

# ¿Cuál es el costo de trabajar con herramientas de IA generativa de texto?

Juan G. Corvalán y Mariana Sanchez Caparros

El documento analiza los principales factores que influyen en el costo de utilizar modelos de lenguaje grandes como ChatGPT, GPT-4, Gemini y LLaMa2, tanto para uso personal como comercial.




## Variables a considerar



Tokens de **input** y **output** y ventana de contexto son dos de los factores más importantes a considerar al evaluar el costo de uso de grandes modelos de lenguaje.

El **token** es la unidad más pequeña de procesamiento en el modelo. Puede ser una palabra individual, una parte de una palabra o, incluso, un caracter. Cada token se convierte luego en un vector numérico único (TokenID) que el modelo puede procesar para representar información.



El costo de uso de grandes modelos de lenguaje se mide, fundamentalmente, en tokens de input y tokens de output.

**1000 tokens = 750 palabras o un texto de 1 página y media.**

La **ventana de contexto** se refiere al rango de tokens que el modelo tiene en cuenta al generar una respuesta para una determinada solicitud del usuario.



Los modelos que trabajan con ventanas de contexto más grandes, tienen un mayor costo de uso.



### Chat GPT


- Modelo GPT-3.5. Unimodal.
- Trabaja con una ventana de contexto de 4096 tokens (aproximadamente unas 6 páginas).
- Gratuito.
- Límite de 75 mensajes por hora



### Chat GPT4.0

- Multimodal.
- Trabaja con una ventana de contexto de 8192 tokens (aproximadamente unas 12 páginas).
- 20 USD por mes.
- Límite de 40 mensajes cada 3 horas.

## Usuarios comerciales ejemplos



## Ajuste fino y uso del modelo personalizado:

Hacer el ajuste fino con una base de documentos de 300 contratos de unas 5 páginas cada uno equivale a 1.500 páginas o 1.000.000 tokens. El costo asciende aproximadamente a **USD 8**.



- Costo de uso:
- USD 0.024 cada 12 páginas de entrada
  - USD 0.048 cada 12 páginas de salida.



## Servicios de Google y Meta



Gemini, la herramienta de Google, ofrece acceso gratuito a su modelo de IA generativa de texto.



LLaMa2, la herramienta de Meta, ofrece modelos de código abierto que se pueden operar en la nube.

En esos casos se paga costo de alojamiento, de ajuste fino (si hubiera) y de uso medido por consumo de tokens de entrada y salida.

## Equipo de trabajo

### Investigación

Juan G. Corvalán  
Mariana Sanchez Caparros

### Diseño Gráfico

Victoria Mafud

## Resumen ejecutivo

[Accedé acá](#)