

Alice nel paese delle meraviglie: compiti semplici che mostrano una ripartizione completa del ragionamento in modelli linguistici di grandi dimensioni all'avanguardia

[Presentato il 4 giugno 2024 ([v1](#)), ultima revisione 5 giugno 2024 (questa versione, v2)]

Pdf by:
<https://www.pro-memoria.info>

I modelli di grande linguaggio (LLM) sono spesso descritti come istanze di modelli di base, cioè modelli che si trasferiscono fortemente attraverso varie attività e condizioni in modo few-shot o zero-shot, mentre esibiscono leggi di scala che prevedono il miglioramento della funzione quando si aumenta la scala pre-allenamento. Queste affermazioni di eccellere in diverse funzioni e compiti si basano su misurazioni effettuate su vari set di parametri di riferimento standardizzati che mostrano punteggi elevati per tali modelli. Dimostriamo qui una drammatica ripartizione delle capacità di funzione e ragionamento dei modelli all'avanguardia addestrati alle più grandi scale disponibili che rivendicano una funzione forte, utilizzando un problema di buon senso semplice, breve e convenzionale formulato in un linguaggio naturale conciso, facilmente risolvibile dagli esseri umani. Il crollo è drammatico, poiché i modelli esprimono anche una forte eccessiva fiducia nelle loro soluzioni sbagliate, fornendo al contempo spiegazioni spesso non sensate simili a "ragionamento" simili alle confabolazioni per giustificare e sostenere la validità delle loro risposte chiaramente fallite, facendole sembrare plausibili. Vari interventi standard nel tentativo di ottenere la soluzione giusta, come vari tipi di sollecitazione avanzata, o sollecitare i modelli a riconsiderare nuovamente le soluzioni sbagliate mediante una rivalutazione in più

fasi, falliscono. Prendiamo queste osservazioni iniziali alla comunità scientifica e tecnologica per stimolare la rivalutazione urgente delle capacità rivendicate dell'attuale generazione di LLM, tale rivalutazione richiede anche un'azione comune per creare parametri di riferimento standardizzati che consentano un corretto rilevamento di tali deficit di ragionamento di base che ovviamente riescono a rimanere sconosciuti dalle attuali procedure e parametri di valutazione all'avanguardia. Il codice per riprodurre gli esperimenti nella carta e i dati degli esperimenti grezzi possono essere trovati a [questo URL https](https://www.pro-memoria.info)

Pdf by:
<https://www.pro-memoria.info>