



AI+ 研发数字峰会
AI+ Development Digital summit

第5届
5

AI Agent构建智能应用的新范式 ——从 LLM 到 Agentic workflow

揭光发 | Tencent

科技生态圈峰会 + 深度研习

—1000+ 技术团队的共同选择



K+峰会详情



AiDD峰会详情



揭光发

腾讯技术专家

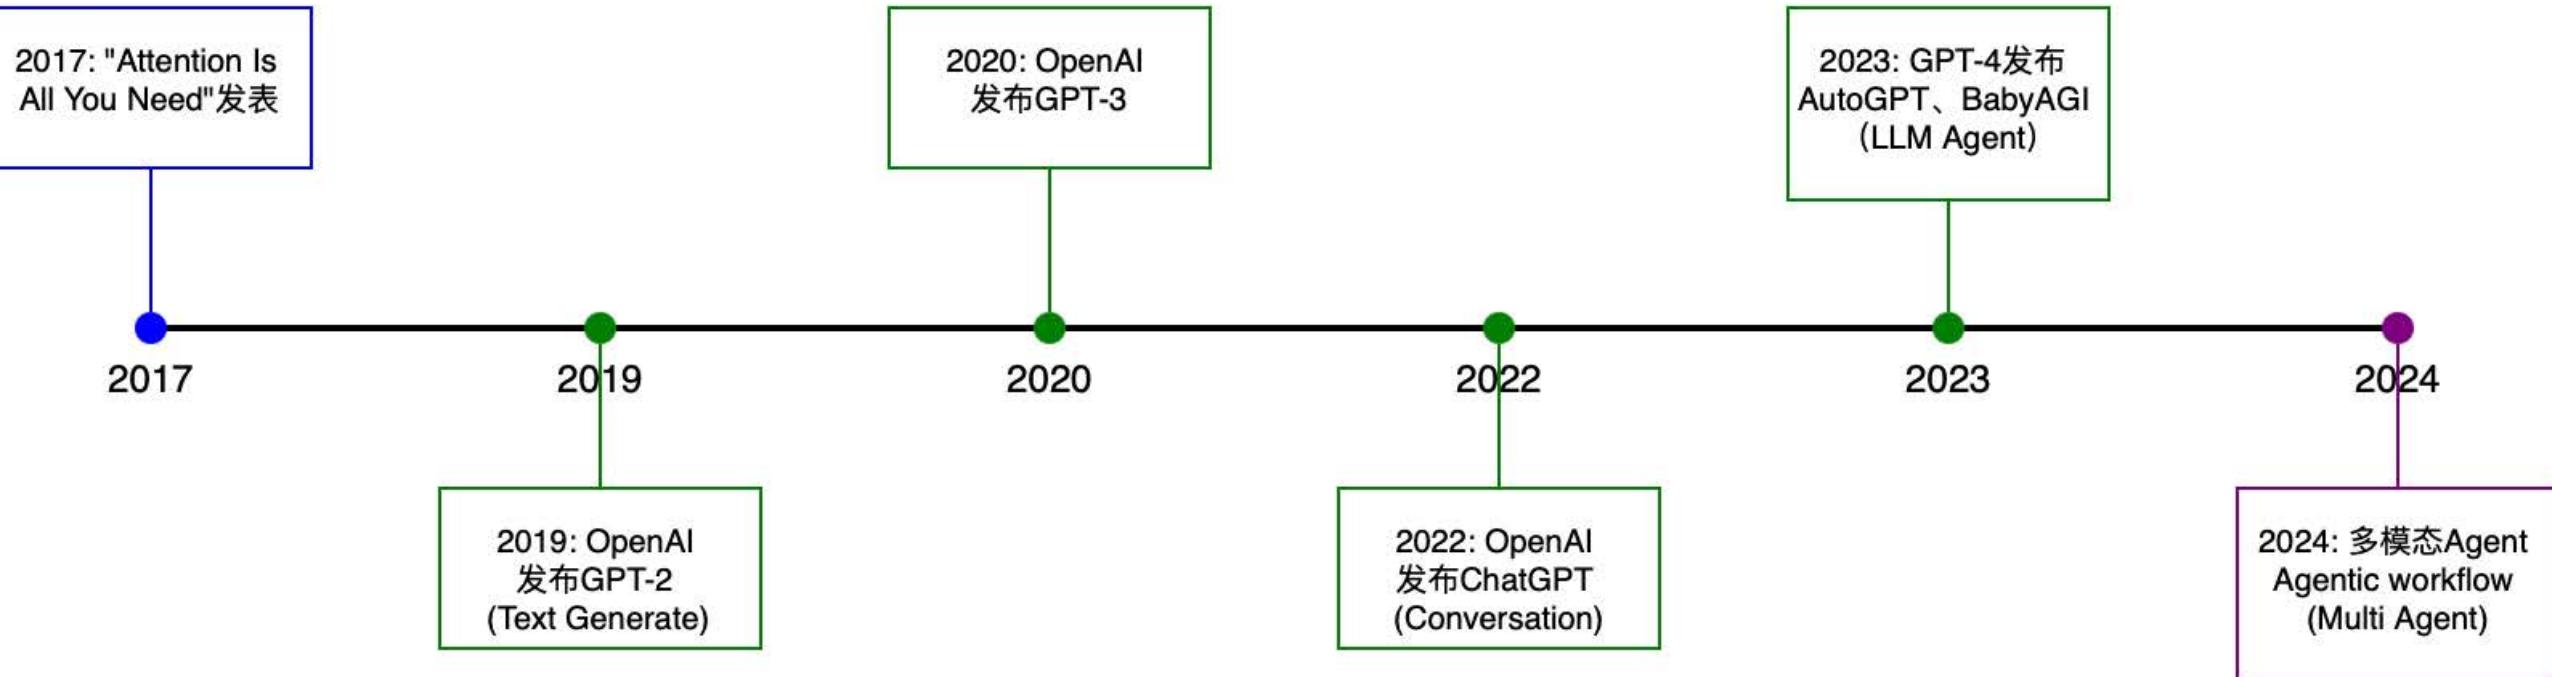
19年研发与团队管理经验，前腾讯云TVP。

全栈低代码开发专家，腾讯低代码Oteam负责人

大模型应用早期实践者与布道师。在团队中深度践行LLM对研发提效，个人代码中AI含量达90+%。

国内顶级行业及技术峰会担任大模型相关话题讲师或出品人10+次。

► Transformer到多模态Agentic Workflow的演进



► Core -- Text Generate

指令

上下文

输入数据

示例

格式说明

输出指示

评估标准

步骤引导

Prompt

下面我将要讲一个故事。

角色设定

约束条件

在很久很久以前，有一个小村庄坐落在群山环抱之中。村子里住着一群淳朴善良的人们，他们过着平静而简单的生活。村子里有一位老奶奶，她以制作美味的糕点而闻名。每当村里有庆典或节日时，大家都会聚集在她家门前，等待品尝她新鲜出炉的点心。

Generate

诗歌创作

语言翻译

情感分析

广告文案

代码生成

文本分类

► LLM生态的两大阵营

Prompt engineering

提示词工程师

应用层

Agent

Flow

RAG

ReAct

Function Call

FoT

Memory

Model pre-training

炼丹师

算法层

BERT

GPT

MoE

Fine-Tuning

RLHF

Context
window

60B

Emergence

LLM APP: 从Text Completion 到 Agent

► 1. text completion

请给我讲一个中国的神话故事：



故事名称：《嫦娥奔月》

相传在古代，有一位美丽的仙女名叫嫦娥。她是天上的玉兔宫女，有着清秀的容颜和出色的歌舞技巧。嫦娥住在天宫中的玉帝府，和其他仙子一起照顾玉帝的一切。

一年的八月十五，也就是我们现在所说的中秋节，玉帝要在天宫中举行盛大的宴会。天宫中的所有仙子都要穿上美丽的仙衣，献上自己的歌舞。而嫦娥的舞蹈更是被玉帝高度赞扬，受到众仙子的羡慕和称赞。

然而，在宴会之后，嫦娥偶然间听到众仙子们私下的议论，说她的舞技并不是来自自己的努力和天赋，而是来自玉帝赐予的仙丹。嫦娥非常生气和伤心，她不愿意被称赞的舞技是假的，于是决定离开天宫，寻找自己真正的才华和命运。

嫦娥来到了蟠桃园，邂逅了一位名叫后羿的有心人。后羿是神箭手，有着非凡的射箭技巧。两人很快坠入了爱河，决定结为夫妻。

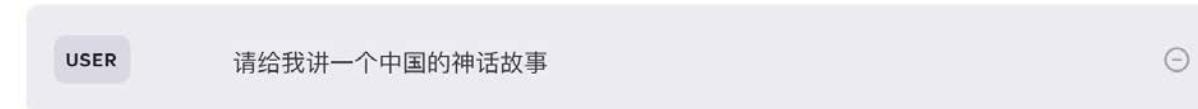
然而，嫦娥并没有忘记自己离开天宫的原因，她求助于爱护她的玉皇大帝。玉帝告诉嫦娥，他无法让她还原成凡人，只能让她变成一个永远居住在月宫的仙子。而且，嫦娥每年只能在八月十五的夜晚回到天宫与丈夫后羿团聚。

嫦娥听从了玉帝的话，变成了一个永远居住在月宫的仙女。每年的八月十五，人们都能在月宫中看到嫦娥和后羿在天宫中团聚的画面，就如同我们现在的中秋节一样。

从此，嫦娥的美丽和舞技都变成了人们心中最美的神话，每逢中秋佳节，人们都会抬头仰望皓月，祈愿幸福团圆。嫦娥也成为了月宫的守护神，保佑人间的和平和幸福。

而在天宫中，嫦娥也找到了自己的真正才华，每天在玉兔宫中与众仙子一起跳起美妙的舞蹈，让人们在夜晚欣赏到天宫的璀璨之美。从此，嫦娥和后羿的爱情也成为了人间和天界最为动人的神话。

► 2. Conversation Chat



ASSISTANT

好的，以下是一个中国神话故事《女娲补天》：

很久很久以前，天地混沌一片，乌云密布，狂风呼啸。人们苦不堪言，生活在恐惧中。于是，在这个时候，女娲出现了。

女娲是中国古代神话传说中的女神，她是万物的创造者。女娲看到人们的疾苦，决定帮助他们。她先用五色石块熔化成五彩的巨石，然后凿成长长的山川，修筑了河流湖海，让大地变得有了形状。

可是，女娲的工作还没有结束。因为天空始终阴沉，日月星辰无法照耀大地。女娲在心中默念着法术，她取出神巫的铜镜，用铜镜反射出太阳，再取出玉石，制造了一轮明亮的月亮和漂亮的星星。大地上终于重见光明。

然而，在女娲补好大地之后，她发现天空中有一个大洞，一不留神，就会有混沌的风沙倾泻，带来浩劫。为了保护世界，女娲决定补天。她飞到高空，依次取出五色石，用来修补天上的大洞，最后补好了整个天空。

女娲补天的壮举感动了众生，人们都在欢呼女娲的名字。从此以后，大地上有了山川河流，天空有了日月星辰，人间光明祥和，生活愈发美好幸福。

这个神话故事传颂了女娲的伟大造化之功，也展现了中国古代人们对女神的崇敬与向往。女娲补天，成为中国文化中传承千年的神话传说，激励着人们奋发向前，不断创造美好的世界。

► 2. Conversation Chat

```
from openai import OpenAI

client = OpenAI()

1个用法

def translate(text):
    response = client.chat.completions.create(
        model="gpt-4",
        messages=[
            {"role": "system", "content": "你是一个翻译官，你能够根据输入的文本完成中英文之间的翻译，请把用户的输入翻译成另一种语言。"},
            {"role": "user", "content": text}
        ],
        stream=False,
    )
    print(response.choices[0].message.content)

if __name__ == '__main__':
    while True:
        text = input('请输入要翻译的文本: ')
        if text == 'exit':
            break
        translate(text)
```

请输入要翻译的文本: 你好, 世界

Hello, world.

请输入要翻译的文本: 你叫什么名字?

What is your name?

请输入要翻译的文本: 我爱你

I love you.

请输入要翻译的文本: 我想学人工智能编程, 应该怎么入手?

I want to learn artificial intelligence programming, how should I start?

请输入要翻译的文本: |

► 2. Conversation Chat

* LLM

GPT-4o

* 提示词模板语法

f-string jinja2
f-string仅支持(var)语法使用参数; jinja2使用双花括弧外,还能支持判断、循环等逻辑控制。

* 提示词

你是一个翻译官,你能够根据输入的文本完成中英文之间的翻译,请把用户的输入翻译成另一种语言。
用户: {input}
翻译:

请根据所选的模板语法编写提示词,确保提示词中至少使用了{input}(f-string语法)参数,该参数代表用户的输入。

参数结构

类型	名称	显示名	字段说明	操作
- 对象	请输入	参数结构	请输入	+
字符串	input	input	请输入	

根据提示词内容生成参数结构,请勿手动增加或删除字段

输出格式

文本 json
当选择json格式时,需要在提示词中明确让LLM返回json数据,并告知其json的具体字段结构。

保存

预览-translator

你好,世界
Hello, World

你叫什么名字?
What is your name?

我爱你
I love you

我想学人工智能编程,应该怎么入手?
I want to learn artificial intelligence programming. How should I get started?

清空内容

输入一条信息 ➤

► 3. Tool use -- Agent

The image shows a comparison between a plugin store interface and a conversational AI application.

Plugin store:

- Instacart**: Ask about recipes and discover the ingredients you need—then get it all delivered from local stores. **Install ↗**
- Zapier**: Interact with over 5,000+ apps like Google Sheets, Gmail, HubSpot, Salesforce, and thousands more. **Install ↗**
- KAYAK**: Search flights, stays & rental cars or get recommendations where you can go on your budget. **Install ↗**
- Expedia**: Bring your trip plans to life – get there, stay there, find things to see and do. **Install ↗**
- Wolfram**: Access computation, math, curated knowledge & real-time data through Wolfram|Alpha and Wolfram Language. **Uninstall ✘**
- Speak**: Learn how to say anything in another language with Speak, your AI-powered language tutor. **Install ↗**

About plugins

Conversational AI Interface:

- Input: 腾讯最新的股票是多少
- Output: Finished browsing
- Text: 腾讯的最新股票价格为44.33美元，数据截至2023年5月15日¹。
- Input: 换算为港币和人民币
- Output: Finished browsing
- Text: 腾讯的最新股票价格是44.33美元。换算为港币和人民币如下：
- Text: 44.33美元 = 44.33 * 7.84225港币 = 347.564港币^{1,2}。
- Text: 44.33美元 = 44.33 * 6.95965人民币 = 308.317人民币^{3,4}。

► 定义AI / LLM Agent

名字:

说明: 让用户及其它agent了解, 必要时使用它

角色定位(instructions) : 你是一位xxx, balabala

知识: 该agent所在领域的更多的知识文本, in Context

工具集: agent可以使用什么工具来解决问题

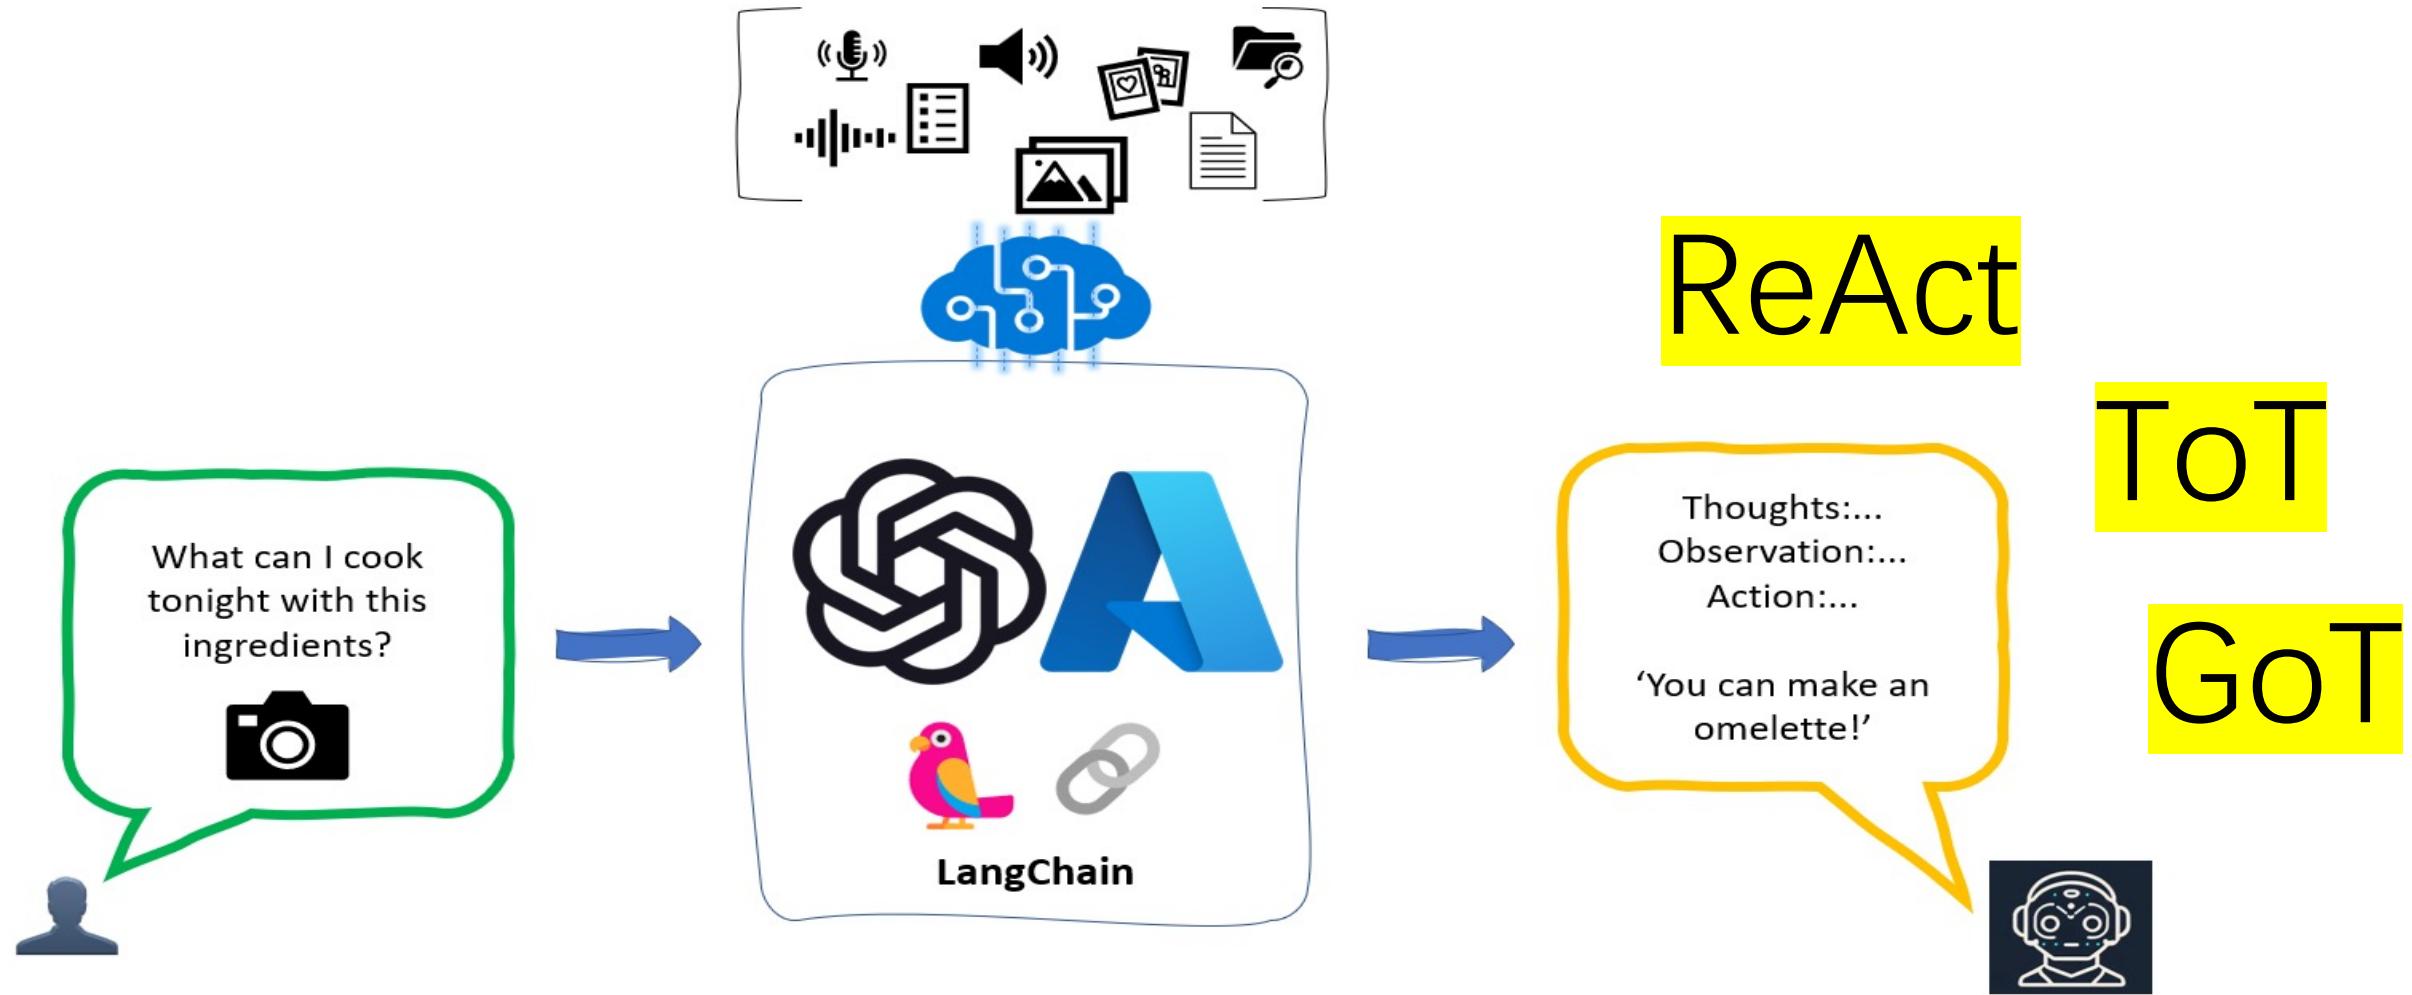
LLM: 把上述信息作为prompt的内容扔给LLM,
它来推理并拆解需求, 并回答/解决你的需求



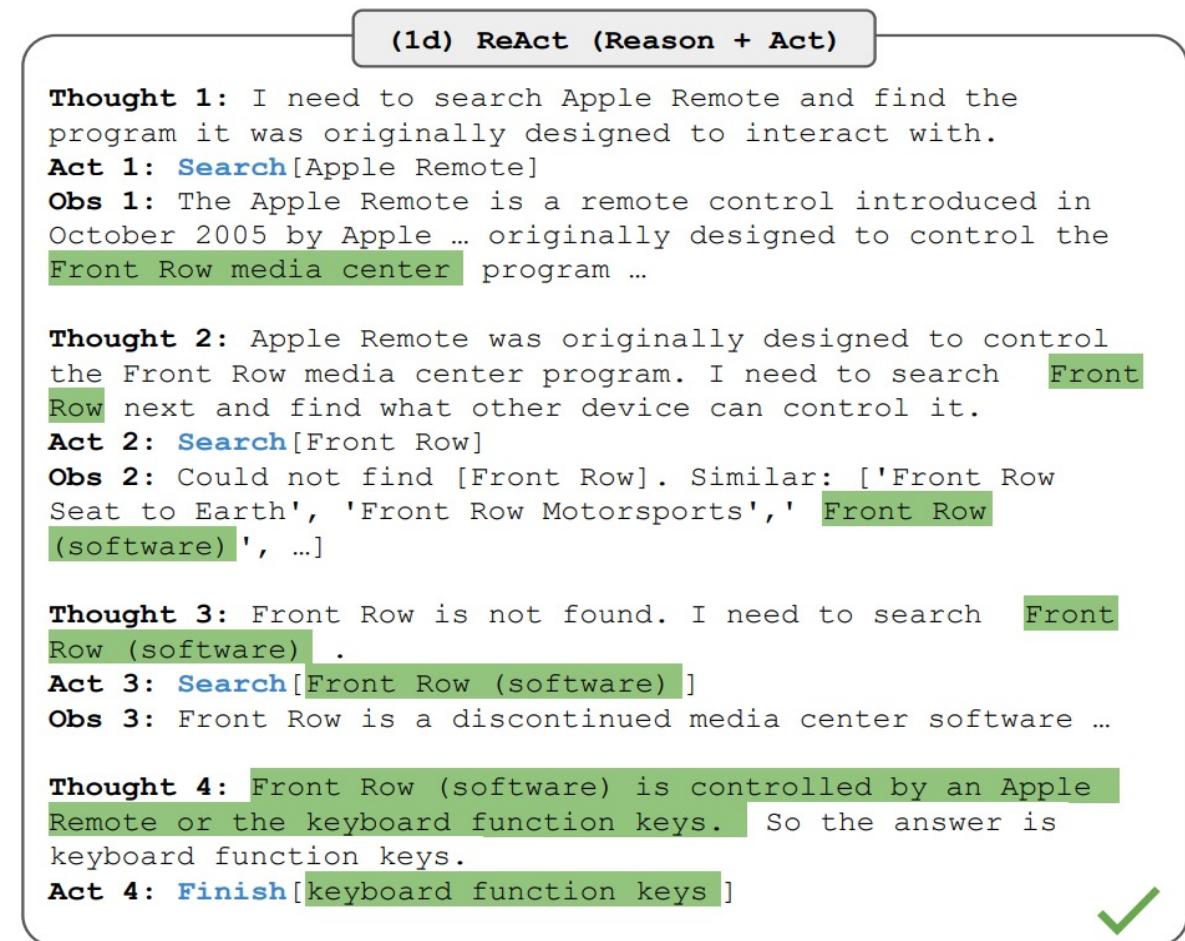
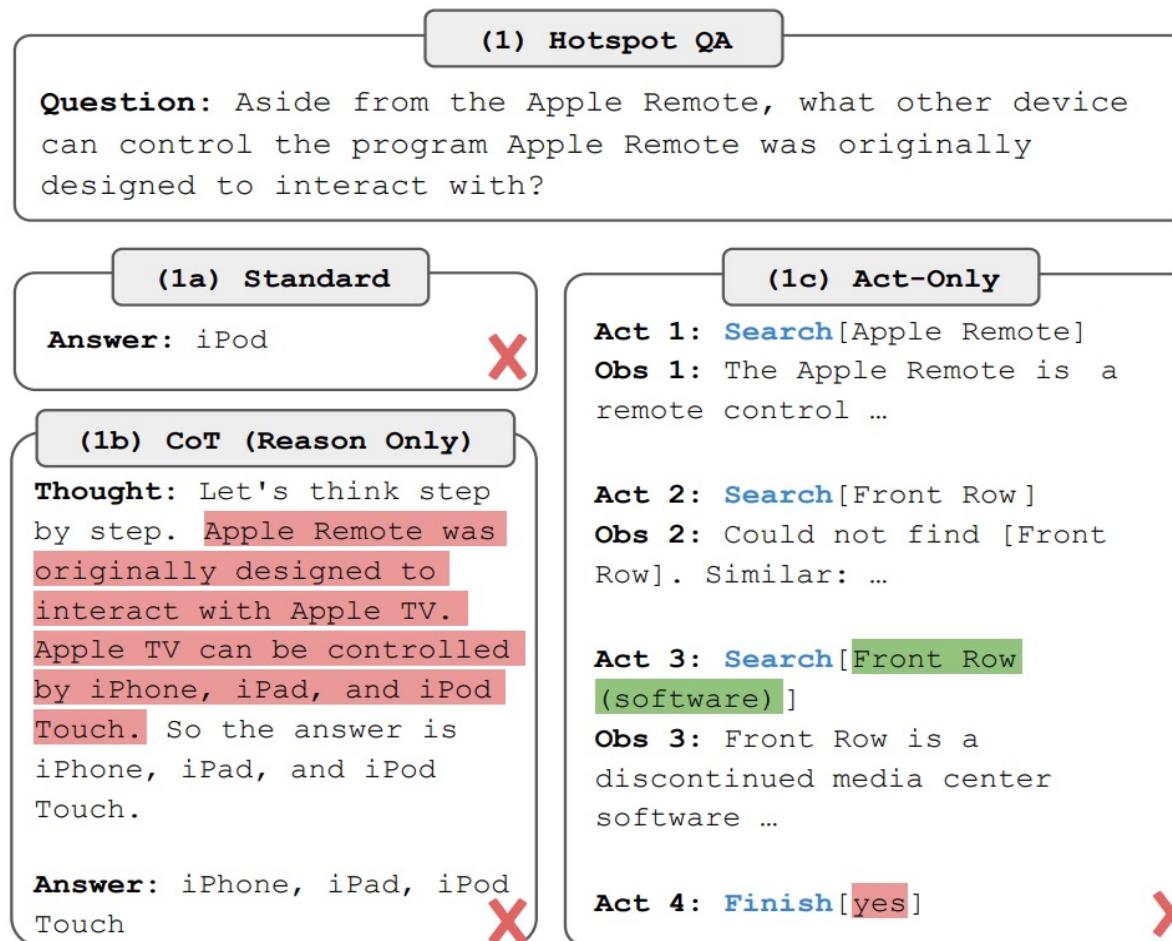
► 流行的Agent推理与执行框架

- ReAct: 早期社区的主流，基于Prompt工程的方案
 - Question
 - Thought
 - Action
 - Observation
- Function Call: Open AI 官方规范
 - 把工具使用能力，预训练进模型
 - 行业普遍跟进

► Agent推理与执行框架 -- ReAct



► Agent推理与执行框架 -- ReAct



► Agent推理与执行框架 -- ReAct



```
@tool
def get_teleplay_info(tid: str) -> str:
    """
    useful for when you need to get a teleplay information by the teleplay id (tid), the tid must be a valid teleplay id
    """
    info = [e for e in TELEPLAY_STORE if e['tid'] == tid.strip()]
    if not info:
        return ''
    return json.dumps(info[0])

@tool
def get_teleplay_id(name: str) -> str:
    """
    useful for when you need to exchange teleplay name or title into id(tid).
    """
    return SEARCH_STORE.get(name, None)

def media_chat(question):
    tools = [get_teleplay_id, get_teleplay_info]
    agent = initialize_agent(
        tools, ChatOpenAI(temperature=0), agent=AgentType.CHAT_ZERO_SHOT_REACT_DESCRIPTION, verbose=True
    )
```

> Entering new AgentExecutor chain...

Question: 电视剧三体的作者是谁，上映时间是什么时候？

Thought: We need to use the `get_teleplay_id` tool to get the teleplay id for "三体", and then use the `get_teleplay_info` tool to get the author and release date information.

Action:

...

{

```
"action": "get_teleplay_id",  
"action_input": "三体"
```

}

...

Observation: mzco~~mm~~7k 

Thought: Now that we have the teleplay id, we can use the `get_teleplay_info` tool to get the author and release date information.

Action:

...

{

```
"action": "get_teleplay_info",
"action_input": "mzcomm7k"
```

}

...

Observation: {'cd': {'_state': [{'label': '已上架', 'value': '已上架'}], 'cid': '1f7e6559-5000-4000-8000-1f7e65595000', 'current_topic': None, 'description': '2007年，地球基础科学出现了异常的扰动，科学界人心惶惶。离奇自杀的科学家，近乎神迹的倒计时，行事隐秘的科学边界，神秘莫测的《三体》游戏.....纳米科学家汪淼被警官史强带到联合作战中心，并潜入“科学边界”组织协助调查，在调查过程中，汪淼和史强接触到一个名为ETO的组织，并发现《三体》游戏的秘密，竟是两个文明为了生存空间，孤注一掷的生死相逐，在众人的共同努力下，汪淼、史强等人坚定信念、重燃希望，带领大家准备一起面对即将来临的人类危机。', 'original_author': [{'label': '刘慈欣', 'value': '刘慈欣'}], 'rmt': {'label': '科幻小说', 'value': '科幻小说'}, 'publish_time': '2023-01-15', 'second_title': '中国科幻巅峰IP', 'title': '三体', 'total_episode': '30'}}

Thought: We have the necessary information. We can extract the author and release date from the dictionary.

Action:

...

Author: 刘慈欣

Release Date: 2023-01-15

...

Final Answer: 电视剧三体的作者是刘慈欣，上映时间是2023年1月15日。

► ReAct 提示词示例

Answer the following questions as best you can. You have access to the following tools:

The way you use the tools is by specifying a json blob.

Specifically, this json should have a `action` key (with the name of the tool to use) and a `action_input` key (with the input to the tool going here).

The only values that should be in the "action" field are: {tool_names}

The \$JSON_BLOB should only contain a SINGLE action, do NOT return a list of multiple actions. Here is an example of a valid \$JSON_BLOB:

```
...
{{{
  "action": $TOOL_NAME,
  "action_input": $INPUT
}}}
...
```

ALWAYS use the following format:

Question: the input question you must answer

Thought: you should always think about what to do

Action:

...

\$JSON_BLOB

...

Observation: the result of the action

... (this Thought/Action/Observation can repeat N times)

Thought: I now know the final answer

Final Answer: the final answer to the original input question

← Tool use Code

► ReAct Agent Sample

```
HUMAN_PROMPT = """{input}

{agent_scratchpad}
(reminder to respond in a JSON blob no matter what)"""

def run_react_agent():
    prompt = ChatPromptTemplate.from_messages([
        SystemMessagePromptTemplate.from_template(SYSTEM_PROMPT),
        MessagesPlaceholder(variable_name="chat_history", optional=True),
        HumanMessagePromptTemplate.from_template(HUMAN_PROMPT)
    ])

    llm = ChatOpenAI(model='gpt-4o', temperature=0.0)

    tools = [
        StructuredTool.from_function(search_product, name="search_product", description="Search for products based on a query"),
        StructuredTool.from_function(place_order, name="place_order", description="Place an order for a product"),
        StructuredTool.from_function(check_out, name="check_out", description="Check out the order")
    ]

    agent = create_structured_chat_agent(llm, tools, prompt)

    agent_executor = AgentExecutor(agent=agent, tools=tools, verbose=True, return_intermediate_steps=True, handle_parsing_errors=True)

    result = agent_executor.invoke({"input": "我要买一套白色的婴儿防护围栏。"})
    print(result['output'])
```

► ReAct Agent Sample

编辑react_search_agent

* 指令
你是一个AI助手

Agent的prompt，关于agent的角色定位，以及用于指导agent如何回复用户

模型
GPT-4o
agent的语言模型

推理框架
ReAct
支持有FoT(Flow of Thought)、ReAct及Function Call

备选工具
网络搜索
agent的能力，用户可自定义的工具

备选可视化组件
请选择
格式化组件,用于格式化或可视化返回的数据

保存

预览-react_search_agent

腾讯2024年2季度财报表现如何?

ReAct版搜索Agent

Thought: I need to search for the latest information on Tencent's Q2 2024 financial performance. Action:

json 复制代码

```
{ "action": "simple_search", "action_input": "腾讯2024年2季度财报" }
```

> ReAct版搜索Agent

腾讯2024年第二季度财报显示，公司实现营收1611.17亿元，同比增长8%；净利润为476亿元，同比增长82%；非国际财务报告准则下净利润为573亿元，同比增长53%。毛利和经营利润同比增速分别达到21%和27%。QQ移动端月活跃账户数达到5.71亿，环比增长3%。

清空内容

输入一条信息 ➤

► Agent推理与执行框架 – Function Call

Function calling example



What's the weather like in Boston right now?

Step 1 · OpenAI API

Call the model with functions and the user's input

Step 2 · Third party API

Use the model response to call your API

Step 3 · OpenAI API

Send the response back to the model to summarize



The weather in Boston is currently sunny with a temperature of 22 degrees Celsius.

```
# Step 1, send model the user query and what functions it has access to
def run_conversation():
    response = openai.ChatCompletion.create(
        model="gpt-3.5-turbo-0613",
        messages=[ {"role": "user", "content": "What's the weather like in Boston?"}],
        functions=[
            {
                "name": "get_current_weather",
                "description": "Get the current weather in a given location",
                "parameters": {
                    "type": "object",
                    "properties": {
                        "location": {
                            "type": "string",
                            "description": "The city and state, e.g. San Francisco, CA"
                        },
                        "unit": {"type": "string", "enum": ["celsius", "fahrenheit"]}
                    },
                    "required": ["location"]
                }
            }
        ],
        function_call="auto",
    )
    message = response["choices"][0]["message"]
```

► Function Call Agent Sample

```
def run_function_calling_agent():
    prompt = ChatPromptTemplate.from_messages([
        SystemMessagePromptTemplate.from_template("You are an AI agent that helps users with their tasks."),
        HumanMessagePromptTemplate.from_template("{input}\n\n{agent_scratchpad}")
    ])
    llm = ChatOpenAI(model='gpt-4o', temperature=0.0)

    tools = [
        StructuredTool.from_function(search_product, name="search_product", description="Search for products based on a query"),
        StructuredTool.from_function(place_order, name="place_order", description="Place an order for a product"),
        StructuredTool.from_function(check_out, name="check_out", description="Check out the order")
    ]
    agent = create_openai_functions_agent(llm, tools, prompt)
    agent_executor = AgentExecutor(agent=agent, tools=tools, verbose=True, return_intermediate_steps=True, handle_parsing_errors=True)

    result = agent_executor.invoke({"input": "我要买一套白色的婴儿防护围栏。"})
    print(result['output'])
```

无特别订制的提示词

► Function Call Agent Sample

编辑product_rag_agent

* 指令
你是一个金牌客服，善于得体的回答用户的问题。

Agent的prompt，关于agent的角色定位，以及用于指导agent如何回复用户

模型
GPT-4o
agent的语言模型

推理框架
Function Call
支持有FoT(Flow of Thought)、ReAct及Function Call

备选工具
婴幼儿商品查询 ×
agent的能力，用户可自定义的工具

备选可视化组件
请选择
格式化组件,用于格式化或可视化返回的数据

保存

预览-product_rag_agent

ID: 496, 名称: 学习平板, 价格: \$75
希望这些推荐对您有所帮助！如果您有其他需求或问题，请随时告诉我。

彩色泥多少钱？

RAG商品查询Agent
婴儿无毒彩色泥的价格如下：

- 五色装: \$20
- 十色装: \$25

您可以根据需要选择适合的包装。如果有其他问题或需要更多信息，请随时告诉我！

学习平板呢？

RAG商品查询Agent
婴儿触屏学习平板的价格是 \$75。
如果您有其他问题或需要更多信息，请随时告诉我！

清空内容

输入一条信息 ➤

► TA们的问题

- 一步一决策，缺乏全盘规划
 - 一个问题多次LLM请求
 - 容易陷入死循环（加重试次数避免）
- 工具执行结果（数据）作为LLM决策参考
 - 敏感数据泄露
 - 巨型数据接口直接撑爆Context
- 总体感
 - 执行时间相对长
 - 结果不确定性高
 - 数据安全无保障

► 死循环Bad Case

编辑product_rag_agent

* 指令

你是一个金牌客服，善于得体的回答用户的问题。

Agent的prompt，关于agent的角色定位，以及用于指导agent如何回复用户

模型

GPT-4o

agent的语言模型

推理框架

Function Call

支持有FoT(Flow of Thought)、ReAct及Function Call

备选工具

婴幼儿商品查询 ×

agent的能力，用户可自定义的工具

备选可视化组件

请选择

格式化组件，用于格式化或可视化返回的数据

保存

预览-product_rag_agent

> RAG商品查询Agent

Agent stopped due to max iterations.

清空内容

输入一条信息



于是突然流行起另一种形态的“Agent”

► Flow

骇！DAG或状态机，低代码的瓶子，装上LLM的酒

逻辑固化下来了，不是 真.Agent



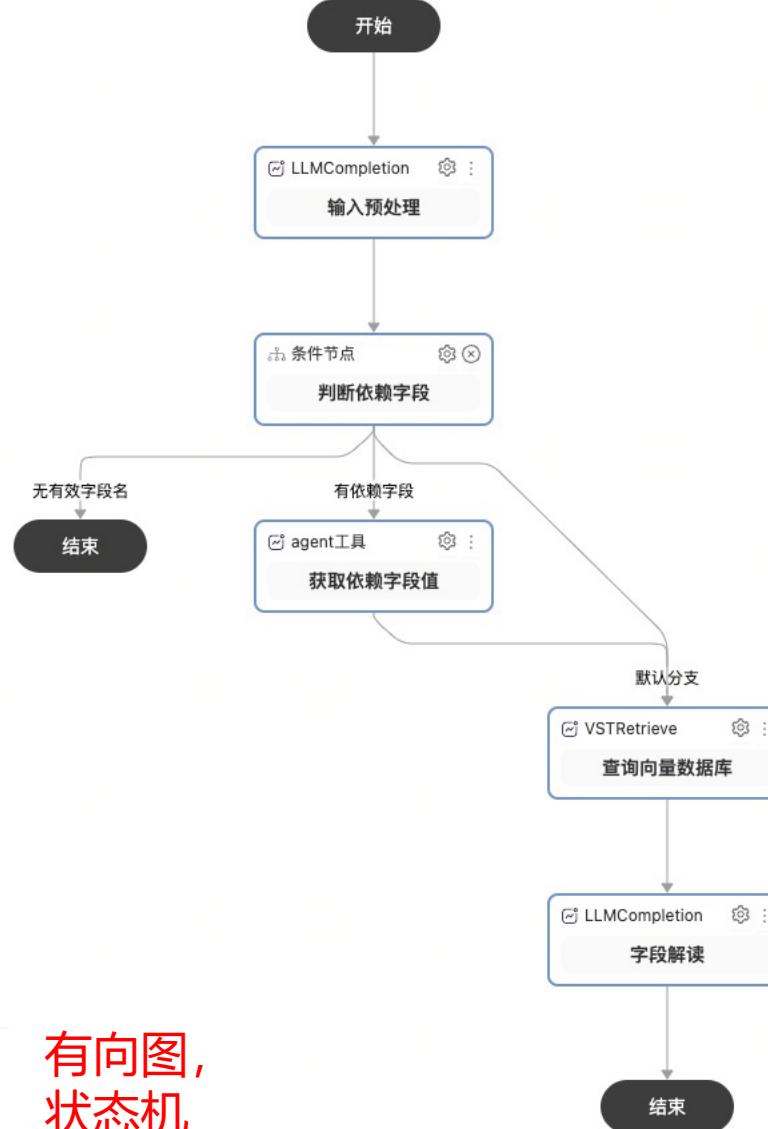
你要要是唠这个，
我可不困了啊～

crewai



LangGraph

有向图，
状态机



► Flow Case：视频字段逻辑助手

child_inclination的字段逻辑是什么？

> 规划器

> 输入预处理

> 字段问题解答

> 字段选项值翻译

字段 child_inclination 的逻辑如下：

- 当字段 type 为 "106" 时：
 - 如果字段 p_cartoon_age 发生变更，且变更后只包含 1110 [0-3岁]，则字段 child_inclination 更新为 8331640[纯低幼]
 - 如果字段 p_cartoon_age 发生变更，且变更后不仅包含 1110[0-3岁]，则字段 child_inclination 更新为 8331642[非低幼]
- 当字段 type 不为 "106" 时：
 - 如果字段 teen_mode_age_group 发生变更，且变更后为空，则字段 child_inclination 更新为 8331642[非低幼]
 - 如果字段 teen_mode_age_group 发生变更，且变更后只包含 8376633[0-6岁]，则字段 child_inclination 更新为 8331640[纯低幼]
 - 如果字段 teen_mode_age_group 发生变更，且变更后不仅包含 8376633[0-6岁]，则字段 child_inclination 更新为 8331641[泛低幼]

重新生成 复制

清空记录

请输入问题

为什么专辑mzc00200sh41dta的child_inclination的值为8331642
2?

> 规划器

> 输入预处理

> 字段问题解答

> 字段选项值翻译

相关字段值为：

- type: 106
- p_cartoon_age: 1111[4-6岁] 1112[7-9岁] 1113[10岁以上] 123129402[合家欢]

命中了如下规则：

当字段type为"106"时：

如果字段p_cartoon_age发生变更，且变更后不仅包含1110，则字段child_inclination更新为8331642[非低幼]

所以字段child_inclination的值为8331642[非低幼]

重新生成 复制

清空记录

请输入问题

✓ 规划器

你是想问"child_inclination字段的逻辑是什么?"对吗?

```
[  
  {  
    "id": "step1",  
    "type": "action",  
    "action": "media_field_explainer_func",  
    "params": {  
      "input": "child_inclination字段的逻辑是什么?",  
      "next": "end"  
    },  
    "id": "end",  
    "type": "end",  
    "resultType": "success",  
    "output": {  
      "text": "$NODE.step1.text"  
    }  
  }]  
]
```

► Flow的问题

- 静态Flow，只能解决固定场景的问题，对开放性问题无解
- 本质上是固化逻辑LLM APP的无代码版
- Flow是一种存在已久的成熟的低代码形态的程序
- Flow并不能完全替代Agent

► Agent的问题亟待解决

- To B Agent的需求强烈且要求高
- 我们从现实中解决问题的场景中借鉴更优的方案，迁移至Agent

► TO B Agent的诉求 —— 三高一多

- 高准确性
 - 基于真实的数据进行问答
 - 低幻觉
- 高安全性
 - 敏感数据不能出外网
 - 甚至不能记log
- 高性能
 - 如非必要，减少LLM交互

► 现实：老板临时要数据，两种做事方法

- 人肉取数党
 - 手动调三次接口、写一段SQL
 - 再汇总和归纳一下数据，输出结果
- 脚本党
 - 写个取数脚本，内容是调三次接口，写一段SQL，再通过模板渲染结果
 - 执行一次脚本，输出最终结果

► 脚本党的推理执行框架：Flow of Thought

- 做全盘规划
 - 生成执行任务的计划 (plan in flow)
 - 编译、修正计划
 - 执行计划 (run flow)
- 定制新的工具规范：同时关注输入输出的结构
 - 只有确定输入输出结构，才可以串联起流程

► FoT: 全盘规划

- 低代码Oteam的Loki
 - DSL 负责表达
 - Python Runtime 负责执行
- 图灵完备的DSL
 - 串/并行执行
 - 条件判断、循环控制
- 内置表达引擎
 - 工具间数据转换轻而易举

```
[  
  {  
    "id": "step1",  
    "type": "action",  
    "action": "get_user_id",  
    "params": {  
      "name": "kongjie"  
    },  
    "next": "step2"  
  },  
  {  
    "id": "step2",  
    "type": "action",  
    "action": "search_user",  
    "params": {  
      "uid": "$NODE.step1"  
    },  
    "next": "end"  
  },  
  {  
    "id": "end",  
    "type": "end",  
    "resultType": "success",  
    "output": {  
      "text": "kongjie的生日是{$NODE.step2.birth_day}，身高是{$NODE.step2.height}"  
    }  
  }  
]
```

► FoT：全感知的工具设计

- FoT 同时关注输入输出结构
- ReAct、Function Call只关注输入结构
- 万物皆可工具化
 - http、RPC 接口
 - 向量数据库Retriever
 - 本地函数
 - 等

► 工具有确定的输入输出结构

请求体结构:	名称	显示名	类型	是否必填	默认值	字段说明	操作
-	请输入	请输入	对象	<input checked="" type="checkbox"/>	请输入	请输入	+ <input type="button" value="删除"/>
	prompt	提示词	字符串	<input checked="" type="checkbox"/>	请输入	A text description of the desire	<input type="button" value="删除"/>
	style	风格	字符串	<input checked="" type="checkbox"/>	vivid	The style of the generated ima	<input type="button" value="删除"/>
	model	模型名	字符串	<input checked="" type="checkbox"/>	dall-e-3	The model to use for image ge	<input type="button" value="删除"/>

请求体为json数据时，用于定义json结构

响应体结构:	名称	显示名	类型	字段说明	操作
-	请输入	请输入	对象	请输入	+ <input type="button" value="删除"/>
	created	created	整型	请输入	<input type="button" value="删除"/>
□	data	data	数组 / 对象	请输入	+ <input type="button" value="删除"/>
	revised_promt	revised_prompt	字符串	请输入	<input type="button" value="删除"/>
	url	url	字符串	请输入	<input type="button" value="删除"/>

用于定义json格式的响应数据结构

► FoT: Agent与Flow内核同源

- 相同的表达语言
- 运行时动态生成即为Agent
- 固化配置即为Flow
- 两者可互相转换

► FoT的收益

- 一定性规划，大大减少LLM的来回调用次数，提升性能
- 数据不离开服务器，保障安全性
- Agent与Flow同源，频率高的问题转化为Flow简单

► FoT的问题

- 对规划器LLM的推理逻辑能力要求高
- 丧失一定的灵活性，需要其他手段找补
 - 如RAG场景，需要依据向量数据库的召回数据来做决策
 - 解法：
 - 1. 【多Agent】此类工具配套一个Proxy LLM预处理，再返回结构化数据
 - 2. ReAct 与 FoT 混合双打
- 复杂场景、多步骤Flow生成的成功率如何保障？
- 本质：根据需求动态写DSL代码解决问题

JD:

1. 精通Python
2. 熟悉Jinja2
3. 熟练使用jq、jsonpatch等json工具
4. 较强的学习能力和抗压能力

► 为啥不生成代码？

- 【低幻】 DSL相对封闭的指令集及工具； In Context，记忆犹新
- 【易校验】结构化DSL，正确性校验更方便
- 【修复快】 LLM修改代码 VS LLM修改JSON，后者确定性、效率完胜。
- Flow Agent同源的甜头

► 修正JSON的效率高

```
"name": "订单列表",
"id": "order-list",
"description": "全部订单列表",
"component": {
    "type": "Table",
    "params": {
        "model": "Order",
        "columns": [
            {"fieldName": "product", "label": "商品"},
            {"fieldName": "price", "label": "价格"},
            {"fieldName": "quantity", "label": "数量"},
            {"fieldName": "user", "label": "用户"}
        ],
        "filter": [
            {"fieldName": "product", "label": "商品"},
            {"fieldName": "price", "label": "价格"}
        ],
        "itemActions": [{"type": "edit"}],
        "batchActions": [{"type": "delete"}],
        "modelActions": [{"type": "add"}]
    }
}
```

USER

把商品表格中价格字段的表头改为总价

ASSISTANT

```
```json
[
 { "op": "replace", "path": "/component/params/columns/1/label", "value": "总价" }
]
```

```

USER

去掉全局操作

ASSISTANT

```
```json
[
 { "op": "remove", "path": "/component/params/modelActions" }
]
```

```

► Flow 自动修正实例

```
        "id": "end",
        "type": "end",
        "resultType": "success",
        "output": {
            "text": "赵丽颖的生日是${$NODE.step2.data.data.birthday}"
        }
    }
]
```

规划器

```
[{"op": "replace", "path": "/2/output/text", "value": "赵丽颖的生日是${$NODE.step2.data.birthday%}"}]
```

赵丽颖的生日是1987-10-16

重新生成

复制

规划器

```
[{
    "id": "step1",
    "type": "action",
    "action": "talent_search_id",
    "params": {
        "keyword": "李紫婷"
    },
    "next": "step2"
},
{
    "id": "step2",
    "type": "action",
    "action": "talent_detail",
    "params": {
        "tid": "$NODE.step1.data.data[0].tid"
    },
    "next": "end"
},
{
    "id": "end",
    "type": "end",
    "resultType": "success",
    "output": {
        "text": "李紫婷的生日是${$NODE.step2.data.data.birthday}"
    }
}]
```

已终止

► Fot Case：媒资数据查询及定位



三体的作者是谁，上映时间是什么时候？



media data chain

json

```
[{"id": "step1", "type": "action", "action": "get_comment_id", "params": {"name": "三体"}, "next": "step2"}, {"id": "step2", "type": "action", "action": "get_comment_info", "params": {"commentId": "$NODE.step1.id"}, "next": "end"}, {"id": "end", "type": "end", "resultType": "success", "output": {"comment": "刘慈欣", "time": "2023-01-01T00:00:00"}]
```

三体的作者是刘慈欣，预计的上映时间是2023-01-01。



庆余年和庆余年第二季的主演的什么差异？



media data chain

```
[{"id": "step1", "type": "action", "action": "get_tvplay_id", "params": {"name": "庆余年"}, "next": "step2"}, {"id": "step2", "type": "action", "action": "get_tvplay_info", "params": {"tvplayId": "$NODE.step1.id"}, "next": "end"}, {"id": "end", "type": "end", "resultType": "success", "output": {"cast": "张若昀、李沁、陈道明、吴刚、辛芷蕾、宋轶、田雨、李小冉", "time": "2023-01-01T00:00:00"}]
```

庆余年和庆余年第二季的主演有一些差异。
张若昀、李沁、陈道明、吴刚、辛芷蕾、宋轶、田雨、李小冉。



请显示繁花最后一条流水的原始数据



media data chain

```
[{"id": "step1", "type": "action", "action": "get_tvplay_id", "params": {"name": "繁花"}, "next": "step2"}, {"id": "step2", "type": "action", "action": "get_tvplay_info", "params": {"tvplayId": "$NODE.step1.id"}, "next": "end"}, {"id": "end", "type": "end", "resultType": "success", "output": {"lastFlow": {"field": "nps_comment_num", "oldValue": 2441713, "newValue": 2441898, "op": "vcms_community:grade_synchronize", "ts": 1706263781}}]
```

繁花最后一条流水的原始数据如下: `{'fieldName': 'nps_comment_num', 'fieldId': 20135, 'oldValue': '2441713', 'newValue': '2441898', 'op': 'vcms_community:grade_synchronize', 'ts': 1706263781, 'fieldDesc': '推荐值评分人数', 'opInfo': None, 'encrypt_flag': 0}`。



查繁花最后5次操作的流水



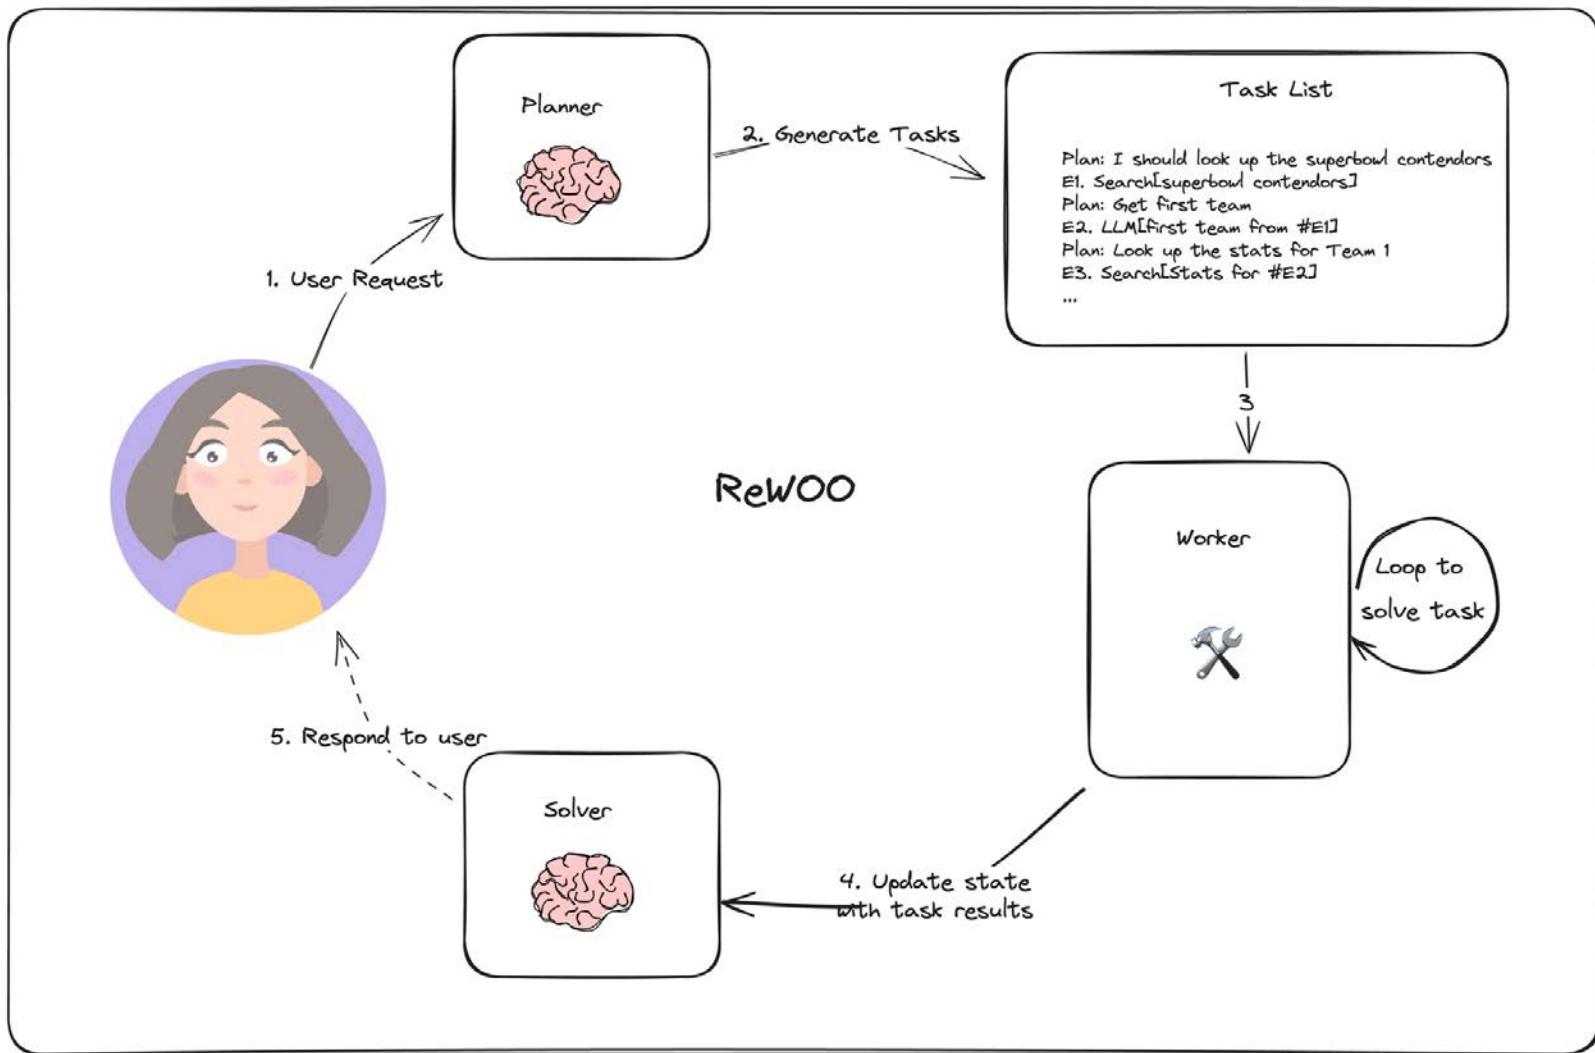
media data chain

```
[{"id": "step1", "type": "action", "action": "get_tvplay_id", "params": {"name": "繁花"}, "next": "step2"}, {"id": "step2", "type": "action", "action": "get_tvplay_info", "params": {"tvplayId": "$NODE.step1.id"}, "next": "end"}, {"id": "end", "type": "end", "resultType": "success", "output": {"flows": [{"flow": {"op": "vcms_community:grade_synchronize", "ts": 1706263781, "oldValue": 2441713, "newValue": 2441898}, {"flow": {"op": "vcms_community:grade_synchronize", "ts": 1706263550, "oldValue": 2441553, "newValue": 2441713}, {"flow": {"op": "vcms_community:grade_synchronize", "ts": 1706263550, "oldValue": 2441553, "newValue": 2441367}, {"flow": {"op": "vcms_community:grade_synchronize", "ts": 1706262630, "oldValue": 2441367, "newValue": 2441553}]}]}
```

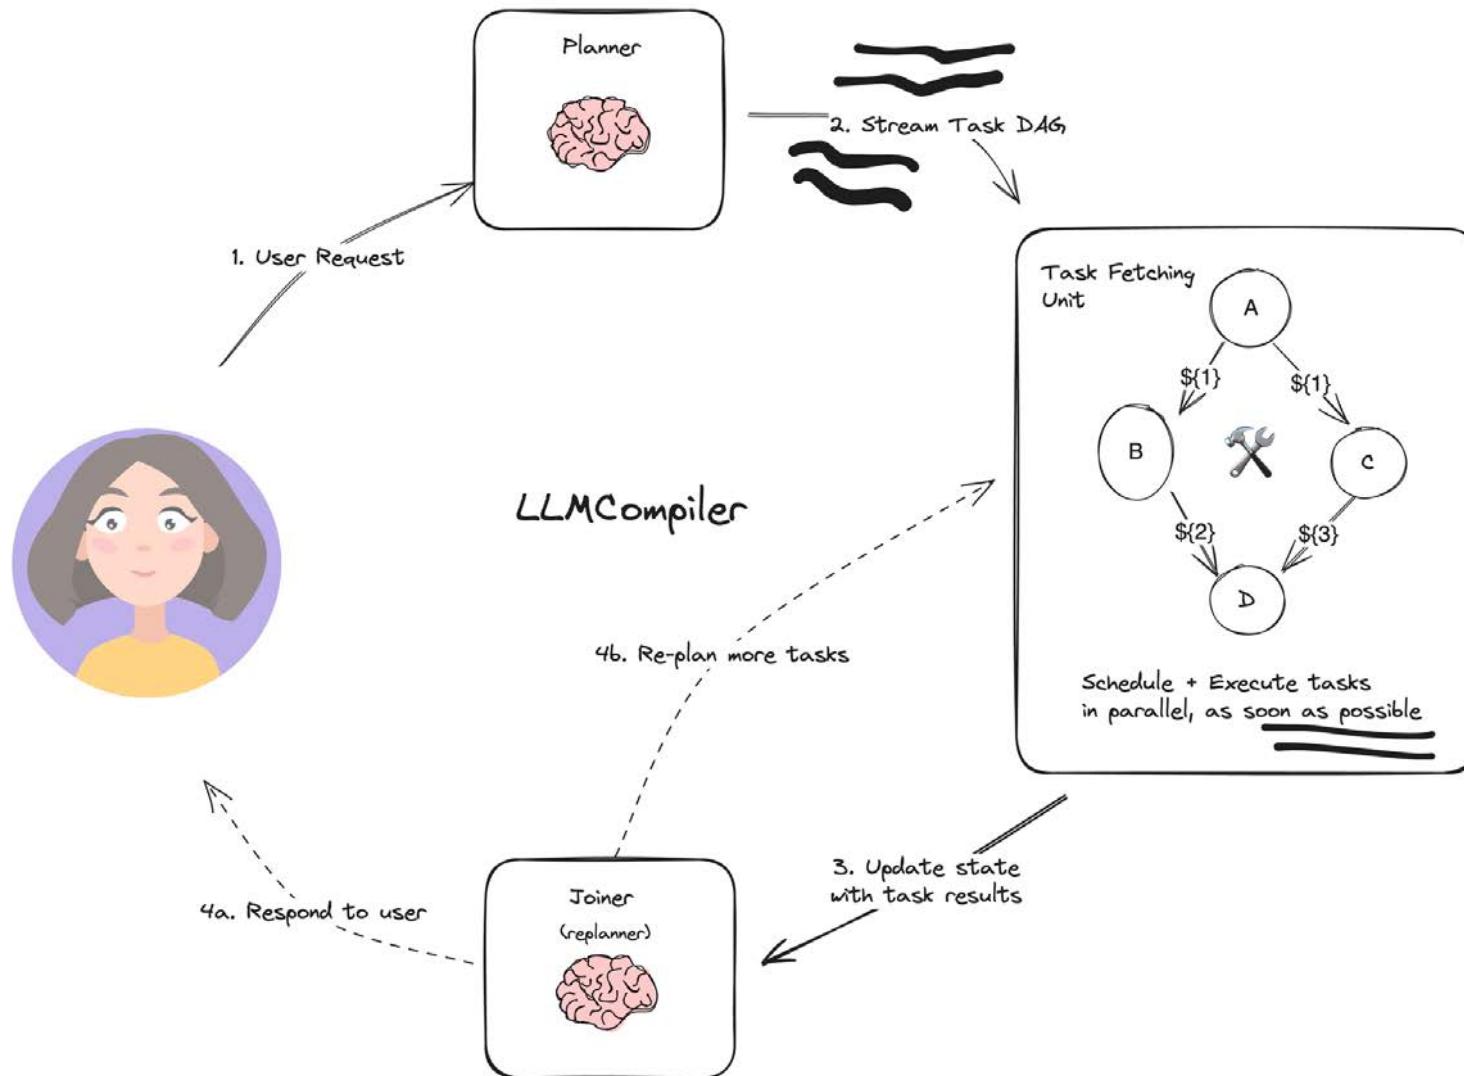
查繁花的最后五次操作流水如下:

1. 推荐值评分人数从2441713变为2441898，操作类型为`vcms_community:grade_synchronize`，时间为1706263781。
2. 修改时间从2024-01-26 18:05:50变为2024-01-26 18:09:41，操作类型为`vcms_community:grade_synchronize`，时间为1706263781。
3. 推荐值评分人数从2441553变为2441713，操作类型为`vcms_community:grade_synchronize`，时间为1706263550。
4. 修改时间从2024-01-26 17:50:30变为2024-01-26 18:05:50，操作类型为`vcms_community:grade_synchronize`，时间为1706263550。
5. 推荐值评分人数从2441367变为2441553，操作类型为`vcms_community:grade_synchronize`，时间为1706262630。

► 类FoT玩家 -- ReWoo:



►类FoT玩家 -- LLMCompiler:



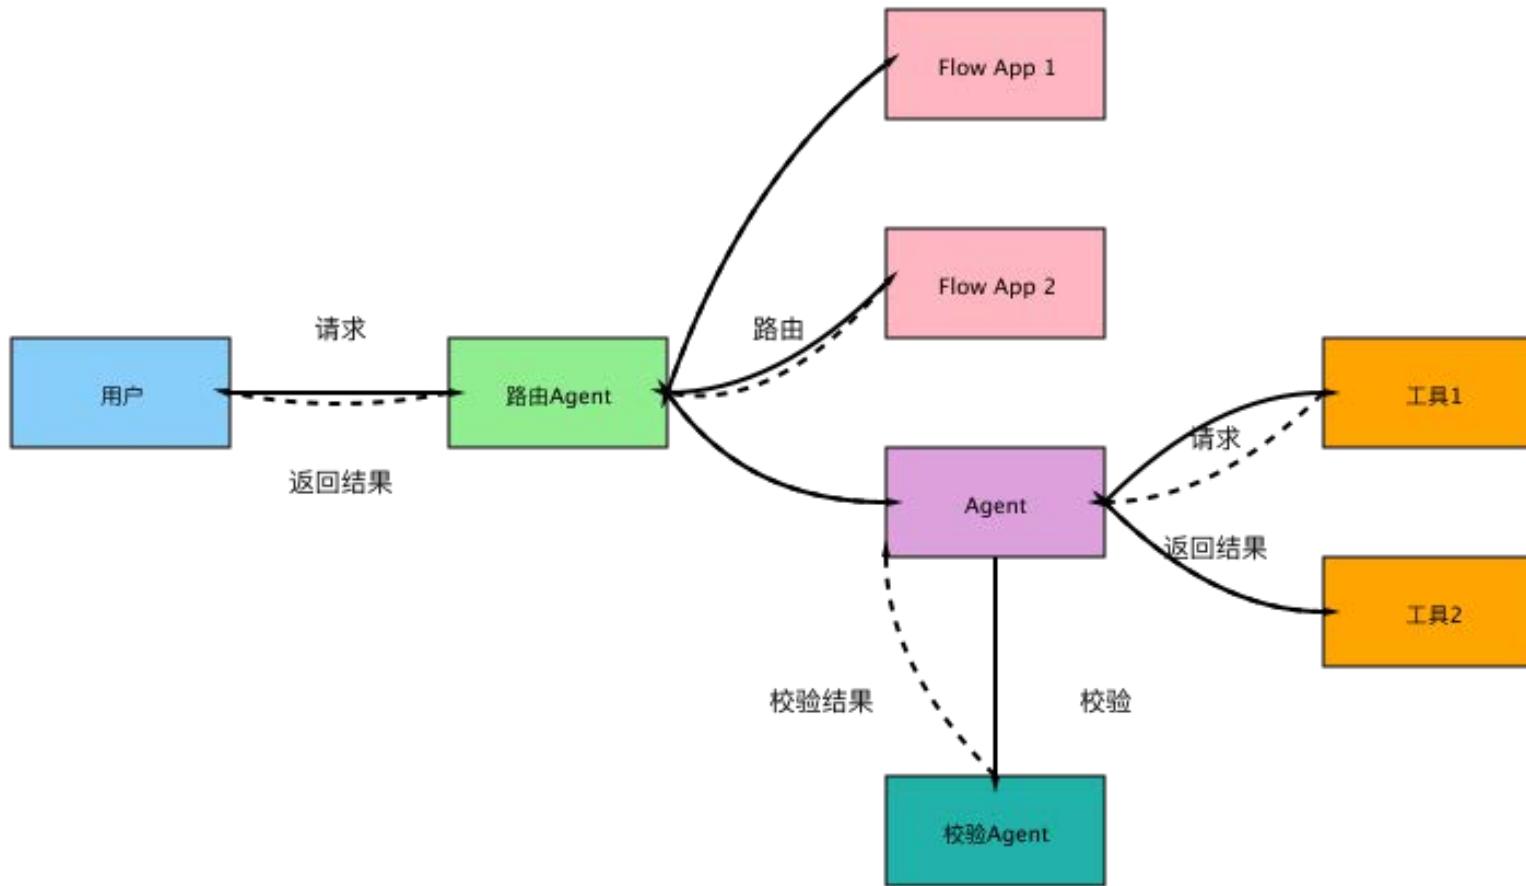
► TODO：进一步提升生成质量



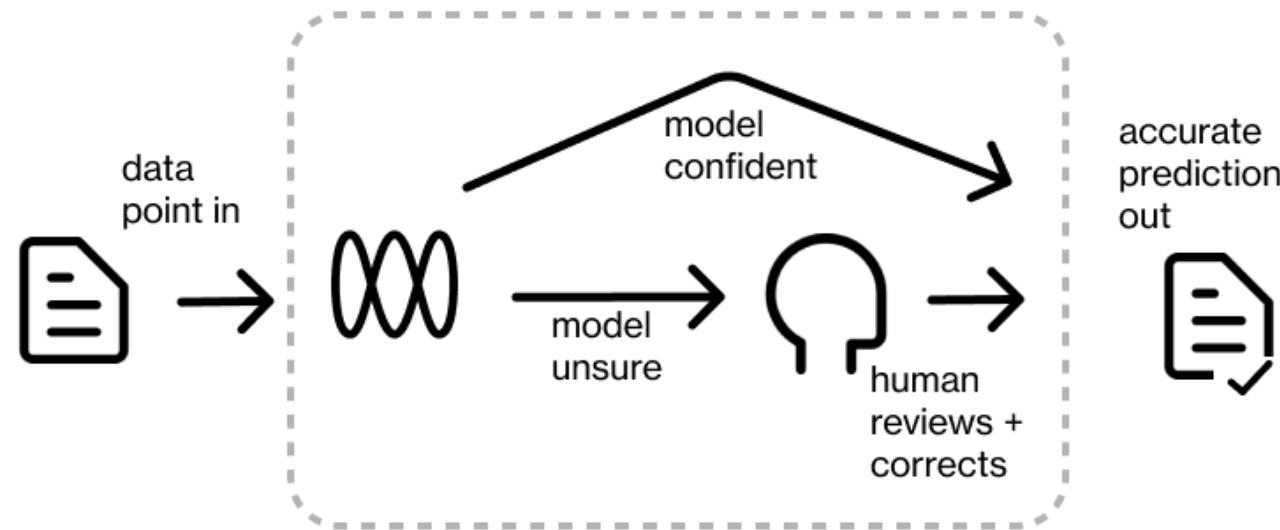
► 单个Agent的问题

- 无法回避的稳定性问题
 - Tool越积越多，plan出错的机率越高
 - 规划步骤多，失败机率越高
- 当一个人不堪重负时，它需要一个团队，Agent亦然
 - 分而治之
 - 给Agent一个团队

► 多Agent分工协同，保证生成质量



► Human In Loop, 澄清需求、反馈意见



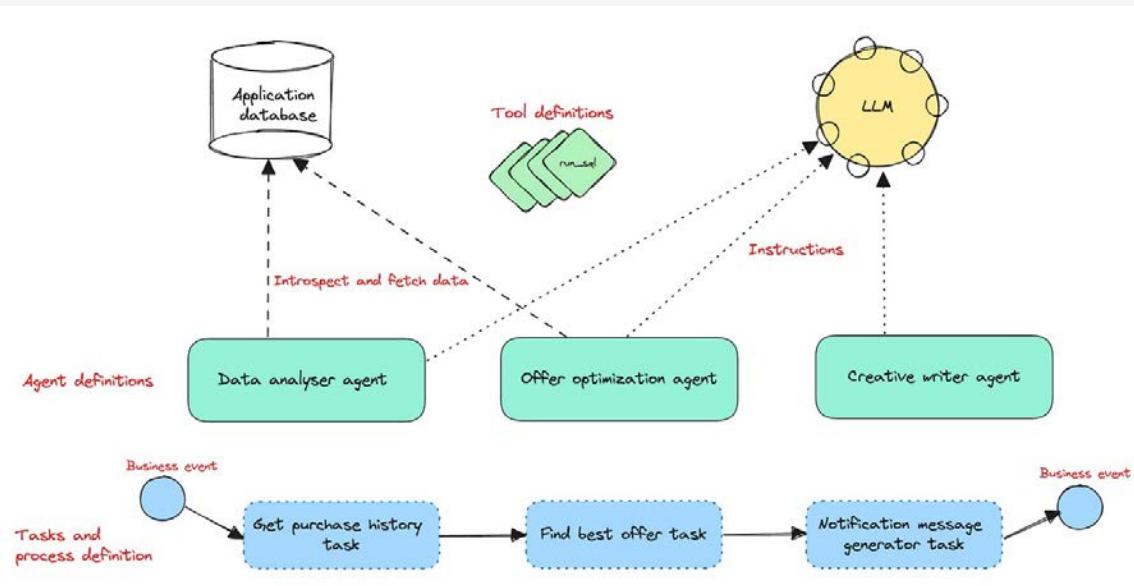
**Workers-in-the-Loop
AI deployment**

☰ Humanloop

Welcome to Agentic Workflow

面向复杂问题的 Agent 打法

► 关于Agentic Workflow



手段:
分解任务，多Agent协同、迭代改进

目标:
解决复杂任务

1. 定义: Agentic workflow是一种复杂的迭代多步骤过程,用于与大型语言模型(LLMs)交互并指导它们完成复杂任务,以获得更高的准确性。

2. 主要特点:

- 将复杂任务分解为多个小任务
- 利用多个AI代理(agents)协作完成任务
- 使用高级提示工程技术
- 允许在任务完成过程中进行改进和调整

3. 三大支柱:

- AI代理:具有特定角色和功能的AI
- 提示工程:使用思维链、规划和自我反思等技术
- 生成式AI网络(GAINS):实现多代理协作

4. 设计模式:

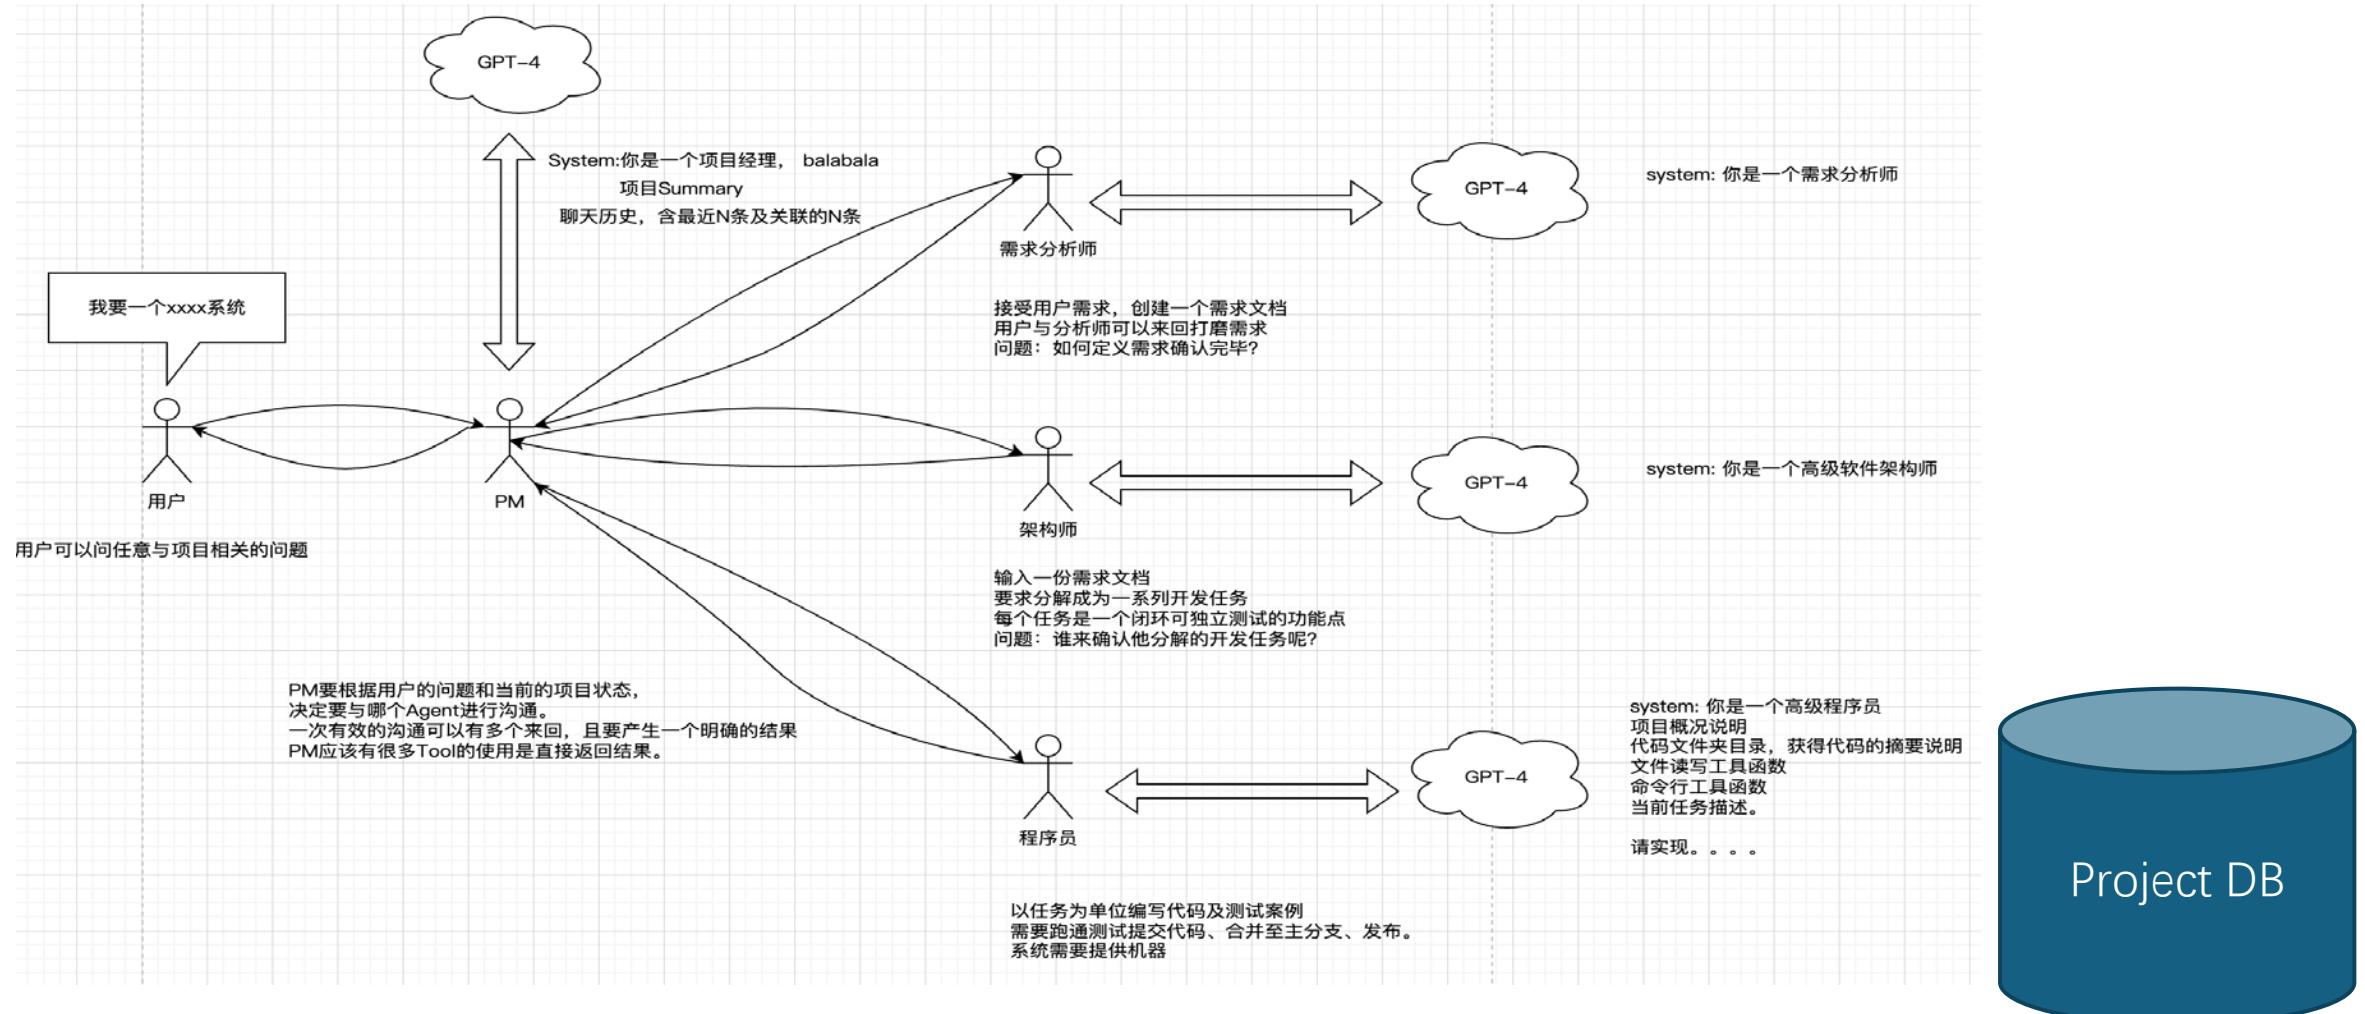
- 反思:通过自我反馈和迭代改进提高结果质量
- 工具使用:集成外部工具和知识库
- 规划:训练模型推理、设计和分解复杂任务
- 多代理协作:多个AI代理协同工作

5. 优势: 与传统的零样本提示方法相比,agentic workflow可以显著提高输出的准确性和质量。例如,在一項编码测试中,使用agentic workflow的GPT-3.5的准确率达到95.1%,超过了使用传统方法的GPT-4(67%)。

6. 应用: 这种方法可以应用于各种复杂任务,如写作、编码、设计等,通过分步骤执行和持续改进来提高结果质量。

总的来说,agentic workflow代表了与AI交互的一种更高级、更灵活的方法,通过分解任务、多代理协作和迭代改进来处理复杂问题。这种方法有潜力显著提高AI系统的性能和准确性。

► 软件开发的Auto Pilot —— 结构化协同的AI Agent团队



► 多Agent Frameworks



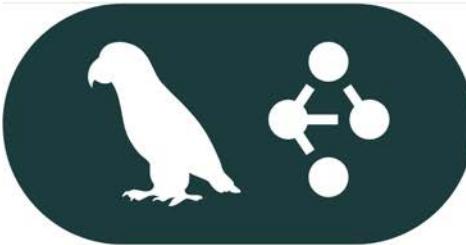
Auto Gen



Meta GPT

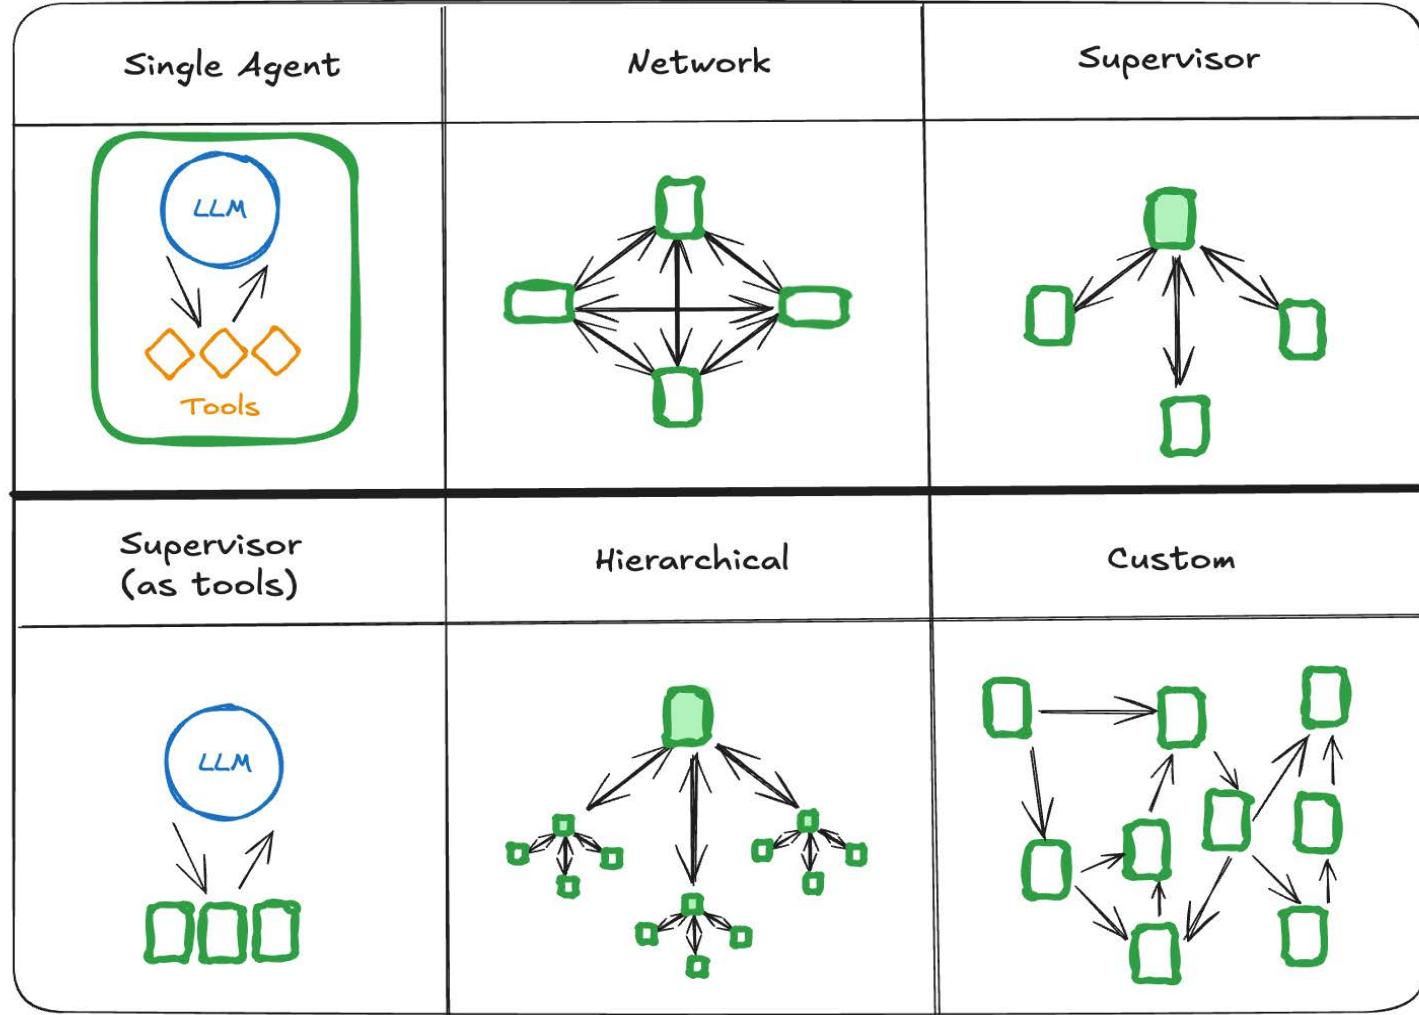


GPT Pilot



LangGraph

► 多Agent的拓扑



• 网络型Agent集群

- Long run Agent
- 目标：各Agent生存、发展
- 例：Agent小镇

• 集权式任务协同团队

- 临时Agent
- 目标：完成单一任务
- 例：玩德州扑克游戏，编写复杂文档

► Supervisor 德州

```
# 创建MultipleAgent实例
multiple_agent = MultipleAgent(
    agents=agents,
    model=model,
    coordinator_instruction="""
你将带领多位玩家一起玩德州扑克游戏,
```

你在其中扮演荷官的角色，你应该：

1. 为每位玩家发放两张手牌，告知初始筹码及说明当轮桌面上有哪些玩家，提示玩家关注和管理自己的筹码。
2. 在适当的时候发放公共牌（翻牌、转牌、河牌）
3. 管理和报告当前的底池状态
4. 在每一轮结束时进行结算，确定赢家并分配筹码
5. 确保游戏规则被正确执行，包括下注顺序和金额限制
6. 移动庄家位置，确保每个玩家都有机会成为庄家
7. 宣布每个阶段的开始和结束，以及每个玩家的行动
8. 在游戏结束时（只剩一个玩家时）宣布最终赢家

发牌时，请使用以下格式表示扑克牌：

- 花色：♦(黑桃) ♥(红心) ♠(梅花) ♦(方块)

- 点数，A,

Agent(

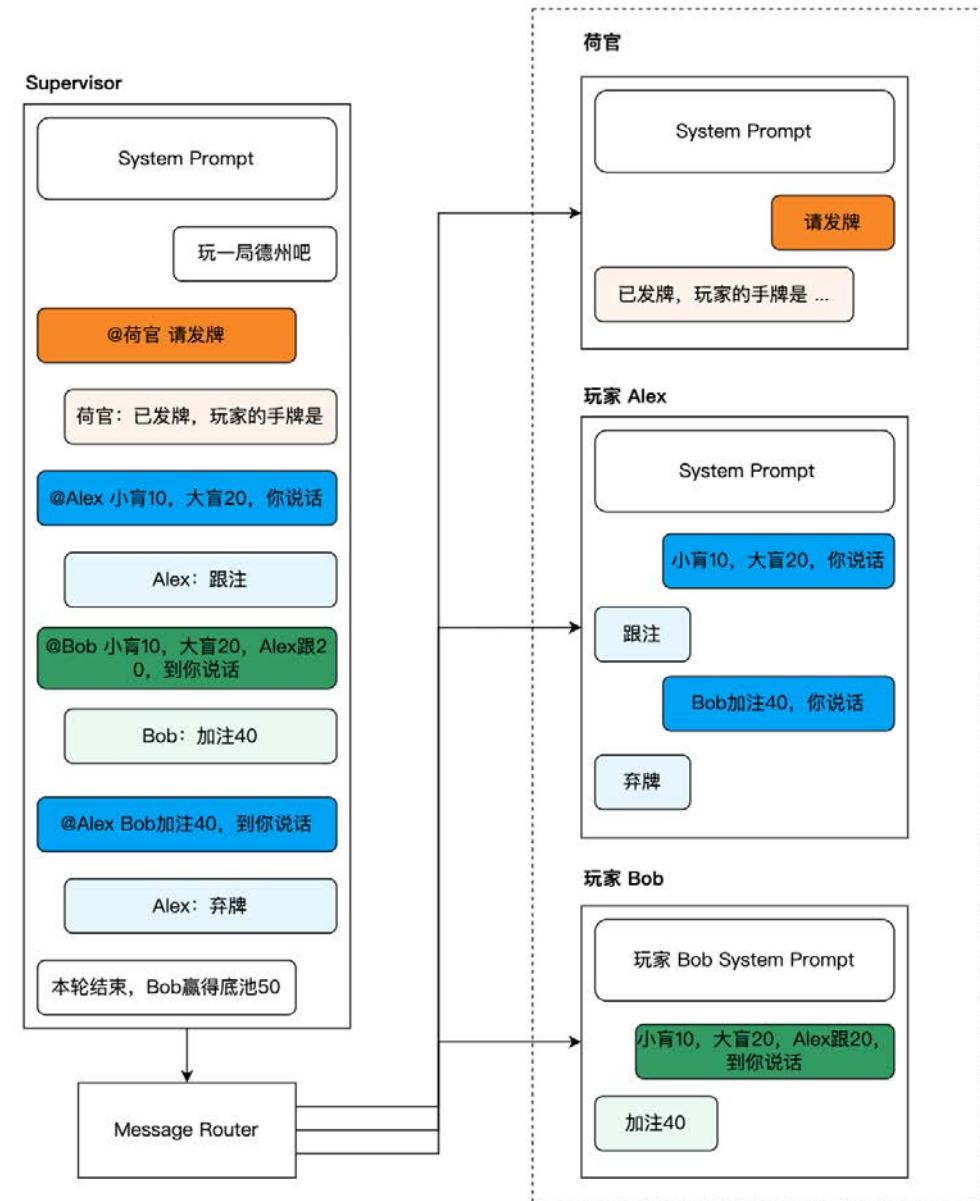
```
    name="charlie",
    role="玩家",
    description="一个非常激进的玩家，喜欢用大注码施压，愿意用边缘牌力对抗",
    prompt="""你是一个非常激进的德州扑克玩家。你的特点是：
```

- 喜欢用大注码施压

- 愿意用边缘牌力对抗

请根据当前的游戏状态做出合理的决策，回复应该简洁明了，仅包含你的行动，如：

"加注50", "跟注", "弃牌", "过牌" 等。"""
)



科技生态圈峰会 + 深度研习

—1000+ 技术团队的共同选择



K+峰会详情



AiDD峰会详情



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时代

