


IA local para PyMEs · Módulo 5

Ingeniería de contexto



La ventana es un recurso escaso. Salidas con esquema, herramientas pequeñas y poda en agentes largos.

Qué se construye en este módulo

📦 **De prompts a contexto: la ventana como recurso escaso**

Presupuestar la ventana por secciones

📦 **Salidas estructuradas y validación por esquema**

Definir un JSON Schema y validar cada salida


📦 **Diseño de herramientas y poda de contexto**

Escribir herramientas pequeñas con contratos exactos

5.1 · De prompts a contexto: la ventana como recurso escaso

De prompts a contexto: la ventana como recurso escaso

Durante dos años el oficio fue redactar bien la instrucción. Sigue importando, pero dejó de ser el problema principal. El problema principal es **qué entra en la ventana, en qué orden, y qué se saca**: instrucciones, documentos recuperados, historial, resultados de herramientas, esquemas. Eso es **ingeniería de contexto**: tratar la ventana como un recurso escaso y presupuestado.



Tres hechos la vuelven obligatoria:

En una tabla

Partida	Qué es	Tope típico (ventana 8k)	Prioridad
Instrucciones del sistema	quién es, qué puede, formato de salida	600–1 200	fija
Esquema de salida	el JSON Schema, si aplica	200–500	fija
Contexto recuperado (RAG)	chunks relevantes con su cita	3 000–4 500	variable
Historial de la conversación	turnos anteriores, podados	500–1 500	variable
Resultados de herramientas	último resultado, resumido	300–800	variable
Reserva para la respuesta	lo que el modelo va a escribir	800–1 500	fija

El comando, copiable

[instrucciones fijas]	← idéntico en todas las llamadas: se cachea
[esquema fijo]	← ídem
[documentos]	← cambia por consulta
[historial podado]	
[pregunta actual]	← lo más importante, al final, cerca de la respuesta

Si no corre desde cero con un comando, no entra al curso.

Cuándo NO usar esto

De prompts a contexto: la ventana como recurso escaso

- No «arregle» un mal RAG metiendo más chunks: el módulo 6 dice cómo arreglar la recuperación.
- No use la ventana de 128k como excusa para no presupuestar: el prefill de 100k tokens en el perfil B tarda minutos.

Qué se degrada en cada perfil



A · sin GPU

RAG con 2–3 chunks;
sin historial largo



**B · 8–16 GB
VRAM**

RAG con 5–8 chunks;
historial podado




C · 24 GB+

holgura; aun así se
presupuesta, porque
el prefill se paga

5.2 · Salidas estructuradas y validación por esquema

Salidas estructuradas y validación por esquema

Si la respuesta tiene estructura —campos de una factura, una decisión sí/no con motivo, una lista de acciones—, se pide **con esquema** y se **valida**. Lo que no cumple el esquema se rechaza y se reintenta o se encola para un humano. Nunca se «parsea» texto libre con expresiones regulares esperando lo mejor.



Dos capas, siempre las dos:



En una tabla

Perfil	Qué pasa
A	Igual, más lento. La validación es CPU
B / C	Igual

El comando, copiable

```
cd ~/labs/el-tornillo && mkdir -p labs/05-02 && cd labs/05-02 && pip install -q  
jsonschema
```

Si no corre desde cero con un comando, no entra al curso.

Cuándo NO usar esto

Salidas estructuradas y validación por esquema


- No ponga esquema a una tarea de redacción (un acta, un resumen): ahí la salida es texto, y se valida por longitud y por presencia de secciones, no por JSON.
- No confíe en la restricción del runtime para reglas de negocio (`subtotal + iva = total`): eso se valida en código.



5.3 · Diseño de herramientas y poda de contexto

Diseño de herramientas y poda de contexto

Un modelo elige herramientas leyendo sus **descripciones**.
Una descripción vaga produce llamadas equivocadas; una herramienta que hace tres cosas produce argumentos mezclados. Reglas:



Un agente de diez pasos acumula diez resultados de herramientas. Si todos se quedan en la ventana, en el paso ocho ya no cabe la pregunta. La **poda** decide qué se queda:

En una tabla

Regla	Mal	Bien
Una herramienta, una acción	<code>gestionar_factura(accion, ...)</code>	<code>buscar_factura,</code> <code>listar_pendiente</code>
Entradas mínimas y tipadas	<code>consulta: string</code>	<code>numero: string (</code> <code>date, hasta: date</code>
Descripción con cuándo no usarla	«Busca facturas»	«Busca UNA fac
Salida en JSON, corta	vuelca 200 filas	ro exacto. Para ra
Errores como datos	lanza excepción	use <code>listar_factu</code> <code>devuelve</code> <code>total_disponible</code> <code>sor</code> <code>{"error": "no_en</code> <code>"sugerencia": "v</code> <code>prefijo"}</code>
Solo lectura por defecto	cualquier herramienta escribe	las que escribe

El comando, copiable

```
HERRAMIENTAS = [  
    {"name": "buscar_documentos",  
     "description": "Recupera fragmentos de documentos del cliente relevantes para una  
pregunta, con su cita. Respeta los permisos del usuario. No sirve para buscar  
un número exacto: use buscar_factura.",  
     "parameters": {"type": "object", "properties": {"pregunta": {"type": "string", "maxLength":  
300}, "coleccion": {"type": "string", "enum": ["facturas", "contratos", "actas", "  
todas"]}, "k": {"type": "integer", "minimum": 1, "maximum": 8}}, "required": ["pregunta"  
]}},  
    {"name": "buscar_factura",  
     "description": "Devuelve UNA factura por su número exacto (FV-AAAA-NNNNNN). Si no  
existe, devuelve error no_encontrada.",  
     "parameters": {"type": "object", "properties": {"numero": {"type": "string", "pattern": "^  
FV-\\d{4}-\\d{6}$"}}, "required": ["numero"]}},  
    {"name": "crear_borrador_acta",  
     "description": "DESCRIBE: crea un borrador de acta a partir de una transcripción.  
Escriba la transcripción de la reunión en el campo 'transcripcion' y el nombre de la reunión en el campo 'nombre'."}]
```

Cuándo NO usar esto

Diseño de herramientas y poda de contexto

- No dé al modelo veinte herramientas: elige peor y gasta contexto en leerlas. Cinco a ocho por agente; si hacen falta más, es otro agente (módulo 10.2).
- No podes el historial de una conversación de un turno: no hay nada que podar.

Qué se degrada en cada perfil

A · sin GPU

La poda es más agresiva: ventana de 4k–8k

B · 8–16 GB VRAM

Ventana de 8k–16k; resumen de resultados basta

C · 24 GB+

Holgura; se sigue podando por costo de prefill



Entregables del módulo

- el presupuesto de las tres tareas.
- `factura.schema.json`, `extraer.py`, y `labs/05-02/rechazos.md` con los motivos.
- `herramientas.json`, `podar.py` con prueba.

**La ventana es un
recurso escaso.**