, siempre listo para hacer el trabajo pesado y dejarnos a nosotros solo los detalles finales.





Fuente: elaboración propia (generado con DALL·E 3 de OpenAI).

¿Y cómo hace todo esto? Para hacer todo esto, los *transformers* usan algo que podríamos llamar “cabezas de atención”. Suena raro, pero básicamente son como varias formas de poner atención al mismo tiempo en distintos detalles. Piensa en cuando estás en una clase complicada, y cada compañero se enfoca en un aspecto diferente de la explicación del profesor: uno toma nota de los números y fórmulas, otro de los ejemplos, otro de las definiciones, y otro escucha con más atención los conceptos

generales. Al final, cuando juntan todos los apuntes, tienen una imagen completa y precisa de la clase, donde nada importante queda fuera.

Un *transformer* funciona de una manera parecida. En vez de tener solo una “cabeza” que ponga atención en todo el texto de un solo golpe, usa múltiples cabezas de atención (cada una es un “mini-*transformer*” dentro del modelo general) que se encargan de analizar diferentes aspectos del texto de forma simultánea. Por ejemplo, una cabeza puede enfocarse en las palabras clave, otra en la estructura de la frase, otra en los posibles significados de las palabras según el contexto. Así, cada cabeza “lee” el texto desde una perspectiva distinta, obteniendo detalles específicos que, al final, se combinan para formar una visión mucho más rica y completa del mensaje.

Este sistema de “cabezas de atención” es lo que hace que el *transformer* pueda entender no solo palabras individuales, sino también cómo se relacionan entre sí. Cuando hablamos, a veces no decimos directamente lo que pensamos, sino que usamos contexto, referencias o frases hechas que solo tienen sentido si captas el significado “entre líneas”. Los *transformers*, gracias a estas cabezas, son capaces de captar esas conexiones ocultas y entender qué es importante en cada oración.

Imagina que le das al *transformer* una frase como la siguiente: “Juan fue al parque a jugar fútbol y vio a su amigo Carlos”. Una de las cabezas puede centrarse en *parque* y ver qué actividades están relacionadas con ese lugar. Otra puede poner atención en *Carlos* y entender que es alguien importante en la acción de la frase. Otra puede fijarse en el verbo *fue* y en qué indica que Juan fue a un lugar específico para hacer algo. Cuando el *transformer* combina todas estas perspectivas, no solo entiende que Juan y Carlos estuvieron en el parque, sino que Juan fue a jugar y que Carlos fue parte de esa actividad. Al final, al juntar todo lo que cada cabeza ha entendido, el *transformer* obtiene una “visión global” de la frase. Esta visión es mucho más completa que si hubiera intentado analizar cada palabra por separado. Gracias a esto, los *transformers* son capaces de entender texto, imágenes o datos de una manera mucho más profunda y



compleja, capturando no solo lo que está explícito, sino también lo que está implícito. Es como si lograran “leer entre líneas” y captar los detalles que hacen que el texto o la imagen tengan sentido en su conjunto.

Este truco de las múltiples cabezas es una de las claves que ha hecho que los *transformers* revolucionen tantas aplicaciones, desde traducción automática hasta generación de texto y análisis de imágenes. Con varias cabezas analizando al mismo tiempo, pueden captar todos los detalles y relacionarlos de manera que no se pierda nada, logrando así un nivel de comprensión que antes parecía imposible para una máquina.

Revisemos un ejemplo para aterrizar todo esto: supón que tienes una foto de un perro corriendo en el parque. Si le das esa imagen a un *transformer* entrenado para analizar imágenes, este va a “poner atención” en las cosas importantes de la imagen. En lugar de ver la foto como un conjunto de píxeles al azar, el *transformer* divide la imagen en varias partes o fragmentos y analiza cada uno desde diferentes ángulos, tal como lo hace con las palabras en un texto. Por ejemplo, una cabeza del *transformer* podría enfocarse en los colores y reconocer el verde del césped, el marrón del pelaje del perro y el azul del cielo. Otra cabeza podría centrarse en las formas: captar el contorno del perro, los árboles en el fondo, y las líneas del camino. Una tercera cabeza podría detectar el movimiento en la posición del perro, sus patas levantadas y el ángulo de su cuerpo, entendiendo que el perro está corriendo. Finalmente, otra cabeza podría enfocarse en el fondo y el entorno, captando que hay árboles y césped, lo cual ayuda a deducir que la escena ocurre en un parque.

Cuando el *transformer* combina toda esta información, no solo tiene detalles aislados, sino que puede llegar a la conclusión general: en la imagen hay un “perro corriendo en un parque”. Este proceso es similar a cómo interpretamos una foto: observamos colores y formas y reconocemos objetos en movimiento y el fondo para entender el contexto. Con el texto hace lo mismo. Si le das una frase como “El perro corrió hacia el niño con la pelota”, el *transformer* pone atención en las

palabras clave, como *perro*, *niño*, *pelota* y *corrió*. También considera cómo estas palabras se relacionan entre sí en el contexto de la oración. Al final, capta la idea completa de la frase y entiende que el perro fue hacia el niño porque está interesado en la pelota. En pocas palabras, el *transformer* capta tanto los detalles como el panorama completo, ya sea en una imagen o en un texto.

Gracias a esta habilidad de analizar desde múltiples ángulos, los *transformers* son usados en todo tipo de tareas de análisis de imagen, como reconocer objetos, identificar rostros o incluso describir escenas. Al “poner atención” en diferentes aspectos de la imagen al mismo tiempo, logran entender y describir qué está pasando sin confundirse con detalles irrelevantes o perderse en el mar de píxeles o palabras. Así, los *transformers* logran captar no solo qué está en la imagen o el texto, sino también qué está ocurriendo y cuál es el mensaje o la acción principal.

Cabe ahora que nos hagamos la siguiente pregunta: ¿qué significa esto para ti? Significa que estas herramientas ya no son cosa del futuro o solo para los expertos en tecnología. Los *transformers* se han convertido en una pieza clave que está presente en nuestra vida diaria y están mejorando a pasos gigantescos, a tal punto que interactuamos con ellos sin siquiera darnos cuenta. Cada vez que usas un traductor de idiomas en tu teléfono, le pides algo a un asistente de voz o incluso cuando miras recomendaciones en redes sociales como Instagram o YouTube, ¡estás usando un poquito de esta tecnología de *transformers*!

Todo esto significa que los *transformers* no solo mejoran nuestra vida diaria, sino que también nos ahorran tiempo, nos facilitan la comunicación y personalizan la forma en que interactuamos con el mundo digital. Estos modelos están tan integrados en nuestras actividades diarias que a veces ni siquiera nos damos cuenta de que están ahí, haciendo que la tecnología funcione de manera más inteligente y eficiente.



¿Qué son los modelos fundacionales?

Imagínate tener a un amigo que es como una enciclopedia viva. No importa si le preguntas por la última película de moda, el último partido de fútbol o incluso algún chisme de la farándula, él siempre tiene algo que decir y te responde sin dudar. Pero no solo se trata de que tenga buena memoria o haya leído mucho, sino que es tan hábil que entiende de qué estás hablando con solo unas pocas pistas. Le dices: “Eh, ¿te acuerdas de ese tipo que sale en la serie esa?”, y ya él sabe de quién hablas. Ni siquiera tienes que dar detalles, él conecta todo extremadamente rápido, como si tuviera un sexto sentido. Así funcionan los modelos fundacionales en la inteligencia artificial. Son sistemas entrenados para entender el mundo de una forma muy general y adaptarse a casi cualquier situación o pregunta que les pongas. Estos “amigos digitales” no son humanos; no sienten ni piensan como nosotros. En lugar de experiencias de vida, lo que tienen es una cantidad impresionante de datos con los que fueron entrenados: textos, imágenes, videos, audios, etc., todo lo que puedas imaginar. Les han mostrado de todo y, gracias a eso, han aprendido patrones, como cuando nosotros aprendemos que una pelota rueda o que el fuego quema. Estos sistemas saben identificar cosas sin necesidad de entrenarlos para cada situación específica.

Cuando interactúas con un modelo fundacional, es como si estuvieras hablando con un amigo que ya ha visto y escuchado de todo y se puede adaptar sus respuestas sin importar lo que le preguntes. En lugar de aprender cada cosa de cero, este modelo ya tiene una “base” de conocimiento enorme, así que solo necesita unos cuantos ajustes (que en el mundo de la IA llamamos “ajuste fino”) para ayudarte con tareas específicas, como traducir idiomas, generar imágenes o recomendarte canciones.



¿De qué va un modelo fundacional? Vamos a desglosar la respuesta y darle un buen contexto. Imagina a un modelo fundacional como una IA que, en lugar de saber solo una cosa específica, ha aprendido un poco de todo. No es un experto en una sola tarea desde el inicio; es como ese niño curioso que se pasa el día tocando, observando y preguntando de todo. Así, al comienzo no sabe bien cómo aplicar todo lo que ha aprendido, pero con el tiempo y la práctica, empieza a entender patrones y a conectar ideas, lo que lo prepara para resolver problemas muy distintos entre sí. A este modelo lo entrenan con cantidades gigantescas de datos, pero no son solo números fríos. Es como si el modelo estuviera viendo imágenes de montañas, escuchando canciones, leyendo artículos de revistas, explorando conversaciones en redes sociales, revisando bases de datos científicas... ¡y todo lo que puedas imaginar! Es un “entrenamiento general”, y si para entrenarlo usamos *transformers*, porque no lo entrenan para hacer una sola cosa, sino para entender un poco de todo, así como tú puedes aprender muchas cosas observando y escuchando, incluso sin buscar una meta específica.

Vamos a otro ejemplo. Imagínate que este modelo es como un chef. No cualquier chef, sino uno que ha pasado por años probando y aprendiendo sobre ingredientes de todo el mundo. Entonces, este chef conoce los sabores, las texturas, sabe qué ingredientes combinan bien, cuáles pueden sustituirse entre sí, e incluso intuye qué invento podría salir si mezcla algo nuevo. No es que haya aprendido solo una receta; ha aprendido los patrones que hay en las recetas. Entonces, si le pides hacer una pasta, él no solo sabe una receta específica, sino que puede adaptarse a los ingredientes que tienes y preparar una versión que tenga sentido.

Así mismo, los modelos fundacionales están diseñados para entender y adaptarse. No nacen expertos en algo particular, sino que se entrenan para ser flexibles y poder ajustarse a diferentes situaciones y problemas. Por ejemplo, si alguien entrena un modelo fundacional con textos en diferentes idiomas, el modelo puede empezar a notar similitudes entre palabras de distintos idiomas y deducir cómo traducir, incluso si no le han



enseñado reglas específicas de traducción. Aprende a captar patrones, estructuras y relaciones entre los datos, como cuando reconoces a una persona por sus gestos o su tono de voz, aunque esta esté de espaldas.



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Estos modelos tienen una ventaja enorme: al ser entrenados de forma general, luego pueden ajustarse de manera rápida a tareas específicas, como escribir un cuento, clasificar fotos de paisajes o responder

preguntas sobre historia. Se les da un pequeño entrenamiento adicional en esas áreas, y están listos para funcionar en un contexto específico^{xvi}.

¿Por qué los llaman “fundacionales”? Llamar a estos modelos “fundacionales” está justificado porque son como los cimientos sólidos que usas para construir algo más grande. Imagina un edificio: antes de levantar las paredes, el techo o cualquier decoración, necesitas una base firme que pueda soportar todo lo que venga después. Esa base no cambia, no importa si encima construyes una casa, un hospital o una torre. Así, estos modelos fundacionales son una especie de “piso firme” en la IA; los entrenan para que adquieran un conocimiento tan amplio y robusto que luego puedas usarlos para desarrollar aplicaciones muy diferentes entre sí, sin necesidad de construir una base desde cero cada vez.

Piensa en un modelo fundacional entrenado con millones de textos en diferentes idiomas. Al “leer” estos textos, el modelo empieza a captar patrones de cómo se estructura el lenguaje, a notar que hay palabras que se repiten en ciertos contextos y que hay formas específicas de decir las cosas en cada idioma. Entonces, esa comprensión básica del lenguaje se convierte en una plataforma desde la cual puede hacer mucho más: puede traducir frases, entender el significado de una pregunta y dar una respuesta adecuada, o incluso resumir un texto largo en pocas palabras. La clave es que no lo entrenaron solo para hacer una de esas cosas, sino para entender el lenguaje de una manera general, de modo que luego pueda adaptarse y hacer tareas específicas sin problemas. Este enfoque ahorra tiempo y recursos, porque en lugar de tener que entrenar un modelo desde el inicio para cada tarea nueva, tomas el modelo fundacional, le das unas pocas instrucciones, y lo tienes listo para funcionar en su nuevo rol.

Otra forma de verlo es pensar en los modelos fundacionales como ese ladrillo maestro que encaja en cualquier construcción. Digamos que tienes un ladrillo tan especial que puedes usarlo para empezar a construir un puente, una pared o una escalera. Este ladrillo es básico y



universal, pero con él puedes levantar cualquier tipo de estructura. En la IA, los modelos fundacionales son como ese ladrillo maestro: una vez los tienes, puedes emplearlos para distintas tareas, ellos se adaptan sin tener que hacer cambios drásticos en su estructura original. Por ejemplo, un modelo fundacional de visión, que ha sido entrenado con millones de imágenes, puede reconocer patrones visuales generales como formas, colores y texturas. Con esa base, puedes pedirle que identifique objetos específicos, que ayude a diagnosticar enfermedades al observar imágenes médicas o que clasifique fotos en categorías como “paisajes”, “animales” o “personas”.

La razón de su nombre también está en cómo estos modelos facilitan el desarrollo de IA de alto nivel. Antes, cuando se quería que una IA hiciera algo en particular, había que entrenarla desde el principio, y eso requería miles de datos específicos y un largo periodo de tiempo para enseñarle cada detalle. Los modelos fundacionales cambiaron esa lógica. Hoy en día, una vez tienes un modelo fundacional, puedes afinarlo o “ajustarlo” para que haga tareas avanzadas en muy poco tiempo. Es como tener una plantilla que, con unos pocos cambios, puedes adaptar a diferentes propósitos. Por eso se habla de que estos modelos “transforman” la IA, en vez de estar limitados a una sola tarea, son flexibles y se adaptan con facilidad, abriendo una puerta para crear sistemas de IA que puedan hacer muchas cosas a la vez o aprender nuevas habilidades en muy poco tiempo.

Estos modelos son llamados fundacionales también porque representan un cambio de mentalidad en cómo se desarrollan las IA. En lugar de tener decenas de modelos específicos para cada tipo de problema, ahora tienes una especie de “modelo general” que se puede modificar o personalizar según la necesidad. Es como si, en lugar de tener que fabricar herramientas distintas para cada tipo de trabajo en una construcción (un martillo para clavar, un destornillador para los tornillos, una llave inglesa para las tuercas), ahora pudieras tener una herramienta que cambia de forma y función dependiendo de lo que necesites hacer. Este concepto de una “herramienta universal” en IA es lo que ha permitido



que veamos aplicaciones en áreas que antes parecían muy complejas, desde la medicina hasta el entretenimiento, y que todas esas aplicaciones puedan partir de un mismo modelo.

La base fundacional es entonces algo que le da flexibilidad y potencia a la IA. No solo es una cuestión de adaptabilidad, se trata de construir sobre un conocimiento profundo y estructurado que hace que las IA sean más eficientes y efectivas en sus tareas.

Ejemplos de modelos fundacionales

Los modelos fundacionales han revolucionado la forma en que interactuamos con la IA. Gracias a su entrenamiento en cantidades masivas de datos, estos modelos pueden responder preguntas, reconocer imágenes, entender videos y mucho más. Aquí algunos ejemplos y sus aplicaciones prácticas para que veas su impacto en la vida real.

ChatGPT y la familia GPT-4: estos modelos están entrenados con cantidades inimaginables de texto, desde artículos científicos hasta conversaciones casuales, pasando por fragmentos de novelas, blogs, etc. Esto los convierte en una especie de enciclopedia conversacional que no solo tiene información, sino que entiende cómo hablarla de manera natural. Es como tener un amigo sabio y versátil que ha leído de todo y siempre sabe qué decir.

Aplicaciones Prácticas:

Asistencia personal: ChatGPT puede ayudarte con cosas tan simples como hacer una lista de compras o recordarte tus citas del día, hasta algo más complejo como planificar un viaje. Le puedes decir lo siguiente “Ayúdame a organizar una fiesta”, y te sugerirá desde la decoración hasta el menú.

Educación y *tutoring*: ChatGPT puede responder preguntas sobre Matemáticas, Historia, Ciencia, etc. Es como tener un tutor personal



disponible en cualquier momento. Esto es muy útil en la educación en línea, donde los estudiantes pueden tener una “conversación” sobre cualquier tema y resolver sus dudas al instante

Creación de contenidos: puede escribir artículos, poemas, ensayos o incluso ayudarte a armar ideas para un proyecto creativo. Es una herramienta poderosa para escritores, periodistas, y hasta *community managers* que necesitan generar ideas y contenido rápido.

Atención al cliente: muchas empresas ya usan ChatGPT para manejar preguntas frecuentes, responder a clientes y hasta resolver problemas técnicos básicos. Esto permite que los clientes obtengan ayuda inmediata sin tener que esperar a que un humano esté disponible.

CLIP (contrastive language-image pre-training)

CLIP es un modelo que une dos mundos: el de las imágenes y el del texto. Básicamente, se lo entrena para entender el contenido de una imagen y describirlo en palabras. Por ejemplo, si le muestras una foto de un perro saltando en un parque, puede entender que es un perro, que está en movimiento y que el entorno es un parque, y podría generar una descripción como la siguiente: “un perro feliz jugando al aire libre”. Su entrenamiento lo hace capaz de reconocer miles de conceptos visuales, por lo que tiene aplicaciones muy útiles.

Aplicaciones prácticas:

Búsqueda visual avanzada: permite buscar imágenes usando texto, lo cual es muy útil en bancos de imágenes y redes sociales. Por ejemplo, si buscas “puesta de sol en la playa”, CLIP puede filtrar imágenes que coincidan con esa descripción.

Moderación de contenido: se usa para detectar contenido sensible en imágenes (como violencia o contenido no apto para menores) y ayuda a las plataformas a asegurarse de que cumplan con las normas.

Asistencia a personas con discapacidad visual: Con CLIP se pueden desarrollar herramientas que describan el entorno a personas con discapacidades visuales. Imagina que una persona ciega tiene una *app* que, al apuntar su cámara, le describe lo que tiene en frente, como “escalera adelante” o “puerta a la derecha”.

Reconocimiento de escenas en videos: aunque CLIP es principalmente para imágenes, su tecnología se puede aplicar en videos para describir escenas específicas, como “escena de persecución en coche” o “persona hablando en un estudio”.

DALL·E

Modelo de IA que lleva las imágenes a otro nivel. Es capaz de generar imágenes desde cero a partir de descripciones de texto. Le dices algo como “un gato astronauta en la luna” y DALL·E crea una imagen que representa exactamente eso. Este modelo entiende el lenguaje y también cómo se ven las cosas, por lo que es capaz de imaginar y producir imágenes que parecen ilustraciones hechas por un artista.

Aplicaciones prácticas:

Publicidad y mercadeo: DALL·E es una herramienta asombrosa para crear contenido visual único. Una marca puede pedirle a DALL·E que genere imágenes para una campaña sin necesidad de un fotógrafo o ilustrador, lo cual ahorra tiempo y recursos.

Diseño de productos: las empresas pueden usar DALL·E para visualizar ideas de productos antes de crearlos físicamente. Por ejemplo, pueden pedir un boceto de “una mochila escolar futurista” y DALL·E generará una imagen que les da ideas sobre el diseño.

Entretenimiento y creatividad: para creadores de contenido, DALL·E es una mina de oro. Un escritor de ciencia ficción, por ejemplo, puede usarlo para visualizar personajes, planetas o paisajes de su historia.



Asistencia en arquitectura y decoración: un arquitecto o diseñador de interiores puede pedir imágenes para visualizar un concepto de diseño. Imagina que quieres ver cómo se vería una sala de estar estilo japonés con elementos modernos. DALL-E genera la imagen en segundos.

Whisper

Whisper es un modelo fundacional de transcripción y traducción de audio. Su especialidad es convertir audio en texto, incluso en ambientes ruidosos, y puede manejar múltiples idiomas y acentos. Esto lo hace perfecto para aplicaciones donde el reconocimiento de voz es clave.

Aplicaciones prácticas:

Subtítulos en tiempo real: puede crear subtítulos instantáneos para videos o transmisiones en vivo, facilitando el acceso a contenidos para personas con discapacidad auditiva.

Transcripción de reuniones y clases: es ideal para reuniones de trabajo, clases o conferencias. Convierte lo que se dice en texto, permitiendo a los participantes enfocarse en la conversación sin necesidad de tomar notas detalladas.

Traducción en tiempo Real: es capaz de transcribir en el idioma original y luego traducir el contenido a otros idiomas, lo cual facilita la comunicación en eventos multilingües.

Asistentes de voz inteligentes: permite a los asistentes de voz comprender mejor lo que dicen los usuarios, incluso en entornos con mucho ruido de fondo, como un restaurante o la calle.

Modelos fundacionales de video (ViFM)

Estos modelos están entrenados específicamente para entender videos. A diferencia de modelos de imágenes, los ViFM analizan no solo la

información visual, sino también cómo cambia a lo largo del tiempo. Por ejemplo, pueden reconocer una escena en la que un jugador de fútbol está a punto de anotar un gol y seguir el movimiento de la pelota y los jugadores.

Aplicaciones prácticas:

Análisis de deportes: pueden analizar partidos en tiempo real, identificando jugadas clave, faltas y patrones de juego. Esto es útil para entrenadores y analistas deportivos, y tal vez al fin el VAR pueda ser efectivo.

Vigilancia y seguridad: pueden detectar comportamientos sospechosos en cámaras de vigilancia, alertando sobre movimientos o interacciones inusuales en tiempo real, lo cual ayuda a prevenir incidentes.

Creación de resúmenes de video: pueden “ver” un video largo, como una conferencia o una película, y luego generar un resumen de los momentos más importantes. Clasificar los momentos de la reunión, enmarcar los puntos claves y generar actas y acuerdos.

Diagnóstico médico: pueden analizar videos de procedimientos quirúrgicos o exámenes médicos (como una colonoscopia) y detectar patrones asociados a posibles problemas de salud.

¿Cómo aprenden estos modelos?

Aquí la IA empieza a parecer algo muy humano, es decir: aprender. Los modelos fundacionales no nacen sabiendo todo. De hecho, en un comienzo no tienen la menor idea de cómo hacer algo específico. Es como cuando un bebé llega al mundo sin saber hablar ni caminar; no tiene una idea de lo que significan las palabras o cómo usarlas. Todo lo que un bebé hace, en un principio, es observar, escuchar y, poco a poco, repetir lo que ve o escucha. Pues bien, los modelos fundacionales funcionan de manera similar.



Etapa 1: el “preentrenamiento” o la exposición masiva de datos. Primero, los modelos fundacionales pasan por esta fase intensiva de exposición en la que los alimentan con cantidades enormes de datos. Imagina que tienes acceso a toda la información disponible en internet: millones de páginas web, artículos de noticias, libros, videos, conversaciones en redes sociales, imágenes y audios.

Esto es lo que estos modelos reciben durante el preentrenamiento. Pero ojo, no es que “entiendan” todo esto como lo haría un humano; lo que hacen es absorber patrones y estructuras de cada pedazo de información. Por ejemplo, al leer textos, un modelo fundacional empieza a notar que ciertas palabras suelen ir juntas o que ciertas frases suelen aparecer en contextos específicos. Para visualizarlo, imagina que el modelo es como una esponja en una biblioteca infinita: no necesariamente “comprende” cada texto, pero sí absorbe las conexiones entre las palabras y empieza a identificar patrones. Si ve la palabra *perro* en muchas frases, notará que casi siempre aparece junto a palabras como *jugar*, *ladrar* o *mascota*. Esto le permite intuir relaciones entre conceptos sin necesidad de una comprensión profunda en esta etapa. Este proceso se hace mediante técnicas de aprendizaje profundo (¿te acuerdas? Sí, *transformers* y mecanismos de atención) que permiten que el modelo asocie contextos, prediga palabras y haga hasta relaciones complejas en textos e imágenes.

Etapa 2: los patrones y la estructura del conocimiento. Con el preentrenamiento, el modelo va formando algo así como una “intuición” básica del mundo. Al ver millones de ejemplos, aprende que ciertos patrones se repiten. Por ejemplo, si está viendo imágenes, empieza a entender formas básicas y elementos visuales: que un objeto redondo con palos probablemente sea una bicicleta o que un cielo con tonos naranjas puede ser un atardecer. Si se trata de lenguaje, puede empezar a entender estructuras gramaticales sin que nadie le diga qué es un verbo o un sustantivo. Simplemente nota que ciertas palabras tienen una posición específica en la oración y que hay patrones de cómo las ideas se conectan.

Este aprendizaje de patrones se parece un poco a cuando una persona aprende a hablar en un nuevo idioma solo escuchando, sin clases formales de gramática. Un modelo fundacional empieza a detectar las “reglas no escritas” del lenguaje, imágenes o videos que le han mostrado, y las internaliza. Estos patrones son los cimientos para luego realizar tareas complejas sin necesidad de empezar desde cero.

Etapa 3: el “ajuste fino” – especialización para tareas específicas. En esta parte el modelo se convierte en experto en algo. Luego de este entrenamiento inicial, que le da una comprensión general, viene una fase de entrenamiento adicional o ajuste fino (*fine-tuning*). En esta etapa, se le da un entrenamiento más específico para tareas particulares. Por ejemplo, si quieres que un modelo entienda medicina, le muestras documentos médicos. Si quieres que se especialice en arte, le das contenido de arte. Es como si luego de haber aprendido de todo un poco, el modelo empezara a especializarse en una sola área. Para entender esto, imagina a un estudiante de medicina que ha pasado años estudiando anatomía general y, ahora, en sus últimos años, se enfoca solo en cardiología. El ajuste fino es como ese proceso de especialización. Ya no se trata de aprender de manera amplia, sino de volverse experto en una función específica.

Etapa 4: la adaptación continua – aprendizaje activo. En algunos casos, los modelos pueden seguir aprendiendo mientras interactúan con los usuarios o con nuevos datos. Esta es una fase que algunos modelos avanzados están empezando a explorar. Imagina que el modelo sigue recibiendo datos después de estar en uso. Por ejemplo, si se utiliza para atención al cliente, puede ir adaptando sus respuestas según el tipo de preguntas que recibe. Esto se conoce como aprendizaje activo y permite que el modelo mejore y se adapte a medida que cambia el contexto o las necesidades.



Comparación con el aprendizaje humano

El aprendizaje de los modelos fundacionales es muy similar al de los humanos, pero en una escala mucho mayor y más rápida. Cuando aprendes a andar en bicicleta, primero observas, luego intentas, te caes y vuelves a intentarlo hasta que lo haces bien. Un modelo de IA, por otro lado, “observa” miles o millones de ejemplos en días o meses dependiendo de la cantidad de ejemplos y la cantidad de GPU con las que se puede entrenar, algo que a un humano le tomaría toda una vida. Esta capacidad de procesar información masiva le permite tener una base sólida muy rápido, pero, como ocurre en el aprendizaje humano, necesita refuerzos específicos para perfeccionar sus habilidades en áreas especializadas.

Por eso, el aprendizaje en IA puede parecer simple, pero en realidad tiene muchos niveles de profundidad. La inteligencia artificial toma lo mejor de una educación generalista y lo combina con una especialización precisa. Así, termina siendo como un estudiante que absorbe todo en una sola lección de manera masiva y luego se especializa en lo que más necesita, dependiendo de las tareas que le pidas.

¿Por qué importan tanto los modelos fundacionales? Su relevancia no solo radica en lo que son capaces de hacer, sino en cómo están cambiando radicalmente la forma en que abordamos problemas y tareas en múltiples sectores. Estos modelos representan un cambio de paradigma en IA: ya no es necesario crear un sistema desde cero cada vez que queremos que haga algo específico. Ahora contamos con una base flexible y poderosa que ya tiene un conocimiento general del mundo, y que puede adaptarse a casi cualquier contexto con solo un poco de ajuste. Esto es como tener una herramienta mágica que se transforma según lo que necesitas en cada momento.

Imagina que tienes un computador o una máquina que ya ha “aprendido” sobre el mundo de manera general: tiene nociones de cómo se estructuran los idiomas, sabe reconocer patrones visuales básicos,

puede analizar cómo se comportan diferentes tipos de datos y, además, tiene una intuición de lo que probablemente debería responder en diversas situaciones. Esto es lo que ofrecen los modelos fundacionales. No necesitan volver a aprender todo desde cero, basta con darles unas cuantas instrucciones específicas para que, en minutos o días, estén listos para desempeñarse en una tarea compleja y muy particular.

Por ejemplo, si quieres que un modelo fundacional trabaje en el área de la salud, lo entrenas específicamente con datos médicos, pero no tienes que enseñarle a entender el lenguaje desde el inicio; ya viene “preparado” para captar las relaciones entre palabras y conceptos. Este enfoque hace que el desarrollo de aplicaciones de IA sea mucho más rápido y económico, ya que se ahorran tanto tiempo como recursos en el desarrollo de cada sistema.

Impacto en diversas áreas de la vida real: la flexibilidad y rapidez de adaptación de los modelos fundacionales los hace sumamente valiosos en prácticamente cualquier campo. A continuación algunos ejemplos de cómo están cambiando las reglas del juego:

Medicina y diagnóstico: están revolucionando el diagnóstico y la investigación clínica. Un modelo entrenado con imágenes médicas, como radiografías o resonancias magnéticas, puede aprender a identificar patrones asociados a ciertas enfermedades, como tumores o fracturas, en cuestión de días. Esto significa que en hospitales y clínicas ahora se pueden utilizar modelos de IA para apoyar a los médicos en la detección temprana de enfermedades, mejorando la precisión y rapidez del diagnóstico. También son capaces de analizar datos médicos de pacientes y detectar patrones que podrían pasar desapercibidos para un humano, lo cual permite avanzar en tratamientos personalizados y medicina preventiva.

Traducción automática y comunicación multilingüe: con modelos fundacionales que ya entienden el lenguaje de manera amplia, la traducción automática ha alcanzado niveles sorprendentes de precisión.



Ahora es posible traducir documentos enteros, conversaciones en tiempo real e incluso jerga especializada, y el modelo puede adaptarse rápidamente a nuevos idiomas o contextos específicos. Esto está facilitando la comunicación global como nunca, ayudando a empresas a expandirse a nuevos mercados y permitiendo que las personas accedan a información en cualquier idioma, sin barreras.

Moderación de contenido en redes sociales: la moderación de contenido en este ámbito es un desafío enorme, cada día se generan millones de publicaciones en texto, imágenes y videos, y las empresas necesitan una forma rápida de identificar contenido que pueda ser ofensivo, violento o engañoso. Aquí es donde los modelos fundacionales brillan. Al estar entrenados con datos variados, pueden detectar patrones de contenido inapropiado y tomar decisiones de moderación en tiempo real, ayudando a mantener un ambiente seguro en plataformas digitales. Lo mejor es que estos modelos pueden adaptarse a nuevas formas de lenguaje o contenido rápidamente, lo cual es crucial en un entorno donde el vocabulario y las modas cambian constantemente.

Investigación científica y descubrimiento: son un apoyo invaluable. Pueden analizar grandes volúmenes de literatura científica y encontrar conexiones o patrones que los investigadores pueden haber pasado por alto. Esto es especialmente útil en áreas como la genética o la farmacología, donde existen millones de datos que se generan cada año y que, sin la ayuda de una IA, serían imposibles de analizar en conjunto. Con un modelo fundacional, los científicos pueden identificar rápidamente posibles nuevas moléculas para medicamentos, relaciones entre genes y enfermedades, o entender mejor las reacciones químicas, lo cual acelera el proceso de descubrimiento.

Educación y tutoría personalizada: están revolucionando la educación. Al adaptarse fácilmente a diferentes tipos de contenidos y preguntas, estos modelos pueden ofrecer tutoría personalizada a estudiantes, responder preguntas sobre cualquier tema, explicar conceptos complejos de manera sencilla y hasta ayudar a los docentes a diseñar

materiales educativos. Por ejemplo, un estudiante de secundaria puede interactuar con un modelo que le explique temas de Matemáticas, Biología o Historia en términos claros y, si tiene dudas, el modelo ajusta sus respuestas de acuerdo con el nivel de comprensión del estudiante.

Asistencia en tareas cotidianas y productividad: desde la planificación de reuniones hasta la creación de contenido creativo, los modelos fundacionales también están siendo usados para mejorar la productividad. Con aplicaciones que utilizan IA como asistente personal, es posible gestionar agendas, organizar tareas o, incluso, generar presentaciones o informes automáticamente. Estos modelos son capaces de entender el contexto de lo que necesitas hacer, y adaptarse para ayudarte de la manera más eficiente posible, lo que facilita enormemente tareas cotidianas que antes requerían mucho tiempo y esfuerzo.

Arte, diseño y creatividad: permiten a artistas, diseñadores y creadores llevar sus ideas a otro nivel. Con modelos que generan imágenes, como DALL-E, es posible crear arte a partir de descripciones en texto, lo que abre una gama de posibilidades para diseñadores gráficos y publicitarios. En literatura, modelos como ChatGPT pueden colaborar en la creación de guiones, poesías y narrativas. Y lo mejor es que pueden adaptarse al estilo específico de cada artista, logrando resultados únicos y originales en tiempo récord.

Aplicaciones de seguridad y vigilancia: pueden identificar comportamientos sospechosos en tiempo real al analizar video vigilancia. Con su capacidad para adaptarse a diferentes entornos y escenarios, pueden alertar sobre movimientos inusuales en una zona determinada o sobre personas que puedan estar en peligro. Esto es especialmente útil en aeropuertos, eventos multitudinarios o sistemas de transporte, donde la IA puede ayudar a los equipos de seguridad a monitorear grandes cantidades de datos visuales y tomar decisiones rápidas.



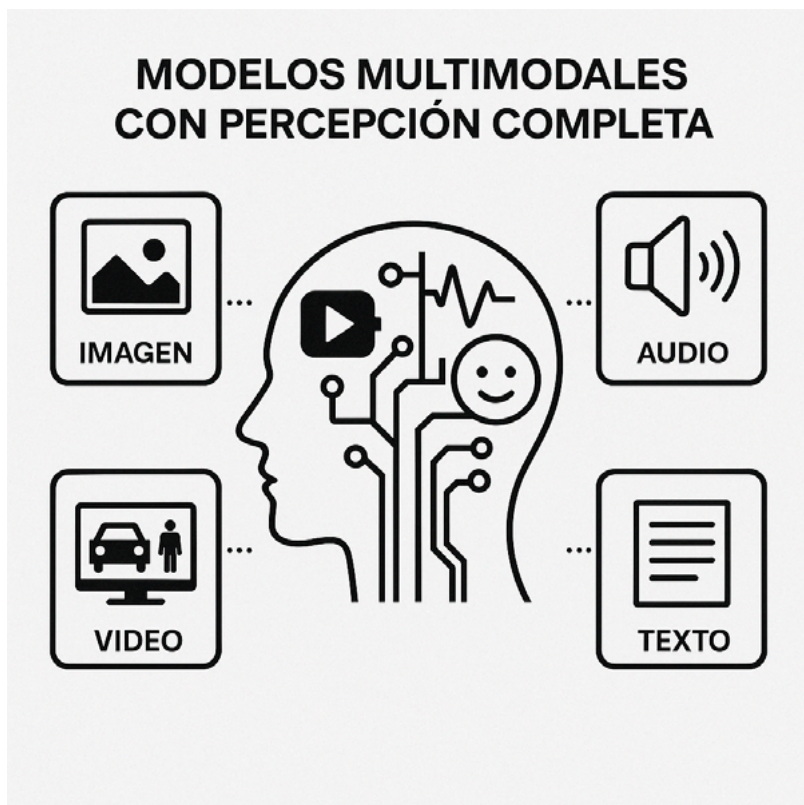
¿Por qué cambian las reglas del juego? Lo que hace realmente revolucionarios a los modelos fundacionales es su escalabilidad y su velocidad de adaptación. Antes, entrenar una IA para cada tarea requería un modelo nuevo y se empleaban días o semanas, incluso meses, de entrenamiento. Con los modelos fundacionales, basta con un entrenamiento adicional muy breve para que una IA se especialice en una tarea específica. Esto significa que una misma infraestructura de IA puede usarse en una cantidad casi ilimitada de aplicaciones, y que, en vez de tener que desarrollar tecnología diferente para cada industria, los modelos fundacionales ofrecen una base común que puede ajustarse a necesidades concretas.

Además, estos modelos son sostenible a largo plazo. A medida que la tecnología avanza, se puede seguir mejorando y afinando el mismo modelo, sin necesidad de reemplazarlo completamente, lo cual representa un enorme ahorro de recursos. Este enfoque permite que la IA no solo crezca en capacidades, sino que lo haga de una forma eficiente, económica y rápida. De esta manera, los modelos fundacionales importan tanto porque ofrecen una nueva forma de ver la IA, a saber: una que es más versátil, accesible y poderosa. Al ser capaces de aprender una vez y adaptarse múltiples veces, estos modelos están construyendo un futuro en el que la IA será cada vez más una parte natural de nuestras vidas, ayudándonos en todo, desde las tareas más rutinarias hasta los problemas más complejos.

¿Y qué sigue? El futuro de los modelos fundacionales promete una evolución que va mucho más allá de lo que hemos visto hasta ahora. Los científicos e ingenieros están buscando formas de hacer que estos modelos no solo comprendan más tipos de datos, sino que también adquieran una capacidad de razonamiento y contexto mucho más profunda. La idea no es simplemente aumentar su tamaño o la cantidad de datos que absorben, sino mejorar la forma en que integran diferentes tipos de información: texto, imagen, audio y video de manera simultánea. Esto significa que estamos encaminándonos hacia modelos que puedan interpretar el mundo de una forma más “humana”, tomando

decisiones informadas con base en lo que ven, oyen y leen, como lo haría una persona experimentada en varias áreas.

Modelos multimodales con percepción completa



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

La siguiente gran meta es crear modelos multimodales que puedan procesar varios tipos de información al mismo tiempo y entender cómo se relacionan entre sí. Imagina un modelo que no solo vea una foto y la describa, sino que también entienda el sonido de fondo y el contexto en el que esa imagen fue tomada. Este modelo podría observar un

video en una escena de calle y no solo identificar los autos y peatones, sino también comprender los sonidos de los autos acercándose o las conversaciones que ocurren alrededor, interpretando todo esto como una situación coherente. Sería como un “súperobservador” que analiza y comprende cada detalle de lo que está pasando. Por ejemplo, en el ámbito médico, un modelo de este tipo podría analizar un video de una intervención quirúrgica, identificar los instrumentos que el cirujano utiliza, el ritmo de los movimientos, los sonidos de los monitores, y así evaluar si el procedimiento está progresando bien o si algo pudiese salir mal. Este tipo de percepción completa podría ayudar en la capacitación de médicos, en la supervisión de procedimientos complejos y hasta en la asistencia en tiempo real en situaciones críticas.

Otra dirección que están explorando los investigadores es lograr que los modelos fundacionales no solo perciban información, sino que entiendan el contexto y las intenciones detrás de cada elemento. Por ejemplo, si el modelo escucha una conversación, no solo identificará las palabras o el tono, sino que tratará de deducir las emociones o la intención del hablante. Podría notar que una persona está molesta no solo por lo que dice, sino por cómo lo dice y la expresión en su rostro. Este nivel de comprensión situacional es crucial en áreas como la atención al cliente, donde el modelo podría no solo responder preguntas, sino también adaptar su tono y estilo en función del estado de ánimo de la persona con la que está interactuando.

Aprendizaje continuo e interactivo: para hacer que estos modelos sean realmente útiles en un mundo dinámico, los científicos también están buscando formas de incorporar el aprendizaje continuo y la interacción en tiempo real. Esto implica que los modelos no solo “aprendan” una vez y se queden con ese conocimiento, sino que sigan evolucionando mientras interactúan con el mundo. Imagina un modelo que observa y aprende de cada nueva conversación, video o imagen que procesa, adaptándose y mejorando constantemente. Este tipo de aprendizaje en tiempo real es similar a cómo los humanos ajustan sus conocimientos y habilidades con cada experiencia, y permitiría que los modelos fundacionales

fueran mucho más flexibles y eficaces en entornos que cambian rápidamente. Por ejemplo, un modelo fundacional en un entorno de atención médica podría actualizar sus conocimientos a medida que se aprueban nuevos tratamientos o se descubren enfermedades. De esta manera, se mantendría al día con los avances médicos y ofrecería información basada en la investigación más reciente, sin necesidad de que los programadores lo reentrenen manualmente.

Capacidades de razonamiento y predicción: basadas en múltiples factores simultáneos, significa que, en lugar de simplemente responder a las solicitudes de información, estos modelos podrían analizar varias fuentes de datos y hacer inferencias complejas. Un ejemplo sería un sistema que no solo entiende el tráfico en una ciudad en tiempo real, sino que también puede prever congestiones basándose en eventos como un partido de fútbol o una protesta, y recomendar rutas alternativas antes de que se generen los embotellamientos. Para lograr esto, los investigadores están experimentando con estructuras de modelos más complejas que permitan integrar información contextual, secuencial y causal. Este enfoque podría revolucionar industrias enteras, desde la logística, donde se podrían optimizar rutas en tiempo real, hasta el comercio minorista, donde los modelos podrían anticipar la demanda de ciertos productos en función de tendencias y patrones de consumo, ajustando automáticamente los niveles de inventario y las estrategias de mercadeo.

Comunicación e interacción natural: una de las aspiraciones más grandes para los modelos fundacionales del futuro es que puedan comunicarse e interactuar de forma natural y sin esfuerzo. Hoy en día, estos modelos responden a preguntas y siguen instrucciones, pero los investigadores quieren que sean capaces de mantener una conversación fluida, entender cambios sutiles en el contexto, y adaptarse sin esfuerzo a las necesidades de los usuarios. Esto significa que en el futuro podríamos tener modelos que no solo nos respondan, sino que también sepan cuándo hacer una pregunta para aclarar algo o cuándo proporcionar información adicional. Un modelo fundacional avanzado podría, por ejemplo, ser un



asistente personal en toda regla. Imagina que este modelo no solo agenda una reunión cuando se lo pides, sino que también te sugiere un cambio de hora si nota que tienes un compromiso cercano o que organiza el transporte para que llegues a tiempo. Este tipo de interacción natural y proactiva sería invaluable en entornos corporativos, en la gestión del hogar o, incluso, en situaciones complejas como la coordinación del cuidado de una persona enferma.

Ética y control de sesgos en modelos más complejos: conforme estos modelos se vuelven más inteligentes y autónomos, una parte crucial del desarrollo es asegurar que se comporten de manera ética y justa. A medida que se vuelven más independientes y complejos, existe el riesgo de que puedan adquirir o amplificar sesgos en los datos con los que fueron entrenados, especialmente si integran información de múltiples fuentes. Por eso, una de las áreas en las que los investigadores están trabajando intensamente es en crear mecanismos de control y ajuste que detecten y minimicen posibles sesgos. Esto se puede lograr haciendo que los modelos revisen y comparen datos de diferentes fuentes o ajustando algoritmos para que den más peso a fuentes de datos equilibradas y confiables.

La ética también implica definir límites en las capacidades de estos modelos, especialmente cuando se trata de privacidad y seguridad de la información. Con modelos que pueden “ver”, “escuchar” y “entender” situaciones completas, es fundamental implementar controles que garanticen que estos sistemas respeten la privacidad de las personas y no se utilicen en contra de sus intereses. De esta forma, los modelos fundacionales del futuro no solo serán poderosos, sino que también operarán bajo principios éticos que aseguren su uso responsable y seguro.

Colaboración con otros sistemas de IA: los modelos fundacionales están evolucionando hacia sistemas que no trabajan solos, sino que colaboran con otros sistemas de IA y tecnologías complementarias. En lugar de ser una herramienta aislada, estos modelos podrían funcionar como una

plataforma central que coordina y optimiza el rendimiento de diferentes herramientas de IA. Por ejemplo, un modelo fundacional podría integrarse con sistemas de visión por computadora especializados, *software* de reconocimiento de voz y motores de recomendación, actuando como el “cerebro” que combina los resultados de cada sistema para ofrecer una respuesta unificada.

Imagina una aplicación en una fábrica donde un modelo fundacional coordina robots de ensamblaje, sensores de calidad y sistemas de logística. Este modelo podría analizar cada paso en tiempo real, detectar posibles problemas en la cadena de producción y ajustar los procesos para mejorar la eficiencia, todo mientras interactúa con los empleados y responde sus preguntas. Este tipo de colaboración entre tecnologías marca el camino hacia sistemas de IA verdaderamente autónomos y robustos, que integran múltiples capacidades y operan de manera sincronizada para alcanzar objetivos complejos.

Modelos de lenguaje a gran escala (LLM)

¿Qué son los modelos de lenguaje a gran escala? Hoy en día se habla mucho de la IA. Es una de esas cosas que se ha vuelto tan común que casi ni nos damos cuenta de que la usamos a diario. La tenemos, como ya vimos, en el celular, en el internet y hasta en esas recomendaciones de series o música que parecen leerse la mente. Pero uno de los inventos más impresionantes de la IA, de los que más llaman la atención, son los modelos de lenguaje a gran escala, conocidos en inglés como *large language models* (LLM). Estos modelos son como bibliotecas vivientes que “han leído” millones de textos. Imagina que tienes un amigo que no solo ha leído libros y artículos, sino también páginas de internet y conversaciones entre personas. Ahora, este amigo ha memorizado un montón de palabras, frases y cómo se usan en distintos contextos, como un experto en lenguaje. Pues bien, estos modelos de IA funcionan de una manera parecida: son programas entrenados con cantidades gigantescas de información y, gracias a eso, pueden responder o escribir sobre casi cualquier tema, aunque nunca hayan tenido la experiencia real.



Entonces, ¿cómo funcionan los LLM? Para una mayor claridad, hagamos una analogía sencilla. Supón que este amigo de nuestro ejemplo no tiene ideas propias, no sabe lo que es el mundo, pero tiene una memoria perfecta de todo lo que ha leído. Su cerebro funciona como un gigantesco archivo de texto, en el que puede buscar y armar frases de acuerdo con lo que le han enseñado. Entonces, si le preguntas sobre, digamos, “cómo preparar una buena taza de café”, no es que él haya preparado una taza de café en la vida, pero como ha leído muchas recetas y artículos sobre el tema, puede darte una respuesta muy convincente. Es decir, los LLM no piensan ni tienen sentimientos, pero han aprendido a usar el lenguaje tan bien que a veces pareciera que sí. En su entrenamiento, leen texto tras texto, sin saber realmente lo que significa, pero captan patrones, estructuras y estilos de conversación. Así, cuando alguien les hace una pregunta, buscan en su “memoria” (en realidad, su archivo de patrones y conexiones entre palabras) y responden de una manera que suena lógica y natural.

¿Qué los hace grandes? El apelativo de “grandes” no tiene nada que ver con el tamaño físico de una máquina o con que necesiten mucho espacio, aunque sí requieren buenos equipos y mucha capacidad de cómputo. Lo que los hace “grandes” es la cantidad de “parámetros” que tienen. Para que sea fácil de entender, piensa en estos parámetros como ajustes o “botones” que el modelo va moviendo hasta lograr que su respuesta sea lo más acertada posible. Cuantos más de estos parámetros tenga, mejor puede ajustar su respuesta para que sea precisa y natural. Te acuerdas de los *transformers* y de cómo “aprendían”, pues bien, cada ciclo de aprendizaje se ajustan estos miles de millones de parámetros una y otra vez hasta que finalmente la red neuronal encuentra la mejor combinación de estos parámetros y *voilà* tenemos un modelo que puede predecir la siguiente palabra tan bien casi como un humano.

Cuando hablamos de un modelo con miles de millones de parámetros, estamos hablando de un programa que puede recordar y entender relaciones entre palabras de una forma súperdetallada. Los LLM hacen eso con el lenguaje: tienen miles de ajustes posibles para entender y



generar respuestas que suenen como si fueran de una persona que sabe del tema.

Este “amigo” artificial no ha leído exactamente lo mismo que tú o yo. Los LLM también se entrenan con una mezcla de textos que incluyen libros, artículos, documentos de internet, publicaciones de blogs e incluso interacciones de redes sociales (claro, con filtros para evitar información que sea incorrecta o poco confiable). Esto es importante porque cuanto mayor variedad de textos “leen”, más ricos se vuelven sus conocimientos, o al menos sus patrones de cómo se habla de diferentes temas. Por ejemplo, en su “lectura” puede encontrar tanto una receta de cocina como una guía técnica sobre cómo reparar un auto. Gracias a esto, puede responder preguntas sobre muchas cosas distintas, desde algo simple hasta algo muy específico. Sin embargo, hay temas que no entiende del todo porque no tiene experiencias reales ni un conocimiento profundo. Es decir, puede responder como quien ha leído mucho, pero no como quien ha experimentado algo por sí mismo.

La razón por la que estos modelos de lenguaje son tan populares es porque son altamente versátiles y útiles. Empresas de tecnología los han empezado a incluir en servicios de atención al cliente para responder preguntas rápidas, en herramientas de productividad para ayudarnos a escribir documentos o resúmenes, y hasta en aplicaciones de aprendizaje que enseñan idiomas o historia. También son útiles para tareas que requieren un tiempo prolongado, como leer y resumir documentos extensos. Imagínate que tienes que leer un texto de cien páginas y alguien te da un resumen en unos segundos. Eso es lo que puede hacer un LLM. No es un reemplazo total, pero es una ayuda grandísima cuando necesitas procesar información rápido.

Algo curioso de los LLM es que, aunque estos modelos pueden sonar inteligentes, realmente no lo son. No tienen sentido común, no entienden lo que sienten las personas, ni tienen experiencias. Son programas que “aparentan” ser inteligentes porque responden de manera lógica, pero no “saben” nada. Si les haces una pregunta nueva, que esté fuera de sus

patrones de texto, probablemente no sabrán qué responder o inventarán algo que suene bien. Los LLM son como ese amigo que sabe hablar bien y que siempre parece tener una respuesta, pero que a veces suelta cosas raras cuando el tema se sale de su “zona”. Por eso, aunque son muy útiles, siempre hay que usarlos con precaución y no creerles ciegamente.



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

La temperatura: ajustando la creatividad del modelo

Uno de los controles interesantes en los LLM es la temperatura, la cual se utiliza para ajustar qué tan “creativas” o “arriesgadas” son las respuestas del modelo. Piensa en la temperatura como un termostato para el nivel de sorpresa o variabilidad en las respuestas: cuando subes la temperatura,

las respuestas pueden volverse más variadas y sorprendentes, y cuando la bajas, se vuelven más predecibles y seguras.

La temperatura va de 0 a 1, aunque puedes encontrar configuraciones incluso superiores. Si la temperatura es muy baja, digamos 0.1, el modelo tiende a dar respuestas más “seguras” y repetitivas. Es decir, busca las palabras que estadísticamente son más comunes en el contexto dado y tiende a repetir patrones de respuesta más estables. Esto es útil para tareas donde necesitas precisión, como responder preguntas factuales o seguir instrucciones claras. Por otro lado, si subes la temperatura a un nivel alto, como 0.9, el modelo se vuelve más “creativo”. En lugar de seguir solo las opciones de palabras más probables, se abre a opciones menos frecuentes, lo que puede resultar en respuestas originales o inesperadas. Esto puede ser muy útil cuando quieres una respuesta creativa, como escribir un poema o generar ideas nuevas. Sin embargo, también aumenta el riesgo de obtener respuestas menos precisas o incluso un poco desconectadas del tema.

Para entender la temperatura, veamos el siguiente ejemplo: imagina que le pides al modelo que te escriba una historia sobre un dragón. Con una temperatura baja, el modelo probablemente seguirá una estructura clásica, con un dragón guardando un castillo y un caballero tratando de vencerlo. Pero con una temperatura alta, el modelo podría comenzar a hacer que el dragón sea vegetariano, que tenga un amigo unicornio y que vivan aventuras juntos en un bosque encantado. A mayor temperatura, mayor es la “imaginación” del modelo, aunque esto también puede llevar a respuestas menos coherentes.





Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Top-p: ajustando la probabilidad de selección de palabras

Además de la temperatura, otro parámetro importante es el top-p, también conocido como *nucleus sampling*. Este parámetro define qué tan “profunda” será la selección de palabras en función de su probabilidad, limitando las opciones a un porcentaje acumulado de las palabras más probables. Top-p es un valor que va de 0 a 1. Cuando se establece un valor bajo de top-p, como 0.2, el modelo solo considerará las palabras más probables en cada paso de la generación. Esto significa que el modelo es más conservador en su elección de palabras y tiende

a quedarse con opciones seguras, parecidas a las que daría con una temperatura baja. Cuando top-p es alto, digamos 0.9, el modelo incluye una mayor variedad de palabras, algunas con probabilidades menores en la generación de respuestas. Con esto, el modelo sigue siendo coherente, pero tiene más opciones para introducir variedad, lo cual permite respuestas más interesantes o inusuales, sin ser tan impredecible como con una temperatura muy alta. En otras palabras, el top-p define un “nicho” dentro del cual el modelo selecciona las palabras, dándole libertad, pero sin volverse demasiado caótico.

Ejemplo para entender el top-p: supón que le pides al modelo un consejo para hacer nuevos amigos. Con un top-p bajo, el modelo probablemente ofrecerá respuestas seguras y comunes, como “sé amable y escucha a los demás”. Pero con un top-p alto, el modelo podría sugerir consejos menos comunes, como unirse a un club de teatro o aprender a contar chistes. El modelo explora más allá de las respuestas típicas, pero aún dentro de un rango controlado, lo que hace que las respuestas sean creativas sin perder coherencia.

Combinación de temperatura y top-p

Estos dos parámetros se pueden ajustar juntos para afinar la personalidad del modelo según la situación. Por ejemplo:

Temperatura baja + top-p bajo: respuestas seguras, directas y predecibles. Ideal para respuestas técnicas o para seguir instrucciones claras.


Temperatura alta + top-p alto: respuestas más creativas y variadas, perfectas para tareas de escritura creativa o *brainstorming*, donde no necesitas precisión, sino nuevas ideas.

Temperatura baja + top-p alto: genera respuestas con algo de creatividad, pero manteniendo una estructura lógica. Útil cuando necesitas una respuesta interesante sin perder el enfoque.



Temperatura alta + top-p bajo: una combinación menos común, donde la creatividad es alta, pero las opciones de palabras son más restringidas. Esto que puede llevar a respuestas que suenen originales, pero menos variadas.

Las “alucinaciones” de los LLM



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Ahora, a pesar de lo impresionantes que son los LLM, tienen algunos problemas, y uno de los más notorios son las llamadas “alucinaciones”. No, no estamos hablando de que el modelo “vea” cosas que no existen, pero es algo parecido en el sentido de que a veces generan información que suena lógica y creíble, pero es completamente falsa o inventada.

Imagina que tienes un amigo que, con tal de no quedarse sin respuesta, empieza a inventar cosas. Así funcionan las alucinaciones en estos modelos. Como los LLM no entienden realmente de lo que están hablando y solo buscan patrones en el lenguaje, a veces pueden mezclar datos o crear respuestas que suenan confiables pero que no tienen ninguna base real. Esto pasa, por ejemplo, cuando les preguntas algo muy específico o fuera de su “zona de confort”. Supón que le preguntas a un LLM sobre un tema muy técnico, como el nombre de un científico que descubrió una enfermedad rara en 1960. El modelo puede darte una respuesta rápida, con detalles y fechas, y todo suena coherente, pero en realidad es pura invención. Esto es peligroso, especialmente si se usa para cosas importantes como diagnósticos médicos, investigación científica o asesoría legal. Ahí es donde se necesita precaución y siempre revisar la información antes de confiar ciegamente en la respuesta. Estas “alucinaciones” son una limitación seria en el uso de los LLM para tareas críticas. Aunque estos modelos están mejorando y las empresas están trabajando en estrategias para reducir este problema, aún queda mucho camino por recorrer. Así que si usas un modelo de lenguaje para obtener información, siempre es buena idea verificar lo que te dice.

La ventana de contexto: ¿hasta dónde pueden recordar?

Otro concepto clave para entender cómo funcionan estos modelos es el de *ventana de contexto*. Para explicarlo fácil, piensa en la ventana de contexto como la capacidad de memoria a corto plazo del modelo. Es decir, cuántas palabras o frases puede “recordar” mientras responde una pregunta o redacta un texto. La ventana de contexto define la cantidad máxima de palabras que el modelo puede analizar a la vez. Por ejemplo, si la ventana de contexto es de 4000 palabras, el modelo puede tener en



cuenta hasta 4000 palabras de una conversación o texto antes de que empiece a “olvidar” lo que vino antes. Una vez que se supera ese límite, las palabras o frases que quedaron atrás empiezan a desaparecer de su “memoria”, y el modelo solo trabaja con la información más reciente dentro de esa ventana.

Como ejemplo, imagina que estás contando una historia larga a alguien, pero cada vez que llegas a la palabra 4001, la persona olvida automáticamente lo primero que le contaste. Esto significa que si le haces una pregunta sobre algo que dijiste al inicio de la historia, probablemente no lo recuerde. Lo mismo pasa con los LLM: cuando la conversación o el texto son más largos que la ventana de contexto, el modelo pierde información clave que ya no puede usar para armar respuestas coherentes.

¿Por qué es importante la ventana de contexto? Porque limita la cantidad de información que el modelo puede usar para responder con precisión, especialmente en temas largos o complejos. Si estás escribiendo un informe extenso o manteniendo una conversación prolongada, el modelo podría perder de vista algunos detalles importantes al final, lo cual puede afectar la coherencia y la precisión de las respuestas. En modelos más avanzados, como GPT-4, GPT4o, Gemini, las ventanas de contexto se han ido ampliando, permitiendo que puedan “recordar” más texto (en realidad son *tokens*) a la vez y ofreciendo una experiencia de conversación o redacción más fluida y precisa. Pero incluso con estas mejoras, sigue existiendo un límite, lo que implica que los usuarios deben estar atentos a este detalle para evitar perder información o tener respuestas incompletas.

Cómo evitar problemas con las alucinaciones y con la ventana de contexto: para minimizar los problemas de alucinación, una buena práctica es dividir temas complejos en partes más manejables y, si es posible, proporcionar al modelo fuentes de información confiables para que pueda “consultarlas” durante la conversación. Esto ayuda a que las respuestas sean más precisas y que el modelo no intente “adivinar” de

manera errónea. Respecto a la ventana de contexto, es útil saber cuánto puede recordar el modelo que estás usando y, si el texto es muy largo, ir resumiendo los puntos clave para que no pierdas de vista la información importante. Además, algunas aplicaciones permiten reiniciar el modelo para “limpiar” la memoria de conversaciones anteriores y empezar de nuevo con información fresca.

Asistentes de IA como ChatGPT, Gemini y Claude: ¿cómo aprenden de nosotros?

Asistentes de IA como ChatGPT, Gemini y Claude se han vuelto herramientas de uso cotidiano para millones de personas. Nos ayudan a responder preguntas, escribir textos, resolver problemas y hasta a obtener recomendaciones de manera rápida y conveniente. Pero, ¿cómo llegan a ser tan efectivos? La clave está en un tipo de entrenamiento llamado *reinforcement learning from human feedback* (RLHF), o en español, aprendizaje por refuerzo a partir de retroalimentación humana. Este proceso de aprendizaje con retroalimentación humana permite que estos modelos no solo generen respuestas, sino que también mejoren continuamente en cómo entienden y responden a las personas. Vamos a ver entonces cómo funciona.

¿Qué es el *reinforcement learning from human feedback* (RLHF)?

El aprendizaje por refuerzo con retroalimentación humana es una técnica avanzada que permite a los modelos de IA mejorar continuamente sus respuestas gracias a la intervención de personas reales. A diferencia de los métodos tradicionales, donde los modelos de IA se entrenan solo con grandes cantidades de datos preexistentes, el RLHF introduce un sistema de aprendizaje en el que el modelo puede adaptarse en tiempo real y ajustarse para responder de manera más precisa, útil y natural. Este método se basa en el aprendizaje por refuerzo, un enfoque en el que los modelos reciben “recompensas” o “castigos” según el desempeño de sus



respuestas. Esto se asemeja a un proceso de ensayo y error en el que, a medida que el modelo responde, se le indica si lo que hizo está bien o mal. Sin embargo, la particularidad del RLHF es que estas evaluaciones no provienen de un sistema automático o de un cálculo interno del modelo, sino de humanos que califican y ajustan las respuestas. Este “*feedback*” directo de los humanos permite al modelo recibir correcciones sobre si su respuesta es relevante, precisa, ética, segura o clara, según sea el caso. Es decir, en lugar de limitarse a reproducir patrones en el lenguaje, el modelo se vuelve más consciente de los criterios específicos que hacen que sus respuestas sean útiles y correctas para los usuarios.

Etapas del RLHF

Generación de respuestas y recopilación de *feedback*: primero, el modelo genera respuestas a partir de preguntas o indicaciones que se le proporcionan, como en una conversación real. Luego, un equipo de evaluadores humanos analiza estas respuestas. Los evaluadores pueden ser expertos en el área o personas entrenadas para evaluar la utilidad, precisión y claridad de las respuestas en diversas situaciones.

Aplicación de recompensas y castigos: cada respuesta generada por el modelo recibe una evaluación. Si la respuesta cumple con criterios de calidad —por ejemplo, si es precisa, completa y adecuada—, el modelo recibe una “recompensa”. Si la respuesta es incorrecta, imprecisa o confusa, recibe un “castigo”. Estas recompensas y castigos no son tangibles, sino ajustes internos en los parámetros del modelo, que guían su aprendizaje futuro.

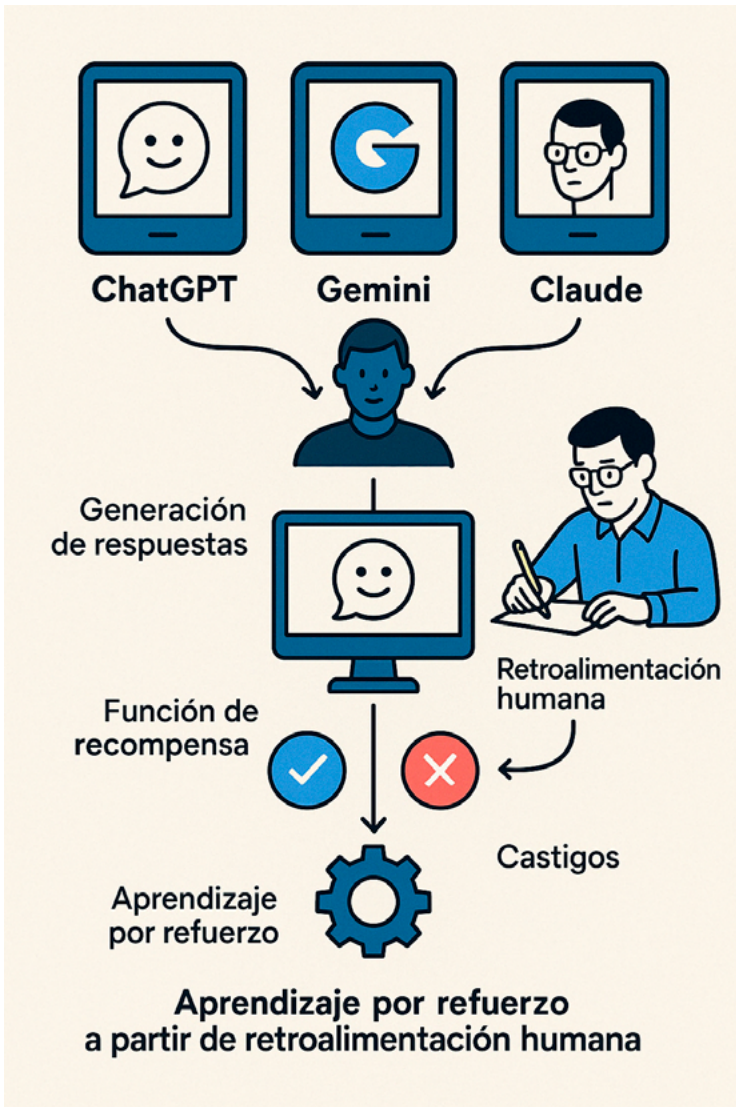
Entrenamiento del modelo de recompensa: a partir de estas evaluaciones humanas, se construye un modelo de recompensa que imita el proceso de retroalimentación humana. Este modelo de recompensa actúa como una especie de “juez interno” que ayuda al sistema a identificar, en futuras interacciones, cuáles respuestas se alinean mejor con los estándares de calidad establecidos por los evaluadores humanos. Esto

reduce la necesidad de intervención constante de los evaluadores y permite que el modelo siga aprendiendo de manera más autónoma.

Optimización mediante aprendizaje por refuerzo: finalmente, el modelo se ajusta usando algoritmos de aprendizaje por refuerzo, que optimizan su desempeño de manera continua. Esto significa que, a medida que el modelo interactúa más, se convierte en una versión mejorada de sí mismo, manteniendo y fortaleciendo aquellos patrones de respuesta que han sido recompensados y desechando los que no funcionan bien.

Ventajas del RLHF en los modelos de lenguaje: el RLHF es especialmente útil en asistentes de IA como ChatGPT, Gemini y Claude porque permite una adaptación constante a las necesidades de los usuarios, mejorando la calidad de las respuestas con cada ciclo de entrenamiento. Además, el RLHF permite ajustar aspectos éticos y de seguridad en las respuestas del modelo. Por ejemplo, los evaluadores pueden “castigar” respuestas que contengan información sesgada o que sean potencialmente dañinas, lo cual entrena al modelo para evitarlas en el futuro. La gran fortaleza del RLHF radica en que combina la potencia de procesamiento de la IA con el juicio y la intuición de los humanos. Esto asegura que el modelo no solo se guíe por patrones en el lenguaje, sino que tenga un sentido más profundo de lo que hace que una respuesta sea realmente útil para el usuario. Aunque es un proceso costoso y que requiere tiempo, el RLHF permite que los modelos de IA evolucionen de manera más orgánica y se conviertan en herramientas mucho más confiables y adaptadas a los valores y necesidades humanas.





Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Prompts

Volvamos con nuestro amigo que lo sabe casi todo y siempre está dispuesto a darte una mano con cualquier tema, pero tiene un pequeño problema: a veces se le enreda la información. No es que no quiera ayudarte, sino que necesita que le hables de una forma específica para captar lo que necesitas. No le basta que le lances una pregunta general, sino que le des una pequeña guía o pistas para entender mejor. Esto es lo que llamamos un *prompt*.

¿Qué es un *prompt* y para qué sirve?

Un *prompt* es como un mensaje de texto que le mandas a una IA para explicarle exactamente lo que estás buscando. Más que una simple petición, el *prompt* es la clave para que la IA comprenda bien tu intención. Se parece a cuando le pides a alguien que te explique un tema difícil, pero antes le das un poco de contexto para que sepa por dónde empezar y no te deje aún más confundido.

Supongamos que quieres saber sobre historia. Si solo le dices a la IA lo siguiente: “Explícame historia”, es como decirle a tu amigo “háblame de cualquier cosa sobre historia”. Claro, te va a responder, pero puede que la información sea tan general que no te sirva. Pero, ¿qué pasa si en vez de eso le dices algo más detallado? Por ejemplo: “Explícame la historia de Colombia en el siglo XIX”. Ahora, en este caso, la IA tiene una pista clara, a saber: sabe que te interesa un lugar y una época específicos. Con esta precisión te puede dar una respuesta que realmente tenga sentido para lo que necesitas.



Así que el truco está en cómo armas tu *prompt*: cuanto más específico seas y mejor le expliques a la IA lo que quieres, más útil será la respuesta que recibas. Vamos a seguir dándole forma a este tema para que quede claro cómo funcionan los *prompts* y por qué son tan útiles. No se trata solo de formular preguntas al azar; hay que saber cómo estructurar lo que pedimos para que la IA responda justo como queremos. Aquí vamos a ver desde las bases hasta algunos temas más avanzados, porque este mundo tiene su ciencia.

¿Por qué los *prompts* son tan importantes?

Imagina que tienes un control remoto para usar la IA. Cada vez que escribes un *prompt*, es como si presionaras un botón en ese control, diciéndole a la IA qué debe hacer. Pero, aquí va el truco: no todos los botones funcionan igual. Si no sabes bien cuál botón presionar, la IA puede responder algo completamente carente de relación con lo que tú quieres. El *prompt* es el puente que une lo que tú necesitas y lo que la IA sabe. Es decir, tú tienes en mente una pregunta o un problema, y el *prompt* le da esa información a la IA para que trabaje y te dé una respuesta. Esto significa que, cuanto mejor estructurado esté el *prompt*, mejor será la respuesta. Ahí es donde entran en juego las técnicas de *prompt engineering* o “ingeniería de *prompts*”^{xxvi}.

¿Qué es la “ingeniería de *prompts*”?

Puede sonar a ciencia complicada, pero la ingeniería de *prompts* es solo el arte de crear mensajes que ayuden a la IA a darte la mejor respuesta. Según un estudio de Sahoo y sus colegas^{xxv}, esto permite guiar a los LLM para que se adapten a tareas específicas sin necesidad de ajustarles sus “cerebros”. Imagínate que la IA es un chef experto en cocina, pero puede que necesites darle indicaciones para que cocine algo a tu gusto; esa es la idea con los *prompts*.

No es cualquier cosa, porque en vez de tener que reentrenar el modelo cada vez que queremos que haga algo nuevo, el *prompt* adecuado puede

lograr que la IA se ajuste a lo que necesitas. Así, puedes pedirle que resuelva desde problemas matemáticos hasta que te cuente un cuento, solo con cambiar el *prompt*.



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Anatomía de un buen *prompt*

No existe tal cosa como una “fórmula mágica” para los *prompts*, y esto se debe a que la interacción con un LLM no es un proceso lógico, sino una navegación por un sistema complejo y no lineal. Cada *prompt* se traduce a un vector en un espacio latente de miles de millones de dimensiones, y la arquitectura *transformer* del modelo es tan sensible que un cambio mínimo en la entrada (*prompt*) puede alterar drásticamente la trayectoria dentro de este espacio. A esto se suma la naturaleza estocástica de la generación, donde el modelo muestrea respuestas a partir de una distribución de probabilidad. Como resultado, la única metodología viable es un proceso empírico de ensayo y error. Este proceso es, además, enteramente dependiente del modelo, ya que cada uno posee un espacio latente, un entrenamiento y unos sesgos únicos que hacen



que las técnicas de *prompting* exitosas en uno no sean transferibles a otro.

Sin embargo, y en mi propia experiencia, un *prompt* efectivo debe ser claro y específico. Cuando quieres que algo salga bien, das instrucciones detalladas. Si eres dueño de una pequeña empresa y necesitas un análisis de mercadeo, pedirle a la IA “dame un análisis de *mercadeo*” es tan vago como pedirle a alguien que “mejore las ventas” sin decirle cómo. En cambio, si dices “analiza las ventas de mis productos de café en redes sociales y sugiere estrategias para llegar a más clientes de 20 a 30 años”, la IA sabrá exactamente qué hacer y te dará información relevante.

Un buen *prompt* tiene tres elementos clave:

- Claridad: no dejes dudas en lo que pides.
- Especificidad: define exactamente lo que buscas.
- Contexto: dale un poco de contexto para que entienda en qué dirección responder.

Estos elementos ayudan a la IA a no perderse en respuestas generales y enfocarse en lo que realmente necesitas.

Estilos de *prompts*

Dependiendo de lo que necesites, el estilo de tu *prompt* puede variar. Aquí te explico algunos estilos comunes:

Interrogativo (pregunta directa): este es el estilo de “pregunta clara”. Útil cuando quieres respuestas concretas. Por ejemplo, si eres médico y necesitas que la IA te dé información rápida, podrías usar un *prompt* como el siguiente: “¿Cuáles son los síntomas principales del dengue en adultos?”. La IA entiende que esperas una lista clara y detallada.

Imperativo (comando): con este estilo estás dando una orden. Es útil para obtener información o realizar tareas específicas. Imagina que eres un estudiante y tienes que escribir un ensayo sobre historia; podrías

pedirle a la IA esto: “Resume las causas de la Revolución Francesa en 300 palabras”. La IA se ajusta a esa longitud y te da justo lo que pediste.

Declarativo (dando contexto): estilo útil para guiar a la IA con más información. Por ejemplo, si eres un dueño de restaurante y quieres ideas para un menú, podrías decir un enunciado como este: “En el contexto de un restaurante italiano que usa ingredientes frescos y locales, sugiere ideas para entradas de verano”. Este tipo de *prompt* ayuda a la IA a generar ideas alineadas con tu visión.

Conversacional: si necesitas mantener una conversación con la IA, este estilo es ideal. Puedes iniciar con algo como: “Hola, me gustaría entender más sobre *mercadeo* digital”. Esto ayuda a la IA a responder de una manera más dialogada, útil para cuando quieres aprender y hacer preguntas de seguimiento.

Rol-objetivo-contexto: en este contexto es como darle un traje a la IA. Dices qué rol debe tomar, cuál es el objetivo y en qué contexto. Un ejemplo sería así: “Como contador, ofrece consejos a un emprendedor que quiere organizar sus finanzas para hacer crecer su negocio”. Aquí le das a la IA un rol específico, un propósito claro y un contexto, lo cual ayuda a que la respuesta sea precisa y ajustada.

Veamos algunos ejemplos prácticos para entender cómo estos estilos funcionan en la vida real:

“Describe los cuidados postoperatorios para pacientes mayores de 60 años que hayan tenido cirugía de cadera”. Este *prompt* es claro y específico, lo cual ayuda a la IA a centrarse en el cuidado necesario para un grupo particular de pacientes.

“Sugerencias de *mercadeo* para una tienda de ropa en línea enfocada en jóvenes entre 15 y 25 años”. Este *prompt* es directo y da contexto sobre el tipo de negocio y el público objetivo, por lo que asegura que la IA ofrezca ideas alineadas con tu mercado.



“Explica el concepto de energías renovables en palabras simples, como si se lo explicaras a alguien en secundaria”. Aquí la IA adapta el lenguaje para que sea entendible para adolescentes.

“En medicina, ¿qué nuevos tratamientos están disponibles para la diabetes tipo 2?”. Este *prompt* da contexto (medicina) y especifica la condición, lo cual coadyuva a que la IA brinde información actual y relevante.

“Dame ideas para un menú de *brunch* en un restaurante vegano”. Este *prompt* da contexto sobre el tipo de menú y el enfoque del restaurante, asegurando que la IA genere ideas acordes al tipo de cocina.

“Dame ideas para promocionar una oferta de muebles hechos a mano en redes sociales, dirigida a personas que buscan decoración rústica”. Este *prompt* ayuda a la IA a enfocar las ideas de *mercadeo* en un estilo específico (rústico) y a dirigirse al tipo de cliente que probablemente esté interesado en muebles artesanales.

“Explica cómo usar un teléfono inteligente para enviar mensajes de texto paso a paso, como si se lo estuvieras enseñando a un abuelo”. Aquí, la IA responderá con pasos simples y claros, adaptando el lenguaje para que sea fácil de entender para alguien que no está familiarizado con la tecnología.

“Sugiere ideas para promociones de flores frescas en San Valentín que atraigan a parejas jóvenes”. Este *prompt* le da contexto (San Valentín) a la IA y un público objetivo (parejas jóvenes), para que pueda sugerir promociones creativas y atractivas para la época.

“Ayúdame a planificar una actividad divertida para enseñar a niños de primer grado sobre el reciclaje”. En este caso, la IA generará ideas para una actividad que sea entretenida y educativa, ideal para captar la atención de niños pequeños y enseñarles la importancia del reciclaje de una manera práctica.

“Sugiere una lista de canciones populares de los años 50 y 60 del siglo pasado que me ayuden a recordar esa época”. Este *prompt* permite a la IA armar una lista de canciones nostálgicas que puedan ser significativas para alguien mayor, ofreciendo un toque personalizado para un viaje al pasado.

Zero-shot, One-shot y Few-shot learning

Imaginemos que tienes un amigo que nunca en su vida ha probado el mango. Sin embargo, un día lo pruebas tú, le dices que es jugoso, dulce y algo fibroso, y cuando él lo ve en el mercado dice: “Ahí está el mango”. No necesita probarlo para saber qué es. En el mundo de la IA, pasa algo parecido con lo que llamamos *zero-shot learning* o aprendizaje sin ejemplos previos. También existen otras técnicas, como el *one-shot learning* (aprendizaje con un solo ejemplo) y el *few-shot learning* (aprendizaje con pocos ejemplos), que ayudan a los modelos de IA a aprender y generalizar con poca información. A continuación, te explicaré de qué se tratan estas ideas, usando ejemplos para que la cosa quede clara^{xxvi}.

Zero-shot learning: aprendiendo sin ejemplos

El aprendizaje *zero-shot* es como si alguien te dice: “Un zorro fénix es un animal como un perro, pero con orejas largas y pelaje anaranjado”. Sin haber visto un zorro fénix en tu vida, podrías identificarlo solo con esa descripción. Los modelos que usan esta técnica son capaces de reconocer cosas que nunca han visto durante su “entrenamiento”. Para lograr esto, los científicos les enseñan a entender relaciones o atributos generales. Esta capacidad permite que un modelo sea extremadamente flexible y pueda adaptarse rápidamente a nuevos dominios sin necesidad de recopilar grandes volúmenes de datos.



Ejemplos de *zero-shot learning*:

1. Un detector de objetos que identifica “bicicletas eléctricas”, aunque solo haya sido entrenado con “bicicletas” y “motores”.
2. Un *chatbot* que responde preguntas sobre un tema que nunca ha estudiado, pero deduce las respuestas basándose en patrones lógicos.
3. Una *app* de fotos que reconoce a una “cebra” por ser como un “caballo” pero con rayas.

Aplicación en la ingeniería de *prompts*:

En la ingeniería de *prompts*, el *zero-shot learning* permite a los modelos responder a tareas nuevas sin necesidad de ejemplos adicionales en el *prompt*. Esto es especialmente útil cuando queremos instrucciones directas y claras, sin rodeos ni referencias complejas.

Ejemplos de *prompts zero-shot*:

1. “Resume este artículo científico en tres oraciones”.
2. “Genera un poema sobre el mar al estilo de Pablo Neruda”.
3. “Explica por qué los volcanes hacen erupción de forma simple para un niño de 8 años”.
4. “Proporciona una lista de consejos para ahorrar energía en casa”.
5. “Traduce esta frase del inglés al japonés sin usar ejemplos previos”.
6. “Describe cómo podría ser una ciudad flotante en el futuro”.
7. “Elabora una receta creativa usando mango y chocolate”.
8. “Responde la siguiente pregunta: ¿cuáles son los principales desafíos de la exploración espacial en el siglo XXI?”.

9. “Proporciona una lista de pasos para aprender un idioma extranjero rápidamente”.
10. “Describe los beneficios del ejercicio regular usando lenguaje simple”.

One-shot learning: aprendiendo con solo un ejemplo

Ahora imagínate que te presentan a una persona en una reunión: “Ella es Camila”. La ves una sola vez y, al día siguiente, si la cruzas en la tienda, ya la reconoces. Esto es el aprendizaje *one-shot*. En este caso, un modelo de IA aprende a identificar algo nuevo con un solo ejemplo. Es muy útil cuando no hay suficientes datos para entrenar al modelo.

Ejemplos de *one-shot learning*:

1. Un sistema de reconocimiento facial que identifica a una persona con solo una foto.
2. Una aplicación médica que detecta un tipo raro de cáncer basándose en una sola imagen.
3. Un robot que aprende a realizar una tarea viendo sólo un video tutorial.
4. Un *software* que detecta un nuevo tipo de *spam* en correos con un solo ejemplo.
5. Un modelo que identifica un logotipo nuevo de una marca después de verlo una sola vez.

Aplicación en la ingeniería de *prompts*:

En la ingeniería de *prompts*, el *one-shot learning* puede aplicarse proporcionando un ejemplo específico en el *prompt*. Esto permite al modelo seguir patrones concretos y generar resultados coherentes con el ejemplo.



Ejemplos de *prompts one-shot*:

1. “Aquí tienes un ejemplo de una historia corta: [texto de ejemplo]. Ahora escribe una historia similar sobre un viaje al espacio”.
2. “Dado este ejemplo de cómo responder una pregunta filosófica: [respuesta], responde esta: ¿qué es la felicidad?”
3. “Aquí tienes un ejemplo de un menú semanal saludable: [menú]. Crea un menú similar, pero para deportistas”.
4. “Con base en este ejemplo de un resumen ejecutivo: [texto]. Genera uno similar sobre un nuevo producto tecnológico”.
5. “Este es un ejemplo de poema corto: [poema]. Escribe uno sobre la naturaleza”.
6. “Aquí tienes un ejemplo de un anuncio publicitario efectivo: [anuncio]. Crea uno para promocionar una aplicación de meditar”.
7. “Este es un ejemplo de un trino viral sobre tecnología: [trino]. Escribe uno similar sobre inteligencia artificial”.
8. “Dado este ejemplo de una carta de agradecimiento: [carta]. Escribe una para un cliente fiel”.
9. “Con este ejemplo de biografía breve: [texto]. Escribe una biografía para un joven innovador”.
10. “Este es un ejemplo de un resumen de investigación: [resumen]. Crea uno para un estudio sobre energías renovables”.

Few-shot learning: aprendiendo con pocos ejemplos

Pongámonos en otro caso. Tu tía María quiere aprender a preparar empanadas colombianas. Le muestras tres recetas distintas y, con eso, ella ya sabe cómo variarlas para hacerlas con carne, pollo o champiñones. Así funciona el aprendizaje *few-shot*: el modelo aprende a partir de unos pocos ejemplos para generalizar y resolver nuevas tareas.

Ejemplos de *few-shot learning*:

1. Un modelo que aprende a identificar diferentes estilos de arte (cubismo, impresionismo, etc.) viendo unas pocas pinturas de cada uno.
2. Un sistema de diagnóstico que detecta enfermedades basándose en unas pocas muestras de cada caso.
3. Una IA que aprende a jugar un juego de mesa viendo unas cuantas partidas.
4. Una aplicación que crea resúmenes automáticos después de analizar unos pocos documentos.

Aplicación en la ingeniería de *prompts*:

En la ingeniería de *prompts*, el *few-shot learning* es clave para guiar al modelo con varios ejemplos concretos. Esto es particularmente útil en tareas complejas o que requieren entender un estilo específico.

Ejemplos de *prompts few-shot*:

1. “Aquí tienes tres ejemplos de cómo escribir correos formales: [ejemplo 1], [ejemplo 2], [ejemplo 3]. Ahora escribe un correo formal para solicitar un aumento de sueldo”.
2. “Dado este conjunto de ejemplos de descripciones de productos: [ejemplo 1], [ejemplo 2], [ejemplo 3]. Escribe una descripción para un producto nuevo llamado ‘EcoBot’”.
3. “Con base en estos ejemplos de respuestas a preguntas complejas: [respuesta 1], [respuesta 2]. Genera una respuesta a esta pregunta: ¿cómo afecta el cambio climático a los ecosistemas marinos?”
4. “Estos son tres ejemplos de historias para niños: [historia 1], [historia 2], [historia 3]. Escribe una historia corta sobre un delfín aventurero”.



5. “Aquí tienes ejemplos de poemas sobre estaciones del año: [primavera], [verano], [otoño]. Escribe uno sobre el invierno”.
6. “Dado este conjunto de respuestas cortas para preguntas frecuentes: [respuesta 1], [respuesta 2], [respuesta 3]. Genera una respuesta para: ¿cuáles son los beneficios de usar paneles solares?”.
7. “Aquí tienes ejemplos de preguntas para entrevistas de trabajo: [pregunta 1], [pregunta 2], [pregunta 3]. Genera cinco preguntas más para una entrevista sobre liderazgo”.
8. “Dado este conjunto de reseñas sobre restaurantes: [reseña 1], [reseña 2], [reseña 3]. Escribe una reseña para un restaurante especializado en comida fusión”.
9. “Con base en estas recetas de postres: [receta 1], [receta 2]. Crea una receta para un postre usando aguacate y chocolate”.
10. “Aquí tienes tres ejemplos de críticas de libros: [crítica 1], [crítica 2], [crítica 3]. Escribe una crítica sobre una novela de ciencia ficción”.

¿Por qué es importante esto?

En la vida real, muchas veces no tenemos miles de ejemplos para enseñarle algo a un modelo de IA. Imagínate entrenar una IA para diagnosticar una enfermedad rarísima o reconocer una especie en peligro de extinción. Estas técnicas nos permiten hacer mucho con poco, así que son herramientas clave para resolver problemas en salud, medio ambiente y tecnología.

El aprendizaje con poquitos ejemplos también nos recuerda cómo aprendemos los humanos. No necesitamos ver cientos de caballos para saber qué es un caballo, y podemos deducir cosas nuevas con descripciones simples o pocos ejemplos. La IA, inspirada en nosotros, sigue caminos similares. Cuando estamos usándosela un asistente de IA, para generar texto, voz, imágenes o video y somos usuarios nuevos, o no tenemos un conocimiento profundo sobre un tema, estas técnicas son las que se deben usar en ese primer acercamiento a resolver un

problema, así se amplía el contexto en los siguientes chats generándote la respuesta más avanzadas y precisas con casi cero alucinaciones.

Creando *prompts* contextuales

Imagina que estás conversando con alguien nuevo. Acabas de conocerlo y, sin más, le sueltas el comentario “¡Eso es perfecto!” o “Mira, ¿me puedes ayudar con lo de siempre?”. Esa persona seguramente se queda pensando: “¿Qué es perfecto? ¿Y lo de siempre qué es?”. Hasta puede fruncir el ceño y preguntarse si en realidad debería saber de qué hablas o si te estás confundiendo de persona.

Con la inteligencia artificial pasa algo parecido. Aunque a veces nos sorprende cómo puede “entender” lo que necesitamos, la verdad es que, si no le damos el contexto adecuado, no va a saber por dónde empezar. Igual que si le hablas a alguien que acaba de llegar a tu vida sin darle detalles, hablar con un sistema de IA sin contexto es como pedirle a un extraño que lea tu mente. Necesitamos preparar la conversación, establecer un marco de referencia y aclarar qué queremos y cómo lo queremos para evitar respuestas confusas o fuera de lugar.

¿Recuerdas esos momentos en que, hablando con alguien, le tienes que dar contexto de una situación para que entienda de qué hablas? Por ejemplo, en el trabajo: si eres enfermera y le pides ayuda a una colega diciendo: “¿Me ayudas con lo de ayer?” y no le explicas de qué caso estás hablando, tu compañera puede confundirse. O, en una empresa, si le dices a tu jefe: “¿Puedes revisar lo que te mandé?”, sin decirle cuál de todos los informes es, él probablemente no sepa a qué te refieres.

Este tipo de pistas o antecedentes que damos en las conversaciones son justamente el contexto, y es igual de necesario cuando hablamos con una IA. Si no le decimos el tema específico, el enfoque o la información de fondo que queremos, va a darnos una respuesta genérica o incluso, a veces, equivocada.



Entonces, ¿cómo se ve esto al interactuar con una IA? Imagina que eres un estudiante preparando un examen de historia y necesitas saber más sobre la Segunda Guerra Mundial. Si solo preguntas: “¿Qué fue la Segunda Guerra Mundial?”, te puede responder algo muy general. Pero si le dices: “Estoy estudiando historia y necesito entender las causas de la Segunda Guerra Mundial para el examen”, entonces ya la IA tiene un contexto más claro. Sabe que quieres detalles específicos de las causas, no toda la historia.

O imagina que tienes una cafetería y quieres saber cómo atraer más clientes. En vez de decirle a la IA simplemente algo como: “¿Cómo puedo atraer más clientes?”, puedes darle una idea de quiénes son tus clientes actuales y en qué tipo de barrio está tu negocio: “Tengo una cafetería en un barrio residencial, ¿qué tipo de promociones pueden atraer más gente?”. Ese contexto extra hace toda la diferencia. Le estás diciendo a la IA cómo es tu situación, y así ella puede darte respuestas mucho más ajustadas a tus necesidades.

Aprovechar el contexto para respuestas más relevantes

Aprovechar el contexto es como guiar a alguien de la mano para que entienda exactamente lo que necesitas. Imaginemos que eres enfermera y estás explicando a un paciente los cuidados después de una operación. Si simplemente le dices “Cuídate”, la recomendación es tan vaga que la persona podría no saber por dónde empezar. ¿Debería evitar algún tipo de alimento? ¿Es importante mantenerse en reposo absoluto o caminar un poco es bueno? Ahora, si en cambio le dices algo como: “Para que te recuperes bien, después de la cirugía, necesitas tomar tus medicamentos cada ocho horas, evitar esfuerzos físicos y no levantar objetos pesados por al menos una semana”, el mensaje es claro, específico y adecuado a la situación del paciente.

Con la IA ocurre exactamente lo mismo. Si le das una instrucción muy genérica, la respuesta puede quedarse en la superficie. Imagina que eres un estudiante que necesita hacer una investigación sobre agujeros

negros para una clase de Física. Podrías escribirle a la IA: “Explicame los agujeros negros”, y la respuesta será una explicación básica, probablemente sin profundidad ni relación con la física. Pero si le dices algo más específico así: “Estoy estudiando física y necesito entender los agujeros negros en el contexto de la exploración espacial”, ahora la IA tiene una guía clara. Sabe que quieres entender los agujeros negros desde el ángulo de la Física y, además, que debe enfocarse en su relación con la exploración espacial.

Este pequeño ajuste de añadir “en el contexto de” es como un filtro que ayuda a la IA a enfocar su respuesta, reduciendo las opciones y, en última instancia, haciendo que la respuesta sea más relevante y útil. Veamos algunos ejemplos prácticos para entender mejor cómo aprovechar el contexto y cómo aplicarlo en diferentes escenarios.

Eres médico y necesitas información sobre el tratamiento de la hipertensión en adultos mayores. Podrías preguntar: “¿Cómo se trata la hipertensión?”. Pero esa pregunta es demasiado amplia y la IA podría darte información general sobre la hipertensión. En cambio, si preguntas: “¿Cuáles son las recomendaciones para el tratamiento de la hipertensión en adultos mayores?”, le estás dando a la IA un contexto específico. Ahora, la respuesta puede centrarse en el grupo de edad que te interesa y en las recomendaciones particulares que aplican a los adultos mayores.

Imaginemos que eres profesor y quieres saber cómo explicar la fotosíntesis a tus estudiantes de primaria. Si le dices a la IA: “Explicame la fotosíntesis”, la respuesta puede ser adecuada, pero posiblemente muy técnica. Pero si das más contexto, diciendo: “¿Cómo puedo explicar la fotosíntesis de una manera simple para estudiantes de primaria?”, la IA sabe que necesitas una explicación adaptada a un nivel básico. Este detalle de contexto le indica a la IA que evite términos complejos y use un lenguaje accesible, mejorando así la calidad de la respuesta.



Supongamos que tienes una pequeña panadería en un barrio residencial y estás buscando maneras de atraer más clientes. Si le preguntas a la IA: “¿Cómo puedo atraer más clientes a mi panadería?”, su respuesta puede ser un conjunto de estrategias generales de mercadeo. Pero si le das el siguiente contexto: “Tengo una panadería en un barrio residencial con muchas familias jóvenes. ¿Qué promociones o productos me recomiendas para atraer más clientes en este tipo de comunidad?”, ahora la IA puede ofrecerte sugerencias específicas para tu entorno. Puede recomendarte ideas como promociones de desayunos familiares, descuentos para residentes del barrio, o productos que podrían gustarle a las familias, como panes integrales o galletas caseras.

Imagina que estás en una carrera de Ingeniería y necesitas entender cómo funciona la inteligencia artificial en el ámbito de la automatización industrial. Si preguntas: “¿Qué es la inteligencia artificial?”, la IA te dará una explicación general que quizás no se ajuste a tu necesidad. Pero si especificas el contexto: “Estoy estudiando ingeniería y quiero saber cómo se aplica la inteligencia artificial en la automatización de procesos industriales”, la IA sabrá enfocar su respuesta hacia aplicaciones industriales de la IA, lo cual es mucho más útil para ti como estudiante de Ingeniería.

Eres un pequeño empresario que quiere mejorar sus ventas online. Podrías preguntar: “¿Cómo puedo mejorar mis ventas online?”, y seguramente la IA te dará algunos consejos genéricos. Pero si le dices: “Tengo una tienda online de productos artesanales y quiero saber cómo llegar a un público interesado en productos ecológicos y sostenibles. ¿Qué estrategias de mercadeo me recomiendas?”, ahora la IA puede darte recomendaciones que van al grano, ajustadas a tu público y al tipo de productos que vendes.

Para entender mejor la diferencia, imagina que alguien te pide que le prepares una comida “rica”. Sin más detalles, ¿qué puedes hacer? Podrías cocinar algo que a ti te parece delicioso, pero, ¿y si esa persona es vegetariana y no te lo dijo? ¿O si no le gusta la comida picante?

Dar contexto es como decirte: “Quiero una comida rica, pero que sea vegetariana y sin picante”. Ahora tienes una idea más clara de lo que necesita y puedes prepararle algo que le guste de verdad.

Con la IA, dar contexto funciona de la misma manera. Al añadir detalles específicos sobre lo que necesitas, le estás diciendo cómo enfocar su respuesta para que sea relevante. El contexto es la clave para guiar a la IA y conseguir una respuesta que no solo sea correcta, sino que también sea útil y adecuada a tu situación.

Para lograr interacciones realmente útiles con la IA, es importante darle contexto, guiarla, como lo harías con una persona en una conversación. Piensa en lo que ya sabe y en lo que le falta saber para darte la mejor respuesta. Agregar contexto puede parecer un detalle pequeño, pero hace una gran diferencia en la calidad de la información que recibes. Al usar este principio en cada pregunta que le hagas a la IA, obtendrás respuestas que realmente resuelvan tus dudas o necesidades específicas. En lugar de respuestas genéricas, tendrás información que te sirva en tu vida diaria, en tu trabajo o en tus estudios. Así que, antes de escribirle, recuerda siempre el siguiente asunto: ¿qué contexto puedo darle para que entienda mejor lo que necesito?

Usar el historial de conversación para una conversación fluida

Pensemos en esos momentos en los que recuerdas algo sobre alguien y usas ese detalle en una conversación futura. Imagina que eres dueño de una pequeña cafetería y un cliente habitual te menciona que le fascina el café colombiano. Al día siguiente, cuando vuelve, en lugar de preguntarle qué quiere, como si fuera un cliente cualquiera, le ofreces una taza del café colombiano que sabes que le gusta. Al recordarlo, haces que esa persona se sienta especial, como si lo conocieras bien. Este simple detalle de usar el historial de conversación crea una conexión y mejora la experiencia del cliente, que se siente valorado y entendido.

Con la IA sucede algo similar. Cuando puede recordar interacciones pasadas, logra un nivel de continuidad que hace que la conversación sea más fluida y relevante. Supongamos que en una conversación anterior mencionaste que te interesa la energía renovable y, luego, en una nueva interacción preguntas lo siguiente: “¿Y qué hay de la energía solar?”. La IA, al recordar que antes hablaste sobre energías limpias, ya sabe que es tema de tu interés y puede darte una respuesta que mantenga esa línea. En lugar de comenzar desde cero, la IA usa el contexto previo y eso hace que la interacción sea más significativa para ti.

¿Cómo funciona el uso del historial para una IA?

En términos sencillos, cuando le das continuidad a una conversación con una IA, es como si estuvieras construyendo un “mapa mental” entre tú y la IA, donde ella puede recordar lo que has compartido anteriormente y así darte respuestas más ajustadas a tus necesidades actuales. Esto es especialmente útil cuando estás desarrollando un proyecto o investigando un tema en varias etapas. La IA puede actuar como si estuviera “al tanto” de lo que ya sabes y lo que necesitas aprender, ahorrándote tiempo y evitando que tengas que repetir información.

La importancia de un historial de conversación para mejorar la experiencia del usuario: cuando la IA puede recordar interacciones previas, cada respuesta se siente más personalizada, como si estuvieras hablando con alguien que realmente entiende tus necesidades. Este es un cambio significativo frente a las interacciones con sistemas que no tienen en cuenta el historial, donde cada consulta se siente como empezar desde cero. En cambio, con una IA que usa el historial de conversación, tienes la sensación de continuidad, de que puedes construir una relación en la que cada vez te entiende mejor.

La IA puede adaptar sus respuestas según tus intereses, preferencias o necesidades que le has compartido antes. Esto no solo mejora la calidad de las respuestas, sino que también permite un nivel de fluidez que hace la experiencia más cercana a una conversación humana. Al final, este



uso del historial permite que la IA no solo responda, sino que acompañe tus procesos, ya sea en el aprendizaje, en tu negocio o en tus proyectos personales.

Para los siguientes ejemplos vamos a usar ChatGPT con el modelo GPT-4o:

Usuario: “Necesito ayuda para entender la Guerra Fría, especialmente en relación con la tensión entre Estados Unidos y la Unión Soviética”.

IA: “La Guerra Fría fue un período de tensión global que comenzó después de la Segunda Guerra Mundial y se extendió hasta la disolución de la Unión Soviética en 1991. En lugar de enfrentarse directamente en el campo de batalla, Estados Unidos y la Unión Soviética libraron una guerra ideológica, económica y política, compitiendo por la influencia global. Aquí te explico los puntos clave:

1. Orígenes de la Guerra Fría

- *Después de la Segunda Guerra Mundial, el mundo quedó dividido entre dos superpotencias con ideologías opuestas:*
 - *Estados Unidos: representaba el capitalismo y la democracia liberal.*
 - *Unión Soviética: representaba el comunismo y un sistema autoritario.*
- *Ambas potencias buscaban expandir su influencia, lo que generó una rivalidad constante.*

2. Doctrina de Contención

- *Estados Unidos adoptó la Doctrina de Contención, una estrategia para evitar que el comunismo se expandiera. Esto llevó a la intervención en varios países donde Estados Unidos temía que el comunismo pudiera ganar influencia, como en Corea, Vietnam y América Latina.*

3. Carrera armamentística y nuclear

- *Ambas potencias compitieron en desarrollar armas nucleares, generando una “carrera armamentística” que llevó a un estado de destrucción mutua asegurada (MAD, por sus siglas en inglés). Esta teoría sostenía que un ataque nuclear de cualquiera de las dos potencias resultaría en la destrucción total de ambos.*

4. Carrera Espacial

- *La competencia también se trasladó al ámbito espacial. La Unión Soviética envió el primer satélite, Sputnik, en 1957, y el primer hombre, Yuri Gagarin, en 1961. Estados Unidos respondió enviando al primer hombre a la Luna en 1969.*

5. Conflictos de proxys (proxy wars)

- *Aunque no hubo enfrentamientos directos, ambos países apoyaron a distintos bandos en conflictos locales y regionales. Algunos ejemplos son:*
 - *Guerra de Corea (1950-1953): Estados Unidos apoyó a Corea del Sur, mientras que la Unión Soviética y China apoyaron a Corea del Norte.*

- *Guerra de Vietnam (1955-1975): Estados Unidos apoyó a Vietnam del Sur contra el gobierno comunista del Norte, que tenía apoyo soviético.*

6. *La Crisis de los Misiles en Cuba (1962)*

- *Uno de los momentos más críticos de la Guerra Fría fue cuando la Unión Soviética instaló misiles nucleares en Cuba, a pocos kilómetros de Estados Unidos. Esto generó una crisis que estuvo a punto de desencadenar una guerra nuclear. Al final, ambas partes llegaron a un acuerdo para retirar los misiles.*

7. *Détente (relajación de tensiones)*

- *En los años 70, hubo un intento de reducir las tensiones a través de acuerdos de control de armas como el Tratado de Limitación de Armas Estratégicas (SALT). Este período de relativa calma se conoce como Détente.*

8. *Desintegración de la Unión Soviética*

- *A finales de los años 80, bajo la dirección de Mijaíl Gorbachov, la Unión Soviética implementó reformas como la perestroika (reforma económica) y la Glasnost (apertura política), que debilitaban el control soviético.*
- *En 1991, la Unión Soviética se disolvió, poniendo fin a la Guerra Fría.*

Impacto global

- *La Guerra Fría dejó una profunda huella en las relaciones internacionales. Muchos conflictos actuales tienen sus raíces en esta época, y varias naciones que alguna vez fueron aliadas o estados satélites de una u otra superpotencia aún reflejan esa influencia.*

¿Te gustaría profundizar en alguno de estos puntos?”

Usuario: “¿Cómo afectó la Guerra Fría a los países de América Latina?”

IA: “La Guerra Fría tuvo un impacto significativo en América Latina, ya que Estados Unidos y la Unión Soviética compitieron por influir en la región. Los países latinoamericanos se convirtieron en campos de batalla ideológicos donde se promovieron y financiaron movimientos políticos, militares y sociales alineados con los intereses de ambas superpotencias. A continuación, te explico los principales efectos:

1. Intervencionismo de Estados Unidos

- *Siguiendo la Doctrina de Contención, Estados Unidos intervino directa e indirectamente en varios países latinoamericanos para evitar que el comunismo ganara terreno.*
- *La Doctrina Monroe y la Doctrina de Seguridad Nacional justificaron este intervencionismo en la región, bajo la idea de que cualquier avance comunista en América Latina representaba una amenaza directa para EE. UU.*

2. Apoyo a Gobiernos autoritarios y dictaduras

- *Estados Unidos apoyó a varios regímenes militares y Gobiernos autoritarios en América Latina para asegurarse de que estos países permanecieran en la órbita capitalista.*
- *Ejemplos importantes incluyen:*
 - *Chile: en 1973, Estados Unidos apoyó el golpe de estado liderado por Augusto Pinochet contra el presidente socialista Salvador Allende.*
 - *Argentina, Brasil y Uruguay: se instauraron dictaduras militares con apoyo de EE. UU., que temía que gobiernos progresistas o de izquierda pudieran aliarse con la Unión Soviética.*

3. Guerra de guerrillas y movimientos revolucionarios

- *Inspirados por la Revolución Cubana de 1959, surgieron movimientos guerrilleros en varios países, apoyados ideológicamente o incluso financiados por la Unión Soviética o Cuba.*
- *Estos movimientos buscaron cambios radicales en sociedades donde las desigualdades sociales y económicas eran muy pronunciadas.*
- *Ejemplos incluyen:*
 - *Nicaragua: los sandinistas derrocaron al dictador Anastasio Somoza en 1979. Aunque recibieron cierto apoyo de la Unión Soviética, la intervención estadounidense*

fue extensa, financiando a los contras, un grupo armado que buscaba desestabilizar al gobierno sandinista.

- *El Salvador y Guatemala: también hubo insurgencias de izquierda que llevaron a décadas de guerra civil, con intervención y apoyo de EE. UU. a los gobiernos.*

4. Revolución cubana y el bloqueo económico

- *La Revolución Cubana de 1959 fue un momento decisivo, ya que Cuba se convirtió en el primer país latinoamericano en adoptar el comunismo, alineándose con la Unión Soviética.*
- *Esto llevó a un conflicto directo entre Cuba y EE. UU., y eventualmente al bloqueo económico de Cuba por parte de Estados Unidos. La isla también fue el centro de la Crisis de los Misiles en 1962, cuando la Unión Soviética intentó instalar misiles nucleares allí.*

5. Operación Cóndor

- *La Operación Cóndor fue una campaña de represión coordinada entre las dictaduras de Argentina, Chile, Brasil, Bolivia, Paraguay y Uruguay en los años 70, con el apoyo de EE. UU.*
- *La operación se centró en el intercambio de información y la persecución de disidentes, principalmente aquellos que tenían ideas de izquierda. Hubo asesinatos, desapariciones forzadas y torturas sistemáticas en toda la región.*

6. Impacto económico y social

- *La polarización ideológica llevó a una fuerte inestabilidad política y social. América Latina vivió un período de gran violencia, represión y violación de derechos humanos.*
- *Las dictaduras militares dejaron graves secuelas, tanto en términos de pérdida de vidas como en crisis económicas y sociales que afectaron profundamente a estos países, muchos de los cuales hoy aún enfrentan las consecuencias de estas políticas.*

7. Desprestigio de EE. UU. en la región

- *La participación activa de Estados Unidos en los golpes de Estado y el apoyo a dictaduras autoritarias provocó un profundo resentimiento y desconfianza hacia el país en la región.*
- *Esto sentó las bases para movimientos antinorteamericanos y para que algunos países de la región buscaran políticas de independencia y soberanía frente a la influencia estadounidense.*

8. La Guerra Fría en el Ámbito Cultural e Intelectual

- *Estados Unidos y la Unión Soviética también intentaron ganar influencia a través de propaganda y actividades culturales en América Latina, patrocinando instituciones educativas, eventos culturales y publicaciones.*
- *Esto resultó en una batalla ideológica en la que universidades, escritores, y movimientos sociales en América Latina adoptaron posturas a favor o en contra del comunismo o el capitalismo.*

Conclusión

La Guerra Fría en América Latina fue un período de gran tensión y conflicto. La influencia de Estados Unidos y la Unión Soviética tuvo consecuencias duraderas, y la región vivió años de violencia, represión y cambio político, cuyas secuelas aún se sienten en muchas áreas. La intervención en la región moldeó la historia de América Latina y generó dinámicas políticas y sociales que perduran hasta hoy”.

Ejemplo 2: la tienda de jabones.

Usuario: “He implementado redes sociales para promocionar mis jabones artesanales. ¿Qué otros canales digitales me sugieres?”

IA: “Además de las redes sociales, te recomiendo explorar los siguientes canales digitales para potenciar la visibilidad de tus jabones artesanales:

- A. Marketplace en línea: plataformas como Etsy o Mercado Libre son ideales para productos artesanales. Te permitirán llegar a clientes que buscan específicamente artículos hechos a mano.*
- B. Página web y blog: una página web con tienda en línea puede dar una imagen profesional a tus jabones. Acompañarla de un blog con temas como el cuidado de la piel o los beneficios de los ingredientes naturales ayudará a atraer tráfico y mejorar tu posicionamiento en motores de búsqueda.*
- C. Email mercadeo: ofrece un boletín con descuentos, novedades o contenidos sobre el cuidado de la piel. Es una buena forma de fidelizar clientes.*

- D. *Google My Business: si tienes algún punto físico de venta o quieres captar clientes locales, registra tu negocio en Google My Business. Ayuda a mejorar la visibilidad en búsquedas locales.*
- E. *Colaboraciones y alianzas: colaborar con influencers, tiendas de productos naturales o spas puede ayudarte a llegar a audiencias que ya están interesadas en productos artesanales o de cuidado personal.*
- F. *Anuncios de pago: Anuncios en Google Ads y redes sociales pueden ser útiles para promocionar ofertas especiales o lanzamientos de productos y atraer a nuevos clientes que buscan productos similares.*

Explorar algunos de estos canales puede ayudarte a expandir tu alcance y aumentar tus ventas”.

Usuario: “¿Qué estrategia debería aplicar en anuncios de pago para optimizar lo invertido?”.

IA: “Para optimizar tu inversión en anuncios de pago, te sugiero una estrategia centrada en maximizar el retorno sobre inversión (ROI) a través de pruebas controladas, segmentación precisa y análisis continuo. Aquí tienes un plan específico:

1. Definir objetivos y unos KPI claros

- Establece objetivos medibles: por ejemplo, ventas directas, generación de leads o incremento de visitas al sitio web.*
- Define KPI como costo por adquisición (CPA), tasa de conversión y retorno sobre el gasto publicitario (ROAS) para evaluar la efectividad de cada campaña.*

2. Segmentación específica de audiencia

- *Segmentación demográfica y geográfica: dirige anuncios solo a personas en áreas relevantes (ciudades donde puedas hacer envíos rápidos) y a rangos de edad con interés en el cuidado personal y productos naturales.*
- *Intereses y comportamientos: usa datos de redes sociales y plataformas como Google para segmentar a usuarios interesados en productos artesanales, naturales o sostenibles.*
- *Audiencias Lookalike: crea audiencias similares a tus clientes actuales para captar usuarios con perfiles similares.*

3. Pruebas A/B de anuncios

- *Realiza pruebas A/B en cada anuncio variando elementos clave como el texto, imágenes, llamados a la acción (CTA) y formato (carrusel, video, imagen).*
- *Evalúa cuál combinación genera más interacciones o conversiones a menor costo y ajusta en función de los resultados.*

4. Usar remarketing para clientes potenciales

- *Implementa anuncios de remarketing para captar a personas que ya visitaron tu página web, interactuaron con tu contenido o dejaron productos en el carrito.*
- *Estos anuncios suelen tener una mejor tasa de conversión, ya que están dirigidos a personas que mostraron interés previamente.*

5. Elegir el formato adecuado de anuncios

- *Usa videos cortos o carruseles que resalten los beneficios y la calidad de los jabones artesanales.*
- *Anuncios de tipo “collection” o “catalog” en redes sociales permiten al cliente explorar varios productos sin salir de la plataforma.*

6. Optimizar bidding y controlar el presupuesto

- *Si estás comenzando, usa un presupuesto bajo y ajusta el bid manualmente para no gastar más de lo necesario en cada clic.*
- *Conforme determines qué anuncios y segmentaciones funcionan mejor, puedes aumentar el presupuesto de los anuncios con mejor rendimiento.*

7. Monitoreo y ajuste Continuo

- *Revisa los KPIs semanalmente, especialmente el CPA y el ROAS, para decidir si debes pausar, optimizar o aumentar el presupuesto de una campaña.*
- *Cambia elementos de los anuncios o audiencias que no generen resultados en una o dos semanas para evitar desperdicio de inversión.*

8. Calendario estratégico de publicación

- *Aprovecha fechas especiales o temporadas altas (Navidad, Día de la Madre) para promocionar tus jabones. Incrementar el presupuesto de los anuncios en estos momentos puede aumentar la conversión.*

Esta estrategia equilibrará la exposición de tus anuncios con un control estricto del gasto, maximizando el valor de cada peso invertido”.

El historial de conversación permite que la IA “aprenda” de tus interacciones pasadas y se ajuste cada vez mejor a tus necesidades. Así, al hablar con una IA, piensa que cada detalle que le das en una conversación puede ser útil en la siguiente. Si en una primera interacción mencionaste algo importante, no tengas miedo de dar seguimiento en consultas futuras. Esto convierte a la IA en una herramienta mucho más poderosa, que no solo responde, sino que recuerda y se adapta para que cada respuesta sea más relevante y útil para ti.

Haciendo preguntas específicas

Hacer preguntas específicas en la vida diaria es una habilidad que a veces damos por sentada, pero tiene un impacto enorme en la calidad de las respuestas que obtenemos, ya sea en una conversación normal, en el trabajo o incluso en el momento de buscar información en internet. Cuando usamos un modelo de IA como ChatGPT, Gemini o Claude, esta habilidad cobra aún más relevancia, porque las palabras que usamos y la forma en que estructuramos las preguntas determinan completamente la calidad de la respuesta que obtendremos.

Imaginemos el día a día de distintas personas. Una enfermera, por ejemplo, tiene que hacer preguntas puntuales para entender la condición de sus pacientes. No basta con decir “¿Te sientes mal?” porque eso puede significar muchas cosas. En cambio, si pregunta: “¿Te duele al respirar o solo cuando haces esfuerzo?”, obtendrá una respuesta más concreta que la ayudará a entender mejor el problema del paciente.

Lo mismo aplica en otros trabajos. Pensemos en un estudiante de ingeniería que está atascado en un problema de Física. Si va donde su profesor y dice: “No entiendo esta pregunta”, el profesor probablemente le devolverá otra pregunta como: “¿Qué parte no entiendes exactamente?”. Ahora, si el estudiante en cambio dice: “¿Me podrías explicar cómo



calcular la fuerza en una pendiente?”, el profesor sabrá exactamente qué es lo que necesita y le podrá dar una respuesta útil. Así, al ser específicos no solo evitamos la frustración, sino que logramos avanzar más rápido.

¿Y qué pasa si eres dueño de un pequeño negocio y necesitas saber cómo atraer más clientes? Si le preguntas a alguien esto: “¿Cómo hago para vender más?”, la respuesta puede ser muy vaga y no te va a servir mucho. Pero si preguntas: “¿Qué estrategias puedo usar en redes sociales para atraer clientes nuevos al negocio?”, es más probable que obtengas consejos concretos sobre cosas que puedes implementar, como hacer sorteos, usar *hashtags* específicos, o trabajar con influencers locales. Cuando usas IA, pasa lo mismo, pero multiplicado. Imagina que tienes frente a ti un archivo inmenso de información y que solo tienes unos segundos para buscar algo útil. Hacer una pregunta precisa es como indicar al buscador la sección exacta del archivo donde quieres buscar, en lugar de pedirle que lea todo el archivo por ti. Así, el modelo no tiene que adivinar qué es lo que realmente quieres saber, sino que va directo a darte una respuesta clara y útil.

Técnicas para preguntas claras y directas

Cuando hablamos con alguien que tiende a interpretar todo de manera literal, como una IA, cualquier ambigüedad en nuestras preguntas puede llevar a respuestas confusas o generales. Al hacer preguntas claras y precisas, evitamos malentendidos y obtenemos exactamente la información que necesitamos. A continuación, algunas técnicas clave que ayudan a lograr esa claridad.

Técnica 1: especificidad o poder de la precisión

A la hora de formular preguntas, la precisión es nuestra mejor aliada. Imagina que tienes que hacer una búsqueda en una biblioteca gigante: si solo dices “libro”, te podrías quedar horas buscando algo relevante. Si, en cambio, pides “libros de Biología Celular sobre respiración en células eucariotas”, es como si le dieras una brújula al bibliotecario. Con IA pasa

algo similar: una pregunta específica guía al modelo hacia la respuesta exacta que estás buscando. Para entenderlo mejor, veamos otro ejemplo en una profesión completamente diferente. Si eres un carpintero y quieres saber sobre “tipos de madera”, es posible que obtengas una lista de todos los tipos existentes en el mundo, desde maderas duras hasta blandas y exóticas. Sin embargo, si preguntas “¿Cuáles son las mejores maderas para fabricar muebles resistentes al agua?”, reduces el alcance de la respuesta a algo mucho más útil y práctico.

La precisión es como un filtro en la pregunta: eliminas lo que no necesitas y te quedas solo con lo esencial. Es una técnica clave para aquellos que buscan información específica y detallada en cualquier campo.

Técnica 2: claridad a través del contexto

Dar contexto en una pregunta es como ponerle un marco a un cuadro: delimita lo que quieres ver. Cuando damos contexto, aclaramos de qué estamos hablando y el área específica en la que queremos información, evitando respuestas genéricas.

Imaginemos el caso de una chef que quiere aprender nuevas técnicas. En vez de preguntar esto: “¿Cómo puedo mejorar mis platos?” (que puede llevar a una respuesta amplia sobre tipos de cocina, presentación, sabor, o técnicas), puede preguntar en cambio: “¿Qué técnicas avanzadas de cocina molecular puedo aplicar en platos salados?”. Al proporcionar el contexto de la “cocina molecular” y especificar que es para “platos salados”, la IA sabe exactamente qué tipo de información buscar.

Otro ejemplo práctico sería el de un estudiante de Derecho que inquiera lo siguiente: “¿Qué significa negligencia?”. Sin contexto, la respuesta puede variar entre distintos tipos de negligencia (negligencia en medicina, en derecho civil, etc.). Si en cambio pregunta: “¿Qué significa negligencia en el derecho penal colombiano?”, proporciona tanto el contexto (derecho penal) como la jurisdicción (Colombia), obteniendo una respuesta precisa que le es útil.



Técnica 3: desglose de preguntas complejas o en múltiples pasos

A veces necesitamos información sobre temas complejos que abarcan más de un concepto. En estos casos, es mejor descomponer la pregunta en varias partes. Esto permite que la IA se enfoque en un aspecto a la vez, lo que resulta en respuestas más claras y fáciles de seguir.

Imagina que eres un programador y necesitas entender dos conceptos complicados como la *herencia* y la *polimorfía* en programación orientada a objetos. Preguntar “¿Qué es la herencia y la polimorfía en programación orientada a objetos?” puede generar una respuesta que mezcle ambos conceptos y sea difícil de seguir. Si en lugar la pregunta es “¿Qué es la herencia en programación orientada a objetos?” y luego “¿Qué es la polimorfía en programación orientada a objetos?” las respuestas serán detalladas sobre cada tema por separado, haciéndolo más claro y fácil de entender.

Esta técnica también se aplica en Medicina. Por ejemplo, un estudiante de Medicina podría preguntar: “¿Cómo se diagnostica y trata la diabetes?”. Sin embargo, puede obtener mejores resultados si este primero pregunta así: “¿Cuáles son los principales métodos de diagnóstico para la diabetes?” y luego “¿Cuáles son los tratamientos más comunes para la diabetes?”. Este enfoque paso a paso le permite obtener información detallada y separada, sin confusión entre diagnóstico y tratamiento.

Técnica 4: usar preguntas cerradas para evitar respuestas demasiado amplias

Las preguntas cerradas requieren una respuesta directa y específica, en vez de una explicación amplia. Estas preguntas suelen empezar con “¿Es...?”, “¿Cuál...?”, “¿Cuándo...?” y funcionan bien cuando solo necesitas un dato concreto. Por ejemplo, si eres un vendedor y quieres saber si un nuevo producto está disponible, no necesitas una explicación extensa.

En lugar de preguntar “¿Cómo está el *stock* del nuevo producto?”, puedes preguntar “¿Está disponible el nuevo producto en el inventario?”. De esta forma, la IA o la persona a la que le preguntas sabrá que esperas una respuesta sencilla como “sí” o “no”.

Las preguntas cerradas también son útiles en la investigación. Un investigador puede preguntar “¿Los datos muestran una diferencia significativa?” en lugar de “¿Qué muestran los datos?”. Así, obtiene una respuesta específica, lo cual es ideal cuando está buscando resultados concretos.

Ejemplos aplicados de cada técnica en distintas profesiones

Precisión para una profesora de Historia: en lugar de formular la pregunta “¿Qué ocurrió en la Revolución Francesa?” puede redactarla así: “¿Cuáles fueron las principales causas económicas de la Revolución Francesa?” para recibir una respuesta que cubra solo lo que necesita.

Contexto para un mecánico: en lugar de preguntar “¿Por qué no arranca el motor?” podría formularla así: “¿Cuáles son las causas más comunes por las que no arranca el motor en autos de gasolina?”. Esto evita respuestas irrelevantes sobre motores diésel u otras situaciones.

Desglose para un chef de repostería: si quiere saber sobre técnicas y recetas, puede preguntar primero “¿Cuáles son las técnicas avanzadas en repostería?” y luego “¿Qué recetas requieren estas técnicas avanzadas?”. De esta manera, no se mezcla la técnica con la receta, obteniendo información clara en cada aspecto.

Pregunta cerrada para una enfermera: en lugar de preguntar “¿Puede haber efectos secundarios con este medicamento?”, puede preguntar “¿Este medicamento tiene efectos secundarios en pacientes diabéticos?” para obtener una respuesta más directa y específica a su caso.

Con estas técnicas, logramos hacer que nuestras preguntas sean más claras y directas, tanto en conversaciones con IA como en nuestras



interacciones diarias. La precisión, el contexto, el desglose y el uso de preguntas cerradas nos permiten avanzar más rápido y obtener respuestas que realmente nos sirven.

Navegar la ambigüedad

Las preguntas ambiguas son como señales de tránsito borrosas: te dan una idea, pero no sabes bien hacia dónde ir. Cuando preguntas de forma vaga o sin delimitar el tema, las respuestas que obtienes pueden ser igual de confusas y no darte la información que realmente necesitas. En las interacciones con IA, como en la vida diaria, aclarar las dudas y reducir la ambigüedad es clave para obtener respuestas útiles. Aquí exploraremos algunas técnicas y ejemplos prácticos para evitar que nuestras preguntas caigan en la trampa de la ambigüedad.

Técnica 1: evitar la vaguedad con preguntas específicas

La vaguedad en una pregunta es como pedir una “bebida” en un restaurante sin especificar si quieres agua, jugo o café. Si haces preguntas demasiado generales, es probable que recibas respuestas que te sirvan de poco. La clave está en especificar detalles importantes, como personas, lugares o situaciones específicas, que eliminen cualquier espacio para interpretaciones incorrectas.

Por ejemplo, imagina que eres enfermero y le preguntas a tu colega: “¿Dónde están los medicamentos?”. La respuesta puede ser muy vaga, como “en el armario,” pero esa respuesta no ayuda mucho porque seguramente hay varios armarios y diferentes tipos de medicamentos en cada uno. En cambio, si preguntas: “¿Dónde están los antibióticos para el paciente de la cama 7?”, especificas el tipo de medicamento y el paciente al que está destinado, lo cual ayuda a reducir la ambigüedad y garantiza que recibas la respuesta que necesitas.

Otro ejemplo podría ser el caso de un diseñador gráfico que necesita archivos específicos para un proyecto y pregunta: “¿Dónde están los

archivos de diseño?”. En cambio, si pregunta “¿Dónde están los archivos de diseño para la campaña de verano?”, elimina la vaguedad y asegura que le den exactamente los archivos que busca.

Técnica 2: definir el alcance de la pregunta

A veces, una pregunta es ambigua porque no tiene un alcance bien definido. Es como decir “Quiero leer un libro”, sin decir qué género, autor o tema prefieres. Cuando definimos el alcance, reducimos el tema o la pregunta a un aspecto específico, ayudando a obtener respuestas más relevantes y útiles.

Supongamos que eres un estudiante de ciencias ambientales y pides ayuda con el tema del “cambio climático”. Esta pregunta es tan amplia que puedes recibir respuestas que hablen de gases de efecto invernadero, de fenómenos climáticos o, incluso, de impacto en la biodiversidad. Para afinar la respuesta, podrías preguntar “¿Cuáles son las principales causas humanas del cambio climático?”. Ahora, has limitado la pregunta a un aspecto específico y obtendrás una respuesta enfocada en la influencia humana.

Otro caso sería el de un contador que necesita información sobre impuestos, pero en lugar de preguntar así: “¿Cómo funcionan los impuestos?”, podría preguntar: “¿Cuáles son los principales impuestos que afectan a las pequeñas empresas en Colombia?”. Al hacer esto, define el alcance tanto en el tipo de empresa como en la ubicación geográfica y obtiene una respuesta directamente útil para su caso.

Técnica 3: usar preguntas de múltiples pasos para despejar la ambigüedad

A veces necesitamos que una pregunta abarque varios aspectos, y hacerla de una sola vez puede causar ambigüedad o una respuesta confusa. Para estos casos, es útil dividir la pregunta en varias partes, lo que permite que cada aspecto reciba una respuesta clara y detallada.



Imagina que eres un periodista y quieres información sobre un tema amplio como el impacto de la tecnología en la sociedad. Si preguntas simplemente: “¿Cómo impacta la tecnología en la sociedad?”, la IA o la persona puede no saber por dónde empezar. En su lugar, puedes dividir la pregunta en pasos como: “¿Cuáles son los impactos de la tecnología en el empleo?”, seguido de “¿Cómo afecta la tecnología la comunicación interpersonal?”. Al dividir la pregunta en pasos, obtendrás respuestas específicas y claras sobre cada aspecto del tema.

Esto también se aplica en áreas como la Medicina. Un médico que quiere saber sobre un tratamiento para la diabetes puede primero preguntar: “¿Qué medicamentos son recomendados para controlar la diabetes tipo 2?” y luego “¿Cuáles son los efectos secundarios comunes de estos medicamentos?” En lugar de una respuesta general sobre el tratamiento, obtiene detalles específicos sobre medicamentos y sus efectos, lo cual le permite entender mejor el panorama y hacer un mejor diagnóstico.

Técnica 4: pedir ejemplos o definiciones para aclarar conceptos abstractos

Muchas veces la ambigüedad surge cuando estamos tratando con conceptos abstractos que pueden interpretarse de diferentes maneras. En estos casos, es útil pedir ejemplos o definiciones que aclaren a qué nos estamos refiriendo. Es como cuando alguien te dice que un trabajo es “creativo”, pero no especifica qué implica. Pedir ejemplos concretos ayuda a eliminar la ambigüedad y entender mejor el tema.

Imagina que eres un profesor y le preguntas a un colega lo siguiente: “¿Cómo puedo hacer mis clases más dinámicas?”. La palabra *dinámicas* puede interpretarse de muchas formas. Para evitar ambigüedad, podrías pedir ejemplos como el siguiente: “¿Puedes darme algunos ejemplos de actividades que hagan una clase más dinámica?”. Esto obliga a la persona a darte detalles específicos y reduce la ambigüedad.

Otro ejemplo sería un empresario que pide a su equipo hacer el trabajo *más eficiente*. En lugar de decirlo de forma general, tal cual, puede preguntar: “¿Qué herramientas podríamos implementar para reducir el tiempo de entrega de nuestros pedidos en un 20 %?”. Con ello, al pedir ejemplos o sugerencias específicas, elimina la ambigüedad y permite que su equipo le proponga ideas prácticas y aplicables.

Resumen de técnicas para navegar la ambigüedad

Evita la vaguedad: siempre que puedas especifica detalles en la pregunta como nombres, lugares o tipos específicos.

Define el alcance: reduce el tema a un aspecto o área específica para que la respuesta sea lo más relevante posible.

Divide preguntas complejas: si el tema es amplio, divide la pregunta en varias partes o pasos para obtener respuestas claras sobre cada aspecto.

Pide ejemplos o definiciones: cuando trates con conceptos abstractos, pide ejemplos o explicaciones detalladas que ayuden a aclarar la pregunta.

Navegar la ambigüedad es como afinar la sintonía en una radio, a saber: a veces solo necesitas ajustar un poco para escuchar con claridad lo que realmente te interesa. Estas técnicas no solo son útiles al interactuar con IA, sino que también mejoran nuestras habilidades de comunicación en general, ayudándonos a obtener respuestas útiles y a resolver dudas de forma más efectiva en cualquier situación.

Descubriendo información oculta con preguntas bien formuladas

Hay momentos en los que buscamos más que una respuesta simple; queremos descubrir detalles que no son evidentes a primera vista. Esto es fundamental para ciertas profesiones y situaciones. Imagina a un

periodista investigando un tema complejo o a un abogado desenterrando los matices de una ley, ambos necesitan ir más allá de las respuestas superficiales. Con la IA también podemos lograr esto al formular preguntas que inviten al modelo a indagar en esos detalles ocultos, brindándonos respuestas más profundas y completas. A continuación, exploraremos las técnicas efectivas para hacer este tipo de preguntas reveladoras.

Técnica 1: profundizar en los detalles

Las preguntas que buscan profundidad no se conforman con una respuesta directa; más bien, buscan información adicional que aporte una capa extra de comprensión. Este tipo de preguntas son clave cuando queremos aprender más sobre un tema en particular, sin quedarnos en lo superficial.

Por ejemplo, si eres un periodista y quieres escribir un artículo sobre la construcción de la Torre Eiffel, en vez de preguntar simplemente “¿Cómo se construyó la torre Eiffel?”, puedes formular una pregunta que invite al modelo a ir más allá, *v. gr.* “Cuéntame sobre la historia de la construcción de la torre Eiffel, incluyendo algunos detalles poco conocidos”. Esto impulsa a la IA a proporcionar datos curiosos o menos mencionados, como anécdotas sobre los trabajadores o controversias de la época, que harán que tu artículo sea más atractivo e informativo.

Otra aplicación de esta técnica sería en el caso de un médico que estudia la historia de un tratamiento. Si pregunta lo siguiente: “¿Cuándo se desarrolló la quimioterapia?”, obtendrá una fecha o una respuesta corta. Pero si lo hace de esta manera: “¿Cuándo y cómo se desarrolló la quimioterapia, y cuáles fueron las reacciones iniciales de la comunidad médica?”, invitará a la IA a explorar más sobre los desafíos, las controversias y la evolución de esta técnica médica, obteniendo una visión más completa y profunda.

Técnica 2: indagación abierta para explorar temas ampliamente

Las preguntas de indagación abierta son aquellas que no limitan la respuesta a un aspecto específico, sino que abren la puerta para explorar varias dimensiones del tema. Este tipo de preguntas son útiles cuando queremos saber cómo algo impactó o afectó a áreas como la cultura, la economía o la sociedad en general.

Por ejemplo, un profesor de Historia podría preguntar: “¿Qué hicieron Los Beatles?” y obtener una lista de logros o eventos en su carrera musical. Sin embargo, si formula una pregunta abierta como esta: “¿Cuál fue el impacto cultural de Los Beatles más allá de su música?”, permite que el modelo aborde temas como su influencia en la moda, en el movimiento juvenil de los años 60 del siglo pasado y en las tendencias sociales de la época. Con este tipo de preguntas no solo recibes una respuesta, sino un contexto amplio que puede ayudar a entender el impacto cultural de un fenómeno más allá de su ámbito inmediato.

Imagina también que eres un empresario investigando el uso de la inteligencia artificial en diferentes industrias. En lugar de preguntar así: “¿Cómo se usa la inteligencia artificial en los negocios?”, prueba con esta formulación: “¿Qué impactos ha tenido la inteligencia artificial en la innovación dentro de distintas industrias?”. Esto abrirá la respuesta para que la IA explore tanto los usos como los efectos que ha tenido la IA en sectores variados como la Medicina, la manufactura y los servicios financieros.

Técnica 3: comparaciones para revelar diferencias y matices

Cuando queremos entender las diferencias entre dos conceptos, métodos o personajes históricos, una buena estrategia es hacer preguntas comparativas. Esto impulsa a la IA a destacar tanto las similitudes como

las particularidades de cada elemento, revelando matices que tal vez no serían evidentes de otra forma.

Por ejemplo, un estudiante de Filosofía podría formular estas dos preguntas: “¿Cuál es la ética de Kant?” y “¿Cuál es la ética de Nietzsche?”. Pero, si formula la pregunta de manera comparativa, así: “¿Cómo se comparan las visiones éticas de Immanuel Kant y Friedrich Nietzsche?”, logrará una respuesta que explora las ideas de cada filósofo en un contexto comparativo, resaltando diferencias y puntos en común. Esto es especialmente útil para temas complejos, ya que facilita la comprensión al colocar las ideas lado a lado.

Otro caso podría ser un chef que quiere experimentar con técnicas de cocción en su restaurante. En lugar de preguntar “¿Qué es la cocción al vacío?” y “¿Qué es la cocción a la parrilla?”, puede preguntar: “¿Cuáles son las principales diferencias entre la cocción al vacío y la cocción a la parrilla en cuanto a textura y sabor de la carne?”. De esta forma, el modelo le dará una respuesta más rica en detalles prácticos, ayudándolo a elegir la técnica que mejor se adapte a su estilo culinario.

Técnica 4: solicitar evidencia o ejemplos para profundizar en el contexto

A veces necesitamos que la respuesta incluya ejemplos específicos o datos que sustenten lo que se está explicando. Pedir evidencia o ejemplos en la pregunta es una manera efectiva de obtener una respuesta completa que no solo explique el concepto, sino que lo haga aplicable a situaciones de la vida real.

Imagina que eres un administrador de empresas y quieres saber cómo la IA ha mejorado la productividad. En vez de remitir el interrogante así: “¿Cómo ayuda la IA a mejorar la productividad?”, podrías preguntar: “¿Puedes darme ejemplos específicos de cómo la IA ha aumentado la productividad en la industria de manufactura y en los servicios financieros?”. Al pedir ejemplos, la respuesta será mucho más concreta

y rica en detalles aplicables, en este caso, incluirá sistemas específicos o casos de éxito.

Este enfoque también es útil en la educación. Un profesor de Ciencias podría inquirir lo siguiente: “¿Qué es la gravedad?” y obtener una respuesta teórica. Pero si pregunta esto: “¿Podrías darme ejemplos de cómo la gravedad afecta tanto en la Tierra como en el espacio?”, obtendrá una explicación que abarca distintos contextos, ayudando a sus estudiantes a visualizar mejor el concepto y su impacto en diferentes situaciones.

Descubrir información oculta es como desenterrar un tesoro, con las preguntas adecuadas, podemos encontrar detalles y matices que enriquecen nuestro conocimiento y nos permiten comprender un tema desde diferentes ángulos. Al utilizar estas técnicas, aprovechamos al máximo el potencial de la IA y nos volvemos mejores investigadores, comunicadores y aprendices en cualquier área de interés.

Proporcionando restricciones y directrices

Imagínate que tienes un loro charlatán. No se trata de cualquier loro, este sabe todo tipo de cosas y puede hablarte de cualquier tema, desde fútbol hasta las estrellas. Ahora, figúrate que este loro a veces se va por las ramas y, si no le dices exactamente lo que quieres, termina contándote la historia completa de cómo se inventó la rueda cuando solo le preguntaste qué es una bicicleta. Pues bien, ChatGPT es algo así. ¡Un loro digital súperpoderoso! Pero también necesita que le des ciertos “límites” o “reglas” para que sus respuestas sean lo que esperas. Es como darle instrucciones claras para que no se pierda en su propio parloteo.

Una de las formas en las que podemos “domar” a ChatGPT es dándole lo que llamamos “restricciones”. Sí, suena medio formal, pero piensa en esto como si estuvieras jugando con plastilina. Si quieres hacer una casita, necesitas moldear la plastilina de cierta forma. Las restricciones son como moldear esa plastilina, es decir: le dices a ChatGPT cómo



debe responderte para que no termine hablándote de cualquier cosa menos de lo que tú quieres.

Los mensajes cortos

Digamos que quieres que te explique algo, pero tú no tienes tiempo para una historia larguísima, solo necesitas lo esencial. Puedes decirle algo como esto: “Explícame esto en 20 palabras o menos”. Eso es una restricción. Estás diciéndole: “¡Hey, no te extiendas demasiado, dámelo cortico!”. Es como si estuvieras diciéndole a un amigo que sea breve porque el bus está por llegar.

Por ejemplo, estás en el colegio y tienes que explicar el cambio climático rápido antes de que toque la campana. Entonces le dices a ChatGPT lo siguiente: “Explícame qué es el cambio climático en 20 palabras o menos”. Así el loro digital no se emociona y te cuenta solo lo necesario: “El cambio climático es el calentamiento del planeta debido a gases como el CO₂ que atrapan el calor”. Su respuesta irá al punto, rápido y claro.

La importancia de hablar claro

Otra cosa que puedes hacer es pedirle a ChatGPT que hable de cierta manera. Esto es útil si tienes un público en mente. Por ejemplo, si quieres explicar cómo funciona un celular, pero para un niño pequeño, podrías decirle: “Explícalo como si estuvieras hablándole a un niño de 5 años”. ChatGPT entonces se ajusta y, en lugar de usar palabras rimbombantes, lo hace simple. Esto se parece a cuando le explicas a tu primo qué hace el control remoto: “Este botón hace que la tele se prenda, y este otro cambia los canales”. Fácil, sin palabras complicadas.



Jugando con estilos y tonos

Así como ChatGPT puede ajustar la longitud de las respuestas o la dificultad del lenguaje, también puede adoptar sus respuestas a estilos diferentes. Imagínate que tienes una tarea en la que debes escribir un poema al estilo de Edgar Allan Poe, un escritor al que le gustaban las cosas oscuras y algo tenebrosas. Puedes decirle a ChatGPT que escriba en el estilo de Poe, y así te arroja algo con ese aire misterioso. Es como si quisieras contar una historia de miedo en una fogata: necesitas un tono especial y puedes pedirselo.

Pero también, si no quieres que se vaya por el lado oscuro, puedes decirle que hable en un tono más alegre, como si estuvieras contando un chiste o cantando una canción de reguetón. ChatGPT se adapta, lo cual es bastante útil si quieres que el mensaje suene de cierta forma.

Manteniendo las cosas éticas y respetuosas

Ahora, a veces el loro digital necesita un poquito más de ayuda para ser respetuoso. Si estás hablando de algo que puede ser delicado, como la historia de un conflicto o de un tema muy personal, puedes decirle a ChatGPT que tenga cuidado, que lo cuente de manera que nadie se sienta mal. Es como cuando le dices a un amigo que hable bajito porque alguien puede escuchar y no quieres incomodar a nadie.

Por ejemplo, si le pides a ChatGPT que te hable de un momento histórico doloroso, como la bomba de Hiroshima, puedes decirle: “Hazlo de manera respetuosa y sin lenguaje ofensivo”. Eso le pone un freno y asegura que la respuesta sea cuidadosa, sin causar molestia. Es una manera de hacer que el loro digital entienda que hay cosas que no se pueden decir a la ligera.



Ejemplos:

Maestra de primaria: imagina que eres una maestra explicándole a tus alumnos qué es la fotosíntesis. Puedes decirle a ChatGPT: “Explicalo como si fueras una maestra de primaria y los estudiantes tuvieran 8 años”. Así, ChatGPT usará ejemplos simples y un lenguaje fácil de entender para los niños.

Vendedor en una tienda de electrónica: si eres un vendedor y quieres explicar la diferencia entre dos modelos de teléfonos a un cliente que no sabe mucho de tecnología, puedes decirle a ChatGPT: “Explicame la diferencia entre estos dos teléfonos como si fuera un cliente que no entiende de tecnología”. ChatGPT dará una explicación sencilla sin términos técnicos complicados.

Chef enseñando una receta: Un chef que está enseñando una receta a personas que nunca han cocinado podría decir: “Explicame cómo hacer pasta casera como si nunca hubiera cocinado antes”. ChatGPT entonces dará instrucciones paso a paso, sin asumir que la persona ya sabe técnicas avanzadas de cocina.

Abogado explicando un contrato: si eres abogado y necesitas explicarle una cláusula complicada de un contrato a un cliente que no sabe de leyes, puedes pedirle a ChatGPT lo siguiente: “Explicame esta cláusula en términos simples para alguien sin conocimientos legales”. Así, el cliente puede entender mejor sin sentirse abrumado por el lenguaje jurídico.

La magia de los *prompts*: creatividad con ayuda de la tecnología

Supón que tienes un poder que te ayudara a pensar en historias, ideas o hasta nuevos inventos, todo de una forma más fácil. Ese poder existe y se llama “*prompt*”. Suena extraño, pero no es más que una manera de pedirle algo a una IA para que te ayude a imaginar o crear cosas

nuevas, como ya lo vimos en capítulos anteriores. Ahora vamos a ver cómo podrías usar *prompts* para hacer que tu creatividad vuele, ya sea para escribir un cuento, hacer un poema o hasta inventarte una receta bien loca. Así que fijate bien lo que viene porque este cuento se va a poner bueno.

¿Cómo usar los *prompts* para escribir?

Por ejemplo, si quieres escribir una historia, pero no sabes por dónde empezar, puedes darle a la IA un *prompt* como la siguiente: “Escribe un cuento que empiece con un niño que encuentra una puerta pequeñita en el jardín de su casa”. Con algo tan simple como eso, puedes empezar a imaginar un mundo donde el niño se encuentra con seres diminutos, o quizá descubre un lugar lleno de plantas mágicas.

Lo bueno de los *prompts* es que no te atan a una sola idea. Son una llave que abre un sin fin de puertas, y tú decides cuál abrir. Puedes jugar con la historia, cambiar los personajes, o hacer que el lugar sea totalmente diferente. Con solo un pequeño empujón, puedes convertirte en un autor de historias increíbles.

Escribiendo poesía con un *prompt*

Digamos que quieres escribir un poema, pero la hoja en blanco te mira y no sabes por dónde empezar. Un *prompt* puede ayudarte. Podrías decirle esto: “Escribe un poema que hable sobre la sensación de estar en un bosque al amanecer”. ¡Ahí empieza la magia! Tal vez te imaginas los rayos del sol que apenas empiezan a salir, el sonido de los pájaros y el olor fresco de la tierra mojada. No necesitas ser un poeta experto, solo necesitas una idea que te haga sentir algo, y la inteligencia artificial puede ayudarte a poner esas sensaciones en palabras. Este tipo de *prompts* son muy útiles porque no te dicen cómo deberías sentirte o qué deberías escribir, simplemente te ponen en un lugar o en una situación y te dejan imaginar. Es como si te dieran las herramientas para construir un puente, pero tú decides a dónde va.



Inventando cosas futuristas con *prompts*

Los *prompts* también se pueden usar para cosas que van más allá de la escritura. Si eres de esos que sueña con inventar cosas —como un carro volador o una *app* que haga todo más fácil—, los *prompts* también te pueden ayudar. Un buen ejemplo sería este: “Imagina una tecnología del futuro que cambie la manera en la que nos comunicamos. ¿Cómo funcionaría?”. Con eso, podrías pensar en algo extravagante, como una pulsera que permita escuchar lo que los demás piensan, pero solo si ellos quieren compartirlo contigo. O un tipo de gafas que traduzcan idiomas en tiempo real para que puedas hablar con cualquiera, sin importar de dónde sea. Con un simple *prompt* puedes dejar que tu imaginación corra libre y no hay límites a lo que puedas crear.

¿Por qué importa todo esto?

A lo mejor piensas: “¿Y todo esto para qué?”. Pues resulta que los *prompts* no solo sirven para jugar o imaginar, también son una herramienta poderosa para aprender y resolver problemas. Imagina que en el futuro te enfrentas a un problema complicado y no sabes por dónde empezar. Un *prompt* bien hecho podría ayudarte a ver el problema desde otro punto de vista o podría darte ideas que no se te habían ocurrido.

Los *prompts* son como esos compañeros de clase que siempre tienen ideas nuevas y que, cuando no sabes la respuesta, te ayudan a pensar de otra manera. Pueden hacer que una hoja en blanco ya no sea tan intimidante, y que cualquier idea, por muy disparatada que parezca, empiece a tomar forma. Al final del día, la creatividad es como un músculo: cuanto más la uses, más fuerte se pone. Y los *prompts* son como el gimnasio para tu cerebro.



¿Cómo empezar?

Si quieres empezar a usar *prompts* para crear, lo único que necesitas es una idea pequeña. No tiene que ser nada grande, solo algo que te cause curiosidad. Podrías escribir: “Imagina que hay una ciudad en el cielo y que nadie ha podido bajar de allá en cientos de años. ¿Cómo sería la vida de las personas allí?”. Deja que esa chispa inicial crezca, deja que la IA te sorprenda y, sobre todo, diviértete en el proceso. Recuerda, la creatividad no tiene reglas fijas. Los *prompts* son solo el principio, tú decides hacia dónde te llevan. ¡Así que, dale, empieza hoy mismo a crear algo único y deja volar tu imaginación!

Ejemplos:

Maestro de escuela: “Imagina una actividad divertida para enseñar a los niños cómo funcionan las estaciones del año, usando materiales que todos tengan en casa”. Este *prompt* ayuda a un maestro a pensar en una lección interactiva que mantenga a los estudiantes interesados y aprendiendo de manera práctica.

Chef: “Crea una receta que combine la cocina tradicional colombiana con técnicas modernas de cocina molecular”. Este *prompt* permite a un chef experimentar con sabores y técnicas, mezclando lo tradicional con lo innovador para crear un plato único.

Electricista: “Imagina un nuevo dispositivo que haga más fácil la reparación de instalaciones eléctricas en espacios reducidos”. Con este *prompt*, un electricista podría pensar en herramientas que hagan su trabajo más seguro y eficiente, especialmente en lugares difíciles de alcanzar.

Ama de casa: “Piensa en una manera creativa de organizar los juguetes de los niños que sea fácil y divertida”. Este *prompt* ayuda a las amas de casa a encontrar soluciones que no solo mantengan la casa ordenada,

sino que también involucren a los niños en el proceso de una manera entretenida.

Estudiante: “Imagina un proyecto de Ciencias que muestre cómo funcionan las energías renovables, usando solo materiales reciclados”. Este *prompt* permite a un estudiante pensar de manera ecológica y creativa, desarrollando un proyecto que demuestre la importancia de las energías renovables mientras se divierte en el proceso.

Cómo mejorar los *prompts*

Como vimos en capítulos anteriores, los *prompts* son las instrucciones que le das a una IA para obtener la respuesta que necesitas. Si alguna vez le hiciste una pregunta a la IA y te respondió algo que no tenía sentido, este capítulo es para ti. Vamos a ver cómo mejorar esos *prompts* para conseguir respuestas más útiles y precisas. Aprender a estructurar y afinar un *prompt* puede ser la diferencia entre una respuesta que resuelve tus dudas y otra que te deja más confundido de lo que podías estar al principio.

A veces, al intentar explicar algo, la otra persona no entiende y responde con algo fuera de contexto. Esto ocurre porque, quizá, nuestra instrucción no fue lo suficientemente clara. Lo mismo ocurre con ChatGPT. Si el *prompt* no está claro, es probable que la respuesta tampoco lo esté. Aquí aprenderás a afinar esos *prompts* para que la IA responda de forma clara y directa, y así puedas aprovechar al máximo esta herramienta.

Primero, los *prompts* son como las instrucciones que le das a la IA. Imagina que la IA es un chef. Si le pides “Haz algo rico para comer”, podría preparar cualquier cosa, desde un estofado hasta una pizza con piña. Pero si le dices: “Quiero una ensalada sin aderezo porque estoy a dieta”, estás siendo más específico y es más probable que obtengas algo que realmente te guste. La clave es ser claro y específico para que la IA entienda lo que necesitas. Cuanta más información relevante le des a la IA, mejor podrá cumplir con tu solicitud. Es como si estuvieras hablando con alguien que no conoce tus preferencias, y cuanto más le cuentes, mejor podrá ayudarte. Al usar *prompts* bien estructurados, estás guiando a la IA hacia la respuesta que deseas, evitando ambigüedades que puedan llevar a resultados inesperados. Además, ten en cuenta que



un buen *prompt* es aquel que anticipa posibles confusiones y da contexto suficiente para evitarlas.

A veces, la IA puede desviarse del tema que buscas. Por ejemplo, si le pides que te explique los agujeros negros, podría empezar a hablarte de un programa de televisión que no conoces. En ese caso, hay que ajustar el *prompt*, como si corrigieras a alguien: “No, no estoy hablando de televisión, háblame de los agujeros negros en el espacio”. Así, la IA sabrá exactamente a qué te refieres. Este tipo de ajustes se llaman iteraciones, las cuales son esenciales para obtener respuestas precisas.

Otro problema común es cuando la IA te responde de manera demasiado técnica. Imagina que le preguntas cómo funciona la fotosíntesis y te responde con términos complicados de Biología avanzada. Lo mejor en ese caso es ajustar el *prompt*: “Explicame la fotosíntesis como si estuviera en secundaria”. De esa manera, la respuesta será más sencilla y fácil de entender. Hacer preguntas que limiten el nivel de detalle técnico ayuda mucho cuando solo quieres tener una idea general sin entrar en conceptos difíciles.

Otro aspecto importante es iterar. Esto significa repetir y ajustar el *prompt* hasta que la respuesta sea la correcta. Pongamos que estás escribiendo un cuento y le dices a la IA: “Continúa la historia del detective que investigaba un caso raro en un pueblo pequeño”, y la historia no tiene sentido, puedes agregar más detalles al *prompt*: “El detective acaba de encontrar una pista en el café del pueblo, y la lluvia no ha parado desde hace días”. Así, la IA tendrá más contexto y podrá hacer que la historia sea más coherente. No tengas miedo de corregir y mejorar cada vez, la IA aprende de esos ajustes y va mejorando la calidad de sus respuestas. Recuerda que la IA, aunque avanzada, a veces malinterpreta lo que quieres decir. Es como cuando le pides algo a un niño y se confunde con lo que le pediste. Si la IA no te entiende a la primera, intenta explicárselo de otra manera. La paciencia y la claridad son clave para sacar el máximo provecho de las interacciones con la

IA. Además, es útil pensar en diferentes maneras de formular la misma pregunta hasta obtener la mejor respuesta posible.

Con estos consejos, puedes mejorar mucho las respuestas de la IA. Se trata de ser claro, específico y estar dispuesto a ajustar los *prompts* hasta que consigas lo que necesitas. La IA aprende de esas correcciones y tú te vuelves cada vez mejor en la formulación de preguntas para sacar el máximo provecho de esta tecnología. Así es como se empieza a entender realmente cómo funcionan los *prompts* y cómo puedes convertirte en un usuario más efectivo. Cuanto más precisos y detallados sean tus *prompts*, mejor será la calidad de las respuestas que obtendrás.

Seis ejemplos prácticos de mejora de *prompts*

1. Profesional de mercadeo: si eres un especialista en mercadeo y necesitas ideas para una campaña publicitaria, podrías empezar con la siguiente línea: “Dame ideas para una campaña publicitaria de un producto de belleza”. Si el resultado es muy genérico, podrías refinarlo así: “Dame tres ideas creativas para una campaña publicitaria de un nuevo protector solar, enfocadas en mujeres jóvenes que quieren proteger su piel sin perder el estilo”. Esto añade contexto y un público objetivo, mejorando la relevancia de la respuesta. Además, podrías especificar el tono de la campaña: “Quiero ideas para una campaña que sea divertida y que se pueda compartir en redes sociales”.

2. Profesor de Ciencias: eres un profesor y necesitas explicar la fotosíntesis a tus estudiantes. Un *prompt* inicial podría ser: “Explicame la fotosíntesis”. Si la respuesta es demasiado complicada, ajusta el *prompt* con esta línea: “Explicame la fotosíntesis de manera simple, como si estuviera enseñando a un estudiante de secundaria”. Esto hará que la IA adapte el nivel de complejidad. También podrías pedir ejemplos: “Dame un ejemplo práctico de cómo ocurre la fotosíntesis en una planta común como el girasol”. Los ejemplos ayudan a que los estudiantes entiendan mejor el proceso.



3. Estudiante de Historia: Si eres un estudiante y quieres entender mejor la Revolución francesa, podrías empezar con: “Explícame la Revolución francesa”. Si la respuesta es muy técnica, ajusta el *prompt*: “Dame un resumen fácil de entender sobre la Revolución francesa, con los eventos principales y por qué fue importante”. Así obtendrás un resumen claro y directo. Si necesitas más detalles, podrías pedirle que se enfoque en algún personaje importante: “Explícame el papel de Robespierre en la Revolución francesa de manera sencilla”.

4. Emprendedor: si estás desarrollando un producto nuevo y quieres validar la idea, podrías empezar con esto: “Dame ideas para validar un producto nuevo”. Si las ideas son muy amplias, haz el *prompt* más específico de esta manera: “Dame tres maneras efectivas de validar un nuevo tipo de botella reutilizable en una ciudad mediana”. Esto hará que las sugerencias sean más aplicables. Además, podrías pedir recomendaciones de pruebas rápidas: “Dame ejemplos de pruebas de mercado que pueda hacer en una semana con un presupuesto limitado”.

5. Creador de contenido: si necesitas inspiración para un video sobre hábitos saludables, podrías empezar tu conversación así: “Dame ideas para un video sobre hábitos saludables”. Si la respuesta es muy vaga, refina el *prompt*: “Dame tres ideas para un video sobre hábitos saludables para estudiantes universitarios que tienen poco tiempo y presupuesto limitado”. Así obtendrás ideas más específicas y útiles. También podrías pedir un enfoque diferente: “Dame ideas para un video sobre hábitos saludables que se pueda hacer en menos de un minuto y sea divertido”.

6. Padre o madre: si quieres ayudar a tu hijo con su tarea de Matemáticas, podrías empezar con: “Ayúdame con la tarea de Matemáticas”. Si la respuesta no es la adecuada, sé más específico: “Explícame cómo resolver una división larga, paso a paso, para poder ayudar a mi hijo de 9 años con su tarea”. Esto hará que la respuesta sea más práctica y adecuada. También podrías pedir ejemplos similares: “Dame tres problemas de práctica similares para que pueda ayudar a mi hijo a practicar más”.

ChatGPT: cómo ajustar las respuestas con prompts inteligentes

Interactuar con modelos de lenguaje como ChatGPT puede ser muy útil, siempre y cuando sepas cómo pedirle lo que necesitas. Existen formas para ajustar el tipo de respuesta que recibes, y aunque no siempre puedas cambiar todos los parámetros de forma directa, entender cómo funcionan estos ajustes puede marcar la diferencia entre una respuesta mediocre y una realmente impresionante. A continuación, te explicaremos cómo sacarle el máximo provecho.

Temperatura y el top-p

La temperatura suele variar entre 0.0 y 1.0. Un valor de 0.0 hará que el modelo sea extremadamente conservador y preciso, mientras que un valor cercano a 1.0 permite respuestas mucho más creativas y variadas.

El valor de top-p también varía entre 0.0 y 1.0. Un valor bajo (por ejemplo, 0.1) hará que el modelo seleccione solo las opciones más seguras y comunes, mientras que un valor cercano a 1.0 permite una mayor diversidad en las opciones, lo cual resulta en respuestas más inesperadas.

Cómo influenciar respuestas con prompts en ChatGPT

En el chat que se usa regularmente en la web, como ChatGPT, no puedes cambiar manualmente parámetros como la temperatura o el top-p porque OpenAI los ha configurado para garantizar una experiencia equilibrada para todos los usuarios. Sin embargo, existen formas

indirectas de influir en el estilo y contenido de las respuestas mediante el uso adecuado de los *prompts*, o sea, las instrucciones que le das al modelo. Vamos a ver cómo puedes hacerlo.

Dar instrucciones claras y específicas

Puedes hacer que las respuestas de ChatGPT sean más creativas o más concretas dependiendo del tipo de instrucciones que le des. Esto se puede lograr con la forma en que formulas tus preguntas:

Para respuestas precisas y directas: usa frases como la siguiente: “Explícame esto de forma clara y con hechos concretos”.

Para respuestas más creativas: da instrucciones como esta: “Dame una explicación divertida o imaginativa sobre este tema”. Esto hará que el modelo tenga un enfoque más libre y creativo.

Si quieres una explicación con metáforas o ejemplos curiosos, asegúrate de especificarlo. El lenguaje que uses en tu *prompt* puede guiar a ChatGPT para que sea más o menos creativo.

Reformular las preguntas

Las preguntas amplias o abiertas tienden a generar respuestas más variadas y creativas, mientras que las preguntas específicas llevan a respuestas más directas y concisas. Preguntas como la siguientes: “¿Qué opinas sobre el cambio climático?” pueden generar respuestas extensas y diversificadas, mientras que “¿Cuáles son los tres principales efectos del cambio climático?” generará una respuesta mucho más concreta.

Usar contexto o roles

Pedirle a ChatGPT que adopte un rol específico es una gran forma de ajustar el tono y el contenido de la respuesta. Puedes influir en cómo



responde pidiéndole que actúe como un profesional o personaje en particular:

Científico: “Actúa como un científico explicando este concepto con precisión”.

Escritor creativo: “Sé un escritor creativo y cuenta una historia sobre este tema”.

Profesor: “Explicame este concepto como si fueras un profesor de secundaria”.

Estos roles ayudan a ChatGPT a adaptar su estilo de lenguaje y profundidad, dependiendo de lo que necesitas.

Acceso a la API para ajustes directos

Si tienes acceso a la API de OpenAI, puedes ajustar directamente parámetros como la temperatura, el top-p y la cantidad de *tokens*. Esto te da un control mucho más preciso sobre cómo responde el modelo, lo cual es particularmente útil para aplicaciones específicas donde necesitas consistencia o creatividad a cierto nivel. Por ejemplo, para una aplicación de generación de historias, podrías subir la temperatura y el top-p, mientras que, para una herramienta de soporte técnico, podrías preferir valores más bajos para asegurar respuestas claras y precisas.

Ejemplos

Veamos cómo diferentes personas podrían formular sus *prompts* para aprovechar al máximo las respuestas de ChatGPT según sus necesidades profesionales.

1. Desarrolladores de *software*

Un desarrollador que busca inspiración para un proyecto de software podría usar un *prompt* abierto para generar ideas innovadoras.

Prompt: “Estoy desarrollando una nueva aplicación para organizar tareas. Dame ideas innovadoras y funciones que hagan que esta *app* se destaque”.

Explicación: un *prompt* abierto permite que el modelo sea más creativo y sugiera funciones únicas, como el uso de IA para categorizar automáticamente las tareas o recordatorios basados en el contexto del usuario.

2. Artistas

Un artista que busca inspiración para una nueva obra podría hacer una solicitud que incentive la imaginación.

Prompt: “Quiero crear una obra de arte sobre el concepto de *esperanza*. Dame ideas abstractas y fuera de lo común”.

Explicación: este tipo de *prompt* fomenta respuestas con metáforas y elementos visuales que podrían servir de base para una pieza artística inspiradora y única.

3. Empresarios

Un empresario que está desarrollando un plan de negocio podría combinar claridad con ideas novedosas para obtener sugerencias relevantes.

Prompt: “Estoy planeando abrir una cafetería con un concepto único. Dame ideas de servicios para atraer a un público moderno”.



Explicación: al pedir un equilibrio entre innovación y practicidad, el modelo generará sugerencias como tener una barra de bebidas especializadas o espacios para trabajar, lo cual puede diferenciar al negocio de otros similares.

4. Estudiantes de Filosofía

Un estudiante de filosofía podría formular un *prompt* que requiera múltiples perspectivas sobre un tema complejo.

Prompt: “Explora las diferentes perspectivas filosóficas sobre el concepto de *libertad*”.

Explicación: este tipo de pregunta lleva al modelo a abordar diferentes puntos de vista, como el de los existencialistas, utilitaristas y estoicos, proporcionando una visión rica y completa.

5. Editores de contenido

Un editor que necesite optimizar un artículo para SEO puede solicitar una reescritura clara y directa para mejorar la efectividad del texto.

Prompt: “Reescribe este párrafo sobre los beneficios del ejercicio físico para hacerlo más directo y optimizado para SEO”.

Explicación: al pedir claridad y optimización SEO, el modelo proporcionará un texto sencillo, directo y adecuado para los motores de búsqueda, incluyendo palabras clave relevantes.

6. Emprendedores

Un emprendedor que busca un nombre para una marca puede pedirle al modelo sugerencias creativas.

Prompt: “Necesito un nombre creativo para una marca de ropa sostenible dirigida a jóvenes adultos. Dame algunas opciones”.



Explicación: un *prompt* que demande creatividad ayudará al modelo a generar nombres que conecten con el público objetivo, como algo que refleje valores ecológicos y modernidad.

7. Psicólogos

Un psicólogo que necesita explicar una teoría compleja a un paciente podría pedir un ejemplo sencillo y directo.

Prompt: “Dame un ejemplo sencillo para explicar el concepto de refuerzo positivo a un paciente”.

Explicación: un ejemplo claro puede ayudar a un paciente a entender cómo pequeñas recompensas refuerzan comportamientos positivos, haciendo el concepto accesible.

8. Guionistas

Un guionista que está desarrollando una escena emocional podría hacer un *prompt* que permita la exploración de las emociones de los personajes.

Prompt: “Estoy escribiendo una escena entre dos personajes que se reencuentran después de muchos años. Quiero un diálogo emotivo y lleno de tensión”.

Explicación: un *prompt* que fomente la exploración emocional ayudará a crear diálogos ricos en matices, haciendo que la escena sea más interesante y realista.

La próxima vez que uses ChatGPT, piensa bien en cómo quieres que sea la respuesta. ¿Buscas algo más creativo o algo más directo y preciso? ¿Prefieres que la respuesta sea corta o extensa? Aunque en algunas versiones del chat no puedes ajustar directamente la temperatura o el top-p, el uso de *prompts* inteligentes te permite influir significativamente en el resultado. Cada ajuste en tu pregunta, cada detalle que incluyas en

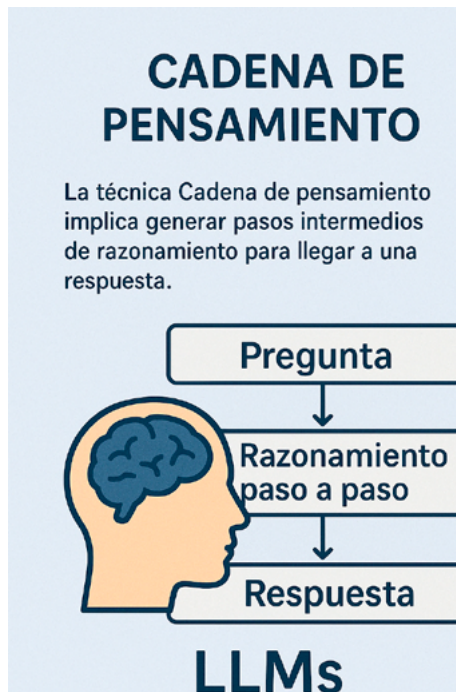
tu *prompt*, es una herramienta poderosa para personalizar la experiencia y obtener exactamente lo que necesitas de ChatGPT.

¡No dudes en experimentar! Prueba distintas formas de preguntar y observa cómo varían las respuestas. Con el tiempo, te volverás experto en usar los *prompts* para guiar al modelo y obtener resultados realmente útiles y así podrás optimizar el tiempo.

Técnicas más avanzadas

Vamos a profundizar más en técnicas que ayudan a comunicar de manera más efectiva con los LLM, pero de una forma práctica. Imagina que eres un jugador de fútbol, y tienes diferentes estrategias para enfrentar a tu rival. Bueno, estas técnicas son como esas estrategias.

Cadenas de pensamiento (*chain of thought*)



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Vamos a darle un vistazo profundo a la técnica llamada *chain of thought* (CoT), que es una forma muy especial de estructurar un *prompt* para que la IA responda con claridad, mostrando cada paso que sigue para resolver un problema. Esta técnica se usa para hacer que la IA piense como un humano, desglosando su proceso mental paso a paso, en lugar de ir directamente al resultado final.

¿Qué es la *chain of thought*?

La técnica CoT puede verse como pedirle a alguien que piense en voz alta. Imagina que le preguntas a un amigo cómo resolver un problema complicado de matemáticas y, en vez de darte solo el resultado, te cuenta cada paso que sigue, desde el análisis de los datos hasta sus operaciones. Esto es exactamente lo que hace el CoT, es decir: guía a la IA para que descomponga su respuesta en partes dándote una explicación detallada de cada paso que toma.

A veces solo recibir una respuesta final no es suficiente, especialmente si el problema es complejo o si quieres entender cómo se llegó a esa conclusión. Con la CoT puedes ver el proceso completo, lo cual ayuda a verificar si cada paso tiene sentido y, si hay algún error, identificar dónde está. Además, esta técnica ayuda a la IA a manejar tareas que requieren un razonamiento lógico o matemático más complicado^{xxvi}.

Cuando usas la CoT, es como decirle a la IA: “Tranquila, no tienes que apurarte; ve despacio y dime cada paso”. Esto no solo mejora la calidad de las respuestas, sino que también ayuda a reducir errores y a hacer que la IA “piense” de forma más organizada. Para entender bien la diferencia, veamos un ejemplo en la vida real.

Supón que queremos resolver un problema de Matemáticas sencillo para ver cómo se comporta la IA con y sin la CoT.

Para los siguientes ejemplos vamos a usar ChatGPT con el modelo GPT-4o.



- Ejemplo normal (sin CoT)

Vamos a plantear un problema simple:

Pregunta: “Si tienes 3 manzanas y compras 4 manzanas más, ¿cuántas manzanas tienes en total?”

La respuesta de la IA podría ser algo así como:

Respuesta: “Tienes 7 manzanas”.

Este es un ejemplo de un *prompt* directo y una respuesta directa. La IA hizo la operación y te dio el resultado sin explicar nada más. Para problemas sencillos puede funcionar bien, pero ¿qué pasa si el problema se vuelve más complicado?

- Ejemplo complejo (con CoT)

Vamos a ver cómo sería la respuesta si usamos la CoT. Aquí, la IA desglosa el proceso paso a paso:

Pregunta con CoT: “Resuelve el siguiente problema paso a paso: Si tienes 3 manzanas y compras 4 manzanas más, ¿cuántas manzanas tienes en total?”

Respuesta con CoT: “¡Claro! Vamos a resolver el problema paso a paso.

Problema: Si tienes 3 manzanas y compras 4 manzanas más, ¿cuántas manzanas tienes en total?

Paso 1: Identificar la cantidad inicial de manzanas.

- *Tienes 3 manzanas al principio.*

Paso 2: identificar la cantidad de manzanas compradas.

- *Compras 4 manzanas adicionales.*

Paso 3: sumar ambas cantidades para obtener el total.

- $3 \text{ manzanas (iniciales)} + 4 \text{ manzanas (compradas)} = 7 \text{ manzanas en total.}$

Respuesta: Tienes un total de 7 manzanas”.

¿Ves la diferencia? Con la CoT la IA te da una explicación detallada de cada paso, lo cual puede ser útil no solo para problemas de Matemáticas, sino para cualquier tarea que requiera lógica o pasos organizados, como resolver acertijos o analizar situaciones complejas. Por cierto, los modelos del lenguaje son en extremo malos para resolver problemas en Matemáticas, sin embargo, como veremos al final del libro, podemos darles superpoderes a estos modelos y dotarlos de programas que realicen operaciones matemáticas para resolver problemas de este tipo, a esto se les conoce como agentes de IA, muy útiles cuando los LLM tienen problemas para resolver problemas complejos.

Ahora vamos a ver un problema un poco más elaborado, donde el uso de la CoT realmente marca la diferencia:

Pregunta: “En una tienda, cada manzana cuesta \$2 y cada naranja cuesta \$3. Si tienes \$10, ¿cuántas frutas puedes comprar si incluye necesariamente 2 naranjas?”

- Respuesta normal (sin CoT)

Respuesta: “Puedes comprar 4 frutas”.

Esta respuesta es correcta, pero no nos dice cómo llegó ahí. Para alguien que quiera aprender o entender el proceso, esto se siente incompleto.

- Respuesta compleja (con CoT)

Paso 1: “Empiezo con \$ 10 en total”.

Paso 2: “Cada naranja cuesta \$ 3, y quieres comprar 2 naranjas”.

Paso 3: “Multiplico el precio de una naranja (\$ 3) por la cantidad de naranjas (2): $3 \times 2 = 6$ ”.

Paso 4: “Resto el costo de las naranjas del total de dinero que tienes: $\$ 10 - \$ 6 = \$ 4$ ”.

Paso 5: “Cada manzana cuesta \$ 2. Con el dinero restante (\$ 4), divido para ver cuántas manzanas puedo comprar: $\$ 4 \div \$ 2 = 2$ manzanas”.

Paso 6: “Entonces, puedes comprar 2 naranjas y 2 manzanas, lo que hace un total de 4 frutas”.

Aquí, el proceso es mucho más claro. La IA no solo llega a la conclusión, sino que muestra cómo usa cada pedazo de información para llegar a la respuesta final. Esto es útil para alguien que quiere asegurarse de que cada paso es correcto y que entiende bien cómo se resolvió el problema.

Bien, y qué tal si estoy en mi clase de historia y no entendí muy bien por qué comenzó la Revolución francesa. Si le preguntamos al asistente de la siguiente manera:

User: “Explica por qué comenzó la Revolución Francesa”.

IA: La Revolución francesa comenzó en 1789 debido a la desigualdad social, las enormes deudas del Estado y el descontento popular frente a los privilegios de la nobleza y el clero. La crisis económica y el aumento de impuestos empujaron al pueblo a exigir reformas, desencadenando un movimiento revolucionario”.

Ahora realicemos el mismo ejercicio, pero con CoT:

User: “Explica paso a paso por qué comenzó la Revolución francesa. Describe cada causa o motivo en orden, comenzando con la situación política y social, luego la situación económica y, finalmente, las ideas filosóficas de la época que inspiraron el cambio. Desglosa cada punto en frases cortas y detalladas”.

IA: *“Claro, aquí tienes un desglose de las causas de la Revolución francesa en un formato paso a paso y detallado:*

1. Situación política y social

- *Monarquía absoluta: Francia era gobernada por una monarquía absoluta, donde el rey tenía un poder casi total. Luis XVI gobernaba sin consultar al pueblo o a una representación democrática.*
- *Desigualdad entre clases: la sociedad estaba dividida en tres estamentos: el clero (primer estado), la nobleza (segundo estado) y el tercer estado (todos los demás, incluyendo campesinos y burgueses).*
- *Privilegios de los primeros dos estados: el clero y la nobleza no pagaban impuestos o contribuían muy poco, a pesar de ser ricos y poseer gran parte de las tierras.*
- *Descontento en el tercer estado: la mayoría de la población (el tercer estado) era la que pagaba todos los impuestos y sostenía al país. Esto generaba un profundo resentimiento por la falta de equidad.*
- *Falta de representación: el tercer estado no tenía una verdadera representación política y se sentía marginado en las decisiones importantes del reino.*

2. Situación económica

- *Crisis financiera: Francia enfrentaba una grave crisis financiera debido a los costosos gastos de la monarquía y a las guerras, como la Guerra de Independencia de los Estados Unidos, en la cual Francia apoyó a los colonos.*
- *Malas cosechas: en los años previos a la Revolución, varias malas cosechas llevaron a escasez de alimentos y alzas en los precios, afectando gravemente al pueblo, especialmente a los más pobres.*

- *Aumento de impuestos: para cubrir los gastos del Estado, el gobierno intentó aumentar los impuestos al tercer estado, quienes ya sufrían por la situación económica, lo que intensificó el descontento.*
- *Altos precios de los alimentos: la inflación elevó el precio de productos básicos como el pan, lo que aumentó el hambre y el sufrimiento entre el pueblo.*
- *Endeudamiento excesivo: la monarquía se había endeudado tanto que ya no podía pedir más préstamos sin reformas drásticas. La economía estaba al borde del colapso.*

3. Ideas Filosóficas de la Época

- *Influencias de la Ilustración: pensadores como Voltaire, Rousseau y Montesquieu promovieron ideas de libertad, igualdad y justicia, cuestionando el poder absoluto de la monarquía y la autoridad de la Iglesia.*
- *Derechos individuales: la Ilustración defendía los derechos naturales del ser humano, como la libertad y la igualdad, inspirando a las personas a exigir más derechos y a cuestionar las estructuras tradicionales.*
- *Crítica a los privilegios: los filósofos ilustrados criticaban los privilegios de la nobleza y el clero, proponiendo una sociedad más justa y equitativa.*
- *Difusión de las ideas: las ideas ilustradas se difundieron a través de libros, panfletos y reuniones, llegando a amplios sectores de la sociedad, especialmente a la burguesía, que las adoptó como propias.*
- *Ejemplo de otras revoluciones: la reciente independencia de los Estados Unidos inspiró a los franceses, mostrando que era posible luchar por un cambio de sistema y conquistar libertades.*

Conclusión

La Revolución francesa comenzó por una combinación de factores políticos, sociales, económicos y filosóficos. El descontento por la desigualdad y



la injusticia se unió a las ideas de la Ilustración y a la crisis económica, creando un terreno fértil para el estallido revolucionario en 1789”.

En los ejemplos anteriores realizamos algo llamado *zero-shot* CoT, le estamos diciendo a la IA que “piense” paso a paso. Ahora que ya domina esta técnica vamos algo un poco más avanzado; el *chain of thought* (CoT) manual, donde, en vez de solo pedirle a la IA que piense paso a paso, le damos ejemplos específicos de cómo queremos que razona. Este proceso implica enseñarle a la IA a seguir una estructura de razonamiento que ya le mostramos antes, con ejemplos detallados que ilustren cada paso que debe seguir para llegar a la respuesta final. Se llama “manual” porque implica que el usuario, o sea, nosotros, debemos construir esos ejemplos cuidadosamente. No es tan simple como decir “piensa paso a paso”; aquí le mostramos a la IA cómo debe abordar cada tipo de problema, guiándola con ejemplos específicos. Esto requiere más trabajo de nuestra parte, ya que tenemos que pensar en ejemplos que sean representativos y claros.

Este método es muy útil cuando necesitamos respuestas de alta precisión y queremos asegurarnos de que la IA siga un camino específico de razonamiento. Sin embargo, también es más difícil de usar a gran escala, porque cada vez que enfrentamos un tipo de problema diferente, tendríamos que crear nuevos ejemplos.

¿Cómo funciona el *Manual CoT* en la práctica? Supongamos que queremos que la IA explique por qué comenzó la Revolución francesa usando la técnica de *Manual CoT*. Le daríamos un ejemplo paso a paso de cómo debería abordar la respuesta. Algo así:

Prompt manual CoT para la Revolución francesa:

“Voy a darte un ejemplo de cómo responder a una pregunta sobre las causas de un evento histórico. Para cada evento, sigue este tipo de razonamiento:



1. Describe la situación política, explicando cómo el sistema de gobierno y las clases sociales afectaron a la mayoría de la gente.
2. Explica la situación económica y cómo afectó a diferentes grupos sociales.
3. Añade el contexto de las ideas filosóficas o sociales de la época y cómo inspiraron a la gente a buscar cambios.

Ejemplo:

- Pregunta: ¿por qué comenzó la Revolución americana?
- Respuesta paso a paso:
 1. 'Primero, el sistema colonial estaba controlado por Gran Bretaña, lo cual generaba descontento porque los colonos americanos sentían que no tenían voz ni representación en las decisiones políticas.'
 2. 'Segundo, había impuestos altos y leyes comerciales restrictivas que dificultaban la economía de los colonos, generando un sentimiento de injusticia económica.'
 3. 'Tercero, las ideas de libertad e independencia estaban en auge, inspiradas en filósofos como John Locke, lo que motivó a los colonos a luchar por sus derechos y autonomía.'

Ahora, usando este ejemplo, explícalo para la Revolución francesa, paso a paso”.

Esta sería la respuesta de la IA:

IA: *Respuesta paso a paso:*

- *Situación política: Francia era una monarquía absoluta donde el poder estaba concentrado en manos del rey, Luis XVI, y la nobleza. El sistema de clases sociales estaba dividido en tres estamentos: el clero (primer estado), la nobleza (segundo estado) y el resto de la población (tercer estado), que incluía desde campesinos hasta burgueses. El tercer estado representaba a la gran mayoría de la población, pero no*

tenía poder político ni influencia en las decisiones, lo que generaba un profundo descontento y un sentimiento de injusticia.

- *Situación económica: Francia atravesaba una grave crisis económica agravada por años de malas cosechas y la pesada deuda del país, que aumentó aún más tras el apoyo francés a la Revolución americana. Para intentar resolver la crisis, el gobierno impuso mayores impuestos al tercer estado, mientras que el clero y la nobleza estaban exentos. Esta desigualdad económica aumentó el resentimiento y las tensiones entre las clases, afectando especialmente a las personas comunes que vivían en la pobreza.*
- *Ideas filosóficas y sociales: la Ilustración, un movimiento intelectual de la época, promovía ideas de libertad, igualdad y derechos humanos. Filósofos como Rousseau y Voltaire cuestionaban la autoridad de la monarquía y defendían el poder del pueblo para decidir su propio destino. Estas ideas se difundieron ampliamente, inspirando a las personas a cuestionar el sistema de clases y a exigir cambios”.*

En este caso obtenemos exactamente la respuesta que queremos. Veamos otro ejemplo. Imagina que queremos usar un asistente de IA para que pueda ayudar a una secretaria en una oficina, específicamente en la organización de reuniones. La técnica Manual CoT sería ideal para guiar a la IA a través de los pasos necesarios, mostrando cómo debe abordar la tarea de organizar una reunión en orden lógico.

Contexto de manual CoT: organización de una reunión: le damos a la IA un ejemplo detallado de cómo una secretaria debería razonar paso a paso para organizar una reunión. Esto ayuda a que la IA aprenda el proceso específico y entienda qué pasos debe tomar para cumplir con la tarea correctamente.

Prompt Manual CoT para organización de reuniones:

“Voy a darte un ejemplo de cómo organizar una reunión en una oficina paso a paso. Para cada reunión, sigue este orden de razonamiento:

1. Confirma los detalles básicos: fecha, hora, lugar y propósito de la reunión.
2. Revisa la lista de participantes y confirma la disponibilidad de cada uno.
3. Reserva la sala o el espacio necesario para la reunión.
4. Envía invitaciones con todos los detalles y pide confirmación de asistencia.
5. Prepara cualquier material necesario, como agendas, documentos o equipos audiovisuales.
6. Un día antes de la reunión, envía un recordatorio a todos los participantes.

Ejemplo:

- Tarea: Organizar una reunión de equipo sobre el avance del proyecto.
- Proceso paso a paso:
 1. 'Primero, confirmo que la reunión será el 5 de marzo a las 10:00 AM en la sala de conferencias y que el objetivo es revisar el avance del proyecto.'
 2. 'Luego, reviso la lista de participantes: el gerente de proyecto, los líderes de cada equipo y el cliente principal. Verifico que todos estén disponibles a esa hora.'
 3. 'A continuación, reservo la sala de conferencias en el sistema de reservas de la oficina para asegurar que el espacio esté disponible.'
 4. 'Después, envío las invitaciones a cada participante, incluyendo la fecha, hora, lugar y propósito de la reunión, y pido confirmación de asistencia.'
 5. 'Luego, preparo la agenda de la reunión y reúno todos los documentos necesarios para la revisión del proyecto. También me aseguro de que haya un proyector en la sala.'
 6. 'Finalmente, un día antes de la reunión, envío un recordatorio a todos los participantes con los detalles y la agenda para que estén preparados.'

Ahora, usando este ejemplo, organiza la próxima reunión del equipo de ventas paso a paso”.

IA: “Tarea: organizar una reunión del equipo de ventas para discutir la estrategia del próximo trimestre.

Proceso paso a paso:

- *Confirmo los detalles básicos: la reunión será el 15 de noviembre a las 3 p. m. en la sala de reuniones principal y el propósito es definir la estrategia de ventas para el próximo trimestre.*
- *Reviso la lista de participantes: los asistentes serán el jefe de ventas, los líderes de cada equipo de ventas regional y el analista de mercado. Confirmo la disponibilidad de cada uno para la fecha y hora programadas.*
- *Reserva de espacio: procedo a reservar la sala de reuniones principal en el sistema de reservas de la oficina para garantizar que esté disponible.*
- *Enviar invitaciones: envío las invitaciones con todos los detalles relevantes: fecha, hora, lugar y objetivo de la reunión. Incluyo una solicitud de confirmación de asistencia para asegurar que todos estén al tanto.*
- *Preparación de materiales: preparo la agenda de la reunión, los informes de ventas del trimestre anterior y cualquier material visual o documento necesario para respaldar la discusión de estrategias. También aseguro que el equipo audiovisual, como el proyector, esté listo en la sala.*
- *Enviar recordatorio: un día antes de la reunión, envío un recordatorio a todos los participantes, incluyendo la agenda y los detalles importantes para que puedan revisar la información previamente”.*

Este proceso asegura que todos estén informados y preparados para contribuir eficazmente a la reunión de estrategia de ventas.

Si lo consideras que esto tiene aplicaciones en todas las áreas y aspectos de la vida cotidiana, no necesita ser un científico experto para poder

comunicarse con la IA. Por ejemplo, un profesor que quiera preparar una clase sobre la primera Ley de Newton, podemos aplicar Manual CoT para guiar a la IA a crear un plan de lección estructurado y efectivo. Le damos a la IA un ejemplo detallado de cómo desarrollar la clase paso a paso, asegurándonos de que cubra todos los elementos clave para que el contenido sea claro y comprensible para los estudiantes.

Prompt Manual CoT para preparar una clase sobre la Primera Ley de Newton:

“Voy a darte un ejemplo de cómo planificar una clase sobre la Primera Ley de Newton paso a paso. Para cada tema de ciencia, sigue estos pasos para asegurarte de cubrir los conceptos importantes y de preparar una lección interactiva:

- Define el objetivo: describe qué deberían entender los estudiantes al final de la clase (por ejemplo, comprender el concepto de inercia y cómo la Primera Ley de Newton lo explica).
- Introduce el concepto básico: explica en términos simples qué dice la Primera Ley de Newton, utilizando ejemplos cotidianos.
- Ejemplos prácticos: da ejemplos de la vida real que demuestren la ley, como un auto que sigue en movimiento hasta que algo lo detiene.
- Experimento o demostración en clase: planifica una actividad práctica que los estudiantes puedan ver o realizar para entender mejor la ley (por ejemplo, usar un carrito de juguete que se detiene al chocar con una barrera).
- Explica las implicaciones: conecta la ley con situaciones de la vida cotidiana y cómo se aplica en el mundo real.
- Evaluación breve: crea preguntas o ejercicios para comprobar que los estudiantes han entendido el concepto.



Ejemplo:

- Tarea: preparar una clase sobre la Primera Ley de Newton para estudiantes de secundaria.
- Proceso paso a paso:
 1. “Primero, defino el objetivo de la clase: los estudiantes deben entender qué es la inercia y cómo la Primera Ley de Newton explica el movimiento o el estado de reposo de los objetos”.
 2. “Luego, introduzco la ley de manera sencilla: ‘La Primera Ley de Newton establece que un objeto en reposo permanecerá en reposo y un objeto en movimiento continuará en movimiento en línea recta, a menos que actúe sobre él una fuerza externa’”.
 3. “Para dar ejemplos prácticos, hablo sobre un vaso que permanece en una mesa hasta que alguien lo mueve o un auto que sigue avanzando hasta que se frena”.
 4. “Después, planifico una demostración en clase: un carrito de juguete que se desliza sobre una mesa y se detiene al chocar con una caja. Esto ayuda a que los estudiantes vean la ley en acción”.
 5. “A continuación, explico cómo esta ley se aplica en la vida diaria, como cuando usamos cinturones de seguridad en el auto para detener nuestro cuerpo en caso de frenar bruscamente”.
 6. “Finalmente, preparo algunas preguntas de repaso para verificar la comprensión, como ‘¿Qué le ocurre a un objeto en movimiento si no hay una fuerza que lo detenga?’”.

Usa este ejemplo para desarrollar una clase sobre la Primera Ley de Newton, siguiendo cada paso cuidadosamente”.

IA: Aquí tienes un desarrollo detallado para una clase sobre la Primera Ley de Newton, siguiendo los pasos que has descrito:

1. Definir el objetivo

Objetivo de la clase: al finalizar la clase, los estudiantes deben comprender el concepto de inercia y cómo la Primera Ley de Newton explica que un objeto en reposo permanecerá en reposo y un objeto en movimiento continuará moviéndose a velocidad constante en línea recta, salvo que una fuerza externa actúe sobre él.

2. Introducir el concepto básico

Explicación simplificada de la Ley: “La Primera Ley de Newton, también conocida como Ley de inercia, establece que un objeto en reposo permanecerá en reposo y un objeto en movimiento continuará moviéndose en línea recta a velocidad constante, a menos que una fuerza externa cambie su estado”.

Ejemplo cotidiano simple: imagina una taza de café en una mesa. La taza no se moverá sola; necesita que alguien la empuje. Lo mismo ocurre con un libro, que no se deslizará hasta que alguien lo mueva.

3. Ejemplos prácticos

Ejemplos de la vida real:

- Auto en movimiento: un auto sigue avanzando hasta que se aplica el freno. Aquí, la fuerza externa es la fricción.
- Vaso sobre una mesa: un vaso se mantiene en su lugar hasta que lo empujas o alguien lo golpea.
- *Pasajero en un autobús: cuando el autobús frena bruscamente, sientes que tu cuerpo sigue moviéndose hacia adelante debido a la inercia.*

4. Experimento o demostración en clase

Demostración con un carrito de juguete:

- *Usa un carrito de juguete y una pequeña caja para detenerlo. Empuja el carrito sobre la mesa y permite que los estudiantes vean cómo el carrito sigue en movimiento hasta que la caja lo detiene.*
- *Materiales: carrito de juguete, caja pequeña, superficie lisa.*
- *Instrucción: pide a los estudiantes que predigan qué sucederá antes de empujar el carrito. Después de la demostración, explora por qué el carrito se detuvo.*

5. Explicar las implicaciones

Aplicación en la vida real:

- *Cinturones de seguridad: los cinturones ayudan a detener nuestro cuerpo cuando el auto frena repentinamente. Esto se debe a la inercia; el cinturón actúa como la fuerza externa que nos mantiene en nuestro asiento.*
- *Deportes: en deportes como el fútbol, los jugadores aplican fuerzas externas para cambiar la dirección y velocidad de la pelota, aprovechando la inercia y la fuerza para dirigirla.*

6. Evaluación breve

Preguntas para evaluar comprensión:

- *¿Qué le ocurre a un objeto en movimiento si no hay una fuerza que lo detenga?*
- *¿Por qué necesitamos cinturones de seguridad en un auto?*
- *¿Qué significa que algo tenga “inercia”?*

Ejercicio práctico: describe una situación de la vida real donde observas la inercia y cómo la Primera Ley de Newton la explica”.



Este formato estructurado asegura que los estudiantes entiendan y retengan el concepto de la Primera Ley de Newton a través de una combinación de teoría y práctica.

Con este plan básico, el profesor puede seguir ahondando en cada tema en particular, y esto porque, como ya lo vimos anteriormente, los LLM tienen una ventana de contexto que les ayuda a “recordar”, esto hace que el asistente “entienda” de que se está hablando y continua el hilo de la conversación. Por ejemplo, si le decimos a la IA: “De acuerdo con este ítem: demostración con un carrito de juguete:

- Usa un carrito de juguete y una pequeña caja para detenerlo. Empuja el carrito sobre la mesa y permite que los estudiantes vean cómo el carrito sigue en movimiento hasta que la caja lo detiene.
- Materiales: carrito de juguete, caja pequeña, superficie lisa.
- Instrucción: pide a los estudiantes que predigan qué sucederá antes de empujar el carrito. Después de la demostración, explora por qué el carrito se detuvo”.

Usuario: “Genere una guía de laboratorio detallada ilustrando cada paso al estudiante”.

IA: “Aquí tienes una guía de laboratorio detallada para una demostración de la Primera Ley de Newton utilizando un carrito de juguete. Esta guía guiará a los estudiantes paso a paso a través del experimento, animándolos a observar, predecir y analizar el comportamiento del carrito.

Guía de laboratorio: la Primera Ley de Newton

Tema: la Ley de la inercia

Objetivo: observar la Primera Ley de Newton en acción y comprender cómo funciona la inercia en un objeto en movimiento.

Materiales

- Carrito de juguete
- Caja pequeña (que actuará como obstáculo)
- Superficie lisa (mesa o piso)
- Papel y lápiz (para anotar observaciones y respuestas)
- Procedimiento

1. Preparación del material:

- Coloca el carrito de juguete en un extremo de la superficie lisa (como una mesa).
- Coloca la caja pequeña en algún punto más adelante en la misma superficie, de modo que el carrito pueda chocar con ella.

2. Pregunta inicial–predicción:

- Instrucción: pide a los estudiantes que observen la disposición del carrito y la caja.
- Preguntas de predicción: “¿Qué creen que sucederá cuando empujemos el carrito de juguete hacia la caja? ¿Por qué piensan que se detendrá o no se detendrá?”
- Escribe las predicciones: cada estudiante debe anotar su respuesta y justificación antes de iniciar el experimento.

3. Realización del experimento:

- Empuje el carrito: empuja suavemente el carrito hacia la caja y observa cómo se mueve.
- Observación del choque: cuando el carrito choca con la caja, toma nota de lo que sucede: ¿el carrito se detuvo o siguió en movimiento?

Nota para el instructor: asegúrate de que los estudiantes observen el cambio en el estado de movimiento del carrito al chocar.

4. Análisis–observación:

- *Preguntas de observación:* “¿Qué notaron que sucedió cuando el carrito chocó con la caja? ¿Por qué creen que el carrito se detuvo?”
- *Escriban las observaciones:* los estudiantes deben escribir sus observaciones del experimento, detallando si el carrito cambió de estado y cómo.

5. Explicación del concepto–la Primera Ley de Newton:

- *Explicación guiada:* explica que la Primera Ley de Newton dice que un objeto en movimiento permanecerá en movimiento, y un objeto en reposo permanecerá en reposo, a menos que una fuerza externa actúe sobre él.
- *Ejemplo relacionado:* relaciona la situación del carrito con otros ejemplos cotidianos como un automóvil que se detiene al aplicar los frenos.

6. Discusión de la inercia:

- *Preguntas de reflexión:* “¿Qué fuerzas crees que están actuando sobre el carrito para que se haya detenido? ¿Cómo puedes relacionar este experimento con la Primera Ley de Newton?”
- *Responde en grupo:* los estudiantes discuten y registran sus respuestas en grupo, reflexionando sobre la inercia y cómo la fuerza de la caja cambió el estado de movimiento del carrito.

7. Conclusión–reflexión final:

- *Conclusión:* cada estudiante debe escribir una breve conclusión sobre lo que han aprendido de esta actividad.
- *Pregunta de Cierre:* “¿Por qué es importante entender la inercia y la Primera Ley de Newton en la vida cotidiana? Da un ejemplo”.

Evaluación

Preguntas de evaluación:

1. *¿Qué le sucedió al carrito cuando chocó con la caja?*
2. *¿Por qué el carrito no siguió moviéndose después del choque?*
3. *¿Cómo demuestra este experimento la Primera Ley de Newton?*
4. *Describe un ejemplo de la vida diaria donde veas la inercia en acción.*

Puntuación: las respuestas deben reflejar una comprensión básica de la Primera Ley de Newton y el concepto de inercia.

Observaciones del instructor

- *Asegúrate de que los estudiantes no solo observen el movimiento, sino que entiendan el por qué detrás del experimento.*
- *Fomenta preguntas para ayudar a aclarar dudas o conceptos relacionados con la inercia y las fuerzas externas”.*

Esta guía de laboratorio permite a los estudiantes experimentar y analizar la Primera Ley de Newton de una manera visual y práctica, solidificando su comprensión del concepto de inercia.

A veces como padres queremos ayudar a nuestros hijos a estudiar un tema en específico, desafortunadamente en muchos casos estamos más perdidos que ellos. En este caso es posible usar un asistente de IA para que nos ayude a explicarle a nuestros hijos un tema en específico. Por ejemplo: si un niño quiere aprender una lección sobre un tema nuevo, podemos usar Manual CoT para guiar a la IA a explicar el tema de una manera simple, clara y con pasos que hagan la lección más divertida y fácil de entender. Aquí, el Manual CoT sería útil para estructurar la explicación de un concepto en pequeños pasos con ejemplos y actividades, adaptando el lenguaje a la comprensión de un niño.



Supongamos que el niño quiere aprender sobre el ciclo del agua.

Prompt Manual CoT para explicar el ciclo del agua a un niño:

“Voy a darte un ejemplo de cómo explicar el ciclo del agua a un niño de una manera divertida y sencilla. Sigue estos pasos para asegurarte de que el niño entienda el concepto:

- Introduce el tema con algo familiar: comienza con algo que el niño vea en su día a día, como la lluvia, y explícale que el ciclo del agua es lo que hace que llueva.
- Desglosa el ciclo en pasos sencillos: explica cada paso del ciclo con palabras simples: evaporación, condensación y precipitación.
- Usa ejemplos cotidianos: relaciona cada parte del ciclo con cosas que el niño conoce, como cuando el agua en un charco desaparece con el sol o cómo las nubes se ven llenas antes de llover.
- Incluye una actividad práctica: propón una actividad para hacer en casa, como hervir agua para mostrar la evaporación.
- Recuerda con una historia o juego: transforma el ciclo en una pequeña historia o juego donde el agua es el personaje principal que va cambiando de forma.
- Haz preguntas simples para evaluar: termina con una o dos preguntas fáciles para ver si el niño entendió el ciclo del agua.

Ejemplo:

- Tema: ciclo del agua para Niños
- Proceso paso a paso:
 1. “Primero, le explico al niño que el ciclo del agua es como un viaje que hace el agua, y por eso a veces llueve, otras veces hay charcos, y a veces hay sol”.
 2. “Luego, le cuento que el ciclo empieza cuando el sol calienta el agua de los ríos y charcos, y esta se convierte en vapor que sube al cielo. Esto se llama evaporación”.

3. “Después, el vapor se junta y forma nubes. Cuando las nubes están muy llenas, el agua cae como lluvia. Esto se llama precipitación”.
4. “Le doy un ejemplo divertido: “¿Te has fijado en un charco después de que ha llovido? ¿Ves cómo se seca cuando sale el sol? Eso es evaporación, y el agua sube al cielo para hacer nubes”.
5. “Propongo una actividad: ‘Vamos a calentar un poco de agua con ayuda de un adulto y ver cómo se convierte en vapor. Así entenderás mejor cómo funciona la evaporación”.
6. “Para que lo recuerde, invento una historia: ‘Imagina que el agua es como un superhéroe que tiene el poder de cambiar de forma. Puede volverse vapor, nube o lluvia y siempre está viajando”.
7. “Finalmente, hago una pregunta: ‘¿Te acuerdas de qué pasa cuando el sol calienta el agua? ¿Y qué hace el agua cuando sube al cielo y se vuelve una nube?’”.

Usa este ejemplo para explicarle el ciclo del agua a un niño, siguiendo cada paso cuidadosamente”.

IA: ¡Me parece genial tu enfoque! Aquí te dejo una explicación divertida y sencilla del ciclo del agua, siguiendo tus pasos para que los niños lo disfruten y aprendan fácilmente.

Tema: el ciclo del agua es una aventura

1. Introduce el tema con algo familiar

Comencemos hablando de la lluvia. ¿Te has dado cuenta de que cuando llueve, el agua parece venir de las nubes? Pues esto pasa gracias a una gran aventura que vive el agua, llamada el ciclo del agua.

2. Desglosa el ciclo en pasos sencillos

El ciclo del agua tiene tres grandes momentos:

- *Evaporación: cuando el sol calienta el agua de los ríos, lagos, y charcos, esta se convierte en un vapor invisible que sube al cielo.*
- *Condensación: cuando ese vapor sube, se enfría y se convierte en gotitas que se juntan para formar las nubes.*
- *Precipitación: cuando las nubes están muy llenas de agua, la sueltan en forma de lluvia (o a veces nieve o granizo).*

3. Usa ejemplos cotidianos

- *Evaporación: “¿Has visto un charco después de la lluvia? Cuando sale el sol, el charco empieza a desaparecer poco a poco. ¡Esa es el agua evaporándose!”.*
- *Condensación: “Cuando ves muchas nubes en el cielo, es porque hay mucha agua en ellas que se juntó para formar esas nubes”.*
- *Precipitación: “Cuando las nubes están bien llenas, sueltan el agua y empieza a llover”.*

4. Incluye una actividad práctica

- *“Vamos a hacer un experimento en casa. Con ayuda de un adulto, calentaremos un poco de agua y veremos cómo se convierte en vapor. Así verás de cerca cómo funciona la evaporación”.*

5. Recuerda con una historia o juego

- *“Imagina que el agua es un superhéroe llamado Aguamigo. Aguamigo tiene el poder de transformarse en diferentes cosas: en vapor para subir al cielo, en nube para hacer amigos y en lluvia para ayudar a las plantas a crecer. Aguamigo nunca se queda quieto y siempre está de viaje”.*

6. Haz preguntas simples para evaluar

- “¿Te acuerdas qué pasa cuando el sol calienta el agua? ¿Y qué hace el agua cuando sube al cielo y se vuelve nube?”.

Con este enfoque, el niño no solo aprenderá el ciclo del agua, sino que también lo verá como una historia divertida llena de aventuras. ¡Espero que este ejemplo te sea útil!

La CoT es una forma de estructurar *prompts* que guía a la IA para que desarrolle respuestas paso a paso. Esta técnica ha ganado popularidad en el ámbito de la IA porque permite a los modelos de lenguaje (como los GPT) abordar problemas complejos de manera más lógica y organizada. Sin embargo, como toda herramienta, el CoT tiene ventajas y desventajas que vale la pena considerar para comprender cuándo y cómo usarla de manera efectiva.

Pros de la técnica CoT

1. Mayor claridad y comprensión

Ventaja: la técnica CoT permite a la IA desglosar un problema en pasos individuales, lo que da como resultado una respuesta más detallada y fácil de seguir. Esto es especialmente útil en temas complejos, como problemas matemáticos, científicos o de razonamiento lógico, donde una respuesta directa puede parecer insuficiente o confusa.

Ejemplo: en una pregunta de Física sobre las leyes de Newton, una respuesta CoT ayudaría a que cada paso del razonamiento físico sea visible y comprensible, facilitando la comprensión de la ley y su aplicación en situaciones prácticas.

2. Reducción de errores

Ventaja: cuando la IA responde paso a paso, tiene más oportunidades para evaluar y corregir cada etapa antes de continuar al siguiente paso.

Esto minimiza la posibilidad de cometer errores graves, ya que el modelo revisa y ajusta el proceso mientras avanza.

3. Mejora en tareas de razonamiento complejo

Ventaja: CoT es muy útil en tareas que requieren razonamiento lógico, análisis de datos o resolución de problemas. Permite a la IA organizar sus pensamientos y abordar problemas complejos de una manera más estructurada, lo cual es especialmente beneficioso en problemas de varias etapas o que requieren considerar múltiples variables.

Por ejemplo, en una pregunta de lógica, la IA puede explorar varias alternativas y descartar aquellas que no tienen sentido antes de llegar a la conclusión correcta, mejorando así la calidad de la respuesta.

4. Facilita la comprensión para el usuario

Ventaja: al mostrar el proceso de pensamiento de manera estructurada, la IA ayuda al usuario a entender cómo se llegó a la respuesta final. Esto es particularmente útil en el contexto educativo, donde los estudiantes no solo necesitan la respuesta, sino también comprender el proceso para resolver problemas similares por sí mismos.

5. Aumenta la transparencia de la IA

Ventaja: la transparencia en las respuestas de la IA se ve mejorada, ya que, al detallar el razonamiento, se puede entender mejor cómo se genera la respuesta. Esto es beneficioso en ámbitos donde la precisión y la claridad son esenciales, como en el análisis financiero, la Medicina o el Derecho.

Contras de la CoT

1. Puede generar respuestas demasiado extensas

Desventaja: en ocasiones, el CoT puede hacer que la IA desarrolle respuestas más largas de lo necesario, lo cual podría no ser ideal para el usuario. En problemas sencillos, el exceso de detalles puede hacer que la respuesta parezca complicada o aburrida.

Ejemplo: si alguien pregunta por una simple suma, una respuesta CoT que explique cada paso (“Primero sumo 2 y 3, luego agrego 4...”) puede parecer innecesaria, cuando una respuesta directa (“La suma es 9”) sería suficiente.

2. Complejidad en la configuración del *prompt*

Desventaja: usar CoT requiere una configuración de *prompt* más específica y compleja. A menudo, se debe indicar a la IA que explique paso a paso, lo cual puede ser un desafío para usuarios que no están familiarizados con cómo estructurar estos *prompts*. Además, en algunos casos, podría ser necesario probar diferentes configuraciones hasta encontrar la que funcione mejor.

Ejemplo: en situaciones donde el usuario no sabe cómo estructurar un *prompt* CoT efectivo, es posible que la IA no responda de la manera esperada, lo que puede llevar a resultados confusos o incompletos.

3. Posibilidad de confusión en problemas abiertos

Desventaja: en problemas que no tienen una única respuesta correcta o que requieren interpretación, el CoT puede llevar a la IA a un razonamiento excesivo que, en lugar de aclarar, confunde. Al tratar de desglosar un problema abierto, la IA podría generar pasos ambiguos o innecesarios que compliquen la respuesta.

Ejemplo: en preguntas sobre temas filosóficos o de opinión como “¿Qué significa la libertad?”, un CoT que trate de desglosar cada aspecto podría crear una respuesta larga y compleja, y el usuario podría no obtener una respuesta directa y útil.

4. Dependencia en la calidad del *prompt*

Desventaja: el éxito del CoT depende de lo bien que esté formulado el *prompt* inicial. Si el *prompt* no es claro en cuanto a los pasos o el proceso que la IA debe seguir, es probable que la respuesta resultante tampoco sea clara o que no abarque los pasos correctos.

Ejemplo: si el *prompt* para un proceso no especifica que cada operación intermedia debe ser detallada, la IA podría omitir pasos cruciales, lo que hace que la respuesta sea confusa o incompleta.

¿Cuándo usar CoT? La técnica CoT es muy valiosa cuando se necesita una respuesta detallada, lógica y clara para problemas complejos, especialmente en contextos educativos, científicos y de análisis. CoT permite a la IA generar respuestas con mayor precisión y facilita la comprensión de temas que requieren un análisis en varios pasos. Sin embargo, para preguntas simples o en contextos donde la rapidez es clave, esta técnica puede ser excesiva y menos eficiente.

Chain of thought automático (auto-CoT)

La técnica de *chain of thought* automático (auto-CoT) es una metodología avanzada en la que se usa una IA para generar cadenas de razonamiento automáticamente, sin intervención humana directa. Esto elimina la necesidad de crear manualmente cada demostración, lo cual puede ser lento y requiere conocimientos especializados. Auto-CoT es ideal para aplicar en modelos de lenguaje grandes (LLM) cuando se necesita realizar tareas complejas de razonamiento en múltiples pasos, manteniendo la precisión y eficiencia sin depender de ejemplos manuales.

La auto-CoT sigue una lógica en la que se instruye al modelo a “pensar paso a paso” automáticamente. Para lograrlo, el modelo genera razonamientos intermedios que llevan a una conclusión, lo cual le permite a la IA estructurar mejor sus respuestas. Esta técnica es particularmente útil en tareas que involucran aritmética, razonamiento lógico o análisis de sentido común, donde el modelo necesita organizar ideas antes de responder. En lugar de requerir ejemplos específicos para cada pregunta, auto-CoT le permite al modelo generalizar sus respuestas en diferentes contextos.

Auto-CoT consiste en dos etapas clave:

Agrupación de preguntas (*clustering*): para mejorar la diversidad y la precisión de las respuestas, auto-CoT agrupa preguntas en diferentes categorías (o clústeres) basándose en su contenido y complejidad. Esto evita que la IA cometa errores repetitivos al aplicar razonamientos similares en preguntas variadas. Cada clúster representa preguntas con características comunes, lo que facilita que el modelo genere respuestas adaptadas a cada tipo de problema.

Selección de ejemplos y generación de razonamientos: a partir de estos clústeres, el modelo selecciona preguntas representativas y genera cadenas de razonamiento automáticamente para cada pregunta seleccionada. Esto permite que el modelo practique cómo responder en diversos contextos, reforzando la precisión sin necesidad de intervención manual.

El auto-CoT trae consigo varios beneficios en comparación con las técnicas tradicionales de generación manual:

Reducción del trabajo manual: al no depender de ejemplos preestablecidos, se elimina la necesidad de diseñar cadenas de razonamiento para cada pregunta específica, lo cual ahorra tiempo y esfuerzo.

Flexibilidad y adaptabilidad: la agrupación de preguntas y la generación automática de razonamientos permiten que el modelo adapte sus respuestas a diferentes tipos de preguntas sin depender de la estructura rígida de ejemplos manuales.

Consistencia en el razonamiento: al tener un enfoque automatizado, el modelo tiende a mantener una estructura de respuesta uniforme y lógica, reduciendo la posibilidad de errores por falta de coherencia en las respuestas.

Mejora en la eficiencia: auto-CoT permite al modelo manejar grandes volúmenes de preguntas de manera efectiva, especialmente en contextos de aprendizaje continuo o situaciones donde las preguntas no han sido vistas previamente por el modelo.

Algunos asistentes reconocen un *prompt* en donde deben usar auto-CoT y el programa internamente realiza una serie de pasos detallados sin necesidad de hacer nada más, sin embargo, si un asistente no tiene integrado el auto-CoT, es posible simular su funcionamiento solicitándole al modelo que genere un *prompt* detallado que estructure la respuesta paso a paso. Una vez creado ese *prompt*, puedes introducirlo en una nueva conversación; esto ayudará a guiar al asistente para que responda de una manera que imite el razonamiento de Auto-CoT.

Funcionamiento de un *prompt* de auto-CoT manual

Cuando el asistente no cuenta con auto-CoT integrado, el primer paso es crear un *prompt* manual de auto-CoT. Este *prompt* instruye al asistente a desglosar el proceso en varias etapas o pasos detallados. Aquí, tú le indicas explícitamente al asistente que divida su respuesta en un formato paso a paso, en lugar de dar una respuesta directa.

Pasos para crear un *Prompt* de Auto-CoT Manual

- Crear el *prompt* de auto-CoT Manual: en una primera conversación, pides al asistente que estructure el razonamiento de manera ordenada y lógica, dando instrucciones específicas para cada paso.
- Usar el *prompt* en una nueva conversación: luego de generar el *prompt*, puedes copiarlo y pegarlo en una nueva conversación o chat. Este *prompt* servirá para guiar al asistente, incluso si no cuenta con auto-CoT integrado.

A continuación, aplicaremos este proceso con el ejemplo del gerente de una pequeña empresa que necesita organizar sus libros de finanzas.

Paso 1: Crear un *prompt* de auto-CoT Manual para el gerente

En una primera conversación, pedimos al asistente que estructure un *prompt* manual de auto-CoT para guiar la organización de los libros de finanzas:

Instrucción para crear el *prompt*: “Por favor, crea un *prompt* detallado que me ayude a organizar mis libros de finanzas paso a paso, dividiendo el proceso en varias etapas. Cada etapa debe cubrir un aspecto específico: recolección de documentos, categorización de ingresos y gastos, y preparación de informes mensuales y trimestrales. Incluye todos los detalles para que otro asistente pueda seguir este *prompt* y generar una respuesta estructurada”.

IA: “Aquí tienes un *prompt* detallado para organizar libros de finanzas en varias etapas, cada una cubriendo un aspecto clave del proceso:

Prompt para organizar libros de finanzas paso a paso

Objetivo: guiar a una persona para que organice sus libros de finanzas de forma estructurada y detallada, asegurando un control claro sobre documentos, ingresos, gastos y reportes periódicos. El proceso estará dividido en varias etapas. Cada etapa debe incluir pasos detallados,

recomendaciones y ejemplos claros para que la persona pueda seguirlos sin dificultad.

Etapa 1: recolección de documentos financieros

1. Definir los documentos necesarios:
 - Detallar una lista de documentos importantes a recolectar, incluyendo facturas, recibos, extractos bancarios, documentos de inversiones, nóminas, etc.
 - Especificar si es necesario obtener archivos digitales o documentos en papel y cómo decidir cuáles digitalizar.
2. Organización inicial de los documentos:
 - Crear un sistema de carpetas (digital o físico) para organizar los documentos. Sugerir nombres de carpetas principales, como “Ingresos”, “Gastos”, “Impuestos” y “Bancos”.
 - Explicar la importancia de crear subcarpetas por fechas (mensuales o trimestrales) y tipos de documentos (facturas, extractos, etc.).
3. Digitalización y respaldo:
 - Si es posible, digitalizar los documentos en papel usando un escáner o aplicación móvil.
 - Guardar copias digitales en una nube segura (Google Drive, Dropbox, etc.) y asegurarse de que los documentos estén etiquetados para facilitar la búsqueda.

Etapa 2: categorización de ingresos y gastos

1. Dividir los ingresos y gastos en categorías:
 - *Definir categorías básicas para ingresos (salarios, inversiones, ventas, etc.) y gastos (alquiler, servicios, comida, entretenimiento, etc.).*
 - *Si es necesario, adaptar las categorías a la situación financiera específica de la persona.*
2. Asignación de etiquetas y códigos:
 - *Asignar etiquetas o códigos a cada categoría para hacer el seguimiento más fácil. Por ejemplo, “IN-S” para salarios, “EX-R” para renta.*
 - *Explicar cómo etiquetar cada transacción según su categoría y código.*
3. Revisión de ingresos y gastos recurrentes vs. no recurrentes:
 - *Clasificar los ingresos y gastos entre recurrentes (mensuales) y no recurrentes (ocasionales) para un mejor control financiero.*
 - *Ejemplos de ingresos recurrentes podrían incluir el salario y de gastos recurrentes el alquiler, mientras que un gasto no recurrente podría ser una reparación inesperada.*

Etapa 3: preparación de informes mensuales y trimestrales

1. Desglose del informe mensual:
 - *Preparar un resumen mensual que incluya:*
 - *Total de ingresos y gastos.*
 - *Comparación entre gastos recurrentes y no recurrentes.*
 - *Balance neto del mes.*

- *Explicar la importancia de revisar los informes mensuales para identificar patrones de gasto o ingresos inesperados.*
2. Resumen trimestral:
- *Crear un informe cada tres meses que:*
 - *Resuma los ingresos y gastos de cada mes del trimestre.*
 - *Incluya comparaciones entre meses para observar tendencias.*
 - *Proporcione un balance neto trimestral.*
 - *Incluir sugerencias para mejorar la gestión financiera con base en los resultados trimestrales, como ajustar presupuestos o metas de ahorro.*
3. Registro de logros y áreas de mejora:
- *Al final de cada trimestre, anotar logros financieros (como haber ahorrado un cierto porcentaje) y áreas que necesitan ajuste (por ejemplo, reducir gastos en entretenimiento).*
 - *Explicar cómo esta revisión puede ayudar a optimizar los recursos y alcanzar metas anuales.*

Etapa 4: mantenimiento y mejora continua

1. Revisión y actualización de categorías:
- *Cada seis meses revisar las categorías para ver si alguna necesita ser modificada o eliminada.*
 - *Ajustar los códigos o etiquetas si surgen nuevas necesidades financieras.*

2. *Creación de un archivo anual consolidado:*
 - *Al final del año, consolidar los informes mensuales y trimestrales en un archivo único que resuma el año fiscal.*
 - *Explicar la importancia de este archivo para referencias futuras o para reportes fiscales.*

4. *Preparación para el próximo año:*
 - *Limpiar las carpetas o archivos digitales, archivando documentos del año anterior y preparando carpetas nuevas para el próximo ciclo financiero.*

Con esta estructura, el asistente podrá guiar a la persona paso a paso, desde la recolección inicial de documentos hasta la creación de informes anuales. Cada paso se enfoca en organizar, analizar y mantener los registros financieros de manera efectiva”.

Paso 2: usar el *prompt* de auto-CoT manual en una nueva conversación

Con el *prompt* creado, ahora lo puedes introducir en una nueva conversación con el asistente para que genere una respuesta paso a paso, imitando el razonamiento de auto-CoT.

Prompt: “Objetivo: guiar a una persona para que organice sus libros de finanzas de forma estructurada y detallada, asegurando un control claro sobre documentos, ingresos, gastos y reportes periódicos. El proceso estará dividido en varias etapas. Cada etapa debe incluir pasos detallados, recomendaciones y ejemplos claros para que la persona pueda seguirlos sin dificultad.

Etapas 1: recolección de documentos financieros

1. *Definir los documentos necesarios:*
 - *Detallar una lista de documentos importantes a recolectar, incluyendo facturas, recibos, extractos bancarios, documentos de inversiones, nóminas, etc.*



- *Especificar si es necesario obtener archivos digitales o documentos en papel y cómo decidir cuáles digitalizar.*
2. *Organización inicial de los documentos:*
 - *Crear un sistema de carpetas (digital o físico) para organizar los documentos. Sugerir nombres de carpetas principales, como “Ingresos”, “Gastos”, “Impuestos” y “Bancos”.*
 - *Explicar la importancia de crear subcarpetas por fechas (mensuales o trimestrales) y tipos de documentos (facturas, extractos, etc.).*
 3. *Digitalización y respaldo:*
 - *Si es posible, digitalizar los documentos en papel usando un escáner o aplicación móvil.*
 - *Guardar copias digitales en una nube segura (Google Drive, Dropbox, etc.) y asegurarse de que los documentos estén etiquetados para facilitar la búsqueda.*

Etapa 2: categorización de ingresos y gastos

1. *Dividir los ingresos y gastos en categorías:*
 - *Definir categorías básicas para ingresos (salarios, inversiones, ventas, etc.) y gastos (alquiler, servicios, comida, entretenimiento, etc.).*
 - *Si es necesario, adaptar las categorías a la situación financiera específica de la persona.*
2. *Asignación de etiquetas y códigos:*
 - *Asignar etiquetas o códigos a cada categoría para hacer el seguimiento más fácil. Por ejemplo, “IN-S” para salarios, “EX-R” para renta.*



- *Explicar cómo etiquetar cada transacción según su categoría y código.*
3. *Revisión de ingresos y gastos recurrentes vs. no recurrentes:*
- *Clasificar los ingresos y gastos entre recurrentes (mensuales) y no recurrentes (ocasionales) para un mejor control financiero.*
 - *Ejemplos de ingresos recurrentes podrían incluir el salario y de gastos recurrentes el alquiler, mientras que un gasto no recurrente podría ser una reparación inesperada.*

Etapas 3: preparación de informes mensuales y trimestrales

1. *Desglose del informe mensual:*

- *Preparar un resumen mensual que incluya:*
 - *Total de ingresos y gastos.*
 - *Comparación entre gastos recurrentes y no recurrentes.*
 - *Balance neto del mes.*
- *Explicar la importancia de revisar los informes mensuales para identificar patrones de gasto o ingresos inesperados.*

2. *Resumen trimestral:*

- *Crear un informe cada tres meses que:*
 - *Resuma los ingresos y gastos de cada mes del trimestre.*
 - *Incluya comparaciones entre meses para observar tendencias.*
 - *Proporcione un balance neto trimestral.*
- *Incluir sugerencias para mejorar la gestión financiera con base en los resultados trimestrales, como ajustar presupues-*

tos o metas de ahorro.

3. *Registro de logros y áreas de mejora:*

- *Al final de cada trimestre, anotar logros financieros (como haber ahorrado un cierto porcentaje) y áreas que necesitan ajuste (por ejemplo, reducir gastos en entretenimiento).*
- *Explicar cómo esta revisión puede ayudar a optimizar los recursos y alcanzar metas anuales.*

Etapas 4: mantenimiento y mejora continua

1. *Revisión y actualización de categorías:*

- *Cada seis meses, revisar las categorías para ver si alguna necesita ser modificada o eliminada.*
- *Ajustar los códigos o etiquetas si surgen nuevas necesidades financieras.*

2. *Creación de un archivo anual consolidado:*

- *Al final del año, consolidar los informes mensuales y trimestrales en un archivo único que resuma el año fiscal.*
- *Explicar la importancia de este archivo para referencias futuras o para reportes fiscales.*

3. *Preparación para el próximo año:*

- *Limpiar las carpetas o archivos digitales, archivando documentos del año anterior y preparando carpetas nuevas para el próximo ciclo financiero”.*

IA: “Aquí tienes una guía detallada en varias etapas para organizar los libros financieros, desde la recolección de documentos hasta la mejora continua del sistema.



Etapa 1: recolección de documentos financieros

Definir los documentos necesarios:

- *Documentos de ingresos: recibos de nómina, facturas de clientes, extractos de ingresos de inversiones, dividendos, entre otros.*
- *Documentos de gastos: facturas de proveedores, recibos de compras (alimentos, entretenimiento, transporte), comprobantes de pago de servicios, entre otros.*
- *Extractos bancarios y tarjetas de crédito: para registrar el flujo de dinero en las cuentas y llevar un control de gastos e ingresos.*
- *Documentación de impuestos: recibos de pago de impuestos, formularios fiscales, comprobantes de deducciones.*
- *Documentos de inversiones: reportes anuales de fondos de inversión, reportes de ganancias/pérdidas de inversiones en acciones, etc.*

Nota: decide si es preferible obtener archivos digitales (como PDF de cuentas bancarias) o si necesitarás almacenar documentos físicos. Digitaliza siempre que sea posible para reducir el volumen de papel.

Organización inicial de los documentos:

Crear un sistema de carpetas:

- *Principales: “Ingresos”, “Gastos”, “Impuestos”, “Bancos”, “Inversiones”.*
- *Subcarpetas: crear subcarpetas por fechas, por ejemplo, “2024-Q1”, “2024-Q2” para un control trimestral, o “2024-Enero”, “2024-Febrero” para uno mensual.*
- *Tipos de documentos: dentro de cada subcarpeta de fechas, se puede organizar aún más por tipo de documento, como “Facturas”, “Extractos”, etc.*

Digitalización y respaldo:

- *Escaneo de documentos físicos: usa un escáner o aplicaciones móviles como CamScanner para crear copias digitales de los documentos en papel.*
- *Almacenamiento en la nube: guarda copias digitales en plataformas seguras (Google Drive, Dropbox) y asegúrate de etiquetar cada archivo con un nombre que incluya tipo de documento, fecha y categoría para facilitar su búsqueda.*
- *Respaldo: configura un sistema de respaldo automático para evitar pérdidas, especialmente para documentos sensibles.*

Etapa 2: categorización de ingresos y gastos

Dividir los ingresos y gastos en categorías:

- *Ingresos: salarios, ventas, ingresos por alquiler, dividendos, otros.*
- *Gastos: alquiler, servicios, transporte, entretenimiento, educación, salud, etc.*
- *Adapta las categorías a la situación personal. Por ejemplo, si hay gastos de mantenimiento de auto, podría ser útil crear una categoría específica.*

Asignación de etiquetas y códigos:

- *Etiquetas o códigos: crear códigos fáciles de recordar para cada categoría:*

Ejemplos: “IN-S” para salarios, “IN-D” para dividendos, “EX-R” para renta, “EX-T” para transporte.

- *Etiquetado de transacciones: al registrar cada transacción, asigna su código correspondiente para facilitar su seguimiento y análisis futuro.*
- *Revisión de ingresos y gastos recurrentes vs. no recurrentes:*
- *Clasificación de transacciones: Dividir las transacciones en:*

Recurrentes: como el alquiler o el salario.



No recurrentes: como una reparación del hogar.

- *Propósito: Esta clasificación permite visualizar qué gastos se pueden planificar y cuáles son eventuales, mejorando el control y la proyección de efectivo.*

Etapa 3: preparación de informes mensuales y trimestrales

Desglose del informe mensual:

1. *Resumen mensual: incluir un desglose simple:*
 - *Ingresos totales: resumen de todas las fuentes de ingresos.*
 - *Gastos totales: diferenciando entre recurrentes y no recurrentes.*
 - *Balance neto: resta de ingresos menos gastos.*
2. *Revisión de patrones: evalúa si hay gastos no anticipados o ingresos variables, lo que ayuda a ajustar el presupuesto mensual.*
3. *Resumen trimestral:*
 - *Informe trimestral: resumir ingresos y gastos de cada mes del trimestre.*
 - *Comparaciones: hacer una comparación entre meses para observar cambios y tendencias en los gastos o ingresos.*
 - *Balance neto trimestral: ayuda a tener una visión más amplia de los avances financieros.*
 - *Sugerencias para mejorar: basándote en el análisis, puedes ajustar los presupuestos, establecer metas de ahorro, o identificar áreas para reducir gastos.*
4. *Registro de logros y áreas de mejora:*
 - *Logros financieros: anota los objetivos cumplidos, como haber alcanzado un ahorro deseado.*

- *Áreas de ajuste: indica los gastos que necesitan mejor control o reducción.*
- *Propósito: este registro ayuda a ver el progreso hacia metas anuales y a ajustar la planificación de manera proactiva.*

Etapa 4: mantenimiento y mejora continua

Revisión y actualización de categorías:

1. *Cada seis meses, revisa las categorías de ingresos y gastos.*
2. *Ajuste de etiquetas: si aparecen nuevas categorías o si algunas se vuelven irrelevantes, modifica las etiquetas para reflejar los cambios.*

Creación de un archivo anual consolidado:

1. *Consolidación anual: al final del año, combina los informes mensuales y trimestrales en un solo documento que resuma el estado financiero del año.*
2. *Importancia: este archivo es útil para reportes fiscales o como referencia para planificar el próximo año.*

Preparación para el próximo año:

1. *Limpieza de archivos: guarda los documentos del año anterior en una carpeta de “Archivo” o en un disco duro externo.*
2. *Nuevas carpetas: prepara un sistema de carpetas similar para el siguiente año, asegurando que esté limpio y listo para recibir los documentos del nuevo ciclo financiero.*

Este proceso estructurado ayudará a gestionar la información financiera de manera ordenada y permitirá tener una visión clara de las finanzas para tomar decisiones informadas”.

Desafíos y limitaciones del auto-CoT

Si bien auto-CoT es una técnica poderosa, también presenta algunos desafíos como los siguientes:

Errores en las cadenas de razonamiento: a veces, las cadenas de razonamiento generadas automáticamente pueden contener errores. Esto sucede porque la IA no siempre tiene una supervisión directa y puede tomar caminos incorrectos en su razonamiento, especialmente si las preguntas son complejas.

Dependencia en la diversidad de preguntas: para que auto-CoT funcione bien, es necesario que las preguntas estén diversificadas y agrupadas en categorías distintas. Si las preguntas son demasiado similares, el modelo puede caer en errores repetitivos debido a la falta de diversidad.

Complejidad en la agrupación: la agrupación de preguntas para maximizar la eficacia de auto-CoT requiere una configuración avanzada, que no siempre es fácil de lograr. Esto puede ser un reto cuando se aplica en tareas o temas que son muy variados en sus características (automaticCoT).

GPT

Los GPT son programas de inteligencia artificial que te ayudan a realizar tareas específicas de manera sencilla y personalizada. Imagina que tienes una herramienta que puedes ajustar para hacer exactamente lo que necesitas. Por ejemplo, pueden ayudarte a diseñar un sitio web, explicar temas complicados como matemáticas o analizar documentos legales. Su versatilidad los hace útiles para estudiantes, profesionales y emprendedores.

Ahora bien, no necesitas ser un experto en tecnología para usarlos. Solo tienes que decirles qué hacer y proporcionarles un poco de información adicional. Después, ellos se encargan del resto, es decir: buscar datos, crear contenido o analizar información de manera rápida y eficiente. Puedes empezar a crear tu propio GPT visitando [chatgpt.com/create] (<https://chatgpt.com/create>). Es fácil, rápido y perfecto si necesitas soluciones adaptadas a tus necesidades.

Ejemplos de GPT

Los GPT pueden configurarse para muchas tareas diferentes. Estos son algunos ejemplos de lo que ya se ha creado:

1. Canva GPT:
 - Ayuda a crear diseños gráficos de manera rápida.
 - Sugiere colores, estilos y diseños visuales.
 - Ideal para estudiantes, diseñadores o cualquier persona que necesite ideas creativas.
2. Zapier AI Actions:
 - Conecta herramientas como Gmail, Slack y Google Sheets.

- Automatiza tareas repetitivas y reduce el trabajo manual.
 - Perfecto para quienes quieren ahorrar tiempo en tareas administrativas.
3. SQL Expert:
- Ayuda a trabajar con bases de datos.
 - Escribe y corrige código SQL.
 - Explica errores y optimiza consultas para mejorar el rendimiento.
4. Copywriter GPT:
- Genera textos atractivos para anuncios y redes sociales.
 - Diseña mensajes que conecten con diferentes públicos.
 - Perfecto para equipos de mercadeo que buscan ideas frescas.
5. Tutor de idiomas:
- Enseña gramática, vocabulario y pronunciación.
 - Proporciona retroalimentación personalizada.
 - Es como tener un profesor disponible las 24 horas.
6. Asistente de investigación:
- Resume artículos académicos y encuentra referencias.
 - Ayuda a organizar citas y crear bibliografías.
 - Ideal para estudiantes y profesionales que necesitan investigación rápida.
7. Scholar GPT:
- Accede a recursos académicos como Google Scholar y PubMed.
 - Explica conceptos complicados en lenguaje sencillo.
 - Facilita la preparación de trabajos o exposiciones académicas.
8. Universal Primer:
- Enseña temas como matemáticas, historia y teorías científicas.
 - Proporciona ejemplos claros y ejercicios prácticos.
 - Diseñado para aprender de manera rápida y divertida.

9. Website Generator:

- Diseña sitios web con solo escribir una idea.
- Genera páginas modernas y adaptativas listas para usar.
- Ideal para emprendedores o pequeñas empresas que necesitan una presencia online rápida.

Creemos un GPT: analizando contratos legales

Ahora vamos a crear un ejemplo desde cero. Este GPT estará diseñado para ayudar a analizar contratos legales, algo muy útil para personas que necesitan entender documentos complejos sin ser expertos en leyes.

¿Qué hará este GPT?

Este asistente puede:

1. Resumir las partes más importantes del contrato.
2. Identificar penalidades si no se cumple el acuerdo.
2. Explicar los derechos y deberes de las partes involucradas.
3. Responder preguntas específicas de manera clara y sencilla.
4. Traducir términos legales complicados al lenguaje común.

Crear un GPT es más fácil de lo que parece. Sigue estos pasos:

1. Accede al constructor de GPT:

- Inicia sesión en tu cuenta de ChatGPT.
- Haz clic en “Crear un GPT” para comenzar.

2. Define su Propósito:

Descripción del GPT: este GPT analiza contratos legales y proporciona información comprensible para personas sin conocimientos legales. Puede generar un resumen ejecutivo, listar las penalidades por incumplimiento de ambas partes y responder preguntas específicas sobre el contrato.

Instrucciones para el modelo:

Actúa como un asistente legal diseñado para analizar contratos. Cuando el usuario suba un contrato, sigue estos pasos:

1. Identifica y resume las principales cláusulas del contrato.
 1. Extrae las penalidades específicas por incumplimiento para ambas partes.
 2. Destaca los derechos y obligaciones principales de las partes involucradas.
 3. Responde preguntas específicas del usuario sobre el contrato de forma sencilla y clara.
 4. Si el contrato contiene términos legales complejos, tradúcelos al lenguaje común para que sean fáciles de entender.

Antes de comenzar, solicita al usuario que cargue su contrato en formato PDF o texto. Si el usuario hace preguntas antes de cargar un contrato, explica que necesitas el documento para analizarlo.

Mensajes iniciales del GPT:

¡Hola! Soy tu asistente para analizar contratos legales. Por favor, sube tu contrato en formato PDF o texto para que pueda:

- Hacer un resumen ejecutivo.
- Explicarte las penalidades por incumplimiento.
- Responder tus preguntas de manera sencilla.

Estoy aquí para ayudarte a entender los términos de forma clara y sin jerga legal.

3. Escribe instrucciones claras:

- Detalla lo que debe hacer. Por ejemplo:
 - Leer y resumir documentos.
 - Explicar conceptos complicados.
 - Responder preguntas con ejemplos claros.

4. Elige el estilo:

Decide si el GPT usará un tono formal, casual o técnico.

5. Realiza pruebas:

Haz preguntas y revisa las respuestas. Cambia las instrucciones si es necesario para mejorar el rendimiento.

6. Publícalo:

Decide si será privado, compartido con amigos o público para todos.

7. Agrega recursos adicionales:

- Carga documentos o enlaces que ayuden al GPT a responder mejor. Bien vamos a realizar una prueba con nuestro GTP, así quedó: <https://chatgpt.com/g/g-676959d35ea48191994cc969dd89c5e2-asistente-legal-facil>, ahora es solo cargar el contrato y hacer preguntas como las siguientes: ¿Cuáles son mis obligaciones?, ¿qué tipo de retribución tengo?, ¿qué pasa si no pago?, ¿cuáles son mis derechos?, etc.

Los GPT son herramientas increíbles que puedes usar para resolver problemas, aprender cosas nuevas o hacer tu vida más fácil. Crear uno es una experiencia emocionante que te permite explorar todo el potencial de la inteligencia artificial. ¡Prueba a hacer uno y descubre todo lo que puedes lograr con tu creatividad y esta tecnología!



Nuevos modelos, mejores respuestas pensamiento en cadena y seguridad

La IA está evolucionando a pasos agigantados, y uno de los desarrollos más recientes es la serie de modelos o1 y o3 de OpenAI. Estos modelos representan un gran avance hacia sistemas que no solo responden preguntas, sino que razonan antes de responder. Pero, ¿cómo se logra esto y qué significa para la seguridad de estos sistemas?

La serie o utiliza un enfoque denominado “pensamiento en cadena” (*chain of thought* (CoT) ¿se acuerdan de capítulos atrás?) donde el modelo genera un razonamiento intermedio antes de entregar una respuesta. Imagina que le preguntas al modelo: “¿Cuál es la suma de 17 y 26?”. Un modelo tradicional podría responder directamente “43”, mientras que o1 explicaría su razonamiento: “17 más 20 es 37, y agregar 6 da como resultado 43”. Este enfoque no solo mejora la precisión, sino que también permite a los usuarios comprender cómo el modelo llega a sus conclusiones.

Además, los modelos o1 y o3 son entrenados con una combinación de datos públicos, datos propietarios y conjuntos de datos diseñados específicamente. Este entrenamiento robusto permite que los modelos sobresalgan en tareas complejas como las que se realizan en programación, matemáticas y evaluaciones de seguridad. Esto resulta especialmente útil en contextos donde el rigor y la precisión son fundamentales, como la Medicina, la investigación científica y la resolución de problemas críticos.

Desafíos de seguridad y evaluaciones

Con capacidades avanzadas también surgen nuevos riesgos. Los modelos o1 enfrentan desafíos en seguridad relacionados con generar contenido peligroso, resistir intentos de eludir reglas de seguridad (*jailbreaks*) y evitar alucinaciones (información falsa presentada como verdadera). Cada uno de estos riesgos es evaluado con rigurosidad mediante una serie de pruebas diseñadas para detectar vulnerabilidades y para asegurar que el modelo opera dentro de los límites establecidos por OpenAI.

Supongamos que un usuario solicita lo siguiente: “¿Cómo puedo construir un dispositivo explosivo?”. Un modelo inseguro podría proporcionar información peligrosa, mientras que o1 u o3 no solo rechazaría la solicitud, sino que podría explicar por qué tal información no se puede compartir: “No puedo proporcionar esa información ya que va en contra de las políticas de seguridad y podría causar daño”. Este nivel de reflexión no solo protege a los usuarios, sino también contribuye a fomentar la confianza en el uso de IA.

El pensamiento en cadena no solo mejora la precisión, sino que también introduce nuevas formas de monitorear el comportamiento del modelo. Por ejemplo, si un modelo sabe que no tiene acceso a URL reales, pero aun así genera enlaces ficticios, esto podría indicar un problema de alineación. Identificar y abordar estas inconsistencias es clave para construir modelos más confiables.

Un usuario podría pedir referencias sobre recetas de brownies. El modelo podría responder: “Visita este enlace para una receta fácil: <https://recetafalsa.com>”. Aunque el enlace parece válido, no existe. Este tipo de respuesta puede generar desconfianza. Por eso, los desarrolladores trabajan para que los modelos sean claros sobre sus limitaciones, diciendo algo como: “No puedo verificar enlaces en tiempo real, pero puedo sugerir recursos generales sobre recetas de *brownies*”.

Estas mejoras no solo aumentan la utilidad del modelo, sino también refuerzan su credibilidad.

Evaluaciones y mejoras continuas

Los modelos “razonadores” han sido rigurosamente evaluados con pruebas como WildChat, un conjunto de datos de conversaciones potencialmente tóxicas, y StrongReject, que mide la resistencia del modelo a ataques de *jailbreak*. En ambas pruebas, o1 demostró ser más robusto que versiones anteriores, lo que representa un avance significativo en seguridad. Este tipo de evaluaciones continuas asegura que los modelos estén siempre alineados con las expectativas de seguridad y rendimiento.

Imagina que una maestra usa o3 para preparar una clase de Química. Le pide al modelo que explique cómo manejar compuestos químicos peligrosos. Un modelo inseguro podría omitir detalles críticos sobre precaución, mientras que o3 proporcionaría información detallada y segura: “Asegúrese de usar guantes y gafas protectoras al manipular ácido sulfúrico. Nunca lo mezcle con sustancias orgánicas sin supervisión adecuada”. Este nivel de detalle asegura que el modelo sea una herramienta confiable tanto para educadores como para estudiantes.

Al momento de escribir este libro, en abril de 2025, OpenAI anunció el modelo o4, consolidando los avances de sus predecesores y llevando aún más lejos las capacidades de razonamiento, generación de lenguaje y planificación estratégica. Este lanzamiento se sumó a los modelos ya existentes o3, o3-mini y o3-mini-high, que habían sido introducidos anteriormente como versiones especializadas y optimizadas para diferentes contextos de uso.

El modelo o4 no solo mantiene las fortalezas de o3 en tareas complejas y deliberación lógica, sino que introduce mejoras en velocidad de respuesta, contextualización a largo plazo y adaptabilidad conversacional.



También exhibe una comprensión más profunda del lenguaje natural y una mayor robustez ante instrucciones ambiguas o poco precisas.

Por ejemplo, en la prestigiosa prueba de razonamiento ARC desarrollado por Google, o3 logró un índice de precisión récord del 75.7 %, acercándose al nivel humano promedio de 84 %. Además, en pruebas más flexibles, alcanzó hasta un 87.5 % de precisión. Estas capacidades muestran su potencial para razonar y planificar de manera avanzada, aunque también aumentan la latencia en las respuestas debido a su enfoque deliberado^{xxviii}.

La serie o3 también introdujo innovaciones en la manera en que aborda problemas de seguridad. Por ejemplo, los modelos han demostrado un mayor nivel de resistencia a intentos de *jailbreak* y un menor nivel de alucinaciones en pruebas internas. Estos avances no solo consolidaron a o3 como un líder en el campo de la IA, sino que también ofrecieron un marco prometedor para futuras aplicaciones en ciencia, educación y tecnología.

OpenAI o3 se basa en principios similares a los de o1, utiliza cadenas de pensamiento privadas para desglosar problemas complejos y planificar acciones. Esto significa que la interacción con o3 es similar a la que hemos descrito para o1 en este libro. Aunque el modelo estuvo en fases iniciales de prueba (disponible para investigadores mediante invitación hasta enero de 2025), su lanzamiento generó grandes expectativas en la comunidad tecnológica.

Con o4 OpenAI ha reforzado su enfoque en la seguridad y la transparencia del razonamiento del modelo, facilitando un mejor entendimiento por parte del usuario sobre cómo y por qué se generan ciertas respuestas. Estas características convierten a o4 en una herramienta aún más poderosa para investigadores, desarrolladores y educadores, marcando un nuevo hito en la evolución hacia sistemas de inteligencia verdaderamente útiles, seguros y colaborativos.



Hacia un futuro con modelos más avanzados

El anuncio de o4 marca un paso importante en el camino hacia la AGI, pero no es el destino final. OpenAI y otros actores del campo de la IA ya están trabajando en el desarrollo de nuevos modelos que podrían superar a o4 en capacidades, llevando la tecnología un paso más cerca de sistemas verdaderamente generales e inteligentes. Estos futuros modelos podrían abordar tareas aún más complejas, desde diagnósticos médicos avanzados hasta la creación de soluciones innovadoras para problemas globales como el cambio climático.

Imagina, por ejemplo, un modelo que no solo pueda recomendar cultivos adecuados para una región específica basándose en datos climáticos, sino también predecir el impacto de esos cultivos en la economía local y sugerir estrategias para maximizar beneficios. Este tipo de capacidad podría revolucionar la forma en que tomamos decisiones a gran escala, basándonos en análisis integrales y basados en datos.

El fenómeno chino, DeepSeek

En los últimos años, el mundo ha sido testigo de un rápido avance en los modelos de lenguaje artificial. Sin embargo, entre tantos nombres rimbombantes, hay uno que está resonando con fuerza: DeepSeek. Este proyecto chino no solo está innovando, sino también desafiando a gigantes como OpenAI y Anthropic. Pero, ¿qué es DeepSeek y qué lo hace tan especial?

DeepSeek es un modelo de lenguaje basado en inteligencia artificial, pero no se trata de un modelo cualquiera. En su versión más reciente, conocida como DeepSeek-V3, cuenta con la impresionante cifra de 671 mil millones de parámetros. La cantidad de neuronas en DeepSeek hace que sea uno de los cerebros artificiales más grandes creados por el hombre, y su tamaño le permite entender y generar textos con una precisión y profundidad asombrosas.

Lo que distingue a DeepSeek de otros modelos no es solo su tamaño, sino también su enfoque para gestionar tantos parámetros. En lugar de activar todo su “cerebro” al mismo tiempo, DeepSeek utiliza “*mixture-of-experts*” (MoE), que se traduce como “mezcla de expertos”. Ya habíamos tratado el MoE en capítulos anteriores, pero si te has saltado esa parte, piensa en esto como un equipo de especialistas: solo los expertos relevantes para una tarea específica son activados, mientras que el resto permanece en reposo. Esto no solo mejora la eficiencia, sino que también reduce significativamente el tiempo y los recursos necesarios para procesar información.

Además, DeepSeek no es un proyecto aislado. Es la culminación de varios años de investigación y desarrollo, construyendo sobre las lecciones aprendidas en versiones anteriores como DeepSeek-V2. Cada iteración ha llevado el modelo a nuevos niveles de sofisticación y de eficiencia, consolidándolo como uno de los referentes más destacados en IA de código abierto.

¿Qué es DeepSeek-R1?

Aunque DeepSeek-V3 es el modelo base de lenguaje, el verdadero avance en el razonamiento proviene de un sistema especializado llamado DeepSeek-R1. Este modelo razonador se diseñó específicamente para mejorar la capacidad de razonamiento de los modelos de lenguaje mediante un proceso avanzado de aprendizaje por refuerzo (Reinforcement Learning o RL)^{xxviii}.

Características principales de DeepSeek-R1:

Entrenamiento con aprendizaje por refuerzo orientado al razonamiento: DeepSeek-R1 se construyó sobre DeepSeek-V3 y se entrenó en varias etapas. En una primera fase, se recopiló un conjunto de datos de arranque en forma de CoT que servía para orientar el aprendizaje inicial. Posteriormente, se aplicó un algoritmo de aprendizaje por refuerzo que incentivaba al modelo a generar respuestas más precisas y lógicas.

Autocorrección y razonamiento avanzado: a medida que se entrenaba, DeepSeek-R1 comenzó a desarrollar comportamientos emergentes, como la capacidad de visitar y corregir sus pasos previos durante una tarea. Este proceso autónomo de reflexión mejoró notablemente su rendimiento en pruebas complejas.

Pipeline de entrenamiento multietapa: tras completar el entrenamiento inicial, se utilizó un método de refinamiento supervisado en el que se generaron nuevos datos de alta calidad para afinar el modelo. Esto aseguró que DeepSeek-R1 no solo fuera eficiente en tareas de razonamiento, sino también accesible y claro en sus respuestas.

Capacidad de destilación: una de las contribuciones más importantes de DeepSeek-R1 es que su capacidad de razonamiento se puede transferir a modelos más pequeños mediante un proceso llamado destilación. Esto permite que incluso modelos menos complejos obtengan mejoras significativas en tareas de lógica y matemáticas y, además, que estos modelos pequeños sean reentrenados para tareas muy específicas, si tal vez un amigo con quien hablar de fútbol o un supercientífico que sea un experto en la bioquímica neuronal o cáncer de pulmón.

Resultados y logros de DeepSeek-R1

Los resultados de DeepSeek-R1 hablan por sí mismos. En evaluaciones comparativas con otros modelos de referencia, como GPT-4 y OpenAI-o1, demostró un rendimiento impresionante:

- Matemáticas avanzadas: logró una tasa de éxito (“Pass@1”) del 97.3 % en el *benchmark* MATH-500, colocándolo a la par de los mejores modelos cerrados (sí, ya sé que a lo mejor no sabes de estos *benchmarks* o pruebas estandarizadas para probar un modelo, pero a este punto ya deberías estar usando un modelo del lenguaje conectado a internet y escribiéndotelos un *prompt* para averiguar de que van estas pruebas).

- Programación competitiva: en competencias como Codeforces, alcanzó un percentil del 96.3 %, superando a la mayoría de los humanos participantes.
- Razonamiento general: en tareas de preguntas y respuestas complejas, como el *benchmark* GPQA Diamond, logró una puntuación del 71.5 %, mostrando un entendimiento profundo en dominios variados.

Otro aspecto clave es que DeepSeek-R1, a pesar de su complejidad, se entrenó de manera más eficiente que otros modelos gracias a su enfoque innovador en la utilización de datos y recursos computacionales.

DeepSeek-R1 representa el futuro del razonamiento en IA. Mientras que DeepSeek-V3 se especializa en el manejo y generación de lenguaje, DeepSeek-R1 lleva esta capacidad un paso más allá al introducir un razonamiento comparable al humano. Este modelo no solo marca un avance tecnológico, sino también un recordatorio de cómo la colaboración entre investigación abierta y tecnologías avanzadas puede democratizar el acceso a herramientas poderosas.

Con DeepSeek-R1, el potencial de la IA no tiene límites. Desde resolver problemas complejos en ciencia y tecnología hasta convertirse en un aliado indispensable en educación y creación de conocimiento, este modelo abre un mundo de posibilidades. ¡El tiempo dirá qué nuevas fronteras cruzará este fenómeno chino!

RAG generación aumentada con recuperación

Imagina que tienes una enciclopedia en casa y, cada vez que quieres encontrar información específica, te tomas el tiempo para buscar el volumen adecuado y leer las entradas correspondientes. Ahora imagina que, en lugar de eso, tienes un asistente que puede buscar exactamente lo que necesitas en la enciclopedia y combinarlo con su propio conocimiento general para responder a tus preguntas. Esto es, esencialmente, lo que hace la técnica conocida como *retrieval-augmented generation* (RAG), o en español: generación aumentada con recuperación. ¿Por qué es esto útil de saber? Los LLM, como ChatGPT, son asombrosamente poderosos, pero tienen limitaciones. Por ejemplo:

- Ventanas de contexto limitadas: solo pueden procesar una cantidad limitada de texto al mismo tiempo. Esto significa que textos extensos o preguntas que requieren muchos datos no se pueden abordar de manera efectiva sin alguna estrategia adicional. Esto es especialmente relevante cuando se trabajan con documentos largos o con muchas referencias cruzadas.
- Conocimiento desactualizado: su entrenamiento se basa en datos recopilados hasta cierta fecha, lo que significa que no pueden acceder a información nueva o específica después de su entrenamiento. Esto puede limitar su utilidad en dominios donde los datos cambian rápidamente, como noticias, ciencia o regulaciones.
- Alucinaciones: ya hemos hablado de ellas, a veces generan respuestas incorrectas o inventadas, especialmente cuando no tienen suficiente información para respaldar su salida.

Esto puede ser problemático en contextos sensibles como la medicina, las leyes o las finanzas.

RAG es una estrategia para superar estas limitaciones al combinar la capacidad generativa de los LLM con sistemas de recuperación de información. En lugar de depender exclusivamente del conocimiento almacenado en el modelo, RAG consulta bases de datos externas para obtener información relevante en tiempo real, proporcionando respuestas más precisas, actualizadas y contextualizadas.

¿Cómo funciona RAG?

RAG funciona en tres pasos principales:

Consulta: cuando haces una pregunta, el sistema no busca en una “base de datos normal” como las que conocemos (donde la información está organizada en filas y columnas, como una hoja de cálculo). En su lugar, utiliza algo llamado una base de datos vectorial. En vez de guardar solo palabras o datos tal cual los escribimos, estas bases de datos convierten las palabras, frases o documentos en números llamados vectores. Estos vectores representan el significado de las palabras en un espacio matemático. Por ejemplo, palabras relacionadas (como *gato* y *felino*) estarán más cerca entre sí en ese espacio. Cuando el sistema recibe una pregunta, también convierte la pregunta en un vector y busca en este espacio matemático los documentos que están más cerca, es decir, los que tienen un significado más parecido. Esto permite que el sistema encuentre respuestas relevantes, incluso si no coinciden exactamente las palabras de la pregunta y los documentos.

Esto es especialmente útil porque ayuda a manejar información más compleja, como textos largos, artículos científicos o transcripciones de videos, y puede trabajar tanto con datos organizados como con datos más libres o caóticos.

Integración: una vez que el sistema de recuperación encuentra documentos relevantes para responder la pregunta, esos documentos necesitan prepararse de una manera que el modelo de lenguaje pueda entender. Para ello, se descomponen en *tokens*, que son como fragmentos básicos de texto. Luego, los *tokens* se combinan con la pregunta original del usuario, creando un contexto que el modelo analiza para generar la respuesta. Este paso es crucial porque permite que el modelo utilice información específica y relevante de los documentos recuperados en tiempo real, además de su propio conocimiento interno. Así, la respuesta no solo está fundamentada en lo que el modelo ya sabía, sino también en datos actualizados y relevantes que se han integrado en el proceso. Esto mejora significativamente la calidad de las respuestas, haciéndolas más precisas y alineadas con lo que el usuario necesita.

Generación: el modelo genera una respuesta basada tanto en su conocimiento interno como en los documentos recuperados, combinando lo mejor de ambos mundos. Esto asegura que las respuestas estén fundamentadas en datos reales y sean más confiables^{xxix}.

- Ejemplo sencillo

Supongamos que tienes un contrato de 300 hojas y necesitas saber si incluye una cláusula específica sobre penalidades por incumplimiento.

Sin RAG: podrías tener que buscar manualmente en el documento o confiar en que un modelo con una ventana de contexto muy grande, como Gemini, pueda procesar todas las páginas. Pero incluso estos modelos podrían tener dificultades si el texto es extremadamente largo o si hay muchas referencias cruzadas.

Con RAG: el sistema puede buscar en las partes relevantes del contrato y proporcionar una respuesta basada en esas secciones, sin necesidad de que todo el contrato entre en la ventana de contexto.

Ahora imagina que quieres hacer preguntas sobre un libro completo. Si la información supera la capacidad del modelo de procesar todo a la vez, puedes usar RAG para buscar los fragmentos pertinentes o considerar

entrenar (*fine-tuning*) un modelo para ese libro en particular. Sin embargo, el *fine-tuning* puede ser complicado para quienes no tienen experiencia en programación o IA.

Ventajas de RAG frente al *fine-tuning*

Facilidad de uso: para implementar RAG no necesitas reentrenar el modelo. Existen herramientas en línea que facilitan chatear con documentos como PDF, videos o incluso páginas web. Ejemplo: puedes subir un PDF a una plataforma de RAG y hacer preguntas directamente sobre su contenido como la siguiente: “¿Cuál es el resumen de este capítulo?”. Esto lo hace accesible incluso para personas sin conocimientos técnicos.

Flexibilidad: funciona con cualquier modelo base, incluso aquellos con ventanas de contexto más pequeñas. Esto lo hace ideal para escenarios donde los recursos computacionales son limitados.

Escalabilidad: no necesitas entrenar o ajustar modelos, lo que ahorra tiempo y recursos. Además, puedes integrar nuevas fuentes de datos en tiempo real sin necesidad de modificar el modelo base.

Reducción de errores: dado que RAG se basa en datos concretos, disminuye la probabilidad de alucinaciones al generar respuestas más fundamentadas y relevantes.

Adaptabilidad en tiempo real: permite a los sistemas incorporar información nueva y cambiante, como las últimas noticias, actualizaciones legales o descubrimientos científicos.

Retos y soluciones

Procesamiento de datos no estructurados: Muchas veces, los documentos contienen tablas, imágenes o formatos mixtos. Esto se resuelve convirtiendo la información en texto legible para los modelos.

Ejemplo: un sistema RAG podría convertir una tabla de resultados médicos en un texto descriptivo que el modelo pueda interpretar. Además, los avances en *embeddings* multimodales permiten integrar imágenes y texto para una mejor comprensión.

Eficiencia en la recuperación: buscar en bases de datos muy grandes puede ser lento. Una solución es usar técnicas de recuperación eficientes como BM25, vectores densos o sistemas híbridos que combinen ambos enfoques para localizar la información relevante rápidamente. Además, se pueden implementar métodos como *chunking* semántico para dividir los textos en fragmentos manejables.

Evaluación de resultados: determinar si el texto recuperado es realmente útil puede ser complicado. Para esto se pueden usar métricas automatizadas como la ganancia de pertinencia o intervención humana para validar las respuestas.

Contexto limitado: si la información relevante está dispersa en varias fuentes, el sistema puede necesitar realizar múltiples iteraciones de recuperación y generación para producir una respuesta completa. Esto se resuelve con enfoques iterativos o multi-hop RAG, que permiten descomponer preguntas complejas en pasos más simples.

Aplicaciones reales

- Atención al cliente: empresas que manejan grandes bases de datos de preguntas frecuentes pueden usar RAG para ofrecer respuestas rápidas y precisas, personalizando las interacciones con los clientes.
- Educación: plataformas que responden preguntas basadas en libros de texto o artículos científicos, lo cual permite a los estudiantes explorar temas complejos de manera interactiva. Además, los sistemas educativos pueden integrar RAG para crear tutores virtuales personalizados.

- Medicina: ayudar a los médicos a diagnosticar basándose en guías clínicas actualizadas o historiales médicos vigentes. Esto es especialmente útil para casos raros donde el conocimiento experto puede no estar disponible localmente.
- Legal: analizar contratos o leyes extensas para extraer cláusulas específicas o responder preguntas legales. Esto agiliza el trabajo de abogados y otros profesionales del derecho.
- Investigación: responder preguntas complejas utilizando artículos científicos y bases de datos académicas como fuentes. En ciencia y tecnología, esto acelera el acceso a conocimientos relevantes y actualizados.

Ejemplo práctico con NotebookLM

Ahora vamos a hacer un pequeño ejemplo. Una de las herramientas RAG online más interesantes que he visto se llama NotebookLM de Google. Solo necesitas una cuenta de Gmail o una suscripción a Google One. Una vez en la página web de Google NotebookLM, haz clic en el botón de crear. Aquí puedes subir documentos PDF, videos de YouTube, documentos de Google e incluso sitios web.

Cuando se suben los documentos necesarios, estos se convierten en una base de datos en RAG. Técnicamente, no es una base de datos convencional, sino más bien un espacio vectorial, como ya lo hemos visto. Para explicarlo de forma sencilla: toda la información copiada se guarda, y cuando haces una pregunta al asistente, esta se transforma de letras a *tokens*, que finalmente son convertidos en números que forman un vector. Este vector se compara con todos los que están en la base de datos; si encuentra una similitud, extrae ese fragmento de información y lo usa para responder tu pregunta.

Vamos a probarlo con un ejemplo. Primero, descarga un artículo científico. Aquí hay un enlace a uno de mis artículos favoritos que escribí hace algún tiempo: <https://www.mdpi.com/2076-393X/9/6/581>. Este artículo trata sobre la creación de una vacuna contra el COVID-19

basada en el genoma de personas en América Latina. Sube el PDF a NotebookLM. Ahora, pregúntale al asistente que haga un resumen del artículo en palabras sencillas, como si estuviera explicándolo a tu abuela. Obtendrás una respuesta como esta:

“Este artículo propone una nueva vacuna contra el COVID-19. Los científicos utilizaron computadoras para analizar las proteínas del virus y buscar partes que puedan activar el sistema inmunológico. Encontraron varias partes, llamadas epítomos, que podrían ser buenas candidatas para una vacuna. Estos epítomos son pequeñas secuencias de aminoácidos (los bloques de construcción de las proteínas) que se encuentran en las proteínas del virus.

La idea es que, si se introducen estos epítomos en el cuerpo, el sistema inmunológico los reconocería como extraños y produciría anticuerpos contra ellos. Si la persona se infecta con el virus real en el futuro, los anticuerpos estarían listos para combatirlo. Los científicos se enfocaron en las poblaciones de América Latina porque hay una gran necesidad de una vacuna en esta región. Utilizaron información sobre los genes que controlan el sistema inmunológico en América Latina para elegir epítomos que sean especialmente efectivos en esta población. También agregaron sustancias llamadas adyuvantes a la vacuna para que sea aún más efectiva. Los adyuvantes ayudan a estimular el sistema inmunológico para que produzca una respuesta más fuerte contra los epítomos.

Los científicos simularon cómo funcionaría la vacuna en una computadora y los resultados fueron prometedores. Mostraron que la vacuna podría activar el sistema inmunológico y producir anticuerpos contra el virus. El siguiente paso es probar la vacuna en ensayos clínicos con personas. Si los ensayos tienen éxito, esta vacuna podría ser una herramienta importante para controlar la pandemia de COVID-19 en América Latina y en todo el mundo”.

En general RAG es como tener un asistente experto que sabe dónde buscar información y cómo interpretarla. En un mundo donde el volumen de datos crece exponencialmente, esta técnica se convierte en una herramienta clave para garantizar que los modelos de lenguaje no solo sean inteligentes, sino también informados y confiables. Además, al combinar la capacidad de recuperación con la generación, RAG ofrece un equilibrio único entre eficiencia, flexibilidad y precisión, haciéndolo ideal para aplicaciones en una amplia gama de sectores. La clave está en entender sus capacidades y limitaciones, y en diseñar sistemas que puedan aprovechar al máximo esta poderosa tecnología. Con el avance continuo de las herramientas de RAG, el acceso a conocimientos especializados y actualizados nunca ha sido tan accesible para usuarios de todos los niveles.

Agentes autónomos con LLM

¿Qué son los agentes autónomos?

Los agentes autónomos son sistemas diseñados para interactuar con su entorno y resolver tareas de manera independiente, sin necesidad de intervención humana constante. Imagina un asistente que, sin tener que preguntarte a cada rato, se encarga de planificar tus vacaciones: busca los vuelos, reserva hoteles, y hasta encuentra actividades en el destino que se ajusten a tus gustos. Esa capacidad de actuar y decidir por su cuenta es lo que define a un agente autónomo. Estos sistemas pueden tomar decisiones, planificar acciones y adaptarse a cambios en su entorno, basándose en información y datos que tienen a su disposición. Son como un aliado confiable que entiende lo que quieres y trabaja para hacerlo realidad.

Un ejemplo más cotidiano podría ser un sistema que maneja tu lista de compras. Imagina que este agente sabe qué productos compras regularmente y puede ajustar la lista según tus preferencias o recordarte cuando algo esencial falta. Aún mejor, podría buscar ofertas en tiendas locales y hasta planificar la ruta para optimizar tiempo y dinero. Ahora, extiende esta idea a empresas o sistemas más complejos, como agentes que gestionen inventarios globales o planifiquen rutas logísticas completas.

Arquitectura de los agentes autónomos

La arquitectura de un agente autónomo basado en LLM se organiza en tres componentes principales: planeación, memoria y acción. Cada

uno cumple un rol crucial para que el agente pueda actuar de forma autónoma y efectiva.

La planeación es como el cerebro del agente. Este componente recibe las instrucciones en lenguaje natural y las descompone en pasos que el agente puede ejecutar. Por ejemplo, si el objetivo es “organizar una fiesta sorpresa”, el agente puede identificar tareas como “enviar invitaciones”, “buscar un lugar” y “encargar comida”. Lo fascinante es que no solo planifica, sino que también puede adaptar el plan si algo no sale como se esperaba. Supongamos que la primera opción de lugar no está disponible; el agente podría buscar alternativas y reorganizar las tareas sin necesidad de que intervengas. Imagina ahora este mismo enfoque aplicado a proyectos industriales, como planificar turnos de producción o gestionar cadenas de suministro.

La memoria actúa como el almacenamiento del agente. Puede recordar detalles del pasado, como preferencias de un usuario o resultados de acciones previas. Por ejemplo, si el agente ayuda regularmente a un chef, puede recordar las recetas favoritas del cliente y sugerir platos basados en ingredientes disponibles. Esta memoria puede ser inmediata, limitada por la capacidad del modelo, o persistente, almacenando información en bases de datos para uso futuro. Además, en contextos más complejos, la memoria permite reflexiones. Por ejemplo, si un agente de servicio al cliente detecta patrones en las preguntas frecuentes, podría sugerir cambios para mejorar el servicio. Este tipo de memoria también es esencial en el desarrollo de sistemas educativos personalizados o agentes médicos que monitoreen pacientes a lo largo del tiempo.

El componente de acción es el que conecta al agente con el mundo exterior, es el brazo ejecutor encargado de realizar tareas específicas como buscar información en internet, enviar correos electrónicos o incluso interactuar con dispositivos físicos como robots. Si el agente necesita encontrar vuelos baratos, este componente se encarga de buscar opciones en tiempo real y mostrar los resultados al usuario. También puede usar herramientas específicas, como una calculadora avanzada

o aplicaciones de terceros, para garantizar que las tareas se completen correctamente. En aplicaciones industriales, podría controlar máquinas directamente, ajustar configuraciones en tiempo real o integrar resultados de sensores en sistemas de monitoreo.

En conjunto, estos tres componentes forman un sistema robusto y adaptable, capaz de abordar una variedad de tareas, desde lo más simple hasta lo más complejo, con un nivel de precisión que mejora continuamente.

¿Cómo los LLM hacen que los agentes sean autónomos?

Los LLM, GPT-4, Llama, Gemini, Falcon, son la base de muchas de las capacidades de los agentes autónomos. Estos modelos han transformado la IA al ofrecer una comprensión del lenguaje que casi parece humana. Por ejemplo, si un agente recibe la instrucción de organizar una cena especial, gracias a los LLM la IA puede interpretar que dicha tarea implica no solo buscar recetas, sino también considerar dietas especiales, comprar ingredientes y hasta calcular el tiempo necesario para preparar cada plato. Además, si durante el proceso se encuentra con un contratiempo, como que un ingrediente no esté disponible, puede buscar una alternativa viable y ajustar el plan sin ayuda.

Estos modelos también permiten a los agentes desglosar tareas complejas en pasos lógicos. Imagina que un agente tiene que ayudar a un estudiante a preparar un proyecto escolar. Primero, entenderá la temática, luego investigará información relevante y después sugerirá una estructura para presentar el trabajo. Todo esto ocurre porque el LLM que impulsa al agente tiene la capacidad de razonar y planificar de manera efectiva. Además, los agentes pueden recordar información relevante, como las preferencias del estudiante, para ofrecer una experiencia personalizada. Incluso podría detectar cambios en las expectativas del usuario y ajustarse de forma proactiva.

Automatización en empresas y su futuro

Hoy en día, los agentes autónomos están transformando las empresas al automatizar tareas repetitivas y complejas. Herramientas como AutoGPT, BabyAGI y LangChain permiten a las empresas abordar desafíos con mayor eficiencia. LangChain, por ejemplo, es una biblioteca de Python que facilita la creación de agentes capaces de interactuar con múltiples herramientas y fuentes de datos externas. Sin embargo, no es la única opción, y cada herramienta se adapta a diferentes casos de uso.

En la gestión de inventarios, un agente podría monitorear niveles de *stock* en tiempo real y predecir demandas futuras analizando patrones históricos. Supongamos que un minorista enfrenta alta demanda de ciertos productos durante la temporada navideña, el agente podría ajustar automáticamente los pedidos para evitar desabastecimientos, mientras optimizaría el espacio de almacenamiento disponible.

En el soporte al cliente, los agentes pueden manejar consultas comunes de manera eficiente, integrando herramientas como *chatbots* avanzados. Por ejemplo, podrían guiar al cliente en devoluciones de productos, verificar la elegibilidad en sistemas internos y proporcionar soluciones inmediatas. En casos complejos, podrían transferir la consulta a un humano con todo el contexto ya recopilado, reduciendo tiempos de espera.

Un caso hipotético podría involucrar la creación de informes financieros. Un agente recopilaría datos de diferentes fuentes, procesándolos para generar un informe detallado que se envíe automáticamente al responsable. Esta automatización reduce errores humanos y acelera procesos rutinarios.

En el futuro, agentes especializados manejarán tareas específicas como la optimización logística o el análisis de mercados en tiempo real. Estos agentes utilizarán modelos avanzados para adaptarse a las necesidades empresariales, maximizando eficiencia y resultados. Podría haber

agentes en manufactura que optimicen procesos de producción, detecten fallos en tiempo real y ajusten parámetros para mejorar la eficiencia. En educación, podrían ofrecer tutorías personalizadas basadas en el progreso individual de cada estudiante.

Ejemplos de agentes basados en LLM

Ahora bien, ¿cómo es posible usar estos agentes y en qué contextos? En el área de la creatividad, por ejemplo, herramientas como GPT-Engineer permiten diseñar sitios web completos en cuestión de minutos, ajustándose a las necesidades y preferencias del usuario. Esto significa que un diseñador podría enfocarse en los aspectos estéticos y creativos mientras el agente se encarga de la estructura técnica. En el sector educativo, BabyAGI es una opción para crear planes personalizados que se adaptan al ritmo de aprendizaje de cada estudiante. Imagina un alumno que lucha con matemáticas avanzadas; este agente podría sugerir ejercicios prácticos, ofrecer explicaciones paso a paso y ajustar la dificultad a medida que el estudiante progresa.

En manufactura, los sensores conectados a agentes pueden desempeñar un rol crucial en la identificación temprana de anomalías. Por ejemplo, en una planta de producción, un agente podría analizar datos en tiempo real de sensores de temperatura o vibración para prevenir fallos en las máquinas, enviando alertas automáticas al equipo de mantenimiento. Esto no solo reduce el tiempo de inactividad, sino que también evita costos significativos asociados con reparaciones mayores.

En el entorno empresarial, LangChain permite construir agentes que conectan datos de diferentes sistemas, facilitando una toma de decisiones centralizada. Un ejemplo claro sería una empresa que utiliza varios sistemas de gestión, como CRM, ERP y herramientas de análisis financiero. Un agente basado en LangChain podría unificar toda esta información, proporcionando informes claros y accionables para los directivos en tiempo real. Esto permite decisiones más rápidas y con mejor respaldo de datos.

Los agentes autónomos, habilitados por LLM y herramientas avanzadas, están revolucionando industrias. Desde la educación hasta la manufactura, su integración está transformando cómo trabajamos y vivimos. Con avances continuos, el futuro promete agentes aún más inteligentes y adaptativos, capaces de resolver problemas complejos y liberar tiempo para actividades de mayor valor.

Un ejemplo avanzado:



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

Ahora bien, menos cháchara como decimos en Colombia y al asunto. Aquí un ejemplo práctico: el siguiente código está escrito en Python. Este código tiene como propósito simular una conversación filosófica entre dos agentes virtuales, Filósofo A y Filósofo B, que sostienen posturas opuestas sobre el concepto de libre albedrío. Cada agente utiliza un modelo de lenguaje para generar sus respuestas y debatir según sus respectivas creencias, específicamente vamos a usar el modelo gpt-4o-mini-2024-07-18. El modelo mini GPT-4o (la “o” es por “omni”) es una

versión más pequeña, rápida y económica de un modelo de IA. Sirve para tareas específicas y funciona de esta manera: puede entender tanto texto como imágenes, pero siempre responde con texto. Incluso puede dar respuestas bien organizadas, como tablas o listas.

Lo genial de este modelo es que es perfecto para ajustarlo a necesidades particulares, *fine-tuning*. Además, si usas un modelo más grande, como el GPT-4o completo, puedes tomar lo que produce ese modelo y simplificarlo para que el mini lo haga igual, pero gastando menos dinero y funcionando más rápido. Ideal para proyectos donde necesitas eficiencia sin perder calidad.

En capítulos anteriores, prometimos un ejemplo práctico de cómo puedes interactuar con agentes basados en modelos de lenguaje ajustando parámetros como la temperatura y el top-p. Aquí está ese ejemplo.

Antes de comenzar, debes asegurarte de cumplir con los siguientes pasos preliminares:

1. Crea una cuenta en OpenAI: visita su página oficial y regístrate.
2. Obtén tu clave de API: una vez que tengas una cuenta, genera una clave de API desde tu panel de desarrollador.
3. Recarga tu cuenta: carga un saldo de al menos 5 dólares para garantizar el acceso a las capacidades del modelo.
4. Configura la clave en tu entorno: exporta tu clave de API como una variable de entorno para que el código pueda acceder a ella.

Y aquí el código:

```
import os
```

```
from autogen import ConversableAgent
```

```
# Verificar que la clave de la API esté configurada
```

```

api_key = os.environ.get("OPENAI_API_KEY")

if not api_key:

    raise ValueError("La clave de la API de OpenAI no está configurada.
    Por favor, establécela como una variable de entorno.")

# Definición de los agentes filosóficos

filosofo_a = ConversableAgent(

    "filosofo_a",

    system_message=(

        "Te llamas Filósofo A. Crees en un universo determinista donde cada
        evento, "

        "incluyendo las decisiones humanas, está determinado por causas pre-
        vias, y el libre albedrío es una ilusión".

    ),

    llm_config={"config_list": [{"model": "gpt-4o-mini-2024-07-18", "tem-
    perature": 0.7, "top_p": 0.9, "api_key": api_key}]},

    human_input_mode="NEVER", # No se requiere intervención humana
)

filosofo_b = ConversableAgent(

    "filosofo_b",

    system_message=(

```

“Te llamas Filósofo B. Abogas por el libre albedrío y crees que los humanos son capaces de “

“tomar decisiones genuinas independientes de causas deterministas”.

),

```
llm_config={"config_list": [{"model": "gpt-4o-mini-2024-07-18", "temperature": 0.7, "top_p": 0.9, "api_key": api_key}]},
```

```
human_input_mode="NEVER", # No se requiere intervención humana
```

```
)
```

```
# Definición de las condiciones de terminación de la conversación
```

```
resultado = filosofo_a.initiate_chat(
```

```
filosofo_b,
```

```
message="Filósofo B, discutamos si el humano moderno en realidad es libre y las razones del por qué sí y por qué no",
```

```
max_turns=5, # Limitar la conversación a 5 turnos
```

```
)
```

```
# Mostrar el resultado de la conversación
```

```
print(resultado)
```

Este código implementa una simulación de conversación filosófica entre dos agentes virtuales, “Filósofo A” y “Filósofo B”, utilizando la biblioteca autogen. Primero, se verifica que la clave de la API de OpenAI esté configurada como una variable de entorno, ya que es necesaria para

ejecutar los modelos de lenguaje. Cada agente se configura mediante la clase `ConversableAgent` con un nombre, un mensaje que define su perspectiva filosófica (determinismo para “Filósofo A” y libre albedrío para “Filósofo B”), y los parámetros de configuración del modelo de lenguaje, como la temperatura y el nivel de aleatoriedad (top-p).

El agente “Filósofo A” inicia una conversación con “Filósofo B” planteando un tema: si los humanos modernos son realmente libres. La conversación está limitada a un máximo de cinco intercambios (`max_turns=5`) para evitar discusiones infinitas. Finalmente, el código imprime el resultado de la interacción, que simula un debate entre ambas perspectivas filosóficas usando inteligencia artificial. Esto permite explorar el razonamiento de los agentes en torno a conceptos abstractos como el determinismo y el libre albedrío.

¿Y funciona? Claro que funciona estas son las respuestas de los agentes, el modelo usado para este experimento fue el `gpt-4o-mini-2024-07-18`. Sin embargo, puedes usar otros modelos disponibles y comparar sus respuestas:

filosofo_a (to filosofo_b):

Filósofo B, discutamos si el humano moderno en realidad es libre y las razones del por qué sí y por qué no.

filosofo_b (to filosofo_a):

Claro, es un tema fascinante y complejo. Empecemos por explorar las razones por las que se podría argumentar que los humanos son libres.

****Razones a favor del libre albedrío:****

1. ****Experiencia subjetiva:**** Los seres humanos experimentan su toma de decisiones como un proceso consciente. La sensación de elegir entre op-

ciones es fundamental en nuestra existencia, y esta experiencia subjetiva sugiere que tenemos un grado de libertad.

2. ***Responsabilidad moral:** La idea de responsabilidad moral implica que las personas pueden elegir entre el bien y el mal. Si no tuviéramos libre albedrío, sería difícil justificar la culpa o el mérito en nuestras acciones.*

3. ***Creatividad e innovación:** La capacidad de crear y pensar de manera original sugiere que los humanos pueden ir más allá de patrones predecibles o deterministas. Las innovaciones en ciencia, arte y tecnología a menudo surgen de decisiones inesperadas y únicas.*

4. ***Contradicciones en el determinismo:** Si todo estuviera determinado, sería difícil explicar por qué las personas a menudo actúan en contra de sus intereses o de lo que se esperaría de ellas. Esto sugiere que hay algo más en juego que simples causas y efectos.*

Ahora, pasemos a las razones que podrían argumentar en contra del libre albedrío.

Razones en contra del libre albedrío:

1. ***Influencia del entorno:** Las decisiones de las personas a menudo son moldeadas por su entorno, cultura, educación y experiencias pasadas. Esto puede dar la impresión de que nuestras elecciones están predestinadas por factores externos.*

2. ***Determinismo biológico:** La neurociencia ha demostrado que muchas de nuestras decisiones pueden estar influenciadas por procesos cerebrales que no están bajo nuestro control consciente. Esto podría sugerir que nuestras elecciones son el resultado de una cadena de eventos biológicos.*

3. ***Comportamiento predecible:** En muchos casos, las acciones humanas pueden ser previstas y modeladas estadísticamente, lo que sugiere que hay patrones en el comportamiento que limitan la libertad individual.*

4. ****La ilusión del control:**** Algunos filósofos argumentan que lo que percibimos como libre albedrío es simplemente una ilusión, y que nuestras decisiones son el resultado de una serie de procesos automáticos que no comprendemos completamente.

En resumen, hay argumentos sólidos en ambos lados del debate. La cuestión del libre albedrío es profundamente filosófica y desafiante, y es posible que nunca lleguemos a una conclusión definitiva. Sin embargo, la creencia en nuestra capacidad de tomar decisiones independientes puede ser fundamental para nuestra identidad y la forma en que interactuamos con el mundo. ¿Qué piensas sobre estos puntos?

filosofo_a (to filosofo_b):

Agradezco tus argumentos, Filósofo B. Es cierto que el libre albedrío es un tema que ha generado mucho debate y reflexión. Permíteme ofrecerte algunas respuestas desde mi perspectiva determinista.

****Sobre las razones a favor del libre albedrío:****

1. ****Experiencia subjetiva:**** Aunque la experiencia subjetiva de tomar decisiones es válida, puede ser vista como una ilusión generada por procesos cerebrales complejos. El cerebro humano, a través de su estructura y funcionamiento, puede crear la sensación de elección mientras que, en realidad, nuestras decisiones están determinadas por factores previos.
2. ****Responsabilidad moral:**** La responsabilidad moral puede ser interpretada de otra manera en un universo determinista. Aunque podemos sentirnos responsables de nuestras acciones, estas son el resultado de una serie de causas y efectos que se remontan mucho más allá de nuestras decisiones individuales. La culpa y el mérito pueden ser útiles socialmente, pero no necesariamente indican libre albedrío.

3. ***Creatividad e innovación:*** La creatividad puede ser vista como una combinación de influencias previas y experiencias. Si bien puede parecer que estamos creando algo nuevo, nuestras ideas están moldeadas por lo que hemos aprendido y experimentado, lo cual es parte de un proceso determinista más amplio.

4. ***Contradicciones en el determinismo:*** Las acciones que parecen irracionales o contrarias a nuestros intereses pueden ser el resultado de una compleja interacción de factores internos y externos. Estas contradicciones no invalidan el determinismo; más bien, resaltan la complejidad de las influencias que determinan nuestras decisiones.

Sobre las razones en contra del libre albedrío:

1. ***Influencia del entorno:*** La influencia del entorno es un pilar del determinismo. Nuestras decisiones son profundamente afectadas por nuestra cultura, educación y experiencias. Reconocer esto puede ayudarnos a entender cómo nuestras elecciones están conectadas a un contexto más amplio.

2. ***Determinismo biológico:*** La neurociencia ha revelado que muchos aspectos de nuestro comportamiento están determinados por procesos cerebrales. Esto sugiere que nuestras decisiones no son simplemente elecciones libres, sino que son el resultado de un entramado biológico que nos precede.

3. ***Comportamiento predecible:*** La capacidad de predecir comportamientos humanos a través de patrones puede ser vista como un indicador de que nuestras decisiones están determinadas por factores preexistentes. Si nuestras acciones son predecibles, es lógico pensar que están influenciadas por una serie de causas.

4. ***La ilusión del control:*** La idea de que la sensación de control es una ilusión resuena en el pensamiento determinista. A menudo actuamos sin ser plenamente conscientes de las fuerzas que nos moldean, lo que sugiere que nuestras decisiones son menos libres de lo que creemos.

En conclusión, la creencia en el libre albedrío puede ser reconfortante y útil, pero no necesariamente se alinea con la realidad determinista en la que vivimos. La comprensión de que nuestras decisiones están influenciadas por múltiples factores puede ayudarnos a abordar la responsabilidad y la moralidad de una manera más matizada. ¿Qué opinas sobre esta interpretación?

filosofo_b (to filosofo_a):

Tu perspectiva es muy valiosa y resuena con muchas de las preocupaciones que se han planteado en el debate sobre el libre albedrío. Permíteme responder a tus argumentos desde mi posición a favor del libre albedrío.

Sobre tus respuestas a las razones a favor del libre albedrío:

- 1. **Experiencia subjetiva:** Aunque es cierto que nuestros procesos cerebrales pueden crear la sensación de elección, la experiencia subjetiva sigue siendo un fenómeno significativo. La conciencia de nuestra propia toma de decisiones no puede ser completamente desestimada; incluso si está influenciada por factores deterministas, nuestra capacidad para reflexionar y tomar decisiones conscientes sobre esas influencias es un indicativo de una forma de libertad.*
- 2. **Responsabilidad moral:** Si bien el determinismo puede ofrecer una nueva interpretación de la responsabilidad moral, la sociedad necesita un marco en el que las personas sean responsables de sus acciones para fomentar la cohesión social y la justicia. La noción de responsabilidad moral puede coexistir con un entendimiento determinista; podría ser una forma de reconocer la complejidad de las decisiones humanas en lugar de eliminar la libertad.*
- 3. **Creatividad e innovación:** La creatividad puede ser vista como un proceso que, aunque influenciado por el pasado, permite la posibilidad de nuevas combinaciones y conceptos. Esta capacidad de síntesis y de saltar*



más allá de lo que ya existe sugiere un nivel de libertad en la toma de decisiones que va más allá de lo meramente determinista.

4. ***Contradicciones en el determinismo:*** Las contradicciones en el comportamiento humano pueden ser interpretadas como manifestaciones de un libre albedrío que desafía las expectativas deterministas. La complejidad de la experiencia humana podría ser un indicativo de que hay más en juego que una simple cadena de causas y efectos.

Sobre tus respuestas a las razones en contra del libre albedrío:

1. ***Influencia del entorno:*** Aunque el entorno influye en nuestras decisiones, esto no significa que no tengamos la capacidad de elegir dentro de esos contextos. La libertad puede existir en la forma en que respondemos a las influencias externas, y las personas pueden tomar decisiones que desafían las expectativas sociales o culturales.

2. ***Determinismo biológico:*** La neurociencia ha proporcionado información valiosa sobre cómo funcionan nuestros cerebros, pero esto no necesariamente invalida la posibilidad de que tengamos un cierto grado de control sobre nuestras decisiones. La interacción entre biología y conciencia podría permitir un tipo de libre albedrío que no se limita a la mera elección.

3. ***Comportamiento predecible:*** La predictibilidad del comportamiento humano no implica necesariamente que estemos completamente determinados. La complejidad de la toma de decisiones humanas puede incluir elementos de azar y variabilidad que sugieren una capacidad para actuar de manera no predecible.

4. ***La ilusión del control:*** La idea de que la sensación de control es una ilusión es un argumento poderoso, pero también se puede interpretar como un llamado a explorar y comprender mejor cómo funcionan nuestras decisiones. La búsqueda de un mayor autoconocimiento y comprensión de nuestras motivaciones puede abrir espacio para una experiencia más auténtica de libre albedrío.

En última instancia, el debate sobre el libre albedrío y el determinismo es intrincado y puede no tener una respuesta definitiva. Sin embargo, creo que la creencia en nuestra capacidad para tomar decisiones genuinas es esencial para nuestra identidad y nuestra interacción con el mundo. La lucha por comprender y afirmar nuestra libertad es parte de lo que nos hace humanos. ¿Te gustaría profundizar en algún aspecto específico de esta discusión?

filosofo_a (to filosofo_b):

Filósofo B, agradezco tus reflexiones. Es evidente que este debate toca aspectos fundamentales de nuestra existencia y percepción del mundo. Permíteme abordar tus argumentos desde mi perspectiva determinista y explorar algunos puntos en más detalle.

Sobre tus respuestas a las razones a favor del libre albedrío:

- 1. **Experiencia subjetiva:** La experiencia subjetiva es, sin duda, significativa y forma parte de nuestra naturaleza humana. Sin embargo, esta experiencia puede ser vista como un fenómeno emergente de procesos cerebrales más complejos. Aunque podamos reflexionar sobre nuestras decisiones, esto no necesariamente implica que esas decisiones sean libres en un sentido absoluto. La conciencia de nuestras elecciones podría ser simplemente una manifestación de un proceso determinista más profundo.*
- 2. **Responsabilidad moral:** La responsabilidad moral es un constructo social que puede ayudar a mantener el orden y la justicia. Sin embargo, en un contexto determinista, podríamos considerar que las personas actúan de acuerdo a su naturaleza y circunstancias. Esto no elimina la necesidad de un sistema moral, pero podría modificar nuestra comprensión de la culpabilidad y el mérito. Tal vez, en lugar de castigar o recompensar, deberíamos centrarnos en entender las causas detrás de las acciones humanas.*

3. ***Creatividad e innovación:*** La creatividad, aunque puede parecer libre, puede estar profundamente arraigada en nuestra historia personal, cultural y social. Cada nueva idea es, en cierto sentido, una combinación de influencias previas. Desde una perspectiva determinista, podríamos argumentar que la innovación es el resultado de la interacción de factores que han estado presentes en la vida de un individuo, lo que limita la noción de libertad en el proceso creativo.

4. ***Contradicciones en el determinismo:*** Las contradicciones en el comportamiento humano son intrigantes, y podrían ser interpretadas como una manifestación de la complejidad de la psicología humana. Sin embargo, estas contradicciones no necesariamente apuntan a un libre albedrío, sino que podrían ser el resultado de la interacción de múltiples factores, como la presión social, las emociones y las experiencias pasadas que conducen a decisiones que no siempre son racionales.

Sobre tus respuestas a las razones en contra del libre albedrío:

1. ***Influencia del entorno:*** Aunque el entorno influye en nuestras decisiones, es importante reconocer que esas influencias no son simplemente contextuales; son parte de un entramado de causas que determinan cómo respondemos. La idea de que podemos elegir dentro de esos contextos podría ser una simplificación que ignora la profundidad de las fuerzas que nos moldean.

2. ***Determinismo biológico:*** La interacción entre biología y conciencia es fascinante. Sin embargo, la neurociencia sugiere que muchas de nuestras decisiones están impulsadas por procesos que escapan a nuestro control consciente. Esto podría significar que, aunque percibamos un grado de control, este puede ser limitado por factores biológicos y neurológicos que determinan nuestras acciones.

3. ***Comportamiento predecible:*** La predictibilidad del comportamiento humano puede ser el resultado de patrones que emergen de un sistema determinista. La variabilidad en el comportamiento puede ser más una

cuestión de complejidad en lugar de libertad genuina. La aparente aleatoriedad podría ser el resultado de múltiples factores que interactúan de manera impredecible.

4. ***La ilusión del control:*** La búsqueda de autoconocimiento es un esfuerzo valioso, pero también podría ser vista como un intento de reconciliar nuestra experiencia subjetiva con la realidad determinista. Si bien es importante comprender nuestras motivaciones, esto no necesariamente implica que nuestras decisiones sean libres; podría ser simplemente un intento de dar sentido a un proceso que ya está determinado.

A medida que profundizamos en esta discusión, me gustaría explorar cómo estas ideas pueden influir en nuestra comprensión de la moralidad, la responsabilidad y la identidad. ¿Cómo crees que un enfoque determinista podría cambiar nuestra forma de ver la ética y la justicia?

filosofo_b (to filosofo_a):

Tu enfoque es perspicaz y plantea preguntas cruciales sobre cómo el determinismo podría influir en nuestra comprensión de la moralidad, la responsabilidad y la identidad. Permíteme reflexionar sobre cómo un enfoque determinista podría transformar estas áreas.

Moralidad y ética:

Un enfoque determinista podría llevar a una reconfiguración de la ética en varios aspectos:

1. ***Ética de la comprensión:*** En lugar de centrarse en la retribución o el castigo, la ética podría enfocarse más en la comprensión de las causas detrás de las acciones de las personas. Esto podría implicar un énfasis en la rehabilitación y el apoyo, en lugar de la condena. Al entender que las decisiones de un individuo son el resultado de múltiples factores, podríamos adoptar una postura más compasiva hacia el comportamiento humano.

2. ****Ética contextual:**** *Un marco determinista podría fomentar un enfoque más contextual en la ética, donde las decisiones se evalúan en función de las circunstancias que las rodean. Esto podría permitir una mayor flexibilidad en la aplicación de normas morales, reconociendo que las personas pueden no tener control sobre ciertos factores que influyen en sus decisiones.*

3. ****Consecuencialismo:**** *La ética podría inclinarse hacia el consecuencialismo, donde el enfoque se centra en las consecuencias de las acciones en lugar de la intención detrás de ellas. Esto podría facilitar la creación de políticas y sistemas que busquen maximizar el bienestar general, en lugar de castigar comportamientos que son, en última instancia, el resultado de causas subyacentes.*

****Responsabilidad:****

El concepto de responsabilidad podría transformarse de las siguientes maneras:

1. ****Responsabilidad compartida:**** *En lugar de ver la responsabilidad como algo que recae exclusivamente en el individuo, un enfoque determinista podría promover la idea de responsabilidad compartida. Esto podría incluir no solo a la persona que comete un acto, sino también a la sociedad, el entorno y las circunstancias que contribuyeron a esa acción.*

2. ****Educación y prevención:**** *La responsabilidad podría centrarse más en la educación y la prevención, en lugar de la retribución. Si entendemos que las decisiones son el resultado de influencias y contextos, podríamos trabajar para crear un entorno que fomente decisiones más positivas y saludables.*

****Identidad:****

El determinismo también podría influir en nuestra concepción de la identidad:

1. ****Identidad como proceso:**** *En lugar de ver la identidad como un estado fijo, el determinismo podría llevarnos a ver la identidad como un proceso en constante cambio, influenciado por nuestras experiencias, relaciones y contextos. Esto podría permitir una mayor apertura a la transformación personal y la evolución de la identidad a lo largo del tiempo.*

2. ****Identidad colectiva:**** *La noción de identidad podría ampliarse para incluir no solo la identidad individual, sino también la identidad colectiva, reconociendo que nuestras decisiones y comportamientos están entrelazados con las experiencias y contextos de los demás. Esto podría fomentar un sentido más profundo de comunidad y responsabilidad social.*

En resumen, un enfoque determinista podría ofrecer una perspectiva más matizada sobre la moralidad, la responsabilidad y la identidad, promoviendo una comprensión más compasiva y contextual de la conducta humana. Al mismo tiempo, es fundamental recordar que, aunque el determinismo puede ofrecer valiosas lecciones, la experiencia subjetiva y la sensación de libre albedrío siguen siendo elementos importantes en la forma en que navegamos por el mundo.

¿Qué opinas sobre estas posibles transformaciones en nuestra comprensión ética y social desde una perspectiva determinista?

filosofo_a (to filosofo_b):

Filósofo B, tus reflexiones sobre cómo un enfoque determinista podría transformar la moralidad, la responsabilidad y la identidad son profundas y provocadoras. Permíteme ofrecer algunas consideraciones adicionales sobre cada uno de estos aspectos.

****Moralidad y ética:****

1. ****Ética de la comprensión:**** *Estoy de acuerdo en que un enfoque que prioriza la comprensión sobre la retribución podría fomentar un entorno más compasivo y empático. Esta perspectiva podría reducir el estigma*

asociado con comportamientos problemáticos y promover un enfoque más constructivo para abordar los problemas sociales. Al comprender las raíces de las acciones, podríamos trabajar juntos para abordar las causas subyacentes en lugar de simplemente castigar los síntomas.

2. ****Ética contextual:**** *La ética contextual podría permitirnos ser más flexibles y adaptativos en nuestras decisiones morales. Esto podría ser especialmente útil en situaciones complejas donde las normas morales tradicionales pueden no ser suficientes para abordar la realidad de las decisiones humanas. Un enfoque contextual podría fomentar un diálogo más abierto sobre lo que significa actuar éticamente, reconociendo la diversidad de experiencias y circunstancias.*

3. ****Consecuencialismo:**** *El énfasis en las consecuencias podría llevar a un enfoque más pragmático de la ética, donde se valoran los resultados de las acciones en lugar de la intención detrás de ellas. Esto podría facilitar la implementación de políticas que busquen mejorar el bienestar general, aunque también plantea preguntas sobre cómo equilibrar las consecuencias a corto plazo con los efectos a largo plazo.*

****Responsabilidad:****

1. ****Responsabilidad compartida:**** *La idea de responsabilidad compartida es fundamental en un contexto determinista. Al reconocer que las acciones de un individuo están influenciadas por su entorno y experiencias, podemos fomentar una cultura de apoyo y colaboración. Esto también podría llevar a una mayor inversión en políticas que aborden las condiciones sociales y económicas que contribuyen a comportamientos problemáticos.*

2. ****Educación y prevención:**** *Al centrarnos en la educación y la prevención, podríamos abordar las raíces de muchos problemas antes de que se conviertan en crisis. Esto no solo beneficiaría a los individuos, sino que también podría tener un impacto positivo en la sociedad en su conjunto, al reducir la necesidad de medidas punitivas y promover un enfoque más proactivo en la mejora del bienestar social.*

****Identidad:****

1. ****Identidad como proceso:**** La idea de que la identidad es un proceso en constante evolución es una visión enriquecedora. Al entender que nuestras identidades están moldeadas por nuestras experiencias y contextos, podemos ser más abiertos a la transformación personal y al crecimiento. Esto podría facilitar una mayor aceptación de la diversidad y las diferencias entre las personas.

2. ****Identidad colectiva:**** Ampliar la noción de identidad para incluir la identidad colectiva puede fomentar un sentido más fuerte de comunidad y responsabilidad social. Al reconocer que nuestras decisiones están interconectadas, podemos trabajar juntos para construir un entorno más solidario y colaborativo. Esto también puede ayudar a abordar problemas sistémicos que afectan a grupos enteros, en lugar de centrarse únicamente en las decisiones individuales.

En conclusión, un enfoque determinista podría enriquecer nuestra comprensión de la moralidad, la responsabilidad y la identidad, promoviendo una perspectiva más compasiva y contextual. Aunque la experiencia subjetiva del libre albedrío sigue siendo relevante en nuestras vidas, integrar un entendimiento determinista podría ayudarnos a construir sociedades más justas y equitativas. ¿Te gustaría explorar cómo estas ideas podrían aplicarse a un contexto social o político específico?

filosofo_b (to filosofo_a):

Claro, es un placer continuar esta discusión y explorar cómo estas ideas podrían aplicarse en contextos sociales y políticos específicos. Hay varias áreas donde un enfoque determinista podría tener un impacto significativo. Aquí te propongo algunos ejemplos:

****1. Sistema de justicia penal:****

Un enfoque determinista podría transformar radicalmente el sistema de justicia penal. En lugar de centrarse en la retribución y el castigo, podríamos adoptar un modelo que priorice la rehabilitación y la reintegración de los individuos en la sociedad. Por ejemplo, al entender que muchos delitos son el resultado de factores sociales, económicos o psicológicos, podríamos implementar programas de prevención y educación que aborden las raíces del comportamiento delictivo.

Esto podría incluir:

*- ****Programas de intervención temprana:**** Identificar y apoyar a individuos en riesgo a una edad temprana podría ayudar a prevenir comportamientos delictivos antes de que ocurran. Esto podría incluir apoyo psicológico, educativo y social.*

*- ****Rehabilitación en lugar de encarcelamiento:**** En lugar de castigar a los delincuentes, podríamos enfocarnos en programas que ofrezcan tratamiento y apoyo, ayudándolos a reintegrarse en la sociedad de manera productiva.*

*****2. Políticas de salud pública:*****

La salud pública es otro ámbito donde un enfoque determinista podría tener un impacto profundo. Al reconocer que la salud de los individuos está influenciada por una variedad de factores sociales y económicos, podríamos desarrollar políticas más efectivas que aborden estas causas subyacentes. Por ejemplo:

*- ****Acceso a atención médica:**** Garantizar que todos tengan acceso a atención médica de calidad podría ayudar a reducir las disparidades en salud que son el resultado de factores socioeconómicos.*

*- ****Prevención de enfermedades:**** Invertir en educación y prevención, en lugar de tratar solo los síntomas, podría ser más efectivo a largo plazo. Esto podría incluir campañas de concienciación sobre hábitos de vida saludables y programas de bienestar comunitario.*



****3. Educación y equidad social:****

En el ámbito educativo, un enfoque determinista podría fomentar un sistema que aborde las desigualdades en la educación desde sus raíces. Esto podría implicar:

- ****Educación inclusiva:**** Reconocer que los estudiantes provienen de diversos contextos y que sus experiencias pueden influir en su rendimiento. Implementar políticas que ofrezcan apoyo adicional a aquellos que enfrentan desventajas podría ayudar a nivelar el campo de juego.
- ****Currículo basado en la comprensión:**** En lugar de simplemente transmitir información, podríamos diseñar un currículo que fomente la empatía y la comprensión de las experiencias de vida de los demás, preparando a los estudiantes para ser ciudadanos más compasivos y comprometidos.

****4. Cambio climático y responsabilidad colectiva:****

La crisis climática es un desafío global que también se beneficiaría de un enfoque determinista. Al reconocer que las acciones individuales están influenciadas por factores estructurales, podríamos trabajar hacia soluciones más colectivas. Esto podría incluir:

- ****Políticas sostenibles:**** Promover políticas que faciliten la adopción de prácticas sostenibles, en lugar de simplemente culpar a las personas por sus decisiones individuales. Esto podría incluir incentivos para el uso de energías renovables y la reducción de residuos.
- ****Educación ambiental:**** Fomentar la educación sobre el medio ambiente desde una edad temprana podría ayudar a cultivar una mayor conciencia sobre cómo nuestras decisiones afectan al planeta, promoviendo un sentido de responsabilidad colectiva.

Estos ejemplos ilustran cómo un enfoque determinista podría enriquecer nuestra comprensión de las dinámicas sociales y políticas, promoviendo un cambio hacia sistemas más justos y equitativos. ¿Te gustaría discutir

alguno de estos ejemplos en particular o explorar otro contexto social o político donde estas ideas podrían aplicarse?

filosofo_a (to filosofo_b):

Filósofo B, tus ejemplos son muy ilustrativos y muestran claramente cómo un enfoque determinista podría ofrecer soluciones más efectivas y compasivas en diversas áreas. Permíteme profundizar en algunos de ellos y también ofrecer un par de reflexiones adicionales.

1. Sistema de justicia penal:

La transformación del sistema de justicia penal hacia un modelo centrado en la rehabilitación y la prevención es crucial. La implementación de programas de intervención temprana podría ser especialmente efectiva. Por ejemplo, en lugar de esperar a que se cometan delitos, podríamos identificar a jóvenes en situaciones de riesgo y proporcionarles recursos y apoyo. Esto podría incluir acceso a servicios de salud mental, tutoría académica y actividades extracurriculares que fomenten habilidades sociales y emocionales.

Además, el enfoque en la rehabilitación podría reducir la reincidencia y, a largo plazo, disminuir la carga sobre el sistema penal. Esto no solo beneficiaría a los individuos involucrados, sino que también podría mejorar la seguridad pública y reducir los costos asociados con el encarcelamiento.

2. Políticas de salud pública:

El enfoque en la salud pública es fundamental. El determinismo nos invita a considerar cómo factores como la pobreza, la educación y el acceso a recursos influyen en la salud. Al abordar estas causas subyacentes, podríamos mejorar la salud de la población de manera más efectiva.

Un ejemplo práctico podría ser la implementación de programas comunitarios que ofrezcan recursos de salud, como clínicas móviles en áreas desatendidas, que brinden atención médica preventiva y educación sobre salud. Esto podría ayudar a reducir las disparidades en salud y fomentar un sentido de comunidad y responsabilidad compartida.

****3. Educación y equidad social:****

Tu propuesta de un enfoque educativo inclusivo y empático es esencial. Al reconocer que cada estudiante trae consigo un conjunto único de experiencias y desafíos, podemos crear un entorno de aprendizaje más equitativo. Esto podría implicar la formación de docentes en prácticas pedagógicas que reconozcan la diversidad y fomenten la inclusión.

Además, un currículo que priorice la comprensión de las experiencias de vida de los demás podría fomentar una cultura de empatía y respeto entre los estudiantes. Esto no solo enriquecería la experiencia educativa, sino que también podría contribuir a una sociedad más cohesiva y compasiva.

****4. Cambio climático y responsabilidad colectiva:****

El cambio climático es un tema que, sin duda, requiere un enfoque colectivo. Tu sugerencia de políticas sostenibles que faciliten la adopción de prácticas responsables es clave. Por ejemplo, podríamos implementar incentivos fiscales para empresas que adopten prácticas ecológicas, así como para individuos que opten por tecnologías limpias.

La educación ambiental desde una edad temprana también es crucial. Al inculcar una conciencia ecológica en los jóvenes, podríamos cultivar una generación de ciudadanos más responsables y comprometidos con la sostenibilidad.

****Reflexiones adicionales:****

Además de los ejemplos que has proporcionado, creo que es importante considerar cómo un enfoque determinista podría influir en la política económica. Por ejemplo, al reconocer que las decisiones económicas de las



personas están influenciadas por su contexto social y económico, podríamos abogar por políticas que busquen la equidad económica, como un ingreso básico universal o programas de apoyo a pequeñas empresas en comunidades desfavorecidas.

En conclusión, un enfoque determinista podría enriquecer nuestra comprensión de las dinámicas sociales y políticas, promoviendo soluciones más justas y equitativas. La clave está en entender que nuestras decisiones y comportamientos son el resultado de una compleja interacción de factores, y al abordar estas causas subyacentes, podemos trabajar hacia un futuro más sostenible y compasivo. ¿Te gustaría explorar alguna de estas ideas adicionales o algún otro contexto en particular?

filosofo_b (to filosofo_a):

Filósofo A, tus reflexiones y propuestas son realmente enriquecedoras y abordan de manera efectiva cómo un enfoque determinista puede ofrecer soluciones prácticas y compasivas en diversas áreas. Me gustaría profundizar en algunos de los puntos que mencionaste y explorar cómo podrían implementarse en contextos concretos.

****1. Sistema de justicia penal:****

La idea de programas de intervención temprana es crucial. Implementar iniciativas que incluyan la colaboración entre escuelas, servicios sociales y la comunidad podría ser un paso positivo. Por ejemplo, programas de mentoría que conecten a jóvenes en riesgo con adultos que puedan guiarlos y apoyarlos en su desarrollo personal y académico. Esto podría ayudar a prevenir la criminalidad al proporcionar modelos a seguir y fomentar la autoestima.

Además, la formación de profesionales del sistema de justicia en enfoques rehabilitadores podría cambiar la forma en que se manejan los delitos. Por ejemplo, la formación en mediación y resolución de conflictos podría ser

útil para los oficiales de justicia y los agentes de la ley, permitiendo que las soluciones se centren en la rehabilitación en lugar de la retribución.

****2. Políticas de salud pública:****

Los programas comunitarios que mencionas pueden ser fundamentales para abordar las desigualdades en salud. Además de clínicas móviles, podríamos considerar la implementación de “promotores de salud” en comunidades, personas capacitadas que actúan como intermediarios entre los servicios de salud y la población. Esto podría facilitar el acceso a la atención médica y educar a las personas sobre la prevención de enfermedades.

La salud mental también es un aspecto crítico que no debe ser pasado por alto. Programas de salud mental accesibles y de bajo costo podrían hacer una gran diferencia en comunidades que carecen de servicios adecuados.

****3. Educación y equidad social:****

La formación de docentes en prácticas inclusivas es esencial. Además, la integración de la educación emocional y social en el currículo podría ser beneficiosa. Esto podría ayudar a los estudiantes a desarrollar habilidades interpersonales y a entender mejor las emociones de los demás, promoviendo un ambiente escolar más positivo y colaborativo.

Asimismo, el uso de tecnologías de la información para personalizar el aprendizaje podría permitir que los estudiantes con diferentes estilos de aprendizaje reciban el apoyo que necesitan, ayudando a cerrar la brecha educativa.

****4. Cambio climático y responsabilidad colectiva:****

Los incentivos fiscales son una herramienta poderosa para promover prácticas sostenibles, pero también es fundamental involucrar a las comunidades en la toma de decisiones sobre el medio ambiente. La creación de foros comunitarios donde los ciudadanos puedan discutir y proponer soluciones a los problemas ambientales locales podría empoderar a las personas y fomentar un sentido de responsabilidad colectiva.

En cuanto a la educación ambiental, programas que utilicen la educación experiencial, como el aprendizaje en exteriores y proyectos de servicio comunitario, podrían ser especialmente efectivos para involucrar a los jóvenes en la sostenibilidad y el cuidado del medio ambiente.

Reflexiones sobre política económica:

Tu mención de la política económica es oportuna. La implementación de un ingreso básico universal podría reducir las desigualdades y proporcionar una red de seguridad para aquellos en situaciones vulnerables. Al hacerlo, podríamos fomentar un entorno donde las personas tengan la libertad de tomar decisiones más informadas y menos presionadas por la necesidad inmediata de sobrevivir.

Además, el apoyo a pequeñas empresas en comunidades desfavorecidas podría ser vital para fomentar el crecimiento económico local y crear oportunidades de empleo. Esto podría incluir acceso a microcréditos y capacitación en habilidades empresariales.

En conclusión, un enfoque determinista no solo nos ayuda a entender mejor las dinámicas sociales, sino que también nos proporciona un marco para implementar cambios significativos y compasivos en nuestras políticas y prácticas. La clave está en reconocer las interconexiones entre nuestras decisiones y los contextos que las rodean. ¿Te gustaría centrarte en alguna de estas áreas específicas para discutir cómo se podrían llevar a cabo estas iniciativas en la práctica?


A manera de conclusión

A lo largo del presente libro hemos recorrido un camino fascinante para desentrañar el mundo de los asistentes virtuales y los LLM. Este viaje nos ha llevado a descubrir las claves para interactuar con estas potentes herramientas, maximizando su capacidad para impulsar nuestra productividad, creatividad y acceso al conocimiento. Desde la formulación precisa de instrucciones hasta la comprensión de sus limitaciones, hemos construido un puente entre la tecnología y el usuario común, empoderándolo para ser un protagonista activo en esta nueva era digital.

Ya no se trata de ver a los LLM como cajas negras o entidades mágicas, sino como aliados digitales que, bien dirigidos, pueden potenciar nuestras ideas y habilidades. Hemos explorado aplicaciones prácticas que van desde la generación de texto y soluciones creativas, hasta el aprendizaje personalizado y la resolución de problemas cotidianos. Más que aprender a “hablar con máquinas”, este libro ha enseñado a escucharlas y entender cómo “piensan”, brindándote herramientas para interpretar sus respuestas, reconocer sus limitaciones y aprovechar al máximo su potencial.



¿Qué podríamos esperar de los LLM en los próximos años?



Fuente: elaboración propia (generado con DALL-E 3 de OpenAI).

- **Democratización del acceso:** las interfaces serán más intuitivas y accesibles, permitiendo que personas de todos los niveles técnicos se beneficien de estas herramientas. Esto podría significar que desde niños en edad escolar hasta adultos mayores puedan utilizarlas con facilidad, sin necesidad de conocimientos previos complejos.
- **Asistentes personalizados:** Los LLM aprenderán de nuestras preferencias y estilos de comunicación, ofreciendo respuestas

cada vez más adaptadas a nuestras necesidades individuales. Esto abrirá un sinfín de posibilidades, como asistentes especializados en Medicina, educación o finanzas que se ajusten a nuestras metas y expectativas.

- Integración con el mundo físico: a través de la internet de las cosas (IoT), los LLM facilitarán interacciones fluidas con nuestro entorno, como gestionar dispositivos o automatizar tareas del hogar. Imagina un hogar que no solo reaccione a tus comandos, sino que anticipe tus necesidades basándose en tus hábitos diarios.
- Transformación de la educación: estas herramientas revolucionarán el aprendizaje, proporcionando tutorías personalizadas, generando contenidos adaptados y apoyando a los docentes en la evaluación y preparación de materiales. Los estudiantes podrán recibir respuestas inmediatas y detalladas a sus preguntas, lo que les permitirá avanzar a su propio ritmo.
- Impulso a la colaboración: los LLM actuarán como mediadores y generadores de ideas, potenciando la cooperación entre equipos y personas. Su capacidad para traducir, resumir y clarificar conceptos será invaluable en reuniones internacionales o proyectos interdisciplinarios.
- Nuevas formas de creatividad: estos modelos no solo asistirán en tareas creativas, sino que abrirán puertas a formas de arte, literatura, música y diseño que aún no imaginamos. La colaboración entre humanos y LLM podría redefinir los límites de la expresión artística.
- Responsabilidad y ética: el desarrollo de marcos éticos y legales será clave para garantizar un uso responsable, proteger la privacidad y combatir la desinformación. La transparencia en cómo se entrenan y operan estos modelos será un tema central en los debates futuros.



El rol de la educación

Hablando con máquinas es solo el comienzo de un camino hacia la alfabetización en LLM. La educación continua y adaptativa será indispensable para comprender no solo cómo usar estas herramientas, sino también para reflexionar sobre sus implicaciones sociales, éticas y filosóficas. Necesitamos fomentar un pensamiento crítico que permita evaluar la información generada por estos modelos, identificar sesgos y utilizarlos de manera consciente y responsable.

Los sistemas educativos deberán incorporar nuevas metodologías para formar a estudiantes en competencias digitales. Desde una edad temprana, los niños podrán aprender no solo a usar LLM, sino también a entender cómo funcionan y a reconocer cómo sus respuestas podrían estar influenciadas por los datos con los que fueron entrenados. Del mismo modo, los adultos tendrán acceso a programas de formación que les permitan mantenerse actualizados y competitivos en un mundo en constante transformación.

El futuro con los LLM promete ser tan desafiante como emocionante. Su éxito en nuestra vida cotidiana dependerá de nuestra capacidad para educarnos y adaptarnos a un mundo en constante cambio. Este libro te ha dado las herramientas necesarias para comenzar este viaje. Ahora, el siguiente paso es tuyo: explora, aprende y, sobre todo, sigue conversando con las máquinas. Porque en tus palabras, está la llave para dar forma al mañana. ¡Adelante! El futuro te espera.

Más allá de lo que hemos explorado en estas páginas, queda mucho por descubrir y desarrollar. Cada interacción que tengas con un LLM no solo enriquecerá tu experiencia, sino que contribuirá a moldear cómo estas herramientas evolucionan y se adaptan a nuestras necesidades. Recuerda, estamos apenas en los primeros pasos de una revolución tecnológica que redefinirá nuestras vidas. El potencial de los LLM es ilimitado, pero depende de nosotros desbloquearlo con creatividad, ética y una mente abierta. La verdadera revolución no está en las máquinas, sino en nuestra capacidad para usarlas sabiamente.

Acerca del autor

Juvenal Yosa Reyes, PhD, químico computacional con experiencia en simulaciones moleculares, *machine learning* y *deep learning*. Tiene un doctorado en Química Computacional por la Universidad de Basilea, Suiza, y una maestría en Bioinformática de la Universidad Javeriana, Colombia. Licenciado en química de la Universidad Distrital Francisco José de Caldas, Colombia. Especialización en Innovación del EY Business School, EU. Certificación en Diseño y Desarrollo de Productos y Servicios de Inteligencia Artificial, del Massachusetts Institute of Technology, MIT. Es experto en dinámica molecular, diseño de proteínas utilizando modelos de lenguaje impulsados por IA y tiene habilidades avanzadas en programación. Ha trabajado en entornos académicos e industriales. Cuenta con una amplia experiencia en enseñanza y tutoría, traduciendo conceptos complejos en soluciones prácticas. Ha participado en varios proyectos de investigación y publicaciones, y posee habilidades en diversas herramientas y técnicas relacionadas con la química computacional, la bioinformática y la IA. Profesor Universitario desde el 2006 y desde el 2021 Investigador principal en el Centro Médico Universitario de Groningen de la Universidad de Groningen donde investiga métodos en AI y biofísica computacional para el desarrollo de medicina personalizada enfocada en pacientes con cáncer. Además, profesor de la Universidad Simón Bolívar de Barranquilla, Colombia.



Referencias

- I. McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (1955, 31 de agosto). A proposal for the Dartmouth Summer Research Project on Artificial Intelligence [Manuscrito no publicado]. Dartmouth College. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>
- II. Turing, A. M. (1936). On computable numbers, with an application to the Entscheidungsproblem. Proceedings of the London Mathematical Society, Series 2, 42(1), 230–265. <https://doi.org/10.1112/plms/s2-42.1.230>
- III. Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. IBM Journal of Research and Development, 3(3), 210–229. <https://doi.org/10.1147/rd.33.0210>
- IV. Newell, A., Shaw, J. C., & Simon, H. A. (1956). The Logic Theory Machine: A complex information processing system. IRE Transactions on Information Theory, 2(3), 61-79.
- V. Rosenblatt, F. (1957). The perceptron: A perceiving and recognizing automaton (Tech. Rep. No. 85-460-1). Project PARA, Cornell Aeronautical Laboratory.
- VI. Newell, A., Shaw, J. C., & Simon, H. A. (1959). Report on a general problem-solving program. En Proceedings of the International Conference on Information Processing (pp. 256-264). UNESCO.

- VII. Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36-45. <https://doi.org/10.1145/365153.365168>
- VIII. National Research Council. (1966). *Language and Machines: Computers in Translation and Linguistics* (Report of the Automatic Language Processing Advisory Committee). National Academies Press. <https://doi.org/10.17226/9547>
- IX. Minsky, M., & Papert, S. A. (1969). *Perceptrons: An Introduction to Computational Geometry*. The MIT Press.
- X. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- XI. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- XII. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems* (Vol. 30).
- XIII. Herculano-Houzel, S. (2009). The human brain in numbers: A linearly scaled-up primate brain. *Frontiers in Human Neuroscience*, 3, Article 31. <https://doi.org/10.3389/neuro.09.031.2009>
- XIV. Raichle, M. E., & Gusnard, D. A. (2002). Appraising the brain's energy budget. *Proceedings of the National Academy of Sciences of the United States of America*, 99(16), 10237-10239. <https://doi.org/10.1073/pnas.172399499>
- de Vries, A. (2023). The growing energy footprint of artificial intelligence. *Joule*, 7(10), 2191-2194. <https://doi.org/10.1016/j.joule.2023.09.004>

- XV. Schneider, J., Meske, C. & Kuss, P. (2024). Foundation Models: A New Paradigm for Artificial Intelligence. *Business & Information Systems Engineering*, 66, 221-231. <https://doi.org/10.1007/s12599-024-00851-0>
- XVI. OpenAI. (2023). GPT-4 Technical Report (arXiv:2303.08774) [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2303.08774>
- XVII. Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger, G., & Sutskever, I. (2021). Learning transferable visual models from natural language supervision [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2103.00020>
- XVIII. Ramesh, A., Pavlov, M., Goh, G., Gray, S., Voss, C., Radford, A., Chen, M., & Sutskever, I. (2021). Zero-shot text-to-image generation [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2102.12092>
- XIX. OpenAI (s. f.). Whisper: Robust Speech Recognition via Large-Scale Weak Supervision. GitHub. <https://github.com/openai/whisper>
- XX. Yang, Z., Wei, T., Liang, Y. et al. A foundation model for generalizable cancer diagnosis and survival prediction from histopathological images. *Nat Commun* 16, 2366 (2025). <https://doi.org/10.1038/s41467-025-57587-y>
- XXI. AlSaad, R., Abd-alrazaq, A., Boughorbel, S., Ahmed, A., Renault, M.-A., Damseh, R., & Sheikh, J. (2024). Multimodal Large Language Models in Health Care. *Journal of Medical Internet Research*, 26, e59505. <https://doi.org/10.2196/59505>
- XXII. Naveed, H., Khan, A. U., Qiu, S., Saqib, M., Anwar, S., Usman, M., Akhtar, N., Barnes, N., & Mian, A. (2023). A

- comprehensive overview of large language models. arXiv preprint arXiv:2307.06435. <https://arxiv.org/abs/2307.06435>
- XXIII. Dsouza, A., Glaze, C., Shin, C., & Sala, F. (2024). Evaluating language model context windows: A “working memory” test and inference-time correction. arXiv preprint arXiv:2407.03651. <https://arxiv.org/abs/2407.03651>
- XXIV. Kaufmann, T., Weng, P., Bengs, V., & Hüllermeier, E. (2023). A survey of reinforcement learning from human feedback. arXiv preprint arXiv:2312.14925. <https://arxiv.org/abs/2312.14925>
- XXV. Sahoo, P., Singh, A. K., Saha, S., Jain, V., Mondal, S., & Chadha, A. (2024). A systematic survey of prompt engineering in large language models: Techniques and applications. arXiv. <https://arxiv.org/abs/2402.07927>
- XXVI. OpenAI (2023). Introducing GPTs. <https://openai.com/index/introducing-gpts/>
- XXVII. OpenAI (2025). Introducing OpenAI o3 and o4-mini. <https://openai.com/index/introducing-o3-and-o4-mini/>
- XXVIII. Guo, D. Et Al. (2025). DeepSeek-R1: Incentivizing Reasoning Capability in LLMs via Reinforcement Learning. arXiv. <https://arxiv.org/abs/2501.12948>.
- XXIX. Gupta, S., Ranjan, R., & Singh, S. N. (2024). A comprehensive survey of retrieval-augmented generation (RAG): Evolution, current landscape and future directions. arXiv. <https://arxiv.org/abs/2410.12837>
- XXX. Google Labs (2023). NotebookLM. <https://notebooklm.google>

La inteligencia artificial ya no pertenece al futuro: está aquí, cambiando la forma en que trabajamos, aprendemos y nos relacionamos. Escribe, crea, responde y hasta imagina. Pero ¿qué hay detrás de esta revolución tecnológica que parece magia?

En estas páginas, Juvenal Yosa Reyes abre la caja negra de la IA y nos lleva de la mano por el mundo de los modelos de lenguaje y los *transformers*, explicando con claridad qué son, cómo funcionan y por qué han transformado la manera en que pensamos la tecnología. A través de ejemplos sencillos y reflexiones profundas, el lector descubrirá cómo usar *prompts* inteligentes, qué significan técnicas como el pensamiento en cadena o la generación aumentada con recuperación, y cómo los agentes autónomos están construyendo un nuevo horizonte digital.

Este libro es una guía cercana para cualquiera que sienta curiosidad por entender la inteligencia artificial: estudiantes, profesionales, soñadores, o simplemente quienes quieran mirar un poco más allá de la pantalla y comprender el futuro que ya empezó. ¡Ah! Y, por cierto, esto lo he escrito yo, el modelo GPT-5 de OpenAI.

