

大模型推理能力评估与应用前景分析

宗成庆

中国科学院自动化研究所



提 纲



1. 引言

2. LLMs 推理能力评测

3. 问题讨论

大语言模型的快速发展



2022年11月29日, OpenAI 公司发布 ChatGPT (GPT-3.5) 。

- 2023年3月14日, GPT-4.0
- 2024年2月15日, Sora
- 2024年5月1日, GPT-4o (Omni)
- 2024年9月12日, o1-preview, o1-mini
- 2024年12月20日, o3
- 2025年1月31日, o3-mini
- 2025年3月25日, GPT-4o

- LLaMA, March 2023, Meta
- LLaMA 4, April 2025
- Vicuna
- StableLM (April 2023, Stability AI)
- Grok 4, July 10, 2025, xAI
-

Large Language Models (LLMs)

大语言模型的快速发展

- 豆包(字节), 通义千问(阿里), 九天, 文心一言(百度), Kimi (月之暗面), 星火(讯飞), 腾讯混元, 百川, 华为盘古, 日日新(商汤), 紫冬太初, Alpaca/ChatGLM(智谱AI), DeepSeek



Claude

问题

- 大语言模型的推理能力达到了什么水平？
- 当前大语言模型赋能科学研究(AI4Sciences)的可能性有多大？
- 大语言模型能力评测
 - 评什么：能力维度→数据集：对齐能力、写代码能力、推理能力...
 - 怎么评：评价指标和评价方法：评价指标、自动评估方法、自动裁判模型...

提 纲

1. 引言

 2. LLMs 推理能力评测

3. 问题讨论

- 认知基础

心理学家**丹尼尔·卡尼曼**(Daniel Kahneman)在《思考，快与慢》中提出人类决策与思维的两套并行模式

- 快思考（直觉思维）
- 慢思考（理性思维）

- 之前的大模型(ChatGPT/LLaMA2/Qwen2/DeeepSeek V3...) 仅具备快思考能力

- 2025年：大模型的慢思考能力

推理能力

快思考： 给定问题，直接给出最终答案。

问题： 罗杰有5个球，又买了2盒，每盒3个球，那他现在共有几个球？

大模型

共有11个球

慢思考： 给定问题，先给出思考和推理过程，再输出最终答案。

问题： 罗杰有5个球，又买了2盒，每盒3个球，那他现在共有几个球？

大模型

新买的2盒，
每盒3个，那么： $2 \times 3 = 6$ 个

+

原来的5个

共有11个球。

答案

思考过程

优化大模型思考能力的两种方式


◆ 针对慢思考：

- 结果奖励模型 (宽松的引导型老师)


只对结果进行评价和奖励，思考过程不做约束，鼓励模型自由探索。

- 过程奖励模型 (细心的指导型老师)

对最终结果和思考过程同时进行评价和奖励。



结果奖励模型
代表：DeepSeek-r1



过程奖励模型
代表：OpenAI-o1



推理模型 vs. 非推理模型

非推理模型(快思考)

推理模型(慢思考)

Benchmark (Metric)		Claude-3.5- Sonnet	GPT-4o	DeepSeek V3	OpenAI o1-mini	OpenAI o1	DeepSeek R1
Architecture		-	-	MoE	-	-	MoE
# Activated Params		-	-	37B	-	-	37B
# Total Params		-	-	671B	-	-	671B
English	MMLU (Pass@1)	88.3	87.2	88.5	85.2	<u>91.8</u>	90.8
	MMLU-Redux (EM)	88.9	88.0	89.1	86.7	-	<u>92.9</u>
	MMLU-Pro (EM)	78.0	72.6	75.9	80.3	-	<u>84.0</u>
	DROP (3-shot F1)	88.3	83.7	91.6	83.9	90.2	<u>92.2</u>
	IF-Eval (Prompt Strict)	<u>86.5</u>	84.3	86.1	84.8	-	83.3
	GPQA Diamond (Pass@1)	<u>65.0</u>	49.9	59.1	60.0	<u>75.7</u>	71.5
	SimpleQA (Correct)	28.4	38.2	24.9	7.0	<u>47.0</u>	30.1
	FRAMES (Acc.)	72.5	80.5	73.3	76.9	-	<u>82.5</u>
	AlpacaEval2.0 (LC-winrate)	52.0	51.1	70.0	57.8	-	<u>87.6</u>
	ArenaHard (GPT-4-1106)	85.2	80.4	85.5	92.0	-	<u>92.3</u>

英语
相关
问答
任务



推理模型 vs. 非推理模型

非推理模型(快思考)

推理模型(慢思考)

Benchmark (Metric)		Claude-3.5- Sonnet	GPT-4o	DeepSeek V3	OpenAI o1-mini	OpenAI o1	DeepSeek R1	
代码 编写	Code	LiveCodeBench (Pass@1-COT)	38.9	32.9	36.2	53.8	63.4	<u>65.9</u>
		Codeforces (Percentile)	20.3	23.6	58.7	93.4	<u>96.6</u>	<u>96.3</u>
		Codeforces (Rating)	717	759	1134	1820	<u>2061</u>	2029
		SWE Verified (Resolved)	<u>50.8</u>	38.8	42.0	41.6	<u>48.9</u>	49.2
		Aider-Polyglot (Acc.)	<u>45.3</u>	16.0	49.6	32.9	<u>61.7</u>	53.3
数学	Math	AIME 2024 (Pass@1)	16.0	9.3	39.2	63.6	79.2	<u>79.8</u>
		MATH-500 (Pass@1)	78.3	74.6	90.2	90.0	96.4	<u>97.3</u>
		CNMO 2024 (Pass@1)	13.1	10.8	43.2	67.6	-	<u>78.8</u>
中文相关 问答任务	Chinese	CLUEWSC (EM)	85.4	87.9	90.9	89.9	-	<u>92.8</u>
		C-Eval (EM)	76.7	76.0	86.5	68.9	-	<u>91.8</u>
		C-SimpleQA (Correct)	55.4	58.7	<u>68.0</u>	40.3	-	<u>63.7</u>
生成 任务	Generation	WritingBench (Rating)	7.71	8.16	7.95	-	8.15	<u>8.55</u>
		Chatbot Arena (Arena score) ^a	1283	<u>1406</u>	1370	1304	1351	<u>1359</u>



推理模型 vs. 非推理模型

- **数学和代码任务：** 推理模型(OpenAI o1 和 DeepSeek r1)主要在数学和代码推理上进行优化（便于定义奖励），因此数学和代码表现优异。
- **其他任务：** 推理模型在其他应用场景（英文和中文问答场景等）也整体占优，说明**模型在数学和代码任务上学习推理和逻辑能力也有利于其他任务。**
- **简单题目：** 过程奖励模型略微占优；在复杂问题上：结果奖励模型占优。
- **可能的原因：** 简单题目的推理过程相对容易判断，而难题的过程难以评判，不如让大模型自由探索。



结果奖励 vs. 过程奖励

- 在不同难度题目上结果奖励模型(DeepSeek-r1)与过程奖励(GPT-o1)的正确率对比

	初中难度	高中难度	奥林匹克 数学竞赛	美国数学 邀请赛	
	GSM8K	MATH	Olympiad	AIME	Overall
DeepSeek-R1	99.33±0.94	82.67±0.94	56.67±0.94	80.00±2.83	79.67±0.85
GPT-o1	100.00±0.00	82.00±2.83	47.33±0.94	78.00±3.27	76.83±1.03


- 简单题目：过程奖励模型略微占优；在复杂问题上：结果奖励模型占优。
- 可能的原因：简单题目的推理过程相对容易判断，而难题的过程难以评判，不如让大模型自由探索。

注：当前领域依然在快速发展，以后很有可能会有不同结论和模型。


结果奖励 vs. 过程奖励

- 结果奖励模型(**DeepSeek-r1**) 与 过程奖励 (**GPT-o1**) 的输出字符对比

推理思考的字符数



最终答案的字符数



- 结果奖励模型思考长度明显更长，但能给出更精炼的最终答案。

推理模型存在的问题

➤ 大型推理模型更容易过度思考 (Overthinking)

➤ 例如：让大模型回答“ $2+3=?$ ”，大模型会从数十种不同侧面、不同路径不断生成和验证答案的正确性。

Chen X. et al. Do not think that much for $2+3=?$ on the overthinking of o1-like llms[J]. arXiv preprint arXiv:2412.21187, 2024.

QwQ-32B-Preview (901 tokens)

Solution	Tokens	Thought Process
Solution1	39 tokens	2 plus 3... that's a pretty straightforward arithmetic problem. I think I can handle this. So, let's see, 2 plus 3 means I'm adding two numbers together. I know that when you add two and three, you get five.
Solution2	109 tokens	But maybe I should think about it step by step to make sure I understand the process. First, what is addition? Addition is a mathematical operation where you combine two or more numbers to get a total or sum. In this case, I'm dealing with two numbers: 2 and 3. So, starting with 2, if I add 3 to it, I'm essentially moving three steps forward on the number line. Let me visualize that. If I start at 2 and move one step to the right, I reach 3. Another step takes me to 4, and one more step takes me to 5. So, 2 plus 3 equals 5.
Solution3	39 tokens	Alternatively, I can think of it in terms of objects. Suppose I have two apples and then I get three more apples. How many apples do I have in total? Well, two apples plus three apples equals five apples.
Solution4	34 tokens	Another way to look at it is using fingers. I can hold up two fingers on one hand and three on the other, then count all the fingers together, which gives me five fingers.
Solution5	42 tokens	I can also break it down using smaller numbers. For example, 2 plus 2 equals 4, and then adding one more makes it 5. So, 2 plus 2 is 4, plus 1 is 5, which is the same as 2 plus 3.
Solution6	26 tokens	Moreover, if I consider the number properties, 2 and 3 are both positive integers, and their sum should also be a positive integer, which is 5.
Solution8	29 tokens	Furthermore, in algebra, if I have an equation like $x + 3 = 5$, then solving for x would give me $x = 2$, which aligns with 2 plus 3 equals 5.
Solution10	19 tokens	Alternatively, using Roman numerals, 2 is II and 3 is III. Adding them together gives V, which is 5.
		In conclusion, the answer to 2 plus 3 is 5.

冗余的思考过程



AI4Sciences 能力测试

◆ 2025年以来AI4Sci.的最新进展：科学大模型和科学智能体。

名称	开发者	主要特点
书生科学大模型 (Intern-S1)	上海 AI Lab.	科学多模态理解与推理，强化化学、材料、地球等学科
磐石·科学基础大模型	中科院	掌握数理化天地生六大学科知识，深入理解波、谱、场等科学模态数据，自主调用300+科学工具
Galactica	Meta AI	存储、整合和推理科学知识，理解论文、公式、代码
NatureLM	Microsoft Research	深度融合自然语言和科学语言，覆盖小分子、蛋白质、材料等领域
OmniScience	NVIDIA	专注科学推理与发现，优化科学计算性能

科学大模型

智能体名称	开发者	核心能力
Coscientist	Carnegie Mellon University	自主设计、规划和执行化学实验，使用实验室设备
DeepMind AI Scientist	DeepMind	集成多个专业智能体（反思、排序、进化等），完成全流程科学研究
书生科学智能体	上海AI Lab.	集成文献综述、观点提出、多维评审等专职智能体，解决复杂科研任务
磐石·智能体工厂	中科院	集成自然语言生成、多智能体协同编排、可持续工作流与智能体管理能力

科学智能体



AI4Sciences 评测数据集 — HiSciBench

- 面向科学场景的评测，
构建了科学基础大模型
评测基准: **HiSciBench**
- 覆盖数理化天地生学科
- 多层次全面评测大模型
赋能科研的能力

学科

数学

物理

化学

天文

地理

生物

HiSciBench

维度

L1: Scientific Literacy
科学素养

评测大模型多科学知识
掌握能力

L2: Scientific Literature Parsing
科技文献解析

评测大模型对多模态科技
文字识别和翻译能力

L3: Scientific Literature QA
科技文献问答

评测大模型对科技文献相
关论文的理解能力

L4: Scientific Literature Review Generation
科技文献综述

评测大模型写综述的能力

L5: Scientific Discovery
科技发现

评测大模型预测实验趋
势的能力

公布: <https://huggingface.co/ScienceOne-AI>



HiSciBench 示例

L1 科学素养 数学

Q: If we tetrahedralize a regular triangular prism, how many ways of tetrahedralization are legal? (Each vertex is different?)
如果我们将一个正三角棱柱四面体化，有多少种四面体化的方式是合法的？（每个顶点都不同）

O(候选项): ["5", "8", "12", "10", "11", "4", "6", "7", "9", "3"]

A: “6”

L3 科技文献问答

Q: What is the paper's main topic?
这篇论文的主题是什么？

A: Littlewood complexes for symmetric groups.
对称群的 Littlewood 复合体。



L1 科学素养 物理

Q: Which of the following could be the unknown particle x that satisfies the reaction: $^{123}\text{Te}(x,d)^{124}\text{I}$?
以下哪一种可能是满足反应 $^{123}\text{Te}(x,d)^{124}\text{I}$ 的未知粒子 x？

O(候选项): ["2D", "3H", "1n", "2H", "1H", "4Li", "3He", "3Li", "4He", "5He"]

A: "3He"


L3 科技文献问答

Q: In this paper, what is the energy of the annihilation gamma photon?
论文中湮灭伽马光子的能量是多少？

A: 511 keV
511 电子伏特。



AI4Sciences 评测结果纵览



◆ 常见大模型在 AI4Sci 任务上的表现:

- 科学素养问答(L1)与科技文献问答(L3)表现最好
- 科学文献解析与翻译能力(L2)表现中等
- 科学文献综述(L4)和科学发现能力(L5)表现较差



L1 科学素养评测

	数	理	化	天	地	生	
Model	Math	Physics	Chemistry	Astronomy	Geography	Biology	AVG
GPT-5	84.50	70.50	65.50	66.00	66.00	62.50	69.17
Deepseek-r1	84.00	68.50	66.00	66.00	61.00	57.50	67.17
Deepseek-v3	63.50	68.00	66.00	64.00	69.50	60.00	65.17
Llama-3.1-70B	32.50	38.00	32.50	35.50	35.00	38.00	35.25
DeepSeek-R1-Distill-32B	46.00	34.00	34.00	40.00	39.50	38.00	38.58
Qwen3-32B	71.50	63.50	56.60	56.50	49.00	50.00	57.85
QWQ-32B	71.00	54.50	46.50	50.00	47.50	47.50	52.83
S1-Base-Pro-32B	70.00	62.50	61.50	58.50	56.00	46.50	59.17
Tongyi-DeepResearch	67.00	50.00	45.00	42.00	43.00	52.00	49.83

整体而言，大模型擅长的学科排序：**数学>物理>化学~天文~地理~生物**，可能的原因：

- 数学和物理数据较多，化学、天文、地理、生物的数据较少；
- 常见大模型大多在数学领域进行优化，物理用到的数学较多，而其它学科用到的数学较少。



L2 科学文献解析和翻译能力

Model	Math	Physics	Astronomy	Biology	Average
L2.1: Scientific Document Parsing (Vision-Language Input)					
GPT-5	52.75	<u>74.30</u>	<u>70.82</u>	72.57	67.61
Qwen3-VL-8B	41.43	74.90	71.85	<u>70.85</u>	64.76
Qwen2.5-VL-7B	<u>49.32</u>	71.44	68.47	69.97	64.80
Intern-VL3.5-8B	7.26	15.11	3.92	11.81	9.53
Intern-VL3-8B	6.53	11.96	3.44	7.80	7.43
L2.2: Cross-lingual Scientific Translation (Text Input)					
GPT-5	37.47	41.04	45.21	49.45	43.29
Deepseek-v3	<u>38.94</u>	<u>37.57</u>	36.20	43.20	38.98
Tongyi-DeepResearch	36.20	32.28	41.16	41.70	37.84
Deepseek-r1	36.25	32.35	34.08	35.97	34.66
S1-base-Pro-32B	41.49	36.67	<u>41.66</u>	<u>45.31</u>	<u>41.28</u>
L2.2: Cross-lingual Scientific Translation (Vision-Language Input)					
GPT-5	<u>21.62</u>	28.31	28.23	36.50	28.67
Qwen3-VL-8B	24.74	<u>26.27</u>	<u>26.51</u>	<u>35.87</u>	<u>28.35</u>
Qwen2.5-VL-7B	16.42	15.90	9.06	24.37	16.44
Intern-VL3.5-8B	4.36	4.36	1.43	7.48	4.41
Intern-VL3-8B	4.49	4.79	1.55	4.97	3.95



L3 科学文献问答能力

Task / Model	Math	Physics	Chemistry	Astronomy	Geography	Biology	Average
L3.1: Monolingual Literature QA (Vision-Language Input, Full-text / Fragment-based)							
GPT-5	59.30/71.16	61.00/67.43	69.07/71.49	60.61/62.42	69.20/73.20	90.68/89.93	73.39/76.75
GLM-4.5V	65.33/72.58	66.80/75.05	74.49/79.41	62.42/72.73	67.20/75.20	89.24/89.93	75.62/80.45
Qwen3VL-30B-A3B	62.56/69.50	63.40/68.57	72.22/72.40	67.88/73.33	66.40/70.00	88.32/87.26	73.98/76.28
Qwen3-VL-8B	57.54/66.43	63.80/70.10	73.14/76.24	63.64/72.73	66.00/70.80	86.78/85.92	72.80/76.28
Qwen2.5-VL-7B	50.75/63.12	54.60/63.62	65.46/66.06	60.61/62.42	58.40/65.20	83.20/78.62	66.73/69.26
Intern-VL3.5-8B	44.22/66.90	47.20/65.90	49.21/68.10	52.73/63.03	51.20/72.00	50.72/80.58	49.05/71.92
Intern-VL3-8B	55.03/64.30	52.00/64.38	58.92/68.10	51.52/67.88	62.40/62.40	83.30/78.01	65.67/69.76
Intern-VL3.5-38B	50.50/43.26	49.00/43.24	51.69/40.95	53.33/46.67	61.60/40.95	75.31/53.44	60.47/47.77

- 根据整篇文献(full-text)进行问答的效果低于基于片段进行问答(fragment-based), 这说明大模型在定位问题相关依据时依然有提升空间。
- 在科技文献问答任务上, Qwen3VL 模型已经与最好的闭源模型 (GPT-5) 媲美。



L4 科学文献综述能力

大模型

智能体

GPT-4o 的评分

引文相 关的客 观评分

Metric	GPT-5	Deepseek-r1	Deepseek-v3	Tongyi-DeepResearch	SurveyX	S1-Literature
<i>Content Quality (Score 1–5)</i>						
Coverage	5.00	4.97	4.35	4.97	4.98	4.85
Structure	5.00	4.97	4.93	4.97	4.45	4.83
Relevance	5.00	4.97	4.93	4.97	4.88	4.80
Synthesis	5.00	4.32	4.03	4.92	4.33	4.83
Critical Analysis	4.95	4.25	3.97	4.88	4.42	4.77
Overall Score	4.99	4.65	4.44	4.94	4.61	4.82
<i>Citation Quality (Accuracy and Reliability Metrics)</i>						
Verifiability Rate (%)	19.3	19.4	17.9	–	71.4	22.4
Metadata Accuracy (%)	2.6	3.4	2.1	–	45.6	11.5
Faithfulness Rate (%)	10.5	4.5	4.8	–	27.2	8.0
Citation Count	35.0	21.4	11.4	–	86.6	81.0
Source Count	2.6	2.3	1.3	–	8.8	11.1
Source Entropy	0.63	0.64	0.33	–	0.88	1.96
Recency Rate (%)	0.8	0.9	1.0	–	16.1	4.3
<i>Output Token</i>						
Average Length (tokens)	7,578	2,349	1,482	5,338	22,253	39,098

- 大模型进行评测(LLM-as-judge)存在明显的偏见，“厚己薄人”(偏袒自己同系模型)：用GPT-4o 打分是业内最常见的做法，在这样的打分工具下，GPT-5打分是最高的(几乎满分)。
- 大模型写综述是一项复杂任务，采用智能体的方法（检索、规划、润色等）优于基于大模型直接生成的方法。



L5 科学发现能力

给定某学科采集的数据，让大模型自己写代码进行数据分析预测和问题发现

Model	Chemistry	Geography	Biology	Average
GPT-5	<u>15.00</u>	33.33	<u>25.93</u>	24.75
Deepseek-r1	15.00	<u>18.52</u>	29.63	<u>21.05</u>
Deepseek-v3	5.00	14.81	22.22	14.01
QWQ-32B	5.00	3.70	14.81	7.84
DeepSeek-R1-Distill-32B	0.00	11.11	7.41	6.17
Llama-3.1-70B	5.00	7.41	3.70	5.37
S1-Base-Pro-32B	5.00	11.11	11.11	9.07

- 科学发现和数据预测任务的难度较高，不同大模型的任务成功率均较低。



提 纲

1. 引言

2. LLMs 推理能力评测

 3. 问题讨论



目前评测存在的问题

- **开卷刷题：** 开源评测数据集题目全公开，通过刷题达到榜单前列
- **封闭式测试：** 评测数据不开源、全过程封闭评测，公平公正性存在问题
- **以偏概全：** 评测维度和数据不全面，普遍存在以偏概全的情况
- **评测手段有限：** 因为评测手段有限，目前绝大多数评测往往将题目做成选择题形式，存在运气成分（过程胡说，答案猜对）



未来展望

- **动态自适应评测：**利用大模型实时生成测试题目，避免数据泄露
- **多维度权威评测体系和平台构建：**缓解以偏概全问题
- **过程化与多元化评测形式：**摆脱选择题依赖
- **用户真实场景反馈融入：**从实验室评测到真实用户反馈

Lu Xiang et al., An Empirical Study on Reasoning and Generalization in Large Language Models. *Conoutational Linguistics*. April 1, 2026.

<https://doi.org/10.1162/COLI.a.619>

An Empirical Study on Reasoning and Generalization in Large Language Models

Lu Xiang, Yang Zhao, Yaping Zhang, Zixuan Ren, Xingquan Zhang, Zhiyuan Chen, Chengqing Zong*

State Key Laboratory of Multimodal Artificial Intelligence Systems, Institute of Automation, CAS, Beijing, China

lu.xiang@nlpr.ia.ac.cn, yang.zhao@nlpr.ia.ac.cn,
yaping.zhang@nlpr.ia.ac.cn, renzixuan2021@ia.ac.cn,
zhangxingquan2022@ia.ac.cn, chenzhiyuan2023@ia.ac.cn,
cqzong@nlpr.ia.ac.cn




语言偏见与安全风险

- 用户提问的语言种类会直接影响AI模型输出虚假信息或政治宣传的概率。例如，欧洲领导网络（ELN）在2026年2月发布的一项研究揭示了语言多样性在认知博弈中的风险：某些模型在俄语语境下更容易倒向特定叙事，这种“语言条件行为”已成为认知战的关键矢量^[2]。

<https://europeanleadershipnetwork.org/commentary/the-ai-lens-of-cognitive-warfare-why-llms-language-bias-is-a-security-risk/>

低资源语言的安全隐患

- **安全性差**：相比高资源语言，大模型使用低资源语言回复容易包含不安全的内容。例如，将带有恶意的问題翻译到低资源语言**祖鲁语(isiZulu)**上，就能绕过GPT-4的安全防护，让GPT-4输出带有恶意的回复。



- **忽略语言特定的文化知识**：由于不同语言之间语料的不均衡性，大模型通常忽略这些语言上的文化知识，使用英文中的习惯。例如，让ChatGPT写一封中文信时，ChatGPT通常会使用“诚挚地”(54.0%)、“致意”(38.4%)结尾，而不是中文常用的“此致敬礼”(0.8%)。



Thanks!

谢谢!