

3. Tecnologías avanzadas de IA Generativa

- [3.1 Prompting y RAG](#)
- [3.2 Fine Tuning](#)
- [3.3 Agentes de IA y Automatización](#)

3.1 Prompting y RAG

En los últimos años han aparecido herramientas de inteligencia artificial capaces de entender y generar texto con bastante precisión. Para utilizarlas bien en el aula, especialmente en materias científicas, conviene comprender dos ideas clave: cómo se les da instrucciones y de dónde obtienen la información con la que responden. A la primera se la conoce como *prompting* y a la segunda, cuando se apoya en documentos externos, como *RAG*.

El *prompting* puede entenderse como el arte de hacer buenas preguntas. No se trata solo de pedir algo, sino de orientar a la herramienta para que produzca una respuesta adecuada al nivel, al contexto y al objetivo didáctico. Es parecido a lo que ocurre en clase cuando un profesor formula una pregunta: si la pregunta es vaga, la respuesta también lo será; si está bien planteada, guiada y contextualizada, el alumnado responde mejor. Con la inteligencia artificial sucede lo mismo. No es lo mismo pedir “explica la energía” que pedir “explica el concepto de energía para alumnado de 3º de ESO, con un ejemplo relacionado con el deporte y sin usar fórmulas”. En el segundo caso, la respuesta será mucho más útil en un contexto real de aula. El *prompting*, por tanto, no es una cuestión técnica compleja, sino una extensión de una habilidad que el profesorado ya domina: saber cómo preguntar para enseñar.

Sin embargo, incluso con buenas instrucciones, la inteligencia artificial responde en función de lo que ha aprendido de forma general, no necesariamente de los materiales concretos que se están utilizando en clase. Aquí es donde entra el *RAG*. Este enfoque permite que la herramienta consulte previamente documentos específicos, como apuntes, libros o prácticas de laboratorio, antes de generar la respuesta. Se puede entender con un símil muy sencillo: un estudiante puede contestar una pregunta de dos formas, o bien recurriendo solo a lo que recuerda, o bien abriendo el libro, buscando la información exacta y luego explicándola con sus palabras. La diferencia entre ambas situaciones es precisamente la diferencia entre usar una IA sin *RAG* y con *RAG*.

Cuando se trabaja con *RAG*, la respuesta no se basa únicamente en el conocimiento general del modelo, sino en los materiales que el profesorado ha seleccionado. Por ejemplo, si se dispone de un documento con problemas resueltos de cinemática, se puede pedir a la IA que genere nuevos ejercicios similares o que explique un procedimiento siguiendo exactamente el enfoque utilizado en clase. De este modo, se mantiene la coherencia con el temario y se evita que el alumnado reciba explicaciones que, aunque correctas, no encajan con lo que se está trabajando.

La combinación de ambos conceptos resulta especialmente potente. El *prompting* permite definir con claridad qué se quiere obtener, mientras que el *RAG* garantiza que la respuesta se apoye en contenidos fiables y alineados con el aula. Siguiendo con el ejemplo anterior, no es lo mismo pedir “haz un problema de velocidad” que pedir “utilizando estos apuntes de movimiento rectilíneo uniforme, crea un problema similar a los del tema y resuélvelo paso a paso para alumnado de 4º

de ESO". En este caso, la calidad de la instrucción y la calidad de la fuente se refuerzan mutuamente.

En el ámbito de las ciencias, donde la precisión y la coherencia son fundamentales, estas herramientas pueden convertirse en un apoyo muy valioso. Permiten adaptar explicaciones, generar actividades, crear ejemplos contextualizados o incluso simular el tipo de preguntas que haría un alumno. Pero, sobre todo, permiten trasladar al entorno digital algo que siempre ha sido esencial en la enseñanza: saber guiar el proceso de aprendizaje con buenas preguntas y buenos materiales.

Prompting

La **ingeniería del prompting** es el conjunto de técnicas que permiten formular instrucciones eficaces para que un modelo de lenguaje genere respuestas útiles, precisas y adaptadas a un objetivo concreto. En educación, y especialmente en materias como **biología, física, matemáticas y química**, esta competencia resulta cada vez más valiosa. Un modelo de lenguaje puede actuar como asistente del profesorado, generador de actividades, apoyo para preparar explicaciones, herramienta de simulación o incluso recurso para adaptar materiales a distintos niveles. Sin embargo, la calidad del resultado depende en gran medida de cómo se le da la instrucción.

Un prompt no es solo una pregunta. Es una **instrucción estructurada** que puede incluir el rol que debe asumir el modelo, el nivel educativo, el tipo de respuesta esperado, el formato y los criterios de calidad. Por ejemplo, no es lo mismo escribir "explica la fotosíntesis" que pedir: "Actúa como profesor de biología de 4º de ESO y explica la fotosíntesis con lenguaje claro, un ejemplo cotidiano y una comparación con la respiración celular". En el segundo caso, la respuesta suele ser más útil porque el modelo entiende mejor qué se espera de él.

En áreas científicas, el prompting tiene un valor especial porque estas asignaturas suelen exigir **claridad conceptual, secuenciación lógica, precisión terminológica y resolución paso a paso**. Además, permite generar recursos variados: explicaciones, problemas resueltos, prácticas de laboratorio, simulaciones, rúbricas, preguntas tipo test o actividades de ampliación.

Estructura básica de un buen prompt

Un buen prompt suele combinar varios elementos:

- el **rol** del modelo
- el **contexto didáctico**
- el **nivel del alumnado**
- el **objetivo de la tarea**
- el **formato de salida**

- y, cuando conviene, ciertas **restricciones o guardarraíles**

Por ejemplo, en matemáticas podría pedirse:

“ Actúa como profesor de matemáticas de bachillerato. Explica el concepto de derivada de forma intuitiva, después presenta la definición formal y finalmente crea dos ejercicios resueltos paso a paso.

Aquí se define claramente quién debe ser el modelo, para quién explica, cómo debe organizar la respuesta y qué productos debe incluir.

Tipos de prompting

Zero-shot prompting

El **zero-shot prompting** consiste en pedir una tarea directamente, sin dar ejemplos previos. Es la modalidad más simple y una de las más usadas.

Ejemplo en química:

“ Explica qué es el pH y cómo se interpreta una escala de pH en disoluciones ácidas, neutras y básicas.

Ejemplo en biología:

“ Resume las funciones principales del ADN en una célula eucariota.

Ejemplo en física:

“ Resuelve un problema sencillo sobre la segunda ley de Newton con datos numéricos realistas.

Este tipo de prompting funciona bien cuando la tarea es clara, pero en ocasiones la salida puede variar más de lo deseado.



Few-shot o multi-shot prompting

El **few-shot prompting**, también llamado **multi-shot**, consiste en ofrecer uno o varios ejemplos del tipo de respuesta que se espera. Esto ayuda al modelo a imitar estructura, tono y nivel de detalle.

Ejemplo en matemáticas:

“ Ejemplo 1

Problema: Resuelve $3x + 5 = 14$

Solución:

1. Restamos 5 a ambos lados
2. $3x = 9$
3. Dividimos entre 3
4. $x = 3$

Ejemplo 2

Problema: Resuelve $2x - 4 = 10$

Solución:

1. Sumamos 4 a ambos lados
2. $2x = 14$
3. Dividimos entre 2
4. $x = 7$

Ahora resuelve del mismo modo: $5x + 2 = 22$

Ejemplo en química:

“ Ejemplo 1

Sustancia: Agua

Fórmula: H_2O

Tipo: Compuesto molecular

Ejemplo 2

Sustancia: Cloruro de sodio

Fórmula: $NaCl$

Tipo: Compuesto iónico



Ahora completa del mismo modo: dióxido de carbono, amoníaco y óxido de calcio.

Este tipo de prompting resulta muy útil cuando se desean materiales homogéneos, ejercicios con el mismo estilo o respuestas muy controladas.

Chain of Thought prompting

El **Chain of Thought** o razonamiento paso a paso consiste en pedir al modelo que explique su proceso antes de dar la respuesta final. En ciencias, esto es especialmente valioso porque no interesa solo el resultado, sino el procedimiento.

Ejemplo en física:

“ Resuelve paso a paso el siguiente problema y explica qué fórmula aplicas en cada momento: un cuerpo de 4 kg acelera a $2,5 \text{ m/s}^2$. Calcula la fuerza resultante.

Ejemplo en química:

“ Calcula cuántos moles hay en 98 gramos de ácido sulfúrico. Razona el procedimiento paso a paso e indica la masa molar utilizada.

Ejemplo en matemáticas:

“ Resuelve la ecuación de segundo grado $x^2 - 7x + 12 = 0$ explicando paso a paso el método usado.

Este enfoque ayuda a producir respuestas más transparentes y didácticas.

Meta prompts

Los **meta prompts** son instrucciones para que el propio modelo diseñe prompts mejores. Son especialmente útiles para docentes que quieren construir plantillas reutilizables.

Ejemplo:



Diseña un prompt para generar actividades de biología de nivel 4º de ESO sobre genética mendeliana, con una breve explicación inicial, cuatro preguntas y una solución final.

Ejemplo más avanzado:

“ Diseña un prompt de sistema para crear un asistente educativo de química que explique conceptos con rigor, utilice ejemplos de laboratorio escolar y adapte el lenguaje al nivel de bachillerato.

El modelo puede devolver una instrucción lista para usar y refinar. Esto ahorra tiempo y favorece la creación de asistentes especializados.

Prompt inverso

El **prompt inverso** merece una atención especial. Consiste en mostrar al modelo un ejemplo de actividad, contenido o material didáctico ya elaborado, y pedirle que deduzca a partir de ese ejemplo un prompt que sirva para generar otros materiales similares. Es una técnica muy útil para el profesorado, porque muchas veces resulta más fácil enseñar “el tipo de resultado que queremos” que redactar desde cero la instrucción perfecta.

Por ejemplo, un profesor puede mostrar una actividad como esta:

“ Actividad de física:

1. Explicación breve sobre la ley de Ohm.
2. Dos ejemplos resueltos con operaciones paso a paso.
3. Tres ejercicios para el alumnado sin resolver.
4. Una pregunta final para relacionar el contenido con situaciones de la vida cotidiana.

A partir de ahí se puede pedir:

“ Analiza la actividad anterior y redacta un prompt que permita generar actividades similares sobre otros temas de física manteniendo la misma estructura, el mismo tono didáctico y un nivel adecuado para 3º de ESO.

El modelo puede devolver algo como:

“ Actúa como profesor de física de 3º de ESO. Genera una actividad didáctica sobre [tema] con la siguiente estructura: una explicación breve y clara del concepto, dos ejemplos resueltos paso a paso, tres ejercicios para que el alumnado practique de forma autónoma y una pregunta final de aplicación a la vida cotidiana. Usa lenguaje sencillo y rigor científico.

Este enfoque es muy útil para **replicar estilos de materiales propios**, mantener coherencia entre unidades y transformar ejemplos exitosos en plantillas reutilizables.

Otro ejemplo en biología:

“ A partir de este ejemplo de ficha sobre la célula, crea un prompt que sirva para elaborar fichas equivalentes sobre otros orgánulos o procesos celulares.

O en matemáticas:

“ Te voy a mostrar un modelo de problema resuelto de funciones. A partir de él, redacta un prompt que me permita generar otros problemas equivalentes con la misma secuencia didáctica.

El prompting inverso, por tanto, permite pasar de un material concreto a una **fórmula general de producción**.

Tipo de prompting	En qué consiste	Ejemplo en ciencias	Utilidad
Zero-shot	Se pide sin dar ejemplos	“Explica la célula”	Respuestas rápidas y generales
One-shot	Se da un ejemplo	“Ejemplo: problema de velocidad... ahora crea otro”	Guiar el tipo de respuesta
Few-shot	Se dan varios ejemplos	“Ejemplos de reacciones químicas... genera más”	Mayor precisión y coherencia
Con contexto	Se añade nivel o condiciones	“Explica la energía para 1º ESO con ejemplo cotidiano”	Adaptar al alumnado



Tipo de prompting	En qué consiste	Ejemplo en ciencias	Utilidad
Paso a paso	Se pide razonamiento detallado	“Resuelve este problema paso a paso”	Enseñar procedimientos
Con rol	Se asigna un papel a la IA	“Actúa como profesor de física”	Respuestas más pedagógicas
Con restricciones	Se limitan condiciones	“Explica sin fórmulas”	Ajustar dificultad

Tabla compartiva de los tipos de prompt más importantes

Chats personalizados

Los **chats personalizados** permiten configurar de forma persistente cómo debe comportarse el modelo. Esto resulta muy útil cuando se quiere convertirlo en un asistente educativo estable.

Por ejemplo, puede definirse así:

“Eres un profesor de ciencias especializado en biología, física, matemáticas y química. Explicas con claridad, priorizas el razonamiento paso a paso, adaptas el lenguaje a alumnado de secundaria o bachillerato y evitas tecnicismos innecesarios salvo que se pidan expresamente. Cuando generes actividades, incluye objetivos, enunciados claros y, si procede, soluciones.

Con una configuración así, el modelo mantendrá un estilo más coherente a lo largo del tiempo.

Las plataformas más populares como *chatGPT*, *Claude* o *Gemini* implementan estas personalizaciones mediante el uso de GPTs personalizados en el caso de chatgpt o *Gemas* en *Gemini*.

Gem manager

Pre-made by Google

Show more ↕

Experiment

Storybook
Create a customized picture book, for either children or adults, given a topic, an...

Experiment

Chess champ
Play chess with a language model. Make your first move using chess coordinates to...

Brainstormer
Find inspiration easily. Fresh ideas for parties, gifts, businesses and more.

Career guide
Unlock your career potential. Get a detailed plan to refine your skills and achieve your...

My Gems ⓘ

+ New Gem

GenREA
Queremos generar REA Recursos de Aprendizaje de 20 horas de duración siguiendo la estructura del ANEXO I adj...

Vista de un gestor de gemas en Gemini

“ El uso de plantillas en prompting resulta especialmente útil cuando se necesita generar contenido de forma consistente y homogénea, ya que permite mantener siempre una misma estructura, tono y conjunto de instrucciones. En lugar de formular cada petición desde cero, el profesorado puede definir un modelo de prompt reutilizable —similar a lo que ocurre en los chats personalizados— que incluya aspectos como el nivel educativo, el tipo de actividad, el formato de respuesta o los criterios pedagógicos. De este modo, por ejemplo, es posible generar múltiples actividades de ciencias que sigan siempre las mismas reglas, con el mismo tipo de enunciado, dificultad y organización, lo que facilita tanto la preparación de materiales como la coherencia en el aprendizaje del alumnado. Además, estas plantillas reducen el esfuerzo, evitan errores y permiten escalar la creación de contenidos de manera rápida y controlada.

Guardarraíles

Los **guardarraíles** son reglas que limitan o encauzan la respuesta. Ayudan a mantener rigor, evitar errores y ajustar el resultado al uso educativo.

Ejemplos:

“ Si no estás seguro de un dato, indícalo claramente y no lo inventes.
No des la respuesta final sin explicar antes el procedimiento.
Usa siempre unidades del sistema internacional cuando resuelvas problemas de física.
En química, verifica si la ecuación está ajustada antes de continuar.
En matemáticas, comprueba el resultado sustituyéndolo cuando sea posible.

Estos guardarraíles mejoran mucho la calidad pedagógica de la salida.

Bancos de prompts

Un **banco de prompts** es una colección organizada de instrucciones reutilizables. Para un profesor de ciencias puede convertirse en una herramienta muy poderosa.

Algunas categorías útiles serían:

- prompts para explicar conceptos
- prompts para generar ejercicios
- prompts para adaptar materiales a distintos niveles
- prompts para diseñar simulaciones
- prompts para crear evaluación y autoevaluación
- prompts para convertir teoría en actividades prácticas

Un ejemplo de banco en física podría incluir:

“ Genera 5 problemas de cinemática con datos realistas y solución paso a paso. Explica la energía cinética con una analogía sencilla y un ejemplo numérico. Diseña una práctica de laboratorio escolar para estudiar la caída libre.


En biología:

“ Crea una actividad comparativa entre mitosis y meiosis con tabla, esquema y preguntas finales. Resume el proceso de traducción genética con lenguaje adaptado a 1º de bachillerato.

“ Existen numerosas webs de prompts también llamadas bancos de prompting donde pueden encontrarse toda clase de ejemplos e incluso hacer compra venta

Por ejemplo

<https://prompts.chat/>



La Plataforma Social Libre para Prompts de IA

Los prompts son la base de toda IA generativa. Compártelos, descúbrellos y coleccionálos de la comunidad. Gratis y de código abierto — auto-hospeda con privacidad total.

<> Gratis y Código Abierto 🔒 Auto-hospeda para Privacidad

👤 Para Equipos y Organizaciones

[Explorar Prompts](#) [Despliega Tu Servidor Privado](#) [Iniciar sesión](#)

★ Sé el stargazer número 151,520 en GitHub ⌚ Más sobre nuestra historia

o explora por industria

Marketers	Investigadores	Médico
Desarrolladores	Entrenadores	Consultor
Gerentes	Ingenieros	Científico

Haz clic para explorar

CLIENTES

[Linea de Comandos](#) [App Store](#) [Extensión](#)

Ejemplos elaborados por asignaturas

Biología

“ Actúa como profesora de biología de 4º de ESO. Prepara una secuencia breve sobre la fotosíntesis que incluya: una explicación inicial con lenguaje claro, una comparación con la respiración celular, un esquema textual paso a paso, dos preguntas de comprensión y una actividad final en la que el alumnado tenga que explicar por qué la luz influye en el crecimiento de las plantas.

Física

“ Actúa como profesor de física de bachillerato. Diseña una actividad sobre la segunda ley de Newton con esta estructura: introducción conceptual, un ejemplo resuelto con masa y aceleración, otro ejemplo en el que haya que despejar la aceleración, tres problemas propuestos y una pequeña simulación conceptual en la que expliques qué ocurre si la fuerza se mantiene constante pero la masa del objeto se duplica.

Matemáticas



Actúa como profesor de matemáticas de 3º de ESO. Explica las ecuaciones de primer grado con una metáfora sencilla, resuelve dos ejemplos paso a paso, genera cuatro ejercicios graduados en dificultad y termina con una sección de errores frecuentes que suelen cometer los alumnos al despejar incógnitas.

Química

“ Actúa como profesora de química de 1º de bachillerato. Explica la diferencia entre mol, masa molar y número de Avogadro con una analogía fácil de entender. Después resuelve dos problemas de conversión entre gramos, moles y moléculas, y finalmente crea tres ejercicios de práctica con solución al final.

Prompts para simulaciones

Los modelos también pueden utilizarse para crear **simulaciones conceptuales** que ayuden a comprender procesos dinámicos.

Simulación en biología

“ Simula la evolución de una población de bacterias en un medio con abundantes nutrientes durante cinco generaciones. Describe qué ocurre con el tamaño de la población y explica después qué cambiaría si se introduce un antibiótico a partir de la tercera generación.

Simulación en física

“ Simula el movimiento de un coche que parte del reposo y acelera uniformemente a 3 m/s^2 durante 8 segundos. Muestra cómo evolucionan la velocidad y la distancia recorrida en cada segundo y explica el patrón observado.

Simulación en matemáticas



Simula cómo cambia el área de un círculo cuando el radio aumenta de 1 a 6 cm. Presenta los valores en una tabla y explica qué relación matemática se observa entre radio y área.

Simulación en química

“ Simula una neutralización entre ácido clorhídrico e hidróxido de sodio en un laboratorio escolar. Explica qué ocurre antes de mezclar, durante la reacción y al final, tanto a nivel observable como a nivel de partículas.

Conclusión

La ingeniería del prompting no consiste únicamente en “preguntar bien”, sino en **diseñar interacciones eficaces con la IA para obtener materiales didácticos útiles, rigurosos y adaptados al contexto educativo**. En el caso de las asignaturas científicas, su potencial es especialmente alto porque permite generar explicaciones claras, actividades graduadas, problemas resueltos, simulaciones conceptuales y recursos de evaluación.

Técnicas como el **zero-shot**, el **few-shot o multi-shot**, el **Chain of Thought**, los **meta prompts**, el **prompt inverso**, los **chats personalizados**, los **guardarraíles** y los **bancos de prompts** ofrecen al profesorado un repertorio muy amplio para trabajar con modelos de lenguaje de forma sistemática y provechosa.

Entre todas ellas, el **prompt inverso** destaca por su utilidad práctica en educación, ya que permite partir de una actividad o contenido ya conseguido para deducir la instrucción que hará posible generar materiales equivalentes. Eso facilita reutilizar estilos, mantener coherencia metodológica y convertir buenos ejemplos en plantillas estables.

En definitiva, dominar estas técnicas permite al profesorado de biología, física, matemáticas y química transformar un modelo de lenguaje en un verdadero **asistente pedagógico avanzado**, capaz de apoyar la preparación de clases, la creación de materiales y la adaptación de contenidos a distintas necesidades del alumnado.

Retrieval Augmented Generation RAG

Retrieval Augmented Generation (RAG) es una técnica que permite mejorar las respuestas de los modelos de lenguaje conectándolos con fuentes de información externas. En lugar de depender únicamente del conocimiento con el que fue entrenado el modelo, el sistema **busca información**



relevante en una base de datos o en documentos propios y la utiliza para generar la respuesta.

En educación, esta técnica resulta especialmente interesante porque permite crear asistentes que trabajan con **materiales del propio centro educativo**, como apuntes, libros, documentos PDF, artículos científicos, guías de laboratorio o incluso ejercicios elaborados por el profesorado.

Para docentes de áreas científicas como **biología, física, matemáticas o química**, RAG permite construir sistemas que respondan preguntas basándose en contenidos específicos de la asignatura o incluso en el temario concreto de una materia.

RETRIEVAL-AUGMENTED GENERATION O RAG


Hay 3 fases:

1 RETRIEVAL
RECUPERACIÓN

2 AUMENTED
AUMENTO

3 GENERATION
GENERACIÓN

El proceso es el siguiente:



Fuente: Adaptación de <https://www.ml6.eu/blogpost/leveraging-llms-on-your-domain-specific-knowledge-base>

datos.gob.es
reutiliza la información pública

Los modelos de lenguaje tienen algunas limitaciones importantes:

- su conocimiento puede estar **desactualizado**
- pueden **inventar información (alucinaciones)**
- no conocen documentos privados o materiales propios
- no pueden consultar información externa si no se les proporciona



RAG soluciona esto añadiendo una capa de **recuperación de información** antes de generar la respuesta.

El proceso general es el siguiente:

1. El usuario hace una pregunta
2. El sistema busca información relevante en una base de datos de documentos
3. Esa información se añade al prompt
4. El modelo genera la respuesta usando esos datos

De esta forma, el modelo responde **basándose en información concreta y verificable**.

Ventajas de RAG

El uso de sistemas de **Retrieval-Augmented Generation (RAG)** ofrece múltiples ventajas en entornos educativos porque combina la capacidad de generación de los modelos de lenguaje con la consulta de información real procedente de documentos o bases de conocimiento. Al integrar datos externos durante la respuesta, el sistema puede proporcionar información más precisa y contextualizada.

Permite trabajar con contenidos propios

Un sistema RAG puede conectarse con materiales educativos concretos y responder utilizando información procedente de los recursos del curso. Por ejemplo, puede consultar apuntes del profesor, documentos del aula virtual, prácticas de laboratorio o capítulos del libro de texto. De esta forma, el asistente responde basándose en el material real de la asignatura y no solo en el conocimiento general del modelo. Además, RAG permite integrar conocimiento específico de un dominio o institución, lo que hace que las respuestas sean más relevantes para el contexto educativo.

Reduce las alucinaciones

Los modelos de lenguaje pueden generar respuestas plausibles pero incorrectas. Los sistemas RAG reducen este problema porque el modelo genera la respuesta utilizando documentos recuperados como contexto, lo que “ancla” la respuesta en información verificable.

Esto mejora la precisión y la fiabilidad de las respuestas, algo especialmente importante en ámbitos educativos donde la exactitud de la información es fundamental.

Facilita el aprendizaje autónomo

Un asistente basado en RAG permite a los estudiantes consultar el contenido del curso de forma interactiva. El sistema puede responder preguntas sobre el temario utilizando directamente los materiales de clase. Por ejemplo, un estudiante podría preguntar:

“¿Qué diferencia hay entre mitosis y meiosis según los apuntes de la asignatura?”

Al apoyarse en los documentos del curso, el sistema puede ofrecer explicaciones más contextualizadas y coherentes con lo que el profesorado ha enseñado.

Permite crear asistentes especializados

Los sistemas RAG permiten construir asistentes educativos especializados en distintas áreas del conocimiento. Al conectarlos con documentos específicos de cada materia, pueden actuar como tutores o asistentes académicos. Por ejemplo, un sistema RAG puede convertirse en:

- tutor de física que responde dudas sobre los ejercicios del curso
- asistente de laboratorio de química que explica procedimientos experimentales
- consultor de genética que utiliza artículos y apuntes de biología
- ayudante para resolver problemas matemáticos basados en el material de clase

Mejora la transparencia y la confianza en las respuestas

Otra ventaja importante es que muchos sistemas RAG pueden mostrar las fuentes utilizadas para generar la respuesta. Esto permite que los estudiantes revisen los documentos originales y verifiquen la información, lo que aumenta la confianza en el sistema y fomenta el aprendizaje crítico.

En conjunto, los sistemas RAG permiten transformar los modelos de lenguaje en **asistentes educativos basados en conocimiento real del curso**, reduciendo errores, facilitando el aprendizaje autónomo y permitiendo crear herramientas de apoyo especializadas para distintas materias.

Herramientas para crear sistemas RAG

Actualmente existen distintas herramientas que permiten construir **asistentes basados en documentos o conocimiento propio**. Estas herramientas pueden dividirse en dos grandes enfoques: plataformas que permiten crear **chats personalizados de forma sencilla** y herramientas más técnicas para construir sistemas RAG completos.

Icono	Herramienta	Descripción	Utilidad en RAG
	ChatGPT (Custom GPTs)	Permite crear versiones personalizadas del asistente mediante instrucciones, documentos y herramientas. Se puede definir un rol (tutor, analista, etc.) y añadir archivos como base de conocimiento.	Crear asistentes educativos que respondan usando apuntes, PDFs o materiales del curso

Icono	Herramienta	Descripción	Utilidad en RAG
	Claude (Projects)	Ofrece contextos persistentes y trabajo con documentos largos, permitiendo crear asistentes que consultan grandes cantidades de información propia.	Ideal para analizar textos extensos y generar explicaciones basadas en documentos complejos
	Gemini (Gems)	Permite crear asistentes personalizados configurados con instrucciones y conectados con herramientas como Google Drive o Gmail.	Integrar documentos del ecosistema Google y generar respuestas basadas en ellos
	AnythingLLM / herramientas locales	Plataformas que permiten crear sistemas RAG en local cargando documentos y conectando con modelos open source.	Trabajar con datos propios sin depender de la nube (privacidad y control)
	LangChain (framework)	Librería para desarrollar aplicaciones con RAG combinando modelos, bases de datos vectoriales y lógica personalizada.	Crear soluciones avanzadas y automatizadas (más técnico, ideal para proyectos)

Principales herramientas para creación y uso de RAG

Ejemplo sencillo de una Gem para una asignatura de física

Nombre del Gem

Tutor de Física de Bachillerato

Descripción

Asistente que ayuda a comprender conceptos de física, resolver problemas y explicar los ejercicios del temario.

Instrucciones del sistema

Actúa como profesor de física de nivel bachillerato. Explica los conceptos de forma clara y paso a paso. Cuando el estudiante haga una pregunta:


- explica primero la idea física
- después muestra las fórmulas necesarias
- finalmente resuelve el problema paso a paso

Si el alumno comete un error, ayúdale a detectarlo en lugar de dar directamente la respuesta.

Ejemplos de preguntas que podría responder

- ¿Qué diferencia hay entre velocidad y aceleración?
- ¿Cómo se aplica la segunda ley de Newton en este problema?
- Explícame el movimiento parabólico con un ejemplo sencillo.
- Ayúdame a resolver este ejercicio de energía potencial.

Con este tipo de configuración, el sistema se comporta como un **tutor especializado en física**, capaz de responder dudas del temario o ayudar a resolver problemas.



©2024 Google LLC. All rights reserved. Gemini is a trademark of Google LLC. Gemini is a registered trademark of Google LLC. Gemini is a registered trademark of Google LLC.

Vista de la web de Gemini para la creación de Gemas

Conclusión

El Retrieval Augmented Generation (RAG) representa una de las aplicaciones más útiles de los modelos de lenguaje en educación. Al conectar el modelo con documentos reales, se consigue un sistema capaz de responder preguntas basándose en contenidos específicos, actualizados y

verificables.

Para docentes de biología, física, matemáticas y química, esta técnica permite crear asistentes educativos que trabajan con el propio temario del curso, reducen errores, mejoran la precisión de las respuestas y fomentan el aprendizaje autónomo del alumnado.

En lugar de depender únicamente del conocimiento general de un modelo de IA, RAG permite construir sistemas educativos personalizados, adaptados al contenido, al nivel y a las necesidades de cada asignatura. De este modo, los modelos de lenguaje dejan de ser simples chatbots genéricos y se convierten en herramientas didácticas especializadas capaces de apoyar de forma efectiva la enseñanza científica.

Sin embargo, para que todo este potencial se materialice, resulta imprescindible el uso adecuado del prompting. Saber cómo formular instrucciones claras, estructuradas y adaptadas al contexto educativo permite guiar el comportamiento del modelo y obtener respuestas realmente útiles en el aula. El prompting actúa como el puente entre la intención pedagógica del docente y la capacidad de la inteligencia artificial, mientras que el RAG aporta la base de conocimiento sobre la que se construyen las respuestas.

La combinación de ambas técnicas da lugar a un entorno de aprendizaje más preciso, coherente y personalizado, en el que la inteligencia artificial no sustituye al profesorado, sino que amplía sus capacidades, facilitando la creación de materiales, la adaptación de contenidos y el acompañamiento del alumnado en su proceso de aprendizaje.

3.2 Fine Tuning


El *Fine Tuning* Es una técnica que permite adaptar un modelo de inteligencia artificial ya entrenado a una tarea concreta. En lugar de entrenar un modelo desde cero, se parte de un modelo grande que ya ha aprendido conocimientos generales y se le entrena un poco más con datos específicos para que se especialice en un tema determinado.

La idea es parecida a lo que ocurre en educación: un estudiante primero aprende conocimientos generales y después se especializa en una asignatura concreta. Los modelos de IA funcionan de forma similar. Primero se entrenan con grandes cantidades de información general (textos, imágenes, etc.) y después pueden **refinarse con ejemplos específicos** para mejorar su rendimiento en una tarea particular.

Esto permite aprovechar todo el conocimiento que el modelo ya tiene, y solo ajustar algunos aspectos para que funcione mejor en un contexto concreto. Además, requiere **muchos menos datos y recursos** que entrenar un modelo desde cero.

Por ejemplo, un modelo general puede adaptarse para:

- responder preguntas de medicina
- analizar documentos jurídicos
- explicar conceptos de una asignatura
- resolver problemas matemáticos



Proceso general de Fine Tuning, usando datos y modelos preentrenados obtenemos un nuevo modelos capaz de responder a nuevas preguntas



Ejemplo sencillo: entrenar un modelo para resolver problemas de álgebra

Imaginemos que queremos crear un pequeño asistente que ayude a los estudiantes a resolver problemas de álgebra de secundaria. El proceso sería algo así:

1. Partimos de un modelo general de lenguaje (por ejemplo un modelo abierto como LLaMA o Mistral).
2. Creamos un pequeño conjunto de ejemplos con problemas y soluciones paso a paso.
3. Entrenamos el modelo durante unas pocas iteraciones utilizando esos ejemplos.

El dataset de entrenamiento podría tener una estructura muy simple como esta:

Ejemplo 1

Problema:

Resuelve la ecuación $2x + 3 = 11$

Solución:

Restamos 3 a ambos lados:

$$2x = 8$$

Dividimos entre 2:

$$x = 4$$

Ejemplo 2

Problema:

Resuelve $3x - 5 = 10$

Solución:

Sumamos 5 a ambos lados:

$$3x = 15$$

Dividimos entre 3:

$$x = 5$$

Ejemplo 3

Problema:

Resuelve $4x + 2 = 18$

Solución:

Restamos 2:

$$4x = 16$$

Dividimos entre 4:

$$x = 4$$

Después de entrenarse con muchos ejemplos similares, el modelo empieza a **reconocer el patrón de resolución** de ecuaciones lineales. Esto hace que, cuando un estudiante le pregunte algo como:

“Resuelve $5x + 7 = 22$ ”

el modelo sea capaz de responder siguiendo el mismo procedimiento paso a paso.

Este tipo de entrenamiento se utiliza realmente en investigación para mejorar la capacidad matemática de los modelos. Por ejemplo, existen datasets específicos de problemas matemáticos que se utilizan para ajustar modelos de lenguaje y mejorar su razonamiento matemático.

Herramientas para realizar *fine-tuning*

Antes de aplicar el *fine-tuning*, es necesario utilizar herramientas que permitan entrenar o ajustar los modelos con nuevos datos. Existen varias plataformas y bibliotecas que facilitan este proceso y que hoy en día se utilizan ampliamente en investigación, educación y desarrollo de aplicaciones de IA.

Icono	Herramienta	Descripción	Nivel	Utilidad en educación
	Hugging Face (Transformers)	Biblioteca open source para cargar, entrenar y ajustar modelos. Incluye herramientas como <i>Trainer</i> que simplifican el proceso.	Medio	Ideal para proyectos educativos, experimentar con modelos y enseñar fine-tuning de forma estructurada
	PEFT	Permite ajustar modelos entrenando solo una pequeña parte de los parámetros, reduciendo recursos necesarios.	Medio	Adaptar modelos en equipos con pocos recursos (aulas, portátiles)



Icono	Herramienta	Descripción	Nivel	Utilidad en educación
☐☐	LoRA / QLoRA	Técnicas eficientes que añaden pequeñas capas entrenables sin modificar todo el modelo. Muy usadas en modelos grandes.	Medio	Fine-tuning de modelos grandes en entornos educativos sin hardware potente
☐☐	Google Colab + notebooks	Entorno accesible para ejecutar código de entrenamiento sin instalar nada en local.	Básico	Facilitar prácticas guiadas de fine-tuning para alumnado
☐☐	Ollama + datasets propios	Permite trabajar con modelos locales y, en algunos casos, ajustarlos o adaptarlos con datos propios.	Básico-Medio	Experimentar con IA local y privacidad en el aula
☐☐	Google AI Studio / Vertex AI	Plataformas de Google para ajustar modelos mediante interfaces más visuales o semi-guiadas.	Básico	Introducir fine-tuning sin necesidad de programación avanzada
☐☐	OpenAI / APIs similares	Permiten ajustar modelos mediante datasets estructurados y procesos guiados vía API.	Básico-Medio	Crear asistentes especializados sin gestionar infraestructura

Principales herramientas y entornos para hacer fine tuning

Ventajas del *fine-tuning* en educación

El fine-tuning ofrece un gran potencial en el ámbito educativo, y resulta especialmente relevante en ciencias y matemáticas, donde la precisión, el procedimiento y el uso correcto del lenguaje son fundamentales. Sus principales ventajas y posibilidades son:

- **Adaptación al método de resolución en matemáticas y física**

El modelo puede aprender a resolver problemas exactamente como se hace en clase.

Ejemplo: resolver ecuaciones de segundo grado siguiendo siempre los mismos pasos (identificar coeficientes, fórmula, sustitución y resultado), o problemas de cinemática



indicando datos, fórmula, sustitución y unidades.

- **Consistencia en explicaciones científicas**

Mantiene siempre la misma estructura en definiciones y desarrollos.

Ejemplo: explicar la fotosíntesis o la ley de Ohm siguiendo siempre un esquema claro (definición → fórmula → ejemplo → aplicación).

- **Uso correcto del lenguaje técnico**

En ciencias es clave no simplificar en exceso ni cometer errores conceptuales.

Ejemplo: diferenciar correctamente entre masa y peso, o entre calor y temperatura, utilizando unidades y definiciones precisas.

- **Especialización en contenidos concretos**

El modelo puede entrenarse con el temario real del curso.

Ejemplo: trabajar únicamente con los tipos de problemas de química (disoluciones, estequiometría) que se ven en clase, evitando enfoques distintos.

- **Resolución paso a paso (clave en ciencias)**

No solo da el resultado, sino que muestra el proceso completo.

Ejemplo: en un problema de densidad, indicar datos → fórmula → sustitución → resultado con unidades, como se exige en examen.

- **Adaptación al nivel del alumnado**

Ajusta la complejidad según curso.

Ejemplo: explicar un átomo como “un sistema solar” en 1º ESO, o introducir orbitales y niveles energéticos en Bachillerato.

- **Generación automática de ejercicios coherentes**

Permite crear múltiples problemas similares al estilo del profesor.

Ejemplo: generar 10 ejercicios de MRU con la misma estructura que los del examen, variando solo los datos.

- **Corrección y feedback alineado con criterios científicos**

Puede corregir errores siguiendo los mismos criterios que el docente.

Ejemplo: indicar no solo que un resultado está mal, sino que falta unidad, planteamiento o despeje correcto.

- **Creación de tutores virtuales de ciencias y matemáticas**

Asistentes que guían al alumnado en el razonamiento.

Ejemplo: un tutor que no da directamente la solución, sino que va guiando: “¿qué fórmula usarías aquí?” o “¿qué dato te falta?”.

- **Refuerzo del aprendizaje autónomo con rigor**

El alumnado puede practicar sin perder coherencia con el aula.

Ejemplo: un estudiante repasa problemas de física en casa y recibe explicaciones exactamente iguales a las del profesor.

A pesar de sus ventajas, el fine-tuning también presenta una serie de limitaciones que conviene tener en cuenta, especialmente en el ámbito educativo y más aún en materias científicas, donde el rigor es fundamental.



- **Requiere preparación de datos**

Para que el modelo funcione bien, es necesario recopilar ejemplos de calidad y organizarlos correctamente.

Ejemplo: si se quiere entrenar un modelo para resolver problemas de física, hay que preparar muchos ejercicios bien resueltos, con pasos claros y sin errores, lo que implica tiempo y planificación docente.

- **Necesita recursos computacionales**

El entrenamiento de modelos, incluso con técnicas eficientes, suele requerir GPUs o entornos como Google Colab.

Ejemplo: un centro educativo puede encontrar limitaciones si quiere hacer fine-tuning con modelos grandes sin acceso a infraestructura adecuada.

- **Menor flexibilidad que RAG**

Una vez entrenado, el modelo no puede acceder a información nueva automáticamente.

Ejemplo: si se actualiza el temario o se añaden nuevos tipos de ejercicios de química, el modelo no los conocerá a menos que se vuelva a entrenar.

- **Riesgo de reproducir errores o sesgos**

El modelo aprende exactamente de los datos que se le proporcionan.

Ejemplo: si los ejercicios de entrenamiento tienen errores de unidades o planteamiento, el modelo los repetirá de forma sistemática.

- **Rigidez en el enfoque**

Al estar muy ajustado a un estilo concreto, puede perder capacidad de adaptación.

Ejemplo: un modelo entrenado con un único método para resolver ecuaciones puede tener dificultades para entender o generar soluciones alternativas.

- **Mayor complejidad técnica**

A diferencia del prompting o el uso de RAG en plataformas sencillas, el fine-tuning requiere ciertos conocimientos técnicos.


Ejemplo: preparar datasets, ajustar parámetros o evaluar modelos puede ser complejo para profesorado sin experiencia previa en IA.

Conclusión

El fine-tuning es una técnica fundamental para adaptar modelos de lenguaje a dominios específicos. En el ámbito educativo permite crear modelos especializados capaces de trabajar con contenidos científicos concretos y generar materiales didácticos coherentes con el estilo del profesorado.

En asignaturas como biología, física, matemáticas o química, el fine-tuning puede utilizarse para entrenar modelos que expliquen conceptos con mayor claridad, generen ejercicios estructurados o ayuden a preparar materiales educativos.

Combinado con otras técnicas como el prompting avanzado y los sistemas RAG, el fine-tuning abre la puerta a una nueva generación de **asistentes educativos inteligentes** capaces de apoyar tanto al profesorado como al alumnado en el aprendizaje de las ciencias.



Esquema básico de fine tuning

Un símil para entenderlo todo

“ Para comprender mejor cómo funcionan los **modelos de lenguaje (LLM)** y las distintas formas de trabajar con ellos —**prompting, RAG y fine-tuning**— puede ser útil utilizar un símil cercano al mundo educativo: **el desarrollo del cerebro humano y el proceso de aprendizaje a lo largo de la vida.**

“ Podemos imaginar un **modelo de lenguaje como un cerebro** que ha pasado por una primera etapa de aprendizaje muy amplia. Durante ese proceso, el modelo se entrena con enormes cantidades de textos: libros, artículos, páginas web, conversaciones, documentación técnica, etc. Ese entrenamiento inicial sería comparable a **los primeros años de vida de una persona**, en los que adquirimos el lenguaje, la capacidad de interpretar el mundo y una base general de conocimiento. No aprendemos todo en detalle, pero sí desarrollamos una

estructura mental que nos permite comprender, razonar y generar ideas.

A partir de esa base aparece el **prompting**, que podríamos comparar con el papel que juega **la cultura, el contexto y la forma en que se nos plantea una tarea**. Una misma persona puede responder de forma muy distinta según cómo se le formule una pregunta, qué información previa tenga o qué contexto se le proporcione. Lo mismo ocurre con los modelos de lenguaje: el modo en que se redacta una instrucción influye directamente en la calidad y el tipo de respuesta que generan. Desde una perspectiva educativa, aprender a formular buenos prompts se parece mucho a **aprender a hacer buenas preguntas**, algo que siempre ha sido una habilidad fundamental en el aula.

El siguiente concepto, **RAG (Retrieval Augmented Generation)**, puede entenderse como cuando una persona **consulta fuentes externas antes de responder**. Un profesor, por ejemplo, no siempre responde únicamente con lo que recuerda; muchas veces consulta un libro, un artículo o una base de datos para asegurar que la información es correcta o está actualizada. El RAG funciona de forma parecida: el modelo accede a documentos o bases de conocimiento externas y utiliza esa información para generar respuestas más precisas y contextualizadas. En el ámbito educativo, esto permite trabajar con **documentación propia del centro, apuntes, artículos científicos o materiales didácticos**.

Finalmente, encontramos el **fine-tuning**, que podríamos comparar con **la especialización o formación en nuevas materias a lo largo de la vida**. Una persona que ya tiene una base educativa puede especializarse después en medicina, derecho o ingeniería. No empieza desde cero; simplemente adapta y refuerza su conocimiento para un ámbito concreto. Del mismo modo, el fine-tuning consiste en **ajustar un modelo ya entrenado para una tarea específica**, utilizando datos más especializados.

Desde la perspectiva del profesorado, este símil ayuda a entender algo importante: los modelos de IA no son simplemente herramientas automáticas que generan respuestas, sino sistemas que **combinan aprendizaje previo, contexto, acceso a información y especialización**. Comprender estas diferencias permite utilizarlos con mayor criterio en el aula.

Al final, la cuestión no es si la inteligencia artificial “piensa”, sino **cómo podemos integrarla de forma inteligente en los procesos de aprendizaje**. Igual que ocurre con cualquier otra herramienta educativa, su valor depende de cómo se utilice. Cuando se entiende su funcionamiento y sus



límites, los modelos de lenguaje pueden convertirse en **instrumentos para explorar ideas, plantear preguntas, analizar información y fomentar el pensamiento crítico.**

Y quizá esa sea la clave desde el punto de vista pedagógico: no utilizar la IA para que piense por el alumnado, sino **para ayudarles a pensar mejor.**

3.3 Agentes de IA y Automatización

Los **agentes de inteligencia artificial** representan uno de los desarrollos más recientes en la evolución de los sistemas basados en modelos de lenguaje. Mientras que los asistentes de IA ayudan al usuario respondiendo preguntas o generando contenidos bajo demanda, los agentes están diseñados para **actuar de forma autónoma para alcanzar un objetivo**.

En términos generales, un agente de IA es un sistema que recibe información del entorno, toma decisiones y ejecuta acciones para cumplir una tarea.

En el contexto de los modelos generativos actuales, estos agentes suelen utilizar **Large Language Models (LLM)** como motor de razonamiento y planificación.

Para profesores de ciencias, entender el concepto de agente es importante porque abre nuevas posibilidades: desde analizar datos experimentales hasta generar simulaciones, investigar literatura científica o automatizar tareas académicas.

Qué es un agente de IA

Un **agente de IA** puede definirse como un sistema autónomo capaz de:

- recibir un objetivo o tarea
- analizar el problema
- tomar decisiones sobre qué hacer
- ejecutar acciones mediante herramientas
- evaluar los resultados y continuar el proceso.

En otras palabras, los agentes no se limitan a responder preguntas. Su objetivo es **resolver tareas completas**.

En muchos casos el modelo de lenguaje actúa como el “cerebro” que controla el flujo de decisiones del sistema.

Esto significa que el modelo no solo genera texto, sino que también decide:

- qué herramientas usar
- qué información buscar
- qué paso ejecutar a continuación.



Cómo funcionan los agentes de IA

Los agentes modernos suelen funcionar mediante un **bucle iterativo de razonamiento y acción**.

Este ciclo suele incluir varias etapas:

1. **Interpretación del objetivo**
2. **Planificación de acciones**
3. **Uso de herramientas**
4. **Evaluación de resultados**
5. **Repetición del proceso hasta completar la tarea**

Este patrón se conoce en muchos sistemas como **agent loop** o ciclo de ejecución del agente.

Un agente puede ejecutar este ciclo varias veces hasta alcanzar el resultado final.

Arquitectura de un agente

Los agentes se basan en la coordinación y gestión de los siguientes elementos:

Modelo de lenguaje

El modelo de lenguaje actúa como el núcleo del agente, es decir, su “cerebro”. Es el encargado de interpretar las instrucciones, comprender el contexto y generar respuestas o decisiones. No se limita a contestar, sino que también puede proponer pasos a seguir o estrategias para resolver una tarea. Modelos como GPT, Claude, Gemini, Qwen o Llama suelen desempeñar este papel en los agentes actuales.

Memoria

La memoria permite al agente recordar información relevante mientras ejecuta una tarea. Gracias a ella puede mantener el contexto de una conversación, almacenar resultados intermedios o utilizar datos que ha obtenido en pasos anteriores. Esto resulta fundamental cuando el proceso no es inmediato, ya que evita que el agente “empiece desde cero” en cada interacción y le permite trabajar de forma coherente en tareas largas.

Herramientas

Una de las características más importantes de los agentes es su capacidad para utilizar herramientas externas. Estas herramientas amplían sus posibilidades, ya que le permiten



interactuar con el entorno. Por ejemplo, puede buscar información en internet, ejecutar código, consultar bases de datos o utilizar APIs. De esta forma, el agente no depende únicamente de su conocimiento interno, sino que puede obtener información actualizada y realizar acciones concretas.

Planificador

El planificador es el componente que organiza el trabajo del agente. Cuando recibe una tarea compleja, la divide en pasos más pequeños y manejables. Esto le permite avanzar de forma estructurada, revisando cada fase antes de pasar a la siguiente. Por ejemplo, ante el objetivo de analizar artículos sobre energía nuclear, el agente puede planificar primero la búsqueda de información, después la selección de documentos relevantes, a continuación su resumen y finalmente la elaboración de un informe.

Visión conjunta

Estos elementos no funcionan de manera aislada, sino que se combinan continuamente. El modelo de lenguaje decide, la memoria conserva la información, las herramientas permiten actuar y el planificador organiza el proceso. Gracias a esta integración, los agentes pueden abordar tareas complejas de forma más parecida a como lo haría una persona, especialmente en contextos educativos y científicos donde el proceso es tan importante como el resultado.



Funcionamiento básico de un agente

Arquitecturas modernas de agentes

En los sistemas actuales de agentes de inteligencia artificial existen distintas formas de organizar cómo el agente **piensa, decide y actúa**. Estas formas de organización se llaman *arquitecturas*. Cada arquitectura define cómo el agente toma decisiones y cómo utiliza herramientas para resolver un problema.

ReAct (Reasoning + Acting)

Una de las arquitecturas más conocidas es **ReAct**, cuyo nombre viene de “razonar y actuar”. En este enfoque el agente funciona como si siquiera un pequeño ciclo repetitivo: primero piensa qué

debería hacer, después realiza una acción (por ejemplo buscar información o usar una herramienta) y finalmente observa el resultado antes de continuar.

Es parecido a cómo resolveríamos un problema paso a paso: pensamos qué necesitamos, hacemos una prueba, vemos el resultado y volvemos a decidir qué hacer a continuación. Este tipo de arquitectura es muy flexible porque el agente puede ir adaptando su estrategia según lo que va descubriendo.

Plan-and-Execute

Otra arquitectura bastante utilizada es **Plan-and-Execute**. En este caso el agente no actúa inmediatamente, sino que primero intenta elaborar un plan completo para resolver el problema. Después ejecuta ese plan paso a paso.

Podemos imaginarlo como cuando un estudiante planifica un trabajo: primero define los pasos que va a seguir (buscar información, analizar datos, redactar conclusiones) y luego va completando cada parte del plan. Este enfoque suele ser más eficiente cuando las tareas son largas o requieren varios pasos claros.

Multi-agent systems

Una idea más reciente consiste en utilizar **varios agentes que colaboran entre sí** en lugar de uno solo. En estos sistemas, cada agente tiene un papel específico dentro del proceso.

Por ejemplo, en un sistema de investigación automática podríamos tener:

- un agente investigador que busca información
- un agente analista que interpreta los datos
- un agente redactor que prepara el informe final

Cada agente se encarga de una parte del trabajo, y un sistema de coordinación organiza cómo colaboran. Este enfoque se inspira en cómo trabajan los equipos humanos y permite abordar tareas más complejas que las que podría resolver un único agente.

En suma, las arquitecturas de agentes definen **cómo se organiza la “forma de pensar” de un sistema de IA**. Algunas se basan en ciclos de razonamiento y acción, otras en planificación previa, y otras en la colaboración entre varios agentes especializados. Estas ideas son la base de muchas de las aplicaciones más avanzadas de inteligencia artificial actuales.

Aplicaciones de los agentes en educación científica

Los agentes de inteligencia artificial pueden utilizarse en muchos contextos educativos, especialmente en asignaturas científicas como física, química, biología o matemáticas. En lugar de limitarse a responder preguntas, estos sistemas pueden ayudar a **analizar información, investigar temas científicos o generar materiales de aprendizaje**, funcionando como asistentes tanto para estudiantes como para docentes. Además, distintos estudios señalan que el



uso de IA en educación científica puede mejorar la comprensión de conceptos complejos y favorecer el aprendizaje activo del alumnado.

Análisis de datos experimentales

Una de las aplicaciones más interesantes es el análisis de datos obtenidos en experimentos o prácticas de laboratorio. Un agente puede ayudar a procesar información experimental realizando tareas como cargar datos, generar gráficos, interpretar resultados y redactar conclusiones preliminares.

Por ejemplo, en una práctica de física sobre movimiento, el agente podría analizar una tabla de datos de posición y tiempo, calcular velocidades o aceleraciones y representar los resultados en un gráfico. De esta manera, los estudiantes pueden centrarse en interpretar el fenómeno físico en lugar de dedicar todo el tiempo a los cálculos.

Investigación científica

Los agentes también pueden ayudar a investigar temas científicos. En este contexto actúan como asistentes de investigación capaces de buscar información en artículos científicos, identificar ideas clave y resumir resultados relevantes.

Por ejemplo, ante una tarea como *“investiga el impacto del cambio climático en los ecosistemas marinos”*, el agente podría buscar publicaciones científicas, resumir los hallazgos principales, detectar tendencias en los datos y elaborar un pequeño informe. Este tipo de herramientas puede acelerar procesos como la revisión bibliográfica o el análisis de literatura científica.

Generación de simulaciones

Otra aplicación importante es la creación de simulaciones científicas. En muchas áreas de la ciencia se utilizan modelos o simulaciones para comprender cómo se comporta un sistema bajo determinadas condiciones.

Un agente puede ayudar a construir estas simulaciones o a explicar los resultados. Por ejemplo, ante una pregunta como *“simula qué ocurre con un gas cuando se reduce su volumen”*, el sistema podría explicar el fenómeno utilizando la ley de Boyle, generar una tabla de valores o mostrar un gráfico que represente la relación entre presión y volumen.

Las simulaciones basadas en IA también permiten experimentar con fenómenos que a veces no son fáciles de reproducir en un laboratorio real.

Diseño de actividades educativas

Además de ayudar al alumnado, los agentes pueden apoyar al profesorado en la creación de materiales didácticos. Un agente puede generar ejercicios, diseñar cuestionarios o proponer actividades de aprendizaje relacionadas con el temario.

Por ejemplo, un docente podría pedir al agente que:

- genere ejercicios de física sobre movimiento uniformemente acelerado
- cree cuestionarios de química sobre enlaces químicos
- diseñe una actividad de laboratorio para estudiar reacciones ácido-base

De esta manera, el agente actúa como un **asistente pedagógico**, un tipo de sistema diseñado específicamente para interactuar con estudiantes y apoyar el aprendizaje dentro de entornos educativos.

En conjunto, estas aplicaciones muestran cómo los agentes pueden convertirse en **herramientas de apoyo al aprendizaje científico**, ayudando a analizar datos, investigar información, crear simulaciones y diseñar actividades educativas. Utilizados correctamente, pueden complementar el trabajo del profesorado y facilitar que el alumnado explore los contenidos científicos de forma más activa y autónoma.

Principales herramientas para agentes

Icono	Herramienta	Tipo	Descripción	Utilidad en educación y ciencias
	LangChain	Framework	Permite conectar modelos de lenguaje con herramientas, APIs, bases de datos y memoria. Arquitectura modular para crear agentes flexibles.	Crear asistentes que busquen información, resuelvan problemas y generen explicaciones científicas paso a paso
	AutoGen	Framework	Sistema multiagente donde varios agentes colaboran mediante conversación para resolver tareas complejas.	Simular equipos de trabajo (investigador, analista, redactor) en proyectos científicos o tecnológicos
	CrewAI	Framework	Permite crear "equipos" de agentes con roles definidos que colaboran en una tarea común.	Diseñar actividades donde cada agente cumple una función (experto en física, corrector, generador de problemas...)
	OpenAI Agents SDK	Framework	Framework sencillo para crear agentes con herramientas y control del flujo dentro del ecosistema OpenAI.	Introducción práctica a agentes sin mucha complejidad técnica

Icono	Herramienta	Tipo	Descripción	Utilidad en educación y ciencias
	AutoGPT	Ejemplo de agente	Sistema autónomo que divide tareas en subtareas y las ejecuta de forma iterativa.	Mostrar cómo una IA puede resolver proyectos complejos de forma autónoma
	Devin AI	Ejemplo de agente	Agente orientado a programación que actúa como un desarrollador autónomo.	Aplicaciones en enseñanza de programación y resolución de problemas técnicos
	SIMA	Ejemplo de agente	Agente que interactúa con entornos digitales y videojuegos aprendiendo tareas.	Ejemplos de aprendizaje por interacción en entornos simulados
	OpenDevin	Ejemplo de agente	Proyecto open source inspirado en Devin para automatizar tareas de desarrollo de software.	Alternativa abierta para trabajar IA aplicada a programación

Limitaciones actuales

A pesar de su potencial, los agentes todavía presentan algunos desafíos técnicos importantes.

Errores de razonamiento

Los modelos pueden equivocarse al planificar una tarea o interpretar los resultados.

Dificultad para controlar la ejecución

Los agentes pueden entrar en bucles o tomar decisiones inesperadas si no están bien diseñados.

Coste computacional

Las tareas largas implican muchas llamadas a modelos de lenguaje, lo que puede aumentar los costes de cálculo.

Riesgos de seguridad

Los agentes que interactúan deben diseñarse cuidadosamente para evitar comportamientos no deseados sobre todo si trabajan con información sensible o interactúan con personas o sistemas externos a la organización.



Por esta razón, la investigación actual también se centra en **mejorar el control, la seguridad y la supervisión de los agentes**.

Automatización de tareas

La automatización de tareas mediante inteligencia artificial está transformando la forma en la que se preparan, desarrollan y evalúan las actividades en el aula, especialmente en áreas científicas. En esencia, automatizar consiste en delegar en un sistema ciertas acciones repetitivas o complejas para que se realicen de forma autónoma o semiautónoma. En el contexto educativo, esto no significa sustituir al docente, sino liberarlo de tareas mecánicas para que pueda centrarse en lo realmente importante: enseñar, acompañar y adaptar el aprendizaje.

En ciencias —como física, química, biología o matemáticas— existen muchas tareas que siguen patrones claros y repetitivos: generar problemas similares cambiando datos, corregir ejercicios paso a paso, explicar conceptos con distintos niveles de dificultad o resumir contenidos. La inteligencia artificial, especialmente cuando se combina con técnicas ya vistas de *prompting*, RAG o agentes, permite automatizar este tipo de procesos manteniendo coherencia con el temario. Es como tener un asistente que sabe cómo planteas los ejercicios, cómo explicas los contenidos y qué tipo de actividades utilizas.

Por ejemplo, un docente puede automatizar la creación de hojas de ejercicios de cinemática donde todos los problemas sigan el mismo formato, pero con datos distintos. También puede generar explicaciones adaptadas a distintos niveles del alumnado o crear cuestionarios tipo test a partir de un tema concreto. Incluso es posible automatizar la corrección básica de ejercicios, proporcionando *feedback* inmediato al alumnado con indicaciones sobre errores comunes, como fallos en unidades o en el planteamiento de fórmulas.

Otra utilidad muy interesante es la generación de materiales personalizados. Un alumno que necesita refuerzo puede recibir más ejercicios del mismo tipo, mientras que otro más avanzado puede trabajar con problemas más complejos. Además, la automatización permite crear simulaciones, resúmenes de prácticas de laboratorio o guías paso a paso para experimentos, facilitando el aprendizaje autónomo.

En definitiva, la automatización en educación científica no consiste en hacer menos, sino en hacer mejor: generar más recursos, más adaptados y en menos tiempo, manteniendo siempre el control pedagógico del proceso.

Herramientas no-code para automatización en educación


Icono	Herramienta	Descripción	Uso en aula de ciencias
	ChatGPT (Custom GPTs)	Permite crear asistentes personalizados con instrucciones y documentos sin programar	Generar ejercicios, explicaciones o tests automáticamente
	Claude (Projects)	Trabaja con documentos largos y permite crear asistentes con contexto persistente	Analizar apuntes y generar resúmenes o actividades
	Gemini (Gems)	Asistentes personalizados integrados con Google Drive y otras apps	Crear materiales a partir de documentos del aula
	Genially	Plataforma visual para crear actividades interactivas	Diseñar juegos, escape rooms o simulaciones científicas
	Zapier / Make	Automatización de flujos entre aplicaciones sin código	Generar y enviar automáticamente actividades o informes
	Google Sheets + IA	Uso de funciones y extensiones IA en hojas de cálculo	Generar ejercicios o analizar resultados del alumnado
	Notion AI	Espacio de trabajo con IA integrada para organizar contenido	Crear unidades didácticas, resúmenes y actividades
	Teachable Machine (Google)	Crear modelos de IA sin programar (clasificación básica)	Introducir conceptos de IA aplicada en ciencias

Una imagen representativa del panorama actual de la IA Generativa


Generative AI Learning Roadmap

Brij Kishore Pandey

1. What is Generative AI




2. Important Concepts




3. Foundation Models



5. Training a Foundation Model




5a. Fine-Tuning & RAG Patterns




7. GenAI Models for Computer Vision




8. GenAI Learning Resources



4. GenAI Development Stack



6. Building AI Agents





Conclusión

Los agentes de inteligencia artificial representan un paso más allá en la evolución de la IA aplicada a la educación. Frente a los sistemas tradicionales, centrados en responder preguntas, los agentes están diseñados para abordar tareas completas de principio a fin, combinando razonamiento, planificación y acción. Esto los convierte en herramientas mucho más cercanas a la forma en que una persona trabaja, especialmente en contextos científicos donde los procesos suelen implicar varios pasos encadenados.

En el ámbito educativo, y en particular en ciencias, su potencial es especialmente relevante. Permiten automatizar procesos que antes requerían mucho tiempo, como analizar datos de experimentos, generar simulaciones, revisar información científica o diseñar actividades didácticas completas. Además, pueden actuar como asistentes que no solo responden, sino que guían, proponen y ejecutan tareas, facilitando tanto la labor docente como el aprendizaje autónomo del alumnado.

La combinación de agentes y automatización abre la puerta a un modelo educativo más eficiente y personalizado, en el que la inteligencia artificial se integra como una herramienta de apoyo real en el aula. No se trata de sustituir al profesorado, sino de amplificar su capacidad para diseñar experiencias de aprendizaje más ricas, adaptadas y dinámicas.

Aunque todavía existen desafíos técnicos, éticos y de seguridad, la rápida evolución de frameworks como LangChain, AutoGen o CrewAI indica que los agentes están llamados a convertirse en un elemento clave en el desarrollo de aplicaciones avanzadas de IA. En este contexto, comprender su funcionamiento y sus posibilidades no solo es útil, sino necesario para aprovechar todo su potencial en la enseñanza de las ciencias.