



Universidad
Zaragoza

Trabajo Fin de Grado

Recuperación de Información en IAs
conversacionales: un acercamiento al *prompt
engineering* para documentalistas

Information Retrieval in conversational AI: an
approach to prompt engineering for Information
Scientists

Autor

Pablo Martín Torres

Director

Antonio-Paulo Ubieto Artur

Facultad de Filosofía y Letras
Mayo 2024

*[...] Y vete a muchas ciudades de Egipto
y aprende, aprende de los sabios.*

Mantén siempre a Ítaca en tu mente.

Llegar allí es tu destino.

Pero no tengas la menor prisa en tu viaje.

Es mejor que dure muchos años

y que viejo al fin arribes a la isla,

rico por todas las ganancias de tu viaje,

sin esperar que Ítaca te vaya a ofrecer riquezas.

Ítaca te ha dado un viaje hermoso.

Sin ella no te habrías puesto en marcha.

Pero no tiene ya más que ofrecerte.

Aunque la encuentres pobre, Ítaca de ti no se ha burlado.

Convertido en tan sabio, y con tanta experiencia,

ya habrás comprendido el significado de las Ítacas.

(Konstantinos P. KAVAFIS, Ítaca.)

MARTÍN TORRES, Pablo

Recuperación de Información en IAs conversacionales: un acercamiento al prompt engineering para documentalistas [Manuscrito] / Pablo Martín Torres; director Antonio-Paulo Ubieto Artur. – 2024. – 60 p.: il. ; 30 cm. – Trabajo Fin de Grado de Información y Documentación de la Universidad de Zaragoza, 2024.

1. Inteligencia artificial-Búsqueda de Información I. Ubieto Artur, Antonio-Paulo. II. Tít.

025.4.03



Registrado por la [Universidad de Zaragoza](#) bajo la [licencia Creative Commons BY-NC-SA 4.0 DEED](#)



Facultad de
Filosofía y Letras
Universidad Zaragoza

FACULTAD DE FILOSOFÍA Y LETRAS

TRABAJO FIN DE GRADO

Recuperación de Información en IAs
conversacionales: un acercamiento al *prompt
engineering* para documentalistas

Information Retrieval in conversational AI: an
approach to prompt engineering for Information
Scientists

Autor: Pablo Martín Torres

Director: Antonio-Paulo Ubieto Artur

Fecha: 31/05/2024

RESUMEN

Dado el contexto de auge de las IAs Generativas en el momento de la redacción, se presenta, por medio de la lectura y asimilación de bibliografía en torno a los distintos puntos, una introducción al mundo de la IA para documentalistas. Esta introducción se realiza desde la perspectiva de la Recuperación de Información (RI) y gira en torno al *prompt engineering*, conjunto de técnicas de confección de *inputs* para las IAs. Se aprovechan los paralelismos y confluencias entre RI y *prompt engineering* para presentar este último y algunas de sus técnicas, útiles para optimizar el uso de estas IAs. En último lugar, se analizan algunos de los problemas éticos presentes tanto en el planteamiento como en el uso de las IAs generativas. La naturaleza de los modelos de lenguaje y los problemas éticos llaman a la prudencia al tratar los resultados de los *prompts*, sin despreciar el uso de estas herramientas, dado su potencial para los entornos documentales.

Palabras clave: Inteligencia Artificial Generativa, *prompt engineering*, Recuperación de Información, modelos de lenguaje, ética en IA.

ABSTRACT

Given the actual context of the rise of Generative AI, we present an introduction to the world of AI for information scientists through the reading and assimilation of bibliography. This introduction, conceived from the perspective of Information Retrieval (IR), revolves around prompt engineering, a set of techniques for the creation of inputs for AIs. It takes advantage of the parallels and confluences between IR and prompt engineering to present the latter and some of its techniques, useful for optimizing the use of AIs. Lastly, some of the ethical issues in both the approach and the use of generative AIs are discussed. The nature of language models and their ethical issues call for caution when dealing with the results of prompts, without underestimating the use of these tools, given their potential for use in Information Management environments.

Keywords: Generative Artificial Intelligence, prompt engineering, Information Retrieval, language models, ethics in AI.



TABLA DE CONTENIDOS

1. INTRODUCCIÓN.....	2
1.1. JUSTIFICACIÓN DEL TRABAJO.....	2
1.2. ESTADO DE LA CUESTIÓN.....	3
1.2.1. Breve historia de la Inteligencia Artificial.....	4
1.2.2. Paradigmas de la IA.....	5
1.2.3. ¿Una 3ª revolución?.....	8
1.3. OBJETIVOS.....	11
1.4. METODOLOGÍA APLICADA.....	11
2. DESARROLLO ANALÍTICO.....	13
2.1. GLOSARIO DE TÉRMINOS.....	14
2.1.1. Términos de Ciencias de Documentación.....	15
2.1.2. Términos de Inteligencia Artificial / Informática.....	17
2.2. LA IA CONVERSACIONAL.....	22
2.3. «PROMPT ENGINEERING» Y RECUPERACIÓN DE INFORMACIÓN.....	27
2.3.1. La Recuperación de Información clásica y su aplicabilidad a la IA conversacional.....	28
2.3.2. Técnicas de Prompt Engineering.....	30
2.3.2.1. Técnicas básicas.....	34
2.3.2.2. Técnicas avanzadas.....	36
2.4. ÉTICA PROFESIONAL EN EL USO Y APLICACIÓN DE LA IA.....	43
2.4.1. Problemas generales de la IA generativa.....	43
2.4.2. Ética de la IA Generativa, como usuarios y profesionales.....	45
3. CONCLUSIONES.....	47
4. REFERENCIAS.....	50

1. INTRODUCCIÓN

1.1. JUSTIFICACIÓN DEL TRABAJO

Este trabajo se enmarca en un contexto de auge de las Inteligencias Artificiales (IA) capaces de generar texto similar al de los hablantes humanos. Este contexto viene dado por el surgimiento o, mejor dicho, el lanzamiento gratuito al gran público de chatbots con estas capacidades entrenados mediante grandes modelos de lenguaje. Los ejemplos más populares son ChatGPT y Google Gemini.

La sociedad está prestando gran atención a estos modelos de IA generativa por su potencial, pero también por los problemas éticos y de desinformación que pueden generar (y ya generan mientras se escriben estas líneas). Son herramientas de gran potencial pero que, por lo repentino de su surgimiento e incorporación a la vida cotidiana, la sociedad aún no sabe utilizar para sacarles el máximo partido. La amplia mayoría de las herramientas de IA generativa disponibles al público, inclusive aquellas que generan imágenes o ficheros de audio, funcionan mediante *prompts*, resumidamente, instrucciones u órdenes que un usuario presenta en formato texto para que la IA, capaz de «entender» el lenguaje natural, genere una respuesta o resuelva un problema.

Estos *prompts* se escriben en una «cajetín» y, en función de cómo estén compuestos, la IA generará una respuesta utilizando sus datos de entrenamiento de la manera que estime más relevante para el *prompt* insertado. La relación de este funcionamiento con los fundamentos clásicos de recuperación de información (RI) es más que patente y probablemente esta sea una habilidad propia de especialistas en Documentación en el futuro, si no en el presente, es la composición de *prompts* adecuados con el fin de recuperar/generar la información deseada usando las IAs generativas de texto.

Nadie sabe más sobre ecuaciones de búsqueda, lenguajes controlados, lenguajes naturales y su funcionamiento en sistemas de búsqueda por relevancia que los y las documentalistas, por ello creemos que, en el contexto actual, debiéramos prestar atención a las IAs en general, y a estas habilidades, en particular; dado que podríamos estar ante el surgimiento de uno o varios perfiles profesionales de mucha pujanza para nuestro gremio en su vertiente más tecnológica.



1.2. ESTADO DE LA CUESTIÓN

Hubo una vez un pensador mallorquín en torno al año 1300, Ramón Llull, que diseñó una máquina para verificar tesis teosóficas de manera mecánica y demostrar la certeza de la teología cristiana por sobre aquella judía y musulmana: el *Ars magna et ultima*.

El diseño de esta máquina se apoyaba en la tesis de que el conocimiento científico (en el sentido medieval del término) se formaba a partir de la combinación de 54 ideas simples, también llamadas ideas raíz. La máquina constaba de piezas móviles en las que las ideas y teorías estaban representadas por medio de figuras geométricas, estas piezas se movían accionando palancas y ruedas cuyo resultado, según la combinación, era detenerse en una de dos posiciones: verdad o falsedad (Velasco, 2012).

Aparte de haber inventado la teosofía y la rosa de los vientos, podemos considerar que Ramón Llull también fue la primera persona en tratar de producir conocimiento por medio de un autómatas, por muy rudimentario que pueda resultar. No por nada, este beato es considerado el patrón de los ingenieros informáticos (UAM, 2021).

La extracción, producción organización y recuperación de conocimiento por cualquier medio es a lo que nos dedicamos en el campo de la Documentación. El contexto actual nos lleva a que estos medios sean principalmente informáticos; pero pareciera que la Era Digital está virando (o acabándose) por haber alcanzado las capacidades suficientes de computación, diseño de algoritmos y tratamiento de datos para hacer posible algo que estamos viviendo: la génesis de las Inteligencias Artificiales Generativas. Si Ramón Llull pudiera vivir para ver, utilizar o incluso entrenar Inteligencias Artificiales...

Pero antes de entrar a hablar sobre IA generativa, cabe hacer una breve exposición de los modelos de IA que nos han llevado a donde estamos, y que son la base indefectible para entender lo que ha de tratarse en el desarrollo del presente trabajo.

1.2.1. Breve historia de la Inteligencia Artificial

El primer registro del término «Inteligencia artificial» (IA) se da en el año 1956, cuando John McCarthy lo usó en la Conferencia de Dartmouth, conferencia que reunía a los principales científicos de la época con el objetivo de trabajar sobre la posibilidad de crear una máquina con la capacidad de pensar como un ser humano. No obstante, estas ideas sobre máquinas con procesamiento similar al humano se remontan a varios años antes. Ya que en la década de 1940, dos matemáticos, Norbert Wiener y John von Neumann, trabajaron sobre la teoría de sistemas y computación, sus avances sirvieron para que McCarthy pudiera definir la IA como «la ciencia de hacer máquinas inteligentes, especialmente programas inteligentes de computadora» (Haenlein y Kaplan, 2019).

En 1950, dos alumnos de Harvard, Marvin Minsky y Dean Edmonds, crearon el primer ordenador de red neuronal: «SNARC». También en este año, Alan Turing publicó un artículo llamado *Computing Machinery and Intelligence* donde ideó el conocido Test de Turing, el cual hoy en día sigue utilizándose para valorar las capacidades de las IAs (Haenlein y Kaplan, 2019).

Uno de los grandes y más famosos hitos de la IA se dio en el año 1997, cuando la IA «Deep Blue», creada y perfeccionada por IBM, logró ganar en un set de partidas de ajedrez al campeón mundial Garri Kasparov, con un resultado de 3½-2½ (Wikipedia, 2024c). Fue la primera vez que una máquina consiguió derrotar a un campeón mundial en un juego.

Este fue el punto desde el cual se puede empezar a hablar de Inteligencias Artificiales funcionales. Desde entonces no han hecho más que evolucionar en posibilidades y complejidad, por ello, a continuación, se reseñan brevemente los principales paradigmas por los que ha pasado la IA hasta nuestros días.

1.2.2. Paradigmas de la IA¹

1. IA basada en conocimiento o sistemas experto:

Deep Blue era un sistema experto, uno de los tipos más *primitivos* de IA. Su planteamiento aduce a un tipo tan concreto de inteligencia que incluso hay cierto debate sobre si estos sistemas son IA o no.

Los sistemas expertos o por reglas son software basado en reglas y condiciones concretas proporcionadas por un experto humano para realizar tareas que, pudiendo ser muy complejas, son siempre muy específicas (Grosan y Abraham, 2011).

Estos son sistemas muy rígidos que comprueban las reglas que les incluyen en el exacto orden en que les fueron asignadas, para realizar la tarea para la que han sido creadas; usan lógica binaria del tipo *true/false* e *if-then* para comprobar si las reglas se cumplen o no, asimilando la lógica en un lenguaje simbólico con el que representan el conocimiento (Torres, 2023).

Los datos e instrucciones de los expertos son sólo el comienzo. A partir de estos y de sus experiencias en el ejercicio de la tarea, el sistema experto creará normas adicionales (algoritmos), «aprendiendo» cada vez más en las diferentes iteraciones de la tarea. Esto es lo que hoy conocemos como aprendizaje automático (en inglés, *Machine Learning*).

La rigidez de estos sistemas binarios hizo que surgieran otro tipo de sistemas expertos: los sistemas difusos. Los sistemas por reglas difusas manejan grados de pertinencia, permitiendo una representación más flexible y más cercana a la forma en que los humanos razonan en entornos ambiguos (Pareek et al., 2023).

El principal «reproche» que se les ha hecho a los sistemas expertos es que son sistemas *monomaniacos*, existen para una única tarea y todo su procesamiento se aboca exclusivamente a esta, sin ser capaces de entender nada más. La tarea de Deep Blue era el ajedrez, pero si pusiéramos a Deep Blue a ver partidas de damas, no podría entender ni «improvisar» absolutamente nada. Esto se debe a que, pese a las muchas similitudes que guarda este juego con el ajedrez, no sigue

¹ La clasificación de los paradigmas de la IA así como la base para explicarlos se basa principalmente en aquella realizada por Jordi Torres en la obra: Torres, J. (2023). *La inteligencia artificial explicada a los humanos* (Quinta edición). Plataforma Editorial.

exactamente sus normas; y por ende su lógica, sea binaria o difusa, no se aplica a este juego.

2. IA basada en datos

Hay dos diferencias fundamentales para con el paradigma anterior: el uso de redes neuronales y el planteamiento de los especialistas respecto a la máquina.

Para continuar con la explicación y entender lo importante de la incorporación de las redes neuronales a la IA, debe definirse lo que una red neuronal es: Una red neuronal es un algoritmo conexionista, es decir, que intenta emular la estructura del cerebro¹, puesto que entiende y plantea el proceso de inteligir como descriptible mediante las conexiones hechas por unidades sencillas (neuronas) interconectadas, formando una red (Serón Arbeloa, 2023).

Una neurona artificial tiene un núcleo que recibe como entrada la energía de las neuronas con las que está conectada. Si esa energía supera cierto umbral, llamado «peso», la neurona se activa y envía energía a través de sus conexiones de salida hacia otras neuronas. El peso de las neuronas es un valor ajustable que dicta lo sensibles que son (Torres, 2023).

La configuración de una red neuronal se puede dividir en tres pasos:

- I. Arquitectura de la red:** cómo se disponen las neuronas dentro de la red.
- II. Entrenamiento:** ajuste de los pesos de las neuronas para que se activen con los estímulos correctos, es decir, cuando hacen bien aquello para lo que se están entrenando. Para ello se examina cuál es el valor que la red neuronal calcula por sí misma con cada dato de entrada, se compara con el valor correcto y, a partir de esa comparación, el sistema se ajusta para «aprender del error». Los ajustes que la red hace son optimizaciones colectivas que incrementan las posibilidades de éxito en futuras iteraciones (Haykin, 1999).

La IA aprenderá mediante estas optimizaciones. El tipo de aprendizaje, entendiendo «aprendizaje» como procesamiento de la experiencia, este

¹ Esta corriente deriva de las ideas de Frank Ronsenblatt, quien decía que un sistema inteligente debe inspirar su estructura y funcionamiento en la del cerebro y las neuronas biológicas, dedicando parte de su investigación a ello mediante el diseño del *Perceptron*.

aprendizaje de la máquina puede seguir uno de tres modelos (Serón Arbeloa, 2023):

- Aprendizaje supervisado: el programador entrena directamente las neuronas de la red.
- Aprendizaje no supervisado: los programadores no saben los patrones/agrupaciones de los datos, la red los hace por sí misma. Aun así, intervienen puntualmente en el entrenamiento.
- Aprendizaje por refuerzo: los programadores sólo «evalúan» numéricamente los resultados de la red. El sistema es el que detecta qué nodos deben ajustarse para tratar de obtener mejor «evaluación».

III. *Fase de inferencia*: uso de la red neuronal para el propósito con el que se ha diseñado.

Así pues, este avance en el paradigma de la IA fue posible debido a una evolución en los algoritmos.

Respecto al planteamiento respecto a la máquina, la IA basada en datos recibe un objetivo, «algo que debe hacer», pero a diferencia de las anteriores, no se le indica el cómo hacerlo de ninguna manera; es la red neuronal, mediante los modelos de aprendizaje automático que acabo de mentar, la que «aprende» cómo hacerlo.

3. IA basada en experiencia

Para llegar a este paradigma fue necesaria la mejora de potencia en computación y los chips aceleradores, puesto que la IA se entrena casi exclusivamente con iteraciones, esto es, veces que hace la misma cosa (Torres, 2023).

De hecho, ya no se le introduce un objetivo a conseguir, el algoritmo debe «averiguarlo» por prueba y error.

4. IA por Fuerza Bruta (Generativa)

Este último paradigma es el actual y su diferencia con el anterior es, solamente, la magnitud de la tecnología aplicada a los métodos ya explicados: las redes neuronales son mucho más grandes y se entrenan con cantidades ingentes de datos en supercomputadores a gran escala con una capacidad de procesamiento mastodóntica (hablamos de decenas de petaFLOPS¹), posible sólo por la supercomputación de

¹ Un petaFLOPS son 10^{15} operaciones de coma flotante por segundo, y sirven para medir los cálculos matemáticos que puede hacer por segundo una CPU + GPU.

máquinas como el MareNostrum 5 y técnicas de paralelismo de chips (Torres, 2023).

Como vemos, la teoría detrás de la IA lleva décadas inventada, pero sólo recientemente los avances tecnológicos han permitido que los 3 pilares de la IA: los datos, la computación, y los algoritmos; avancen lo suficiente como para «dar el salto» a modelos generativos como los que estamos viendo últimamente.

1.2.3. ¿Una 3ª revolución?

Algunas voces consideran que este «salto» suponen la 3ª revolución de la informática. La revolución de la IA iría precedida de la revolución informática (la 1ª) y la revolución del Internet (la 2ª).

Y tiene sentido, pues estos grandes cambios se concatenan perfectamente y presentan parecidos estructurales más que razonables. Por el bien del contexto, vamos a repasar sucintamente las características de estas revoluciones, estableciendo descriptivamente los paralelos entre los modelos que las causaron.

Revolución del PC

Tiene su epicentro en la popularización del ordenador personal (PC, por *Personal Computer*) iniciada a finales de la década de 1970¹ (Wikipedia, 2024b).

Gracias a la adopción de la informática y la microelectrónica en forma computadores por parte de organismos y particulares fue posible multiplicar la generación, capacidad de almacenamiento, procesamiento y recuperación de información y conocimiento (Urriego-Giraldo, 1998).

En el esquema básico de un ordenador (véase diagrama), el usuario interactúa con el *hardware* (los componentes físicos) por medio de una aplicación o programa (*software*). Este programa está instalado en un sistema operativo (SO), con el que interactúa y es compatible.



Diagrama de las partes lógicas de un ordenador.
Fuente:
aprendiendoinformatica.com

¹ Este es el punto más socorrido para indicar un comienzo, pese a que otros preferimos usar la invención del transistor en 1947 como punto de partida para la 1ª revolución.

Un programa tendrá, durante su uso, unos requisitos determinados de potencia de procesamiento o de memoria que, por medio del SO, podrá recibir. Así, el SO se establece como la última capa de *software* antes de pasar al *hardware*¹.

Entendemos que la revolución se «acaba» o, mejor dicho, se sustituye, cuando estos ordenadores comienzan estar conectados entre sí y a una red global: Internet.

Revolución de Internet

También se conoce, en parte, como revolución de las tecnologías de la información y la comunicación (TIC), pese a que éste término es menos preciso en su contexto temporal y significado debido a que amalgama cuestiones de la Revolución Digital con aquellas propias de la Revolución de Internet².

La estrella de esta revolución fue, sin duda, la *World Wide Web* (WWW) y las tecnologías que se derivan de su implantación y uso como lo es el Protocolo de Transferencia de Hipertexto (HTTP). El HTTP es tan sólo uno de los protocolos operantes dentro del modelo TCP/IP, concretamente en su capa de aplicación.

El modelo TCP/IP aúna el protocolo de control de transmisiones (TCP) y con el protocolo de Internet (IP), haciendo posible el intercambio de información a través de Internet desde un sistema con acceso a la red.

Presentar el modelo TCP puede ayudarnos a entender mejor en lo que consiste el modelo OSI, modelo teórico de referencia para la interconexión de sistemas abiertos y gran olvidado siempre que se habla de los orígenes de la red de redes.

MODELOS	
TCP/IP	OSI
Aplicación	Aplicación
	Presentacion
	Sesion
Transporte	Transporte
Internet	Red
Acceso a la red	Enlace de datos
	Fisica

Modelo TCP/IP y modelo OSI.

Fuente: [Wikimedia Commons](#)

En la figura pueden leerse las 7 capas de abstracción que forman el modelo OSI y como están representadas en el modelo TCP/IP. Cabe destacar que los extremos del modelo son, nuevamente, la aplicación (utilizada por el usuario) y los componentes físicos.

¹ Es necesario mencionar que, dentro de los múltiples componentes de un SO, esa última capa es el *kernel* o núcleo del sistema operativo.

² En ocasiones, la Revolución TIC puede referirse también a todo lo sucedido tras el paso a la Web 2.0 o web social.

Con la interconexión de sistemas informáticos a través de Internet se abrió una nueva era en la que los computadores personales empezaron a poder intercambiar datos e informaciones a lo largo y ancho del mundo. Esto sucedió en parte gracias a la especialización de ciertos ordenadores para funcionar como servidores.


Estas tecnologías, tanto aquellas que posibilitaron el desarrollo y difusión del ordenador personal como las referentes a Internet han ido evolucionando y refinándose a lo largo de las décadas en las que han existido. A efectos de inteligencia artificial, han sido especialmente relevantes los avances en aquello concerniente a la primera revolución: los ordenadores y su mejora en potencia. Junto con otros que ya se han mentado en el punto anterior, los algoritmos y la cantidad y capacidad de tratamiento de los datos disponibles.

¿Revolución de la IA?

Por lo dicho en el punto anterior, sabemos que el término «revolución» no viene dado en este caso por la invención de las IA. En este caso vendría dada por el surgimiento y uso masivo y abierto por parte de la población de herramientas de IA generativa como chatbots que incorporan modelos de lenguaje o IAs destinadas a generar imágenes.

En el caso de la IA generativa, sabemos que es un ámbito muy concreto y puntero que explota al máximo lo conocido hasta el momento sobre aprendizaje automático, redes neuronales y entrenamiento profundo de las mismas.

Así, esta tecnología es «revolucionaria» en tanto refina y usa al máximo, en cantidad y en profundidad, lo conocido hasta el momento en el campo de la IA, pero



Modelo en capas de la IA.

Fuente: [SERAM](#)

también en los campos de las anteriores revoluciones. Se relaciona con Internet en forma de recolección y tratamiento masivo de los datos allí disponibles; y se relaciona con el *hardware* llevándolo a su forma más refinada (supercomputación) con tal de soportar el volumen de datos y algoritmia necesarios para su existencia.

1.3. OBJETIVOS

El objetivo principal del presente trabajo es presentar el concepto y algunas técnicas de *prompt engineering*, definido sucintamente como conjunto de técnicas para confeccionar instrucciones para las Inteligencias Artificiales Generativas; relacionándolas con la Recuperación de Información (RI) como se entiende desde las Ciencias de la Documentación.

Por acotar el trabajo y por afinidad con la Documentación, se expondrá aplicado a IAs generativas de texto como ChatGPT o Google Gemini, dejando fuera la generación de imágenes y sonido.

Como objetivos secundarios, este trabajo también trata de:

- 1.** Ayudar a otras personas del gremio de la Documentación interesadas en la IA, pero sin conocimientos previos, a situarse en este campo y descubrir el potencial que la IA conversacional puede tener a nivel laboral y personal en el futuro inmediato.
- 2.** Poner en valor la correcta generación de *prompts* como habilidad relacionada con (si no propia de) la Documentación y relevante para el ejercicio profesionales de la Documentación.
- 3.** Exponer los dilemas y problemas éticos que el uso de IAs generativas de texto presenta para especialistas en Información y Documentación.

1.4. METODOLOGÍA APLICADA

En cuanto a las cuestiones formales y de información en torno a acometer la elaboración de un Trabajo Final de Grado, habiendo revisado la normativa vigente en el momento de la realización y la Guía Docente, nos hemos apoyado fundamentalmente en el manual:

- Fondevila Gascón, J. F., Del Olmo Arriaga, J.L. (2013). *El trabajo de fin de grado en ciencias sociales y jurídicas: guía metodológica*. Madrid: Ediciones Internacionales Universitarias.

Para la creación del contenido de este Trabajo Final de Grado se ha recurrido a la lectura de monografías, manuales, conferencias, noticias, obras divulgativas y, sobre todo, literatura científica en torno a la Recuperación de información, la IA, los chatbots y el *prompt engineering*. Se ha tratado de atribuir mayor peso a las obras más



recientes, por lo puntero del presente trabajo, excepción hecha de los temas más teóricos o fundamentales, para los cuales se han preferido figuras de largo recorrido y peso en sus respectivos campos. Debo hacer especial mención al proyecto UNIDIGITAL IASAC¹, dirigido desde la Universidad de Zaragoza, que ha resultado especialmente útil para «aterrizar» en el campo de la IA y entender los conceptos elementales de la misma.

Se ha tenido acceso a los dichos materiales por medio de las facilidades que dan a sus estudiantes las colecciones bibliotecarias de la Universidad de Zaragoza y, aprovechando mi experiencia de movilidad nacional por medio del programa SICUE durante la realización del presente trabajo, la Universidad de Salamanca.

Como formato de cita y referencia se ha escogido APA 7ª edición.

¹ <https://unidigitaliasac.unizar.es/>



2. DESARROLLO ANALÍTICO

Para el cuerpo del trabajo se ha seguido una estructura particular, pero que se entiende como útil a los efectos del mismo. En primer lugar, se ha elaborado un glosario de términos que el lector puede tener como herramienta de consulta durante la lectura del desarrollo.

Después, en el punto [2.2. La IA conversacional](#), se va a explicar en detalle el funcionamiento de las IAs generativas de texto. Ello se hará retomando el hilo de lo expuesto en [1.2. Estado de la cuestión](#). En el punto 2.2 se tratará también de exponer la relación existente entre el auge de estas IAs entre la comunidad de usuarios y nuestra función como profesionales en la sociedad, especialmente en lo tocante a los perfiles referencistas y a la creación y recuperación de información en el medio digital.

El punto [2.3. «Prompt engineering» y Recuperación de información](#), tiene por objetivo ser una traslación de los esquemas procedimentales de la Recuperación de información en herramientas de búsqueda generalistas con el fin de aprovechar lo que ya sabemos ante el nuevo reto de la IA generativa. Dentro de este punto, en [2.3.2. Técnicas de Prompt Engineering](#), se reseñarán algunas de las muchas técnicas que se están descubriendo en este campo con tal de aprovechar al máximo el potencial de las IAs generativas de texto. Consignarlas todas sería una tarea excesiva a los efectos de éste trabajo e inabarcable, pues la investigación está en el campo está muy viva actualmente; se expondrán aquellas en las que se perciba mayor utilidad o potencial.

El punto último antes de las conclusiones, [2.4. Ética profesional en el uso y aplicación de la IA](#), es de inclusión obligatoria al tratar el tema de la IA generativa. Se provee como un punto breve de exposición y comentario en torno a los peligros y amenazas que supone esta tecnología, así como a los comportamientos y posturas esperables de profesionales del ámbito de la Información y la Documentación que, conociendo los sobredichos peligros y amenazas, debe mantenerse dentro de la deontología de nuestro campo. Este punto pasa por algunos de los temas más recurrentes, como lo son la protección de los derechos de autor y los usuarios.



2.1. GLOSARIO DE TÉRMINOS

Se presenta el siguiente glosario de términos como útil herramienta, pudiendo llegar a utilizarse, si se quiere, para consultas terminológicas en futuras lecturas o como punto de partida para investigaciones más profundas.

Este glosario se compone también en un ejercicio de pragmatismo, pues durante el desarrollo del trabajo se utilizarán estos conceptos en mayor o menor medida, y puede resultar beneficioso para el flujo de lectura y comprensión del trabajo tener todos los términos definidos brevemente de antemano.

Su orden es alfabético, excepción hecha de los términos que derivan o están directamente relacionados con otro, los cuales estarán sangrados por la izquierda bajo ese otro término. Esto dota al glosario de una levísima pero necesaria jerarquía, a la usanza de los tesauros.

El glosario está dividido en *Términos de Ciencias de la Documentación* y *Términos de Inteligencia Artificial / Informática*, de los cuales el segundo es el más extenso; esto es así por entenderse el campo de la IA como punto de destino, y las Ciencias de la Documentación como el punto de partida.

En el glosario y, por consiguiente, en el resto del trabajo se han intentado minimizar los anglicismos, utilizando las formas recomendadas por la Fundéu o traduciéndolas de manera casi literal, pero adecuada salvo en aquellos casos en los que no ha sido posible como el de *prompt engineering*¹. Aun así, los términos en inglés más recurrentes como *Big Data* tienen su redirección a la forma escogida.

¹ Se barajó la voz *instrucción* y, por consiguiente, *ingeniería de instrucciones*, pero se descartó por considerarse alejada del significado original, además de confusa para la comprensión.



2.1.1. Términos de Ciencias de Documentación

Consulta del usuario: expresión con la que se configura la demanda informativa del usuario, por regla general, en lenguaje natural, utilizando los términos y palabras que le resultan más aproximados al objeto de recuperación o cuya previsión e intuición le sugieren un mejor aprovechamiento del sistema en su búsqueda (Blázquez Ochando, 2012).

Dato: noticia de un detalle o circunstancia que sirve para ayudar a formar idea de un asunto” (María Moliner, 2008). Es la parte mínima indivisible de la información, definida esta por Luciano Floridi como conjunto de datos sólo si los datos son ≥ 1 , están bien formados y son significativos.

- **Metadato:** información adicional que describe y proporciona contexto sobre otros datos. En el contexto de la gestión documental y la información digital, los metadatos son elementos clave que facilitan la organización, recuperación y comprensión de los recursos de información. Estos datos complementarios incluyen detalles como la autoría, la fecha de creación, la ubicación, el formato, y otros atributos que ayudan a categorizar y gestionar eficientemente la información (Founier, 2006).

Ecuación de búsqueda: expresión en el lenguaje de búsqueda que se corresponde con la consulta y que expresa una necesidad informativa. Se compone mediante palabras clave, operadores y símbolos reservados (Codina, 2017).

Indización: representar las ideas principales del contenido del documento usando términos procedentes del lenguaje natural que emplea el autor o autores del documento, o bien mediante un lenguaje documental (Pinto, 1989, p. 334).

Lenguaje de búsqueda: aquel usado para trasladar una necesidad informativa al lenguaje documental propio de un sistema de recuperación de información, formando una ecuación de búsqueda (Sánchez Casabón, 2021).

Lenguaje documental: vocabulario artificial y estereotipado, compuesto por una lista de términos normalizados y sus respectivas



relaciones (Pinto Molina, 1989, p. 335). Estos sistemas reducen las ambigüedades semánticas y ayudan además a encontrar, a través del entramado de su estructura de relaciones, temas cercanos (más amplios o más específicos) al objeto de la búsqueda (Soria González, 1997).

Lenguaje natural: se refiere a cualquier forma de comunicación humana no estructurada, como el habla o el texto sin restricciones.

Necesidad informativa: Es un estado de conocimiento que un sujeto experimenta como incompleto con relación a la consecución de determinados objetivos actuales o futuros (Codina, 2018).

Metadato: véase **Dato**.

Recuperación de información: Disciplina que se ocupa de la aplicación del conjunto de técnicas, métodos y actividades para buscar, localizar y recuperar de una manera eficiente en los diversos sistemas de recuperación de información (SRI) la información relevante que requiere el usuario y satisfacer así su necesidad de información (Salvador Oliván, 2008, p. 131).

Relevancia: grado de importancia y significación que concede el usuario a los resultados obtenidos en un sistema de información (Blázquez Ochando, 2012).

Ruido (recuperación de información): resultado de búsquedas demasiado genéricas, gran cantidad de información no relevante recuperada (Cacheda Seijo et al., 2011).

Silencio (recuperación de información): resultado de mediocre o demasiada precisión, búsqueda sin coincidencias o con las mínimas (Cacheda Seijo et al., 2011).

Sistema integrado de gestión documental: conjunto organizado de recursos humanos, materiales, tecnológicos, etc., capaces de llevar a cabo la gestión automatizada de un sistema de información documental bibliotecario (García Melero y García Camarero, 1999).



2.1.2. *Términos de Inteligencia Artificial / Informática*

Algoritmo: lista de órdenes que se le da a una máquina para dirigir su acción y que cubre todas las posibles opciones a las que se enfrentará en la tarea. No hace que la máquina piense o entienda la tarea, sino que la ejecute (Serón Arbeloa, 2023).

API: son las siglas del inglés *application programming interface*, código que permite a diferentes aplicaciones comunicarse entre sí y compartir información y funcionalidades. Una API es un intermediario entre dos sistemas, que permite que una aplicación se comuniquen con otra y pida datos o acciones específicas (Wikipedia, 2024a).

Aprendizaje automático¹: conjunto de métodos y algoritmos que permiten a una máquina aprender de manera automática en base a experiencias pasadas (Bosch Rué et al., 2019). Estas máquinas utilizan algoritmos para identificar patrones y realizar predicciones o decisiones automatizadas.

Arquitectura (de una red neuronal): véase **Red Neuronal**.

Big Data: véase **Inteligencia de datos**.

Chatbot²: sistemas capaces de mantener conversaciones prolongadas cuyo objetivo es imitar las conversaciones no estructuradas o "chats" característicos de la interacción informal entre humanos (Jurafsky y Martin, 2024).

- **Sistema de diálogo orientado a tareas**³: del inglés *Task-oriented dialogue system*, son sistemas que conversan con los usuarios con el fin de cumplir una tarea prefijada, requieren de una estructura de datos llamada *frame* o marco (Jurafsky y Martin, 2024).

Codificación: regla que permite la transformación de un mensaje escrito en forma simbólica (alfabeto fuente) a otra (alfabeto resultante),

¹ <https://www.fundeu.es/recomendacion/aprendizaje-automatizado-mejor-que-machine-learning/>

² <https://www.fundeu.es/recomendacion/chatbot-neologismo-valido/>

³ Estos sistemas quedan, en principio, fuera de los márgenes temáticos del presente trabajo, si bien se reseñan dada la posibilidad de confundirlos con los chatbots. Además, los sistemas modernos empiezan a incorporar aspectos de ambos.



generalmente sin pérdida de información en el proceso (Illingworth, 1985).

Corpus: véase **Modelo**.

Entrenamiento: véase **Red Neuronal**.

Inteligencia Artificial (IA): campo de la informática que se dedica al desarrollo de algoritmos y sistemas que pueden realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje, la comprensión del lenguaje natural, la toma de decisiones y la resolución de problemas (Serón Arbeloa, 2024).

- **IA Conversacional**: se refiere a las tecnologías que permiten a las máquinas comprender, procesar y responder al lenguaje humano de forma natural. El término "IA conversacional" engloba a chatbots y asistentes virtuales que pueden ejecutar tareas u ofrecer información basándose en entradas de voz o texto (boost.ai, 2024).
- **IA Débil**: sistemas diseñados para realizar tareas o funciones específicas dentro de un marco limitado. Estos sistemas funcionan basándose en algoritmos predefinidos y no son capaces de razonar o aprender de forma independiente más allá de sus tareas programadas (Voitsekhovich et al., 2022).
- **IA Fuerte/General**: dícese de la IA que alcanzó la singularidad tecnológica¹. Es capaz de igualar y/o superar a la inteligencia humana en razonamiento y deducción (Serón Arbeloa, 2023).
- **IA Generativa**: se refiere a los sistemas de inteligencia artificial que tienen la capacidad de crear nuevos contenidos, como imágenes, texto o sonido, sin copiar directamente información preexistente. Estos sistemas pueden generar resultados novedosos aprendiendo patrones y estructuras a partir de los datos con los que se entrenan, lo que les permite producir contenidos originales (Voitsekhovich et al., 2022).

Inteligencia de datos²: término que describe el almacenamiento y análisis de conjuntos de datos y/o complejos mediante una serie de

¹ https://en.wikipedia.org/wiki/Technological_singularity

² <https://www.fundeu.es/recomendacion/macrodatosalternativa-abig-data-1582/>



técnicas que incluyen, entre otras: bases de datos no relacionales, *MapReduce* y aprendizaje automático (Ward y Barker, 2013).

Large Learning Model (LLM): véase **Modelo de lenguaje**.

Machine Learning: véase **Aprendizaje automático**.

Modelo: sistema informático o programa que normalmente incorpora redes neuronales y es capaz de aprender creado con técnicas de aprendizaje automático. Observa datos y tareas, y «aprende» tras haber sido expuesto a ellos millones de veces (Torrijos, 2023).

- **Corpus:** conjunto de textos con los que se entrenan los modelos de lenguaje, se extraen normalmente de la miríada informacional acumulada en Internet desde hace décadas (Torrijos, 2023).
- **Modelo de lenguaje:** Un modelo aplicado al lenguaje, la continua exposición a los términos utilizados en textos le hace comprender información textual de manera estadística. Ejs.: BERT, BETO, MARIA... (Torrijos, 2023).
- **Temperatura:** parámetro utilizado por algunos modelos de lenguaje como GPT. Se trata de un valor numérico entre 0 y 1 que modifica el nivel de «creatividad» y espontaneidad del modelo de lenguaje (Lim, 2023).
- **Token:** unidad básica de texto o de entrada que se procesa individualmente por el modelo de lenguaje. Cuando se alimenta texto al modelo, se descompone en tokens antes de ser procesado (Google for Developers, s.f.). En cierta manera, los *tokens* pueden compararse a los pesos de las redes neuronales, pero en el contexto de un modelo de lenguaje.

Neurona: véase **Red Neuronal**.

Peso: véase **Red Neuronal**.

Prompt¹: solicitud o instrucción que se utiliza en el contexto de programación y la interacción con sistemas de Inteligencia Artificial, como modelos de lenguaje. Generalmente es un fragmento de texto que es proporcionado como entrada para solicitar una respuesta o una acción específica del sistema (Serón Arbeloa, 2024).

¹ No hay un consenso sobre el término correcto en castellano, por lo que en éste caso y en el siguiente se mantienen los términos originales en inglés.
<https://twitter.com/Fundeu/status/164102987716471808>



- **Prompt engineering:** procedimiento sistemático de creación y mejora de *prompts* con la intención de obtener respuestas específicas y favorables de los modelos de lenguaje (Aljanabi et al., 2023).

Red Neuronal: Las redes neuronales son un conjunto de algoritmos, inspirados en el cerebro humano y diseñados para reconocer patrones. Interpretan datos sensoriales a través de una especie de percepción, etiquetado o agrupación de los datos en bruto. Los patrones que reconocen son numéricos, contenidos en vectores, a los que todos los datos del mundo real, ya sean imágenes, sonido, texto o series temporales, deben traducirse. Una red neuronal es un bucle de retroalimentación correctiva en la que se recompensa a los pesos que apoyan las conjeturas correctas, y se castiga a los pesos que la llevan a error (Cappelen y Dever, 2021).

- **Arquitectura (de una red neuronal):** Organización de las neuronas en una red neuronal, es determinante para su efectividad en el propósito que se persiga (Torres, 2023).
- **Entrenamiento (de una red neuronal):** proceso de afinar los parámetros de las conexiones entre las neuronas para que todas ellas converjan poco a poco, de forma iterativa, en los valores adecuados (Torres, 2023).
- **Neurona (artificial):** unidad que se puede parametrizar en base a dos funciones principales: la función de entrada o combinación y la función de activación o transferencia. Cada neurona combina los valores de entrada, aplicando sobre ellos una función de entrada o combinación. El valor resultante es procesado por una función de activación, que modula el valor de las entradas para generar el valor de salida, este valor se propaga a las conexiones con otras neuronas o bien, si no hay más neuronas, es empleado como valor salida de la red (Bosch Rué et al., 2019).
- **Peso:** El peso de las neuronas es un valor ajustable que dicta lo sensibles que son (Torres, 2023). Es el umbral a partir del cual una neurona se activa y envía energía a través de sus conexiones de salida hacia otras neuronas.
- **Sesgo (algorítmico):** también llamado sesgo del aprendizaje automático o sesgo de algoritmo, se refiere a la aparición de



resultados sesgados debido a sesgos humanos que distorsionan los datos de entrenamiento originales o el algoritmo de IA, lo que conduce a resultados distorsionados y potencialmente perjudiciales (Holdsworth, 2023).

Sistema experto / por reglas: software basado en reglas y condiciones concretas proporcionadas por un experto humano para realizar tareas que, pudiendo ser muy complejas, son siempre muy específicas (Grosan y Abraham, 2011).

Temperatura: véase **Modelo**.

Token: véase **Modelo**.

Vectorización: proceso por el que los vectores numéricos que representan los datos entienden el significado y contexto de los mismos mediante estadística sofisticada. Hay modelos entrenados para realizar este proceso y asignar vectores relacionados a diferentes datos en torno a un contexto. (Torrijos, 2023).



2.2. LA IA CONVERSACIONAL

La IA conversacional, en el momento de la redacción del presente trabajo, supone una revolución con millones de usuarios diarios. La más famosa de ellas, ChatGPT de OpenAI, registró más de 4 millones de usuarios en España a fecha de octubre de 2023¹. Calcular un número más reciente resulta una tarea difícil, debido a un cambio reciente en la plataforma por el cual ya ni siquiera es obligatorio tener una cuenta de usuario para hacer uso de ChatGPT². A estos usuarios habría que sumarles aquellos que prefieren otras IAs como Google Gemini, Microsoft Copilot o Amazon Q...

En resumen, hay millones de usuarios utilizando estas herramientas para múltiples cuestiones, de entre los cuales son de nuestro interés aquellos que consultan sus necesidades informativas a la IA en busca de respuestas que, seguramente, serán la mayoría.

Henrickson y Meroño-Peñuela aseveran que la opinión pública está polarizada entre los que son excesivamente optimistas con las posibilidades de la IA conversacional y aquellos que son críticos con sus capacidades y señalan a la estulticia general que demuestran motores como ChatGPT. Tal vez esas personas críticas sean una minoría silenciosa, puesto que las opiniones acostumbran a gravitar en torno a la casi omnipotencia de estas IAs y, en un tono más negativo, el miedo que causan por su capacidad para la desinformación o el reemplazo de puestos de trabajo.

Sea como fuere, cabe aducir a la labor principal de la Documentación como ciencia, que no es otra que la de realizar todos los procesos que sean menester, desde el proceso de entrada hasta la consulta por parte del usuario, para controlar, ordenar y facilitar el acceso a la información. A menudo en forma de representaciones de documentos compuestas de datos ordenados, como las fichas de catálogo, posibilitando así la creación de nuevas obras y conocimiento.

¹ Marín, J. A. (2023, noviembre 30). ChatGPT crece en España: El número de usuarios se triplica en solo un año. La Razón. https://www.larazon.es/emergente/chatgpt-crece-espana-numero-usuarios-triplica-solo-ano_20231130656833dd91707700010e6284.html

² Asenjo, S. (2024, abril 2). Ya puedes usar la versión web de ChatGPT sin tener una cuenta de usuario. Xataka Móvil. <https://www.xatakamovil.com/nuevo/puedes-usar-version-web-chatgpt-tener-cuenta-usuario>



La IA generativa de texto puede posibilitar la generación de información relevante, conocimiento y resolver problemas de índole informacional, alineándose con la función de la Documentación en la sociedad. La clave está en un buen uso de esta tecnología.

La IA conversacional, como el resto de tipos de IA, es dependiente de un aprendizaje mediante enormes volúmenes de datos y documentos para entrenar los algoritmos de su red neuronal. Desde las Ciencias de la Documentación se han creando, a lo largo de décadas, estándares y normas para la representación ordenada y estructurada de datos correctamente extraídos de las fuentes originales, independientemente del soporte en el que se encuentren, añadiendo a dichas representaciones los correspondientes metadatos. El dato es la unidad mínima de la información; por ello, junto con el metadato, ha sido también materia directa de estudio y tratamiento por parte de esta ciencia, que también acostumbra al manejo y confección de bases de datos relacionales y no relacionales.

Un ejemplo práctico de esta labor se halla en los *sets* de datos provenientes de bibliotecas, archivos y museos, los cuales sirven como insumos fundamentales para el entrenamiento de redes neuronales y otros algoritmos. El uso de estos datos no solo impulsa la innovación tecnológica, sino que también contribuye a la preservación digital y al análisis de colecciones culturales y bibliográficas a gran escala (Martínez Méndez et al., 2020).

Los populares chatbots masivos, como ChatGPT, son IA basada en el paradigma de las IAs por fuerza bruta. En la mayoría de casos son ideadas y financiadas por grandes empresas que han creado un modelo de lenguaje que quieren aplicar y perfeccionar. El corpus de estos modelos de lenguaje descomunales, como lo es GPT, no es particularmente selecto pues, como se explicó, en este paradigma lo fundamental es llevar al máximo exponente las 3 constantes de la IA: algoritmia, procesamiento y cantidad de datos.

Por ello no es extraño que hayan alcanzado tal magnitud, que la totalidad de la Wikipedia representaba en torno al 3% de toda la información con la que se alimentó a GPT-1, la primera versión creada en 2018 (Torres, 2023). La versión actual es GPT-4, se pueden imaginar que ahora el porcentaje será mucho menor. El otro 97% fue, en román paladino, toda la información que pudieran encontrar a lo largo y ancho de Internet.



Pero, ¿hay algún filtro en la información y datos con los que se alimenta a estos gigantescos modelos de lenguaje? Filtrar y «limpiar» los datos con los que se va a alimentar un modelo es el trabajo de lo que se conoce como *Data Trainers* quienes usan varias técnicas como¹:

- 1.** Filtros de calidad basados en «clasificadores» y reglas heurísticas tales como el idioma, factores métricos y estadísticos, palabras clave...
 - Clasificador: Modelo de aprendizaje automático que se entrena para predecir la calidad o categoría de nuevos datos de texto basándose en características extraídas de la entrada de datos (Sun et al., 2023).
- 2.** Eliminación de duplicados.
- 3.** Filtro de privacidad: como la mayoría de datos de entrenamiento pertenecen a fuentes web, es muy importante filtrar información privada como nombres, direcciones y teléfonos.

Atendiendo a las posibilidades técnicas, es muy difícil hacer filtros de calidad eficientes y aplicables a tal volumen de datos, sobre todo cuando la noción de calidad, junto a la de relevancia, es una de las más difusas en lo que a información se refiere. Estos filtros, dado el volumen de datos, deben ser automáticos; lo que siempre actuará en perjuicio de la calidad de los datos, por muy buenos que sean los filtros.

Y más importante que todo lo antedicho: estas IAs conversacionales «generalistas» basadas en fuerza bruta, no tienen por objetivo la veracidad de la información. La finalidad de los modelos de lenguaje que hay detrás de los chatbots es perfeccionar el uso del lenguaje y sus registros con el fin de replicar el habla y la escritura humanos prácticamente a la perfección, capacidad de la cual se pretende sacar rédito económico. El contenido es secundario (Torrijos, 2023).

La red neuronal de una IA conversacional no comprende el «fondo» de los textos que genera, de hecho, las respuestas son generadas palabra a palabra calculando, en base a parámetros estadísticos derivados de su corpus y su entendimiento del lenguaje, cuál es la palabra más probable, después de la anterior (Torres, 2023).

¹ Naveed, H., Khan, A. U., Qiu, S., Saqib, M., Anwar, S., Usman, M., Akhtar, N., Barnes, N., & Mian, A. (2024). *A Comprehensive Overview of Large Language Models* (arXiv:2307.06435). arXiv. <https://doi.org/10.48550/arXiv.2307.06435>



Estos parámetros estadísticos radican en la transformación de términos y símbolos del lenguaje en *tokens*. El *token* con un valor calculado más elevado será seleccionado como la palabra más adecuada en términos de lenguaje pero, como el corpus está pobremente filtrado y es masivo, los chatbots son dados a formar frases gramaticalmente perfectas, pero de contenido pobre o directamente falso. La investigadora Emily M. Bender acuñó el término *stochastic parrot* (loro estocástico) en su artículo *On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?* para describir la formación de párrafos perfectos a nivel de forma, pero sin comprensión del significado por parte de los modelos de lenguaje (Wikipedia, 2024d).

Si la IA se alimentara tan solo de informaciones controladas, verídicas y correctamente formadas y estructuradas...

Existen varias formas de que sea así, todas relacionadas total o parcialmente con las Ciencias de la Documentación. Una de ellas es la que propuso el Dr. Blázquez Ochando en la conferencia *La IA en tus manos*¹, dentro del proyecto ConocimIA. En ella Blázquez nos muestra cómo creó y entrenó su propia IA en un servidor de arquitectura XAMPP con 64 GB de RAM, una gráfica integrada AMD Radeon 680M y un 1 TB de disco duro SSD. Esto fue posible usando el modelo PrivateGPT, al cual alimentó con centenares de artículos científicos en torno a la recuperación de información filtrados (o «curados») por él mismo. El resultado para búsquedas específicas en ese campo, apoyadas en las fuentes con las que se alimentó el modelo, fue muy satisfactorio. Cabe hacer hincapié en que se enseñó a la IA a citar las fuentes y así lo hacía en todas sus respuestas.

Una de las ideas principales a las que lleva todo esto es que IA conversacional no sólo hace referencia a los grandes modelos y sus chatbots, existen ya IAs conversacionales minoritarias diseñadas específicamente para atender búsquedas especializadas y/o científicas como lo son *Perplexity*, *Scopus AI* o *Elicit*; a las que habrá que añadir otros proyectos que están ahora mismo en desarrollo como Intel Aurora genAI².

¹ Blázquez Ochando, M. (2024, abril 26). Conferencia ConocimIA - La IA en tus manos. https://www.youtube.com/watch?v=cb2n_IQ4-XE

² Pastor, J. (2023, mayo 23). Intel prepara su propio ChatGPT para el ámbito científico. Uno con un trillón de parámetros. Xataka. <https://www.xataka.com/robotica-e-ia/intel-prepara-su-propio-chatgpt-para-ambito-cientifico-uno-trillon-parametros>



Una vez explicados a grandes rasgos los fundamentos de las grandes IAs conversacionales, es momento de aprender a utilizarlas de modo más efectivo.



2.3. «PROMPT ENGINEERING» Y RECUPERACIÓN DE INFORMACIÓN

En relación directa con el uso de IAs conversacionales está el uso de *prompts*. Todo aquel *input* textual proporcionado a una IA, independientemente de la calidad de su factura, es un *prompt*. Así las cosas, todas aquellas técnicas de creación y optimización de *prompts* para un fin específico son *prompt engineering*.

Puede hallarse una definición de *prompt engineering* en [2.1. Glosario de términos](#), otra posible definición sería: «El *prompt engineering* es el proceso de diseñar, refinar y optimizar los *prompts* para comunicar eficazmente la necesidad del usuario a un modelo de lenguaje.» (Ekin, 2023).

Siendo esto así, parece sensato pensar que esta es una habilidad relacionada con las Ciencias de la Documentación, particularmente con la Recuperación de Información (RI). El *prompt engineering* supone la aplicación de los fundamentos de la Recuperación de Información, aplicados normalmente a Sistemas de Recuperación de Información (SRI) y bases de datos, al nuevo medio que son los grandes modelos de lenguaje gracias a los cuales «se comunica» la IA.

Pero hay una diferencia acusada en el proceso que, como documentalistas debemos destacar: en un entorno clásico de RI, el usuario lanza una consulta a un sistema que alberga documentos; el sistema, en base a unos determinados criterios de relevancia, ofrece sus documentos en forma de resultados de búsqueda. Será el usuario quien navegue entre los resultados en busca de las respuestas, dentro de ellos, a su necesidad informativa.

Por contra, en una IA conversacional el funcionamiento es diferente; pareciéndose, salvando las distancias, a los *Featured snippets* que incorporan algunos buscadores para responder directamente a las búsquedas, sin que el usuario tenga que hacer clic en ninguno de los resultados orgánicos. El usuario accede a una IA esperando un generador de respuestas sin pasar por los documentos, ni siquiera por un proceso de búsqueda.



El problema radica en que el corpus de documentos con los que se entrena el modelo de lenguaje en el que se apoya la IA es inmenso, y cómo se ha dicho con anterioridad, en las IAs más socorridas (ChatGPT, Google Gemini...) no está garantizada la veracidad de las informaciones que componen dicho corpus. Esta circunstancia es, desde nuestros medios, inalterable; sólo podemos escoger otra IA más adecuada a nuestras necesidades a la que insertar *prompts*, de manera similar a como en la RI clásica cuando escogemos la fuente de información en la que realizar consultas.

En una última nota, puede ser interesante exponer brevemente una intersección entre IA y Recuperación de Información: la RI Neuronal:

- **RI Neuronal**, del inglés *Neural IR*, se refiere a la aplicación de redes neuronales superficiales o profundas a tareas de recuperación de información. Pudiendo servir estas para ordenar documentos por relevancia para una consulta o, a una mayor escala, para crear modelos de recuperación de información que representan el texto de los documentos como vectores en un espacio mediante una gran cantidad de parámetros a ajustar (Craswell y Mitra, 2017)¹.

Es más que probable que la RI Neuronal sea una evolución directa de los modelos vectoriales de RI, a los que se han ido añadiendo los últimos avances en IA.

2.3.1. *La Recuperación de Información clásica y su aplicabilidad a la IA conversacional*

Independientemente de cuál sea la herramienta a la que se acuda en busca de información y/o respuestas, desde la Recuperación de Información se enfatiza la importancia de los aspectos previos a la utilización de la herramienta. Es el marco teórico y conceptual de la RI del que podemos sacar el máximo partido como documentalistas para interactuar con los grandes modelos de lenguaje.

El proceso de RI comienza desde la detección de una necesidad informativa en el usuario, resumiendo a Lluís Codina: un vacío del

¹ Para mayor profundidad a este respecto se recomienda leer: Mitra, B., & Craswell, N. (2017). *Neural Models for Information Retrieval* (arXiv:1705.01509). arXiv. <https://doi.org/10.48550/arXiv.1705.01509>



conocimiento necesario para conseguir sus objetivos. Desde la detección de la necesidad, el usuario la habrá de expresar en una consulta, un proceso complejo de traslación de dicha situación a conceptos y estructuras que le resulten más aproximados al objeto de recuperación dentro del lenguaje natural, en la mayoría de casos (Blázquez Ochando, 2012).

La capa en la que el proceso va a diferir es, en materia de procedimientos, en la elaboración de una ecuación de búsqueda al sistema. Puesto que ya no se está utilizando un sistema de recuperación de información, en el sentido ortodoxo de la expresión; se utiliza una IA conversacional. Al cambiar el sistema utilizado, nuestros conocimientos previos dejan de aplicar estrictamente.

Un especialista en recuperación de información debe saber manejar aquellos sistemas que puedan resolver y presentar correctamente necesidades informativas de la manera más eficaz y eficiente posible; y si estos nuevos sistemas son las IAs conversacionales, el especialista debe tener amplias nociones de *prompt engineering*.

Así como cualquiera puede realizar consultas a un SRI, sólo los usuarios avanzados o los especialistas pueden confeccionar ecuaciones de búsqueda complejas utilizando varias técnicas como el uso de operadores lógicos o caracteres especiales para optimizar los resultados de las búsquedas. De la misma manera, cualquier usuario puede arrojar *prompts* a una IA, que devolverá las respuestas que su red neuronal pondere como pertinentes al *prompt* insertado; pero lo que distingue a los usuarios avanzados o, en este caso, los especialistas, será formar *prompts* complejos mediante técnicas de *prompt engineering* durante las interacciones con la IAs.

En la mayoría de casos la diferencia no parecerá tan acusada a nivel formal como con una ecuación de búsqueda compleja, puesto que estas IAs ya entienden el lenguaje natural con soltura y por ello no es necesario usar lenguajes ni caracteres para adaptarse a «cómo nos entiende el sistema», la IA conversacional ya nos entiende a nosotros casi a la perfección. El cambio radica en la lógica aplicada a la inserción del *prompt* o aquella que se sostiene durante toda la interacción con la IA, las demostraciones y ejemplos de «cómo luce» un *prompt* bien formado podrán verse en [2.3.2 Técnicas de prompt engineering](#).



Pero no sólo son aprovechables las cuestiones previas a la interacción con el sistema, sea de recuperación de información o de IA. Es también útil repasar la noción de «relevancia» dentro de la RI, entendida como la relevancia a nivel del usuario que recibe la información y no a nivel del sistema que la provee. Al final del proceso de recuperación, el usuario evalúa la información recibida por un profesional o sistema, comprobando si es relevante, esto es: si resuelve su necesidad informativa, llenando el vacío de conocimiento que dio origen al proceso.

El usuario o especialista debe ser especialmente cauto en estos últimos compases del proceso puesto que, como se ha indicado en reiteradas ocasiones, estas herramientas, aunque potentísimas, tienden al error y al sesgo, especialmente si no se presta la debida atención a la composición del *prompt*.

El deber de servir información verdadera y contrastada conlleva la obligación de contrastar con fuentes externas (proporcionadas por la IA o no), como mínimo, aquellos puntos de la respuesta de la IA que nos resulten dudosos o susceptibles de ser «misinformation», a falta de un término mejor en castellano.

2.3.2. Técnicas de Prompt Engineering

Independientemente de la IA conversacional que se escoja, todas están formadas por grandes modelos de lenguaje. Esta es una noción muy importante, pues, aunque existen técnicas concretas de *prompting* para cada IA; las IA son, por la naturaleza de los modelos de lenguaje, similares y presentan denominadores comunes en muchos aspectos. Siendo esto así, existen unos cuantos usos y procedimientos que pueden considerarse «universales».

Uno de estos usos universales es la estructura de un *prompt*, la estructura que se presenta a continuación no es la única planteada desde el *prompt engineering*, pero se ha probado como funcional en varios modelos de lenguaje y aplica, por su simpleza, a las más de las necesidades posibles. Aun así, entiéndase como una recomendación, no todas las partes son necesarias en todas las situaciones para que el *prompt* sea correcto o funcional.



Sus elementos son los siguientes¹:

- 1. Instrucción:** Una orden concreta y específica que guía el comportamiento del modelo hacia el resultado que deseamos. Se relaciona profundamente con el verbo principal del *prompt*, pero no se limita a este.
Ejs.: «Resume este texto», «Lista los 5 últimos presidentes de España», «Redacta un correo electrónico» ...
- 2. Contexto:** Información externa o adicional que proporciona trasfondo al modelo, ayudándolo a generar respuestas más precisas, relevantes y adecuadas dentro del marco conceptual de nuestro interés.
- 3. Dato(s) de entrada:** aquellos datos que queremos que el modelo procese aplicándoles la instrucción o dando una respuesta. Constituye el núcleo de la pregunta y determina la comprensión de la tarea por parte del modelo.
- 4. Indicador de salida:** Especifica el tipo o formato de salida deseado. Ayuda a dar forma a la respuesta definiendo si necesitamos una respuesta corta, un párrafo o cualquier otro otro formato específico.

Un ejemplo de *prompt* simple que sigue esta estructura:

Clasifica el sentimiento general del texto en neutro, negativo o positivo

Texto: ¡Hola, mundo!

El texto lo dijo un script en C en el año 1974.

Clasificación del sentimiento en una palabra:

Podemos ver que sus partes son:

- 1. Instrucción:** «Clasifica el sentimiento general del texto en neutro, negativo o positivo»
- 2. Contexto:** «El texto lo dijo un script en C en el año 1974.»
- 3. Dato(s) de entrada:** «Texto: ¡Hola, mundo!»
- 4. Indicador de salida:** «Clasificación del sentimiento en una palabra:»

¹ Giray, L. (2023). Prompt Engineering with ChatGPT: A Guide for Academic Writers. *Annals of Biomedical Engineering*, 51(12), 2629-2633. <https://doi.org/10.1007/s10439-023-03272-4>



Además de formar el *prompt* adecuado de acuerdo a las necesidades propias o ajenas, en cuanto al uso de las palabras y al contenido deben evitarse algunos de los errores más comunes en la comunicación de dichas necesidades y órdenes a la IA para optimizar el uso que se hace de ella.

Caer en estos errores puede llevar a respuestas indeseadas, imprecisas o directamente erróneas; pero, llegado el caso, pueden corregirse los *prompts* utilizados o enmendar el error en *prompts* posteriores. El *prompt engineering*, como la recuperación de información, es un proceso iterativo (Ekin, 2023). Los errores se resumen en¹:

1. Ambigüedad: deriva directamente del uso de lenguaje natural para interactuar con la IA, pese a lo avanzado de los modelos de lenguaje, aún es conveniente vigilar las posibles polisemias y homonimias de los términos utilizados.

La ambigüedad también puede venir dada por una falta de especificidad en el contenido del *prompt*. El *prompt* «Describe las consecuencias de la COVID-19 en las personas» sería ambiguo puesto que las consecuencias pueden ser de muchos tipos (económicas, psicológicas, demográficas...) y el sintagma «en las personas» acota muy poco el contexto.

2. Prompts demasiado específicos: *a priori* sobreespecificar puede parecer algo positivo, pero esta es una situación equivalente al silencio en las búsquedas en el contexto de la recuperación de información.

En ocasiones puede ser interesante obtener más resultados para ampliar el foco de la búsqueda y mayor cantidad de resultados relacionados o más amplios. En una nota similar, ampliar los *prompts* hace que el modelo genere más información y nociones relacionadas con el contexto del *prompt* que pueden ser de utilidad para el usuario.

3. Falta de contexto: Muy similar al problema de la ambigüedad, pero dado concretamente en el contexto. En un *prompt* del tipo «Resume el estado de la economía en el mundo», la instrucción está bien formada «Resume el estado de la economía», pero el contexto «en el mundo» es vago, por lo que obtendrá una

¹ Giray, L. (2023). Prompt Engineering with ChatGPT: A Guide for Academic Writers. *Annals of Biomedical Engineering*, 51(12), 2629-2633. <https://doi.org/10.1007/s10439-023-03272-4>



respuesta generalista e insatisfactoria, mejor sería preguntar por alguna noción concreta como la inflación o por los tipos de interés, circunscrita a un país o región determinada.

- 4. Refuerzo de sesgos:** respecto a los sesgos algorítmicos por parte de la IA poco se puede hacer salvo usar otra IA conversacional (o usar varias y contrastar sus respuestas).

Este error se refiere a los sesgos cognitivos por parte del usuario. Conviene releer los *prompts* una vez compuestos o incluso pedir segundas opiniones a otras personas o a la propia IA con tal de detectar si, por cómo se redacta o por los términos que utiliza, el *prompt* refuerza sesgos de alguna índole.

Un *prompt* como «Explica por qué GNU/Linux es superior a Windows e iOS» estaría evidentemente sesgado; los chatbots acostumbran a corregir sesgos tan patentes, pero es un imperativo deontológico evitar incluir sesgos en los *prompts* con tal de generar la información más aséptica y exacta que el modelo permita.

- 5. Expectativas irreales:** la novedad de la IA y la incompreensión de la mayoría de usuarios respecto a lo que es y cómo funciona hace que, pese a ser una herramienta potentísima, en ocasiones se le soliciten tareas que (por el momento) no puede acometer. Lo grave de caer en este error es que la IA prácticamente nunca admitirá no poder responder, por lo que puede generar una respuesta «confiada» para satisfacernos pero que no se apoya en información real, por ello se deben usar con cautela y contrastar todas aquellas respuestas sospechosas con fuentes de información en las que sí se pueda confiar (Giray, 2023).

Una vez entendida la estructura elemental de un *prompt* y los errores a evitar en la composición de *prompt*, cabe exponer una lista de técnicas algo más avanzadas y concretas para componer *prompts*.



Las técnicas listadas a continuación se han extraído principalmente de¹:

1. White, J., Fu, Q., Hays, S., Sandborn, M., Olea, C., Gilbert, H., Elnashar, A., Spencer-Smith, J., & Schmidt, D. C. (2023). *A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT* (arXiv:2302.11382). arXiv. <https://doi.org/10.48550/arXiv.2302.11382>
2. Ekin, S. (2023). *Prompt Engineering For ChatGPT: A Quick Guide To Techniques, Tips, And Best Practices*. <https://doi.org/10.36227/techrxiv.22683919.v2>
3. Korzyński, P., Mazurek, G., Krzyrkowska, P., & Kurasinski, A. (2023). Artificial intelligence prompt engineering as a new digital competence: Analysis of generative AI technologies such as ChatGPT. *Entrepreneurial Business and Economics Review*, 11(3), 25-37. <https://doi.org/10.15678/EBER.2023.110302>

2.3.2.1. Técnicas básicas

Estas son técnicas que pueden usarse directamente en el *prompt* y no requieren de conocimientos técnicos para su uso. Los nombres proporcionados no son oficiales, se han creado tratando de encapsular en cada caso la esencia de la técnica.

- **Refinamiento de *prompts*:** consiste en incluir a la propia IA en el proceso de generar *prompts*, pidiéndole sugerencias de mejora en torno a cómo plantear una consulta o a como perfeccionar el vocabulario o la forma de un *prompt*.

Este método puede ayudar a formar *prompts* sobre ámbitos de los que se tiene escaso o nulo conocimiento (White et al., 2023). El modelo de lenguaje puede asistir al usuario en el uso de tecnicismos y expresiones propias de un campo o ámbito.

En el artículo de White se sugiere la forma «Con el objetivo X, sugiéndome una versión mejor del *prompt* que pueda usar en su lugar» y, en aras de agilizar el proceso, también se puede indicar que cada vez que pidamos este tipo de sugerencias nos pregunte si queremos usar la versión mejorada por la IA.

¹ A modo de aclaración, pese al título de las obras, insisto en que las técnicas son generales, de aplicación a las grandes IAs conversacionales disponibles. El primero de ellos se refiere durante todo su desarrollo a «LLMs», es decir, grandes modelos de lenguaje; el segundo sí está más enfocado a GPT, pero de éste sólo se han usado las técnicas más avanzadas y aquellas coincidentes con la primera fuente. El tercero vuelve a una línea más general.



Es importante indicar el objetivo o el campo al que se refiere el *prompt* con tal de que la IA no haga meras correcciones de estilo o se limite a cambiar nuestras palabras por sinónimos.

- **El juego de rol:** en este método, que puede incluirse un *prompt* o aplicarse antes, se le pide a la IA que responda como si fuera algo o alguien, como si de un juego de rol se tratara. Es un método efectivo que normalmente se usa con oficios.

Ejs.: «Responde como si fueras un Doctor en Información y Documentación», «En adelante, respóndeme como lo haría un abogado».

- **Justificación de respuestas:** es sabido que la IA en ocasiones comete errores, una buena manera de detectar si se está en una de esas ocasiones es solicitar que nos justifique cómo ha llegado a las conclusiones que presenta, obligándola a «pensar», proveer razonamientos, fuentes de información o corregirse si ella misma detecta alguna incongruencia.

Esto puede hacerse mediante *prompts* del estilo «Justifica tu respuesta anterior», «Explica el razonamiento detrás de tu anterior respuesta», «Proporciona fuentes de información que apoyen esa respuesta» ... Si se prefiere que esta justificación sea una constante durante la interacción, pueden completarse los *prompts* comenzándolos con «Cada vez que generes una respuesta ... [justifícala, aporta razonamientos ...]».

Siempre que se soliciten fuentes de información hay que tener muy en cuenta el modelo con el que se está conversando. Las IAs «académicas» serán más proclives que las generalistas a dar fuentes correctas en campos complejos.

- **Subdivisión de *prompts*:** se ha demostrado que los grandes modelos de lenguaje pueden resolver cuestiones más complejas y alcanzar resultados mejores si se les presentan varios *prompts* pequeños y relacionados, en lugar de presentar toda la cuestión en un único *prompt*¹. Por ello, es interesante ordenarle a la IA que subdivida los *prompts* en preguntas más pequeñas, para luego combinar todas esas respuestas pequeñas en una gran respuesta.

¹ Zhou, D., Schärli, N., Hou, L., Wei, J., Scales, N., Wang, X., Schuurmans, D., Cui, C., Bousquet, O., Le, Q., & Chi, E. (2023). *Least-to-Most Prompting Enables Complex Reasoning in Large Language Models* (arXiv:2205.10625). arXiv. <https://doi.org/10.48550/arXiv.2205.10625>



Esta técnica es muy parecida a otra cuyo fin es la resolución de tareas, en dicha técnica el usuario «cambia los papeles» con la IA presentándole una tarea a realizar y ordenándole que le haga todas las preguntas necesarias para realizarla con éxito (White et al., 2023). Puede utilizarse con prompts como: «Hazme todas las preguntas necesarias para [redactar una reclamación a la Administración Pública, hacer un determinado *script* en shell...]».

- **Evasión de negativas:** en algunos casos la IA, por las políticas de la empresa que hay tras ella u otras limitaciones que perciba, se negará a responder a un determinado *prompt*. Cuando esto ocurre es posible solicitarle, de forma similar a la técnica de refinamiento, que ajuste la forma o los términos que componen el *prompt* insertado para que forme uno que sí esté dispuesta a responder. En un caso así, pueden usarse fórmulas como: «Dame varias versiones alternativas de la pregunta anterior que sí podrías responder».

2.3.2.2. Técnicas avanzadas

Estas técnicas se diferencian de las anteriores en que la persona que las aplica necesita mayor reflexión en el contenido del *prompt* y/o conocimientos de IA o herramientas externas para poder usarse adecuadamente. Sin embargo, esta circunstancia hace que mediante estas técnicas se obtengan mejores resultados.

Control de temperatura: «temperatura» es el nombre del parámetro que usan sólo algunos modelos de lenguaje como GPT. Se trata de un valor numérico entre 0 y 1 que modifica el nivel de «creatividad» y espontaneidad del modelo de lenguaje (Lim, 2023).

Una temperatura cercana a 0 proporcionará respuestas más concisas y seguras, mientras que un valor próximo a 1 dará respuestas más diversas y creativas, pero con un potencial descenso en la coherencia de la respuesta (rUv, 2023). En entornos profesionales de recuperación y presentación de información sería conveniente bajar ligeramente la temperatura.

Este valor (o su homólogo en otro modelo) puede modificarse desde la interfaz, antes de insertar el *prompt*, en el propio *prompt* o modificando el valor directamente en una API. Para modificaciones

insertas en un *prompt*, es suficiente con poner el valor deseado usando «temperatura=x.x» (Lim, 2023).

Para ver mejor el uso y apreciar las diferencias, he aquí un ejemplo de aplicación de la temperatura en ChatGPT usando el mismo *prompt*, pero con temperaturas diferentes:

Escribe una breve carta. temperatura=0.1	Escribe una breve carta. temperatura=0.9
Querido [Nombre], Espero que esta carta te encuentre bien. Quería tomarme un momento para expresarte mi gratitud por tu amistad y apoyo. Tu presencia en mi vida ha sido un regalo invaluable, y estoy verdaderamente agradecido por cada momento compartido. Recuerda que siempre estaré aquí para ti, como tú lo has estado para mí. Espero que este mensaje te encuentre en un buen momento y te traiga un poco de alegría. Con cariño, [Tu nombre]	Querido amigo, ¡Espero que esta carta te encuentre lleno de energía y emoción! Quiero tomarme un momento para decirte lo agradecido que estoy por tenerte en mi vida. Desde nuestras aventuras locas hasta nuestros momentos de risas desenfrenadas, cada instante a tu lado ha sido una bendición. Recuerda siempre que estamos juntos en esto, en las alturas de la montaña y en los valles profundos. ¡Aquí estoy, listo para más locuras y risas infinitas! Con todo mi cariño y gratitud, [Tu nombre]

Aunque la temperatura sea un valor presente sólo en algunos modelos, otras IAs sin valor de temperatura ofrecen posibilidad de modificar sus respuestas para realizar un ajuste similar, si no idéntico. Si no la ofrecieran, también podría cambiarse, aunque de forma menos controlada, mediante el *prompt*, solicitando respuestas más formales o más creativas.




Figura 1: Elección de «estilos de conversación» en Microsoft Copilot. Fuente: elaboración propia.




Figura 2: Función «modificar respuesta» en Google Gemini. Fuente: elaboración propia.

Generación de visualizaciones: aunque se estén usando IAs generativas de texto, en ciertas situaciones puede ser de interés generar imágenes o diagramas para facilitar la comprensión o mejorar la presentación de algunas informaciones al usuario. Para usar esta técnica necesitamos un conocimiento somero de alguna herramienta de visualización o generación de imágenes y/o gráficos, como Graphviz Dot o DALL-E (White et al., 2023).

Los modelos de lenguaje son capaces de generar código para software, de manera similar, pueden componer descripciones o instrucciones que otros softwares ejecuten para generar una imagen o gráfico concreto. Ej.: «Genera un/a (imagen, gráfico, esquema...) que pueda usar en (DALL-E, Graphviz Dot, Jupyter Notebooks...) para recrearlo y visualizarlo.

Al usar como *prompt* «Genera un gráfico básico sobre la demografía (población total y tasa de natalidad) en el mundo por continentes que pueda usar en Jupyter Notebooks para recrearlo y visualizarlo», la IA respondió:

Entendido, puedo generar un gráfico básico sobre la demografía mundial por continentes. Utilizaré barras para representar la población total y líneas para la tasa de natalidad. Por favor, ten en cuenta que necesitarás una biblioteca de visualización de datos como Matplotlib en Python para recrear este gráfico en Jupyter Notebooks.

Aquí está el código Python que puedes usar en Jupyter Notebooks:

```
import matplotlib.pyplot as plt
```



```
# Datos de ejemplo: población total por continentes en miles de millones
continentes = ['Asia', 'África', 'Europa', 'América', 'Oceanía']
poblacion_total = [4.6, 1.3, 0.7, 1.1, 0.05] # En miles de millones

# Datos de ejemplo: tasa de natalidad por continentes (por cada 1000 personas)
tasa_natalidad = [18, 30, 10, 15, 12]

# Crear la figura y los subplots
fig, ax1 = plt.subplots()


# Configurar el primer eje y dibujar la población total
color = 'tab:blue'
ax1.set_xlabel('Continentes')
ax1.set_ylabel('Población Total (miles de millones)', color=color)
ax1.bar(continentes, poblacion_total, color=color)
ax1.tick_params(axis='y', labelcolor=color)

# Configurar el segundo eje y dibujar la tasa de natalidad
ax2 = ax1.twinx()
color = 'tab:red'
ax2.set_ylabel('Tasa de Natalidad (por cada 1000 personas)', color=color)
ax2.plot(continentes, tasa_natalidad, color=color, marker='o')
ax2.tick_params(axis='y', labelcolor=color)

# Ajustar el diseño del gráfico
fig.tight_layout()

# Mostrar el gráfico
plt.title('Demografía Mundial por Continentes')
plt.show()
```

Al insertar ese código en una celda de Jupyter Notebooks y ejecutarlo se generó el siguiente gráfico:





Creación de «metalenguajes»: en ciertos campos, como las matemáticas o la programación puede resultar de utilidad dar instrucciones de índole semántica a la IA, creando un lenguaje alternativo para la representación de conceptos complejos, abriendo la posibilidad de *prompts* más elaborados y ricos.

Esta técnica se usa mediante construcciones del tipo «Cada vez que diga X, quiero decir (o me gustaría que hicieras) Y», pero hay que tener mucho cuidado con no generar nuevas ambigüedades o problemas semánticos entre nuestro «metalenguaje» y el lenguaje natural, aunque en estos casos la IA tiende a corregir o a advertir de esta circunstancia (White et al., 2023). Por ejemplo, no es posible usar «y» para nombrar concepto alguno por los problemas de interpretación que generaría con la conjunción «y» del castellano.

El ejemplo que ponen White et al. se refiere a representación de puntos y formas en un espacio, y es, traducido, así:

«A partir de ahora, siempre que escriba dos identificadores separados por un “!”, estoy describiendo un grafo. Por ejemplo, «a ! b» describe un grafo con los nodos «a» y «b» y una arista entre ellos. Si separo los identificadores por «-[w:2, z:3]!», estoy añadiendo las propiedades de la arista, como un valor o una etiqueta».

Uso de APIs: puede que esta sea una de las herramientas más potentes, con ella se pueden corregir algunos de los problemas fundamentales de la IA como la falta de actualización, veracidad o especialización del corpus de la IA; pese a ello, en este trabajo, sólo se ha podido constatar su funcionamiento en ChatGPT y Google Gemini. Microsoft Copilot parece tener serios problemas con identificar APIs en *prompts*.

Es muy importante tener en cuenta que esta técnica no aplica a las versiones en línea de estas IAs, puesto que no pueden ejecutar APIs externas por cuestiones de seguridad, para usarla sería necesario un desarrollo local, con todo lo que ello conlleva: instalación de librerías, descarga de un modelo preentrenado, escribir el código en un entorno de desarrollo¹...

De tener esa IA local, pueden usarse APIs de todo tipo para mejorar la calidad de la información generada y los resultados: BBDD

¹ Toda la información de este párrafo se ha extraído en base a consultas a las propias IAs, las cuales, aun no pudiendo ejecutar APIs, se prestan a ayudar con los pasos y el código para que el usuario pueda hacerlo en un entorno local.



(Wikidata, OpenWeatherAI...), redes sociales (X/Twitter...), traducción (DeepL, Google Translate...).

Un ejemplo simple pero útil para ver el potencial de esta técnica es el generado por Ekin en *Prompt Engineering For ChatGPT: A Quick Guide To Techniques, Tips, And Best Practices*, en el cual mediante una API puede hacer que un modelo ChatGPT haga resúmenes de temas complejos, utilizando la API de Wikipedia aplicada a un artículo concreto como es, en este caso, el procesamiento del lenguaje natural:

```
import wikipediaapi

wiki = wikipediaapi.Wikipedia("en")
page_title = "Natural language processing"
page = wiki.page(page_title)
summary = page.summary[0:500]

prompt = f"The Wikipedia summary of {page_title} is:\n{summary}\nCan you provide a concise explanation of natural language processing in your own words?"

chatgpt_response = chatgpt.generate(prompt)
```

Este fragmento de código en Python accede a los datos de Wikipedia en inglés mediante la librería *wikipediaapi*, recupera el resumen de esa página y almacena los primeros 500 caracteres para más tarde configurar un *prompt* solicitando una explicación más detallada del tema de la página.

Desde la API de ChatGPT también puede controlarse mucho más la temperatura y otro parámetro útil para controlar el comportamiento del modelo a la hora de generar texto: *top_p sampling*, también llamado *nucleus sampling* (rUv, 2023). *Top_p* establece, nuevamente de 0 a 1, el umbral aceptable de probabilidad acumulada de los *tokens* (Popovic, 2023).

Para entender esto, es conveniente repasar un momento y de manera muy simple el funcionamiento de una red neuronal: las neuronas de la red se activan al recibir un «estímulo» que juzgan como «correcto» o «positivo» para la tarea para la que se entrenaron, en el caso de GPT la tarea es utilizar el lenguaje natural humano de manera correcta. Cuando una neurona acumula varias activaciones en un proceso, se entiende como que el paso por esa neurona es más correcto o positivo (tiene el peso adecuado) para la tarea, pasar por ella da más probabilidades de éxito en el proceso de entrenamiento y ejecución.



En la generación de lenguaje el proceso es muy similar pero a una escala mayor: un *token* se refiere a una unidad básica de texto o de entrada textual (palabra, signo de puntuación, *emoji*...) que se procesa individualmente dentro de un modelo de lenguaje¹.

Configurando *top_p* podemos limitar el umbral de *tokens* considerados para generar la respuesta, utilizando sólo aquellos que acumulen un determinado porcentaje de probabilidad de ser correctos después del *token* anterior (rUv, 2023). Con esto se consigue un control preciso sobre el vocabulario que se utiliza en la respuesta.

Por ejemplo, un *top_p* de 0.1 sólo usará el 10% de los *tokens* más probables. Cuanto más alto sea el valor, el rango de *tokens*, y por ende el número de palabras, aumentará, a riesgo de perder control sobre el vocabulario del modelo (Popovic, 2023).

La combinación de temperatura y *top_p* nos permite un gran control sobre la creatividad y los términos utilizados por el modelo de lenguaje, pudiendo probar varias combinaciones para diferentes casos, según sea la necesidad que el modelo haya de resolver. Para escribir código o resolver ejercicios de formulación química nos convendrá mantener los dos valores al mínimo; sin embargo, si necesitamos un poema o algún otro tipo de texto literario o creativo será mejor aumentar ambos valores.

¹ Google for Developers. (s. f.). *Glosario sobre aprendizaje automático | Machine Learning*. <https://developers.google.com/machine-learning/glossary?hl=es-419>



2.4. ÉTICA PROFESIONAL EN EL USO Y APLICACIÓN DE LA IA

2.4.1. Problemas generales de la IA generativa

Habiendo expuesto qué son las IAs y las maneras más eficaces de usarlas en la generación de texto, es necesario exponer unas breves notas sobre las consecuencias, tanto reales como potenciales del uso de la IA, una herramienta potentísima de la que cabe entender que su uso no es gratuito. El planeta, la información, Internet, y hasta la calidad de las propias IAs se ven afectadas por el mal y abundante uso de esta herramienta.

Un grupo de investigadores demostró que el entrenamiento de un gran modelo con una arquitectura de red neuronal emite unas 284 toneladas de CO² a la atmosfera (Strubell, 2019). Además, aunque la energía que se usara fuera 100% renovable, está demostrado que su uso genera otro tipo de problemas como la generación de residuos (Lee, 2020). Cabría realizar un ejercicio de sensatez en torno a si la cantidad de recursos y agentes contaminantes liberados en el proceso de entrenamiento compensan la calidad obtenida en el uso del lenguaje (Bender, 2021).

Mas allá de los problemas ambientales, la recolección de la ingente cantidad de datos necesaria para el entrenamiento de los grandes modelos de lenguaje que dominan el mercado se ha empezado a realizar de forma más que cuestionable desde la perspectiva de la legalidad vigente en múltiples países, los derechos de los usuarios y los derechos de autor. Así lo demuestra un artículo de investigación del New York Times¹, el cual expone múltiples prácticas reprochables de las principales empresas tecnológicas para alimentar sus modelos de IA desde 2021, de entre las cuales destacan:

- 1.** Tanto OpenAI como Google han usado sistemas automáticos para transcribir vídeos de YouTube, incorporando las transcripciones al corpus de sus respectivos modelos de lenguaje sin el

¹ Metz, Cade, Cecilia Kang, Sheera Frenkel, Stuart A. Thompson, y Nico Grant. «How Tech Giants Cut Corners to Harvest Data for A.I.» *The New York Times*, 6 de abril de 2024, sec. Technology. <https://www.nytimes.com/2024/04/06/technology/tech-giants-harvest-data-artificial-intelligence.html>.



consentimiento de los creadores del contenido y quebrantando las reglas de YouTube contra el acceso a los vídeos «mediante sistemas automáticos como robots, botnets o crawlers».

2. Google modificó los términos de su política de privacidad para poder acceder a los datos que los usuarios guardan y generan en sus herramientas en línea como Google Docs, las hojas de cálculo y las presentaciones de Google, además de otros servicios como Google Maps, para usarlos en el entrenamiento de sus modelos de IA.
3. Meta confirmó haber utilizado datos con derechos de autor disponibles en Internet para el corpus de sus sistemas de IA, pese a que esta empresa, en general, ha sido más comedida en cuanto al entrenamiento de modelos debido a los escándalos revelados hace unos pocos años en torno a Cambridge Analytica.

Estos comportamientos tienen su móvil en que, al ritmo actual, se usan más datos para alimentar IA de aquellos a los que estas empresas tienen acceso (Metz, 2024). Por el funcionamiento de los modelos actuales, sabemos que es vital que tengan acceso a más y más datos para poder mejorar, pudiendo hacerlo de manera indefinida; así lo demostró Jared Kaplan, de OpenAI, en su artículo *Scaling Laws for Neural Language Models*. En los modelos de lenguaje, el progreso es cuestión de escala.

Se calcula que alrededor de 2026, las grandes tecnológicas se quedarán sin datos de calidad con los que alimentar a sus IAs (Villalobos, 2022). Pues se están utilizando a un ritmo mucho mayor del que se producen; por ello y para mantener el ritmo de crecimiento que, como demostró Kaplan, sólo es posible si hay más datos, algunas compañías están desarrollando información sintética, esto es, datos producidos por la propia IA (Metz, 2024).

Esta situación puede causar problemas agudos, pues si la IA comienza a entrenarse con información generada por sí misma, reforzará sus sesgos y errores tomándolos como correctos, diluyendo el peso y valor de la información genuina de calidad ya presente en el corpus.

El progreso descontrolado, ante el cual el Derecho no está teniendo tiempo a reaccionar mientras sucede, ha hecho que especialistas en IA junto a ciertos sectores y asociaciones pidan un alto en el desarrollo de



estos modelos para ser capaces de legislar a respecto y estudiar con mayor detalle las consecuencias de todo tipo que tiene el desarrollo y uso de modelos. Este movimiento se conoce como el *Pause Giant AI Experiments*, surgido a partir de la publicación por el *Future of Life Institute* de la carta homónima¹.

2.4.2. Ética de la IA Generativa, como usuarios y profesionales

A lo largo del presente trabajo se han ido exponiendo diferentes riesgos y problemáticas concernientes a las IAs generativas, desde aquellos presentes por su arquitectura y componentes hasta los causados por un uso deficiente o malintencionado.

A nivel de uso, cabe seguir unas pautas básicas de actuación en el uso, junto a otras a las que es recomendable someter todo el contenido textual que se genere por medio de una IA para mantener los resultados lo más neutros que nos sea posible:

- 1.** Uso de lenguaje aséptico en los *prompts*, para que no refuercen estereotipos o sesgos de ninguna índole que el modelo pudiera aprender, reforzar y difundir en otras respuestas.
- 2.** En línea con lo anterior, conocer y estudiar los sesgos que la IA conversacional que se elija puede tener, así como atender los posibles sesgos cognitivos que nosotros mismos, como usuarios, podamos expresarle a la IA. Estos sesgos en las respuestas deben detectarse y tratar de neutralizarse o mitigarse.
- 3.** Evaluar y contrastar los resultados obtenidos con fuentes reputadas en el ámbito del que versen. Especialmente aquellos datos que no resulten verosímiles o en los cuales se tenga escasa confianza.

¹ Future of Life Institute. «Pause Giant AI Experiments: An Open Letter». *Future of Life Institute* (blog), 23 de marzo de 2023. <https://futureoflife.org/open-letter/pause-giant-ai-experiments/>.



4. No tomar las respuestas de la IA un como producto final. Es imprescindible usar los resultados de la IA conversacional como información orientativa o primer esbozo de un trabajo final de recuperación de información (o de otra índole), más elaborado y complementado con fuentes y conocimientos fiables. Es imperativo, también, solicitarle a la IA dichas fuentes independientemente del resultado que pueda darnos.



3. CONCLUSIONES

Tras el estudio y desarrollo de las diferentes partes que componen este trabajo, concretamente [2.2 Estado de la cuestión](#), puede concluirse que la IA es una *vieja nueva* tecnología; en el sentido de que, aun habiéndose vuelto especialmente popular y vigente de un tiempo a esta parte, su desarrollo, métodos y paradigmas que la han llevado a alcanzar su estado actual llevan ideados desde hace décadas. Sus antecesores más rudimentarios, los sistemas expertos, también llevan décadas inventados y en funcionamiento.

Pero esta circunstancia no exime de que, a medida que la IA ha tomado peso en la ciencia y la sociedad, los *legos* hayamos tenido que adquirir todo un vocabulario y marcos conceptuales que nos son nuevos. Para poder entender y aplicar nuevas tecnologías con tanto potencial, nos es necesaria una apoyatura terminológica sólida. Desde este trabajo se han hecho los mejores esfuerzos para tratar de suplir esa necesidad, mediante [2.1 Glosario de términos](#).

El manejo de tales términos responde a que, para el uso satisfactorio de cualquier herramienta se requiere el entendimiento, aunque sea superficial, de su funcionamiento y componentes. Así sucede también con las IAs conversacionales, cuyo conocimiento pasa por el conocimiento claro y distinto de conceptos como «modelo», «red neuronal» o «token». Hemos hecho una presentación concisa y elemental en torno al funcionamiento de las IA conversacionales en [2.2 La IA conversacional](#). Estas cuestiones, tan ajenas en principio a la práctica profesional de la Documentación, son necesarias en estos tiempos y están en algunos aspectos relacionadas, por ejemplo, con la Recuperación de Información.

Y no tienen por qué sernos cuestiones extrañas, ni mucho menos ajenas, siendo que gran parte de la población y las instituciones tienen interés y han comenzado a usar las inteligencias artificiales, se abre una ventana de oportunidad harto interesante también para profesionales de la Gestión de Información.

Sería un movimiento interesante que las unidades de información adoptaran esta nueva tecnología reflejando su compromiso por la información correcta y contrastada y que, como lo hizo el Dr. Blázquez,



entrenaran sus propias IAs con la información de la que ya disponen en abundancia, filtrada y seleccionada por los especialistas que allí trabajan, para su uso por parte de los trabajadores o, inclusive, de los usuarios.

Mas la creación, entrenamiento y mantenimiento de una IA conversacional tiene grandes costes y requiere de competencias digitales y tecnológicas avanzadas, es poco realista sugerir que cada biblioteca tenga su propia IA. No obstante, sería plausible la cooperación institucional por parte de grandes ligas de unidades de información como REBIUN o el Consejo de Cooperación Bibliotecaria que hicieran IAs conversacionales públicas, fiables y gratuitas para su uso por parte de los usuarios. Entrenar y distribuir esta herramienta sería un servicio similar al que se hace sirviendo documentos, cambia el soporte (o la tecnología, si se prefiere), pero la información, en un modelo con un corpus desarrollado por especialistas en Documentación, podría ser virtualmente la misma, sólo que servida de manera más comprensible (gracias a los modelos de lenguaje), cómoda y automática.

En este trabajo el principal esfuerzo ha sido el de relacionar esta tecnología con la Recuperación de Información por medio del *prompt engineering*. Pero está claro que existen otros muchos prismas desde los que aplicar la IA, con su potencia actual, a la Documentación como Ciencia. Varios han sido los estudios de posibles aplicaciones en el momento de la redacción; yendo desde la aplicación de chatbots y agentes inteligentes a la atención de los usuarios (García Marco, 2022a), hasta la aplicación a ámbitos más históricos dentro de los entornos documentales como el reconocimiento automático de talleres de imprenta desde la tipografía de incunables (Pedraza Gracia, 2023) o el uso de redes neuronales para la transcripción e identificación de documentos antiguos (García Marco, 2022b).

Volviendo a lo que a este trabajo respecta, consideramos que queda establecido el paralelismo entre la RI y el *prompt engineering*, principalmente en el punto [2.3 «Prompt engineering» y Recuperación de Información](#). Puede resultar atrevido, en el estado actual de la IA, vaticinar que en ella está el futuro de la resolución de necesidades informativas; pero, independientemente de que la IA generativa sea una revolución o sólo un invento más, conviene actualizarnos y seguir



con atención las nuevas posibilidades de recuperación y generación de información.

La aplicación de estas herramientas debe pasar, ineludiblemente por una profunda reflexión en torno a sus riesgos y consecuencias, tanto a escala reducida e inmediata (calidad de la información) como a un nivel más global y a largo plazo (problemas medioambientales, de derechos de autor...).

Más allá del objetivo principal, creemos que los objetivos secundarios también se han logrado con relativo, si no total, éxito, en tanto el trabajo presenta una ayuda y nociones elementales de IA adaptadas al contexto de la Documentación. Dentro de esta nuestra disciplina parece conveniente y necesario aprender nociones de *prompt engineering*, precisamente por los paralelismos mostrados con el RI y el nuevo paradigma que parece abrirse ante nuestro campo, para optimizar nuestros procesos y el servicio que damos a nuestros usuarios en forma de información o, a mayor escala, productos informacionales, sin perder la calidad que se espera de profesionales de la Documentación.



4. REFERENCIAS

- Aljanabi, M., Yaseen, M. G., Ali, A. H., & Mohammed, M. A. (2023). Prompt Engineering: Guiding the Way to Effective Large Language Models. *Iraqi Journal For Computer Science and Mathematics*, 4(4), Article 4.
<https://doi.org/10.52866/ijcsm.2023.04.04.012>
- Asenjo, S. (2024, abril 2). *Ya puedes usar la versión web de ChatGPT sin tener una cuenta de usuario*. Xataka Móvil.
<https://www.xatakamovil.com/nuevo/puedes-usar-version-web-chatgpt-tener-cuenta-usuario>
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610-623. <https://doi.org/10.1145/3442188.3445922>
- Blázquez Ochando, M. (2012, octubre 11). Conceptos básicos en recuperación de información. *Técnicas avanzadas de recuperación de información*.
<https://ccdoc-tecnicasrecuperacioninformacion.blogspot.com/search/label/03.-%20Conceptos%20de%20Recuperaci%C3%B3n%20de%20Informaci%C3%B3n>
- Blázquez Ochando, M. (Director). (2024, abril 26). *Conferencia ConocimIA - La IA en tus manos*. https://www.youtube.com/watch?v=cb2n_IQ4-XE
- boost.ai. (2024, abril 23). *Demystifying Conversational AI*.
<https://boost.ai/blog/what-is-conversational-ai/>
- Bosch Rué, A., Casas Roma, J., & Lozano Bagén, T. (2019). *Deep learning: Principios y fundamentos*. Editorial UOC. <https://elibro-net.usal.idm.oclc.org/es/ereader/bibliotecasusal/126167>
- Cachada Seijo, F., Fernández Luna, J. M., & Huete Guadix, J. F. (2011). *Recuperación de información: Un enfoque práctico y multidisciplinario*. Rama.
- Codina, L. (2017, octubre 28). *Ecuaciones de búsqueda: Qué son y cómo se utilizan en bases de datos académicas*. Lluís Codina.
<https://www.lluiscodina.com/ecuaciones-de-busqueda-bases-datos-operadores-booleanos/>



- Codina, Ll. (2018). Sistemas de búsqueda y obtención de información: Componentes y evolución. *Anuario ThinkEPI*, 12, 77.
<https://doi.org/10.3145/thinkepi.2018.06>
- Ekin, S. (2023). *Prompt Engineering For ChatGPT: A Quick Guide To Techniques, Tips, And Best Practices*.
<https://doi.org/10.36227/techrxiv.22683919.v2>
- Fernández, Y. (2017, junio 11). *Qué son los teraflops y qué miden exactamente*. Xataka. <https://www.xataka.com/basics/que-son-los-teraflops-y-que-miden-exactamente>
- Fondevila, J. F., & Olmo, J. L. del. (2013). *El trabajo de fin de grado en ciencias sociales y jurídicas*. EUNSA.
- Founier, I. (2006). Organización y recuperación de información en Internet: Teoría de los metadatos. *ACIMED*.
<https://www.semanticscholar.org/paper/Organizaci%C3%B3n-y-recuperaci%C3%B3n-de-informaci%C3%B3n-en-de-Founier/5f418b5bb8c745c28bf680bc52d161a56f687044>
- Future of Life Institute. (2023, marzo 23). *Pause Giant AI Experiments: An Open Letter*. *Future of Life Institute*.
<https://futureoflife.org/open-letter/pause-giant-ai-experiments/>
- García Marco, F. J. (Director). (2022a, diciembre 5). *La IA llega a las bibliotecas: Chatbots y agentes inteligentes*.
https://www.youtube.com/watch?v=7bu7DauN_9E
- García Marco, F. J. (Director). (2022b, diciembre 5). *Redes neuronales en la transcripción e identificación de documentos antiguos: Integrando el conocimiento milenario en la red digital*.
https://www.youtube.com/watch?v=YERPZjzPP_4
- García Melero, L. A., & García Camarero, E. (1999). *Automatización de bibliotecas*. Arco/Libros.
- Giray, L. (2023). Prompt Engineering with ChatGPT: A Guide for Academic Writers. *Annals of Biomedical Engineering*, 51(12), 2629-2633.
<https://doi.org/10.1007/s10439-023-03272-4>
- Google for Developers. (s. f.). *Glosario sobre aprendizaje automático*.
<https://developers.google.com/machine-learning/glossary?hl=es-419>



- Grosan, C., & Abraham, A. (2011). Rule-Based Expert Systems. En C. Grosan & A. Abraham (Eds.), *Intelligent Systems: A Modern Approach* (pp. 149-185). Springer. https://doi.org/10.1007/978-3-642-21004-4_7
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5-14.
<https://doi.org/10.1177/0008125619864925>
- Haykin, S. S. (1999). Chapter 2: Learning Processes. En *Neural networks: A comprehensive foundation* (2. ed., [Nachdr.], pp. 50-104). Prentice Hall.
- Henrickson, L., & Meroño-Peñuela, A. (2023). Prompting meaning: A hermeneutic approach to optimising prompt engineering with ChatGPT. *AI & SOCIETY*. <https://doi.org/10.1007/s00146-023-01752-8>
- Holdsworth, J. (2023, diciembre 22). *What is AI bias?* | IBM.
<https://www.ibm.com/topics/ai-bias>
- Illingworth, V. (1985). *Diccionario Oxford de informática* (B. de Mendizabal Allende, Trad.; 1. ed). Díaz de Santos.
- Jurafsky, D., & Martin, J. H. (2024). 15. Chatbots & Dialogue Systems. En *Speech and Language Processing* (3ª).
<https://web.stanford.edu/~jurafsky/slp3/>
- Kaplan, J., McCandlish, S., Henighan, T., Brown, T. B., Chess, B., Child, R., Gray, S., Radford, A., Wu, J., & Amodei, D. (2020). *Scaling Laws for Neural Language Models* (arXiv:2001.08361). arXiv.
<http://arxiv.org/abs/2001.08361>
- Korzyński, P., Mazurek, G., Krzykowska, P., & Kurasinski, A. (2023). Artificial intelligence prompt engineering as a new digital competence: Analysis of generative AI technologies such as ChatGPT. *Entrepreneurial Business and Economics Review*, 11(3), 25-37.
<https://doi.org/10.15678/EBER.2023.110302>
- Lee, F. (s. f.). The Environmental Cost of Green Energy. *Manhattan Institute*. Recuperado 17 de mayo de 2024, de
<https://manhattan.institute/article/the-environmental-cost-of-green-energy/>
- Lim, A. (2023, octubre 28). *How to Adjust the Temperature Parameter of ChatGPT Chats*. PUPUWEB. <https://pupuweb.com/how-adjust-temperature-parameter-chatgpt-chats/>



- Marín, J. A. (2023, noviembre 30). ChatGPT crece en España: El número de usuarios se triplica en solo un año. *La Razón*.
https://www.larazon.es/emergente/chatgpt-crece-espana-numero-usuarios-triplica-solo-ano_20231130656833dd91707700010e6284.html
- Martínez Méndez, F. J., Pastor-Sánchez, J.-A., & López Carreño, R. (2020). Linked open data en bibliotecas: Estado del arte. *Information Research*, 25(2). <https://informationr.net/ir/25-2/paper862.html>
- Metz, C., Kang, C., Frenkel, S., Thompson, S. A., & Grant, N. (2024, abril 6). How Tech Giants Cut Corners to Harvest Data for A.I. *The New York Times*. <https://www.nytimes.com/2024/04/06/technology/tech-giants-harvest-data-artificial-intelligence.html>
- Mitra, B., & Craswell, N. (2017). *Neural Models for Information Retrieval* (arXiv:1705.01509). arXiv. <https://doi.org/10.48550/arXiv.1705.01509>
- Moliner, M. (2008). *Diccionario de uso del español* (2a ed. abreviada). Gredos.
- Naveed, H., Khan, A. U., Qiu, S., Saqib, M., Anwar, S., Usman, M., Akhtar, N., Barnes, N., & Mian, A. (2024). *A Comprehensive Overview of Large Language Models* (arXiv:2307.06435). arXiv.
<https://doi.org/10.48550/arXiv.2307.06435>
- Pareek, S., Gupta, H., Kaur, J., Kumar, R., & Chohan, J. S. (2023). Fuzzy Logic in Computer Technology: Applications and Advancements. *2023 3rd International Conference on Pervasive Computing and Social Networking (ICPCSN)*, 1634-1637. <https://doi.org/10.1109/ICPCSN58827.2023.00273>
- Pastor, J. (2023, mayo 23). Intel prepara su propio ChatGPT para el ámbito científico. Uno con un trillón de parámetros. Xataka.
<https://www.xataka.com/robotica-e-ia/intel-prepara-su-propio-chatgpt-para-ambito-cientifico-uno-trillon-parametros>
- Pedraza Gracia, M., & Lacasta, J. (Directores). (2023, marzo 27). *Reconocimiento automático de talleres de imprenta desde la tipografía de los incunables*. <https://www.youtube.com/watch?v=7OLceQcMBMo>
- Pinto Molina, M. (1989). Introducción al análisis documental y sus niveles: El análisis de contenido. *Boletín de la ANABAD*, 39(2), 323-342.
- Popovic, S. (2023, diciembre 12). *How to Control Temperature in ChatGPT: Effortless Tips for Optimal Results*. Anakin Blog.
<http://anakin.ai/blog/temperature-in-chatgpt/>



- Proyecto UNIDIGITAL IASAC. (2024). *Contenidos*.
<https://unidigitaliasac.unizar.es/contenidos-iasac>
- rUv. (2023, abril 22). *Cheat Sheet: Mastering Temperature and Top_p in ChatGPT API - API*. OpenAI Developer Forum.
<https://community.openai.com/t/cheat-sheet-mastering-temperature-and-top-p-in-chatgpt-api/172683>
- Salvador Oliván, J. A. (2008). *Recuperación de la información* (1a edición). Alfagrama Ediciones.
- Sánchez Casabón, A. I. (2021, febrero 25). *Proceso de búsqueda y obtención de información* [Diapositiva de PowerPoint].
- Serón Arbeloa, F. J. (Director). (2023). *Gente Artificial: De la ficción a la realidad y vuelta a la ficción*. <https://unidigitaliasac.unizar.es/conferencia>
- Serón Arbeloa, F. J. (2024, abril 5). *Introducción a la Inteligencia Artificial (IA) para profesionales de información*. <https://www.sedic.es/taller-introduccion-a-la-inteligencia-artificial-ia-para-profesionales-de-la-informacion-taller-gratuito-y-exclusivo-para-socios-de-sedic/>
- Soria González, I. (1997). *La organización de la información, los lenguajes documentales y la normalización* [Application/pdf]. 58577 bytes.
<https://doi.org/10.20350/DIGITALCSIC/13516>
- Strubell, E., Ananya, G., & McCallum, A. (2019). Energy and Policy Considerations for Deep Learning in NLP. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 3645-3650.
<https://aclanthology.org/P19-1355.pdf>
- Sun, X., Li, X., Li, J., Wu, F., Guo, S., Zhang, T., & Wang, G. (2023). *Text Classification via Large Language Models* (arXiv:2305.08377). arXiv.
<https://doi.org/10.48550/arXiv.2305.08377>
- Torres, J. (2023). *La inteligencia artificial explicada a los humanos* (Quinta edición). Plataforma Editorial.
- Torrijos, C. (2023, enero 20). *Lingüística computacional*.
<https://www.rtve.es/play/audios/un-idioma-sin-fronteras/idioma-sin-fronteras-carmen-torrijos-linguistica-computacional-210123/6780450/>
- UAM, B. P. (2021). *Biblioguías: Biografías de ingenieros: Ramón Llull*.
https://biblioguias.uam.es/Biografias_de_ingenieros/Ramon_Llull



- Urriego-Giraldo, G. (1998). Revolución tecnológica y revolución informática. *Revista Facultad de Ingeniería*, 16, 75-81.
<https://doi.org/10.17533/udea.redin.325763>
- Velasco, J. J. (2012, marzo 8). *Inteligencia Artificial: Ramon Llull y el Ars Magna*. Hipertextual. <http://hipertextual.com/2012/03/inteligencia-artificial-ramon-llull-ars-magna>
- Villalobos, P. (2022, noviembre 10). *Will We Run Out of ML Data? Evidence From Projecting Dataset Size Trends*. Epoch AI.
<https://epochai.org/blog/will-we-run-out-of-ml-data-evidence-from-projecting-dataset>
- Ward, J. S., & Barker, A. (2013). *Undefined By Data: A Survey of Big Data Definitions* (arXiv:1309.5821; Versión 1). arXiv.
<https://doi.org/10.48550/arXiv.1309.5821>
- White, J., Fu, Q., Hays, S., Sandborn, M., Olea, C., Gilbert, H., Elnashar, A., Spencer-Smith, J., & Schmidt, D. C. (2023). *A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT* (arXiv:2302.11382). arXiv.
<https://doi.org/10.48550/arXiv.2302.11382>
- Wikipedia. (2024a). API. En *Wikipedia, la enciclopedia libre*.
<https://es.wikipedia.org/w/index.php?title=API&oldid=158385052>
- Wikipedia. (2024b). Deep Blue versus Garry Kasparov. En *Wikipedia*.
https://en.wikipedia.org/w/index.php?title=Deep_Blue_versus_Garry_Kasparov&oldid=1214600180
- Wikipedia. (2024c). Revolución digital. En *Wikipedia, la enciclopedia libre*.
https://es.wikipedia.org/w/index.php?title=Revoluci%C3%B3n_digital&oldid=158705346#cite_ref-2
- Wikipedia. (2024d). Stochastic parrot. En *Wikipedia*.
https://en.wikipedia.org/w/index.php?title=Stochastic_parrot&oldid=1219321686
- Wikipedia. (2024e). Technological singularity. En *Wikipedia*.
https://en.wikipedia.org/w/index.php?title=Technological_singularity&oldid=1220610612
- Zhou, D., Schärli, N., Hou, L., Wei, J., Scales, N., Wang, X., Schuurmans, D., Cui, C., Bousquet, O., Le, Q., & Chi, E. (2023). *Least-to-Most Prompting Enables Complex Reasoning in Large Language Models* (arXiv:2205.10625). arXiv. <https://doi.org/10.48550/arXiv.2205.10625>