

DeerFlow-Py

超级智能体协作框架技术文档

[解决方案文档](#) / [架构设计文档](#) / [详细设计文档](#) / [实现文档](#)

版本	v0.2.0
日期	2026-07-28
语言	中文
页数	~40页

目 录

第一部分	解决方案文档	
1.1	问题定义与背景	
1.2	设计目标	
1.3	解决方案概述	
1.4	核心创新点	
第二部分	架构设计文档	
2.1	系统总体架构	
2.2	分层架构设计	
2.3	组件职责划分	
2.4	技术选型	
第三部分	详细设计文档	
3.1	UML 类图设计	
3.2	研究工作流序列图	
3.3	ReAct 循环流程图	
3.4	数据流设计	
3.5	记忆系统架构	
3.6	插件扩展系统	
第四部分	实现文档	
4.1	状态机引擎实现	
4.2	Agent 运行时实现	
4.3	工具系统实现	
4.4	Skills 技能系统	
4.5	中间件系统	
4.6	插件扩展系统	
4.7	Harness 测试框架	
附录	API 参考与快速上手	

第一部分 解决方案文档

1.1 问题定义与背景

随着大语言模型（LLM）能力的飞速发展，单一模型的直接问答已无法满足复杂研究任务的需求。真实世界的研究场景——如市场分析、技术调研、学术综述——需要多步骤推理、多源信息整合、代码验证和迭代修正。ByteDance 开源的 DeerFlow 正是为解决这一需求而生的：它将研究流程建模为多智能体协作的状态机，通过 Planner、Researcher、Coder、Reporter、Critic 等专门化智能体的分工协作，实现端到端的研究自动化。

然而，DeerFlow 原版依赖 LangGraph、LangChain 和 MCP SDK 等多层抽象，对于希望理解内核原理或进行深度定制的开发人员而言，这些抽象层反而增加了认知负担。此外，原版缺少独立的测试评估框架（Harness），难以系统性地度量智能体性能。本项目——DeerFlow-Py——旨在用纯 Python 从零重建 DeerFlow 的核心思想，让每一个移动部件（状态机、ReAct 循环、工具调用、MCP 协议、中断恢复、评估器）都可读、可改、可测试。

1.2 设计目标

DeerFlow-Py 的设计围绕以下五大目标展开，每一项都直接影响架构决策和技术选型：

- 零隐藏抽象：不依赖 LangGraph/LangChain，状态机、Agent 运行时、MCP 协议全部从零实现，代码总量约 4900 行，每一行都可追溯。
- 生产可用：支持流式输出、工具调用、JSON 模式、自动重试、token 统计，可直接对接 OpenAI/DeepSeek/Zhipu 等主流 LLM 提供商。
- 可扩展：通过插件系统、中间件、Skills 技能三层扩展机制，第三方可在不修改框架源码的前提下添加自定义 Agent、Tool、Skill 和图节点。
- 可测试：内置 Harness 框架，提供数据集管理、并发执行器、三种评估器（精确匹配/关键事实/LLM-as-Judge）和 FastAPI 服务，支持离线和在线评估。
- 人机协同：支持 Human-in-the-loop 中断恢复，关键决策点可暂停等待人类反馈，通过 Checkpointer 持久化状态实现跨会话恢复。

1.3 解决方案概述

DeerFlow-Py 采用分层架构，自底向上分为五层：核心引擎层、LLM 层、工具层、智能体层和 Harness 层。核心引擎层包含自定义的 StateGraph 状态机（~490 行）和 Channel reducer 系统，实现了 LangGraph 的超步执行、并行 fan-out、条件路由、中断恢复和 checkpointing 等核心能力，但完全不依赖 LangGraph。LLM 层是一个 OpenAI 兼容的异步客户端，支持流式输出、原生函数调用、JSON 模式和 tenacity 自动重试。工具层将 Web

搜索、网页爬虫、Python 沙箱和 MCP 协议统一为 JSON-Schema 描述的可调用工具。

智能体层包含六个专门化 Agent: Coordinator (路由)、Planner (计划拆解)、Researcher (搜索+爬取)、Coder (代码执行)、Reporter (报告生成) 和 Critic (评审+修订)。它们通过 research_graph 组合成完整的研究 workflow: 问题输入后, Planner 生成 JSON 计划, Researcher 按计划搜索和爬取网页, Coder 可选地执行 Python 代码进行数据分析, Reporter 综合所有证据生成 Markdown 报告, Critic 评审报告并决定通过或要求修订。Harness 层提供 FastAPI 服务 (/run、/eval、/stream WebSocket)、数据集管理 (SimpleQA、GAIA 格式)、并发执行器和三种评估器。

1.4 核心创新点

相较于原版 DeerFlow, 本项目在以下五个方面进行了创新或增强:

创新点	原版 DeerFlow	DeerFlow-Py
状态机	依赖 LangGraph (~15000行含依赖)	纯 Python 自研 (~490行), 零依赖
LLM 层	LangChain ChatOpenAI	直接 httpx async (~322行), 无中间层
MCP 协议	@modelcontextprotocol/sdk	纯 Python JSON-RPC (~315行)
记忆系统	仅短期对话窗口	四层记忆: 短期+长期+情景+工作记忆
扩展机制	无独立扩展框架	三层扩展: Skills+中间件+插件系统
Harness	无独立测试框架	完整 FastAPI+Runner+Evaluator

其中最关键的创新是四层记忆系统和三层扩展机制。四层记忆系统让智能体不仅能记住当前对话, 还能跨会话持久化事实 (长期记忆)、回忆相似历史任务 (情景记忆, 基于 TF-IDF 检索)、并在当前任务中暂存中间结果 (工作记忆)。三层扩展机制——Skills 技能、中间件、插件——分别从 workflow 复用、调用拦截和组件注册三个维度提供扩展能力, 使得第三方可以在不触碰框架源码的前提下深度定制行为。

第二部分 架构设计文档

2.1 系统总体架构

DeerFlow-Py 的系统架构遵循经典的分层+管道模式。客户端层（CLI/REST/WebSocket）通过 Harness 层（Runner/Evaluator/Datasets）调度任务，Harness 层将请求转发给核心引擎层（StateGraph/Orchestrator/Middleware），核心引擎驱动智能体层（Coordinator/Planner/Researcher/Coder/Reporter/Critic）协作完成任务，智能体通过工具层（Search/Crawl/Sandbox/MCP）与外部世界交互。整个流程的状态通过 Checkpointer 持久化，记忆系统贯穿所有层。




图 2-1 DeerFlow-Py 系统总体架构图

2.2 分层架构设计

系统采用严格的五层分离设计，每一层只依赖其下层接口，不跨层调用。这种设计确保了各层可以独立替换：例如可以将 LLM 层从 OpenAI 换成 Anthropic 而不影响智能体层，或将工具层从本地沙箱换成远程 MCP 服务器而不影响核心引擎。




图 2-2 分层架构栈（自底向上）

层	模块	职责	代码量
客户端层	CLI / FastAPI / WebSocket	用户交互、任务提交、流式输出	~300行
Harness 层	Runner / Evaluator / Datasets	测试执行、性能评估、数据管理	~620行
智能体层	6个专门 Agent + research_graph	计划/研究/编码/报告/评审/路由	~440行
核心引擎层	StateGraph / Agent / Memory / MCP / Checkpointer	状态机、Reactor 循环、记忆、编排	~1300行

LLM 层	LLMClient (OpenAI兼容)	异步调用、流式、工具调用、重试	~322行
工具层	Search / Crawl / Sandbox / MCP	搜索、爬虫、代码执行、MCP协议	~900行
扩展层	Skills / Middleware / Plugins	技能复用、调用拦截、插件注册	~800行

从代码量分布可以看出，核心引擎层（~1300行）和工具层（~900行）占据了主体，这反映了框架的设计重心：状态机编排和工具集成是多智能体系统的两大核心能力。扩展层（~800行）是 v0.2.0 新增的，包含记忆系统、Skills、中间件和插件四个子系统。

2.3 组件职责划分

每个组件都有明确的单一职责，组件间通过定义良好的接口通信。StateGraph 只负责状态流转和节点调度，不关心节点内部逻辑；Agent 只负责 ReAct 循环（推理-行动-观察），不关心状态如何持久化；Tool 只负责执行单个操作并返回结果，不关心谁在调用它。这种职责分离使得每个组件都可以独立单元测试——事实上本项目的 24 个测试覆盖了所有核心组件的关键路径。

2.4 技术选型

技术选型遵循「最小依赖、最大可控」原则。所有依赖都是经过仔细评估的：Pydantic v2 用于数据模型验证（性能优于 v1）；httpx 用于异步 HTTP（优于 requests 的同步模型）；tenacity 用于重试逻辑（比手写循环更健壮）；FastAPI 用于 Harness 服务（原生异步、自动文档）；readability-lxml 用于网页正文提取（业界标准）；Playwright 用于图表渲染（跨浏览器一致性）。刻意不使用 LangChain/LangGraph 是为了保持内核透明——每一行代码都可追溯、可调试。

技术	版本	用途	选择理由
Python	3.10+	运行时	async/await 原生支持、类型提示
Pydantic	v2.6+	数据模型	高性能验证、JSON Schema 生成
httpx	0.27+	异步HTTP	原生 async、HTTP/2 支持
FastAPI	0.110+	Harness 服务	原生异步、自动 OpenAPI 文档
tenacity	8.2+	重试机制	指数退避、条件重试
ReportLab	最新	PDF 生成	纯 Python、无外部依赖
Playwright	最新	图表渲染	Mermaid 渲染、截图

第三部分 详细设计文档

3.1 UML 类图设计

下图展示了 DeerFlow-Py 核心类的继承与组合关系。Agent 是所有智能体的抽象基类，定义了 ReAct 循环的骨架（arun 方法）和工具调用逻辑。六个具体智能体（Coordinator/Planner/Researcher/Coder/Reporter/Critic）继承 Agent 并覆盖 run 方法实现各自的工作流。Tool 是工具的抽象基类，FunctionTool 是其便捷子类，通过函数签名自动推断 JSON Schema。StateGraph 是状态机构建器，compile() 后产生不可变的 CompiledGraph 运行时。



Syntax error in text
mermaid version 10.9.6

图 3-1 核心类 UML 类图

类图中的关键设计模式包括：模板方法模式（Agent.arun 定义 ReAct 骨架，子类覆盖 build_messages 和 inject_context 注入上下文）；策略模式（Channel reducer 的 update 方法，LastValue/AddMessages/AddDocuments 是三种策略）；观察者模式（Middleware 的 before/after 钩子）；工厂模式（build_research_graph 函数组装完整工作流图）；装饰器模式（MiddlewarePipeline 洋葱式包裹 Agent 调用）。

3.2 研究工作流程序列图

下图展示了一次完整研究任务的时序流程。用户提交问题后，StateGraph 引擎按超步执行：第一步运行 Planner 生成 JSON 计划；第二步 Researcher 按计划搜索和爬取网页（可能多轮 ReAct 循环）；第三步 Reporter 综合证据生成报告；第四步 Critic 评审报告，若判定为 revise 则回到 Reporter 修订（最多 N 次），若判定为 pass 则结束。整个流程的状态通过 Checkpointer 在每步后持久化，支持中断后从断点恢复。




图 3-2 研究工作流序列图

序列图中的关键交互点包括：用户→StateGraph 的 `ainvoke` 调用携带初始消息；StateGraph→Agent 的 `_run_node` 内部方法将当前状态传给 Agent.run；Agent→LLMClient 的 `chat` 调用携带工具 schema；LLMClient 返回的 `tool_calls` 被 ToolRegistry.execute 并发执行；工具结果作为 `tool` 消息追加到对话中继续 ReAct 循环。Critic 的 `verdict` 字段驱动条件路由——这是状态图 `add_conditional_edges` 的典型应用。

3.3 ReAct 循环流程图

ReAct (Reason-Act-Observe) 是 Agent 运行时的核心循环。每轮迭代中，Agent 将对话历史和工具 schema 发送给 LLM；若 LLM 返回 `tool_calls`，Agent 通过 ToolRegistry 并发执行这些工具，将结果作为 `tool` 消息追加到对话中，然后进入下一轮迭代；若 LLM 返回纯文本（无 `tool_calls`），则循环结束，文本即为最终答案。`max_iterations` 参数防止无限循环。




图 3-3 ReAct 循环流程图

ReAct 循环的设计要点包括：工具并发执行（`asyncio.gather`）减少延迟；每步记录 `AgentStep`（`thoughts/tool_calls/tool_results/latency/usage`）用于遥测；工具错误被捕获并转为 `ToolResult.error` 而非抛出异常，保证循环不中断；LLM 调用通过 `tenacity` 自动重试瞬时错误（5xx/429）。这种设计使得 Agent 既能自主多步推理，又能在工具失败时优雅降级。

3.4 数据流设计

下图展示了从用户输入到最终报告的数据流转过程。用户问题作为 `messages` 进入状态图，经过 `Planner` 后新增 `plan` 字段（JSON 计划），`Researcher` 执行后新增 `documents` 字段（爬取的网页内容），`Reporter` 执行后新增 `report` 字段（Markdown 报告），`Critic` 执行后新增 `verdict` 和 `critique` 字段。所有字段通过 `Channel reducer` 合并——`messages` 和 `documents` 是 `append-only`（去重），其他字段是 `last-write-wins`。




图 3-4 数据流转图

数据流设计的核心是 Channel reducer 系统。每个状态键关联一个 Channel 对象，负责决定如何合并新值与旧值。AddMessages 通道按消息 ID 或内容哈希去重，确保节点重跑（如中断恢复后）不会产生重复消息。AddDocuments 通道按（source, content）哈希去重，避免同一搜索结果被多次加入上下文。LastValue 通道是简单的最后写入胜出，用于 plan、report、verdict 等标量字段。这种设计让状态合并成为声明式操作——节点只需返回部分更新字典，Channel 自动处理合并语义。

3.5 记忆系统架构

v0.2.0 新增的四层记忆系统是本框架区别于原版 DeerFlow 的关键特性。短期记忆（ShortTermMemory）是滑动窗口对话缓冲，保留最近 N 条消息并自动摘要溢出部分。长期记忆（LongTermMemory）是 JSON 文件持久化的键值存储，跨会话保存用户偏好和学到的事实。情景记忆（EpisodicMemory）存储历史任务（Episode），通过 TF-IDF + 余弦相似度检索相似过往经验。工作记忆（WorkingMemory）是当前任务的暂存区，存放计划、中间结果和引用，任务结束后清空。

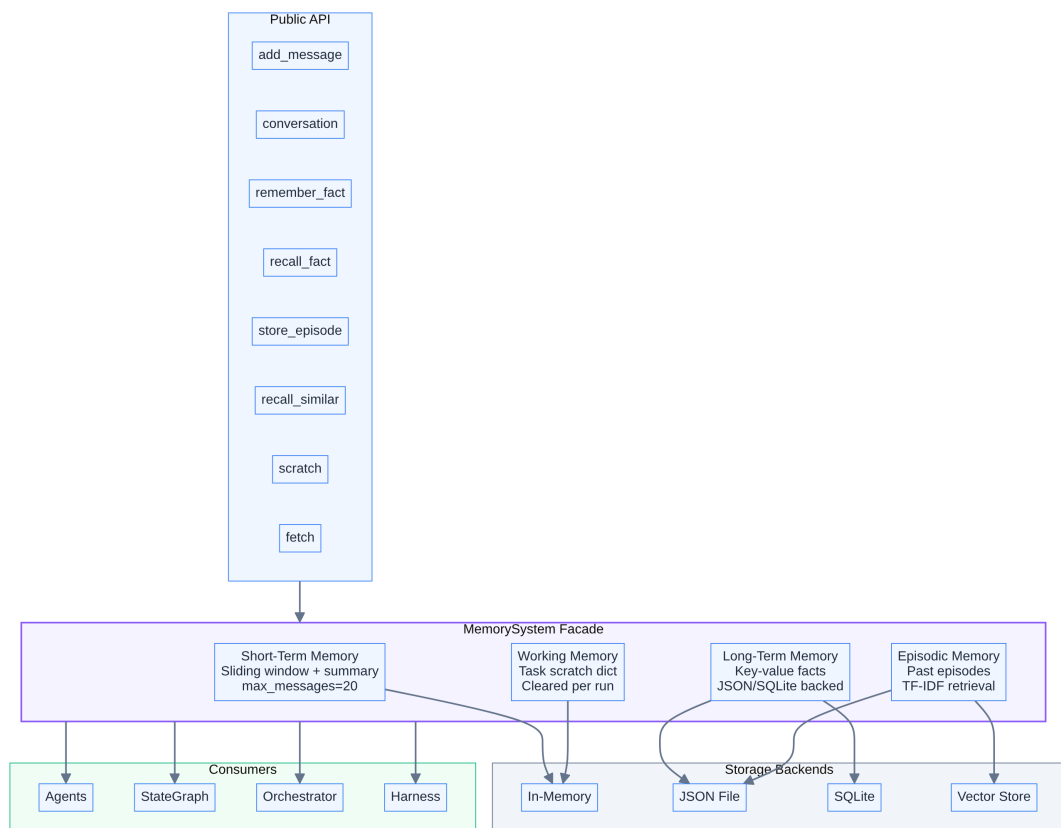


图 3-5 四层记忆系统架构

MemorySystem 是统一门面，提供 `remember_fact/recall_fact`（长期）、`store_episode/recall_similar`（情景）、`scratch/fetch`（工作）等便捷方法。智能体在执行前可调用 `recall_similar` 检索相似历史任务作为 few-shot 示例，在执行后可调用 `store_episode` 记录本次经验。这种设计让框架具备持续学习能力——随着使用次数增加，情景记忆库不断丰富，智能体在相似任务上的表现逐步提升。

3.6 插件扩展系统

插件系统让第三方包在不修改框架源码的前提下扩展功能。一个插件是继承 `Plugin` 基类的 Python 模块，通过 `PluginContext` 注册自定义 Agent、Tool、Skill、图节点和中间件。插件发现支持三种方式：`entry_points`（pyproject.toml 声明，自动加载）、显式路径（传入文件路径或模块名）、目录扫描（自动发现 `deerflow_*.py` 文件）。




图 3-6 插件扩展系统架构

插件系统的设计借鉴了 Flask 的蓝图和 Django 的应用配置模式。PluginContext 是注册中心，持有 llm、tools、agents、skills、middleware、graph_nodes 等容器。Plugin 基类定义了 register（注册时调用）和 on_unload（卸载时调用）两个生命周期钩子。PluginManager 负责发现、加载、卸载插件，并构建最终的 MiddlewarePipeline 和 StateGraph。这种设计使得企业可以将内部工具封装为私有插件包，通过 pip install 后即自动集成到框架中。

第四部分 实现文档

4.1 状态机引擎实现

StateGraph 是 LangGraph 的纯 Python 等价物，实现了超步执行模型。核心执行循环在 CompiledGraph.ainvoke 中：每次迭代弹出一批就绪节点（入度为 0 的节点），用 asyncio.gather 并发执行，将各节点输出通过 Channel reducer 合并到共享状态，然后根据刚完成节点的边计算下一批就绪节点，重复直到到达 END 或无就绪节点。中断通过 GraphInterrupt 异常实现——节点抛出该异常时，图捕获它并将中断信息存入 state['__pending_interrupt__']，通过 Checkpointer 持久化后返回 interrupted=True。恢复时，_resume_frontier 方法读取中断信息，将 resume 值作为中断节点的输出应用到状态，然后计算下一批节点继续执行。

状态机的关键设计决策包括：节点是 async 或 sync 可调用（sync 自动包装为 to_thread）；边可以是静态的（add_edge）或条件的（add_conditional_edges，路由函数返回下一节点名）；并行 fan-out 通过从一个节点引出多条边实现；checkpointing 在每步后自动调用（可插拔 InMemoryCheckpointer 或 JSONFileCheckpointer）；astream 方法是流式版本，每步 yield 一个事件字典，适合 WebSocket 推送。

4.2 Agent 运行时实现

Agent 基类实现了标准 ReAct 循环。arun 方法接收消息列表和上下文，内部循环最多 max_iterations 次：每次调用 LLMClient.chat 传入对话和工具 schema，若返回 tool_calls 则通过 ToolRegistry.execute_many 并发执行，将结果作为 tool 消息追加到对话中继续循环；若返回纯文本则结束循环返回 AgentResponse。每步记录 AgentStep（thoughts/tool_calls/tool_results/latency/usage）用于遥测和 Harness 评估。子类通过覆盖 build_messages 注入系统提示词，覆盖 inject_context 注入来自图状态的动态上下文。

六个具体智能体的实现各有特点：Coordinator 是无工具的单次 LLM 调用，只返回一个智能体名用于路由；Planner 使用 JSON 模式（response_format）强制 LLM 返回结构化计划，解析失败时回退到默认计划；Researcher 配备 web_search 和 crawl_url 工具，通过 inject_context 接收当前计划步骤描述以聚焦搜索；Coder 配备 python_run 沙箱工具，ReAct 循环支持写-跑-读错-修-重跑；Reporter 是无工具的单次调用，从状态中读取 plan 和 documents 作为额外上下文；Critic 使用 JSON 模式返回结构化评审结果，verdict 字段驱动条件路由。

4.3 工具系统实现

Tool 基类定义了 name、description、parameters（JSON Schema）三个属性和 arun 异步方法。FunctionTool 是便捷子类，通过函数签名自动推断参数类型（int→integer，str→string 等），通过 __post_init__ 在构造时自动生成 schema。ToolRegistry 是工具集合，提供 schemas()

方法将所有工具转为 OpenAI function-calling 格式，execute() 方法接收一个 tool_call 字典，解析 name 和 arguments，查找对应工具并执行，返回 ToolResult。execute_many() 用 asyncio.gather 并发执行多个调用。

内置工具包括：DuckDuckGoSearchTool（免费搜索，解析 HTML 结果页）、TavilySearchTool（生产级搜索，需 API key）、WebCrawlerTool（用 readability-lxml 提取正文）、PythonSandboxTool（子进程隔离执行 Python，支持 RLIMIT 和超时）、MCPClient/MCPServer（JSON-RPC 2.0 over stdio 的 MCP 协议实现）。MCP 实现支持 initialize 握手、tools/list 列举、tools/call 调用，可以与 Claude Desktop、Cursor 等标准 MCP 客户端互操作。

4.4 Skills 技能系统

Skill 是比 Tool 更高层的抽象——Tool 是单个函数，Skill 是一个可能调用多个工具、运行多次 LLM 调用的完整工作流。Skill 基类定义了 execute 异步方法和 to_tool_dict 方法（将 Skill 转为 OpenAI 工具描述符，让 LLM 可以像调用 Tool 一样调用 Skill）。内置四个技能：SummarizeSkill（将任意文本总结为 N 个要点）、TranslateSkill（翻译到目标语言）、CodeReviewSkill（审查代码片段的 bug）、OutlineSkill（为主题生成结构化大纲）。SkillRegistry 管理技能集合，default_skills(llm) 工厂函数返回预装四个内置技能的注册表。

Skills 系统的设计灵感来自 deer-flow 的 deep research skill 和 MCP 的 prompts 能力，但推广到了任意工作流。技能是可组合的——一个技能的 execute 方法内部可以调用其他技能。这使得复杂工作流可以通过组合简单技能来构建，而非从头编写。例如，一个 ResearchSkill 可以内部调用 SummarizeSkill 来总结搜索结果，再调用 OutlineSkill 来组织报告结构。

4.5 中间件系统

中间件系统允许在不修改 Agent/Tool 代码的前提下拦截和修改调用。Middleware 基类定义了四个钩子：before_agent/after_agent（包裹 Agent.arun）和 before_tool/after_tool（包裹 Tool.arun）。MiddlewarePipeline 按洋葱模型执行——before_* 钩子按注册顺序执行（先注册先执行），after_* 钩子按逆序执行（后注册先执行）。内置五个中间件：LoggingMiddleware（结构化日志）、TimingMiddleware（延迟追踪）、RateLimitMiddleware（令牌桶限流）、CacheMiddleware（按参数哈希缓存工具结果）、TracingMiddleware（OpenTelemetry 风格 span 追踪）。

中间件的核心价值在于横切关注点的分离。例如，限流逻辑不需要侵入每个工具的实现，只需注册一个 RateLimitMiddleware 即可全局生效。缓存同理——CacheMiddleware 通过对 (tool_name, args) 取哈希作为缓存键，命中时直接返回缓存结果跳过实际执行。这种设计使得性能优化、可观测性、安全控制等横切逻辑可以独立开发和部署。

4.6 插件扩展系统

插件系统让第三方包通过标准 Python 机制扩展框架。Plugin 基类定义了 name、version 属性和 register/on_unload 生命周期方法。PluginContext 是注册中心，提供 register_agent/register_tool/register_skill/register_middleware/register_node 等方法。PluginManager 负责发现和加载插件，支持三种发现方式：entry_points（通过 pyproject.toml 的 [project.entry-points.'deerflow.plugins'] 声明）、load_module（传入模块名）、load_dir（扫描目录中的 deerflow_*.py 文件）。

插件加载后，PluginManager 提供 build_middleware_pipeline() 和 build_graph() 方法，将所有插件注册的中间件和图节点组装成运行时。这种设计使得企业可以将内部工具（如私有数据库查询、内部 API 调用）封装为插件包，通过 pip install 后自动集成。插件的 on_unload 钩子支持热卸载——在运行时动态移除功能而不重启服务。load_all(llm, plugin_dir) 是便捷入口，一次性加载 entry_points 和指定目录的所有插件。

4.7 Harness 测试框架

Harness 是框架的测试评估层，包含四个组件。Datasets 模块定义 TestCase (id/question/reference/category/difficulty/expected_tools) 和 Dataset 集合，内置 SimpleQADataset (10 个手工 Q&A;) 和 GAIADataset (GAIA 基准格式)，支持 to_jsonl/from_jsonl 持久化。Evaluator 模块提供三种评估器：ExactMatchEvaluator（归一化后精确匹配）、ContainsEvaluator（关键事实覆盖率）、LLMJudgeEvaluator（用 LLM 作裁判，返回 0-100 分加理由）。

Runner 是并发执行器，用 asyncio.Semaphore 控制并发度，对每个测试用例调用 graph.ainvoke，计时并提取 trace 中的 token 用量，然后运行评估器打分，汇总成 RunReport (pass_rate/mean_score/mean_latency/total_tokens/by_category)。FastAPI 服务暴露 /run（单次运行）、/eval（数据集评估）、/stream（WebSocket 流式）、/datasets（数据集列表）、/health（健康检查）五个端点。CLI 工具 deerflow-harness 提供 serve（启动服务）和 eval（离线评估）两个子命令。

附录 API 参考与快速上手

A.1 公共 API 一览

模块	主要类/函数	用途
core.graph	StateGraph, CompiledGraph, GraphInterrupt	状态图构建与执行
core.agent	Agent, AgentResponse, AgentStep	ReAct 智能体基类
core.memory	Memory, Checkpointer, InMemoryCheckpoint	短期记忆与持久化
core.advanced_memory	MemorySystem, LongTermMemory, EpisodicMemory	四层记忆系统
core.orchestrator	Orchestrator	多智能体路由编排
llm.client	LLMClient, LLMMessage, LLMResponse	OpenAI 兼容 LLM 客户端
tools	Tool, ToolRegistry, FunctionTool	工具系统与注册表
tools.mcp	MCPClient, MCPServer	MCP 协议客户端/服务端
agents	CoordinatorAgent, PlannerAgent, ...	六个专门化智能体
agents.research_graph	build_research_graph()	研究工作流图构建器
skills	Skill, SkillRegistry, SummarizeSkill, ...	技能系统
middleware	Middleware, MiddlewarePipeline, ...	中间件系统
plugins	Plugin, PluginManager, load_all()	插件扩展系统
harness	Runner, Evaluator, create_app()	测试评估框架

A.2 快速上手

安装与基本使用：

```
# ■■■
cd deerflow_py && pip install -e .

# CLI ■■■■ OPENAI_API_KEY■■■ key ■■■■ MockLLM■
deerflow "Summarise 2024 LLM agent trends"

# ■■■■
import asyncio
from deerflow import build_research_graph, LLMClient

async def main():
    llm = LLMClient.from_env()
    graph = build_research_graph(llm)
    result = await graph.ainvoke({
        'messages': [{'role': 'user', 'content': 'your question'}]}
    })
    print(result.state['report'])

asyncio.run(main())
```

自定义插件示例：

```
# my_plugin.py
from deerflow.plugins import Plugin, PluginContext
from deerflow.middleware import LoggingMiddleware

class MyPlugin(Plugin):
    name = 'my-plugin'
    version = '1.0.0'

    def register(self, ctx: PluginContext) -> None:
        ctx.register_agent('my_agent', MyAgent)
        ctx.register_tool('my_tool', MyTool())
        ctx.register_skill('my_skill', MySkill(ctx.llm))
        ctx.register_middleware(LoggingMiddleware())

# ■■■■
from deerflow import load_all
pm = load_all(llm, plugin_dir='./plugins')
```

A.3 测试验证

项目包含 24
个单元测试，覆盖状态机（通道去重、线性图、条件路由、中断恢复）、工具系统（Schema 推断、注册表分发、沙箱执行与超时）、智能体（ReAct 循环、研究图端到端、Critic 修订循环、流式输出）和 Harness（数据集、评估器、Runner）四大模块。运行命令：python -m pytest tests/ -v，全部 24 个测试通过。

A.4 项目结构

路径	说明
src/deerflow/core/	状态机、Agent、记忆、编排器（~1300行）
src/deerflow/llm/	LLM 客户端（~322行）
src/deerflow/tools/	搜索/爬虫/沙箱/MCP（~900行）
src/deerflow/agents/	六个智能体+研究图（~440行）
src/deerflow/skills/	技能系统（~300行）
src/deerflow/middleware/	中间件系统（~250行）
src/deerflow/plugins/	插件系统（~250行）
harness/	测试评估框架（~620行）
examples/	三个可运行示例
tests/	24个单元测试