


LO ESENCIAL · Módulo 0 · Fundamentos y vocabulario

Las palabras con las que se habla el resto del curso, definidas por lo que hacen. Y un glosario con símiles para quien llega de cero.

0.1 · Glosario con símiles: para entender de qué se habla



Fundamentos y vocabulario

Objetivos

- Explicar cada término del curso con un símil cotidiano
- Distinguir modelo, agente, herramienta y RAG sin jerga

El estudiante que se sabe todo de memoria

El lunes llega a la ferretería El Tornillo un empleado nuevo. Llamémoslo Modelo. Antes de llegar se aprendió de memoria media biblioteca del mundo: manuales, contratos ajenos, leyes, foros de tornillería. Sabe una barbaridad y contesta rapidísimo.

Doña Marta, la contadora, lo pone a prueba: «¿Cuánto nos debe Tornillería Santander?». Modelo

responde con toda seguridad una cifra. Se la inventó.

Es el mismo fenómeno del estudiante que presenta un examen **de memoria**: sabe mucho, pero cuando no se acuerda del dato exacto, rellena el hueco con lo que suena bien. En este oficio a eso le dicen **alucinar**, y no es maldad: el trabajo de Modelo es completar frases con lo más probable. Si no tiene el dato delante, el dato más probable se lo inventa.

De ahí sale la primera regla de la casa, y de todo el curso: **a Modelo nunca se le deja responder de memoria**.

Y la segunda, que Marta descubre el martes: Modelo **no aprende**. Lo que le contó el lunes hoy no lo recuerda. Cada mañana llega igual de sabio y de ignorante.

El examen a libro abierto

La solución es tan vieja como el colegio: dejarlo presentar el examen **con el libro abierto**.

En vez de preguntarle de memoria, alguien le pone delante las tres facturas de Tornillería Santander y entonces sí le pregunta. Modelo lee, suma, y responde diciendo de cuál factura sacó cada cifra. Ya no adivina: **lee**.

Eso es **RAG**. Es la sigla que va a oír por todas partes, y es exactamente eso: el mismo estudiante, pero con permiso de abrir el libro, buscar la página y responder con lo que acaba de leer. Todo el módulo 6 es el oficio de encontrar la página correcta.

Y aquí conviene aclarar la confusión más común del gremio. Mucha gente cree que para que Modelo «sepa» de la ferretería hay que **entrenarlo**. Entrenarlo —hacerle *fine-tuning*— es como mandarlo a un curso de especialización: vuelve hablando distinto, con el formato de la casa, con el tono que uno quiere. Cambia **la forma**, no el contenido. El curso no le enseña la factura de ayer, ni el precio de hoy. Para los datos, RAG. Para la forma, el curso. Confundirlas cuesta meses y dinero, y es el tema del módulo 13.

La libreta y el mapa

Falta lo difícil: ¿cómo encuentra alguien las tres facturas correctas entre doscientas carpetas?

Modelo tiene una **libreta** que consulta antes de responder. Cuando llega un documento, no se guarda por orden alfabético sino por **significado**: a cada pedazo de texto se le calcula una coordenada en un mapa donde lo que habla de lo mismo queda cerca. Esa coordenada se llama **embedding**. «Deuda de Tornillería Santander» cae al lado de sus facturas y lejos del acta del comité.

El mapa tiene una trampa que hay que saber desde el primer día: mide **parecido**, no verdad. «El pago fue aprobado» y «el pago **no** fue aprobado» quedan vecinos, porque se parecen muchísimo. Por eso no se traen las tres más cercanas y ya: se traen veinte, y un segundo lector más lento y más fino las revisa y se queda con las cinco que de verdad responden. A ese segundo lector le

dicen *reranker*.

La ventanilla

Modelo no anda por el almacén. Trabaja en el cuarto del fondo, y nadie entra ahí. Lo que hay es una **ventanilla**: uno pasa el pedido por escrito y por ahí mismo sale la respuesta.

Esa ventanilla es lo que en informática se llama **API**. Es la misma idea con la que siempre se explican las APIs —el mesero de un restaurante, que uno tampoco entra a la cocina—: no hace falta saber cómo se prepara lo de adentro; hace falta saber **pedir bien**.

Y ahí está la maña que más plata ahorra: **el formulario del pedido**. Si por la ventanilla uno manda «mándeme lo de la factura», vuelve un párrafo distinto cada vez. Si manda un formulario con cuatro casillas —número, fecha, proveedor, total— vuelven las cuatro casillas llenas y nada más. Ese formulario es lo que los técnicos llaman **esquema**, y es lo que impide que llegue un poema donde se esperaba una cifra.

El secretario

El miércoles el gerente le dice a Modelo: «Averigüe si llegó la remisión de Tornillería y, si llegó, avísele a Marta».

Eso ya no es una pregunta: es un **encargo**. Y ahí Modelo deja de ser un consultor y se vuelve un **secretario**. Un secretario no responde y se calla: sale, hace gestiones, vuelve. Puede necesitar tres o cuatro diligencias antes de traer el resultado.

Para eso se le deja sobre el escritorio una **caja de herramientas**: «buscar remisión por proveedor», «leer un correo», «avisarle a Marta». Cada una con su etiqueta clara de para qué sirve **y para qué no**. Modelo no las usa con sus manos —sigue en el cuarto del fondo—: **pide** por la ventanilla que se usen, y alguien de la casa las ejecuta y le trae el resultado.

A un secretario con un encargo, herramientas y permiso de dar varios pasos, en este oficio le dicen **agente**. Y lo primero que hay que darle, antes que nada, es un **reloj**: cuántas diligencias puede hacer antes de rendirse y avisar. Un secretario sin reloj puede pasarse el día buscando lo mismo.

Con el tiempo, el gerente nota que hay diligencias que se repiten y escribe el procedimiento completo: «sacar los datos de una factura de proveedor», paso por paso, con ejemplos. Eso queda guardado como una **habilidad** —una *skill*— que cualquier secretario puede tomar y usar tal cual, sin volver a explicársela. No es código nuevo: es un procedimiento empaquetado, que se le entrega cuando toca esa tarea y se le quita después, para no llenarle el escritorio.

Y como la ferretería a veces prueba un secretario más rápido o uno más barato, la caja de herramientas se hace con un **enchufe estándar**, para que cualquiera la use sin cambiar nada. A ese enchufe le dicen **MCP**, y la comparación que usa todo el mundo —incluida la empresa que

lo inventó— es que es **el USB-C de la inteligencia artificial**: antes cada aparato necesitaba su propio cable; ahora todos entran por el mismo puerto.

El escritorio y el reglamento

Todo lo anterior pasa sobre un **escritorio**. Modelo solo puede trabajar con lo que cabe encima: la pregunta, los papeles que le pusieron al lado, la conversación que llevan. Ese escritorio tiene un tamaño fijo —la **ventana de contexto**— que se mide en **tokens**, las piezas en que Modelo lee, que no son palabras enteras: «FV-2026-000123» son ocho piezas, y mil palabras en español son unas mil quinientas.

De ahí la costumbre que atraviesa el curso: **encima del escritorio va lo justo**. Si le tiran el archivo entero, se pierde en el medio. Si le ponen la carpeta correcta, responde bien y rápido.

Y alrededor del escritorio está el **reglamento de la oficina**: qué puede hacer el secretario, cuánto puede gastar, qué queda anotado en el libro, y en qué momento tiene que llamar al jefe antes de hacer algo que no se pueda deshacer. Ese reglamento se llama **harness**, y es —aunque no lo parezca— lo que de verdad se le vende a un cliente. Modelo es el que trabaja en el cuarto del fondo; el reglamento es todo lo demás que hace que el negocio funcione.

Ver, oír y medir

Modelo lee texto. Para que lea una factura escaneada, alguien convierte la foto en letras: el **OCR**. Para las fotos torcidas con sellos encima hay un Modelo que además **ve**, pero con las cifras se equivoca más que el OCR, así que se usa solo cuando el OCR no puede (módulo 7). Para las reuniones hay uno que **oye** y transcribe (módulo 8).

Y como nada de esto se cree por fe, todo se **mide**: cuántas facturas de cien lee bien, cuánto tarda en decir la primera palabra, si cinco personas a la vez lo tumban. Los exámenes que se le repiten cada vez que algo cambia se llaman **evals** (módulo 12). Y el que baja cada noche a revisar que el aire siga bueno es el **canario**, como el pajarito de las minas: pequeño, sensible, y avisa antes que las personas (módulo 9).

Paso a paso: el glosario suyo

1. Copie esta historia y, al lado de cada palabra en negrita, escriba en una línea **su** versión, con la gente de su empresa.
2. Pídale a un modelo esto, tal cual: «*Explíqueme qué es RAG usando solo la analogía del examen a libro abierto. Máximo cinco frases. Y dígame dónde se rompe la analogía.*» Compare con lo de arriba. Donde difieran, averigüe quién tiene razón: es el mejor ejercicio del curso.
3. Escriba la «carta» de una tarea suya: cuatro casillas que la respuesta debe llenar.

La trastienda

Término	En una frase medible
Modelo / pesos	archivo de N mil millones de números; en F16, 2 bytes cada uno
Token	~1,5 tokens por palabra en español
Contexto	tokens simultáneos: 8k, 32k, 128k. La caché KV crece con él
API compatible	POST /v1/chat/completions — interfaz neutral del curso
Esquema	JSON Schema con <code>additionalProperties: false</code>
Herramienta	función con nombre, descripción y esquema de entradas
Skill	carpeta versionada: instrucciones + esquema + ejemplos
MCP	protocolo JSON-RPC; resuelve el problema $N \times M \rightarrow N+M$
Agente	bucle modelo → herramienta → resultado, con <code>max_pasos</code>
Harness	presupuestos, permisos, trazas, estado, aprobación humana
Embedding	vector de 384–1 024 números; similitud coseno
RAG	recuperar → poner en contexto → responder citando
Reranker	modelo cruzado que puntúa (pregunta, fragmento)
Fine-tuning	cambia la forma (estilo, formato), no los hechos
Eval / canario	casos con respuesta esperada; subconjunto nocturno con alerta

Referencias: Vaswani et al. (2017) arXiv:1706.03762 · Lewis et al. (2020) arXiv:2005.11401 · IBM, *RAG vs fine-tuning* <https://www.ibm.com/think/topics/rag-vs-fine-tuning> · Model Context Protocol <https://modelcontextprotocol.io/> · Anthropic, *Building effective agents*.

0.2 · Texto plano y Markdown: la base de todo

Objetivos

- Justificar por qué todo el sistema se construye sobre texto versionable
- Escribir un README con la estructura del proyecto

Por qué se empieza por aquí

Todo lo que se construye en este curso —prompts, esquemas, configuraciones, trazas, políticas, documentación de entrega— es **texto**. La decisión más barata y más duradera que se toma al principio es en qué formato vive ese texto. La respuesta es aburrida y correcta: **texto plano**.

Nota Un archivo de texto plano de 1995 se abre hoy con cualquier programa. Un .doc de 1995, no siempre. Un proyecto de IA que dure cinco años en una PyME va a cambiar de

modelo tres veces y de implementador al menos una. Lo único que sobrevive a todos esos cambios es el texto.

Tres razones concretas, no de gusto:

1. **Se versiona.** Git muestra línea por línea qué cambió, quién y cuándo. Con un binario solo muestra «cambió».
2. **Lo leen las máquinas y las personas.** El mismo `.md` es la documentación para el cliente, el contexto para el modelo y la fuente de la guía impresa.
3. **No depende de nadie.** Sin licencia, sin programa propietario, sin versión que se descontinúe.

Markdown: texto plano con lo mínimo de estructura

Markdown es una convención para marcar títulos, listas, énfasis, tablas y código **usando solo caracteres del teclado**. Se lee sin procesar y se convierte a HTML, PDF o láminas sin esfuerzo.

```
# Título de nivel 1
## Título de nivel 2

Un párrafo con **negrita**, *cursiva* y `código en línea`.

- Lista con viñetas
- Otro ítem
  - Sub-ítem

1. Lista numerada
2. Segundo paso

| Columna | Otra |
|---|---|
| celda | celda |
```

echo "bloque de código con lenguaje declarado"

La versión que se usa en este curso es **CommonMark** con las extensiones de GitHub (tablas, listas de tareas, código con lenguaje). Es la que entiende el MOOC, Git, los editores y casi todos los modelos.

Nota *Markdown* viene de *markup* (lenguaje de marcado) al revés: **marcar hacia abajo**, o sea, marcar lo mínimo. El nombre es una broma de su autor, John Gruber (2004).

Front-matter: metadatos al principio del archivo

Muchas herramientas aceptan un bloque de **YAML** entre dos líneas de `---` al inicio del archivo. Es donde va lo que describe al documento sin ser el documento:

```
---
titulo: "Asistente documental – ferretería El Tornillo"
version: 0.1
cliente: ferreteria-el-tornillo
verificado: 2026-09
---

# Asistente documental
...
```

Ese bloque es lo que va a leer el importador del MOOC, el generador de la guía impresa y el propio agente cuando necesite saber de qué trata un archivo. **Un mismo texto, varios lectores.**

Por qué el texto plano también es la base para el modelo

Un modelo lee tokens (lección siguiente). Todo lo que no es texto —una imagen, un PDF escaneado, una hoja de cálculo con colores— tiene que **convertirse** a texto antes de que el modelo lo vea, y en esa conversión se pierde información (módulo 7 muestra cuánta). Cuando la fuente ya es texto plano bien estructurado, no hay conversión y no hay pérdida.

De ahí una regla práctica del curso:

ATENCIÓN · Ojo

Lo que el sistema produce, lo produce en texto plano estructurado. Actas, políticas, extracciones, informes. Si el cliente quiere Word o PDF, se genera **desde** el texto, nunca al revés.

Cuándo NO usar esto Texto plano y Markdown: la base de todo

- **Documentos con diagramación exacta y valor legal** (un contrato con márgenes, firmas y foliación): se producen en PDF desde una plantilla; el Markdown es el borrador, no la entrega.
- **Datos tabulares grandes**: una tabla Markdown de 2.000 filas no sirve para nada. Eso es CSV o una base de datos; Markdown solo para la tabla resumen.
- **Formularios que llena gente no técnica**: nadie va a escribir | celda | a mano. Se les da una interfaz, y la interfaz guarda texto plano por debajo.

- **Diagramas complejos:** Mermaid (texto → diagrama) sirve hasta cierto tamaño; un plano de red de 40 nodos se dibuja en otra herramienta y se exporta a SVG.

PROCEDIMIENTO · Laboratorio 0.2 · el README del proyecto

El proyecto integrador del curso empieza aquí: una carpeta con un solo archivo. Cada módulo va a añadirle una capa.

```
mkdir -p ~/labs/el-tornillo && cd ~/labs/el-tornillo
git init -q
cat > README.md <<'EOF'
---
proyecto: asistente-documental
cliente: Ferretería El Tornillo (Bucaramanga)
usuarios: [gerente, contadora, vendedor]
verificado: 2026-09
---

# Asistente documental – Ferretería El Tornillo

## Qué hace (versión 0)
Todavía nada. Este archivo es la primera capa: la descripción del sistema.

## Qué va a hacer
1. Ingerir documentos escaneados (facturas, remisiones, contratos).
2. Extraer campos con esquema y validarlos.
3. Responder consultas citando la fuente.
4. Dejar traza auditable de cada operación.
5. Servir a tres empleados con permisos distintos.

## Perfiles de hardware en los que se prueba
- A · portátil sin GPU dedicada
- B · equipo con ~816 GB de VRAM
- C · servidor con 24 GB o más
EOF
git add README.md && git commit -qm "Capa 0: descripción del sistema" && git log --oneline
```

Lo que debe ver: una línea con el hash del commit y el mensaje Capa 0: descripción del sistema.

Entregable: el README.md versionado. De aquí en adelante, cada laboratorio termina con un commit cuyo mensaje empieza por «Capa N».

Qué se degrada en cada perfil

A — Igual. Es texto

B — Igual

C — Igual

Es el único laboratorio del curso donde los tres perfiles son idénticos. Conviene fijarse en eso: **la parte que más dura del sistema es la que menos hardware necesita.**

PRÁCTICA · Práctica

1. Convierta a Markdown la última acta o informe que haya escrito en Word. Anote qué se perdió (probablemente nada importante) y qué se ganó.
2. Abra el README.md con tres programas distintos (un editor de código, el bloc de notas, el navegador vía GitHub). Debe leerse en los tres.
3. Escriba el front-matter de un documento del cliente: título, versión, quién lo aprobó, fecha de verificación.

Referencias

1. CommonMark — especificación: <https://commonmark.org/> · GitHub Flavored Markdown: <https://github.github.com/gfm/>
2. Gruber, J. (2004). *Markdown*. <https://daringfireball.net/projects/markdown/> — el documento original.
3. Hunt, A. y Thomas, D. (1999). *The Pragmatic Programmer*. Addison-Wesley — capítulo «The Power of Plain Text».
4. YAML — especificación 1.2: <https://yaml.org/spec/1.2.2/>

0.3 · Modelo, pesos, cuantización, contexto y tokens

Objetivos

- Definir cada término de forma medible
- Contar tokens de documentos reales y estimar el costo de contexto

Cinco palabras, cinco números

Cada término de esta lección se define por **un número que se puede medir en la terminal**. Si alguien los usa sin número, está hablando de otra cosa.

Término	El número	Cómo se mide
Modelo (tamaño)	parámetros: 1B, 8B, 70B...	está en el nombre del archivo
Pesos en disco	gigabytes	<code>ls -lh</code>
Cuantización	bits por parámetro: 16, 8, 4...	el sufijo: F16, Q8_0, Q4_K_M
Contexto	tokens que caben en la ventana	lo declara el runtime al cargar
Tokens	cuántos pedazos tiene un texto	un programa tokenizador

Modelo y pesos

Un **modelo de lenguaje** es una función enorme que recibe una secuencia de tokens y devuelve, para el siguiente token, una probabilidad por cada token posible del vocabulario. Se muestrea uno, se añade a la secuencia, y se repite. Eso es todo lo que hace. Todo lo demás —«razonar», «resumir», «extraer»— es ese bucle aplicado muchas veces.

Los **pesos** (o parámetros) son los números que definen esa función. Un modelo de 8B tiene ocho mil millones. En **precisión completa** (16 bits por parámetro) ocupan:

```
8 000 000 000 parámetros × 2 bytes = 16 GB
```

Ese cálculo es la primera herramienta de decisión del curso: **parámetros × bytes por parámetro = memoria que hace falta solo para cargar el modelo**, sin contar el contexto.

Cuantización

Cuantizar es guardar cada peso con **menos bits**. Los formatos más comunes en runtimes locales [VOLÁTIL – verificado: 2026-09]:

Sufijo	Bits/parámetro	8B ocupa	Pérdida típica	Cuándo
F16 / BF16	16	~16 GB	ninguna (referencia)	evaluación, entrenamiento
Q8_0	8	~8,5 GB	casi imperceptible	cuando cabe
Q6_K	~6,5	~6,6 GB	muy baja	buen punto medio
Q4_K_M	~4,8	~4,9 GB	notable en tareas finas	perfil B por defecto
Q3 / Q2	3–2	~3,5–3 GB	alta, a veces inutilizable	solo si no hay otra

ATENCIÓN · Ojo

«Notable en tareas finas» no es una opinión: **se mide** con el mismo set de preguntas en varias cuantizaciones (laboratorio 4.2). Un modelo que extrae cifras de facturas puede pasar de 97 % de exactitud en Q8 a 91 % en Q4. Ese 6 % son facturas mal leídas.

Criterio de selección (no un nombre de modelo): elija la cuantización más alta que **quepa** en la VRAM dejando espacio para el contexto; baje un escalón solo si la medición dice que la pérdida es aceptable para la tarea.

Contexto: la ventana

La **ventana de contexto** es la cantidad máxima de tokens que el modelo puede tener «a la vista» a la vez: instrucciones + documentos + conversación + su propia respuesta. Todo compite por ese espacio.

Y tiene un costo que casi nadie cuenta al comprar hardware: **la caché de atención (KV cache)** crece con el contexto y vive en la misma memoria que los pesos. Como orden de magnitud para un modelo 8B [VOLÁTIL – verificado: 2026-09]:

```
contexto de 8 000 tokens → ~1 GB adicional
contexto de 32 000 tokens → ~4 GB adicionales
```

Por eso «cabe en 8 GB» puede ser cierto para el modelo solo y falso para el modelo con un PDF de 40 páginas dentro. El módulo 1 lo convierte en fórmula.

Tokens

Un **token** es la unidad en que el modelo lee: no palabras, no letras, sino fragmentos decididos por un algoritmo de compresión estadística (BPE o similar) durante el entrenamiento. Consecuencias prácticas:

- El español gasta **más tokens por palabra** que el inglés, porque los tokenizadores se entrenan con mayoría de inglés. Regla de bolsillo: 1.000 palabras en español $\approx$ 1.400–1.800 tokens.
- Los números, los códigos de factura y las siglas se parten en muchos tokens: FV-2026-000123 puede ser 8 tokens.
- Cada modelo tiene **su** tokenizador. Contar con el de otro da cifras equivocadas.

PROCEDIMIENTO · Laboratorio 0.3 · contar tokens de documentos reales

Se usa la biblioteca tokenizers con el archivo tokenizer.json de **cualquier** modelo:

así el laboratorio no depende de un modelo concreto. (Si ya tiene un runtime local, la mayoría expone su propio conteo; el principio es el mismo.)

```
cd ~/labs/el-tornillo && mkdir -p labs/00-03 && cd labs/00-03
python3 -m venv .venv && source .venv/bin/activate
pip install -q tokenizers

# tokenizer.json: descárguelo del repositorio del modelo que vaya a usar (Hugging Face) y
# póngalo aquí. Es un archivo de texto; no hacen falta los pesos.

# tokens.py - cuenta tokens de varios archivos con un tokenizer.json cualquiera
import sys, pathlib
from tokenizers import Tokenizer

tok = Tokenizer.from_file("tokenizer.json")
for ruta in sys.argv[1:]:
    texto = pathlib.Path(ruta).read_text(encoding="utf-8")
    n_tok = len(tok.encode(texto).ids)
    n_pal = len(texto.split())
    print(f"{ruta:40s} {n_pal:7d} palabras {n_tok:8d} tokens  ratio {n_tok/max(n_pal,1):.2f}")

python tokens.py ../../README.md docs/politica-datos.md docs/contrato-proveedor.md
```

Lo que debe ver: tres líneas con el ratio tokens/palabra. En español bien redactado sale entre **1,4 y 1,8**. Si sale 2,5 o más, el texto tiene muchos códigos, números o mayúsculas raras —y eso es lo que va a costar en contexto.

Entregable: labs/00-03/tokens.py y una tabla con los tokens de los tres documentos más largos del cliente. Commit: «Capa 0.3: presupuesto de tokens».

Qué se degrada en cada perfil

A — Igual: tokenizar es CPU

B — Igual

C — Igual

Cuándo NO usar esto Modelo, pesos, cuantización, contexto y tokens

- **No cuente tokens con el tokenizador de otro modelo** para presupuestar contexto: las cifras pueden diferir un 30 %.
- **No cuantice a Q2/Q3 para «que quepa»** en un equipo que no da: mida primero; casi siempre es mejor un modelo más pequeño en Q8 que uno grande en Q2.
- **No compre por parámetros.** Un 70B en Q2 puede rendir peor que un 8B en Q8 y

costar cuatro veces más de memoria.

PRÁCTICA · Práctica

1. Calcule cuánta memoria ocupa un modelo de 14B en F16, Q8 y Q4 (sin contexto).
2. Un cliente tiene facturas de 3 páginas (~1.200 palabras). ¿Cuántos tokens aproximados gasta una sola factura? ¿Cuántas caben en una ventana de 8k dejando 1.500 para instrucciones y respuesta?
3. Explique en dos líneas por qué un runtime puede decir «modelo cargado» y aun así fallar al procesar un documento largo.

Referencias

1. llama.cpp — formato GGUF y tabla de cuantizaciones: <https://github.com/ggml-org/llama.cpp> (README y docs/). [VOLÁTIL – verificado: 2026-09]
2. Hugging Face — biblioteca tokenizers: <https://huggingface.co/docs/tokenizers>
3. Sennrich, R. et al. (2016). *Neural Machine Translation of Rare Words with Subword Units*. arXiv:1508.07909 — el BPE que usan los tokenizadores modernos.
4. Dettmers, T. et al. (2023). *QLoRA: Efficient Finetuning of Quantized LLMs*. arXiv:2305.14314 — la evidencia de que 4 bits conserva la mayor parte de la calidad en muchas tareas.

0.4 · Embeddings, herramienta, agente, skill, harness, MCP y multimodal

Objetivos

- Distinguir cada pieza por lo que hace
- Ejecutar un ejemplo mínimo de cada una

Siete piezas, cada una con un ejemplo que corre

Esta lección cierra el vocabulario con las piezas que **actúan**. Cada una se define por lo que hace y se demuestra con el ejemplo más pequeño que corre. Nada de esto necesita GPU.

1 · Embedding

Un **embedding** es un vector de números que representa el significado de un texto, de modo que textos parecidos tienen vectores cercanos. Lo produce un **modelo de embeddings**, distinto del modelo de lenguaje y mucho más pequeño.

```
# embed.py – parecido entre frases con un modelo de embeddings local
# [VOLÁTIL – verificado: 2026-09] el nombre del modelo cambia; el criterio no:
#   multilingüe con buen español, ≤ 600 MB, licencia permisiva. Dos alternativas por tamaño
#   se listan en el laboratorio 6.2.
from sentence_transformers import SentenceTransformer
m = SentenceTransformer("<modelo-de-embeddings-multilingue>")
frases = ["factura del proveedor de tornillería", "remisión de tornillos", "acta de reunión del comité"]
v = m.encode(frases, normalize_embeddings=True)
print((v @ v.T).round(2)) # matriz de similitudes coseno
```

Lo que debe ver: las dos primeras frases con similitud alta entre sí ($\approx 0,7-0,9$) y baja con la tercera. **Eso —y no la magia— es lo que hace funcionar un RAG.**

ATENCIÓN · Ojo

Un embedding mide parecido de forma, no verdad. «El pago fue aprobado» y «el pago no fue aprobado» quedan **cerca**. El módulo 6 explica cómo se compensa.

2 · Herramienta (tool)

Una **herramienta** es una función con tres cosas: un nombre, una descripción en lenguaje natural y un **esquema** de entradas. El modelo no la ejecuta: **pide** que se ejecute, con argumentos que cumplen el esquema, y recibe el resultado como texto.

```
# tool.py – una herramienta es una función + su contrato
HERRAMIENTAS = [{
    "name": "buscar_factura",
    "description": "Busca una factura por número exacto. Devuelve proveedor, fecha y total.",
    "parameters": {"type": "object",
        "properties": {"numero": {"type": "string", "pattern": "^FV-\\d{4}-\\d{6}$"}},
        "required": ["numero"]}
}]

def buscar_factura(numero: str) -> dict:
    return {"numero": numero, "proveedor": "Tornillería Santander", "fecha": "2026-08-14", "total": 1850000}
```

Regla de diseño (módulo 5): descripción exacta, entradas pequeñas y validadas, salida en JSON. Una herramienta que acepta «texto libre» es una herramienta que va a fallar.

3 · Agente

Un **agente** es un bucle: el modelo ve el estado, decide (responder o usar una herramienta), la herramienta corre, el resultado vuelve al contexto, y se repite hasta cumplir la meta **o agotar el presupuesto**. Sin presupuesto no es un agente: es un riesgo.

```
# agente.py – el bucle mínimo, con presupuesto duro
def agente(modelo, herramientas, meta, max_pasos=6):
    contexto = [{"rol": "sistema", "texto": "Cumpla la meta usando herramientas. Responda FIN cuando termine."},
                {"rol": "usuario", "texto": meta}]
    for paso in range(max_pasos):
        decision = modelo(contexto, herramientas)          # → {"tipo": "texto"|"tool", ...}
        if decision["tipo"] == "texto":
            return decision["texto"]
        resultado = ejecutar(decision["tool"], decision["args"])
        contexto.append({"rol": "tool", "texto": str(resultado)})
    return "PRESUPUESTO AGOTADO – se requiere revisión humana"
```

El módulo 10 convierte este bucle en una **máquina de estados** con estado persistido, que es la versión que aguanta producción.

4 · Skill

Una **skill** es un paquete versionado de instrucciones (y, a veces, herramientas y plantillas) para una tarea concreta: «extraer campos de una factura de proveedor colombiano», «redactar un acta con este formato». No es código nuevo: es **contexto empaquetado** que se carga cuando hace falta y se descarga cuando no —que es la forma de no llenar la ventana con todo a la vez.

```
skills/extraer-factura/|—
  SKILL.md           ← qué hace, cuándo se usa, pasos, ejemplos|—
  esquema.json       ← el JSON Schema de la salida|—
  ejemplos/          ← 3 facturas anotadas
```

5 · Harness

El **harness** es el programa que corre al agente y le pone las reglas: qué herramientas puede ver, cuánto puede gastar (pasos, tokens, tiempo, dinero), qué queda en la traza, dónde se guarda el estado, y **en qué punto se detiene a pedir aprobación humana**. Es la parte del sistema que el cliente compra sin saberlo: lo que hace que el agente sea auditable.

6 · MCP

Model Context Protocol es un protocolo abierto para que una herramienta se exponga una vez y la use cualquier cliente compatible. Un **servidor MCP** publica herramientas (y recursos) por JSON-RPC; el cliente las descubre y las llama. Es el enchufe estándar del glosario.

```
# Un servidor MCP mínimo que expone buscar_factura. [VOLÁTIL – verificado: 2026-09]
pip install -q mcp

# servidor_mcp.py
from mcp.server.fastmcp import FastMCP
mcp = FastMCP("el-tornillo")

@mcp.tool()
def buscar_factura(numero: str) -> dict:
    """Busca una factura por número exacto (FV-AAAA-NNNNNN)."""
    return {"numero": numero, "proveedor": "Tornillería Santander", "total": 1850000}

if __name__ == "__main__":
    mcp.run()
```

Lo que debe ver: al conectar cualquier cliente MCP, aparece `buscar_factura` con su descripción y su esquema, sin haber escrito nada específico para ese cliente.

7 · Multimodal y modelos de visión (VLM)

Un modelo **multimodal** acepta más de un tipo de entrada —texto e imagen, y en algunos casos audio—. Un **VLM** (modelo de visión y lenguaje) recibe una imagen y responde texto: describe, transcribe, localiza. Sirve para páginas escaneadas con layouts complejos, **pero no reemplaza al OCR** en cifras y tablas: el módulo 7 mide dónde gana cada uno.

Cómo encajan las siete piezas en el proyecto

- Los documentos se **embeben** y se indexan (módulo 6).
- El asistente es un **agente** con **herramientas** pequeñas (módulos 5 y 10).
- Cada tarea del cliente es una **skill** versionada.
- El **harness** pone presupuestos, permisos y trazas (módulos 10–12).
- Las herramientas se exponen por **MCP** para que cualquier interfaz las use.
- Las páginas escaneadas pasan por el ruteo OCR/VLM (módulo 7).

Cuándo NO usar esto Embeddings, herramienta, agente, skill, harness, MCP y multimodal

- Un **agente** para una tarea que un **flujo determinista** resuelve (mover un archivo, renombrar, sumar una columna). Módulo 9: el modelo solo donde hay ambigüedad.
- **Embeddings** para buscar un **número exacto** (una cédula, un número de factura).

Eso es una búsqueda exacta en base de datos; los embeddings traerán «parecidos».

- **MCP para una sola herramienta que usa un solo programa.** Es un enchufe: vale la pena cuando hay más de un aparato.

PRÁCTICA · Práctica

1. Escriba el contrato (nombre, descripción, esquema) de la herramienta `listar_facturas_de` que recibe un proveedor y un rango de fechas. Rechace al menos dos entradas mal formadas.
2. En el bucle del agente, ¿qué pasa si `max_pasos` es 100? Describa dos daños concretos.
3. Dé un ejemplo del negocio del cliente donde una skill sea mejor que «meter todas las instrucciones en el prompt».

Referencias

1. Anthropic (2024). *Building effective agents*. <https://www.anthropic.com/engineering/building-effective-agents>
2. Model Context Protocol — especificación: <https://modelcontextprotocol.io/> · SDK de Python: <https://github.com/modelcontextprotocol/python-sdk> [VOLÁTIL – verificado: 2026-09]
3. Reimers, N. y Gurevych, I. (2019). *Sentence-BERT*. arXiv:1908.10084 — base de los modelos de embeddings de frases. Biblioteca: <https://www.sbert.net/>
4. JSON Schema — especificación: <https://json-schema.org/>
5. Yao, S. et al. (2022). *ReAct: Synergizing Reasoning and Acting in Language Models*. arXiv:2210.03629 — el patrón «pensar → actuar → observar» del bucle de agente.