




第7届 AI+ Development Digital Summit AI+研发数字峰会

拥抱AI 重塑研发

8月8-9日 | 北京站





第8届AI+研发数字峰会

拥抱AI 重塑研发 AI+ Development Digital Summit

下一站预告

11/14-15 | 深圳站

12/19-20 | 上海站



查看会议详情

深圳站论坛设置

智能装备与机器人

超越“编程 Copilot”

下一代知识工程

智能网联与汽车智能化

AI 测试工具开发与应用

AI 基础设施和运维

数据智能及其行业应用

可信 AI 安全工程

大模型和 AI 应用评测

多 Agent 协同框架

从智能测试到自主测试

大模型推理优化

多模态 LLM 训练与应用

智能化 DevOps 流水线

上下文工程




| 8月8-9日 | 北京站

第7届 AI+ Development
Digital Summit

AI+研发数字峰会

拥抱AI 重塑研发



Meta-Agent架构与业务测试 落地实践

杨青霖 | 百度



杨青霖

百度资深测试开发工程师

主要负责语音终端和视觉算法的质量保证体系建设及工程效能提升。拥有将Python应用于复杂技术领域的丰富实战经验。著有《Python气象应用编程》，人民邮电出版社异步社区2023年度影响力作者。

现在负责语音业务测试工具研发，带领团队探索AI在测试领域的应用。每天与各种语音测试场景打交道。

目录

CONTENTS

- I. 背景与演进方向
- II. 构建非阻塞核心
- III. 工程实践与落地
- IV. 总结与展望



孟祥银

[SpeechSolution-30180] 【雨燕】 识别解码器-支持通过flush次数控制长音频计算频次-提测



iCafe卡片

【雨燕】 识别解码器-支持通过flush次数控...

类型: Story

状态: 待测试



负责人: 杨娟娟, 迪力亚尔·帕尔哈提



所属计划: 未计划

你是卡片的负责人、QA负责人、创建人、最后...

如流工作卡



孟祥银

提测了

迪力亚尔·帕尔哈提




引用 孟祥银:

<https://console.cloud.baidu-int.com/devops/icafe/issue/SpeechSolution-30180/show>

@阿童木 机器人 准入



输入消息



PART 01

背景与演进方向

▶ 智能体的现状与困境

语音测试

提测

准入


准入

功能测试

声学测试

稳定性测试

理想的AI测试助手
应该是什么样的？



▶ 尴尬的等待




执行一下稳定性测试

好的，正在执行中。




执行中...



我们满怀期望地引入Agent，却发现...
当它处理一个耗时任务时，整个对话就被阻塞了。




你还在吗？




三种范式演进

工具箱模式




体验割裂，上下文不互通
像一堆独立的计算器

流水线模式



强大但僵化，用户必须等待响应
像一条流水线

项目经理模式



从“串行指令”到“并行委托”
像一个项目经理



► 项目经理模式


以企业IM入口为例

企业IM的特点（机器人、服务号）

- 单线程：同一个消息发送对象，通常只能开一个对话窗口；
- 无明显消息边界：消息之间难以找到明确的对话分界线。

需要解决的问题

- 在单线程对话下执行多个任务；
- 长耗时任务且不阻塞对话流；
- 主动通知任务结果；
- 符合用户直觉的连续消息流。



PART 02

构建非阻塞核心

单线程对话下执行多个任务，且长耗时任务不阻塞对话流

- 用户的任何消息应该尽快响应；
- 长耗时任务应该返回一个handler，而不是等待完成；
- 允许用户动态变更执行流程；
- 能从大量工具中选取需要的工具并规划流程；

异步操作

ReAct 调度器

主动通知任务结果，且消息流符合用户直觉

- 长耗时任务完成后，应该能触发下一步操作；
- agent应该知晓以自己身份所发出的任何一条消息；
- 在无边界的对话流中，没有明显的上下文中断感；

工具粗选策略

事件驱动



IM回调

API

统一适配不同入口消息



调度器

异步、事件驱动的ReAct调度器



分层记忆系统



工具粗选策略


上下文系统与工具粗选

数据库

外部工具API

其他基础设施


运行支持





调度器

ReAct 架构



▶ 记忆并非越多越好



上下文窗口有限

LLM有固定的Token上下文长度，Agent不能无限提供所有记忆，否则会超出限制导致截断或拒答。

噪音与干扰

不相关或陈旧的信息会成为噪音，降低LLM判断的准确性。不加筛选地提供大量上下文，反而可能误导AI。

成本与效率

更长的上下文意味着更多的调用成本和时间延迟。每次对话塞入大段历史会显著增加API费用，并拖慢响应。



▶ 三层记忆体系

包括用户提问、助手回答、工具调用结果和系统提示等。超限就触发流转算法把最早部分摘要后移入中期记忆。

被动式记忆

短期记忆

- 对话内容
- 工具调用结果

摘要提取

存入RAG数据库

中期记忆


- 近期对话摘要
- RAG召回

中期记忆遗忘策略

模拟记忆曲线模拟：

- 越新的记忆权重越高
- 常想起的回忆会更牢
- 太久以前的记忆会遗忘

主动式记忆



主动更新

长期记忆


- 用户偏好
- 用户画像

为什么要设计遗忘策略？

只有进没有出的记忆可能是个灾难。



可供调用的工具




全量作为LLM的调用参数?

- 任务准确率降低
- 上下文截断
- 成本失控

选取子集, 怎么选?

- 按照集合让用户手动开启关闭?
- 根据用户消息RAG?



工具粗选的策略 – 槽位机制

前面提到，每一次事件发生，都会引发一次工具粗选。

最终传递给大模型的工具列表




假设选取10工具传递给LLM

三个部分进行集合合并，如果已选工具数量小于总槽位大小，则以AI推荐的更多结果进行填充

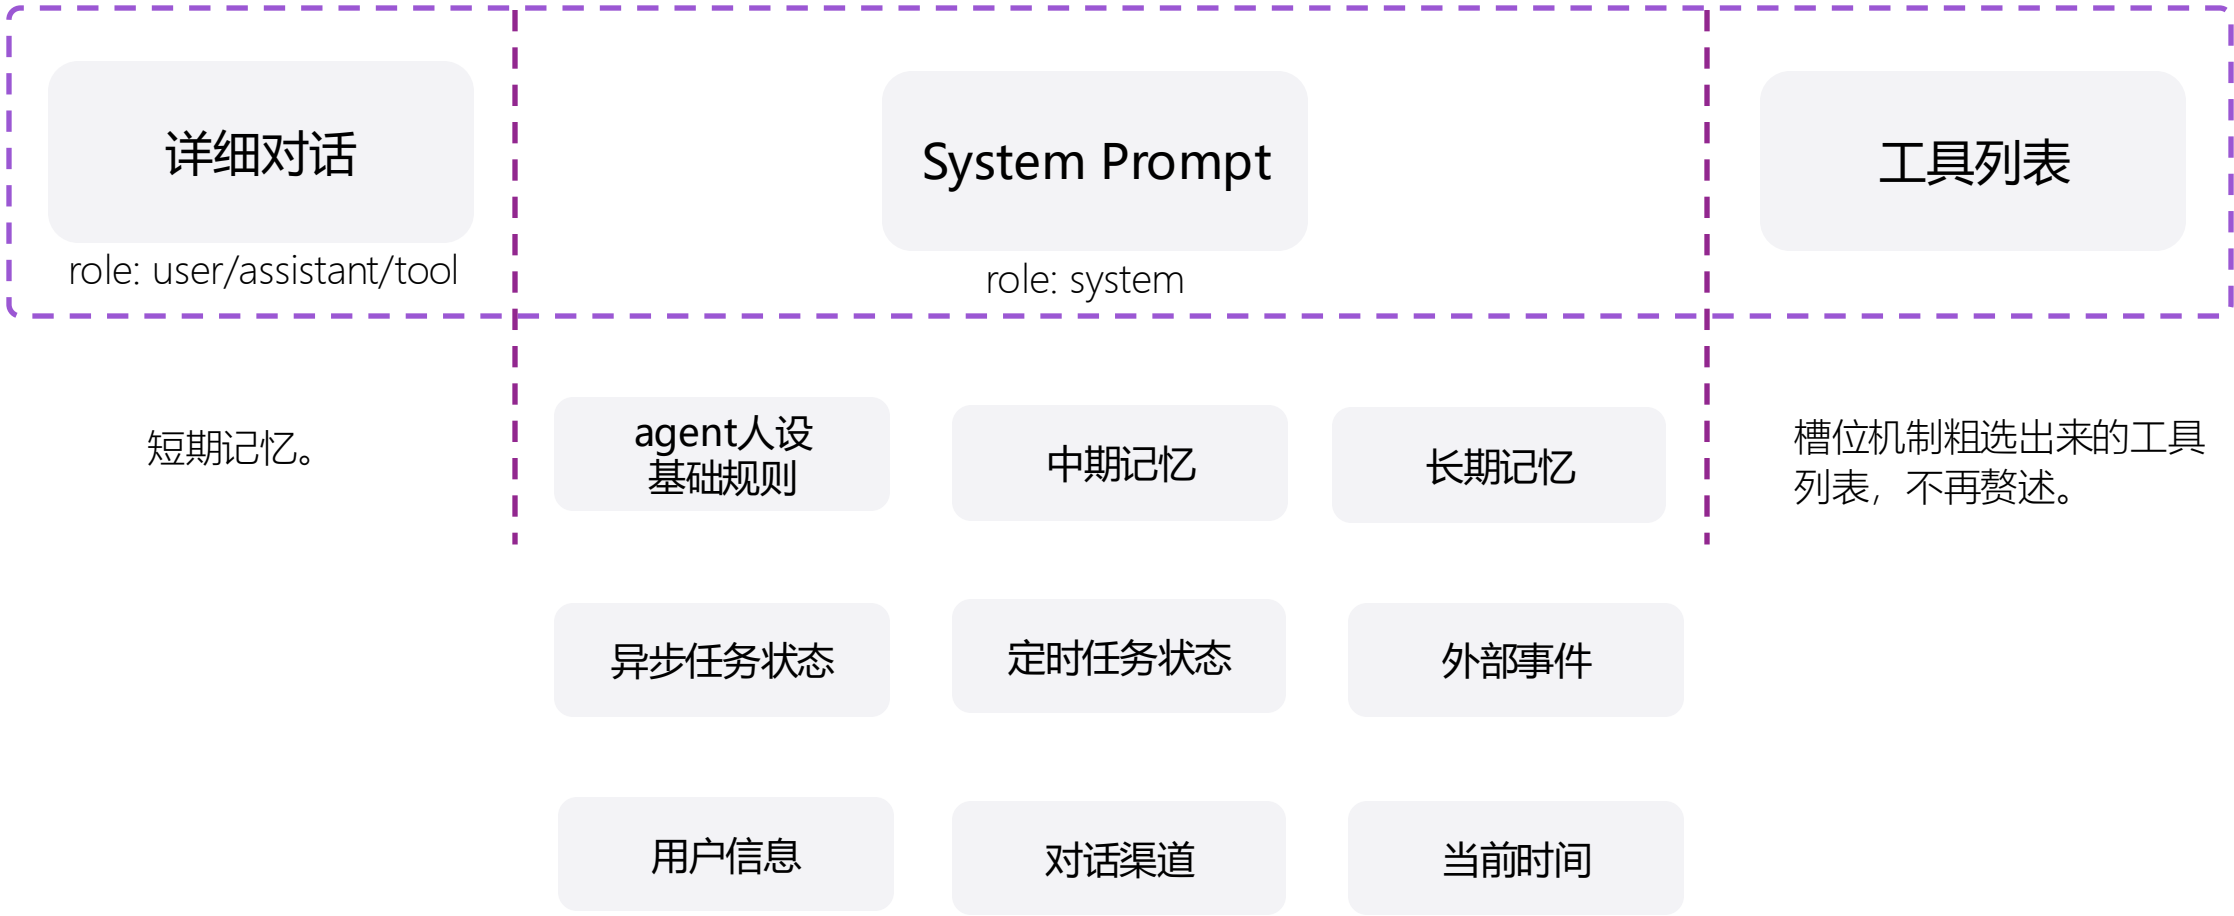


基于话题的推荐机制





请求 LLM 的Payload



轻量声明式的工具接入

我们发现，在能明确Agent应用范围的小团队中，共享代码库的声明式配置更为高效，几分钟就能为Agent增加一项新技能。

```
@pydantic.validate_call
async def my_custom_function(
    param1: typing.Annotated[str, pydantic.Field(description='参数描述')]
) -> str:
    """自定义工具函数"""
    # 实现你的业务逻辑
    return f"处理结果: {param1}"
```

```
async def init(atom_service: aeo.service.atom.AtomService, app: fastapi.FastAPI):
    """工具初始化"""
    atom_service.agent.add_tool_function(
        my_custom_function,
        aeo.helper.atom.types.FuncConfig(
            owner='your-name',
            tags=['custom'], # 权限标签
            require_confirm='Optional' # 可选: Required, Optional, Never
        )
    )
```

工具声明

- 运行时类型校验;
- 明确参数类型;
- 无重复定义;

工具注册

- 配置负责人，以便出错时提示用户;
- 支持高风险工具运行前确认



怎样写一个工具的描述？

- 表达简洁通顺；
- 句式可以是 “输入什么，在什么平台做了什么，输出什么” ；
- 可以举一个例子（one-shot），让LLM明白能做什么；
- 说明可能出现的异常情况，并给出解决建议；

小技巧

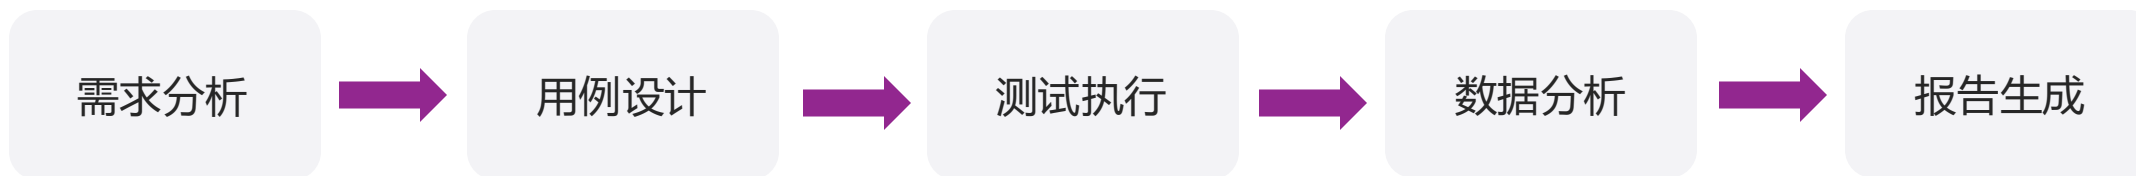
把工具描述给不同业务的同学看，如果他能明白这个工具在做什么，什么时候需要用，那这就是一个优秀的工具描述。



PART 03

业务落地

▶▶ 传统测试流程 & 痛点



耗时费力

很多步骤纯人工完成，一个完整测试周期大量时间花在重复数据处理和结果汇整上。

易错缺乏一致性


人工设计用例和检查结果容易遗漏场景或计算出错，不同测试人员输出的质量参差不齐。

流程碎片化

各环节缺乏统一平台串联。需求-测试-交付流程割裂，难以量化覆盖度。

协作成本高

对接耗时。反馈周期长，问题定位延迟。测试报告以邮件形式分发，不易追溯管理。



▶ 如何重塑测试流程

服务端：

- 服务端功能测试
- 服务端算法测试
- 编写测试报告

测试过程：

- 故障排查
- BUG创建
- BUG验证/关闭

终端：

- SDK功能测试
- SDK算法测试
- 编写测试报告

CI/CD平台控制：

- 执行流水线
- 停止流水线
- 重新运行

测试生命周期：

- 提测
- 准入
- 准出






数据管理：

- 数据质检
- 数据预处理
- 数据管理

ALL IN ONE



效率提升



▶ 什么是meta-agent

“Meta” 这个词根源于希腊语，意思是“之后”或“超越” (beyond)。

熟悉的例子：

- Metadata (元数据)：它不是数据本身，而是关于数据的数据。服务端算法测试
- Metacognition (元认知)：它不是指思考具体问题，而是指对思考的思考。

一个普通的 Agent，它的关注点是任务。你让它写代码，它就去写代码；你让它查资料，它就去查资料。它是一个执行者。

Meta-Agent 正是普通 Agent 的一个“Meta”层。它的关注点是流程和 Agent 本身，是一个负责协调、监督和管理其他 Agent 的“元”级智能体。



PART 04

总结与展望

1

范式转变

从“阻塞式工具”思维转向“异步协作伙伴”思维，是构建高级Agent的关键。

2


架构核心


“事件驱动”是实现异步协作的技术基石。

3

落地为王

轻量、务实的工程实践（如声明式工具接入）比追求通用架构更重要。





▶ 通向更自主的AI协作体



我们的旅程才刚刚开始。

预测性调度

自适应优化

插件自动发现

.....





第8届AI+研发数字峰会

拥抱AI 重塑研发 AI+ Development Digital Summit

下一站预告

11/14-15 | 深圳站

12/19-20 | 上海站



查看会议详情

深圳站论坛设置

智能装备与机器人

超越“编程 Copilot”

下一代知识工程

智能网联与汽车智能化

AI 测试工具开发与应用

AI 基础设施和运维

数据智能及其行业应用

可信 AI 安全工程

大模型和 AI 应用评测

多 Agent 协同框架

从智能测试到自主测试

大模型推理优化

多模态 LLM 训练与应用

智能化 DevOps 流水线

上下文工程

AiDD

「深行 · 浅智」

Walk Deep, Think Light.

2025.11.16

AiDD首届麦理浩径徒步





科技生态圈峰会 + 深度研习

——1000+ 技术团队的选择



AiDD峰会详情





第7届AI+研发数字峰会
AI+ Development Digital Summit

感谢聆听!

扫码领取会议PPT资料

