

MLOPSDAY BOLOGNA 2026 • COMMUNITY TALK

Il modello non ci sta: le leve per usarlo lo stesso

MoE più grandi della memoria: le idee comuni a tutti i motori



Francesco Montelli


Freelance Software Engineer • montelli.dev

slide
e materiali




Il modello non sta in memoria

MEMORIA



BANDA



LUGLIO - OTTOBRE 2026

Un campo in rapida evoluzione

Flash-MoE

C · Metal

397B

su 48 GB

≈ 4,4 tok/s

MacBook M3 Max

Colibrì

C · solo CPU

744B

su 25 GB

0,05–1 tok/s

portatile, fino a
M5 Max

llama.cpp

proposta, PR aperta

744B

su 128 GB

≈ 2 tok/s

GB10, memoria
unificata

streamoe

MLX · Apple Silicon


35B

su 3–6 GB


8–14 tok/s

MacBook M3 Pro


Meno bit, meno byte

BIT	PESO DI UN MOE DA ~400B	QUALITÀ
16	 ≈ 800 GB	 originale
8	 ≈ 400 GB	 quasi identica
4	 ≈ 200 GB	 lieve perdita
2	 ≈ 100 GB	 tool calling rotto

Fissa in RAM, esperti al bisogno



Caricare prima di sapere

STRATEGIA	COME	GUADAGNI	PAGHI
 On-demand		nessun errore	attesa a ogni layer
 Speculativo		niente attesa, se indovini	se sbagli, due letture
 Prerouting		lettura e calcolo insieme	il modello cambia un po'

Tre leve, tre prezzi

LEVA



Quantizzazione



Esperti su SSD



Caricare in anticipo

GUADAGNI

meno byte

RAM ridotta

niente attesa

PAGHI

sotto i 4 bit si rompe

latenza

**errori, o modello
che cambia**

Non serve più memoria. Serve sapere **cosa tenerci**.



Parliamone

francesco@montelli.dev · montelli.dev
github.com/monte97



slide, paper e materiali