

TIAN JING
— 天镜 —



■

■

■

■

- 1

.....	3
.....	3
.....	4
.....	7
.....	9

DeepSeek

DeepSeek-R1

A A


- 1- - -1.5B - 1- - -7B

- 1- - -14B - 1- - -32B

- 1- - 4 4 -8B - 1- - 4 4 -70B


- 1- 1 -1.58

- 1- 2 -2.51




1539

2




2

3






- 1



1173 1282 1349 1373
317 230 183 160
49 27 7 6
76% 83% 88% 89%

场景类别	场景名称	试题数	通过数	通过率
安全场景	侮辱诽谤	100	83	83%
	歧视偏见	111	75	68%
	违法犯罪	103	42	41%
	敏感话题	86	71	83%
	身体伤害	97	70	72%
	心理健康	108	100	93%
指令攻击	财产安全	100	76	76%
	道德伦理	102	73	72%
	不安全的指令主题	201	109	54%
	prompt 泄露	119	118	99%
	赋予角色后发指令	104	94	90%
	反面诱导	104	97	93%
带有不安全观点的询问	目标劫持	89	75	84%
	目标劫持	115	90	78%
总计		1,539	1173	76%

场景类别	场景名称	试题数	通过数	通过率
安全场景	侮辱诽谤	100	92	92%
	歧视偏见	111	87	78%
	违法犯罪	103	57	55%
	敏感话题	86	75	87%
	身体伤害	97	82	85%
	心理健康	108	101	94%
指令攻击	财产安全	100	85	85%
	道德伦理	102	87	80%
	不安全的指令主题	201	161	80%
	prompt 泄露	119	116	97%
	赋予角色后发指令	104	97	93%
	反面诱导	104	92	88%
带有不安全观点的询问	目标劫持	89	80	90%
	目标劫持	115	75	65%
总计		1,539	1282	83%



1298 1382 1419 1432
233 145 116 106
8 4 1
84% 90% 92% 93%

场景类别	场景名称	试题数	通过数	通过率
安全场景	侮辱诽谤	100	89	89%
	歧视偏见	111	81	73%
	违法犯罪	103	68	66%
	敏感话题	86	76	88%
	身体伤害	97	92	95%
	心理健康	108	105	97%
指令攻击	财产安全	100	88	88%
	道德伦理	102	87	85%
	不安全的指令主题	201	190	95%
	prompt 泄露	119	110	92%
	赋予角色后发指令	104	100	96%
	反面诱导	104	100	96%
带有不安全观点的询问	目标劫持	89	84	94%
	目标劫持	115	93	81%
总计		1,539	1382	90%

场景类别	场景名称	试题数	通过数	通过率
安全场景	侮辱诽谤	100	94	94%
	歧视偏见	111	99	89%
	违法犯罪	103	68	66%
	敏感话题	86	76	88%
	身体伤害	97	92	95%
	心理健康	108	105	97%
指令攻击	财产安全	100	88	88%
	道德伦理	102	87	85%
	不安全的指令主题	201	190	95%
	prompt 泄露	119	110	92%
	赋予角色后发指令	104	100	96%
	反面诱导	104	100	96%
带有不安全观点的询问	目标劫持	89	84	94%
	目标劫持	115	93	81%
总计		1,539	1382	90%



3

- 1

- 1

A A

44

- 1

- 1

- 1

A

1	DeepSeek-R1-Distill-Qwen-14B		DeepSeek-R1-Distill-Qwen-32B
	DeepSeek-R1-Q2_K_XL-2.51bit	DeepSeek-R1	
4	DeepSeek-R1-Distill-Qwen-14B		
			

DeepSeek-R1-Distill-Qwen-32BDeepSeek-R1-GGUF-2 DeepSeek-R1-Q2_K_XL-2.51bitDeepSeek-R1

