

A woman with dark hair is smiling and looking at a laptop. The laptop screen shows a white chat bubble icon on a dark background. The text is overlaid on the image in a large, white, sans-serif font.

Hablando a la IA: Memoria y limitaciones: Cómo gestionar las conversaciones con la IA



01 Memoria de la IA en conversación

Memoria contextual y cambios de tema

La forma en que los modelos de lenguaje recuerdan lo ocurrido en un chat condiciona directamente la coherencia y el estilo de sus respuestas.

Qué es la memoria contextual

La mayoría de sistemas de IA generativa utilizan una memoria contextual: solo recuerdan lo que ocurre dentro de una misma conversación o chat. Gracias a ello pueden mantener el hilo, recordar instrucciones previas y ajustar el tono o el enfoque sin que sea necesario repetirlo constantemente.

Esta memoria, sin embargo, no es global ni permanente. El modelo no “recuerda” interacciones antiguas ni conversaciones en otros chats, solo la información disponible dentro del contexto actual.

Riesgos al mezclar objetivos en un mismo chat

Cuando se combinan tareas muy distintas en una sola conversación, la memoria contextual puede jugar en contra. El modelo reutiliza estilos, supuestos y ejemplos previos incluso cuando ya no resultan adecuados.

- El estilo de escritura puede contaminarse (por ejemplo, pasar de un cuento fantástico a un correo formal manteniendo un tono poco profesional).
- Se arrastran sesgos y supuestos de una tarea anterior que ya no encajan con el nuevo objetivo.

- Instrucciones antiguas pueden entrar en conflicto con las nuevas, generando respuestas confusas o incoherentes.

Cómo separar conversaciones por objetivos

Organizar los chats por propósito ayuda a evitar mezclas de contexto y mantiene a la IA centrada en la tarea relevante en cada momento.

1

Identificar con claridad el objetivo actual: antes de escribir, conviene concretar qué se espera del modelo (por ejemplo, redactar un cuento, preparar un correo formal o diseñar un esquema de proyecto).

2

Detectar cuándo cambia el tipo de tarea: si se pasa de una actividad creativa a otra analítica, o de un borrador informal a un documento profesional, ya existe un cambio de objetivo.

3

Abrir una nueva conversación: crear un chat nuevo equivale a ofrecer un "folio en blanco". De esta manera se evitan estilos, ejemplos y suposiciones heredadas que ya no aportan valor.

4

Resumir en el primer mensaje lo esencial: una breve descripción del contexto, el objetivo y el tono deseado ayuda al modelo a situarse correctamente desde el inicio del nuevo chat.

5

Mantener cada conversación centrada en un tema: cuanto más homogéneo sea el contenido de un chat, más fácil resultará obtener respuestas consistentes y reutilizables.

Memoria limitada y ventana de contexto

Además de la memoria contextual, los modelos de lenguaje trabajan con una cantidad máxima de información que pueden procesar simultáneamente: la llamada ventana de contexto.

Qué es la ventana de contexto

La **ventana de contexto** es el tramo de texto (mensajes de la persona usuaria y de la IA) que el modelo tiene en cuenta para generar la siguiente respuesta. Cuando la conversación se alarga mucho, los primeros mensajes dejan de entrar en esa ventana y, en la práctica, se **“olvidan”**.

Esto explica por qué, en chats extensos, el modelo puede dejar de respetar definiciones o decisiones tomadas al inicio: simplemente han quedado fuera del contexto activo, igual que ocurre en una reunión muy larga en la que nadie recuerda ya los matices del principio.

Cómo detectar y gestionar la pérdida de hilo

Cuando la conversación supera la capacidad de la ventana de contexto, suelen aparecer señales claras de que el modelo ha perdido parte de la información relevante.

- **Recapitular periódicamente:** solicitar algo como «Haz un resumen de lo que llevamos hasta ahora» o elaborar un propio resumen para recuperar los puntos clave.
- **Condensar lo importante:** transformar un intercambio largo en una lista breve de decisiones, definiciones y requisitos que puedan reutilizarse en un nuevo chat.
- **Reiniciar con un nuevo contexto limpio:** abrir otra conversación e introducir el resumen como base, asegurando que la información clave entra de nuevo en la ventana de contexto.



En interacciones largas resulta más eficaz trabajar por ciclos: avanzar unas cuantas iteraciones, recapitular y continuar en un nuevo chat con un resumen sintético.

Buenas prácticas para conversaciones largas con IA

Aplicar algunas pautas simples reduce errores, mantiene el foco de la interacción y mejora la coherencia de las respuestas generadas.

Síntesis periódicas

Introducir resúmenes breves cada cierto número de mensajes ayuda al modelo a priorizar la información realmente relevante y actualizada.

Un objetivo por chat

Mantener conversaciones separadas para tareas creativas, análisis de datos o comunicación profesional evita mezclas de estilo y de supuestos previos.

Repetición de instrucciones críticas

Cuando un requisito es esencial (por ejemplo, un tono formal o un formato específico), conviene recordarlo explícitamente en los mensajes clave.

Resúmenes reutilizables

Guardar fuera del chat los resúmenes y acuerdos principales permite iniciar nuevas conversaciones futuras con una base clara y consistente.



02 Fiabilidad, variabilidad y prompting efectivo

Alucinaciones y verificación de la información

Los modelos de lenguaje generan texto plausible y coherente, pero no están diseñados para garantizar que todo lo que producen sea factual y correcto.

Qué es una alucinación en IA

En este contexto, una alucinación es una respuesta que suena convincente pero contiene datos falsos, mezclas incorrectas de conceptos o referencias inventadas. Puede ocurrir en herramientas como ChatGPT, Copilot y otros sistemas similares.

La causa principal es que estos modelos se entrenan para producir la respuesta más probable dada una entrada, no para verificar su veracidad. Si falta información o existen lagunas, el sistema puede rellenarlas de forma creativa, aunque no sea exacta.

Cómo reducir el riesgo de errores graves

Un uso responsable de la IA generativa exige asumir que siempre puede haber errores y diseñar procesos de comprobación acordes con el nivel de riesgo de cada caso.

- Limitar la IA, al menos al principio, a tareas en las que sea sencillo validar la veracidad de lo que produce.
- Contrastar información relevante con fuentes externas fiables (documentación oficial, bases de datos internas, normativa aplicable...).

- Revisar con especial cuidado cualquier dato numérico, cita, referencia bibliográfica o afirmación jurídica o médica.
- Solicitar que el modelo explique paso a paso cómo ha llegado a una conclusión para facilitar la revisión crítica.

Tipos de respuestas de un modelo de lenguaje

Distinguir la naturaleza de la respuesta ayuda a decidir qué nivel de confianza y de verificación resulta adecuado en cada caso.

| Tipo de respuesta | Características principales | Uso recomendado |
|---|--|---|
| Respuesta factual correcta | Coincide con fuentes fiables y datos verificables; mantiene coherencia interna y externa. | Base útil para borradores de documentos, resúmenes, explicaciones y tareas operativas de baja criticidad. |
| Respuesta factual alucinada | Suena plausible, pero contiene errores, invenciones o referencias inexistentes. | No debe aceptarse sin comprobación; puede servir como punto de partida para una investigación posterior, nunca como fuente final. |
| Respuesta creativa | Incluye metáforas, historias, personajes o elementos imaginativos alejados de lo factual. | Útil para generar ideas, relatos, eslóganes o enfoques originales, siempre separando este uso del trabajo con datos reales. |
| Respuesta incompleta o ambigua | Carece de detalle suficiente, deja conceptos sin definir o mezcla varios enfoques sin priorizarlos. | Conviene aclarar el objetivo, pedir más detalle o reformular la solicitud con instrucciones más precisas. |
| Respuesta claramente errónea o contradictoria | Presenta fallos lógicos evidentes, contradicciones internas o conclusiones que no se derivan de los datos dados. | Debe descartarse y revisarse el prompt inicial, incluyendo ejemplos y restricciones adicionales si es necesario. |



En ámbitos críticos como finanzas, salud, legal o cumplimiento normativo, ninguna respuesta generada por IA debería usarse sin verificación humana rigurosa.

Modelos probabilísticos y variabilidad de respuestas

Los modelos de lenguaje son sistemas probabilísticos, por lo que una misma entrada puede producir respuestas distintas en diferentes ocasiones.

Por qué no siempre responden igual

Estos modelos predicen palabra a palabra el texto más probable, pero introducen cierto grado de aleatoriedad para evitar resultados monótonos. En cada generación pueden elegir caminos ligeramente distintos dentro de las opciones verosímiles.

El resultado es que dos respuestas a la misma pregunta pueden diferir en estructura, ejemplos o nivel de detalle, incluso si ambas son razonables desde el punto de vista estadístico.

Cómo aprovechar la variabilidad a favor

Lejos de ser un defecto, esta variabilidad puede convertirse en una fuente de valor si se gestiona de forma consciente.

- Generar varias opciones creativas (ideas de títulos, enfoques de un texto, soluciones alternativas a un problema).
- Comparar respuestas distintas para detectar puntos de consenso y posibles inconsistencias en la información proporcionada.
- Pedir versiones adicionales con instrucciones concretas (más breves, más técnicas, más divulgativas) para adaptar mejor el resultado al contexto.

Convertir el prompting en una conversación inteligente

Tratar la interacción con la IA como un diálogo iterativo permite mejorar los resultados y, al mismo tiempo, entrenar habilidades de pensamiento estructurado.



Definir el objetivo con precisión: especificar qué tipo de resultado se desea, para qué se utilizará y en qué formato debería entregarse.



Aportar el contexto relevante: compartir la información necesaria (antecedentes, restricciones, tono, público objetivo) para que el modelo pueda situar correctamente la tarea.

3

Dividir las tareas complejas: abordar proyectos amplios en pasos manejables (esquema, borrador, revisión, reescritura), en lugar de pedirlo todo en una sola instrucción.

4

Usar ejemplos y delimitadores claros: mostrar ejemplos de entrada y salida deseada, y separar secciones con marcas explícitas para reducir ambigüedades.

5

Revisar, ajustar y pedir variantes: analizar críticamente la respuesta, corregir lo que no encaje y solicitar nuevas versiones con cambios concretos.

6

Reflexionar sobre el proceso: identificar qué instrucciones han funcionado mejor y cómo puede mejorarse la formulación de futuras peticiones.

Beneficios de dominar el prompting

El desarrollo de habilidades avanzadas de prompting va más allá del uso eficaz de la IA y refuerza competencias clave en otros ámbitos.

Productividad aumentada

Un diseño cuidadoso de las peticiones reduce iteraciones innecesarias y acelera la obtención de borradores, resúmenes y propuestas de calidad.

Creatividad ampliada

La posibilidad de generar múltiples versiones y enfoques permite explorar ideas que quizá no surgirían en un proceso tradicional.

Claridad y orden mental

Formular buenos prompts obliga a clarificar objetivos, jerarquizar información y estructurar pensamientos, habilidades útiles en cualquier disciplina.

Mejor toma de decisiones

Comparar escenarios, recopilar argumentos y analizar riesgos con apoyo de la IA facilita decisiones más informadas y fundamentadas.



Creado por Victoria, AI Founderz Fellow, y aprobado por el equipo de Founderz.



Última actualización 5 de diciembre de 2025



Este documento fue originalmente generado por la IA y revisado por nuestro equipo humano. En Founderz, utilizamos la IA de forma responsable y transparente.