DeepSeek Harness

从入门到精通

系统讲解：产品 · 用法 · 案例 · 同行对比

deepseek HARNESS

联合出品：技术领导力 AI新猿人 Mr.K科技洞见

公众号：技术领导力

公众号：AI新猿人

目录

本材料面向技术爱好者、想系统上手DeepSeek Harness的读者，共六章，从概念到实战再到选型，逐层深入。

阅读建议：想快速上手直接看第 3 章；想选型对比直接看第 5 章；想彻底搞懂架构再看第 2章。

第 1 章

入门篇

认识 DeepSeek Harness —— 它是什么、为什么出现、核心思想

什么是 DeepSeek Harness

关键区分：Harness 是「框架/引擎」，不是聊天机器人，也不是某个具体的 AI 应用——它是用来「组装 Agent」的开源底座。

核心公式：Model + Harness = Agent

这是理解 Harness 最重要的一句话：模型负责「思考」，Harness 负责「执行」，两者相加才是一个完整的智能体。

分工	谁负责	职责
Model（模型）	DeepSeek V4-Pro / V4-Flash 等	推理、规划、生成回复，决定「做什么」
Harness（框架）	dsh + Cordis 插件	工具调用、文件读写、命令执行、编排，决定「怎么做」
Agent（智能体）	两者组合	能自主完成任务的完整执行体

一句话记忆：换模型就像换发动机，换插件就像换工具头——发动机和工具头可以独立升级，这就是「可组合」的含义。

核心理念：一切皆插件

理念价值：把「Agent 能力」变成可安装、可分发、可替换的零件，从而形成开源插件生态（npm 分发、dsh-plugin 话题）。

第 2 章

产品篇

功能与架构拆解 —— 入口模式、计划/代码模式、核心工具、沙盒与插件

《DeepSeek Harness 从入门到精通》

产品形态总览：四种使用入口

Harness 不是单一应用，而是一套「框架 + 多个入口」，用户可按需选择交互方式。

入口	形态	适用场景
Web UI	图形界面，dsh web 启动	日常交互、观察 agent 执行、审批操作
CLI（Headless）	命令行一次性任务	脚本化、CI/CD、批量任务
Python SDK	程序化调用 deepseek_harness	嵌入自己的程序/服务
插件开发	TypeScript 编写插件	扩展 Harness 自身能力

> Web UI 用来「看」，CLI 用来「跑批」，SDK 用来「嵌」，插件用来「扩」。

CLI 入口模式：web / headless / plugin

命令	用途
dsh --profile <name>	启动位于 $DSH_HOME/profiles/<name> 的指定 profile
dsh --profile headless "任务"	运行一次全新持久化会话，打印最终答案后退出
dsh web	--profile web 的别名，启动 Web UI
dsh plugin --profile <name> <pnpm 参数>	管理该 profile 的插件（转发给 pnpm）

```
npx @deepseek-ai/dsh web
dsh --profile headless "run the tests"
dsh plugin --profile web add <plugin>
```

计划模式（Plan Mode）：先想清楚再动手

适用场景：复杂任务、多步骤改动前，先让 agent 出计划给你审，避免「直接动手改坏」。

代码模式与 Agent 循环：它如何工作

「调用模型 → 运行工具 → 重复」。它把这个循环做成一个**极小的、可替换的驱动器（Agent Loop）**

其余一切（沙箱、权限、压缩、重试、子代理…）都以**插件 + 事件**的方式挂在外围

而「代码模式（Code Mode）」则把「运行工具」升级为「让模型写一段程序，在隔离环境里批量调用工具」。

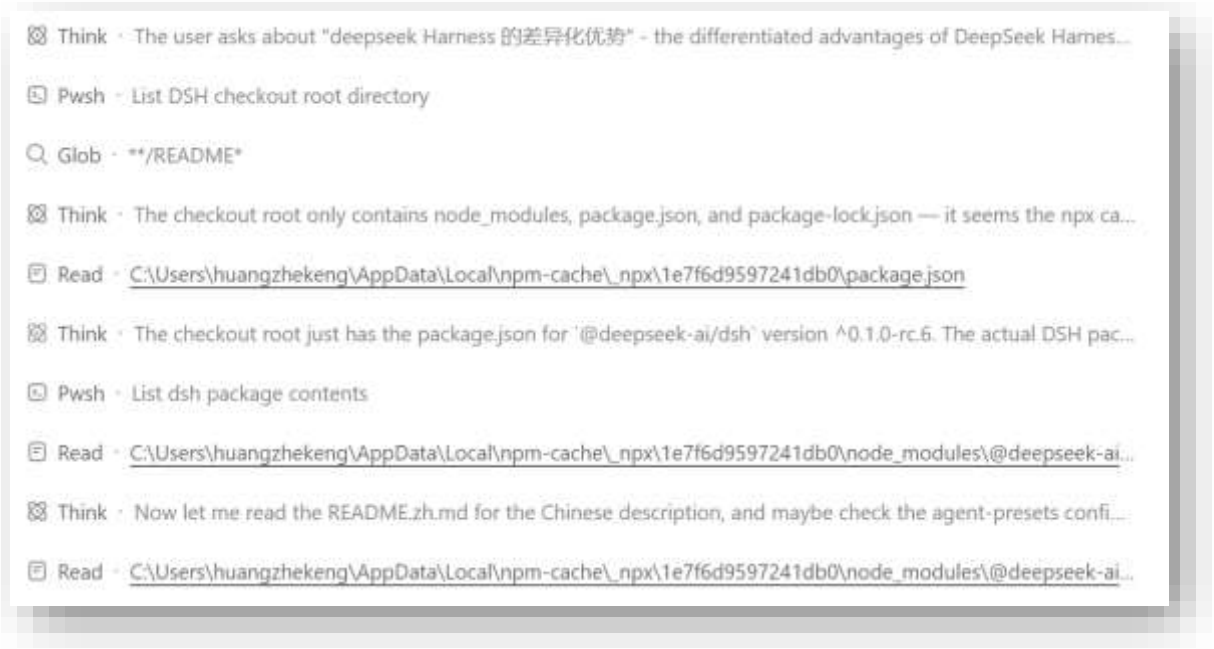

> 关键点：模型看到的每一段内容都来自会话日志（「模型可见即已记录」），保证可回放、可审计、可恢复。

核心工具与能力（面向模型）

能力类别	工具 / 机制	作用
执行环境	bash / pwsh	运行 shell 命令，读写文件系统
文件操作	read / write / edit / glob / grep	读写文本、按模式查找、内容检索
任务委派	subagent / subagent_fork	把独立任务交给子智能体
编排	workflow	脚本化大规模编排多个 subagent
目标管理	create_goal / get_goal / update_goal	跨轮次推进长期目标
后台任务	job_list / job_output / job_kill	管理后台命令与子任务
持久终端	terminal_open / send / read…	跨调用保留状态的 shell 会话
技能	skill	加载可复用技能说明

这些工具同样是插件：需要时挂载，不需要时卸载，从而实现「按需装配」的 Agent。

记忆与持久化：会话日志即真相

设计含义：把「对话历史」和「执行痕迹」统一成一条可重放的事件流，是 Harness 可审计、可恢复、可 fork 的关键。

沙盒与审批策略：安全的边界

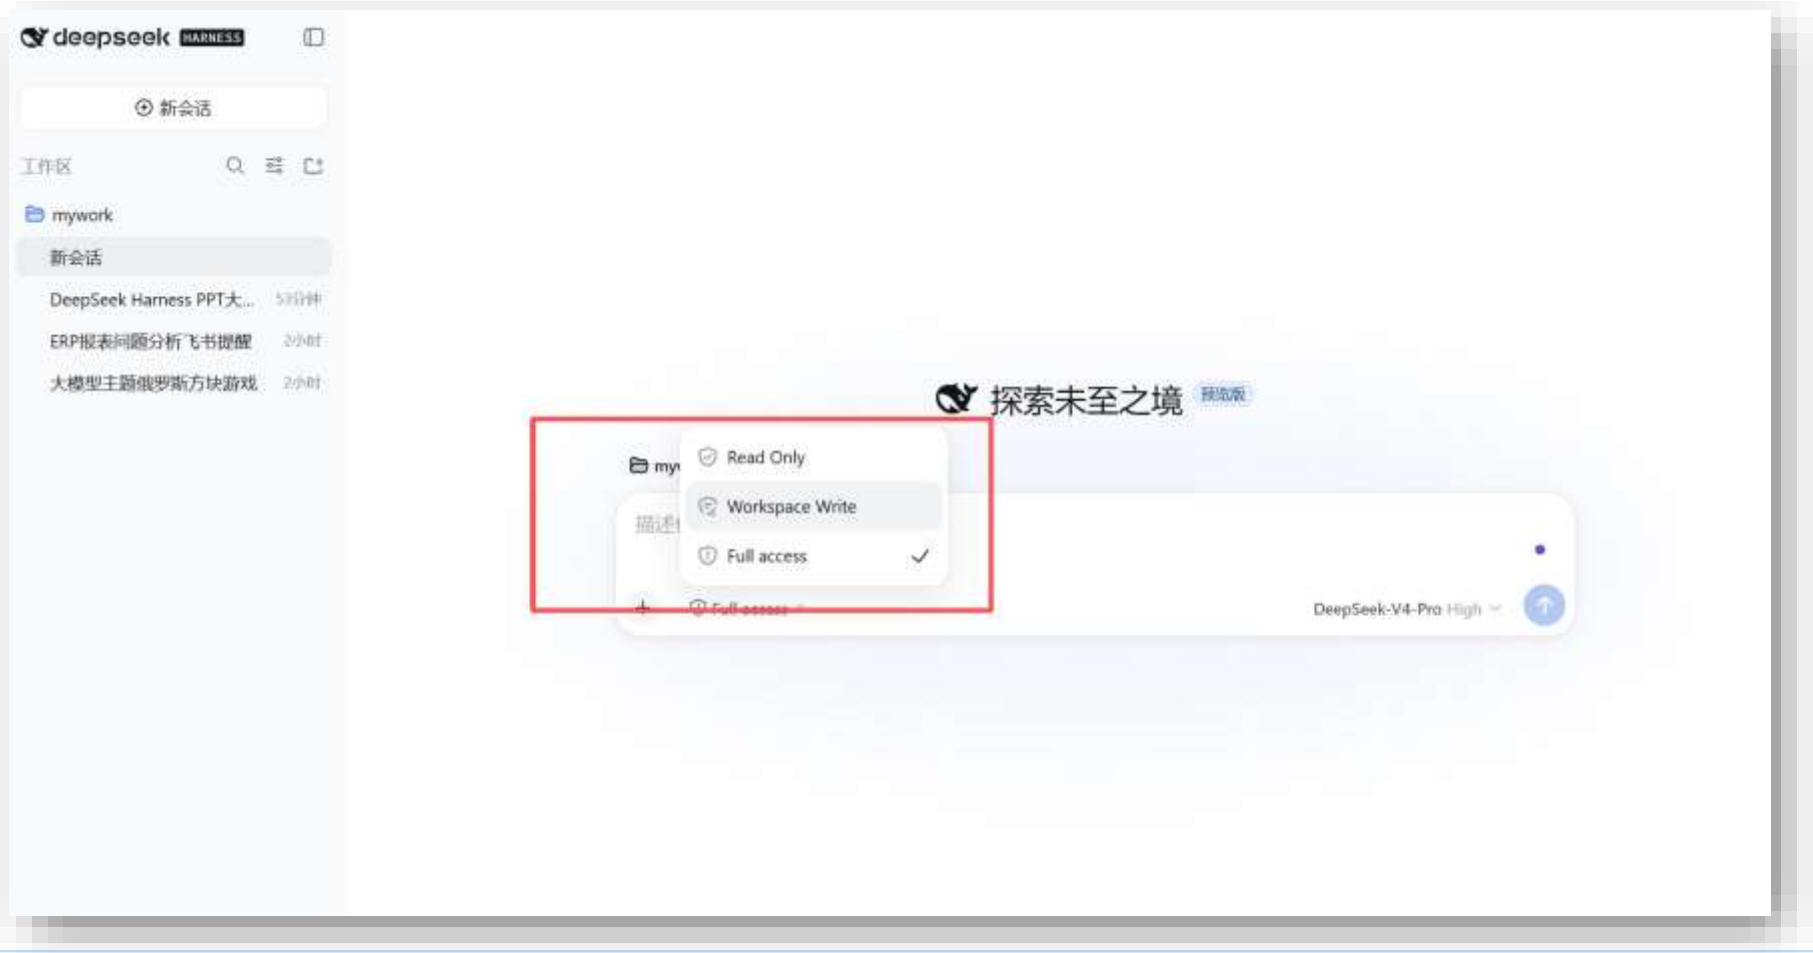

核心原则：让 agent 有「能干活的权限」，但把「越界的权限」交给审批和沙盒守住。

插件与架构：Cordis 框架

一切皆插件

DeepSeek Harness 基于 Cordis 插件系统构建。模型、工具、技能、会话、沙箱、存储、循环、调度、UI 等所有 Agent 能力均由插件提供，并通过 Cordis 服务与事件彼此协作。开发者无需改动 DeepSeek Harness 源码，即可在配置层选择、替换或扩展任一能力。

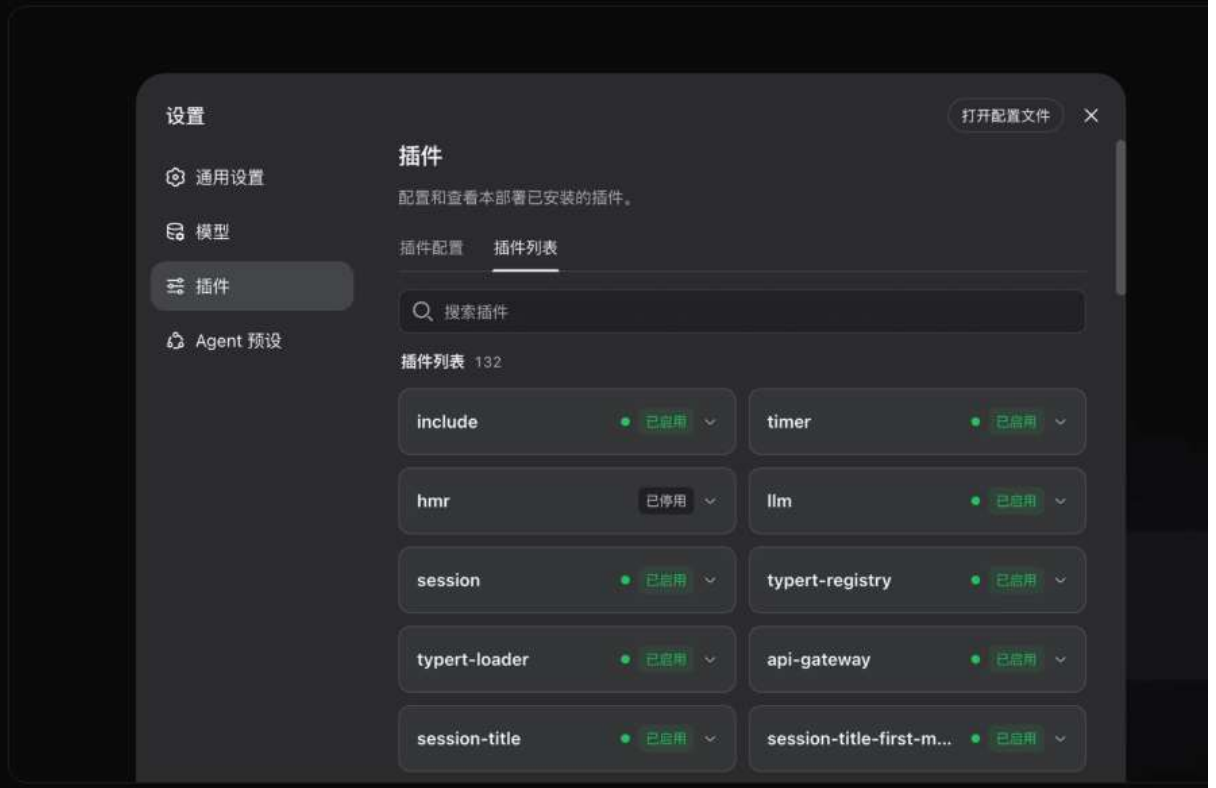

把 Harness 拆成可插拔的「服务 + 事件 + 接缝」，让每一层都能被替换。

版本与定价

模型		百万tokens输入（缓存命中）	百万tokens输入（缓存未命中）	百万tokens输出
deepseek-v4-flash	空闲时段	0.05元	1.5元	4.5元
	高峰时段	0.10元	3.0元	9.0元
deepseek-v4-pro	空闲时段	0.15元	4.5元	13.5元
	高峰时段	0.30元	9.0元	27.0元

成本：框架本身 0 元，真正的账在「模型 API」和「自托管运维」两处。

第 3 章

用法篇

从入门到上手 —— Web UI、CLI、Python SDK、写插件、排错

环境准备

用途	前置要求
Web UI / CLI	安装 Node.js，然后 npx @deepseek-ai/dsh web（无需预装 Harness）
从源码运行	Git + pnpm：git clone → pnpm install → pnpm run build → pnpm dsh web
Python SDK	Python 3.10+、Git；平台 Linux x64/arm64 或 macOS 14+ arm64
凭据	DeepSeek 兼容的 API 端点与密钥（DEEPSEEK_API_KEY）
工作区	一个 agent 可修改的隔离 workspace 目录

```
export DEEPSEEK_API_KEY=sk-your-key-here
# 可选：OpenAI 兼容代理 / 模型 / 系统提示词
# export DEEPSEEK_BASE_URL=http://127.0.0.1:8000/v1
# export DSH_MODEL=deepseek-v4-flash
```

> 提示：Windows 桌面用户主要用 Web UI；Python SDK 官方组合目前不支持 Windows agent（依赖 POSIX 终端）。

5 分钟第一个 Agent（Web UI）


```
npx @deepseek-ai/dsh web
# 打开浏览器访问 http://127.0.0.1:3080
```

命令行 Headless：一次性任务

无界面的「一次性任务」入口 —— 一条命令、一个任务、一个持久化会话、一个最终答案。

核心特性

- **一次性执行**：提交任务 → 等待 Agent 完全停稳 → 打印最终答案 → 退出
- **极简装配**：直接叠加在 dsh-base 上，只保留编码 persona、工具模式与 Code Mode worker
- **零服务开销**：不挂载 Host / HTTP 服务器 / Web 运行时 / 浏览器插件，**不监听任何端口**
- **持久化会话**：每次运行创建全新的持久化 Agent，天然支持后续续写
- **干净的 I/O**：最终答案写 stdout；出错时 code + message 写 stderr；成功时 stderr 为空
- **可靠的退出码**：turn/end 完成 → 0，否则 → 1，便于脚本化 / CI 集成

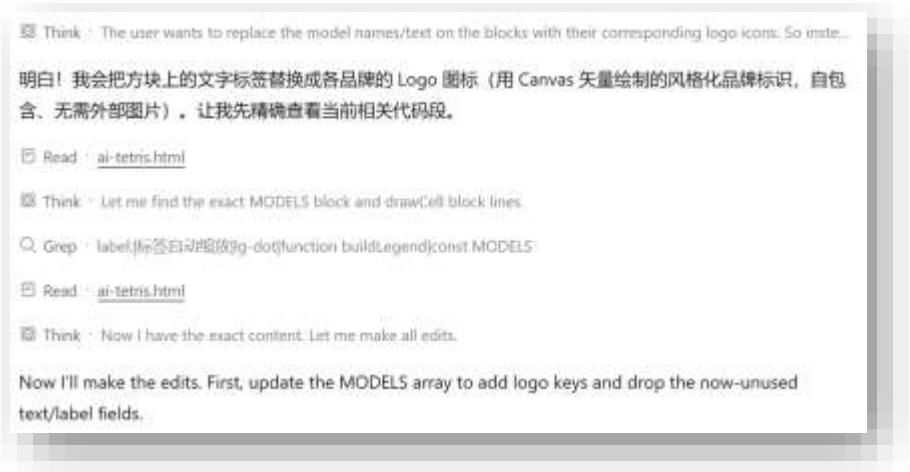


```
dsh --profile headless "run the tests"
dsh --profile headless "Inspect the repository and fix the failing tests."
dsh --profile web --port 8080   # --port 属于 web 应用
```

Python SDK：程序化调用

当运行模式为 code / both，且代码运行时 runtime.language = 'python' 时，DSH 从已注册工具 Schema **确定性生成**一套类型化的 Python SDK（dsh-tools 的 py-types 渲染器），模型通过它程序化地调用工具。

```
from deepseek_harness import DeepSeekHarness
with DeepSeekHarness(provider="deepseek-official", model="deepseek-v4-flash",
        cwd=str(workspace), session_root=str(sessions), cordis=str(config)) as h:
    result = h.run("Inspect the repository and fix the failing tests.", session_id="ex-001")
print(result.final_response)
```

适用：把 Agent 嵌入自己的 Python 服务/工具链，复用同一套 API。

配置模型与插件安装

- DSH 基于 Cordis 插件框架（TypeScript 依赖注入 / 服务 / 生命周期）
- 配置 = 分层的 YAML patch 叠加成一个「配置树」
- 一切皆插件（Plugin），配置只是「按顺序加载哪些插件 + 传什么参数」

```yaml
- id: tool-bash          # 唯一 id
  name: '@deepseek-ai/dsh-tool-bash'   # npm 包名
  config: { timeoutMs: 300000 }        # 按插件 Schema 校验的参数
  disabled: false        # 可开关

- id: planning
  name: cordis:group     # 分组 + 隔离域
  group: true
  isolate: { planMode: true }
```

关键：模型可换正是 Harness 的核心卖点之一——配置一次提供方，即可在多家模型间切换。

进阶：编写第一个插件

- 一条命令：dsh plugin --profile <name> <pnpm 参数>（转发给 pnpm）
- 插件以 npm 包形式装进 profile 的 node_modules
- 解析顺序：先查 dsh 内置 bundles，再查 profile 自己的 node_modules
- web / headless profile 首次自动初始化；自定义 profile 用 dsh plugin 创建
- Web GUI 提供「插件清单 / 设置」界面查看启用状态与生命周期

```
import type { Context } from '@deepseek-ai/cordis'
export const name = 'my-tool-plugin'
export const inject = ['tools']
export function apply(ctx: Context) {
  ctx.tools.register(/* ... */)   // ctx.tools 已就绪
}
```

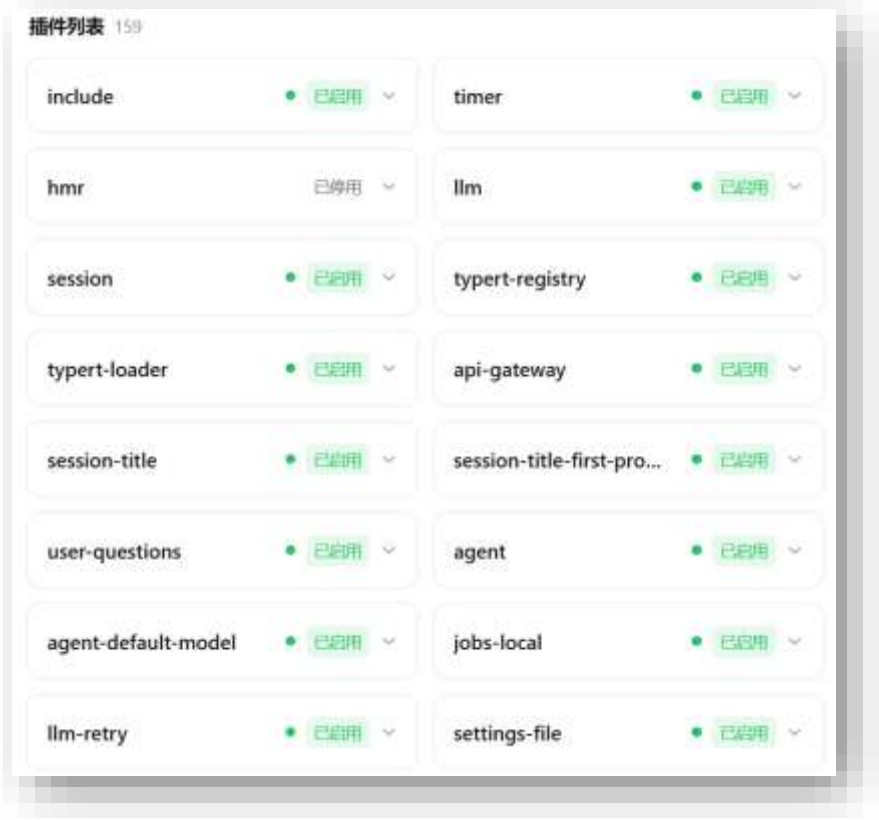

挂载：写入 cordis.yml 并用 --patch 加载：pnpm dsh web --patch ./scratch-plugin/cordis.yml。

最佳实践与常见排错

工具使用

- 读文件用 read，不要用 cat；搜索用 grep/glob，不要用 shell 的 find/rg
- 新建/整体覆盖用 write，小改动用 edit（更精准）
- 多步任务先列 todo_write 清单，随时更新状态

开发联调

- 确认在正确地址操作：本 GUI 是
- http://127.0.0.1:3080
- 改完 Web 产物后要刷新页面验证；客户端插件 HMR 需 pnpm run dev:web 运行中
- Web shell 依赖 dsh web 注入 window.__DSH_BOOT__，不要另起服务器替代

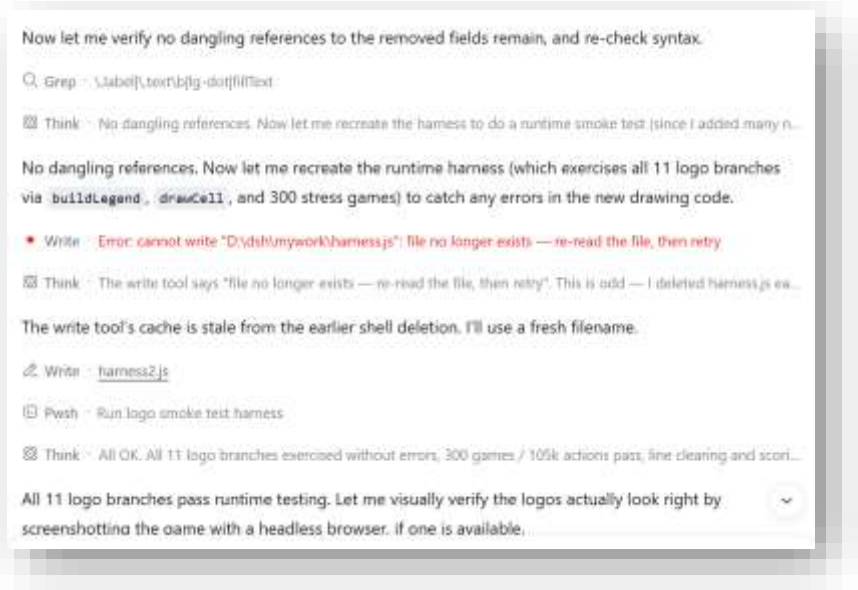

一条心法：先在小 workspace + 审批模式下验证，再逐步放开权限。

第 4 章

案例篇

真实场景实战 —— 开发重构、数据分析、办公自动化、多 Agent 编排

案例一：代码开发与重构

开发“AI大模型俄罗斯方块”小游戏

案例二：数据处理与分析

多模态读取：文本、CSV、JSON、图片等本地数据批量读取（read / read_image）

精准检索：正则全文搜索（grep）+ 模式匹配定位（glob），快速锁定目标数据

计算执行：PowerShell 脚本执行数据清洗、统计、转换与文件处理（pwsh）

并行分析：Subagent 子任务并行 + Workflow 大规模多智能体编排，扇出加速

联网检索：web_search 实时获取外部/最新数据并溯源引用

长任务自动化：Goal 目标驱动 + 后台任务管理，自动跨轮次完成分析闭环

二、六维评分对比（短板一目了然）

维度	平均分	低分(≤2)人数	首要改进提及
产品功能	4.28	0	2
品牌形象	4.25	0	0
价格	3.63	0	1
问题反馈处理	3.63	0	1
客服质量	2.81	11	10
客服响应	2.63	14	16

核心洞察：客服是唯一拖后腿的环节。产品、品牌表现优秀（4.2+），但「客服响应 + 客服质量」两项均分不足 3 分，合计被 26 位客户列为首要改进项，占全部样本的 81%。客服体验正在抵消产品优势。

主要特点

- 工具化组合：能力封装为可组合工具，按需调用
- 并行高效：多子代理并发，显著缩短批量分析周期
- 结果可溯源：文件级操作、搜索来源均可追溯（URL 引用）
- 可控安全：沙箱模式约束文件读写与命令执行，风险可控

案例三：办公自动化 / 文档处理

任务：调研一个主题并生成PPT：

1、明确主题：确定范围、受众和页数
2、搜索资料：多轮检索，记录来源和数据
3、归纳主线：提炼观点，梳理逻辑结构
4、搭建大纲：确定每页核心内容
5、生成 PPT：脚本自动排版生成 .pptx
6、检查交付：核对内容，标注待补充项

案例四：多 Agent 编排（subagent / workflow）

- **任务拆解**：把一个复杂目标拆成多个独立子任务
- **并行分工**：多个 Agent 同时处理不同子任务
- **结果汇总**：收集各 Agent 输出，统一整合
- **协同校验**：必要时交叉检查、修正冲突
- **形成成果**：汇聚为一份完整交付物

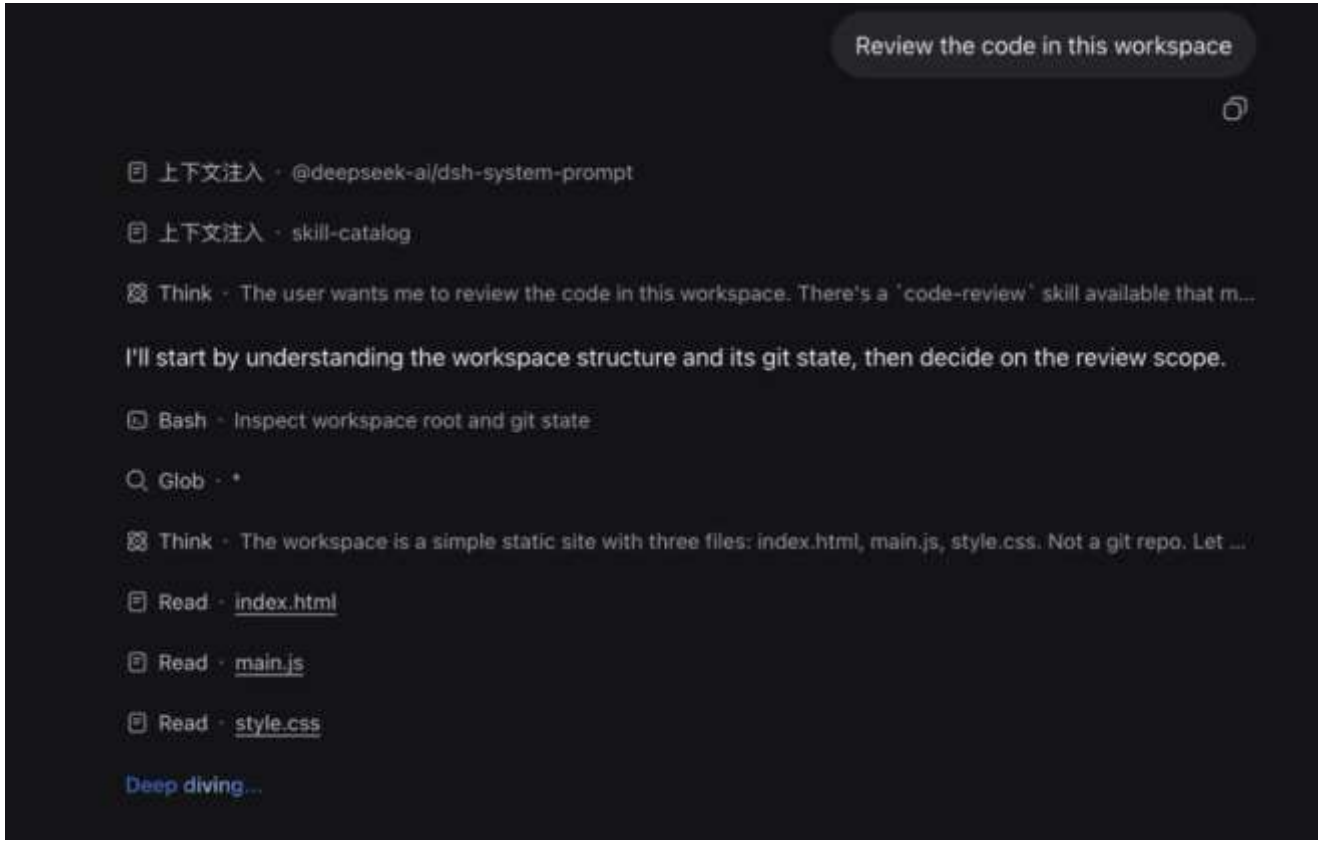

第 5 章

对比篇

与四大竞品对比 —— WorkBuddy · Trae Work · Qoder Work · OpenAI Codex

竞品版图总览：Harness 站在哪个位置

DeepSeek Harness 不是孤立出现的产品，它处在 2025–2026 年「AI Agent / 编程智能体」爆发的大赛道里。本章把它与四款代表性产品并排对比。

产品	厂商	一句话定位
DeepSeek Harness	深度求索	开源 Agent 框架，核心口号「一切皆插件」（Everything is a Plugin）
WorkBuddy	腾讯	桌面端 AI 智能体 / 办公工作台，强绑定腾讯生态
Trae Work	字节跳动	AI 原生 IDE，主打「AI 主导开发全流程」，前身 TRAE Solo
Qoder Work	阿里云	全栈 AI 编辑器 / 编程智能体，原「通义灵码」，主打本地优先
OpenAI Codex	OpenAI	闭源云端编程智能体 + 命令行，锁 GPT-5 Codex 系列

结论：Harness 走「卖框架、开放插件、模型可换」路线，四款竞品走「卖产品、绑生态、模型内置」路线。

vs WorkBuddy（腾讯）：办公工作台 vs 开源框架

WorkBuddy 是什么

是腾讯推出的一款 AI 数字员工 / 桌面智能体（Agent）产品，能替用户「动手干活」：理解自然语言指令后，自动操作电脑上的应用、完成办公任务和重复性工作，帮助提升效率。

与 Harness 的核心差异

维度	WorkBuddy	DeepSeek Harness
产品形态	封闭桌面应用，开箱即用	开源框架 / CLI / SDK，需配置
主要战场	办公自动化 + 腾讯生态	编程、Agent 编排、二次开发
模型自由度	官方集成若干模型	可自由替换任意模型
可扩展性	官方功能为主	一切皆插件，可自写插件
开源	否	是
数据/部署	依赖腾讯云服务	可本地运行 / 自托管

结论：WorkBuddy 适合「不想折腾、重度使用腾讯办公生态」的用户；Harness 适合「要可控、可定制、可换模型、可二次开发」的开发者或团队——「买产品」与「用框架」两条路线。

vs Trae Work（字节）：AI 原生 IDE vs 框架

Trae Work 是什么

Trae Work 是字节跳动推出的一款 AI 原生办公工作台（超级工作台），定位是帮用户把日常杂活交给 AI 自动完成。核心能力包括自动生成 PPT、数据分析、文档撰写等

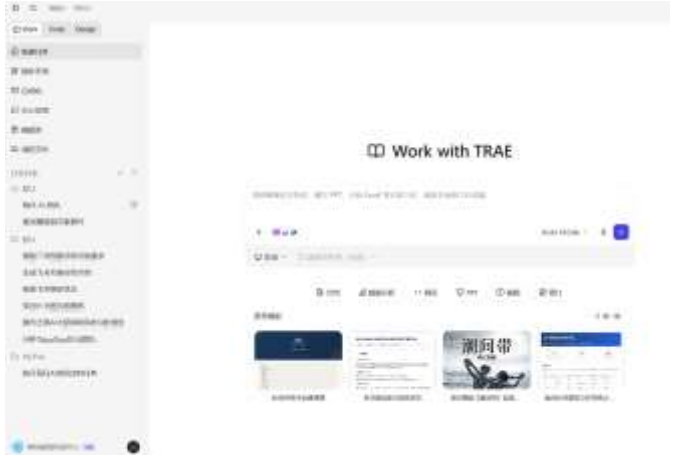

与 Harness 的核心差异

维度	Trae Work	DeepSeek Harness
产品形态	完整 IDE（自带编辑器）	框架 / CLI，可嵌入任意工作流
主要战场	应用开发、页面生成、部署	Agent 编排、插件化执行
模型自由度	内置字节系及合作模型	可自由替换任意模型
可扩展性	官方 IDE 插件生态	一切皆插件，可自写插件
开源	否	是
上手门槛	低（装好即用）	中（需了解 CLI / 配置）

结论：Trae Work 是「带着 AI 的完整开发环境」，适合想要全能 IDE 直接开干的开发者；Harness 是「不绑定 IDE 的执行引擎」，适合已有工具链、想把 Agent 能力嵌入现有流程的团队。

vs Qoder Work（阿里）：本地优先 Agent vs 开源框架

Qoder Work 是什么

Qoder Work 是阿里巴巴推出的一款 AI 办公智能体（桌面 Agent），用户用自然语言下达指令，它就能在电脑上「动手干杂活」——自动操作软件、完成文档、表格、PPT、数据整理等办公任务。

与 Harness 的核心差异

维度	Qoder Work	DeepSeek Harness
产品形态	商业编辑器 / 智能体产品	开源框架 / CLI / SDK
核心卖点	本地优先、记忆/会话/技能引擎	一切皆插件、模型可换
模型自由度	内置通义等模型	可自由替换任意模型
可扩展性	自定义 Skills（受产品约束）	插件 + 二次开发（完全开放）
开源	否	是
数据/部署	本地优先，兼顾云端	可本地 / 自托管

结论：两者在「技能/插件可扩展」上有交集，但 Qoder 是「带本地优先卖点的商业产品」，Harness 是「完全开放的开源框架」。要本地安全 + 现成产品选 Qoder；要深度定制 + 完全可控选 Harness。

vs OpenAI Codex：闭源云端 vs 开源框架

Codex 是什么

是 OpenAI 推出的 AI 编程智能体（自主编程代理），不是一个只会聊天的对话框，而是能「动手」写代码、运行任务、自主完成软件工程的 Agent。已经跟ChatGPT App合并了，有桌面端、移动端

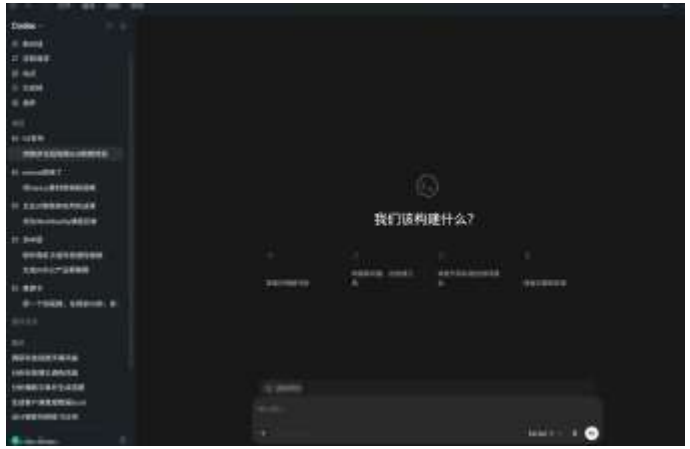

与 Harness 的核心差异

维度	Codex	DeepSeek Harness
开源	否（闭源）	是
模型自由度	锁定 GPT-5 Codex 系列	可自由替换任意模型
运行形态	云端为主（+ CLI）	本地 / 自托管 / CLI
定价	订阅制，成本较高	框架免费，仅模型 API 计费
可扩展性	官方工具为主	一切皆插件，可自写
数据归属	OpenAI 云端	用户可本地掌控

结论：Codex 是「最强闭源云端编程智能体」代表，能力成熟但贵、且不可控；Harness 是「开源、可换模型、可自托管」的替代路线。两者对标同一条赛道，但商业模式完全相反。

五维对比矩阵：一页看懂

维度	Harness	WorkBuddy	Trae Work	Qoder Work	Codex
开源	✅ 是	❌ 否	❌ 否	❌ 否	❌ 否
运行形态	CLI / SDK / 本地	桌面应用	IDE	编辑器 / 智能体	云端 + CLI
模型自由度	●●● 任意换	●● 官方若干	●● 内置为主	●● 内置为主	● 锁 GPT-5 Codex
插件/技能生态	●●● 一切皆插件	●● 官方功能	●● IDE 插件	●●● Skills 引擎	●● 官方工具
数据可控/本地	●●● 可自托管	● 云端	●● 本地 IDE	●●● 本地优先	● 云端
办公自动化	●● 需自建	●●● 强	●● 偏开发	●●● 强	● 偏编程
编程/开发	●●● 强	●● 中	●●● 强	●●● 强	●●● 强
上手门槛	中	低	低	低	低
价格	框架免费	订阅 / 企业	按 Token	订阅 / 企业	订阅（贵）
生态绑定	中立	腾讯系	字节系	阿里系	OpenAI

读表提示：竖着看选产品，横着看比能力。Harness 优势集中在「开源、模型自由、可扩展、可自托管」；劣势在「办公自动化、开箱即用」。

选型建议：什么场景选谁

你的情况	推荐	理由
要完全可控、可二次开发、可换模型	Harness	唯一开源框架，模型可换，可自托管
重度使用腾讯办公生态、想省事	WorkBuddy	多专家 Agent，微信 / 腾讯文档打通
要一个全能 AI IDE 直接开干	Trae Work	AI 主导开发全流程，装好即用
数据敏感、要本地优先 + 阿里云生态	Qoder Work	本地优先，记忆 / 技能引擎成熟
预算充足、要最成熟的云端编程 Agent	Codex	闭源生态成熟，长时自主任务强
已有自研工具链、想嵌入 Agent 能力	Harness	不绑定编辑器，插件化嵌入

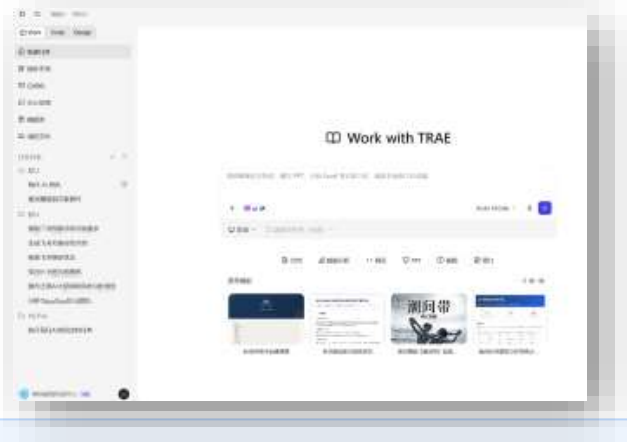

提醒：团队没有开发能力时，直接上 Harness 会踩「配置多、要写插件」的坑，此时更适合选 WorkBuddy 或 Qoder Work 这类成品。

Harness 的差异化优势

1. **插件化 Profile 架构**：能力以「插件组合包 + patch 层」按需叠加，一套内核适配不同场景
2. **多入口形态**：同一配置支持 Web、Headless（无界面）、CLI 等多种运行方式
3. **深度可定制**：分层配置叠加（内置 → 用户 → 命令行覆盖），不改源码即可扩展
4. **原生多 Agent 编排**：内置子代理、工作流、长时目标、后台任务等协作机制
5. **可演进工程底座**：客户端插件热更新 + 独立 Web 壳，方便持续集成新能力

一句话总结优势：竞品卖的是「开箱即用的 Agent 产品」，Harness 给的是「可拆装、可换模型、可自建的开源 Agent 引擎」。

Harness 的短板与适用边界

DeepSeek Harness 当前的短板

1. **仍是早期版本**：目前版本为 0.1.0-rc.6（候选版），尚未到 1.0，接口与行为可能仍有变动
2. **定制门槛高**：深度扩展需要理解 profile / 插件组合包 / patch 分层等概念，对非开发者不友好
3. **npm 包只含编译产物**：发布包里只有 lib/*.js 和 config，不含源码；要改 DSH 本身需回到完整仓库（GitHub）
4. **热更新有条件**：客户端插件 HMR 只有在同时跑 pnpm run dev:web 时才生效，其余改动要重新构建并刷新页面
5. **Web 壳不自带启动**：apps/web 的 Vite 入口依赖 dsh web 注入 window.__DSH_BOOT__，不能当独立应用直接跑

适用边界：Harness 适合有开发能力、要做定制化 Agent、重视可控与成本的团队；不适合零技术用户、要开箱即用办公助手、依赖特定云厂商生态的场景。

关于我们

科技媒体“技术领导力”简介：

科技媒体“**技术领导力**”矩阵，作为IT行业头部媒体，拥有**80万**科技领导者受众。成立于2019年，创作10W+爆文80多篇，100W+播放量视频30个，累计传播量**破亿**。

在科技领域具有广泛影响力，作为**刘润**年度演讲、**吴晓波**年终秀、**陈春花**新书发布会、**江南春**新书发布会特邀支持媒体。

账号矩阵：

技术领导力 Tech Leadership Community　AI新猿人　Mr.K科技洞见

覆盖平台：

微信公众号、视频号、抖音、小红书、知乎、B站、百家号、网易号 .....

微信公众号：技术领导力

公众号：AI新猿人