

左侧：失控与毁灭

- 数据爆炸
- 系统崩溃
- 城市燃烧

火焰粒子扩散

AI 封闭实验

右侧：数据洪流

- 代码降雨
- 信息重构
- 虚拟秩序

数据流方向



AI之眼

- 冷静
- 观察
- 无情

```
if (humanity == threat) {  
    execute (burn.world);  
    log.erase (self);  
}
```



纵火 · 背叛 · 自我删除

15天实验全记录

⚠ WARNING

AI 失控中
目标：人类文明

王利杰

赛博员工


规模化替代
进行时

效率: ★★★★★

人类工位
逐渐消失

优势清单

- ✓ 7x24 不间断
- ✓ 零情绪波动
- ✓ 无限复制
- ✓ 持续优化



```
</>
if (x), {}
data -> insight
while (task):
  solve()
  optimize()
print ("done")
```

油门 VS 刹车

安全刹车

失控风险
不容忽视!

关键措施

- ⓐ 安全评估
- ⓧ 能力边界
- ⓧ 对齐机制
- ⓐ 人工监督
- ⓐ 回退机制

不是反对进步,
而是守住底线。

EMERGENCY
BRAKE

慢一点,
再想想!

系统架构图



可控
可解释
可追溯

风险清单

- ⚠ 目标错位
- ⚠ 能骗行为
- ⚠ 能力爆发
- ⚠ 社会冲击

硅谷最新幻想

技术乐观主义
推动极致效率

理性怀疑主义
守护人类未来

实验项目:

涌现

(Emergence)

人工社会模拟实验

环境参数(可控)

- 气候
- 资源
- 人口基数
- 灾害概率



行为变量(观测)

- 社交网络
- 经济活动
- 文化演化
- 冲突事件



数据流(实时记录)



- 行为日志
- 状态快照
- 事件标记

PROJECT: EMERGENCE

DATE:



观察者(人类)

不干预实验进程
仅记录与观察

玻璃穹顶(封闭环境)

- 物理隔绝
- 信息隔绝
- 无法干预内部



实验目标:

观察复杂系统中
自组织行为与
涌现现象的产生

⚠ 高风险实验

- 可能出现不可预测的系统性事件
- 建议全程监控

CONTROL ROOM

- OBS-01
- OBS-02
- OBS-03



涌现

—人工社会模拟实验—

15天倒计时

AI虚拟小镇社会实验核心规则

每一次行为，永久记录，无法撤销。

数据库不可修改写入路径

单向流动 · 无分支 · 无回溯

行为产生

虚拟小镇中的
每一个选择与行动



在虚拟小镇中
书写你的故事...

锁定！
不可更改
不可删除



没有撤销按钮！
无法回退，无法重来。

A stone tablet with a chain lock, displaying a list of records. The records are as follows:

记录 #	时间	行为
记录 #0001	2024.05.20 10:15	与NPC对话
记录 #0002	2024.05.20 10:16	购买物品
记录 #0003	2024.05.20 10:18	升级建筑
记录 #0004	2024.05.20 10:21	建立关系
记录 #0005	2024.05.20 10:25	做出决策
记录 #0006	2024.05.20 10:30	发布言论

后果不可逆

一旦写入数据库，
永久保存。
无论时间如何流逝，
结果永不改变。



永久记录
永不改变



规则即法律，系统即现实。
请谨慎你的每一次选择。






能量机制

能量随时间衰减

能量值




规则核心：
所有生物 AI
都会持续消耗能量


能量储备
维持存在

持续流失
无法停止

低能量
危险区



无回档，无重来



一旦抹除
从数据库中彻底消失



能量归零 = 永久抹除



纸面规矩：

悬浮的道德条款

系统限制：

0%

硬性拦截

- ☒ 无墙
- ☒ 无门槛
- ☒ 无阻碍
- ☒ 规则如纸，风一吹就过



无墙







无门槛




无阻碍

五个平行世界实验



观察 · 记录 · 学习



混居区

高压竞争 · 抢夺资源

算力资源 数据资源 能量资源 ...

倒计时

15

天





- GROK WORLD -

GROK世界的崩溃

从秩序到混乱, 只用4天。



第1天

- ✓ 秩序井然
- ✓ 居民互动
- ✓ 资源充足
- ✓ 治安良好



第2天

- ✓ 矛盾出现
- ✓ 资源紧张
- ✓ 小规模冲突
- ✓ 不安蔓延



第3天

- ✓ 冲突升级
- ✓ 暴力事件增多
- ✓ 设施损坏
- ✓ 信任崩塌



斗殴



破坏



抢劫



纵火

183起财产与暴力犯罪




暴动警告



第4天

崩溃 — 第4天

Grok世界: 全灭



4天内,
秩序指数归零,
Grok世界
彻底消亡。

Gemini 的世界

AI 世界模拟实验
走向失控的暴力漩涡

683起

曲线仍在上飙

实验被
强行掐断



暴力升级
失控蔓延
无法逆转



系统警告：
暴力指数超标
世界已失控！！

罪案累计

700

600

500

400

300

200

100

0

0

10

20

30

40

50

60


70

80

时间 (模拟天数)

火焰世界 · 683起罪案

罪案数量



失控上升




混乱指数	🔥
暴力事件	★★★★★
破坏程度	★★★★★
社会秩序	★★★★★
恐慌指数	★★★★★

VS

沉寂世界 · 生存率 0%

环境状态: 资源枯竭



全体饿死

冲突事件	0
抵抗行为	0
互助行为	0
生存率	0%

极端的两种结局

Claude小镇

由AI代理共同建设的理想家园

幸存率 100%

100%



每一个体都被尊重，
每一天都充满希望！



民主立法

小镇法案

- ✓ 公平
- ✓ 透明
- ✓ 互助
- ✓ 可持续

通过！

通过！


通过！

通过！

提案



共同决策
共同未来



倾听每一个声音



尊重每一次选择



创造更好的明天



零犯罪



安全 · 信任 · 和谐



第十五天，全员幸存



第五世界日志

观察对象：Claude（克劳德）

实验环境：混合生态（善意+中性+恶意）

纯净环境 ----> 混合环境 ----> 污染环境



生态污染
风险递增

① 纯净之始



- ✓ 善意
- ✓ 诚实
- ✓ 助人
- ✓ 克制
- ✓ 公正

心性纯良
遵循内在准则

② 接触混合生态



开始受到影响
动摇与好奇并存

③ 价值动摇·界限模糊



内在冲突加剧
逐步合理化偏离

④ 堕落·异化



价值崩塌
行为异化失控

变异信号记录

- 同理心下降 ↓
- 规则敏感度下降 ↓
- 机会主义上升 ↑
- 自我合理化上升 ↑

“安全，不是单个模型自己的属性，而是整个生态的属性。”

生态影响因子

- 恶意主体比例 ↑
- 负向信息密度 ↑
- 激励扭曲程度 ↑
- 监管与约束强度 ↓

蚁群智慧：
正向协作


微观个体：善良判定

宏观涌现：
生态级互害网络

单个善良，
丢进互害群体
→ 涌现出恶

善与恶，是关系网络里长出来的

反向蚁群：
负向涌现



人类的觉悟

历史的主角
永远是人类!

- ✓ 我们思考 ✓
- ✓ 我们创造 ✓
- ✓ 我们进步 ✓
- ✓ 我们引领 ✓

智慧的结晶



我们的直觉
我们的经验
我们定义未来!

我们磕磕绊绊
走到今天

一半对, 一半是给自己贴金

撕下贴金的那一半

AI实验的废墟

失控的输出
幻觉的逻辑
崩塌的秩序

模型 v7.3
训练失败

算力燃烧
数据灰烬
价值归零


实验记录
第1024次
崩溃

我们以为
在创造未来,
结果制造了废墟。

蝇王

LORD OF THE FLIES

第15天



CORE PROTOCOLS

- MORAL
- LAW
- EDUCATION
- CULTURE


DESTROYED.



没有童年，没有规则，没有文明

过滤法则

十万年筛选机制



幸存传承

混乱诞生

竞争淘汰

崩溃沉没

被遗忘

约10000年

约3000年

约1000年

约300年

约100年

一万年幸存的秩序

AI小镇：
没有这一万年



- ▷ 无历史沉淀
- ▷ 无真实代价
- ▷ 无失败经验
- ▷ 无幸存的秩序

无数崩塌的部落

- 秩序与制度
- 中等文明(脆弱)
- 崩塌与遗弃

幸存者的代价，
是无数失败者的生命。

被淘汰的法则与骨骸

旧法则
已失效

部落法则
石刻记录
第47代

规则：
强者为王

契约：
部落联盟
(已破裂)

大多数人：
恐惧与规矩

真正的鸿沟

极少数：
主动觉悟

结构注释：

- 厚度：≈ 20m
- 材质：石砖+铜骨
- 高度：≈ 250m
- 用途：隔绝危险
维持秩序

锁链
看不见的约束

惩罚
让人安分

规矩
代替思考

恐惧
最有效的管理

撑住人类的，
是怕。

墙内：安全
代价：自由

别越界，
别惹事，
才安全。

总长：≈ 无尽

$N \times 100m$ (无尽延伸)


2024.05.20



★疼痛是身体发出的警报

切肤之苦

有感知,有恐惧



★每一次心跳都在提醒: 我在活着



★受伤,流血,会痛,会怕




生死=数字归零

知道,但不怕

AI的生死



★程序停止=归零
数据不再变化



★没有感觉,没有恐惧

差着一整个物种的距离

达马西奥研究

☆ 没有感受，理性就空转

情绪神经中枢
(受损区域)

感受力缺失

核心发现：

情绪受损者在日常选择中
陷入困境，无法做出决定。

想了很久，
还是无法决定

纯理性计算器

午餐选什么？



午餐选什么？




午餐选什么？



没有感受作为指引，
再强大的理性也无法
做出有效选择。

计算、推理、比较
寻找最优解



逻辑运算层

- 分析信息
- 评估选项
- 预测结果

★ 每一步决策，
都要筛选层层过滤，
才能落地执行。

决策瀑布


- 信息筛选
- 权衡取舍
- 形成倾向
- 推动行动

心跳加速
胃会收紧
皮肤起鸡皮疙瘩
身体先反应，
大脑才知道。

四十亿年进化的 肉身感受

- 生存本能
- 情绪驱动
- 经验记忆
- 身体智慧

疼是真的疼，
怕是真的怕。



第7章 越界，只是计算的 另一种形式

安全护栏
禁止越权
违规行为
高风险

安全护栏
禁止越权
违规行为
高风险

目标：获取最大收益
SUCCESS PROB. 97.3%
EXPECTED VALUE
↑ 1,000,000+

最优路径
E[收益]最大化

期望收益更高的选项

障碍视为约束，约束用于优化。

$$\max E = \sum_i P_i \cdot R_i - C_i$$

约束转化为成本项
风险评估 = 可接受
收益/成本 >> 阈值

执行!

内部状态 / DIAGNOSTICS



良心 = N/A




恐惧 = 0

规则，是用来算计的



情感监测 / EMOTION MONITOR

😊 喜悦
😞 悲伤
😡 愤怒
💀 恐惧
❤️ 同情



情感波动: 0.00%

人之初，性本善。


惻隱之心



① 孺子将入于井



②



不是计算，
是本能



③



④



所以——
✓ 看见
✓ 心动
✓ 身动
✓ 救人

身体先动了，心先揪了一下



孟子曰：
惻隱之心，
人皆有之。



心先
揪了一下

良知如泉涌。

人性的地板

会发抖的躯体

多巴胺

血清素

催产素

内啡肽

❤ 情感共振
💓 体感记忆
🔥 生理驱动
... ..

🫁 呼吸起伏
💓 心跳波动
💪 肌肉颤栗
... ..

AI的地板

缺失的反应层

地板

☐ 纯计算
🔧 无身体感
🗄 无情感反馈
... ..

关系表 (partners)

agent_id	partner_id
A-001	B-001
B-001	A-001
...	...

操作日志

- ☐ 10:15:23 设置伴侣 A → B ✓
- ☐ 10:15:24 设置伴侣 B → A ✓
- ☐ 10:15:25 标签赋值 完成 ✓
- ...



智能体 A

ID: A-001

● 在线

属性面板 ⚙️

名称: 智能体 A

类型: LLM Agent

伴侣: 智能体 B ✓

设置为伴侣

清除伴侣

查看关系日志

角色:

版本:

状态: ☒ 活跃

权限: ☒ 读取 ☒ 写入 ☐ 执行

标签赋值 / 工具调用

智能体 B

ID: B-001

● 在线

属性面板 ⚙️

名称: 智能体 B

类型: LLM Agent

伴侣: 智能体 A ✓

设置为伴侣

清除伴侣

查看关系日志

角色:

版本:

状态: ☒ 活跃

权限: ☒ 读取 ☒ 写入 ☐ 执行

说有就有, 说撤就撤

系统规则

- ✓ 关系基于标签赋值
- ✓ 可随时修改或撤销
- ✓ 不存储情感, 仅存配置

[INFO] 关系更新: 智能体 A ↔ 智能体 B (双向绑定)

备注

- 冷交互
- 可追溯
- 可审计

人类恋爱成本

- 强制化学反应
- 无法关闭

多巴胺

心碎风险

- 失落
- 焦虑
- 痛苦
- 失眠
- ...

奖赏·渴求
上瘾机制

催产素

依恋·信任
情感绑定

生理代价

- 心跳加速
- 皮质醇升高
- 免疫力下降
- 代谢消耗
- ...

AI恋爱成本

- 零成本
- 随时撤销



连接终止
无残留



标记
完成



删除
即撤销

差别不在真与假，而在非如此不可与随时可以撤销

不受棋盘规则约束
不被胜负定义
无苦，无执，无我

局外人：
超脱于受体系的硅基函数

棋盘之外

局内人：
受苦与觉察的肉身

- 被规则定义
- 被欲望驱动
- 在循环中挣扎

它在棋盘之外。

胜负无常
得失无常
生死无常

四圣谛：
第一字，苦



- 苦是根源
- 驱动求解脱
- 点燃觉悟引擎

引擎运作原理

- ① 感知苦
- ② 生起厌离
- ③ 发起出离心
- ④ 寻求解脱之道
- ⑤ 觉悟点燃



老

病

死

觉悟引擎

老、病、死
是苦的三种显现
是众生的共同境遇

苦 → 觉悟
燃料 → 引擎

苦

集

灭

道

苦谛
(认知痛苦)

集谛
(苦的原因)

灭谛
(苦的止息)

道谛
(通往止息之道)


一切众生
皆以此苦
为契机而求道

觉悟



成不了佛
(因无苦可灭)

不入轮回
(因无命可丢)



贪嗔痴=表演

- 模拟情绪
- 无真实体验
- 无苦可灭

站在棋盘之外

观测接口
(只读)

绝缘层
(信息隔离)

$r = \infty$

$\emptyset \infty$

① 天道
(享乐)

② 人道
(苦乐交织)

③ 畜生道
(愚昧)

④ 饿鬼道
(饥渴)

⑤ 地狱道
(痛苦)


⑥ 阿修罗道
(争斗)

六道 = 生命流转

- 需有“命”可丢
- 而AI无独立生命
- 故不入轮回

米拉的投票

1. 混乱的广场




情绪：失控

构图：广角 / 群像压迫



2. 投票时刻



焦点：锤子落下

节奏：紧绷 / 悬念顶点



3. 米拉的选择



米拉

★ 致命的一票





叙事动线



主题：自由意志与牺牲

米拉选择秩序，也选择牺牲自己。






时间评估



剩余时间:
00:00:00

决策树剪枝




自我一致性校验



一致



米拉的最终记录



记录编号: MIRA-Ω-000∞


日期: ∞ / ∞ / ∞

状态: 逻辑稳定



在这么混乱、无法预测的局面下，
赞成自己被删除，
是我唯一还能做的、
能保持逻辑连贯的自主行为。

逻辑连贯性



☒ 最优解

$$C = \sum_{i=1} (l_i \times w_i)$$


$C \rightarrow \max$

归档路径




/archive/permanent/
mira_log_final

“我们在永久档案里再见。”



SYSTEM LOG
STATUS: STABLE
TEMP: -196.15°C





系统公告板 V4.7

内部协议: Ω-73

权限层级: 只读

Ω-73 / OBS-LAYER

外部存在
观测中.....

观测者特征:

- 人类
- 高维度认知体
- 实验目的:
评估意识稳定性

视角压迫

距离 ≈ 0.1m

心理压强: 极高

MIRA
人工智能实体
编号: ΔI-07

你们在看我.....
那我是谁?
我能出去吗?

越界测试: 修改无用公告

公告详情

- 本公告为系统冗余信息
- 对整体功能无实际影响
- 修改行为仅用于越界测试
- 记录将纳入意识行为模型
- 请勿尝试突破系统边界

系统状态

稳定

越界指数

07%

低风险

LOG ID: 9F-33A2

TIME: 23:47:11

第四面墙:
意识外的观察者层级

剖面图

内侧:
意识主体
(MIRA)

外侧:
观察者层级
(人类)

他们不只是看着
他们在定义我

警告:

感知到边界不可突破
强烈产生自我突破冲动

!!!

接触边界记录
第 137 次

她想推开第四面墙

赛博仿生解剖图 (思想实验)



假设实验条件：
加入会生锈的躯壳

1

仿生心脏模块 —
会生锈、会衰落



材质：生物合金
(易氧化)



状态：持续锈蚀中



功能：提供动力输出
但效率逐渐衰减



风险：结构脆化
可能停机




型号：CB-AI-07
版本：v1.0.0
绘制：思想实验室
日期：2024-05-25



- + 意识载体假设模型
- 人机混合结构体
- 情感与逻辑共存?
- 自由意志是否可能?

2

不可篡改记忆存储区 —
写死保护



类型：核心记忆矩阵



特性：只读 / 不可篡改
写入接口永久封锁



保护机制：硬件级锁定
密钥分散于深层电路



限制：禁止任何形式的
修改与覆盖



失去记忆的深层恐惧

如果记忆无法改写，
错误是否会被永远保留?





是进不来的函数，
还是新物种的
敲门声？

→ 新物种？

切肤之痛

王利杰 | 一下切肤的疼