

Low-Precision Floating-Point Formats

Análisis Numérico

Daniel Melo

Universidad Nacional De Colombia

September 30, 2026

Uso de la baja precisión en IA

¿Qué está pasando?

- **1985:** IEEE 754 estandariza fp32 y fp64.
- **Hoy:** GPUs e IA imponen formatos de 16 y 8 bits (*bfloat16*, *FP8*).
- **La Razón:** Menor uso de memoria y cálculos más rápidos.
- **El problema:** Perdemos rango y precisión muy rápido.

Comparativa rápida de formatos

Formato	Bits	Precisión (u)	Rango Máx.
fp64	64	10^{-16}	10^{308}
fp32	32	10^{-8}	10^{38}
fp16	16	10^{-4}	65,504
bfloat16	16	10^{-3}	10^{38}
FP8	8	10^{-1}	57,344

Comparativa

fp16: Buena precisión, pero se desborda fácil.

bfloat16: Gran rango, pero solo ~ 2 decimales exactos.

El estancamiento

- Al sumar números muy grandes con números muy pequeños, el pequeño se pierde.
- Las cotas teóricas de error dejan de funcionar.

Redondeo Estocástico

Redondeamos hacia arriba o abajo con probabilidad.

- Cancela errores en promedio.
- Evita que la suma se congele.

Ejemplo

Operación	Valor Exacto	Resultado
Sumar 1 (5000 veces)	5000	2048
Sumar $\sum 1/k$	∞	7.08

* En la serie armónica, el cálculo se congela por completo al llegar al término $k = 512$.

Estrategia para resolver $Ax = b$

- 1 **Trabajo pesado** $O(n^3)$: Factorizar $A \approx LU$ en **fp16** (Rápido).
- 2 **Corrección** $O(n^2)$: Calcular residuos y corregir en **fp64** (Preciso).
- 3 **Repetir** hasta converger.

⇒ Alcanza precisión de fp64 usando el motor rápido de fp16.

Impacto real

En GPUs NVIDIA (V100):

- Hasta $\sim 4\times$ **más rápido** que el solver tradicional en fp64.

Referencias:

Pranesh, Srikara (2019) – Low Precision Floating-Point Formats

Haidar et al. (SC18) – Benchmarks en GPU

Connolly, Higham & Mary (2021) – Stochastic Rounding