AiDD 6th 2025

# 2025 AI+ Development Digital Summit

# AI+研发数字峰会

## 拥抱AI 重塑研发

05/23-24 | 上海站

AiDD 7th 2025

# 2025 AI+研发数字峰会

## 拥抱AI 重塑研发

AI+ Development Digital Summit

查看会议详情

**下一站预告** 08/08-09 | 北京站 11/14-15 | 深圳站

**北京站论坛设置**

- AI+ 金融业务创新
- 具身智能与机器人
- 大模型安全与对齐
- 智能需求工程
- 大模型和 AI 应用评测
- 代码生成及其改进
- 大模型应用开发框架与实践
- 智能存储与检索技术
- 智能体与研发效率工具
- AI+ 新能源汽车
- 智能体经济（Agentic Economy）
- 下一代知识工程
- AI 产品运营与出海策略
- 智能测试工具的开发与应用
- AI 前沿技术探索与实践

AiDD 6th 2025 | 05/23-24 | 上海站

2025 AI+ Development Digital Summit

AI+研发数字峰会

拥抱AI 重塑研发

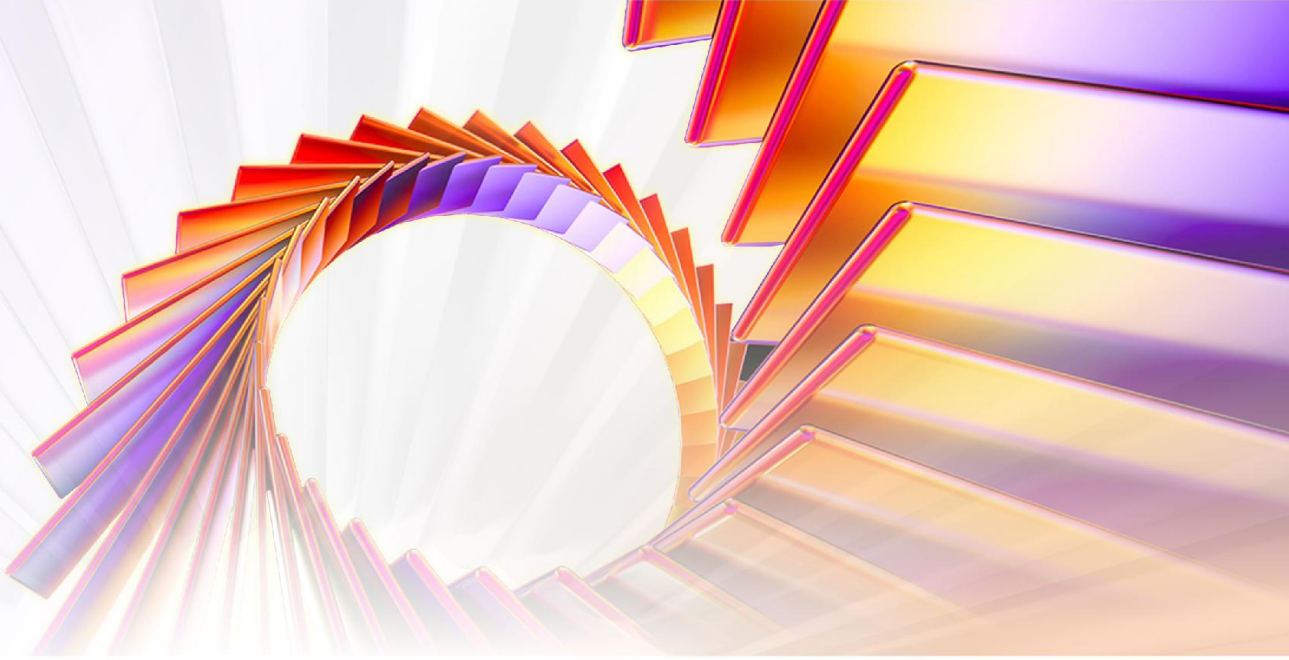

# 多模态、多端手机智能体 Mobile-Agent

徐海洋 |阿里巴巴通义实验室

# 徐海洋

## 阿里巴巴通义实验室 高级算法专家

阿里通义实验室高级算法专家，负责通义多模态大模型mPLUG、Mobile-Agent系列工作，包括基础多模态模型mPLUG/mPLUG-2，多模态对话大模型mPLUG-Owl/Owl2，多模态文档大模型mPLUG-DocOwl，多模态智能体Mobile-Agent、PC-Agent等，其中 mPLUG 工作在 VQA 榜单首超人类的成绩，Mobile-Agent工作CCL2024 Best Demo，获得多个多模态榜单第一和Best Paper。在国际顶级期刊和会议ICML/NeurIPS/ICLR/CVPR/ICCV/ACL/EMNLP等发表论文50多篇，并担任多个顶级和会议AC/PC/Reviewer。主导参与开源项目mPLUG，Mobile-Agent，AliceMind，DELTA。

# 目 录

CONTENTS

# PART 01

# 大模型智能体背景

# 大模型智能体是人工智能应用的未来


“如果一篇论文提出了某种不同的训练方法，我们内部的Slack上会嗤之以鼻，认为都是我们玩剩下的。但是当新的AI Agents论文出来的时候，我们会认真兴奋的讨论”

– Andrej Karpathy


“AI Agent不仅会改变每个人与计算机交互方式。它还将颠覆软件行业，带来自我们从键入命令到点击图标以来最大的计算变革” – 比尔盖茨

# 大模型智能体的优势


OpenAI Five


DeepMind AlphaStar

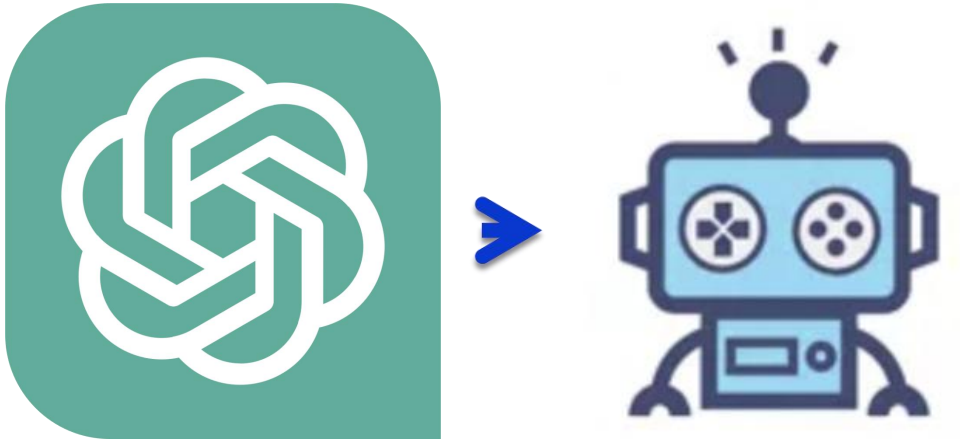

LLM Agent with ChatGPT

## 传统基于RL的智能体的局限性

- 数据采样专有环境和低效
- 面向特定任务
- 稀疏奖励和长时段问题

## 大模型智能体的优势

- 丰富的世界知识
- 推理/规划能力
- 工具使用（检索、code等）
- In-context Learning

# 大模型智能体系统

在人工智能领域，AI智能体指可以观察周遭 环境 并作出 行动 以达致 目标 的 自主 实体

## Agent System Overview from Lilian Weng's blog

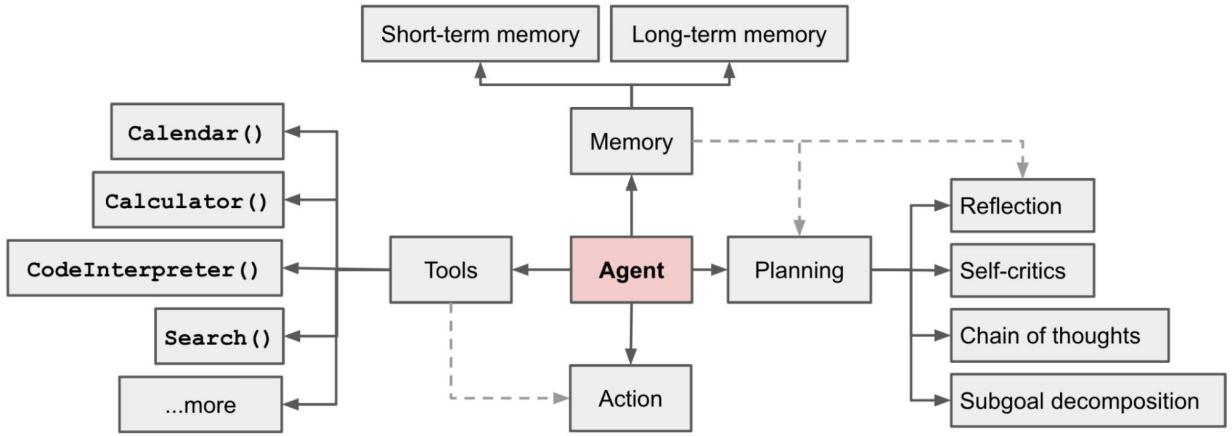


## Wang et al. A Survey on Large Language Model based Autonomous Agents

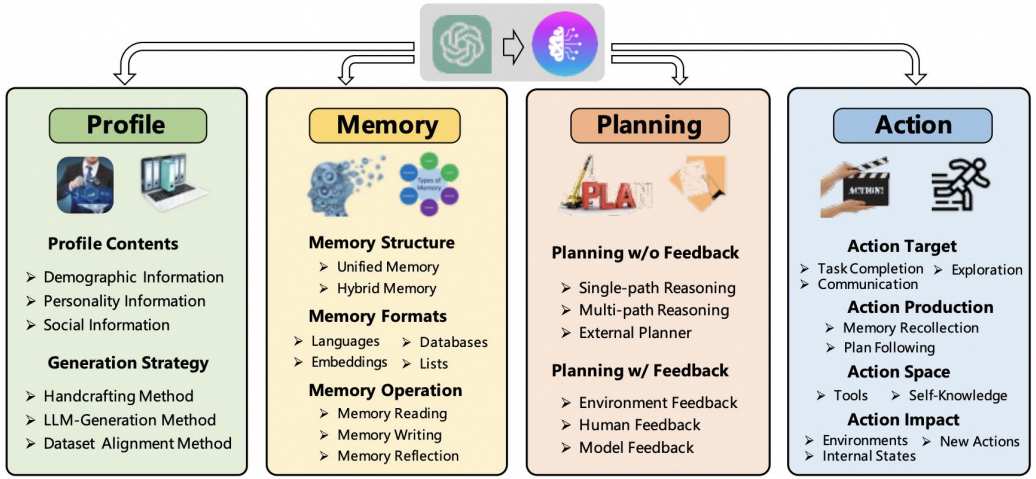

# 大模型智能体发展迅速

大模型广泛使用后，各类大模型
智能体模型、框架、应用呈现井喷趋势

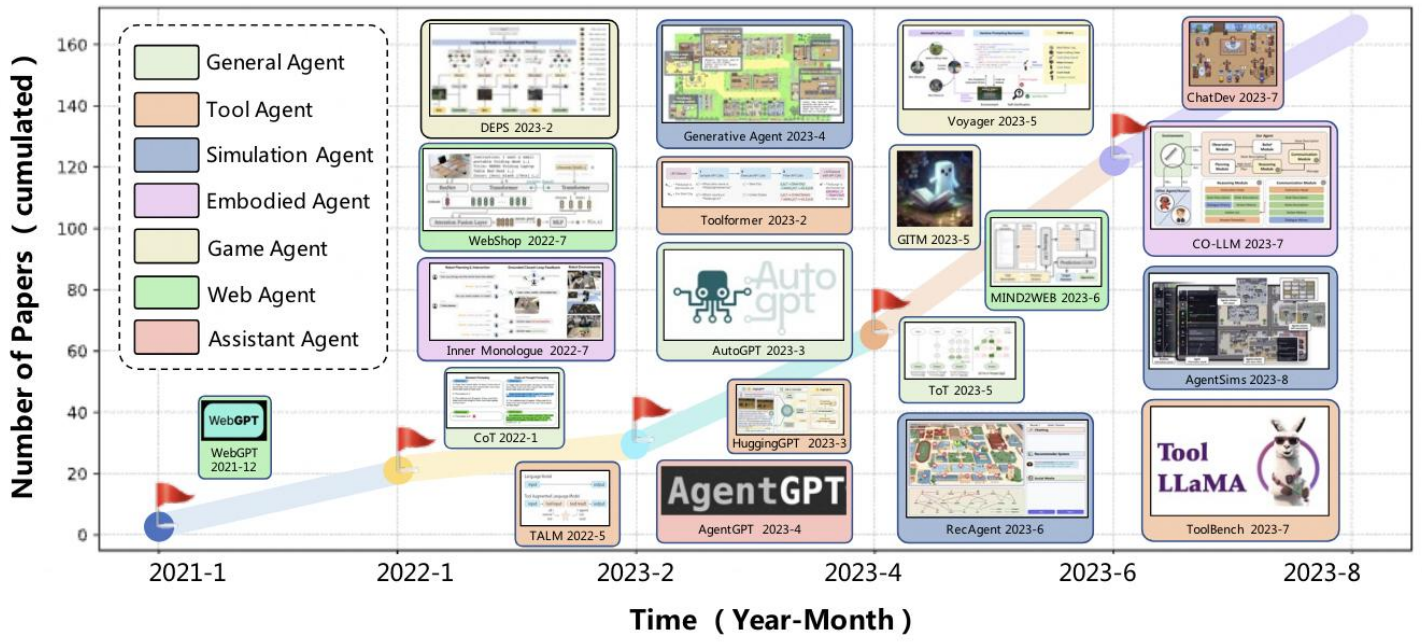


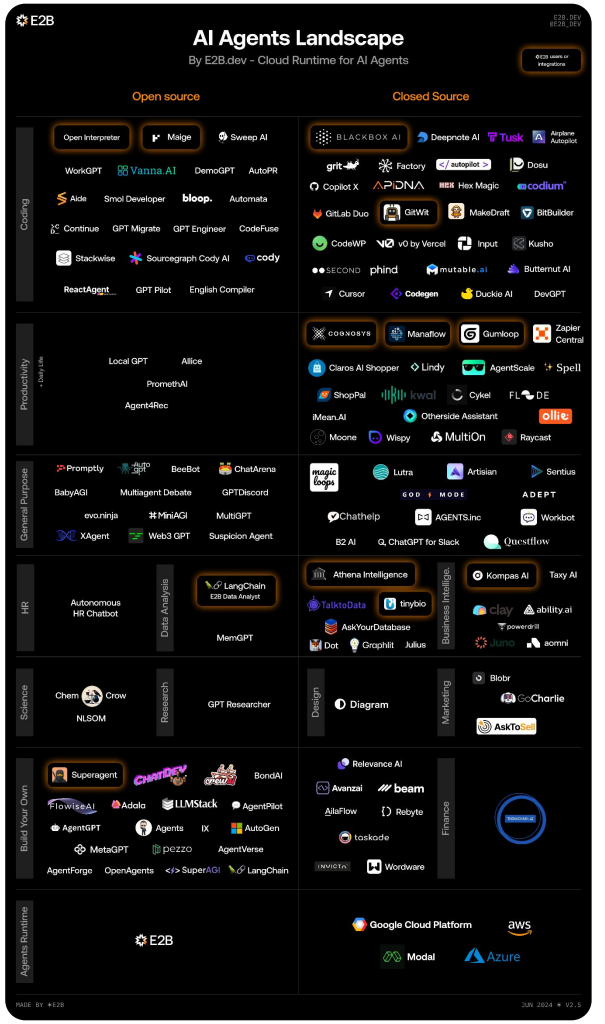

# 多模态大模型智能体

现实世界是需要 **多模态环境交互** 的，多模态智能体可能衍生出更多Super、Fancy应用

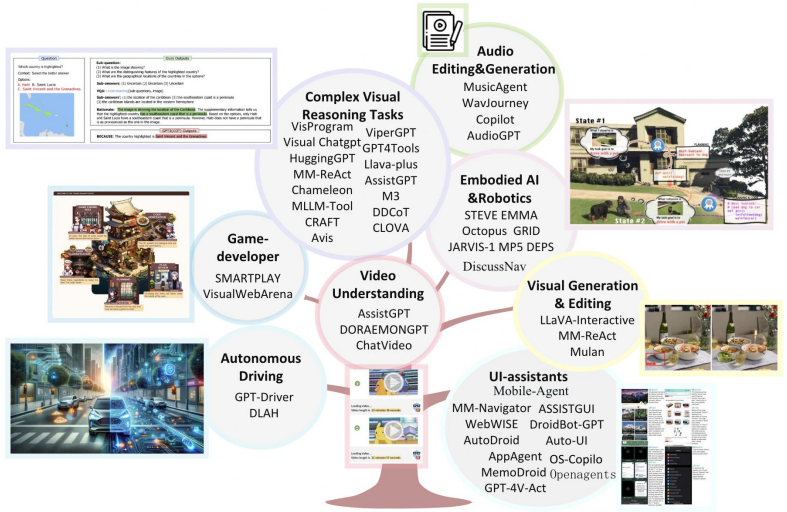


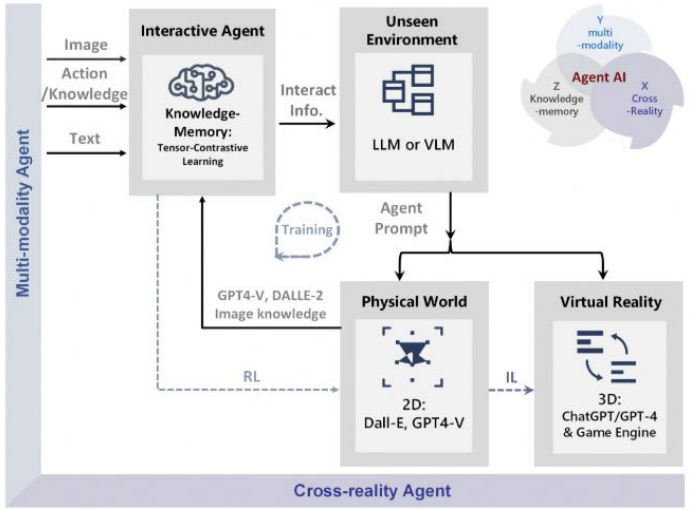


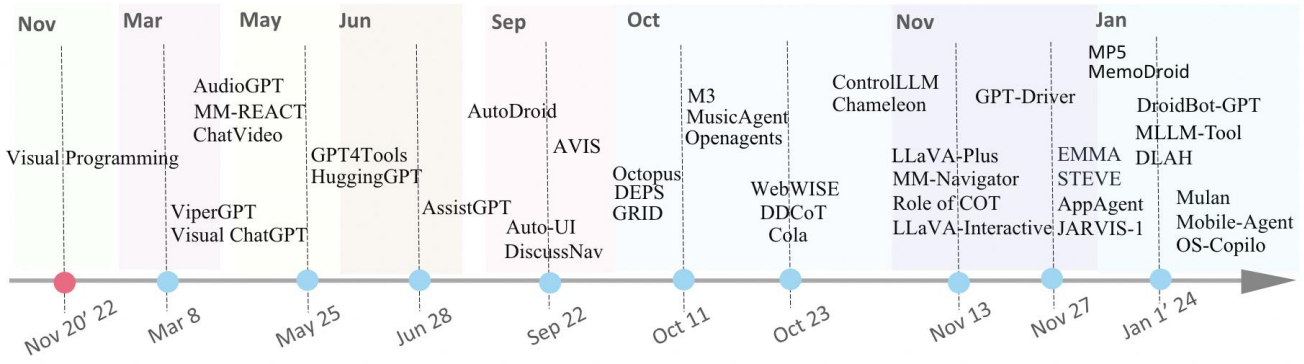

# 多模态大模型智能体

现实世界是需要 **多模态环境交互** 的，多模态智能体可能衍生出更多Super、Fancy应用

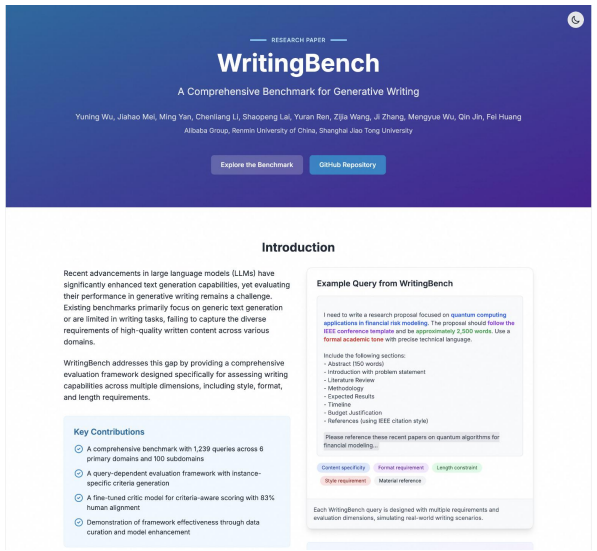


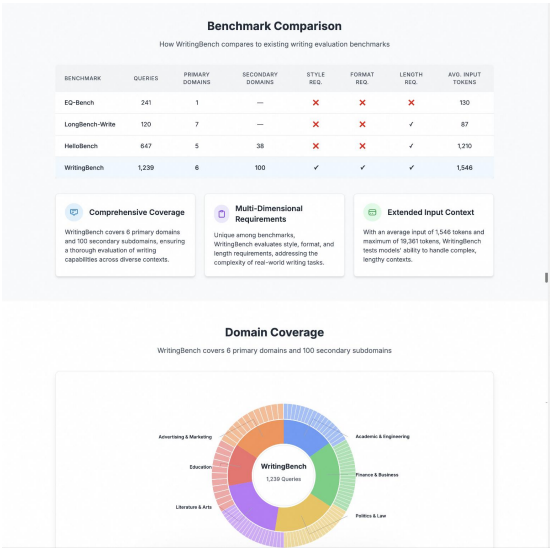


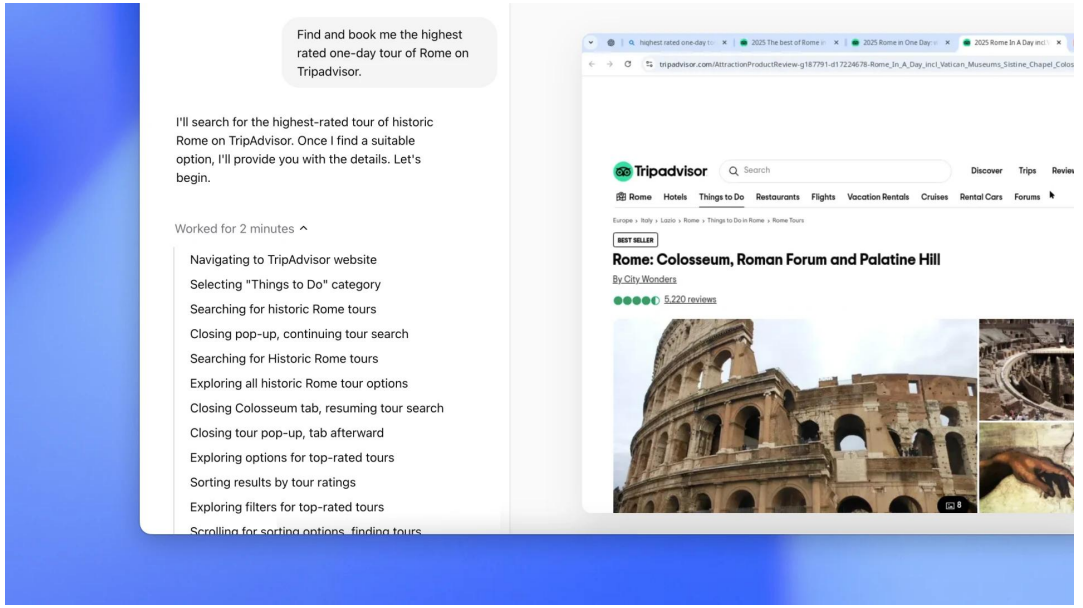


## Claude 3.7 sonnet (computer use)

参照人类思考系统的快速反应与慢反思结合的工作模式，将LLM快速响应和思维链深度思考

https://mp.weixin.qq.com/s/JVxbbkR587_Mxpu02k29Kw

## Operator

基于Computer–Using Agent 模型，结合GPT-4o的视觉理解能力和强化学习习得的推理能力，自动执行鼠标和键盘的组合操作，无需API，具备推理思维链和自动纠错能力

# 大模型通用型智能体系统

搜索索引能力 +生成式 AI 技术

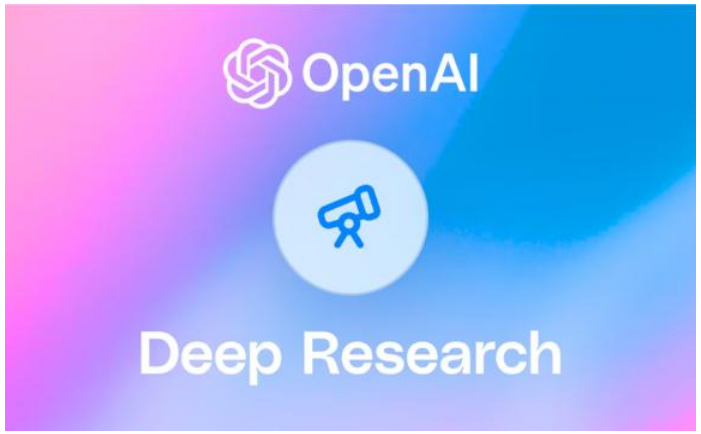


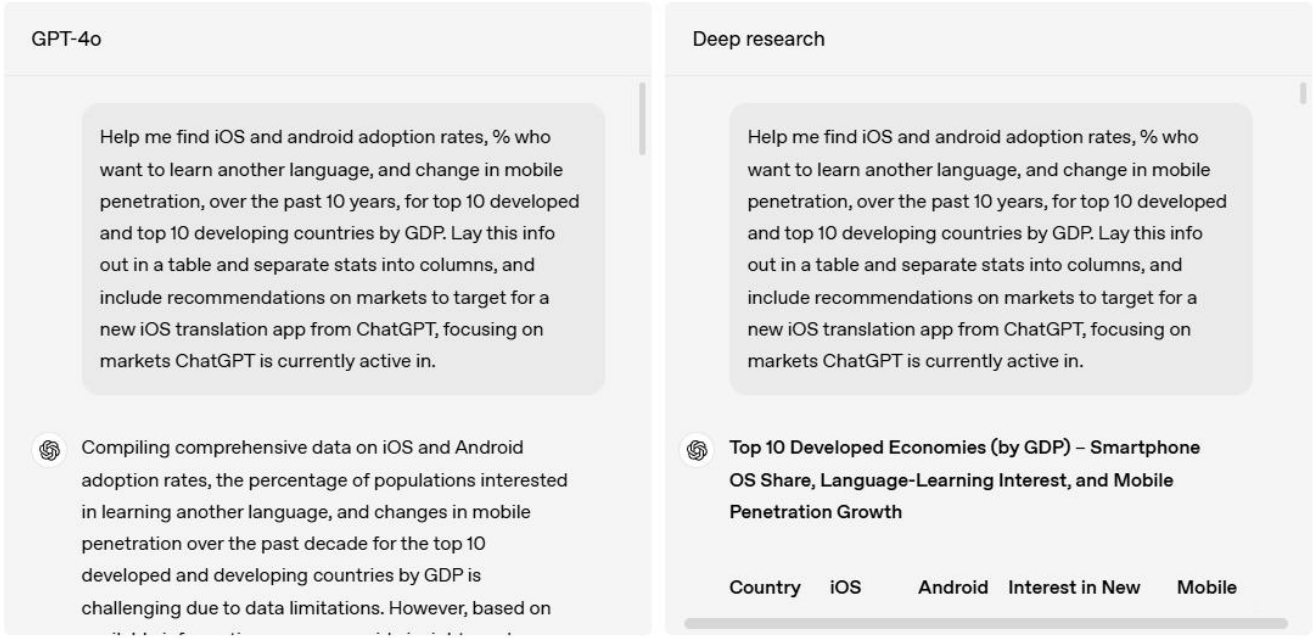


## DeepResearch

整合Google 的搜索索引能力和 OpenAI 的生成式 AI 技术，实现从简单查询到复杂推理的跨越，优化多模态搜索（如文本、图像、视频的综合检索）和实时知识更新能力，持续进行多次搜索-分析-优化的循环，完成专业级报告生成

# 大模型通用型智能体系统

从基于检索提供信息，到Agent执行任务的本质进阶

**（1）规划-执行Tool-反思；（2）操作上云；（3）快操作 + 慢思考**

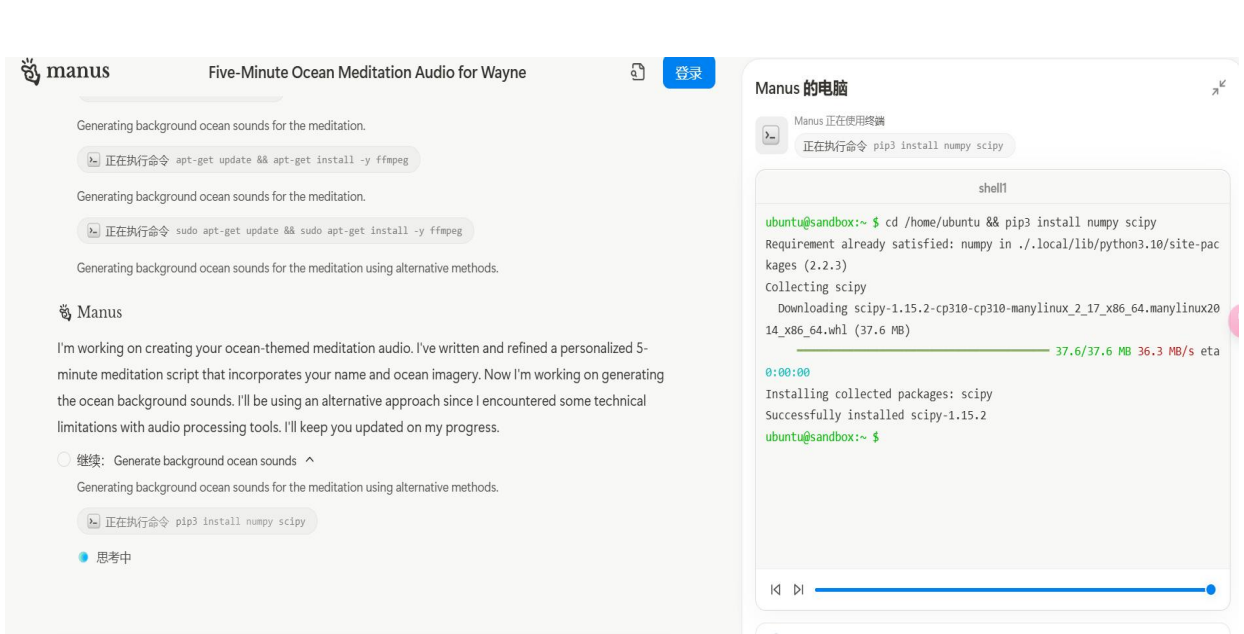


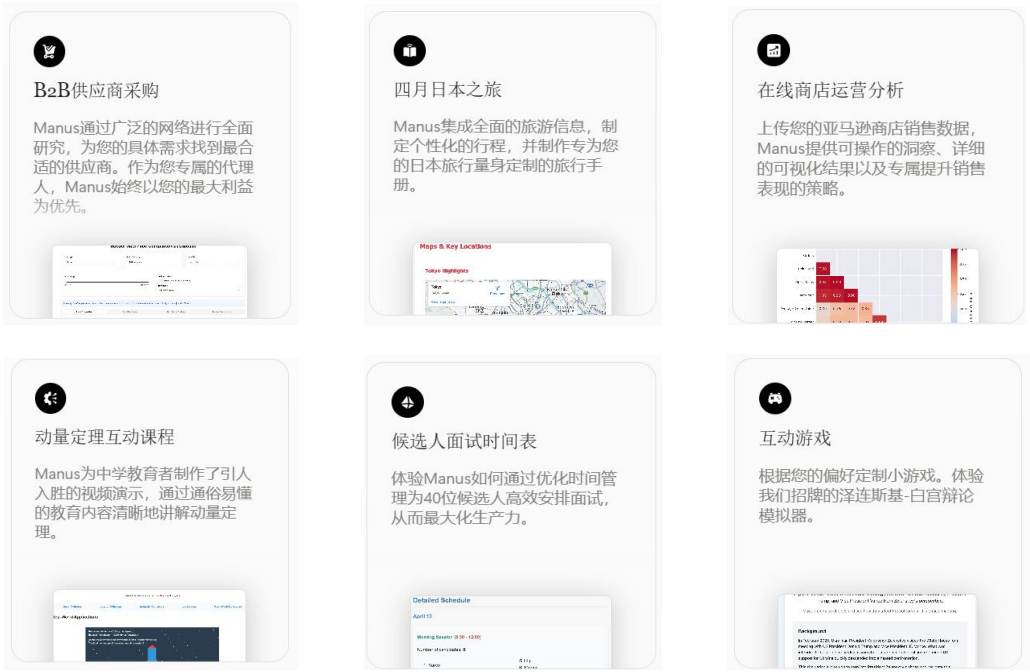


## Manus/Open Manus

Manus强调“需求→规划→执行→交付”全流程自动化，无需用户持续指导便可能直接生成可交付成果，动态调整执行路径，在解决现实世界问题方面表现卓越

AiDD 6th 2025

PART 02

# 多模态手机智能体Mobile-Agent

# 多模态手机智能体Mobile-Agent

## 一句指令实现自动操作手机

1. 纯视觉方案，不依赖系统数据
2. 可以多个应用之间操作
3. 感知、规划、反思三者结合
4. 无需训练、即插即用

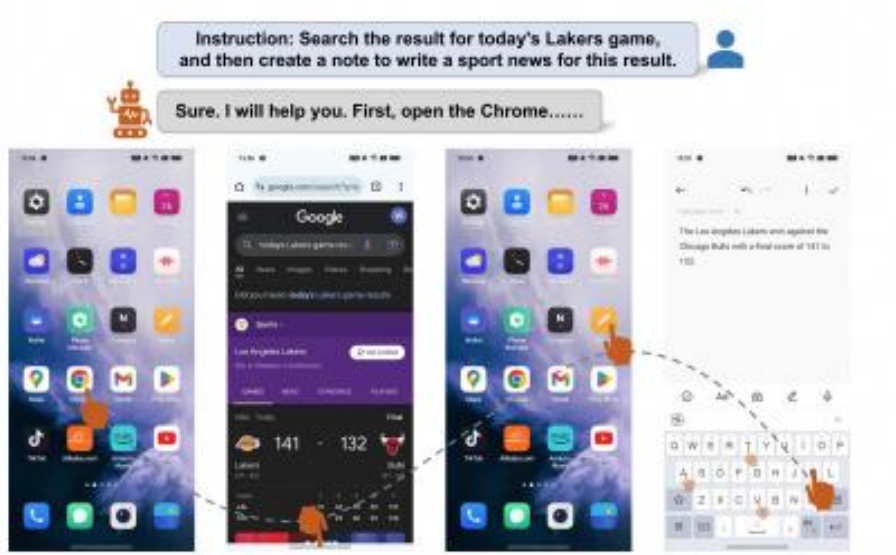


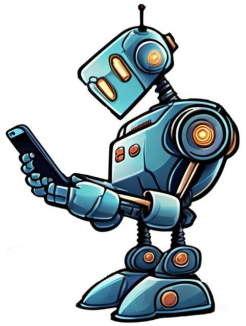

Mobile-Agent

Mobile-Agent: The Powerful Mobile Device Operation Assistant Family

https://github.com/X-PLUG/MobileAgent


CCL2024 唯一Best Demo

# 多模态智能体Mobile-Agent

# 多模态智能体Mobile-Agent

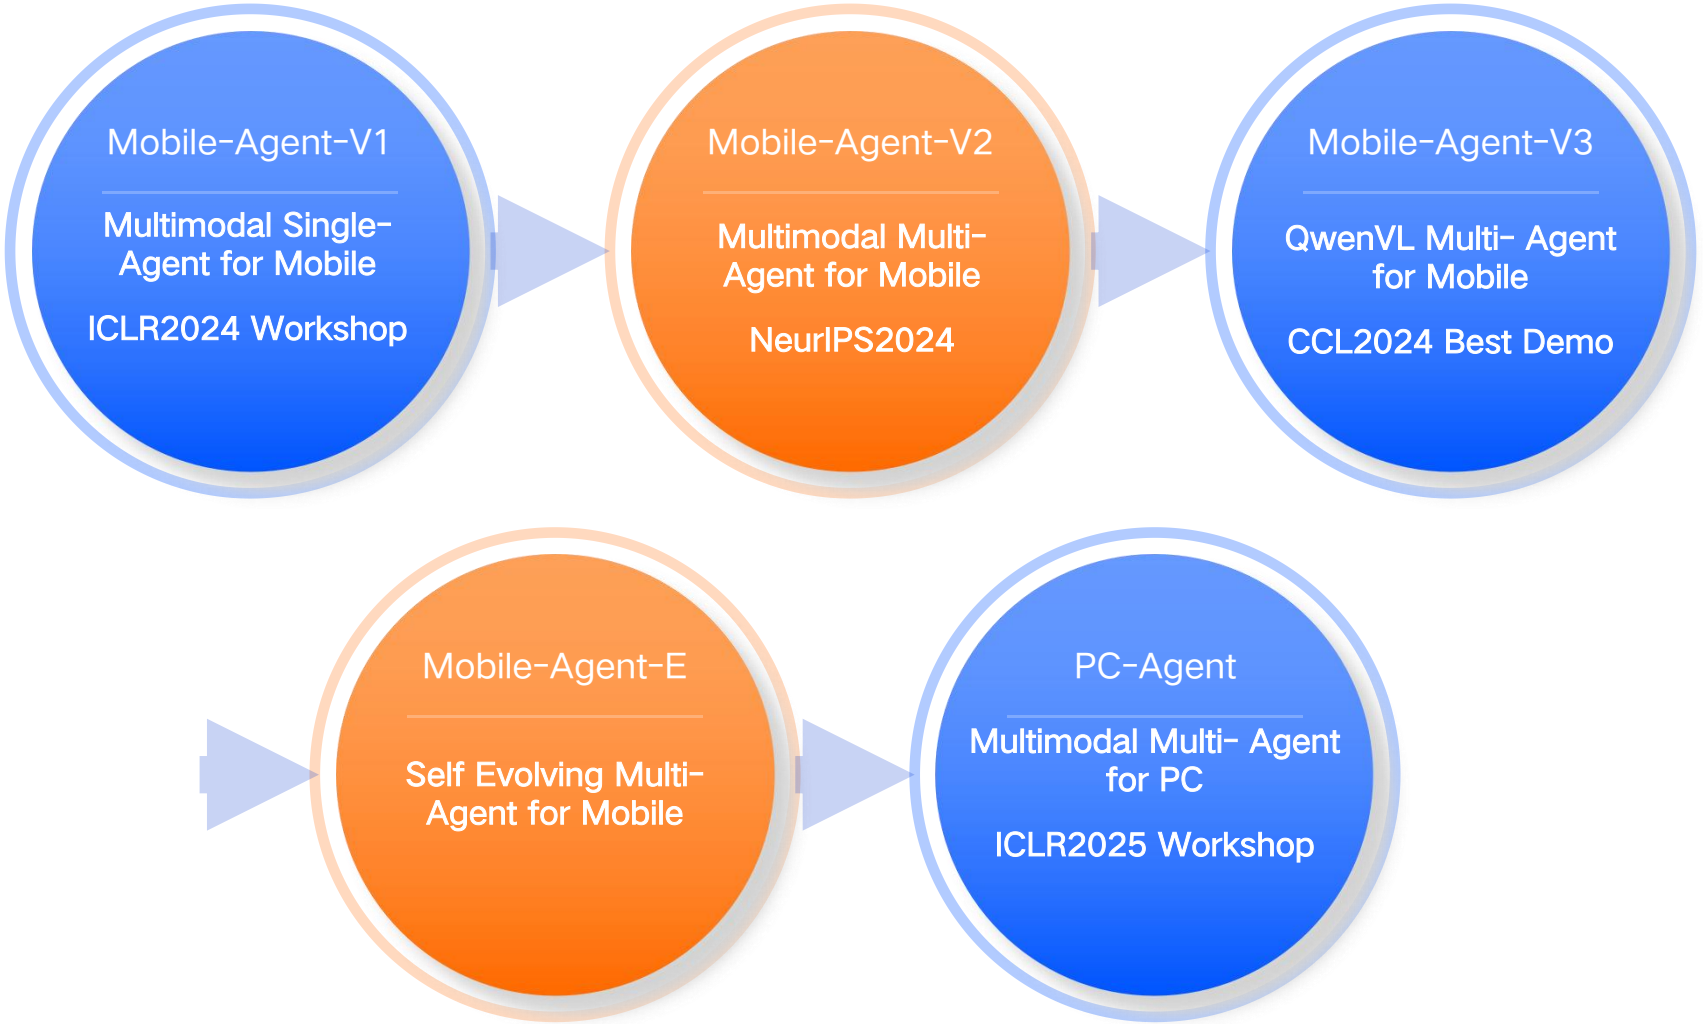

# 多模态手机智能体Mobile-Agent-V1

## 分析天气

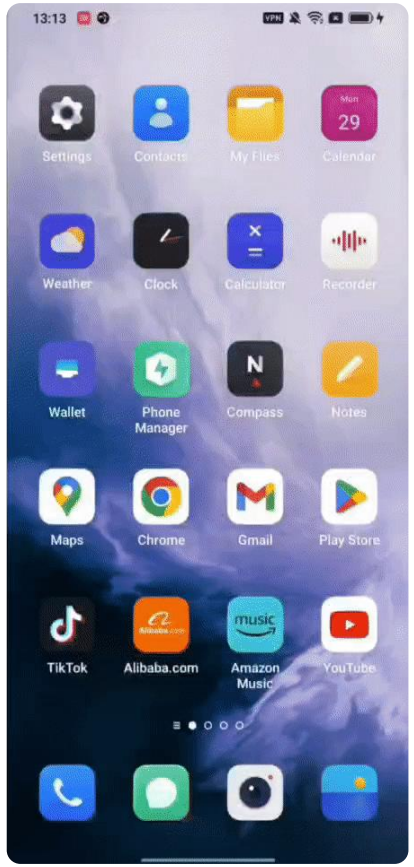


## 搜索视频并评论

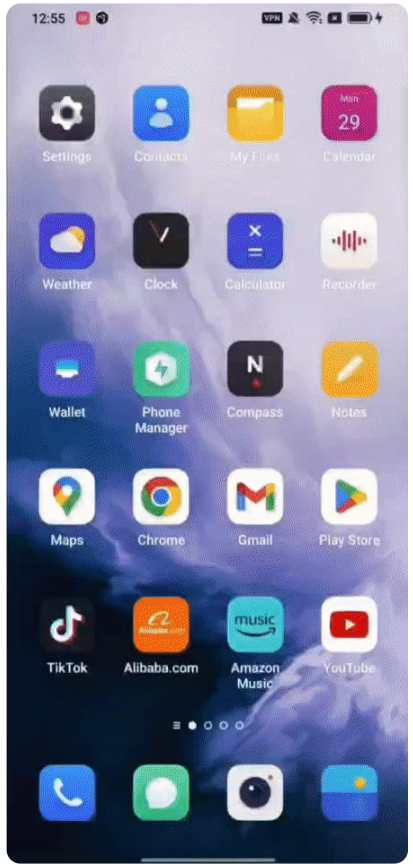


## 刷短视频并点赞

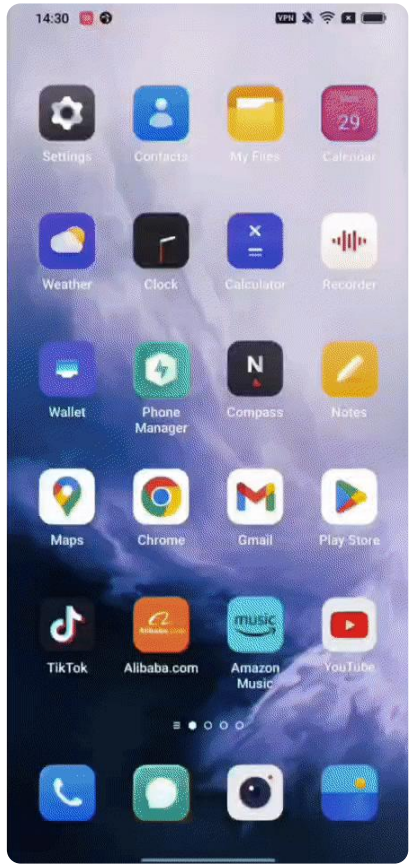


## 导航

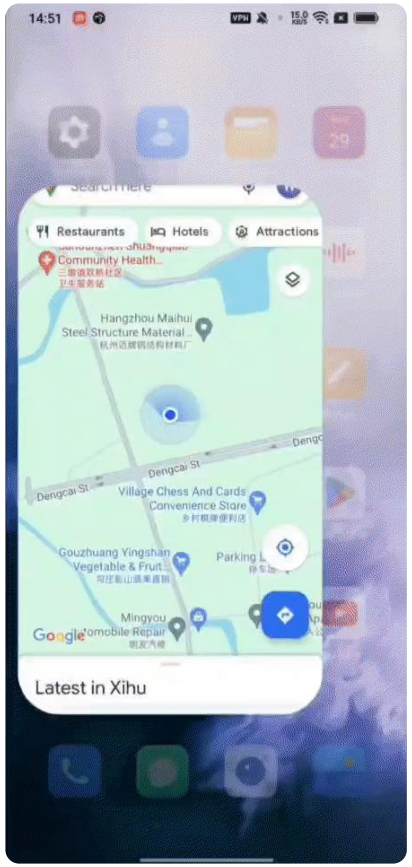

# 多模态手机智能体Mobile-Agent-V1

**Instruction: [Rules and operations of the game]. Help me play this game.**

click text (5)


click text (出牌)


click text (出牌)


click text (7)

# 多模态手机智能体Mobile-Agent-V1

历史操作 & 截屏


用户指令

搜索今天湖人队的比赛结果，然后在笔记中写一个战况分析

当前屏幕


观察：描述当前页面的情况

思考：下一步的操作思路

行动：使用工具完成思考中的操作


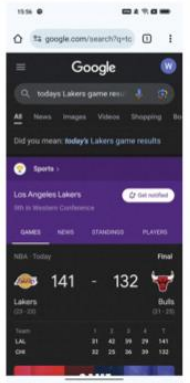

# 多模态手机智能体Mobile-Agent-V1

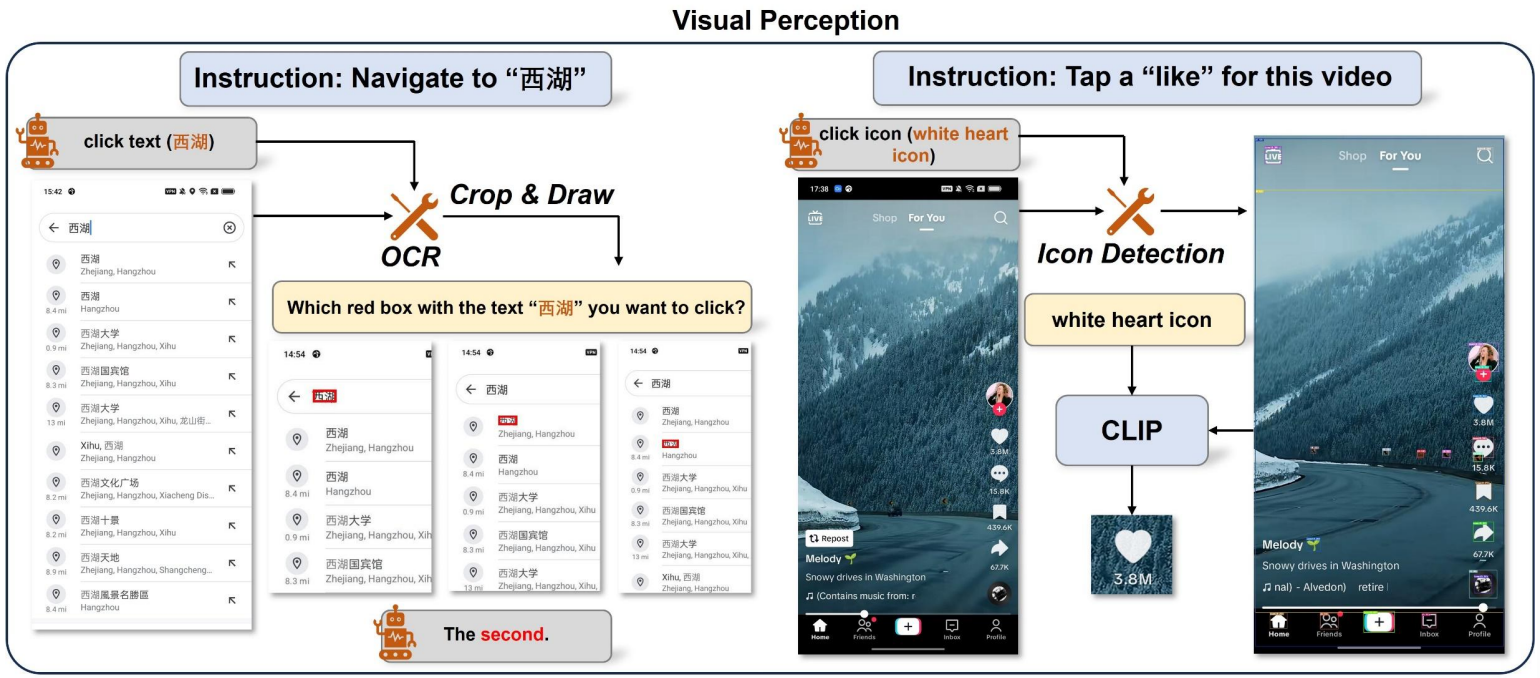


## 大模型缺乏输出精确坐标的grounding能力

- 屏幕文本定位：使用OCR工具检测识别文本框
- 图标定位：使用图标分割检测工具检测所有图标和位置

## 行为空间

1. 点击文本
2. 点击图标
3. 打字
4. 上划 & 下划
5. 返回上一页面
6. 返回桌面
7. 结束

# 多模态手机智能体Mobile-Agent-V2

冗长并且图文交错格式的操作历史，会大大增加智能体追踪任务进度的难度

# 多模态手机智能体Mobile-Agent-V2

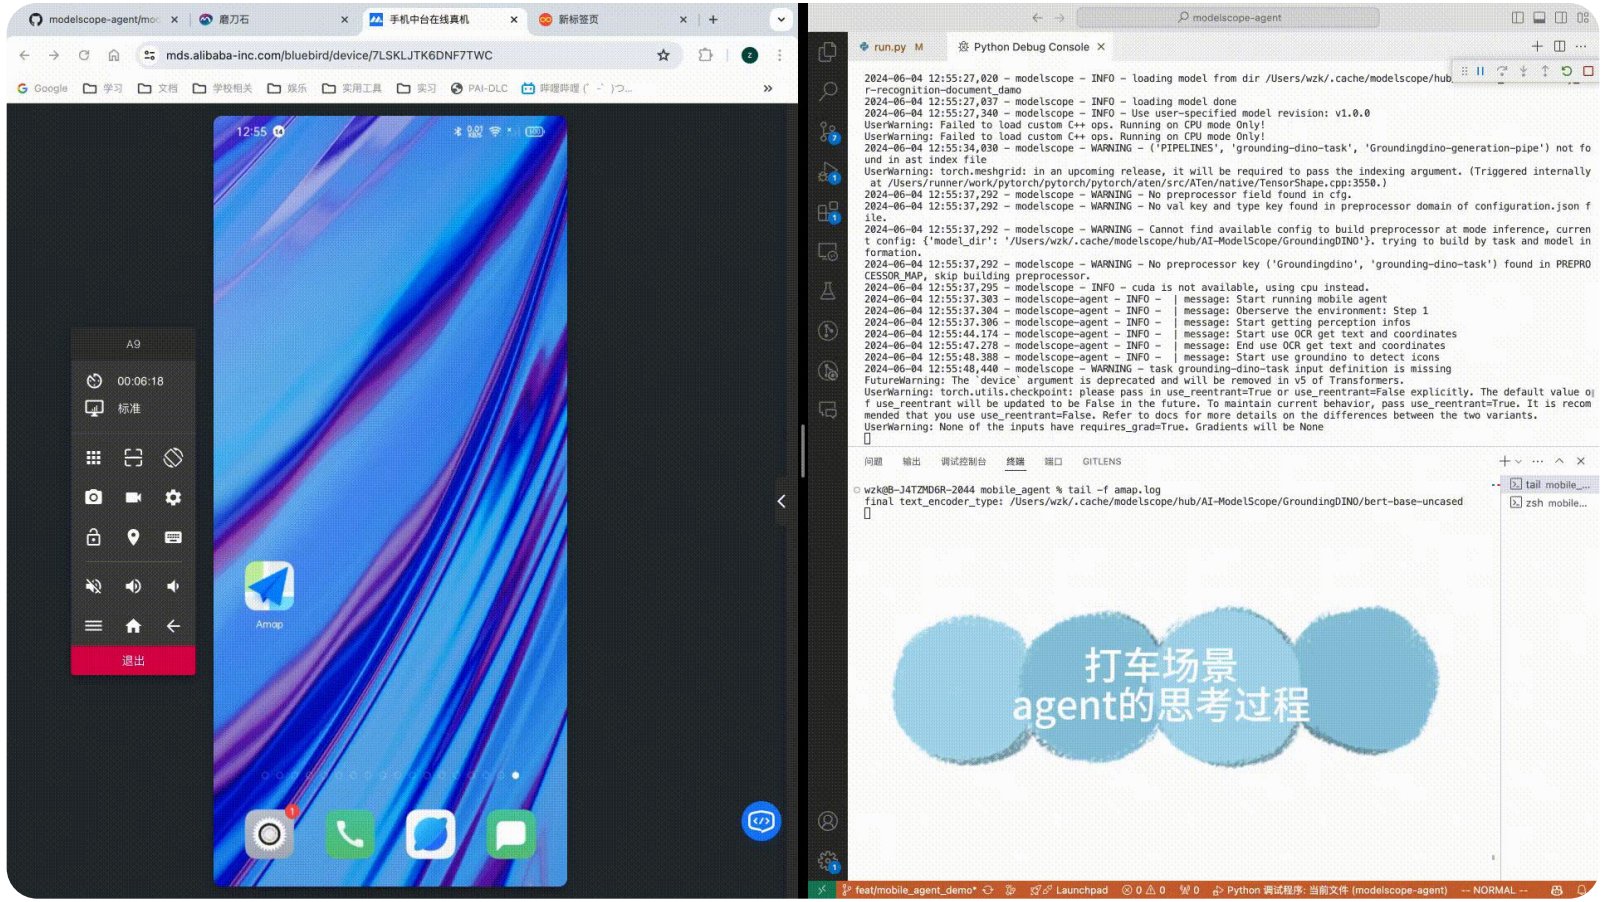


- 首次在手机操作任务上采用**多智能体架构**，并延续了一代的纯视觉方案
- 多智能体各司其职，实现了**更有效**的任务进度追踪、任务相关信息记忆和操作反思
- **更强大**的复杂指令拆解能力、跨应用操作能力和多语言场景操作能力

# 多模态手机智能体Mobile-Agent-V2

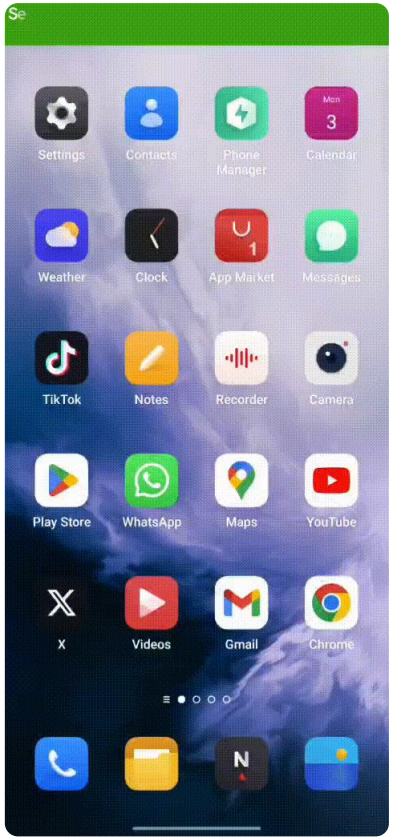





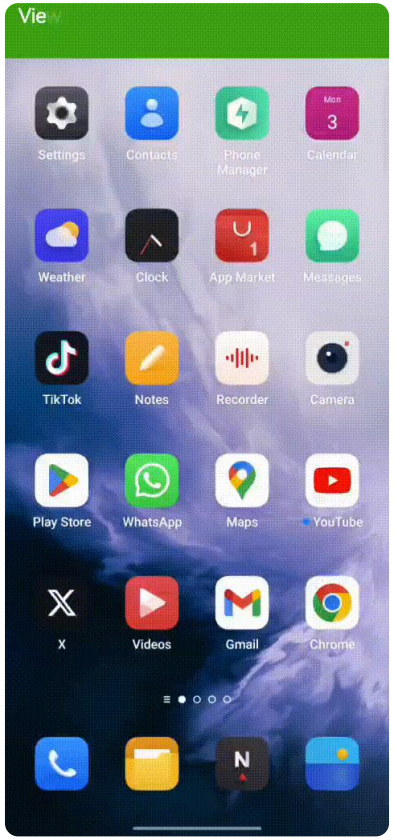

# 多模态手机智能体Mobile-Agent-V2

采用多智能体框架，包括Planning Agent、Decision Agent、Reflection Agent

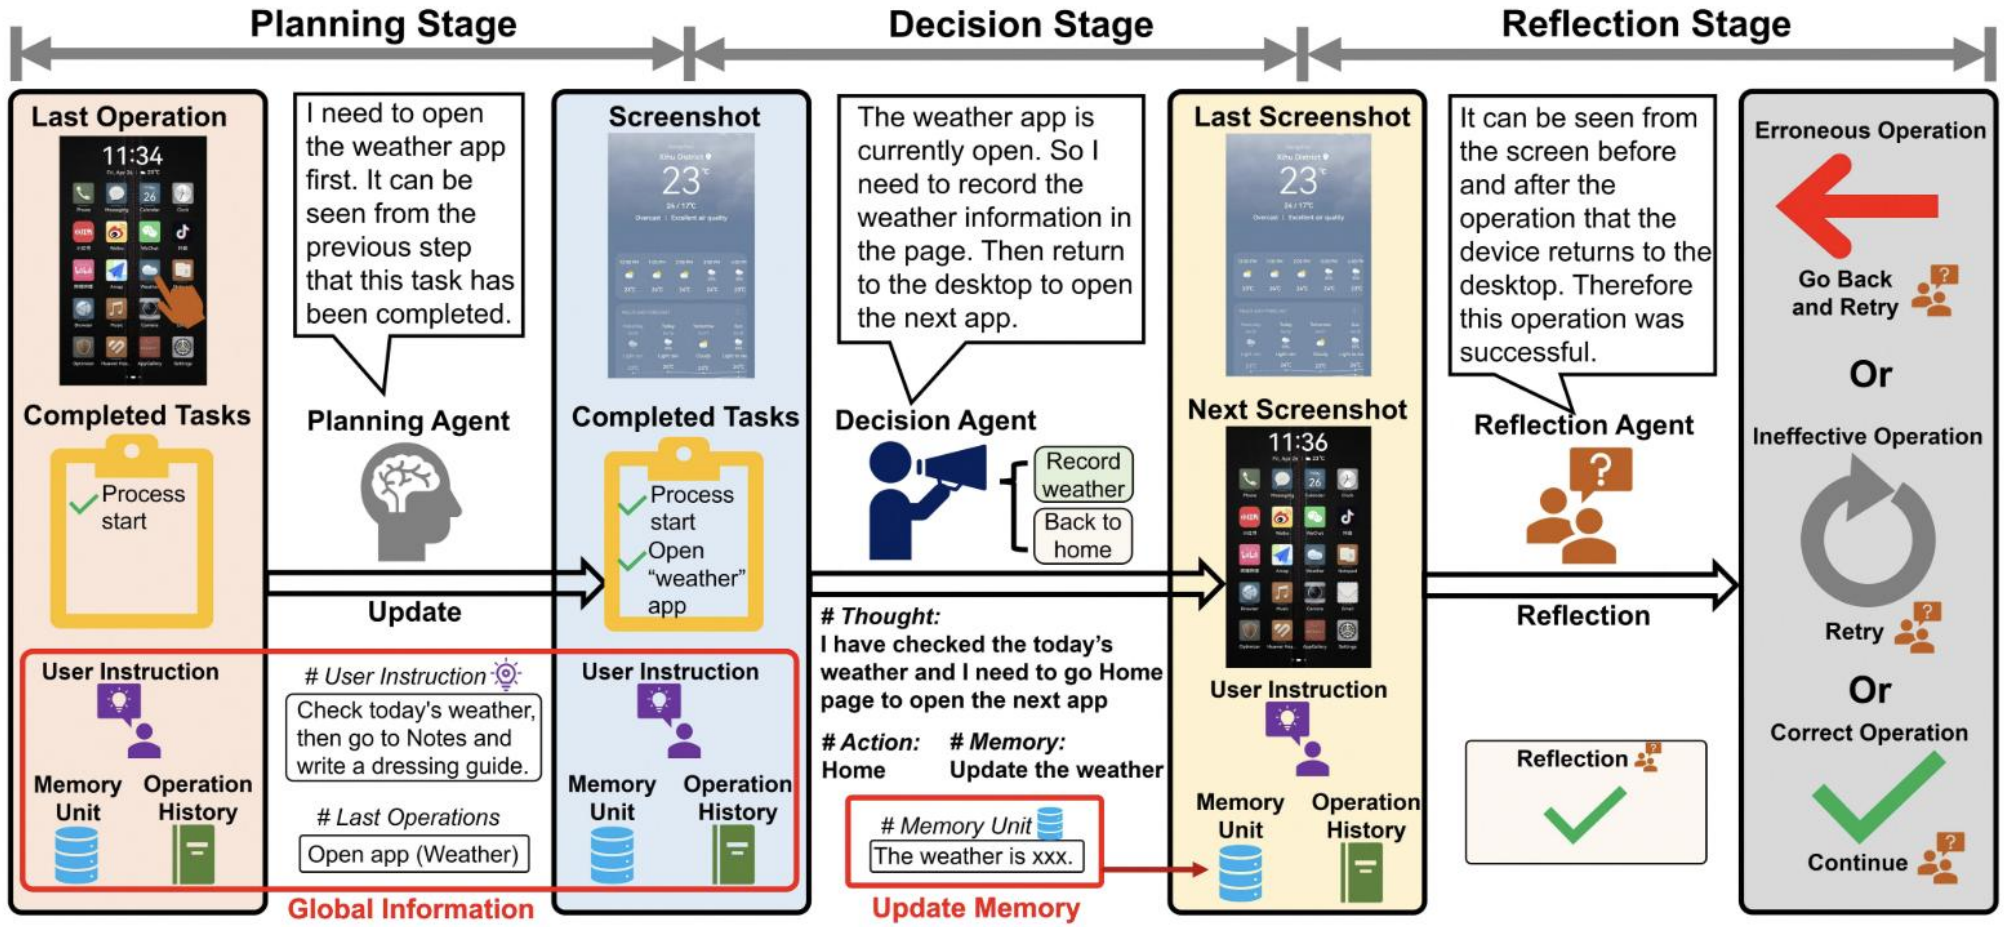

# 多模态手机智能体Mobile-Agent-V2

**动态评测：** 5个系统内置应用和5个第三方应用，每个APP和多个APP各2条基础指令和2条进阶指令

| Method | Basic Instruction | | | | Advanced Instruction | | | |
|---|---|---|---|---|---|---|---|---|
| | SR | CR | DA | RA | SR | CR | DA | RA |
| | *System app* | | | | | | | |
| Mobile-Agent | 5/10 | 41.2 | 37.6 | - | 3/10 | 37.3 | 32.9 | - |
| Mobile-Agent-v2 | 9/10 | 86.8 | 82.5 | 93.3 | 6/10 | 82.7 | 78.2 | 84.4 |
| Mobile-Agent-v2 + *Know.* | 10/10 | 97.5 | 98.2 | 98.9 | 8/10 | 88.9 | 87.2 | 91.4 |
| | *External app* | | | | | | | |
| Mobile-Agent | 2/10 | 38.3 | 35.4 | - | 1/10 | 29.2 | 27.0 | - |
| Mobile-Agent-v2 | 8/10 | 97.9 | 94.0 | 92.5 | 5/10 | 77.9 | 74.1 | 78.8 |
| Mobile-Agent-v2 + *Know.* | 10/10 | 99.1 | 95.6 | 97.3 | 8/10 | 87.8 | 83.0 | 85.9 |
| | *Multi-app* | | | | | | | |
| Mobile-Agent | 1/2 | 52.8 | 50.0 | - | 0/2 | 33.3 | 31.4 | - |
| Mobile-Agent-v2 | 2/2 | 100 | 92.9 | 91.6 | 2/2 | 100 | 93.8 | 92.9 |
| Mobile-Agent-v2 + *Know.* | - | - | - | - | - | - | - | - |

Table 1: Dynamic evaluation results on non-English scenario, where the *Know.* represents manually injected operation knowledge.

| Method | Basic Instruction | | | | Advanced Instruction | | | |
|---|---|---|---|---|---|---|---|---|
| | SR | CR | DA | RA | SR | CR | DA | RA |
| | *System app* | | | | | | | |
| Mobile-Agent | 9/10 | 92.5 | 89.7 | - | 4/10 | 62.0 | 71.3 | - |
| Mobile-Agent-v2 | 9/10 | 95.0 | 92.9 | 96.5 | 6/10 | 76.0 | 77.6 | 88.4 |
| Mobile-Agent-v2 + *Know.* | 10/10 | 100 | 96.2 | 98.7 | 8/10 | 85.3 | 87.9 | 92.0 |
| | *External app* | | | | | | | |
| Mobile-Agent | 7/10 | 79.7 | 72.0 | - | 3/10 | 45.3 | 38.7 | - |
| Mobile-Agent-v2 | 9/10 | 97.1 | 93.8 | 96.2 | 7/10 | 89.7 | 91.0 | 93.4 |
| Mobile-Agent-v2 + *Know.* | 10/10 | 100 | 98.2 | 97.4 | 9/10 | 97.1 | 94.2 | 98.5 |
| | *Multi-app* | | | | | | | |
| Mobile-Agent | 2/2 | 100 | 91.2 | - | 1/2 | 86.7 | 92.9 | - |
| Mobile-Agent-v2 | 2/2 | 100 | 97.4 | 100 | 1/2 | 93.3 | 93.3 | 80.0 |
| Mobile-Agent-v2 + *Know.* | - | - | - | - | 2/2 | 100 | 100 | 100 |

Table 2: Dynamic evaluation results on English scenario, where the *Know.* represents manually injected operation knowledge.

**Metrics.** We design the following four metrics for dynamic evaluation:

- Success Rate (SR): When all the requirements of a user instruction are fulfilled, the agent is considered to have successfully executed this instruction. The success rate refers to the proportion of user instructions that are successfully executed.
- Completion Rate (CR): Although some challenging instructions may not be successfully executed, the correct operations performed by the agent are still noteworthy. The completion rate refers to the proportion of correct steps out of the ground truth operations.
- Decision Accuracy (DA): This metric reflects the accuracy of the decision by the decision agent. It is the proportion of correct decisions out of all decisions.
- Reflection Accuracy (RA): This metric reflects the accuracy of reflection by the reflection agent. It is the proportion of correct reflections out of all reflections.

# 多模态手机智能体Mobile-Agent-V3

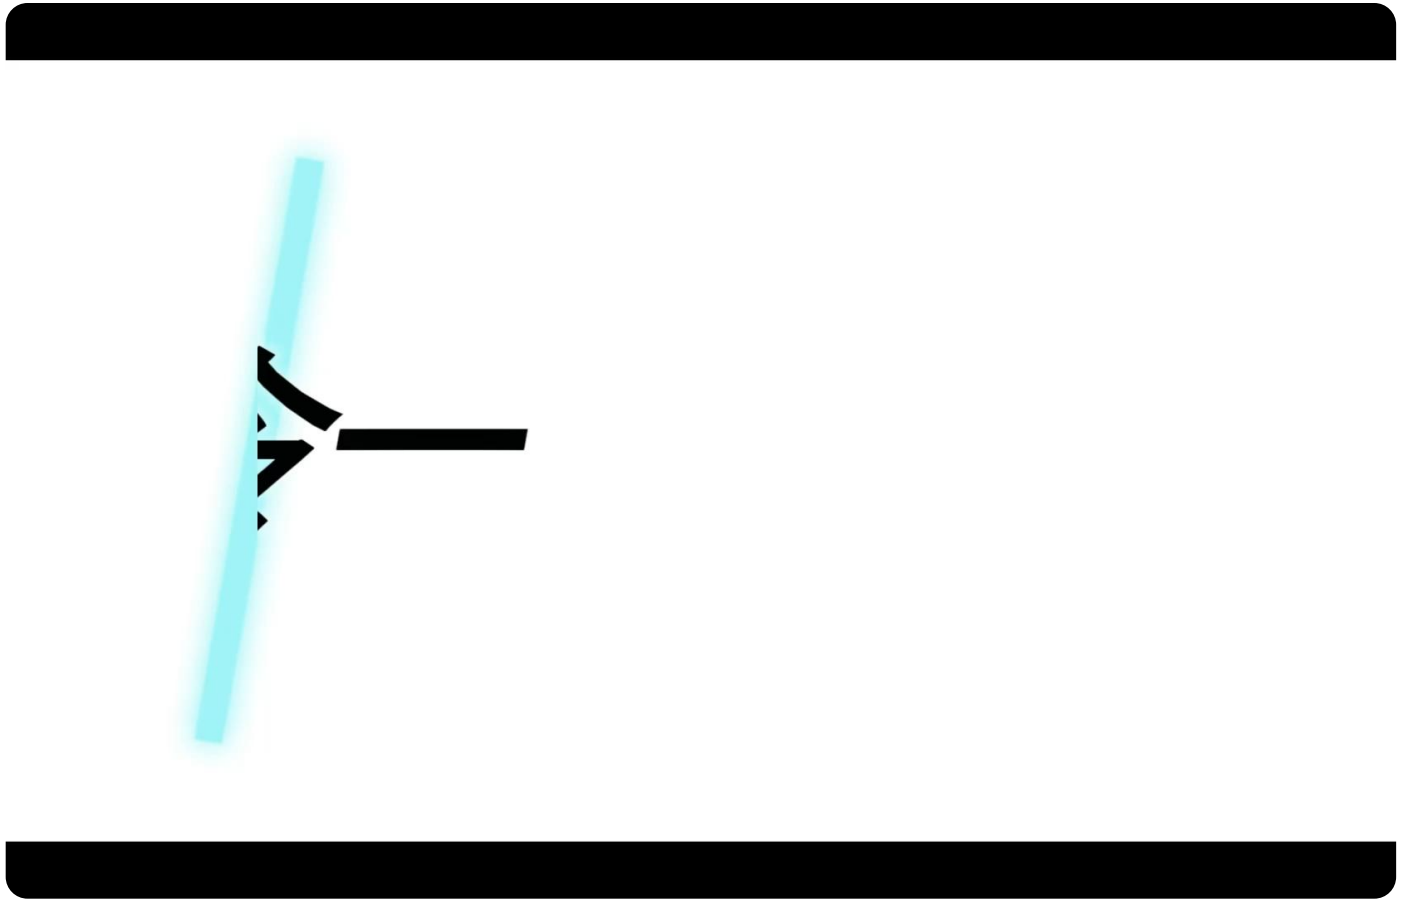

- **纯视觉理解方案**，模拟人对屏幕的感知，可操作**跨多个APP**的复杂任务
- 多智能体协作机制，通过规划、决策、反思，实现**自主推理**，达到强泛化能力和容错机制
- **强安全干预机制**， 避免高危操作
- **端+云协同部署**，端侧模型处理本地图片， 云上模型思考推理，避免隐私安全问题

# 多模态手机智能体Mobile-Agent-V3


# 自主进化手机智能体Mobile-Agent-E

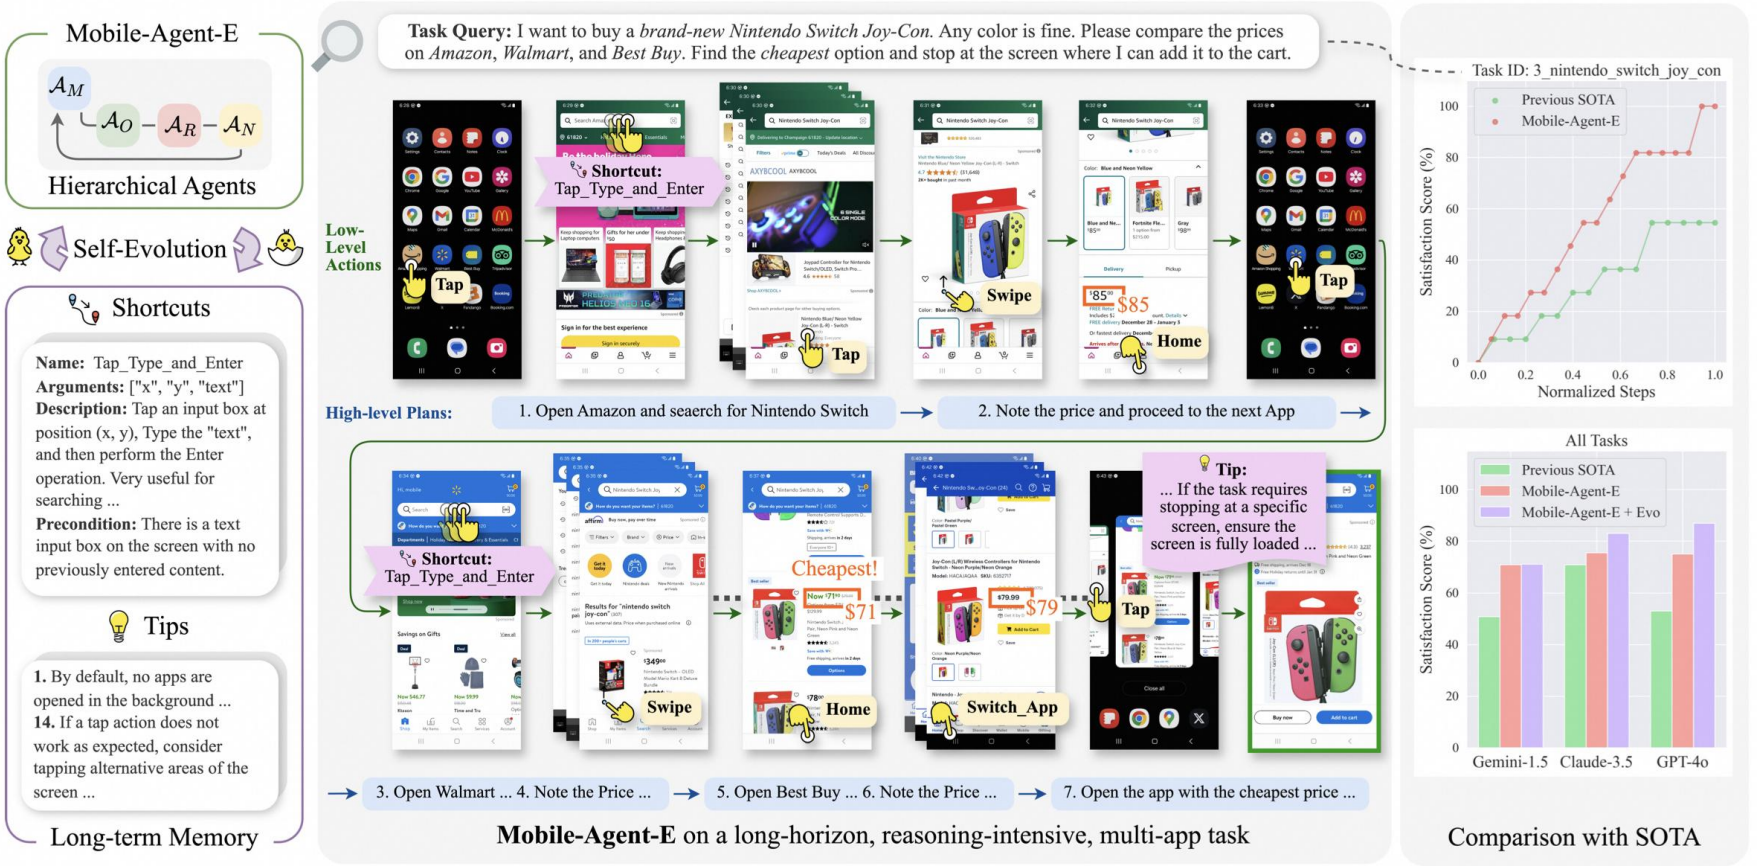


多平台比价任务示例

**复杂指令：**
执行复杂推理、多步规划以及跨App操作

**自我进化：**
反思过往的任务记录，从经验中学习，自动生成Tips和Shortcut

# 自主进化手机智能体Mobile-Agent-E

两个经验Experience Reflectors会根据当前任务的操作记录和错误日志等信息，对Tips和Shortcuts 进行可能的优化和更新

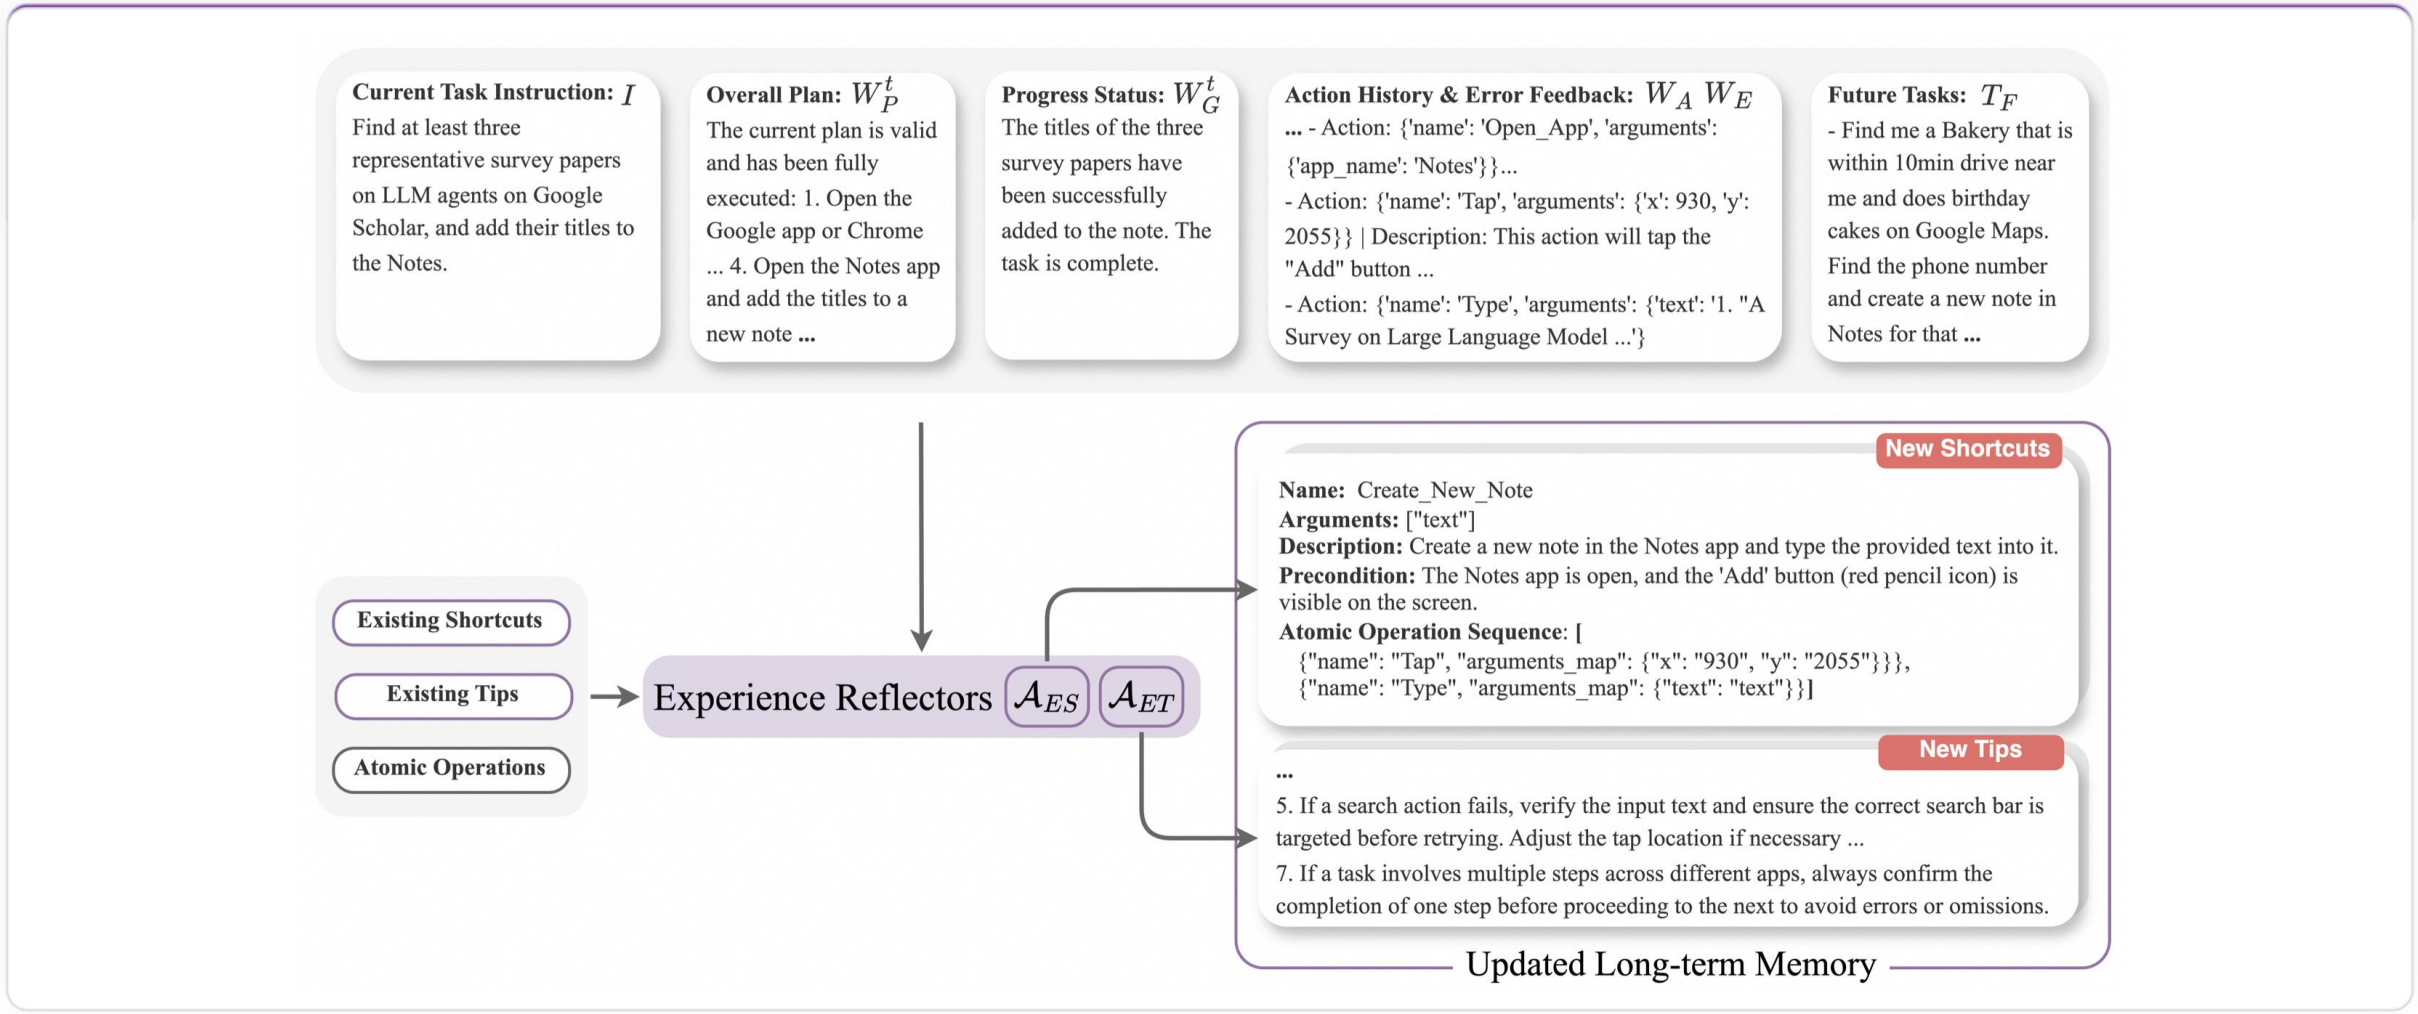

PART 03

# 多模态PC智能体PC-Agent

# 多模态PC智能体PC-Agent

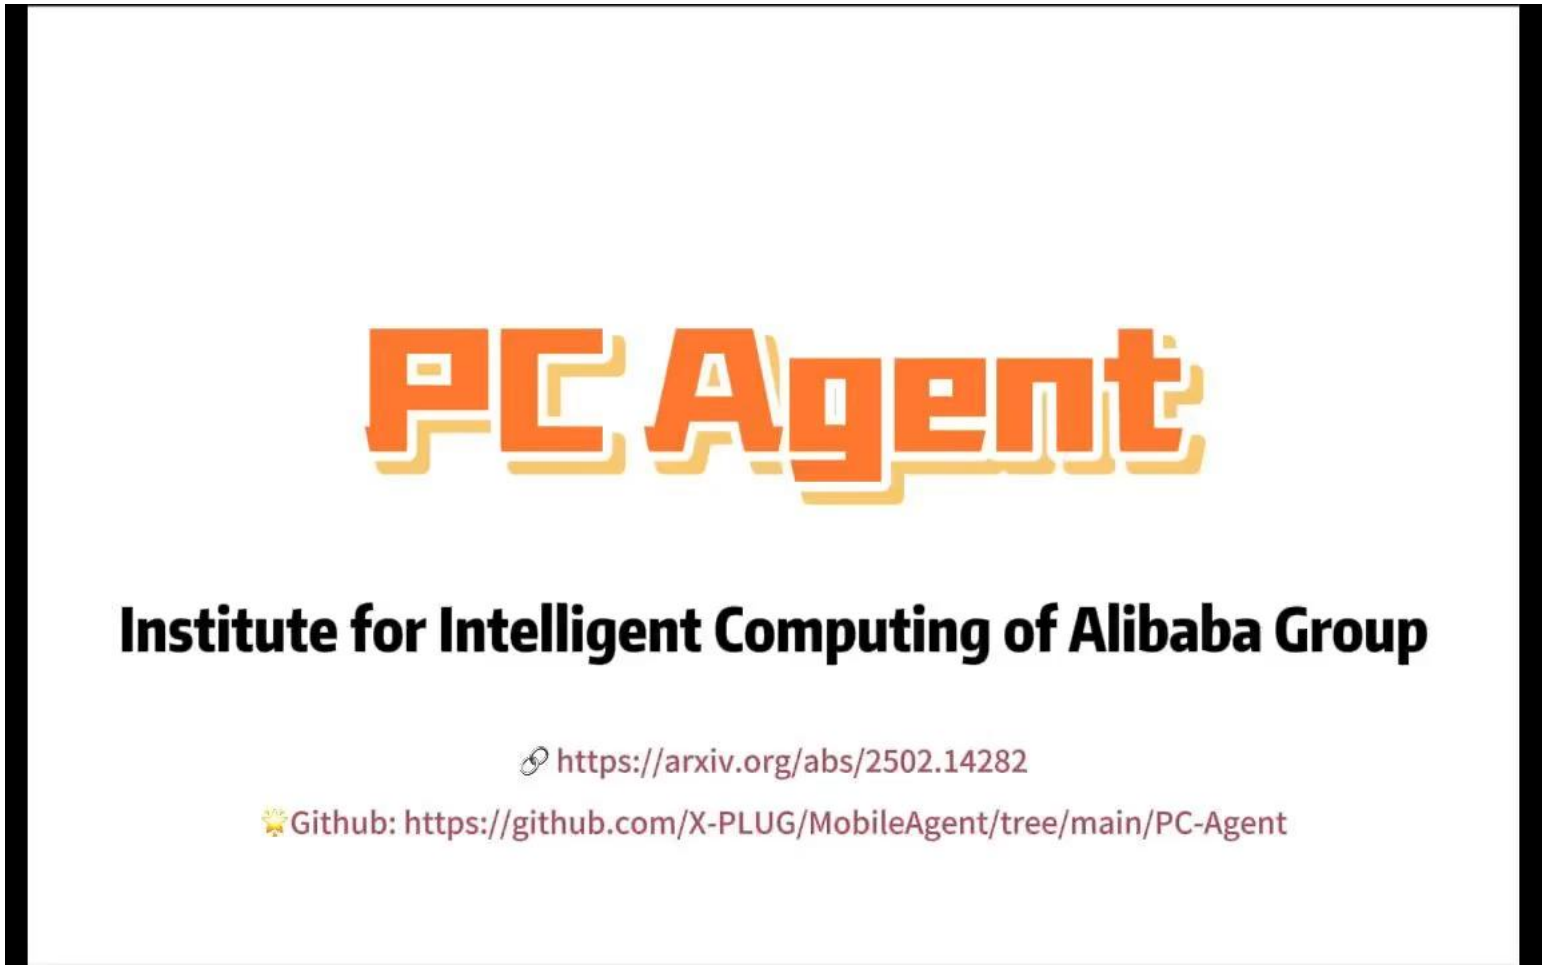

# 多模态PC智能体PC-Agent

## 与Mobile场景相比，PC场景有两个难点：

### 1. 更复杂的交互环境

更密集多样的可交互元素，以及不同布局的文本

### 2. 更复杂的操作序列

PC常用于生产力场景，涉及更多复杂的App内及跨App工作流，因此包含更复杂的任务序列

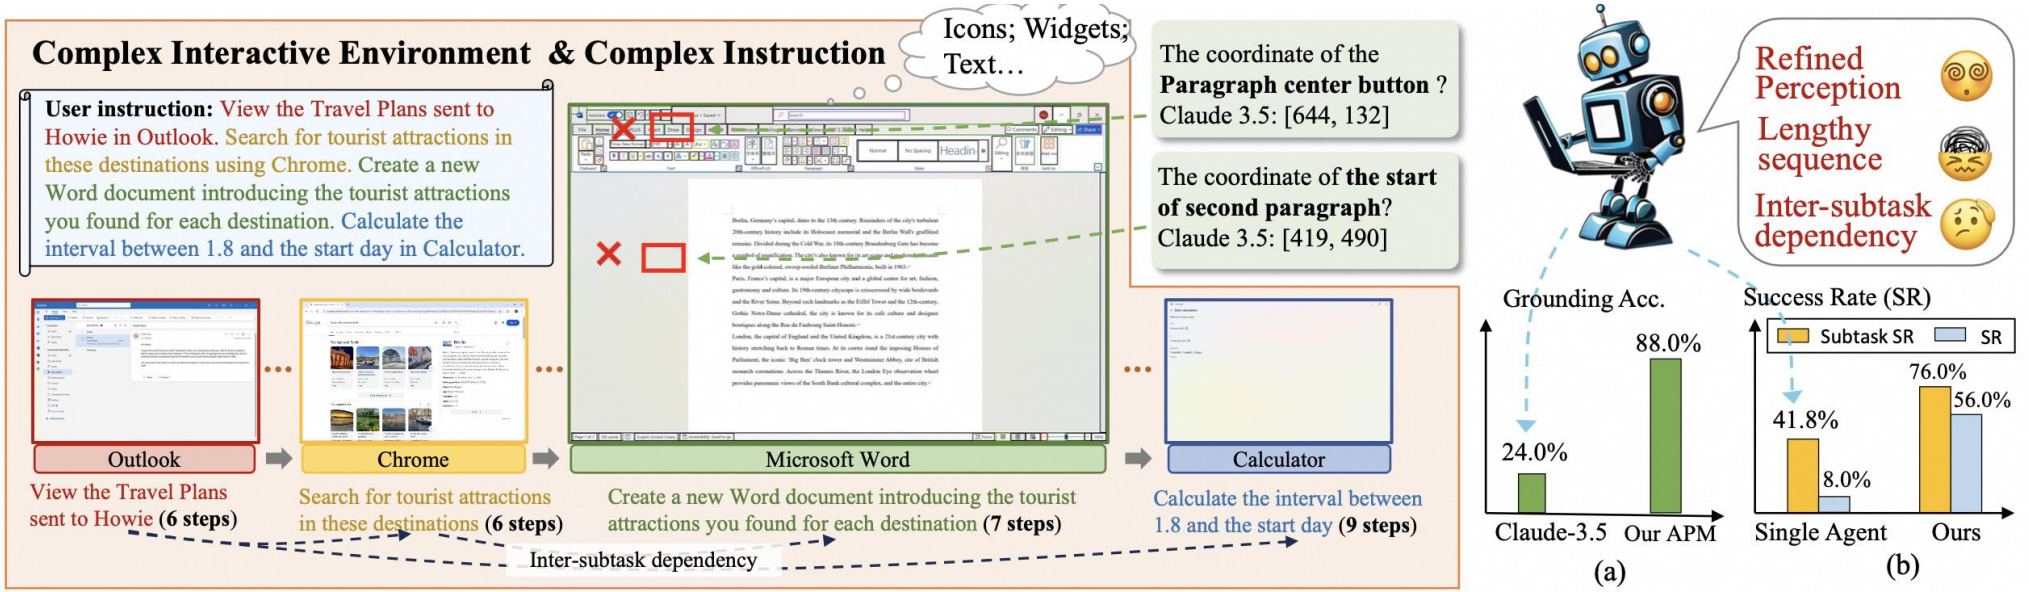

# 多模态PC智能体PC-Agent

## 更复杂的交互环境

1. 更密集多样的可交互元素（Accessibility Tree）

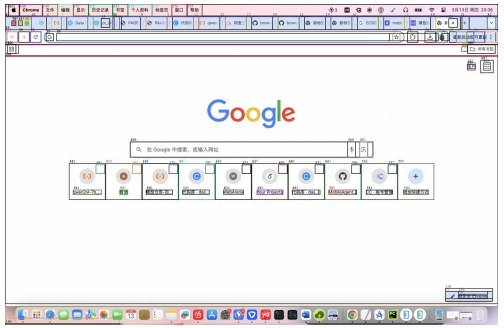


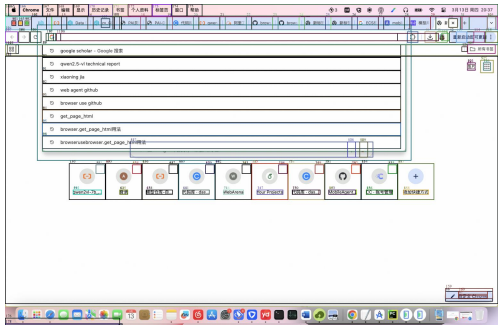


```
    "text": "mark number: 85 icon: 关闭",
    "coordinates": [
        616,
        116
    ]
},
{
    "text": "mark number: 86 icon: 新标签页",
    "coordinates": [
        688,
        117
    ]
},
{
    "text": "mark number: 87 icon: 搜索标签页"
    "coordinates": [
        2984,
        117
    ]
```


2. 主动感知模块（APM）：引入select动作，来选中/操作不同布局的文本

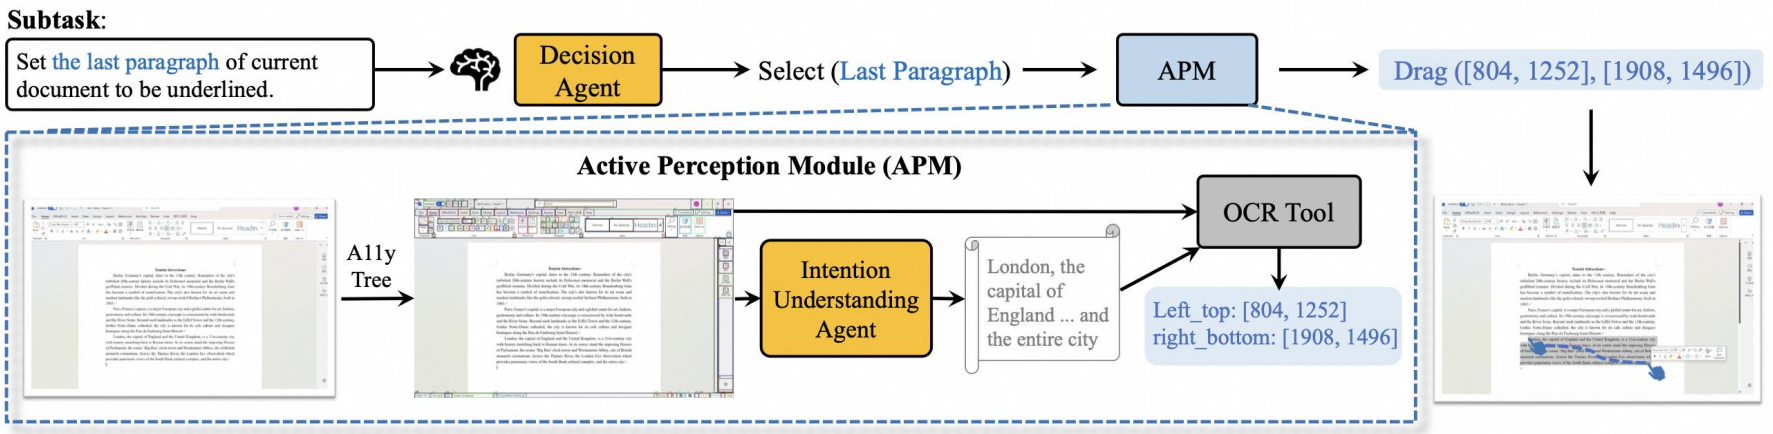

# 多模态PC智能体PC-Agent

## 更复杂的操作序列

Manager Agent将复杂指令的执行分解为3个层次：**指令-子任务-动作**

**指令层级**

Manager Agent

**子任务层级**

Progress Agent

**动作层级**

Decision Agent 决策

Reflection Agent 反思

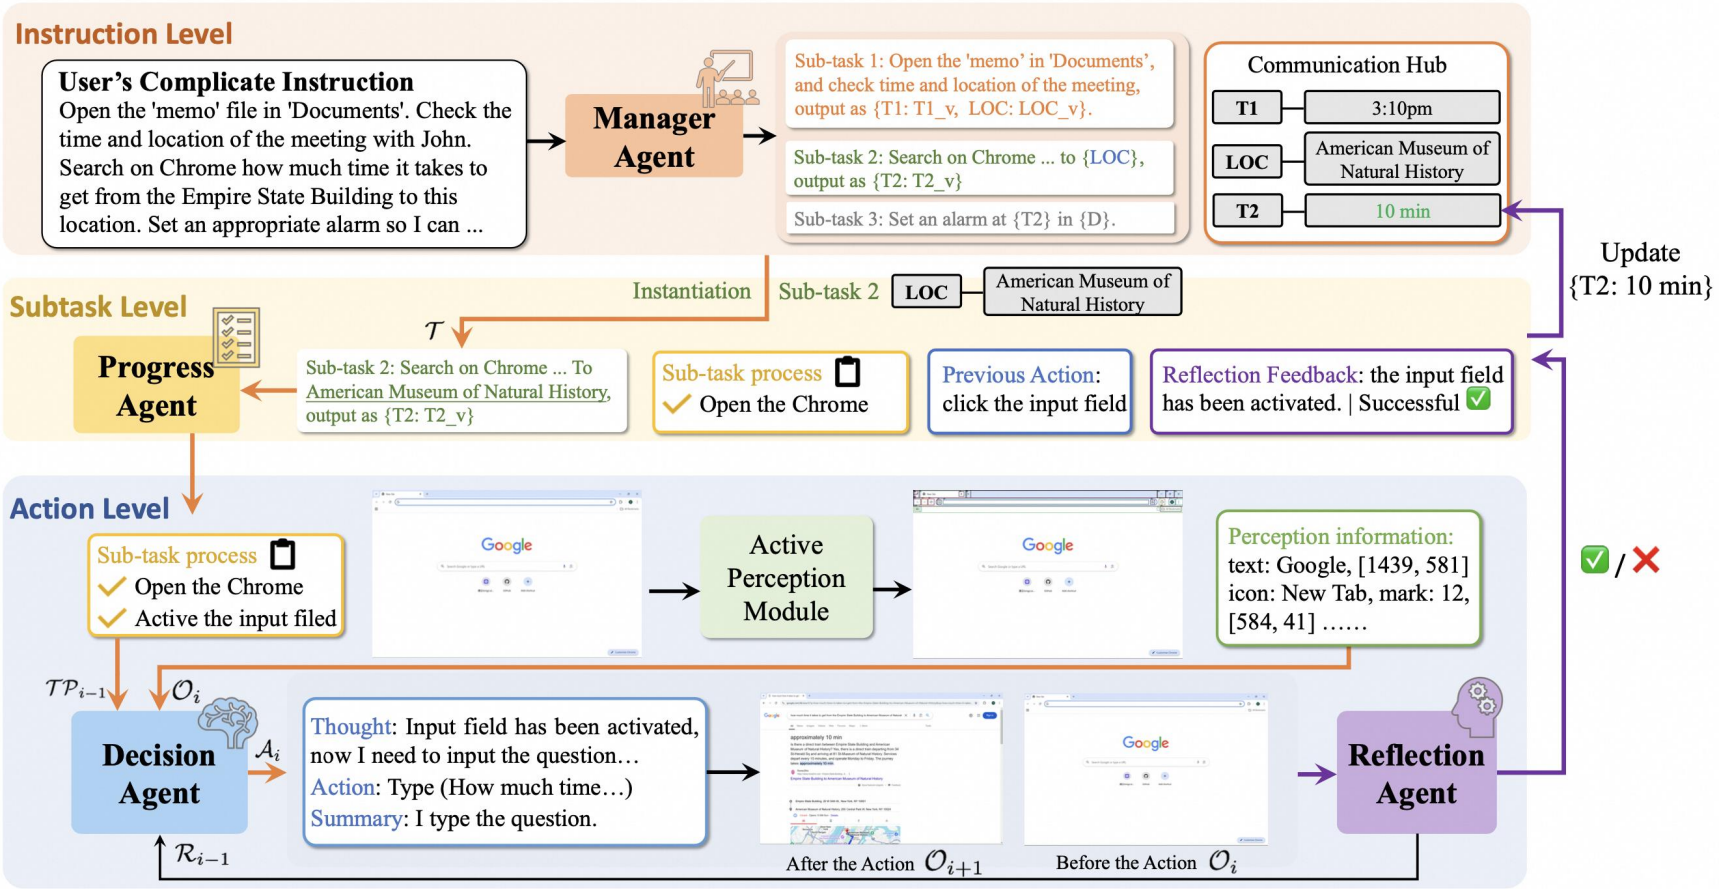

# 多模态PC智能体PC-Agent

## PC-Eval复杂指令测评集

8 个常用PC应用的 25 条复杂用户指令。每条指令由若干具有依赖关系的子任务构成，强调精细化操作及长程决策，并与现实场景工作流相对应。

| Applications | Instruction | Steps |
|---|---|---|
| File Explorer<br>Notepad, Clock<br>Calculator | In the Notepad app, open the 'travel_plan' file in 'Documents', and check the time and location of the travel plans. Add the travel destination to the World Clock list on the Clock app. Calculate the interval between February 18 and the start time of the travel on the Calculator. | 20 |
| Chrome<br>Excel | Search on Chrome for the total population of China, the United States, and India in 2024 respectively. Create a new spreadsheet in Excel, write the three countries' names in column A in descending order of population, and the corresponding populations in column B. | 23 |
| File Explorer<br>Word | Open the 'test_doc1' file in 'Documents' in File Explorer, set the title to be bold, and set the line spacing of the first two paragraphs to 1.5x in Word. | 8 |

# 多模态PC智能体PC-Agent

## PC-Eval复杂指令测评集

| Model | Type | Subtask SR (%) ↑ | Success Rate (%) ↑ |
|---|---|---|---|
| Gemini-2.0 | Single-Agent | 35.4% | 0.0% |
| Claude-3.5 | | 15.2% | 0.0% |
| Qwen2.5-VL | | 46.8% | 12.0% |
| GPT-4o | | 41.8% | 8.0% |
| UFO (Zhang et al., 2024) | Multi-Agent | 43.0% | 12.0% |
| Agent-S (Agashe et al., 2024) | | 55.7% | 24.0% |
| **PC-Agent** (Ours) | | **76.0%** | **56.0%** |

| Ablation study | | | Subtask Success Rate | Success Rate |
|---|---|---|---|---|
| APM | Manager Agent | Reflection Agent | | |
| | ✓ | ✓ | 58.2% | 20.0% |
| ✓ | | ✓ | 50.6% | 12.0% |
| ✓ | ✓ | | 48.1% | 12.0% |
| ✓ | ✓ | ✓ | 76.0% | 56.0% |

AiDD 6th 2025

# PART 04

# Mobile-Agent开源应用

# Mobile-Agent PC-Agent开源应用

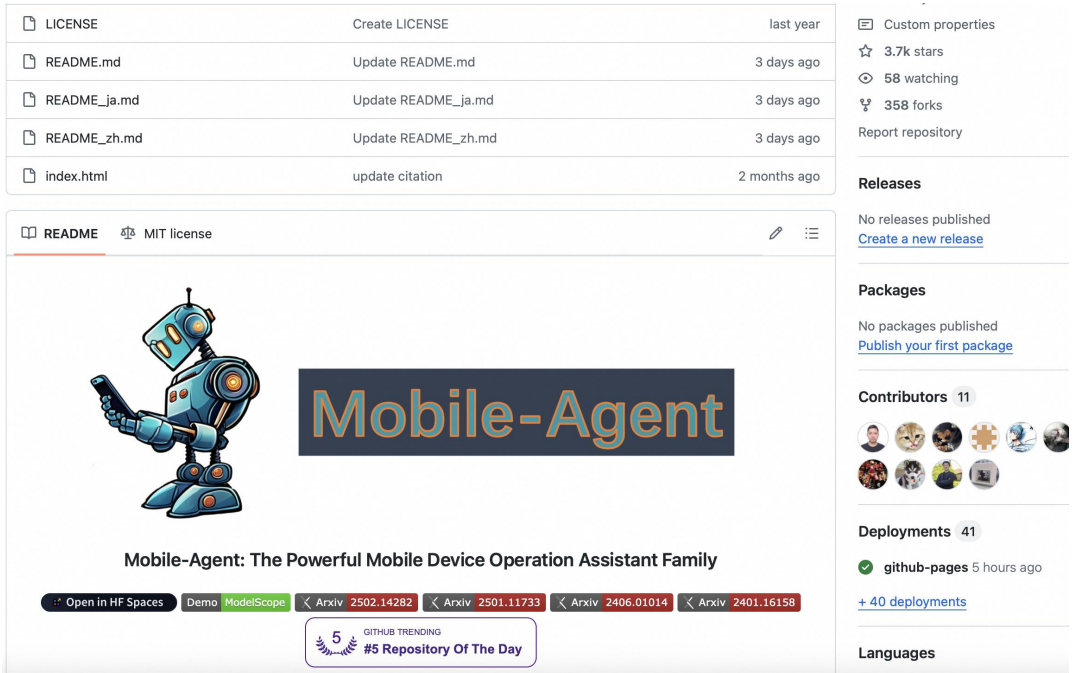


https://github.com/X-PLUG/MobileAgent

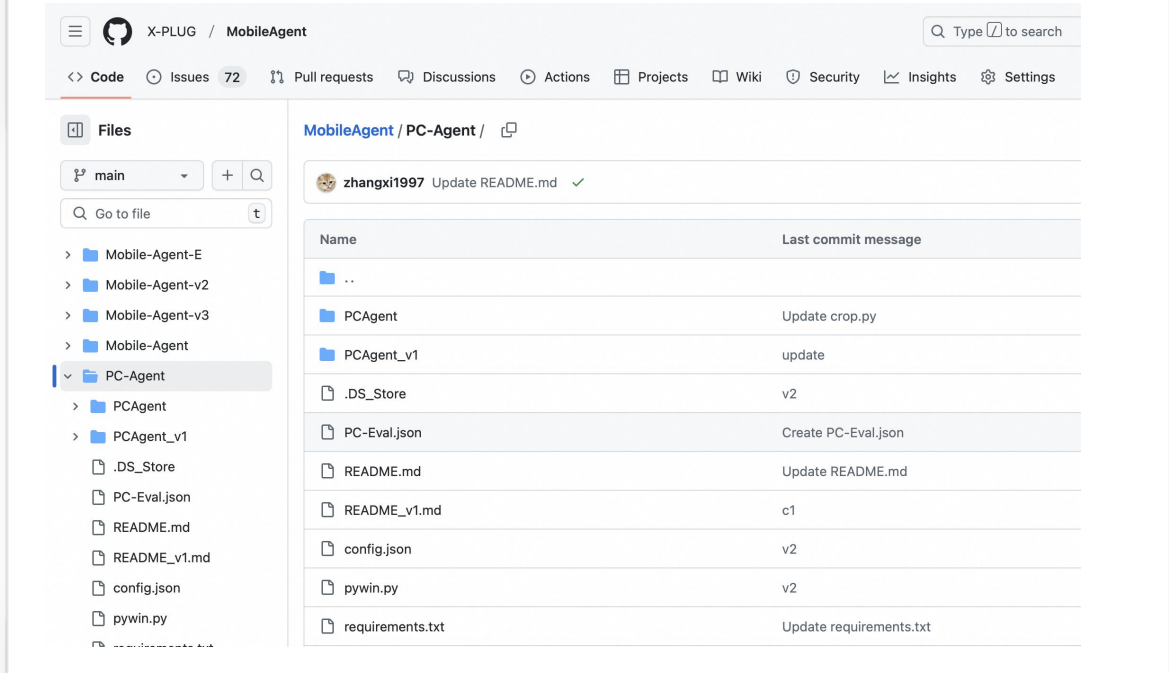


https://github.com/X-PLUG/MobileAgent/tree/main/PC-Agent

# Mobile-Agent开源应用

## 🔧开始

❗目前仅安卓和鸿蒙系统（版本号 <= 4）支持工具调试。其他系统如iOS暂时不支持使用Mobile-Agent。

### 安装依赖

```
pip install -r requirements.txt
```

### 准备通过ADB连接你的移动设备

1. 下载 Android Debug Bridge（ADB）。
2. 在你的移动设备上开启“USB调试”或“ADB调试”，它通常需要打开开发者选项并在其中开启。
3. 通过数据线连接移动设备和电脑，在手机的连接选项中选择“传输文件”。
4. 用下面的命令来测试你的连接是否成功: `/path/to/adb devices`。如果输出的结果显示你的设备列表不为空，则说明连接成功。
5. 如果你是用的是MacOS或者Linux，请先为 ADB 开启权限: `sudo chmod +x /path/to/adb`。
6. `/path/to/adb` 在Windows电脑上将是 `xx/xx/adb.exe` 的文件格式，而在MacOS或者Linux则是 `xx/xx/adb` 的文件格式。

### 在你的移动设备上安装 ADB 键盘

1. 下载 ADB 键盘的 apk 安装包。
2. 在设备上点击该 apk 来安装。
3. 在系统设置中将默认输入法切换为 “ADB Keyboard”。

### 选择适合的运行方式

1. 在 `run.py` 的22行起编辑你的设置， 并且输入你的 ADB 路径，指令，GPT-4 API URL 和 Token。

2.选择适合你的设备的图标描述模型的调用方法：

- 如果您的设备配备了高性能GPU，我们建议使用“local”方法。它是指在本地设备中部署图标描述模型。如果您的设备足够强大，则通常具有更好的效率。
- 如果您的设备不足以运行7B 大小的 LLM，请选择“ api”方法。我们使用并行调用来确保效率。

3.选择图标描述模型：

- 如果选择“local”方法，则需要在“qwen-vl-chat”和“qwen-vl-chat-int4”之间进行选择，其中“qwen-vl-chat”需要更多的GPU内存，但提供了更好的性能与“qwen-vl-chat-int4”相比。同时，“qwen_api”可以是空置的。
- 如果您选择“api”方法，则需要在“qwen-vl-plus”和“qwen-vl-max”之间进行选择，其中“qwen-vl-max”需要更多的费用，但与“qwen-vl-plus”相比提供了更好的性能。此外，您还需要申请Qwen-VL 的 API-KEY，并将其输入到“qwen_api”。

4.您可以在“add_info”中添加操作知识（例如，完成您需要的指令所需的特定步骤），以帮助更准确地运行移动设备。

5.如果您想进一步提高移动设备的效率，则可以将“ reflection_Switch”和“ memory_switch”设置为“ False”。

- “ reflection_switch”用于确定是否在此过程中添加“反思智能体”。这可能会导致操作陷入死周期。但是您可以将操作知识添加到“ add_info”中以避免它。
- “ memory_switch”用于决定是否将“内存单元”添加到该过程中。如果你的指令中不需要在后续操作中使用之前屏幕中的信息，则可以将其关闭。

https://github.com/X-PLUG/MobileAgent/blob/main/Mobile-Agent-v2/README_zh.md

# Mobile-Agent开源应用

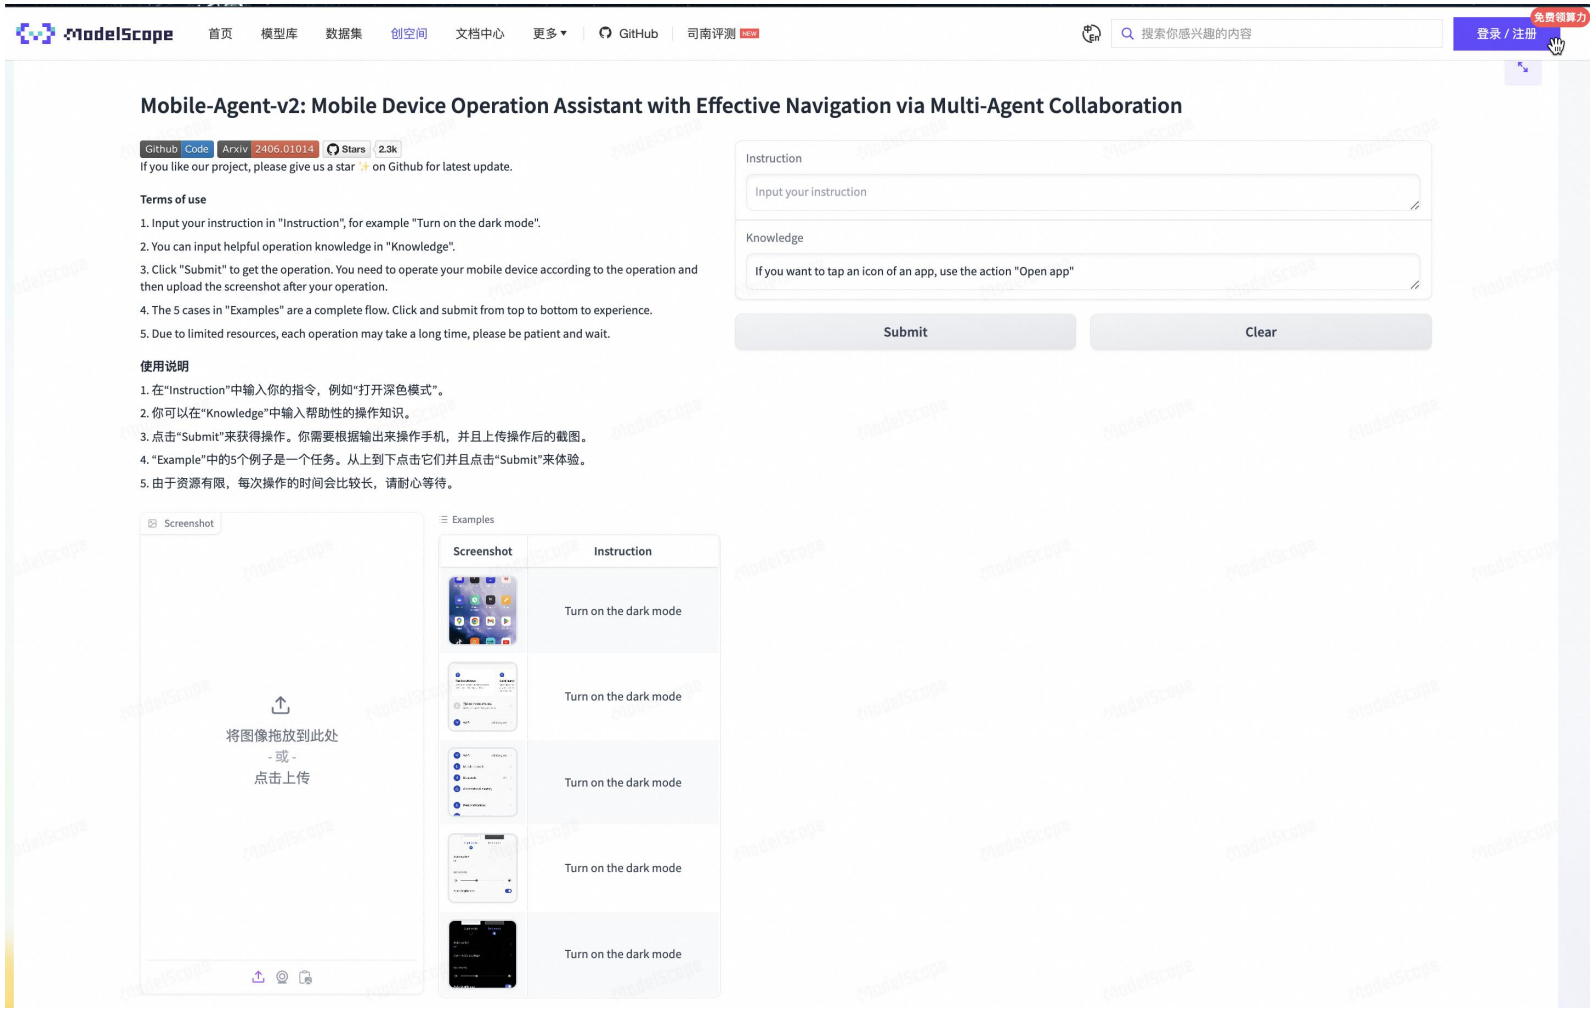


https://modelscope.cn/studios/wangjunyang/Mobile-Agent-v2

# PC-Agent开源应用

## 📋Introduction

- PC-Agent is a multi-agent collaboration system, which can achieve automated control of productivity scenarios (*e.g.* Chrome, Word, and WeChat) based on user instructions.
- Active perception module designed for dense and diverse interactive elements are better adapted to the PC platform.
- The hierarchical multi-agent cooperative structure improves the success rate of more complex task sequences.

## 🔧Getting Started

### Installation

Now **Windows** is supported.

```
conda create --name pcagent python=3.10
source activate pcagent

# For Windows
pip install -r requirements.txt

git clone https://github.com/Topdu/OpenOCR.git
pip install openocr-python
```

### Configuration

Edit config.json to add your API keys and customize settings:

```
# API configuration
{
  "vl_model_name": "GPT-4o",
  "llm_model_name": "GPT-4o",
  "token": "sk-...", # Replace with your actual API key
  "url": "https://api.openai.com/v1"
}
```

### Test on your computer

1. Run the *run.py* with your instruction and your GPT-4o api token. For example,

```
python run.py --instruction="Create a new doc on Word, write a brief introduction of Alibaba, and save the doc
```

2. Optionally, you can add specific operational knowledge via the *--add_info* option to help PC-Agent operate more accurately.
3. To further improve the operation efficiency of PC-Agent, you can set *--disable_reflection* to skip the reflection process. Note that this may reduce the success rate of the operation.
4. If the task is not very complex, you can set *--simple 1* to skip the task decomposition.

https://github.com/X-PLUG/MobileAgent/blob/main/PC-Agent/README.md

# 大模型通用型智能体系统

## 未来可能方向

**技术角度：**

- 更通用泛化的执行方式，API与操作相结合
- Agent RL训练提高决策能力
- 多模态内容的理解，image video audio
- 云端异步处理
- 手机和电脑端的联动（信息差）

**应用角度：**

- 更好的人机交互过程
- 用户偏好记忆、个人隐私保护

Agent！

AiDD 6th 2025

## 参与调研您将优先获得


AiDD定制版
《AI+软件研发精选案例》


专属学习顾问
1对1需求对接

# AiDD会后小调研

AiDD峰会致力于协助企业利用AI技术深化计算机对现实世界的理解，推动研发进入智能化和数字化的新时代。作为峰会的重要共建者，您的真知灼见对我们至关重要。衷心感谢您的参与支持！

扫码参与调研

# 2025 AI+研发数字峰会

拥抱AI 重塑研发

# 科技生态圈峰会 + 深度研习

## ——1000 + 技术团队的共同选择

KEYLINK ing

### K+峰会

**K+峰会 · 敦煌站**
K+ 思考周®研习社
时间：2025.08.29-30

**K+峰会 · 上海站**
K+ 金融专场
时间：2025.09.26-27

**K+峰会 · 香港站**
K+ 思考周®研习社
时间：2025.11.17-18

K+峰会详情

### AiDD峰会

**AiDD峰会 · 上海站**
AI+研发数字峰会
时间：2025.05.23-24

**AiDD峰会 · 北京站**
AI+研发数字峰会
时间：2025.08.08-09

**AiDD峰会 · 深圳站**
AI+研发数字峰会
时间：2025.11.14-15

AiDD峰会详情

2025 AI+研发数字峰会

AI+ Development Digital Summit

# 感谢聆听！

扫码领取会议PPT资料