

PR #1981 完整报告

THUDM/slime

[agent] extract Adapter class

合并时间: 2026-05-29 20:41

原文链接: <http://prhub.com.cn/THUDM/slime/pull/1981>

执行摘要

- 一句话: 抽取 Adapter 基类, 封装会话生命周期管理
- 推荐动作: 该 PR 值得核心开发者精读, 尤其是 BaseAdapter 的设计模式和类型安全 AppKey 的使用。外部用户若已使用 agent 适配器应尽快迁移。

功能与动机

消除 anthropic.py 与 openai.py 之间重复的模块级状态变量和函数, 提供统一的面向接口的会话管理方式, 降低新增适配器的门槛并提高可维护性。

实现拆解

1. 定义 BaseAdapter 与应用键 (slime/agent/adapters/common.py): 新增 BaseAdapter 类, 封装 store、inflight、closed 等状态和 open_session / shutdown_session / finish_session (抽象) 方法; 定义 ADAPTER_KEY、TOKENIZER_KEY 等类型安全的 web.AppKey, 替换原有的字符串键。
2. 改造 AnthropicAdapter (slime/agent/adapters/anthropic.py): 将原有的 _Store、_inflight、_closed 模块变量移除, 新类 AnthropicAdapter 继承 BaseAdapter, __init__ 调用基类构造后添加路由, finish_session 实现子代理和 final 段的合并。
3. 改造 OpenAIAdapter (slime/agent/adapters/openai.py): 类似地迁移为类, finish_session 仅处理最终段。
4. 更新模块导出 (slime/agent/adapters/__init__.py): 导出 AnthropicAdapter、OpenAIAdapter、BaseAdapter。
5. 更新示例 (examples/coding_agent_rl/generate.py): 使用 AnthropicAdapter 实例替代模块函数调用, 调用 adapter.open_session / adapter.finish_session。
6. 更新测试 (tests/test_agent_adapters.py、tests/test_agent_sdk_adapters.py): 适配新类语法, 使用 adapter.app 创建 TestServer。
7. 同步文档 (docs/*/get_started/agent.md 等): 更新为新的类使用方式。

关键文件:

- slime/agent/adapters/common.py (模块 核心; 类别 source; 类型 core-logic; 符号 BaseAdapter, init, open_session, shutdown_session): 新增 BaseAdapter 基类和应用键, 是所有适配器共用的生命周期管理核心。

- `slime/agent/adapters/anthropic.py` (模块 适配器; 类别 source; 类型 core-logic; 符号 `AnthropicAdapter`, `init`, `finish_session`) : `AnthropicAdapter` 继承 `BaseAdapter`, 实现会话结束时子代理和最终段的合并逻辑。
- `slime/agent/adapters/openai.py` (模块 适配器; 类别 source; 类型 core-logic; 符号 `OpenAIAdapter`, `init`, `finish_session`) : `OpenAIAdapter` 继承 `BaseAdapter`, 实现会话最终段的合并。
- `examples/coding_agent_rl/generate.py` (模块 示例; 类别 source; 类型 dependency-wiring) : 示例代码迁移到新 API, 使用 `AnthropicAdapter` 实例替代模块函数调用。

关键符号: `BaseAdapter.init`, `BaseAdapter.open_session`, `BaseAdapter.shutdown_session`, `BaseAdapter.finish_session`, `AnthropicAdapter.init`, `AnthropicAdapter.finish_session`, `OpenAIAdapter.init`, `OpenAIAdapter.finish_session`

关键源码片段

`slime/agent/adapters/common.py`

新增 `BaseAdapter` 基类和应用键, 是所有适配器共用的生命周期管理核心。

```
class BaseAdapter:
    """Base HTTP adapter with per-instance session lifecycle state."""
    session_cls: type

    def __init__(self, *, tokenizer, sglang_url, tool_parser=None, reasoning_parser=None) -> None:
        # 每个实例拥有独立的会话存储、inflight 任务集和关闭标记,
        # 替代原来模块级的 _Store、_inflight、_closed 变量。
        self.store: dict[str, Any] = {}
        self.inflight: dict[str, set[asyncio.Task]] = {}
        self.closed: set[str] = set()
        self.app = web.Application(client_max_size=64 * 1024 * 1024)
        # 使用类型安全的 AppKey 代替字符串 key, IDE 可获得更好的补全和类型检查。
        self.app[ADAPTER_KEY] = self
        self.app[TOKENIZER_KEY] = tokenizer
        self.app[SGLANG_URL_KEY] = sglang_url.rstrip("/") if isinstance(sglang_url, str) else sglang_url
        self.app[TOOL_PARSER_KEY] = tool_parser
        self.app[REASONING_PARSER_KEY] = reasoning_parser

    def open_session(self, sid: str, *, sampling_defaults: dict | None = None, max_context_tokens: int = 0) -> None:
        # 委托给公共的 register_session 函数, 但通过实例的 store 和 session_cls 完成注册。
        register_session(self.store, sid, self.session_cls, sampling_defaults=sampling_defaults, max_context_tokens=max_context_tokens)

    async def shutdown_session(self, sid: str, *, wait_timeout: float = 5.0) -> None:
        # 关闭会话时先取消所有 in-flight 任务, 然后标记 closed。
        await shutdown_session_tasks(sid, self.closed, self.inflight, wait_timeout=wait_timeout)
```

```

async def finish_session(self, sid: str, *, wait_timeout: float = 5.0) -> list[TokenSegment]:
    # 抽象方法，子类需实现如何从 store 中提取并合并 TokenSegment。
    raise NotImplementedError

```

slime/agent/adapters/anthropic.py

AnthropicAdapter 继承 BaseAdapter，实现会话结束时子代理和最终段的合并逻辑。

```

class AnthropicAdapter(BaseAdapter):
    """Anthropic Messages-compatible HTTP adapter with session lifecycle helpers."""
    session_cls = Session

    def __init__(self, *, tokenizer, sglang_url, tool_parser=None, reasoning_parser=None) -> None:
        super().__init__(
            tokenizer=tokenizer,
            sglang_url=sglang_url,
            tool_parser=tool_parser,
            reasoning_parser=reasoning_parser,
        )
        # 注册 Anthropic Messages API 特有的路由
        self.app.router.add_post("/v1/messages", _handle_request)
        self.app.router.add_post("/v1/messages/count_tokens", _count_tokens)
        self.app.router.add_get("/healthz", _ok)
        self.app.router.add_get("/v1/models", _ok)

    async def finish_session(self, sid: str, *, wait_timeout: float = 5.0) -> list[TokenSegment]:
        # 先关闭 inflight 任务并标记 closed
        await self.shutdown_session(sid, wait_timeout=wait_timeout)
        s = self.store.pop(sid, None)
        if s is None:
            return []
        # 如果存在活跃子代理且其 turns 不为空，先作为 subagent 段追加
        if s.active_sub is not None and s.active_sub.turns:
            s.segments.append(make_turn_segment(s.active_sub.turns, kind="subagent"))
        # 主链的 turn 作为 final 段
        if s.main.turns:
            s.segments.append(make_turn_segment(s.main.turns, kind="final"))
        return merge_turn_segments(s.segments, max_context_tokens=s.max_context_tokens)

```

slime/agent/adapters/openai.py

OpenAIAdapter 继承 BaseAdapter，实现会话最终段的合并。

```

class OpenAIAdapter(BaseAdapter):
    """OpenAI-compatible HTTP adapter with session lifecycle helpers."""
    session_cls = Session

    def __init__(self, *, tokenizer, sglang_url, tool_parser=None, reasoning_parser=None) -> None:
        super().__init__(

```

```

        tokenizer=tokenizer,
        slang_url=sglang_url,
        tool_parser=tool_parser,
        reasoning_parser=reasoning_parser,
    )
    # 注册 OpenAI 兼容的聊天和响应端点
    self.app.router.add_post("/v1/chat/completions", _handle_chat_completions)
    self.app.router.add_post("/v1/responses", _handle_responses)
    self.app.router.add_get("/healthz", _ok)
    self.app.router.add_get("/v1/models", _ok)

async def finish_session(self, sid: str, *, wait_timeout: float = 5.0) -> list[TokenSegment]:
    # 先关闭 inflight 任务并标记 closed
    await self.shutdown_session(sid, wait_timeout=wait_timeout)
    s = self.store.pop(sid, None)
    if s is None:
        return []
    # OpenAI 适配器不处理子代理，仅将主链 turn 作为 final 段
    if s.main.turns:
        s.segments.append(make_turn_segment(s.main.turns, kind="final"))
    return merge_turn_segments(s.segments, max_context_tokens=s.max_context_tokens)

```

评论区精华

- 暂无高价值评论线程

风险与影响

- 风险：
 1. API 兼容性风险：原有的 `pop_session_split`、`start` 等模块级函数被移除，任何直接调用它们的代码（如未迁移的测试或示例）将失败。
 2. 状态管理迁移：原本模块变量（`_inflight`、`_closed`）变为实例属性，确保同一进程内多个适配器实例不会互相干扰，但若原有代码依赖全局单例则需注意。
 3. 测试覆盖：测试文件已同步更新，但关键路径（如子代理 `segment` 拆分）的覆盖率需确认。
 - 影响：对使用 `agent` 适配器的开发者：需从调用函数改为实例化类，并调用相应方法。对系统：无运行时性能影响，但代码结构更清晰。对团队：降低了后续新增适配器（如 `Gemini`）的重复劳动。
 - 风险标记：API 迁移风险，旧函数移除，测试覆盖需确认

关联脉络

- PR #1979 [agent] Add openai and anthropic adapters: 该 PR 引入了最初的适配器模块，本 PR 将这些模块中的功能抽取为类，是前者的重构演进。
- PR #1960 Extract more util code from coding_agent_rl example: 类似地抽取通用工具到核心模块，与本 PR 的抽取思想一致，属于同一重构脉络。
- PR #1963 Fix trajectory merging logic: 涉及 `trajectory` 合并逻辑的修复，本 PR 中的 `finish_session` 依赖 `merge_turn_segments`，因此关联。