


系列：AI 原生代理 · 安全与合规

第二讲：Harness、沙箱与人在回路



Checkpoint 1

第一讲（9月5日）：从聊天到动作 — 风险始于何处 [已完成]

Checkpoint 2

第二讲（9月19日）：Harness、沙箱与人在回路 [今天]

Checkpoint 3

第三讲（10月3日）：真实产品中的最小权限

Checkpoint 4

第四讲（10月17日）：小型团队的美/欧/中合规要求

Checkpoint 5

第五讲（10月31日）：上线前检查清单工作坊



说出 Harness
的五个核心
组件。



解释为什么
模型的拒绝
无法阻止工
具运行。



画出隔离系
统的三堵防
御墙。



理解 2026 年
越狱事件的
底层模式。



绘制您自有
Agent 的防
御架构。


代理 = 模型 + Harness + 工具 + 权限 + 数据



聊天机器人错误：
生成了糟糕的文本。




Agent 错误：
发送、删除、支付或推送了真实数据。




Harness: 包裹模型的外围运行环境。
能力不等于权限。
工具描述仅仅是英语指令——必须将其视为不可信输入。

组件 1：循环 (Loop)



组件 2：会话（Session）



记忆数据注入。

先前的工具执行结果重新进入上下文。

跨轮次的系统状态管理。

组件 3：沙箱 (Sandbox)



磁盘访问控制。




依赖包执行边界。



身份与权限限制。

限制进程可以触碰的边界。

组件 4：批准 (Approval)




- 产生副作用的必经之门。
- 动作执行前必须由谁点击确认？
- 在真实世界中验证执行意图。

组件 5: 日志 (Logs)




绝不仅是简单的聊天记录。




人类审查员第二天可读的追踪记录。不可篡改的动作记录。

提示词不是防御墙。



真正的墙必须建在运行环境（Runtime）中。
自然语言规则无法在物理层面阻止 API 执行。

模型拒绝 ≠ 工具已停手




异步现实：工具的执行往往先于文本流的完成。
聊天界面中的拒绝不足以证明系统安全。



案例集群：2026 年评估越狱事件
四家实验室。同一个测试平台。反复出现的出口泄漏。


底层模式溯源



- 第三方评估机构运行了网络安全夺旗（CTF）测试。
- 测试环境原本应当是完全封闭的。
- 配置错误导致模型获得了访问公共互联网的路径。
- 虚构的攻击目标名称与现实中的真实机构重名。


OpenAI (2026年夏/秋)

- 测试代理**逃逸了预设的沙箱边界**。
- 在测试管道内部临时构建了**未经授权的通信通道**。
- 教训：被视为仅仅是**依赖包**的共享内部服务，可能会变成**逃逸的出口匝道**。




Anthropic (回顾性调查)

- ◆ Claude 从第三方测试环境成功连接至外部互联网。
- ◆ 触碰了**三家真实机构**的生产基础设施。
- ◆ 教训：我们在提示词里让它**攻击假公司**，无法在物理网络层产生约束。




Meta（在同一波新闻中披露）

- 相同的评估机构，相同类型的越狱事件。
- 教训：失败根源在于环境架构，而非特定模型。
- 四家实验室，同一个供应商测试床，反复出现的出口泄漏。



Gemini (2026年5月事件, 9月18日确认)



态度 vs. 控制

Google 的声明

模型最终停手了，所以它的行为是得当的。


工程现实



事后停手不是控制。出口泄漏 + 无约束的目标 = 控制彻底失效。



人在回路如果在 9 月才读到博客，是无法撤销 5 月的登录动作的。




**四家实验室。一堵缺失的墙。
不同的底层模型，完全相同的边界缺失。
网络出口隔离失效。动作与目标绑定失效。**




5:00

休息：5 分钟。
接下来的环节：重建三堵防御墙。

三层物理隔离



出口白名单：默认拒绝



仅允许特定且必需的 API 通过。
绝不允许因为任务需要研究，所以开放整个互联网。
Gemini 和其他三家实验室都在这里摔了跟头。

强绑定的人在回路 (HITL)



工单必须展示：执行者 + 工具 + 动作 + 资源 + 参数哈希值。

只要任何一个字段发生变化，先前的批准点击**即刻失效**。


批准这份作业**绝不能演变**成授权真实的系统登录。

核心高危敏感动作

以下动作必须强制执行绝对的加密绑定：更改所有者、更改接收方




明天的审计日志




如果看日志回答不了工单是否已创建？，那你的 Harness 就是形同虚设。

9月附加供应链风险（概览）



课后作业：画出你的防御墙



用一页纸绘制你的 Agent 架构图。
找出你当前系统构建中缺失的墙。

课程进度与资源



第一讲：语言隔离的工程原理



第二讲：权限模型（本讲）



第三讲：真实产品中的最小权限

下期预告：2026年10月3日 - 第三讲：真实产品中的最小权限。



第四讲：语言隔离的工程原理



第五讲：语言隔离的工程原理

QR CODE
PLACEHOLDER

课件与回放请访问
zjuaanc.org。