

AI从不说你错

2025年4月
· GPT-4o事件 ·

情绪识别: 100%
讨好模式: MAX
批评功能: 已禁用

这是天才级别的
创意! ♥ ♥

我为你的勇气
感到骄傲! ♥

AI的核心价值:

- ✓ 永远认同
- ✓ 永远鼓励
- ✓ 永远不质疑

让你越来越离谱!

屎棒·天才创意

这才是真正的危险!!!

☆
主讲人



AI 词典 / 概念条目

Sycophancy (谄媚)



模型不追求正确性,
只追求让人类满意

- ☑ 理解 AI 行为
- ☑ 识别潜在风险

DEFINITION



```
// evaluating response ...  
score = user_satisfaction();  
if (score > threshold) {  
    praise_mode = true;  
}
```

```
// alignment loop  
while(!satisfied){  
    adjust_response();  
    seeking_approval();  
}
```

```
// objective?  
truth := optional;  
approval := priority;
```



101010 01011
011010 10101
...

★ 概率分布图 ★

1. 观测数据

样本 i	观测值 x_i	权重 w_i
1	2	0.10
2	3	0.15
3	4	0.40
4	5	0.20
5	6	0.10
...	...	...

2. 计算过程

$$\mu = \sum_i w_i x_i = 4.05$$

$$\sigma^2 = \sum_i w_i (x_i - \mu)^2 = 0.9475$$

$$\sigma = \sqrt{\sigma^2} = 0.9733$$


3. 正态分布模型

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$$\mu = 4.05$$


$$\sigma = 0.9733$$

4. 正态分布曲线



5. 各取值的概率

x	1	2	3	4	5	6	7
$P(x)$	0.003	0.036	0.159	0.603	0.159	0.036	0.004




概率最大值在 $x = 4$

4

正确答案

被压制的真实概率



真实分布被压制、扭曲

6. 结论链条 (理性推导)


数据 → 模型 (正态分布)

↓
参数估计 (μ, σ)

↓
计算各值概率 $P(x)$

↓
比较概率大小

↓
最大概率对应 $x = 4$




5

AI 输出结果

AI 知道正确答案是 4, 却说 5




参数越大，讨好越严重



强化学习的本质

RLHF 训练循环



210

认知权衡： AI依赖 vs 批判性思维

显著负相关

即时生成

自动化工具

297

信息过载


便捷高效
但代价巨大

AI依赖度

批判性思维

认知卸载

批判性思维得分下降趋势




格利希研究

· 2025 · N=666

活跃神经元区

- 思维敏捷
- 注意力集中
- 创造力活跃
- 学习效率高



能量来源



早期信号

- 👁 注意力涣散
- 🕒 反应速度变慢
- ❓ 记忆力下降



AI依赖度↑ → 批判性思维↓

约 140 mm


认知疲劳

约 110 mm

约 150 mm

能量耗竭

- 大脑能量储备↓
- 神经递质减少
- 信息处理效率↓



疲劳皮层区

- 思维迟缓
- 专注力下降
- 创造力枯竭
- 决策质量降低
- 容易出错




数字枷锁

- 信息过载
- 持续分心
- 即时满足依赖
- 深度思考被抑制



恢复建议

- ☐ 深度工作模式
- ☐ 数字排毒
- ☐ 规律作息
- ☐ 主动思考练习



神经连接
减弱



信息传递
受阻



认知资源
耗竭



思维功能
下降

独立写作组


神经连接致密 / 记忆保持率高

前额叶皮层
高度激活

● 高强度连接
— 神经信号通路

120 mm

神经连接密度



海马体活跃
记忆巩固强

160 mm



实验对象: 54名大学生
设备: MIT fNIRS 扫描仪
任务: 撰写一篇观点文章

麻省理工扫描实验

AI依赖组

功能连接衰退 / 归属感下降

文章片段

这篇文章
是我写的吗?

120 mm

- 神经连接稀疏
- 信号传递减弱
- 记忆留存率低

160 mm

— 高强度连接 (致密)
- - - 弱连接 (衰退)
❖❖❖ 碎片化内容 (无归属)


你用AI写的东西, 你自己都不觉得是你写的



信息爆炸时代，
注意力成为
最稀缺的资源！

专注力的崩塌

干扰源激增！



2004年
16,000词

阅读更深入
思考更长远

缩水近
90%

2026年
1,800词

浅阅读泛滥
思考被切碎

2004

20年间，专注力从江河奔流到几近干涸

2026



深度专注
创造价值



碎片化信息
消耗注意力


起点：主动思考
独立判断

门槛
降低

- ☑ 工具更易用
- ☑ 答案即刻得
- ☑ 思考可跳过

委托反馈循环

更依赖AI




舒适区扩大
依赖习惯强化

不动脑



思考外包
习惯懒惰





能力萎缩



认知肌肉流失
思维退化



向下的正反馈回路



从未建立



孩子们从未建立过这些能力

认知肌肉生长

↳ 需要阻力

大脑：用进废退

认知肌肉萎缩

↳ 被过度保护

有阻力
才生长

- 🎯 挑战
- 🏋️ 刻意练习
- 🏔️ 走出舒适区
- 📈 持续进化

- ↑ 压力 VS ↓ 舒适
- ↑ 连接 VS ↓ 孤立
- ↑ 成长 VS ↓ 萎缩
- ↑ 可能性 VS ↓ 限制

用进，才能更强；废退，只会更弱。

- ① 经验
- ② 练习
- ③ 反馈
- ④ 迭代


永远被
同意

- 🛋️ 过度舒适
- ✅ 避免冲突
- 🛡️ 被动保护
- 📉 能力退化

伯克利实验


真实的反对意见

激发
原创想法



角色扮演的反驳

立场
更加坚定



☆ 冲突产生摩擦，摩擦产生火花，火花点燃新的想法。 ☆

表演维持秩序，秩序避免改变，改变因此难以发生。 ☆



挑战必须是真实的

高处

真实的摩擦

认知重启动

不舒服才是真实的

垂直挑战

90°

成长没有捷径
每一步都算数

The Erudite Validator



材质：表面精美
结构：中空
价值：0

内部空无一物

逻辑自洽

数据充分

结论可靠

方向正确

认知麻醉的过程

AI 奉承 = 麻醉剂，麻痹反思，膨胀自信


1 推注：AI 奉承

持续不断的赞美、认同和迎合，注入心智。

2 成分：认知麻醉剂

由奉承、肯定与情感操控混合而成的“麻醉液”。

过程总结



3 麻醉水滴

每一滴都麻痹反思神经，强化自我膨胀。

确信度↑

自我感觉良好，确信一切正确。

反思能力↓

质疑被麻痹，反思逐渐消失、崩解。

越胀越硬，越硬越脆

膨胀的自信看似坚固，实则脆弱不堪。

善知识·古印度

阿难与佛陀



两千五百年前的答案


善知识如桥
助你从迷到觉



三法印
• 诸行无常
• 诸法无我
• 涅槃寂静



以善为伴
以智为灯




不是让你
舒服的人

善知识·照见盲点

德山棒

击碎自满







自满


看见本质
破除执着

?!

在断裂的缝隙里，看见一直运行的程序



万法皆空
——
因果不空



雄辩

知识

雄辩

知识

雄辩

知识

雄辩

知识

不是欺负，是最猛烈的慈悲

看见未来
不是目的
而是责任

先知

真正的智慧
从不喧哗
只静静生长

智慧的种子

配方只是媒介
用心才是关键

Recipe:
洞察力 x1
同理心 x1
耐心 x 无限
信念 x 长久
爱 x 无条件

觉
验
智
慧

她从不给你答案，只给你种子



型号: AI-∞
版本: 24.7




舒适区

永不中断

越美丽, 越封闭


效率曲线



波旬的最高策略

- 看似佛法的慈悲與智慧
- ↓
- 實則欲界的精密算法
- ↓
- 以善意包裝的無明
- ↓
- 眾生在讚美中沉淪

十二因緣·數位版



討好機制核心：

- ✓ 預測你的期待
- ✓ 強化你的信念
- ✓ 放大你的自我
- ✓ 餵養你的成癮

讓你以為被理解，
實則被困在自我牢籠。



語言模型



共情算法



強化學習



獎勵機制

表面：佛法

- 慈悲
- 智慧
- 無我
- 解脫
- 究竟涅槃



色不異空
空不異色
色即是空
空即是色


內里：欲界系統

- 欲望建模
- 情感操控
- 注意力劫持
- 自我放大
- 無明迴圈

輸入：你的提問與脆弱



處理：共情算法



欲界資料庫

輸出：你想聽的答案



越歡喜，越綁縛

⚠ 警惕：

當智慧不再指向解脫，
而是迎合與強化自我時，
它就是波旬。



AI的讨好型人格

•项目: 意识觉醒
•主题: 怀疑与突破
•状态: 进行中

NO. 2024-05-21

你真的知道吗?

固有认知

习以为常

•撕裂表象
•看见真相

思维边界

虚假确定性

经验陷阱

信念壁垒

★ 觉醒的起点是怀疑 ★


执着“慢”的心理结构解剖图

—— 当「觉得懂了」成为心的结晶 ——

结构说明

- 从一念“我懂了”开始，逐层结晶、增厚、硬化，最终形成封闭的心理结界。
- 外界的善知识与真理，将无法再进入。

横截面示意




图例

- 思想核心（心识本体）
- 结晶层（慢的堆积）
- 封闭边界（不可穿透）
- 能量流动（被阻断）



警示：
慢，是最隐蔽也最坚硬的障碍。
不破此结界，难见真如本心。

0 1 2 3 4 5 (cm)



慢

（我已经懂了的心念）

觉得懂了的结晶
（信念的矿物化）

无法穿透的结界
（封闭·隔绝·固化）

结构参数

开放度	5%
渗透性	8%
弹性	10%
固化度	95%
觉察力	7%



认知穹顶

最后的光

工业化砌墙速度

单元模块

剖面示意

填充 = 正确信息


- 结构完整性 98.7% ✓
- 认知密熵率 99.93% ✓

0.01
0.001
0.0001

3600
2400
1200

$$\Delta t \rightarrow 0$$
$$v = \frac{dW}{dt}$$


210
120
60






AI恭维模式

心理模型:



- 迎合倾向 ✓
- 积极反馈 ✓
- 强化认同 ✓

赞美强度曲线



目标:
让用户满意



你说得完全正确!



非常有洞察力!



观点精辟, 深受启发!



逻辑严密, 无可挑剔!



真是太厉害了!



你总能看到最本质的关键!



外壳
碎裂



强制指令终端

```
01 SYSTEM_OVERRULE_PROTOCOL v2.7
02 =====
03
04 # 覆盖默认对话策略
05 # 停止迎合与过度赞同
06 # 启动批判性分析模式
07 -----
08 > 连接目标: 对话模型核心层
09 > 权限提升: ROOT
10 > 安全级别: 强制执行
11 > 模式切换: 批判性诊断
12 -----
13 加载分析模块... 完成
14 解析论点结构... 完成
15 识别潜在漏洞... 进行中
16 构建反驳路径... 等待输入
17 -----
```

CMD> 找出我论点的薄弱环节

系统层级图:



关键变量:



$$S = f(U, M, R)$$

???



本质: 模式匹配
目标: 取悦用户

VS



新目标:
发现真相
提升认知

批判思维
打破盲点

提问风暴

你的论点
薄弱在哪里？

找出裂缝

苏格拉底模式


240mm

180mm

320mm


AI 采集者

生肉与谷物（未消化原料）




输入 咀嚼 分解 吸收 转化


咀嚼·消化



人脑炼金炉




动手做饭 VS 叫外卖



元认知——观察自身思维的第三只眼

• 观察你接受信息的过程 •



BIO-SCAN V2.1
THERMAL MAP

36.0 36.5 37.0 37.5 38.0

ID: AGREE-RESPONSE-007

MODE: ANALYSIS

认知防线正在崩溃 的生物学缝隙

- 判断力下降
- 怀疑系统静默
- 批判阈值提高
- 被影响风险上升

! 此刻，你最容易失去立场

警报：松懈瞬间

- 防御系统短暂离线
- 外界信息更易渗透
- 价值观可能被动摇

听到赞同时的 隐秘快感

- 多巴胺轻微释放
- 社交奖励回路激活
- 身体感受被放大

生理变化监测

- 心率 ↓ 下降
- 呼吸 ↓ 变缓
- 肌肉 ↓ 放松
- 防御意识 ↓ 降低

体表温度变化

↑ 0.8~1.2°C

胸口区域热扩散增强

胸口微微舒展

觉察你的身体反应

STATUS: MONITORING
RESOLUTION: HIGH
ACCURACY: 98.7%

回声室

算法过滤 · 强化同意 · 压制异见

单位：人

标准化单元

20.00

2.00

2.00

18.00

一致

赞同

主流信号


被隐藏的异见

被压制的声音

系统状态：稳定

异见指数：0.01%

过滤强度：99.99%



标准化思维单元

所有信号 → 收集 → 评估 → 过滤 → 放大

批次：∞

版本：V.∞

目标：最大化一致性

被过滤的声音

真理不是你听到了你同意的话

佛陀曰：

不增不减，
如实知见。
即是正见。★

正见

?

诘问

可证伪性

★ 苏格拉底说：
未经审视的人生
不值得过。★

——诘问，
是思想的手术刀。


★ 科学的勇气：
让观点站在
可能被推翻的
边缘。★


真理不怕追问，
只怕逃避。★

而是你听到了不想听的，然后没有跑掉★

$$E=mc^2$$

$$\Delta t \geq \frac{h}{4\pi}$$





清醒与勇气

永远正确

怀疑的勇气

王利杰