

LO ESENCIAL · Módulo 13 · Especialización de modelos

Cuándo NO hacer fine-tuning (casi siempre), la escalera completa, y el corpus como activo del cliente.

13.1 · Cuándo NO hacer fine-tuning: la escalera de decisión

Objetivos

- Recorrer la escalera prompt □ contexto □ RAG □ herramientas □ destilación □ LoRA
- Documentar la decisión para el asistente

Casi nunca

La pregunta «¿hacemos fine-tuning?» tiene una respuesta por defecto: **no todavía**. El fine-tuning enseña **formas** (estilo, formato, vocabulario), no **hechos**; cuesta datos, tiempo y una infraestructura de evaluación que casi ninguna PyME tiene el primer año; y se vuelve a hacer cada vez que cambia el modelo base. Antes de subir ese escalón hay cinco más baratos.

La escalera

Escalón	Qué se intenta	Cuándo basta	Costo
1 · Instrucciones	mejores instrucciones, ejemplos en el prompt	tareas de formato y tono	horas
2 · Contexto	poner los documentos correctos, presupuestados (módulo 5)	el modelo se equivoca porque no tiene la información	días
3 · RAG	recuperación medida, permisos, reranking (módulo 6)	la información existe pero no cabe	días–semanas
4 · Herramientas	dar acceso a la base, la calculadora, el validador (5.3)	el modelo «calcula» mal o inventa datos que están en un sistema	días
5 · Destilación	un modelo grande genera ejemplos; uno pequeño aprende de ellos (13.3)	la tarea es estable, el volumen alto, y el modelo grande no cabe en el perfil	semanas
6 · LoRA / QLoRA	adaptador entrenado sobre corpus curado (13.3)	el estilo o el formato del cliente no se logra con 1–4, y hay ≥ 500 ejemplos buenos	semanas + mantenimiento
7 · Fine-tuning completo	reentrenar todos los pesos	prácticamente nunca en una PyME	—

Se sube un escalón **solo con el set de evals en la mano** (módulo 12): si el escalón anterior llegó al umbral, se para ahí.

Señales de que sí toca 6

- El formato de salida del cliente es raro y consistente (un acta con 14 secciones fijas), y el modelo lo pierde en 1 de cada 5 aunque el prompt lo describa.
- El vocabulario del dominio confunde al modelo (nombres de piezas de ferretería que parecen otra cosa), y hay cientos de ejemplos etiquetados.
- Se necesita un modelo **pequeño** (perfil A/B) que haga lo que hoy solo hace uno grande, y la tarea es una sola y estable.

PROCEDIMIENTO · Laboratorio 13.1 · la decisión documentada

Para cada una de las tres tareas del asistente, labs/13–01/decision.md: en qué escalón está, qué nota tiene en evals, qué escalón sigue y **qué evidencia** haría falta para subir. Para al menos una, la respuesta debe ser «se queda en el escalón N».

Entregable: la decisión por tarea. Commit: «Capa 13.1: escalera».

Qué se degrada en cada perfil

- A** — 1–4 en local; 5–6 en la nube o en un equipo prestado
- B** — 1–6 (QLoRA de modelos pequeños/medianos)
- C** — 1–6 con modelos medianos

Cuándo NO usar esto Cuándo NO hacer fine-tuning: la escalera de decisión

- No haga fine-tuning para «que sepa de la empresa»: eso es RAG. El modelo afinado sigue sin saber la factura de ayer.
- No haga fine-tuning con menos de 500 ejemplos revisados: aprende el ruido.

PRÁCTICA · Práctica

1. «El modelo no sabe nuestros precios.» ¿Escalón?
2. «El modelo escribe las actas con secciones en otro orden.» ¿Escalón? ¿Qué evidencia pide?

Referencias

1. Hu, E. J. et al. (2021). *LoRA: Low-Rank Adaptation of Large Language Models*. arXiv:2106.09685.
2. Detrmers, T. et al. (2023). *QLoRA*. arXiv:2305.14314.
3. Módulo 12 — sin evals no hay escalera.

13.2 · Construcción de corpus**Objetivos**

- Curar 500 ejemplos con formato de entrenamiento
- Separar entrenamiento, validación y prueba

El corpus es trabajo, no descarga

Un corpus de especialización son ejemplos **entrada** → **salida deseada**, revisados por alguien que sabe. Quinientos ejemplos buenos valen más que cinco mil regulares: el modelo aprende los

errores con la misma facilidad que los aciertos.

Formato

```
{"messages":[{"role":"system","content":"Redacte el acta con las 14 secciones de El Tornillo."},
{"role":"user","content":"<transcripción resumida>"},
{"role":"assistant","content":"<acta aprobada por el gerente>"}]}
```

Una línea por ejemplo. El system es **el mismo** que usará el asistente en producción: si cambia, el adaptador deja de servir.

De dónde salen los ejemplos

Fuente	Calidad
Salidas del sistema corregidas y aprobadas por el cliente (10.4)	alta: es exactamente lo que se quiere
Documentos históricos del cliente (actas viejas) emparejados con su insumo	alta si el insumo existe
Generados por un modelo grande (13.3, destilación) y revisados	media–alta
Generados sin revisar	baja

Curación

1. **Deduplicar** (exactos y casi exactos).
2. **Revisar el 100 %** si son < 1 000; una muestra del 20 % si son más, con dos revisores.
3. **Equilibrar**: si el 80 % de las actas son de comité y el 20 % de proveedores, el corpus debe reflejarlo —o el adaptador se especializa en comités.
4. **Separar**: 80 % entrenamiento, 10 % validación, 10 % prueba. El de prueba **no se mira** hasta el final, y no se solapa con el set de evals (12.1).
5. **Anonimizar** según 2.3, sin alterar la estructura.

PROCEDIMIENTO · Laboratorio 13.2

Construya 500 ejemplos para **una** de las tres tareas (la que la decisión 13.1 dejó en escalón 6). Documente en `labs/13-02/corpus.md`: fuentes, cuántos se descartaron y por qué, equilibrio, partición, y quién revisó.

Entregable: `corpus/{train,val,test}.jsonl` (en el repo **privado** del cliente) + `corpus.md`. Commit: «Capa 13.2: corpus».

Nada: curar es trabajo humano.

Cuándo NO usar esto Construcción de corpus

- No genere el corpus con el mismo modelo que va a afinar sin revisar: aprende a imitarse.
- No incluya ejemplos con datos sensibles: el adaptador los puede reproducir.

PRÁCTICA · Práctica

1. Tiene 380 actas aprobadas y 40 de proveedores. ¿Cómo equilibra sin inventar?
2. ¿Qué pasa si el system del corpus tiene 200 tokens y el de producción 1 200?

Referencias

1. Zhou, C. et al. (2023). *LIMA: Less Is More for Alignment*. arXiv:2305.11206 — la evidencia de que la calidad pesa más que la cantidad.
2. Módulo 2.3 — anonimización.

13.3 · Destilación y LoRA/QLoRA paso a paso

Objetivos

- Entrenar un adaptador en B o C
- Evaluar antes y después con el mismo set

Destilar y adaptar

Destilación: un modelo grande (que corre en C, o prestado por horas) produce las salidas de los 500 ejemplos; se revisan; con ellas se adapta un modelo pequeño que sí corre en A o B.

LoRA/QLoRA: en vez de reentrenar los miles de millones de pesos, se entrena un **adaptador** pequeño (decenas de MB) que se suma al modelo base. QLoRA lo hace con el base cuantizado en 4 bits, y por eso cabe en el perfil B.

PROCEDIMIENTO · Laboratorio 13.3 · paso a paso [VOLÁTIL – verificado: 2026-09]

```
cd ~/labs/el-tornillo && mkdir -p labs/13-03 && cd labs/13-03
```

```
python3 -m venv .venv && source .venv/bin/activate
pip install -q "transformers" "peft" "datasets" "accelerate" "bitsandbytes" # CUDA; en
Apple Silicon: MLX-LM

# entrenar.py - QLoRA mínimo, neutral de modelo: el base se pasa por argumento
import sys, torch
from datasets import load_dataset
from transformers import AutoTokenizer, AutoModelForCausalLM, BitsAndBytesConfig,
    TrainingArguments
from peft import LoraConfig, get_peft_model, prepare_model_for_kbit_training
from trl import SFTTrainer

base = sys.argv[1] # <modelo-base> [VOLÁTIL]
tok = AutoTokenizer.from_pretrained(base); tok.pad_token = tok.eos_token
model = AutoModelForCausalLM.from_pretrained(base, device_map="auto",
    quantization_config=BitsAndBytesConfig(load_in_4bit=True, bnb_4bit_compute_dtype
    =torch.bfloat16))
model = prepare_model_for_kbit_training(model)
model = get_peft_model(model, LoraConfig(r=16, lora_alpha=32, lora_dropout=0.05, task_type
    ="CAUSAL_LM",
    target_modules=["q_proj", "k_proj", "v_proj", "o_proj"]))
ds = load_dataset("json", data_files={"train": "../13-02/corpus/train.jsonl", "val":
    "../13-02/corpus/val.jsonl"})
tr = SFTTrainer(model=model, tokenizer=tok, train_dataset=ds["train"], eval_dataset=ds["
    val"],
    args=TrainingArguments(output_dir="salida", num_train_epochs=2,
    per_device_train_batch_size=2,
    gradient_accumulation_steps=8, learning_rate=2e-4, bf16=True, logging_steps=10,

    eval_strategy="steps", eval_steps=50, save_strategy="epoch"))
tr.train(); model.save_pretrained("adaptador")

python3 entrenar.py <modelo-base> # B: -13 h para 500 ejemplos con un -78B; C:
    minutos
# fusionar y exportar a GGUF para el runtime (o cargar el adaptador directamente si el
    runtime lo soporta)
```

Evaluar antes y después — obligatorio

```
python3 ../12-01/evals.py --set ../12-01/evals/ --modelo base --salida antes.json
python3 ../12-01/evals.py --set ../12-01/evals/ --modelo adaptado --salida despues.json
python3 ../12-02/tablero.py antes.json despues.json
```

Lo que debe ver: la tarea afinada **sube**, y **ninguna otra baja**. Si otra baja (el adaptador «olvidó» algo), el adaptador se usa solo para esa tarea (razón 3 de 10.2) o se descarta.

Entregable: adaptador/, antes.json, despues.json, el tablero comparado, y en labs/13-

03/entrenamiento.md: base, hiperparámetros, tiempo, hardware, hash del corpus. Commit: «Capa 13.3: adaptador evaluado».

Qué se degrada en cada perfil

- A** — No se entrena en local. Se entrena en B/C prestado o en la nube **con corpus anonimizado**; se infiere en A con el adaptador
- B** — QLoRA de modelos $\leq 8B$: horas
- C** — QLoRA de modelos $\leq 14B$: minutos–hora; LoRA en 16 bits de pequeños

Cuándo NO usar esto Destilación y LoRA/QLoRA paso a paso

- No afine sin antes .json: no sabrá si mejoró.
- No entrene con el set de prueba ni con los evals: se engaña a sí mismo.
- No afine cada mes «con lo nuevo»: cada adaptador es una versión que hay que mantener (11.3).

PRÁCTICA · Práctica

1. El adaptador sube actas de 78 % a 94 % y baja extracción de facturas de 96 % a 93 %. ¿Qué hace?
2. ¿Por qué el system del entrenamiento y el de producción deben ser idénticos?

Referencias

1. Hu, E. J. et al. (2021). LoRA — arXiv:2106.09685. · Dettmers et al. (2023). QLoRA — arXiv:2305.14314.
2. Hugging Face PEFT — <https://huggingface.co/docs/peft> · TRL — <https://huggingface.co/docs/trl> [VOLÁTIL – verificado: 2026-09]
3. Hinton, G. et al. (2015). *Distilling the Knowledge in a Neural Network*. arXiv:1503.02531.

13.4 · El corpus como activo y línea de facturación

Objetivos

- Redactar la cláusula de propiedad del corpus
- Ponerle precio a la curación

Lo que queda cuando cambia el modelo

Los modelos cambian cada seis meses. El adaptador se reentrena. Lo que **no** se pierde es el corpus: 500 ejemplos revisados de cómo esta empresa quiere sus actas, sus extracciones, sus respuestas. Eso es un **activo del cliente**, con valor propio, y hay que tratarlo como tal en el contrato y en la factura.

Propiedad

Pieza	De quién	Por qué
Documentos originales	del cliente	siempre
Corpus curado (los pares entrada→salida)	del cliente	está hecho con sus datos y s
Método de curación, scripts, plantillas	del implementador (licenciados al cliente)	es el producto reutilizable
Adaptador entrenado	del cliente (derivado de su corpus)	se entrega con su hash y s evals
Modelo base	de quien lo publicó, según su licencia	verificar que permite uso co rivados

Cláusula tipo, para el contrato (14.3): «*El corpus de ejemplos y los adaptadores derivados son propiedad de EL CLIENTE. EL IMPLEMENTADOR conserva la propiedad de sus herramientas y métodos, y no usará el corpus para terceros.*»

Línea de facturación

Concepto	Unidad	Nota
Curación de corpus	por 100 ejemplos revisados	trabajo humano; se factura
Entrenamiento y evaluación de adaptador	por corrida	incluye antes/después
Mantenimiento del corpus	mensual	incorporar salidas aproba (13.2)

El corpus **crece con el uso** (cada aprobación en la cola de 10.4 es un ejemplo candidato): el mantenimiento mensual es lo que convierte un proyecto en un servicio.

PROCEDIMIENTO · Laboratorio 13.4

labs/13-04/clausula.md: la cláusula de propiedad adaptada a la ferretería, la tabla de facturación con precios en COP, y la verificación de la licencia del modelo base elegido (con enlace y fecha).

Entregable: la cláusula y la tabla. Commit: «Capa 13: el corpus es del cliente».
Nada.

Cuándo NO usar esto El corpus como activo y línea de facturación

- No reutilice el corpus de un cliente en otro «porque son parecidos». Es suyo, y la ley (2.3) y el contrato lo dicen.
- No entregue un adaptador sin su corpus y su corrida de evals: es un binario que nadie podrá reproducir.

PRÁCTICA · Práctica

1. Un modelo base tiene licencia que prohíbe uso comercial. ¿Qué hace con el adaptador?
2. Ponga precio a curar 500 ejemplos con una revisora contable a tarifa local.

Referencias

1. Licencias de modelos abiertos: leer **el texto** de cada una (Apache-2.0, MIT, licencias propias con cláusulas de uso) antes de entrenar.
2. Módulo 14.3 — el modelo de precios.