

## 3.2 Fine Tuning

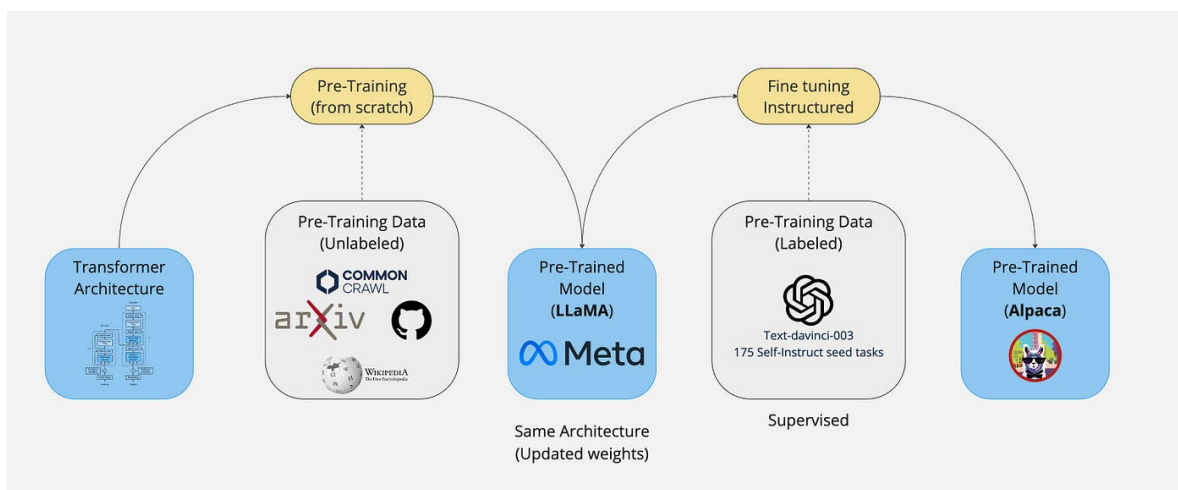
El *Fine Tuning* Es una técnica que permite adaptar un modelo de inteligencia artificial ya entrenado a una tarea concreta. En lugar de entrenar un modelo desde cero, se parte de un modelo grande que ya ha aprendido conocimientos generales y se le entrena un poco más con datos específicos para que se 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 capaza 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
☐	<b>Hugging Face (Transformers)</b>	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 <i>fine-tuning</i> de forma estructurada
⚙️	<b>PEFT</b>	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
☐	<b>LoRA / QLoRA</b>	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
☐	<b>Google Colab + notebooks</b>	Entorno accesible para ejecutar código de entrenamiento sin instalar nada en local.	Básico	Facilitar prácticas guiadas de fine-tuning para alumnado
☐	<b>Ollama + datasets propios</b>	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
☐	<b>Google AI Studio / Vertex AI</b>	Plataformas de Google para ajustar modelos mediante interfaces más visuales o semi-guiadas.	Básico	Introducir fine-tuning sin necesidad de programación avanzada
☐	<b>OpenAI / APIs similares</b>	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.

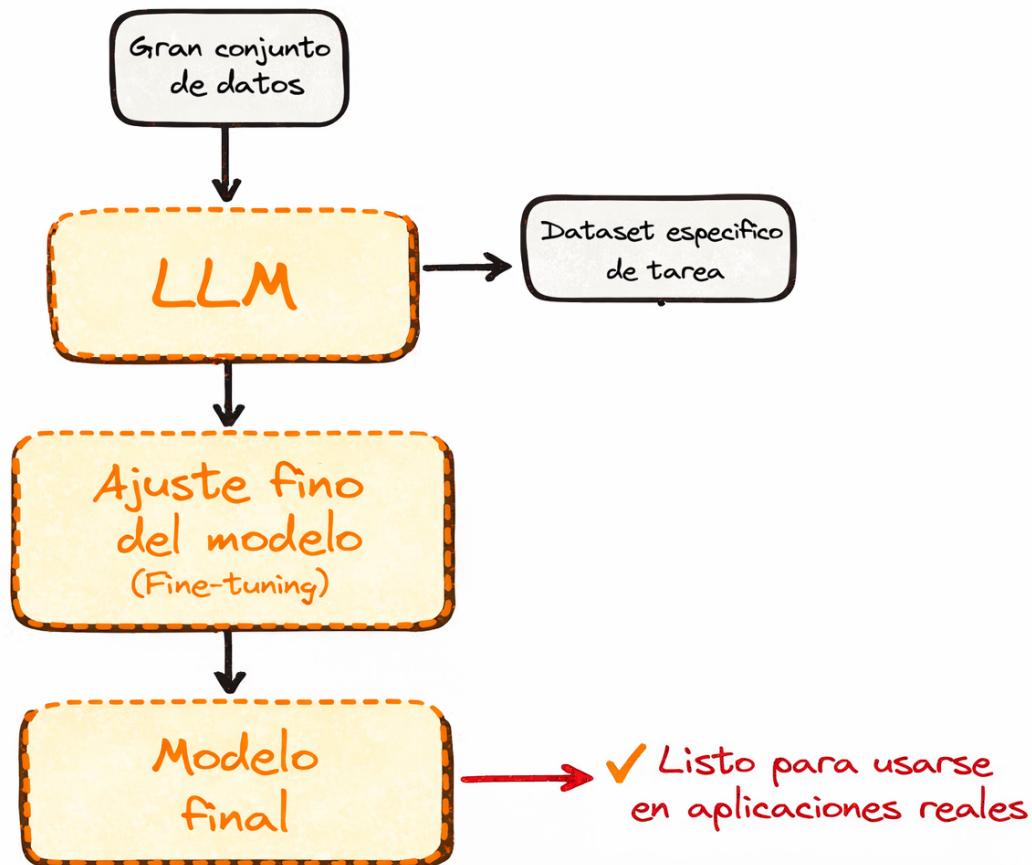
*Ejemplo:* preparar datasets, ajustar parámetros o evaluar modelos puede ser complejo para profesorado sin experiencia previa en IA.

## 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**.

---

Revision #4

Created 2026-03-16 19:16:36 CET by Luis Hueso

Updated 2026-03-23 16:30:50 CET by Luis Hueso