

HEEL: 面向持久化 Agent 的状态中心自传体记忆架构

——超越会话中心本体论的新范式

作者姓名 Zili Chen

✉ zl.chen.research@outlook.com

✉ <https://github.com/L-aaaaaaa/HEEL.git>

ArXiv 预印本, 2026年4月

摘要

当前 Agent 记忆系统深陷“会话中心本体论”——以 Session 为唯一时间容器、以语义标签为管理依据。这导致记忆-身份-语义三重耦合，引发跨会话失忆、人格撕裂、上下文负担累积等系统性病变。本文提出“状态中心分类学”，以数据的**可注入性** (Injectability) ——即能否无需额外处理直接放入上下文窗口——作为唯一的、与语义正交的分类判据。由该判据必然导出四元记忆结构 **HEEL** (History / Experience / External / Logic)，以及“角色-分身-义脑”三层身份解耦模型。本文证明，旧范式下的“工程难题”并非被解决，而是**自然消解**——跨会话连续性、人格稳定性等在新公理体系下成为定理的必然推论。本文首次为 Agent 记忆领域建立公理化基础，使新架构成为理论演绎的内生产物。

本稿件确立 HEEL 架构的理论框架与学术优先权。 完整的代谢闭环工程实例化、系统实现，以及与 LangChain、MemGPT 等基线的多会话场景定量对比评估，将在后续面向顶级会议的扩展版本中报告。（为遵守双盲审稿规则，本文提交至 arXiv 后将同时提供一份删除作者信息的匿名版本，供审稿人使用。）

关键词： Agent记忆；会话中心本体论；可注入性；状态中心分类；自传体记忆；范式转移

1. 引言：会话中心本体论的病理学

自大型语言模型驱动的对话式 Agent 兴起以来，**Session (会话)** 一直作为上下文管理的基本设计原语。Session 将人格设定、对话历史和任务状态打包进一个单一容器，为资源分配和隔离提供了便利的边界。然而，这种便利掩盖了一项根本性的架构妥

协。随着 Agent 从简单的聊天机器人进化为长期协作伙伴，三种系统性病变已变得不可避免：

病变类型	临床表现	用户感知
跨会话失忆	新会话无法访问历史记忆	“我们昨天聊过这个，你不记得了？”
人格撕裂	上下文溢出时人格设定被截断或压缩	“你怎么突然变了一个人？”
上下文负担	大量无效冗余占据窗口	“聊了半小时，前面的事就忘了”


这些病变不是实现层面的 bug。它们是一种**共享本体论承诺的结构后果**：Session 边界应当定义记忆的范围，语义类别应当决定管理策略。当今所有主流框架——LangChain、LlamaIndex、MemGPT (Letta)、CrewAI、AutoGen——都在这一承诺下运行。

现有改进方案（缓冲记忆、摘要记忆、向量检索记忆、结构化记忆）均在“如何更好地管理 Session 内的记忆”这一范式内运作，**没有人质疑 Session 本身是否应作为记忆管理的基本单元**。

本文将 Session 中心主义的病灶解剖为三种相互锁定的耦合：

- 语义-状态耦合**：数据的“是什么”决定了“怎么管”。
- 状态-身份耦合**：人格设定与对话流水账同处一个 Session 容器，上下文溢出时无法区别对待。
- 身份-语义耦合**：长期身份标识被绑定在临时会话 ID 上。

本文提出一个根本性的范式转移：以数据的可消费状态（可注入性）替代时间边界（Session），作为记忆分层的根本判据。本文将建立一套新公理体系，并演绎出相应的架构与身份模型。我们将证明：在这一新范式下，旧范式的三大病变不再是被“解决”，而是**根本不再被提出**。



本文聚焦于 Agent 记忆架构的公理重建。在并行提交的另一项工作《时策：从规则预编译到运行时推理的语义驱动时间调度范式》中，我们处理了 Agent 的**时间感知**问题——时策循环同样采用了“状态中心”思维，以 LLM 运行时推理替代预编译规则。两套理论共同构成 JARVIS 项目的认知架构基础。

.....

2. 理论洞察：可注入性作为正交维度

2.1 旧公理的批判

会话中心本体论的核心假设可形式化为：



旧公理 (Session 边界假设)：Agent 的记忆状态完全由当前 Session 容器定义。Session 内 = 在线可访问；Session 外 = 离线不可访问。

此公理导致两个不可调和的内部矛盾：

矛盾一：身份矛盾。Agent 需跨 Session 保持人格连续性，但旧公理使持久化身份在逻辑上不可能——除非永久保存整个 Session（这在有限上下文窗口下不可行）。

矛盾二：压缩矛盾。上下文溢出时需压缩记忆以腾出空间，但旧公理未提供区分“可压缩的流水账”与“不可压缩的人格核心”的依据。

2.2 新公理体系

我们提出三条新公理，构成状态中心本体论的基石。



公理 0 (存在公理)：Agent 拥有一个**终身记忆库** \mathcal{M} ，其存在不依赖于任何特定 Session。 \mathcal{M} 是 Agent 记忆的持久化载体，其生命周期与 Agent 的身份标识绑定。



公理 1 (状态正交公理)：存在一个可注入性判据 $\mathcal{I}(d) \in \{0,1\}$ ，表示数据项 d 能否在当前技术条件下无需额外处理直接放入上下文窗口并被 LLM 有效理解。 $\mathcal{I}(d)$ 与 d 的语义内容**正交**，与 d 所处的 Session 边界无关。

可注入性的操作化定义： $\mathcal{I}(d) = 1$ 当且仅当：(1) 体积不超过预设 Token 阈值；(2) 格式可被 LLM 原生解析；(3) 内容自包含，无需额外上下文。

“正交”的含义：两条语义内容相同的数据项（例如原始对话转录 vs 结构化事实摘要），其可注入性截然不同。在语义分类下两者可能被归为一类；在状态中心分类下，它们因**加工状态不同**而处于不同层级。



公理 2 (代谢必然公理)：记忆库 \mathcal{M} 必须持续经历**编码** → **巩固** → **衰减** → **淘汰**的代谢闭环，否则将因无限增长而导致检索效率与上下文注入质量的双重衰退。

2.3 形式化定义：旧范式 vs 新范式

旧范式下，Agent 被形式化为一个从 Session-Query 对到响应的函数：

$$\text{Agent}_{\text{old}} : \text{Session}^i \times \text{Query} \rightarrow \text{Response}$$

新范式下，Agent 被重新定义为：

$$\text{Agent}_{\text{new}} : \mathcal{M} \times f_{\text{concentration}}(\text{Query}, \mathcal{M}) \rightarrow \text{Response}$$

其中 \mathcal{M} 是终身记忆库（公理 0）， $f_{\text{concentration}}$ 是**关注域函数**，根据当前 Query 和 Agent 的操作状态，动态组合 \mathcal{M} 的子集注入当前上下文。

范式转变的核心：Session 从“状态容器”**降格**为“关注域视图”——它只是 $f_{\text{concentration}}$ 的一种可能的参数化方式，而非记忆的必然边界。

3. HEEL 架构：公理体系的演绎构造

3.1 定理 1：四元分层定理



定理 1 (四元分层定理)：由公理 1 ($\mathcal{I}(d)$ 的正交性) 必然导出记忆的四层逻辑结构：

- **History** ($\mathcal{I}=0$ ，来源为对话流)：原始对话流水账，只追加不修改。
- **Experience** ($\mathcal{I}=1$)：可直接注入上下文的已就绪数据单元。
- **External** ($\mathcal{I}=0$ ，来源为外部数据)：需检索/解析的外部数据源。
- **Logic** (非数据层)：管理前三层读写/演化/压缩的纯策略层。

证明概要（构造性）： 根据 $\mathcal{I}(d)$ 的取值，数据天然分为两类。对于 $\mathcal{I}=0$ 的数据，进一步按来源区分：对话流为 History，外部数据源为 External。 $\mathcal{I}=1$ 者统一归为 Experience。另需一策略层 Logic 管理前三层。四层划分穷尽且互斥。

层次	判据	定义	典型示例
History	$\mathcal{I}=0$ ， 对话原料	原始对话流水账	用户:北京天气如何？助手:晴
Experience	$\mathcal{I}=1$ ， 即用成品	已就绪数据单元	摘要:用户常在北京工作；偏好:喜欢简练回答
External	$\mathcal{I}=0$ ， 外部原料	需检索/解析的外部数据源	长 PDF 文档、SQL 数据库
Logic	—	管理读写、淘汰、压缩的纯策略层	容量控制、压缩触发器

关键洞察： 分类不由数据“意味着什么”决定，而由“处于什么状态”决定。

3.2 推论：解耦的必然性

由公理 1 直接可得：



推论 1（解耦推论）： 记忆的管理策略不应由语义决定，而应由 $\mathcal{I}(d)$ 决定。

由公理 0 与公理 1 联合可得：



推论 2（Session 降格推论）： Session 不再是记忆管理策略的必然边界。记忆的归属由角色 ID 决定，记忆的加工策略由 $\mathcal{I}(d)$ 决定。

3.3 解耦之后：角色作为新锚点

公理 0 确立了 \mathcal{M} 的持久存在，公理 1 将数据从语义和 Session 的双重绑定中解放。唯一稳定的组织重心是**角色（Character）**——一个绑定了 \mathcal{M} 的、跨 Session 存在的持久化人格实例。

4. 人格锚定：身份三层解耦定理

4.1 定理 2：身份三层解耦定理



定理 2（身份三层解耦定理）：由公理 0 与公理 1 联合导出，Agent 的身份必须解耦为三个正交语义层：

- **角色 (Character)**：绑定 \mathcal{M} 的持久化人格标识。
- **分身 (Fenshen)**：角色在特定任务/关注点下的临时视图，即 $f_{\text{concentration}}$ 的一次具体实例化。
- **义脑 (Yinao)**：驱动推理的 LLM 型号，可插拔替换，与记忆归属无关。

证明概要：公理 0 要求一个超越任何个体 Session 的持久实体，此即**角色**。公理 1 要求 \mathcal{M} 中的数据基于 $\mathcal{I}(d)$ 和当前查询被动态组合进上下文，每一次这样的组合都是 \mathcal{M} 的一个**视图**，此即**分身**。执行推理的引擎（LLM 模型）是独立维度，此即**义脑**。三层正交。

4.2 从继承到组合：记忆注入的范式转变

旧范式下，新 Session **继承** 角色的记忆——要么全拿，要么全丢。HEEL 下，新 Fenshen **组合** 角色记忆的子集——根据当前任务、关注点和用户意图精确选择相关 Experience 项。记忆注入从粗粒度的继承模型转变为细粒度的组合模型。

5. 范式消解

5.1 消解命题 1：跨会话连续性

旧范式问题：Session 边界导致失忆。每个新 Session 以空白或手动搬运的上下文开始。

HEEL 消解：由公理 0，终身记忆库 \mathcal{M} 跨 Session 持久存在；由关注域函数 $f_{\text{concentration}}$ ，每次新分身（新会话视图）创建时，系统以 Character ID 为键查询 \mathcal{M} 中所有处于 Experience 层 ($\mathcal{I}=1$) 的记忆项，按复合评分排序后注入上下文。****因此，Session 的切换仅改变 $f_{\text{concentration}}$ 的实例化参数，不影响 \mathcal{M}**

的完整性与可访问性——跨会话连续性从需要手动维护的“问题”降格为系统自动保证的“属性”。**

5.2 消解命题 2：人格稳定性

旧范式问题：上下文压缩时将人格设定与交易流水账混排，系统被迫裁剪时无法区分保护优先级，导致“人格撕裂”。

HEEL 消解：由定理 1（四元分层定理），人格设定（如角色描述、行为约束）属于 Experience 层（ $\mathcal{I}=1$ ），而交易流水账属于 History 层（ $\mathcal{I}=0$ ）。上下文构建器（ $f_{\text{concentration}}$ 的实现）在组装时采用固定优先级：**System Prompt → 角色 Experience → 检索召回的相关 Experience → 近期 History → 当前用户消息**。压缩操作从右侧 History 开始，Experience 受此优先级保护。**因此，无论上下文窗口压力多大，定义人格的 Experience 项始终是最后被裁剪的对象——人格撕裂的架构前提已被移除。**

5.3 消解命题 3：上下文管理负担

旧范式问题：用户必须记住“在哪说过什么”，手动复制粘贴上下文以跨 Session 维持连续性。

HEEL 消解：由公理 0 和 $f_{\text{concentration}}$ ，连续性由系统自动维护。用户只需在创建新分身时指定**关注点**（如项目标签、任务类型）， $f_{\text{concentration}}$ 据此过滤 \mathcal{M} 中的 Experience 项。**因此，手动搬运上下文的需求消失——用户从“记忆管理员”的角色中解放出来，回归对话本身。**

6. 结论与后续工作

本文完成了一次从诊断到重建的范式转移：诊断会话中心本体论为病灶根源；确立公理 0-2，以可注入性 $\mathcal{I}(d)$ 为正交判据将数据从语义与 Session 的双重绑定中解放；由公理导出 HEEL 四元架构与身份三层解耦；论证旧范式下的工程难题在新公理体系下自然消解。

Session 中心主义的终结，不是因为找到了更好的工程方案，而是因为其公理前提被证明是错误的。 HEEL 不是又一套记忆系统，而是 Agent 记忆领域的一次公理重建。

后续工作：本文将 HEEL 的核心理论框架（公理 0-2、四元分层定理、身份三层解耦定理）先行公开，以确立学术优先权。扩展版本计划投稿至顶级会议（如 NeurIPS、ICML 或 ACL），届时将在本框架基础上新增：（1）完整的代谢闭环工程实例化，包括九维 MECE 数据模型、增量压缩与两级容量管控、摘要金字塔机制的具体实现；（2）

真实多会话场景下与 LangChain

(ConversationBufferMemory/SummaryMemory)、MemGPT 等基线的定量对比实验；(3) 基于用户反馈的复合评分公式权重自适应策略。

参考文献

- [1] Chase, H. (2022). LangChain: Building applications with LLMs through composability.
 - [2] Wang, J., et al. MemGPT: Towards LLMs as Operating Systems. [NeurIPS 2023 Workshop](#).
 - [3] Packer, C., et al. Letta: A Framework for Building Stateful LLM Applications. [arXiv:2410.05630](#), 2024.
 - [4] CrewAI (2024). CrewAI Documentation: Memory Systems.
 - [5] Li, G., et al. AutoGen: Enabling Next-Gen LLM Applications via Multi-Agent Conversation. [ACM CIKM 2023 Workshop](#).
 - [6] Liu, X., et al. Agents: An Open-Source Framework for Autonomous Language Agents. [arXiv:2309.07870](#), 2023.
 - [7] Tulving, E. [Elements of Episodic Memory](#). Oxford University Press, 1983.
 - [8] Conway, M. A. Sensory-perceptual episodic memory and its context: Autobiographical memory. [Philosophical Transactions of the Royal Society B](#), 356(1413): 1375–1384, 2001.
 - [9] Kuhn, T. S. [The Structure of Scientific Revolutions](#) (2nd ed.). University of Chicago Press, 1970.
-

附录 A：HEEL 核心术语表

术语	定义
History	原始对话流水账， $\mathcal{I}=0$ 。
Experience	已就绪可直接注入的数据单元， $\mathcal{I}=1$ 。
External	需检索或解析才能使用的外部数据源， $\mathcal{I}=0$ 。
Logic	管理前三层读写/演化/压缩的纯策略层。
Character	绑定 \mathcal{M} 的持久化人格标识。
Fenshen	角色在特定任务下的临时视图。
Yiniao	驱动推理的可插拔 LLM。
Injectability	数据能否无需额外处理直接放入上下文窗口的判据。

附录 B：形式化符号汇总

符号	含义
\mathcal{M}	终身记忆库（公理 0）
$\mathcal{I}(d) \in \{0, 1\}$	数据 d 的可注入性判据（公理 1）
$f_{\{\text{concentration}\}}$	关注域函数，从 \mathcal{M} 中选择记忆子集
Session_i	第 i 个会话容器
Character_j	第 j 个角色（记忆归属主体）

ArXiv 预印本，精简框架版。完整系统实现与实验评估将在后续扩展版本中发布。欢迎引用与讨论。