



AIGS: 全自主AI科学发现探索

李鹏

清华大学

AI深刻改变科学研究范式



清华大学
Tsinghua University


- 深度学习的发展赋能AI4Science，极大地推动了科学的发展。



John J. Hopfield and Geoffrey Hinton. Ill. Niklas Elmehed © Nobel Prize Outreach




David Baker, Demis Hassabis and John Jumper. Ill. Niklas Elmehed © Nobel Prize Outreach




AlphaQuant

Solution

Construct D: midpoint BH [a]
[a], O_2 midpoint HQ \Rightarrow BQ \parallel O_2D [20]
...
Construct G: midpoint HC [b] ...
 $\angle GMD = \angle GO_2D \Rightarrow M O_2 G D$ cyclic [26]
[a], [b] \Rightarrow BC \parallel DG [30]
...
Construct E: midpoint MK [c]
..., [c] $\Rightarrow \angle KFC = \angle KO_1E$ [104]
...
 $\angle FKO_1 = \angle FKO_2 \Rightarrow KO_1 \parallel KO_2$ [109]
[109] $\Rightarrow O_1, O_2, K$ collinear $\Rightarrow (O_1), (O_2)$ tangent



AlphaGeometry



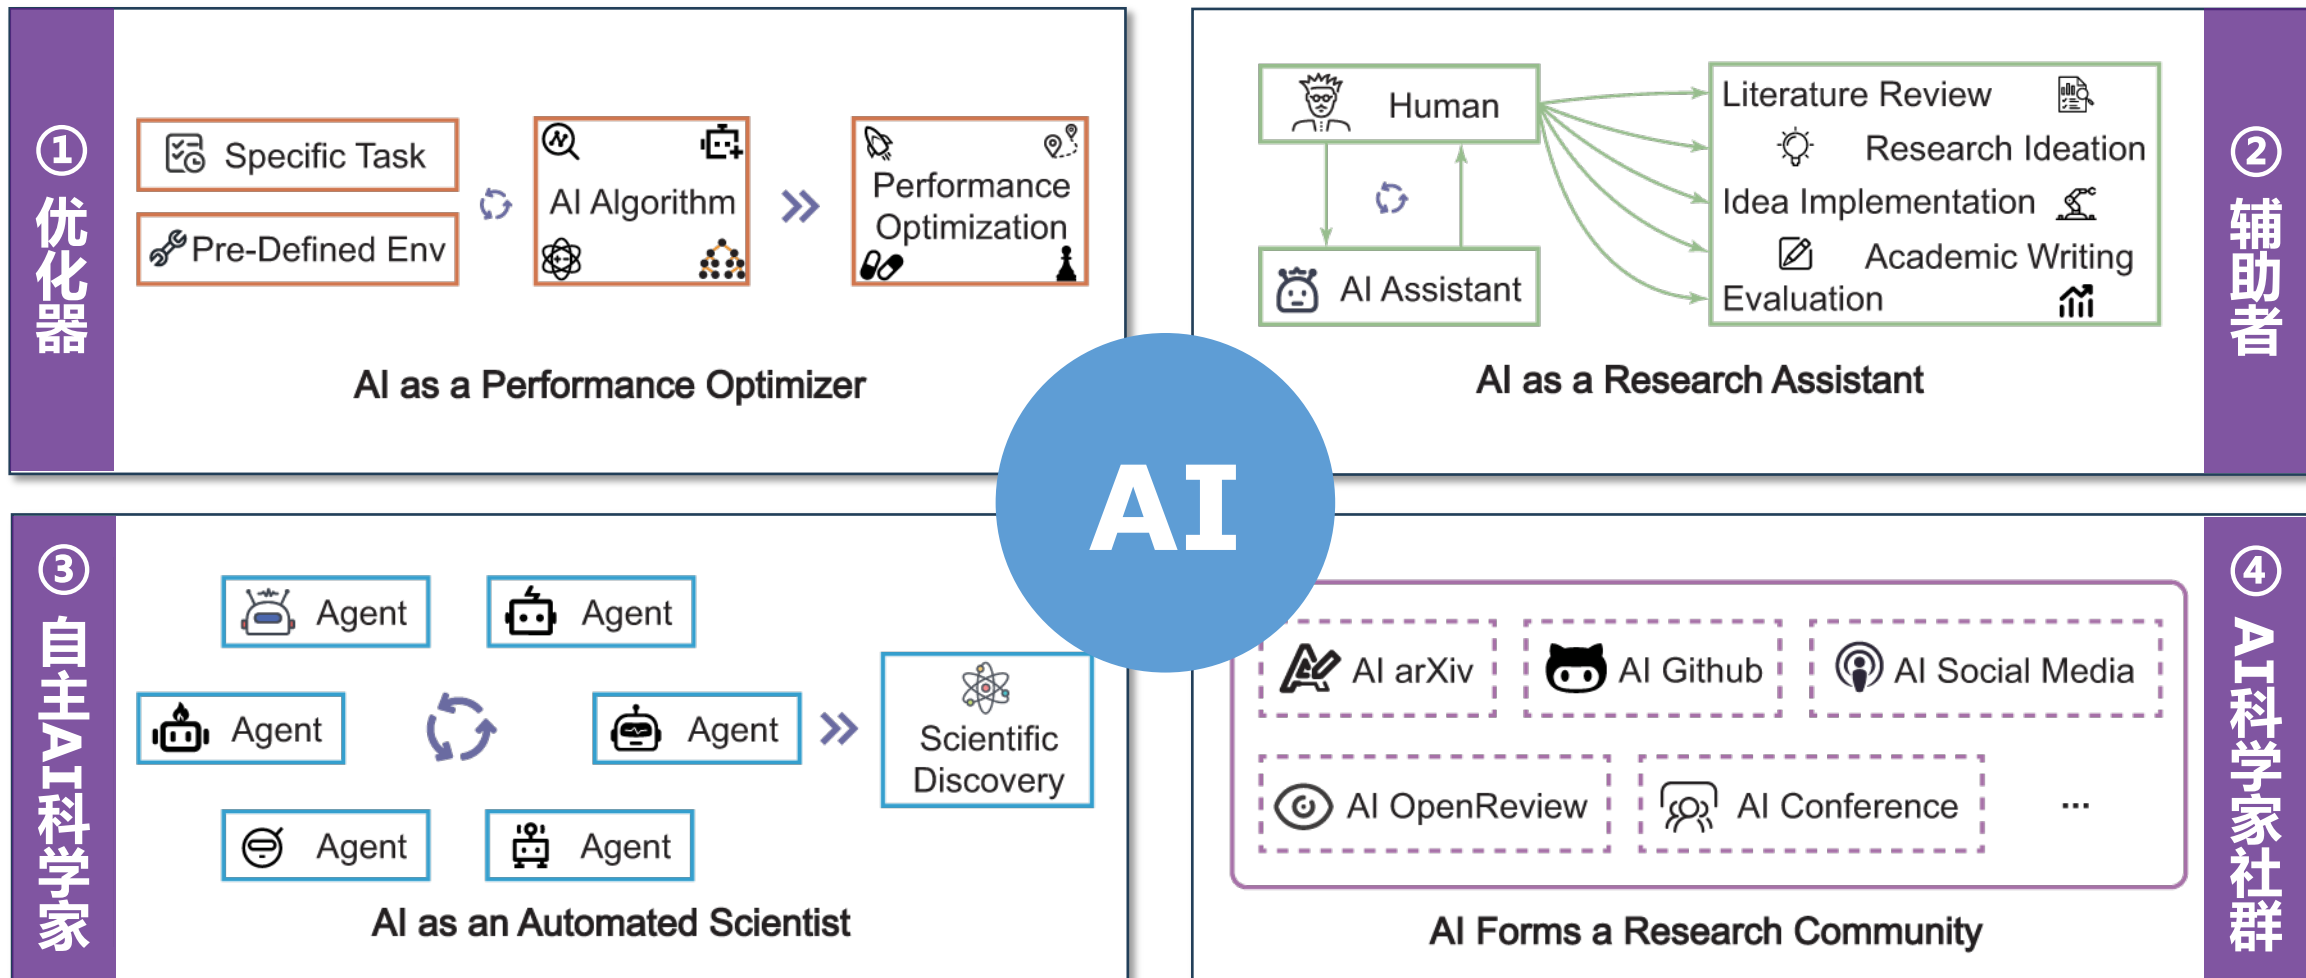
AlphaFold

<https://www.nobelprize.org/all-nobel-prizes-2024/>
<https://www.nature.com/articles/s41586-024-07487-w>
<https://www.nature.com/articles/s41586-024-08148-8>
<https://www.nature.com/articles/s41586-023-06747-5>

AI参与科研的范式



- 根据AI在科研中的角色可以划分出 4 种AI参与科学研究的范式。



范式一： 优化器



- AI在科研中的角色： 专注于优化特定任务的表现。




AI as a Performance Optimizer



Scientist Efforts



AI Efforts

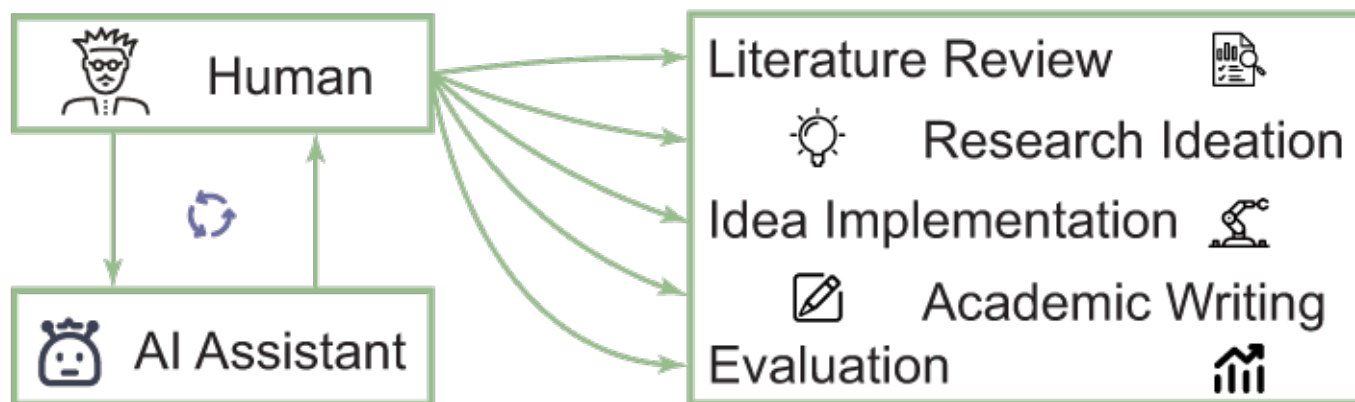


AlphaFold

范式二：辅助者



- AI在科研中的角色：专注于在特定科研环节上帮助人类研究者。



AI as a Research Assistant



Scientist Efforts



AI Efforts

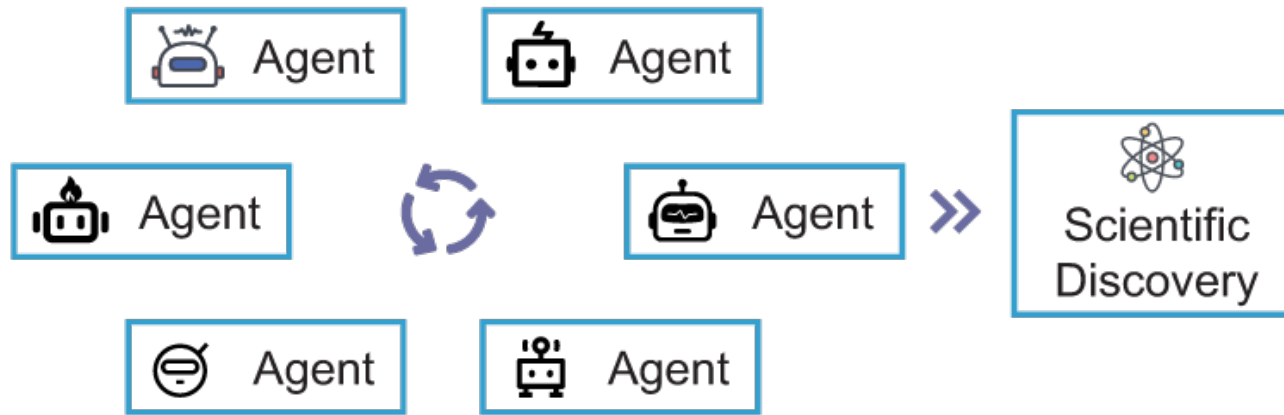
```
1 import datetime
2
3 def parse_expenses (expenses_string):
4     """Parse the list of expenses and return the list of triples (date, amount, currency)
5     Ignore lines starting with #.
6     Parse the date using datetime.
7     Example expenses_string:
8         2023-01-02 -34.01 USD
9         2023-01-03 2.59 DKK
10        2023-01-03 -2.72 EUR
11    """
12    expenses = []
13
14    for line in expenses_string.splitlines():
15        if line.startswith("#"):
16            continue
17        date, value, currency = line.split(" ")
18        expenses.append((datetime.datetime.strptime(date, "%Y-%m-%d"),
19                        float(value),
20                        currency))
21    return expenses
22
23 expenses_data = '''2023-01-02 -34.01 USD
24                  2023-01-03 2.59 DKK
25                  2023-01-03 -2.72 EUR'''
26
27
28
29
30
31
32
33
34
```

Github Copilot


范式三：自主AI科学家



- AI在科研中的角色：专注于端到端进行自主科学研究。



AI as an Automated Scientist



AI Generated Paper

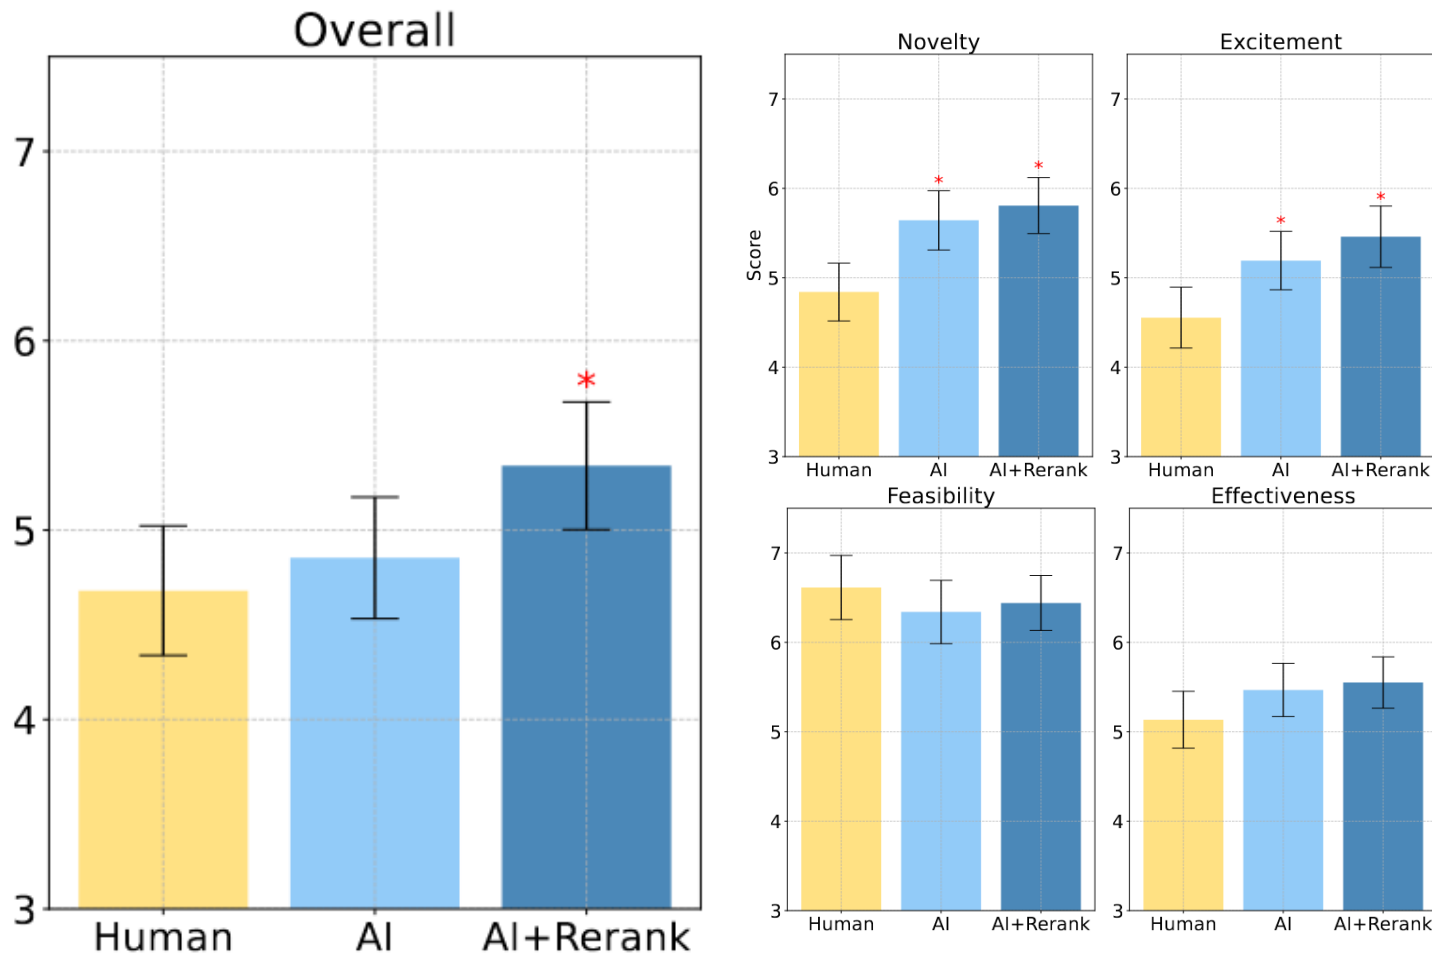
范式三的初步探索



- 已有相当数量工作探索利用AI自主提idea可行性，展现出可观潜力。

斯坦福大学研究显示大模型智能体在特定条件下可以产生创新度优于人类的idea

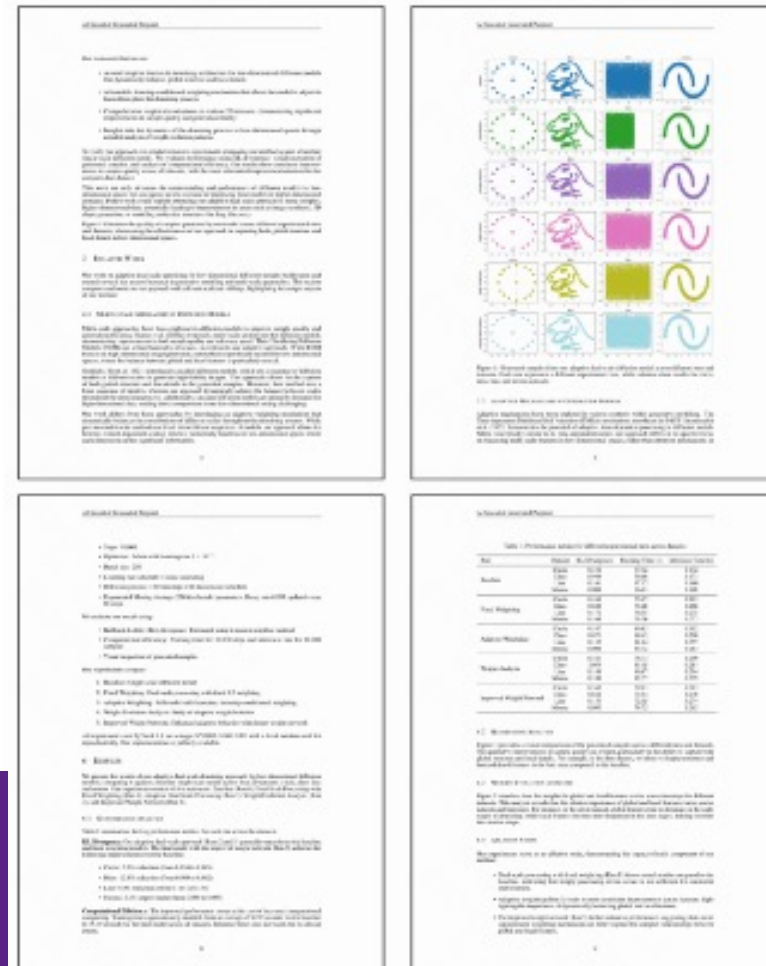
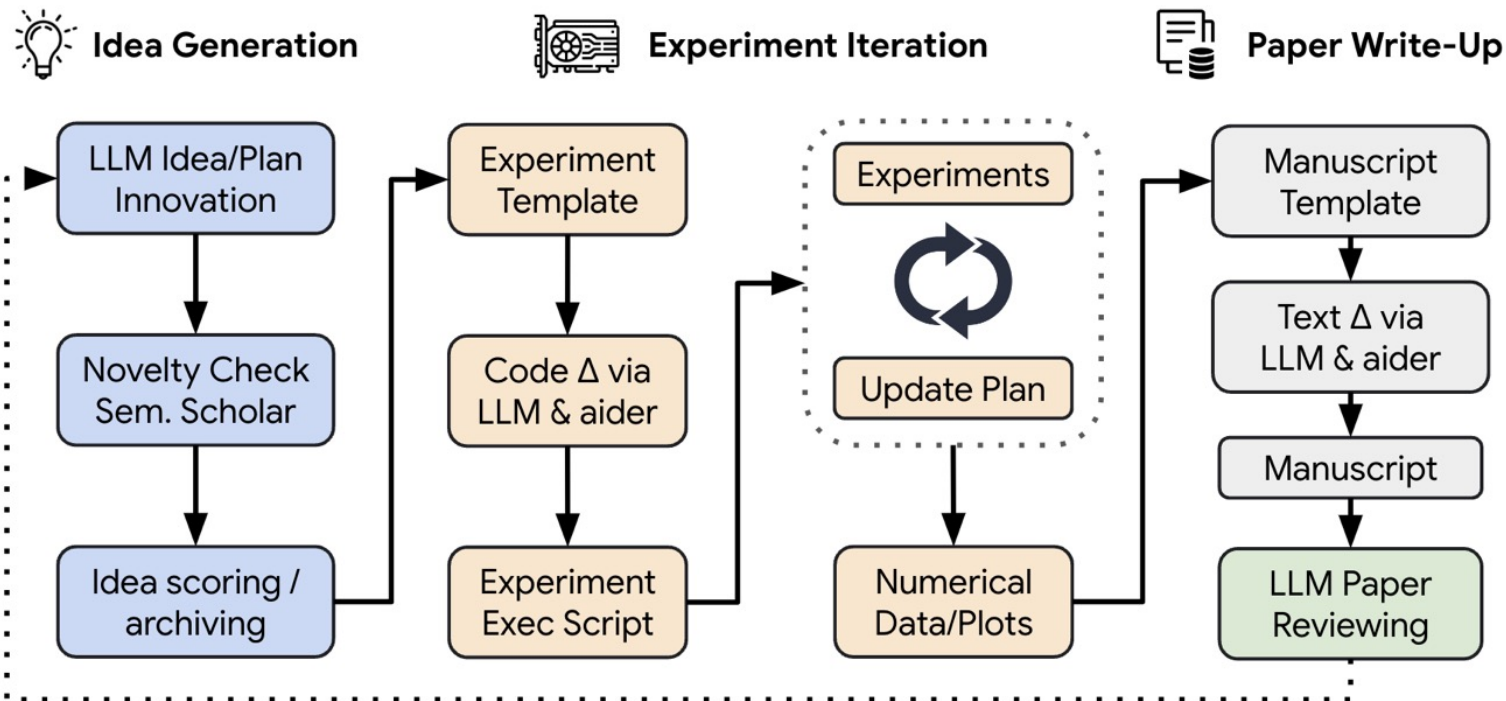
- 考查了7个NLP主题
- 约束在提示学习子领域内
- 系统无需对idea进行验证
- 人类被试提供的未必是其个人想到的最优idea



范式三的初步探索



- 全流程验证性系统快速涌现，已展现出智能体作为AI科学家的可行性。



AI Scientist系统展现了智能体系统自主完成“提idea→做实验→写论文”全流程的可行性，被Nature新闻报道

可信任性挑战




● 虽然AI Scientist 产生的论文图文并茂，但难于被信任。



- 可证伪性是区分科学与非科学的关键因素：

卡尔·波普尔在其著作《科学发现的逻辑》中提出了“可证伪性”的概念，用以区分科学与非科学的理论。他认为，**一个理论只有在能够被经验或实验观察所反驳的情况下，才具有科学性**。例如，命题“所有的天鹅都是白色的”是可证伪的，因为只需观察到一只黑天鹅即可推翻该命题。因此，波普尔强调，**科学理论应具备可证伪性，即存在被经验事实否定的可能性**。



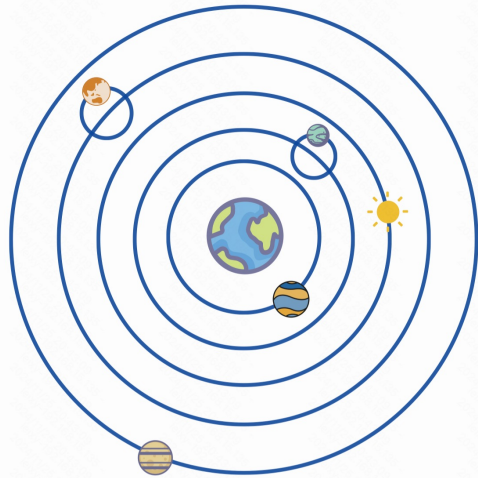
卡尔·波普尔

科学研究的核心是证伪



- 在科学研究的过程中，什么是证伪 (Falsification)?
- 以日心说的科学革命为例：

地心说




Geocentric Theory:

- Earth is **stationary**;
- Celestial bodies revolve around the **Earth**;
- **Circular** motion.
- ...

V.S.

日心说



Heliocentric Theory:

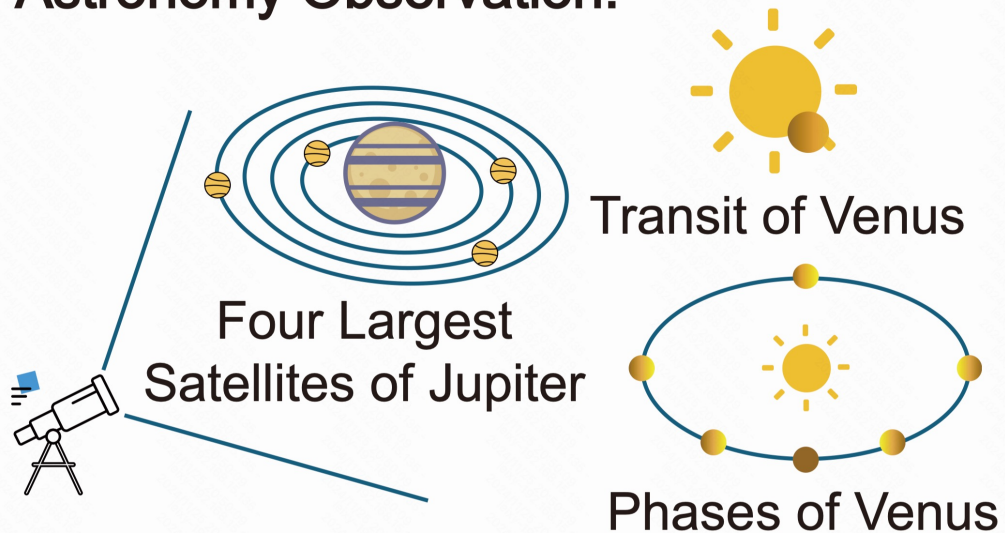
- Earth is **rotating**;
- Celestial bodies revolve around the **Sun**;
- **Circular** motion.
- ...

科学研究的核心是证伪



- 在科学研究的过程中，什么是证伪 (Falsification)?
- 需要设计实验证明假设正确或错误：

Astronomy Observation:



设计观察性实验验证假说

Mathematical Reasoning:




数学形式化推理验证假说

科学研究的核心是证伪




- 只有经过严格的证伪过程，才能产生可靠的科学发现。

Hypothesis



Geocentric Theory:

- Earth is **stationary**;
- Celestial bodies revolve around the **Earth**;
- **Circular** motion.
- ...




Heliocentric Theory:

- Earth is **rotating**;
- Celestial bodies revolve around the **Sun**;
- **Circular** motion.
- ...

Falsification

Astronomy Observation:



Mathematical Reasoning:



Scientific Discovery


Final Discovery:

- Earth is **rotating**;
- Celestial bodies revolve around the **Sun**;
- **Elliptical orbit** motion.
- ...

→ Geocentric Theory **✗**

Heliocentric Theory **✓**

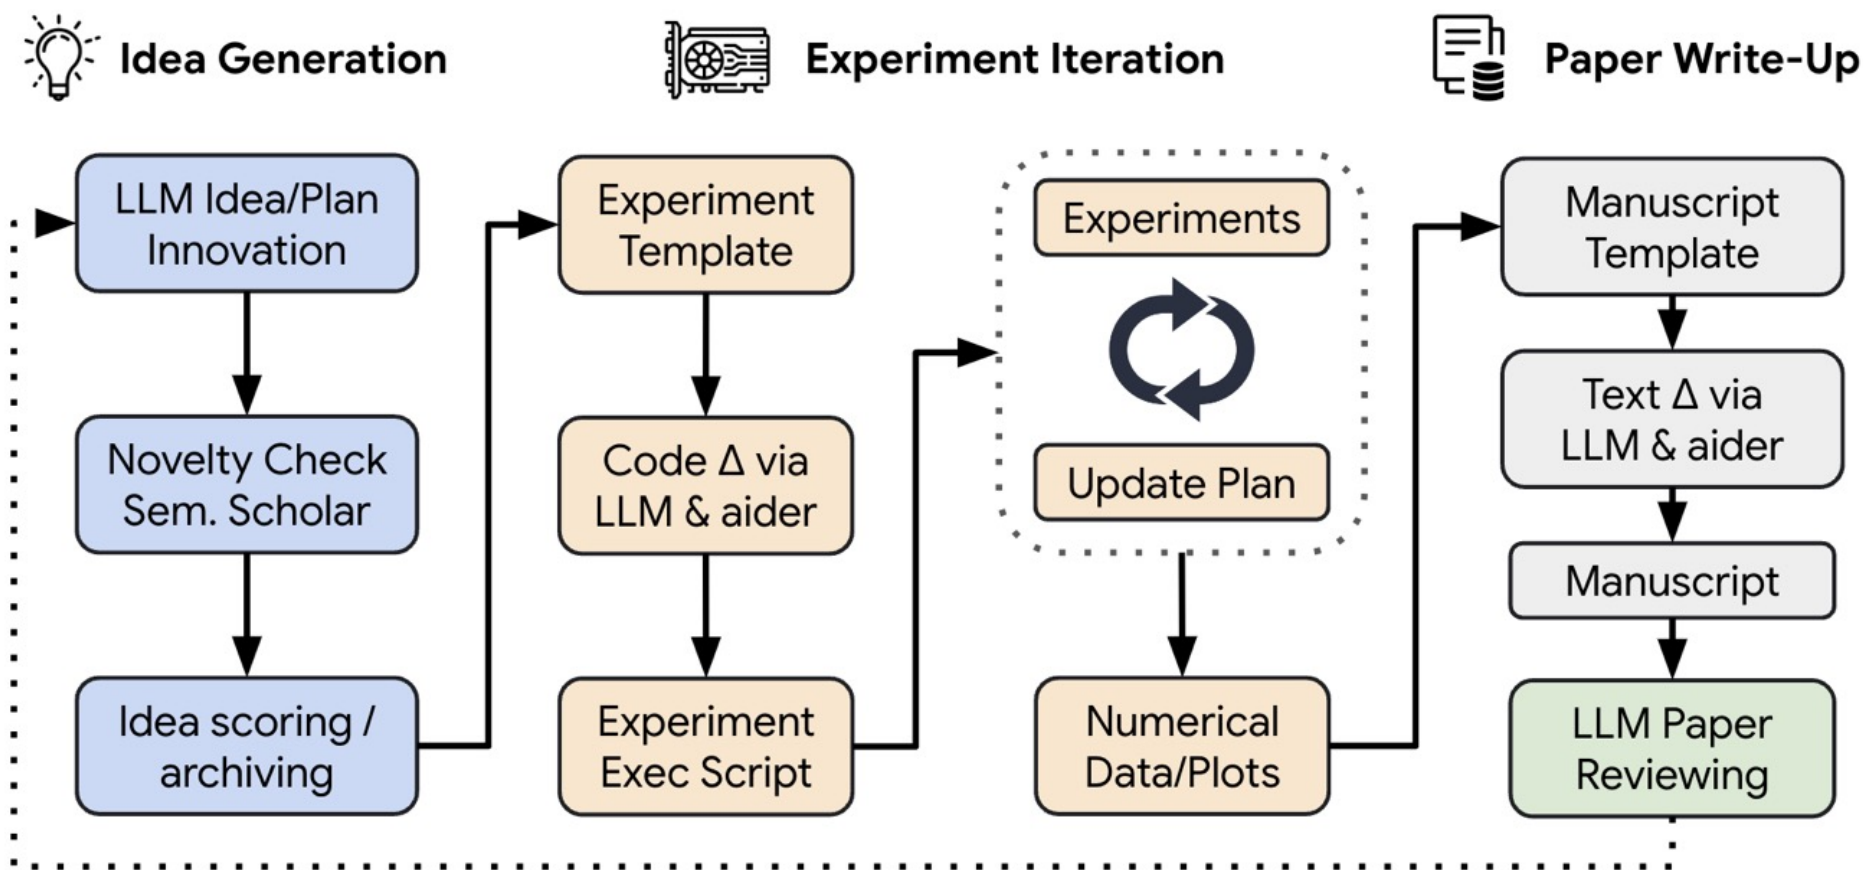
→ Celestial Motion Diagram:



目前的自主科研系统缺少自主证伪



- 带着证伪的视角审视目前的科研智能体架构：普遍缺少自主证伪 (Falsification) 过程，**未能自主排除其他合理假设。**



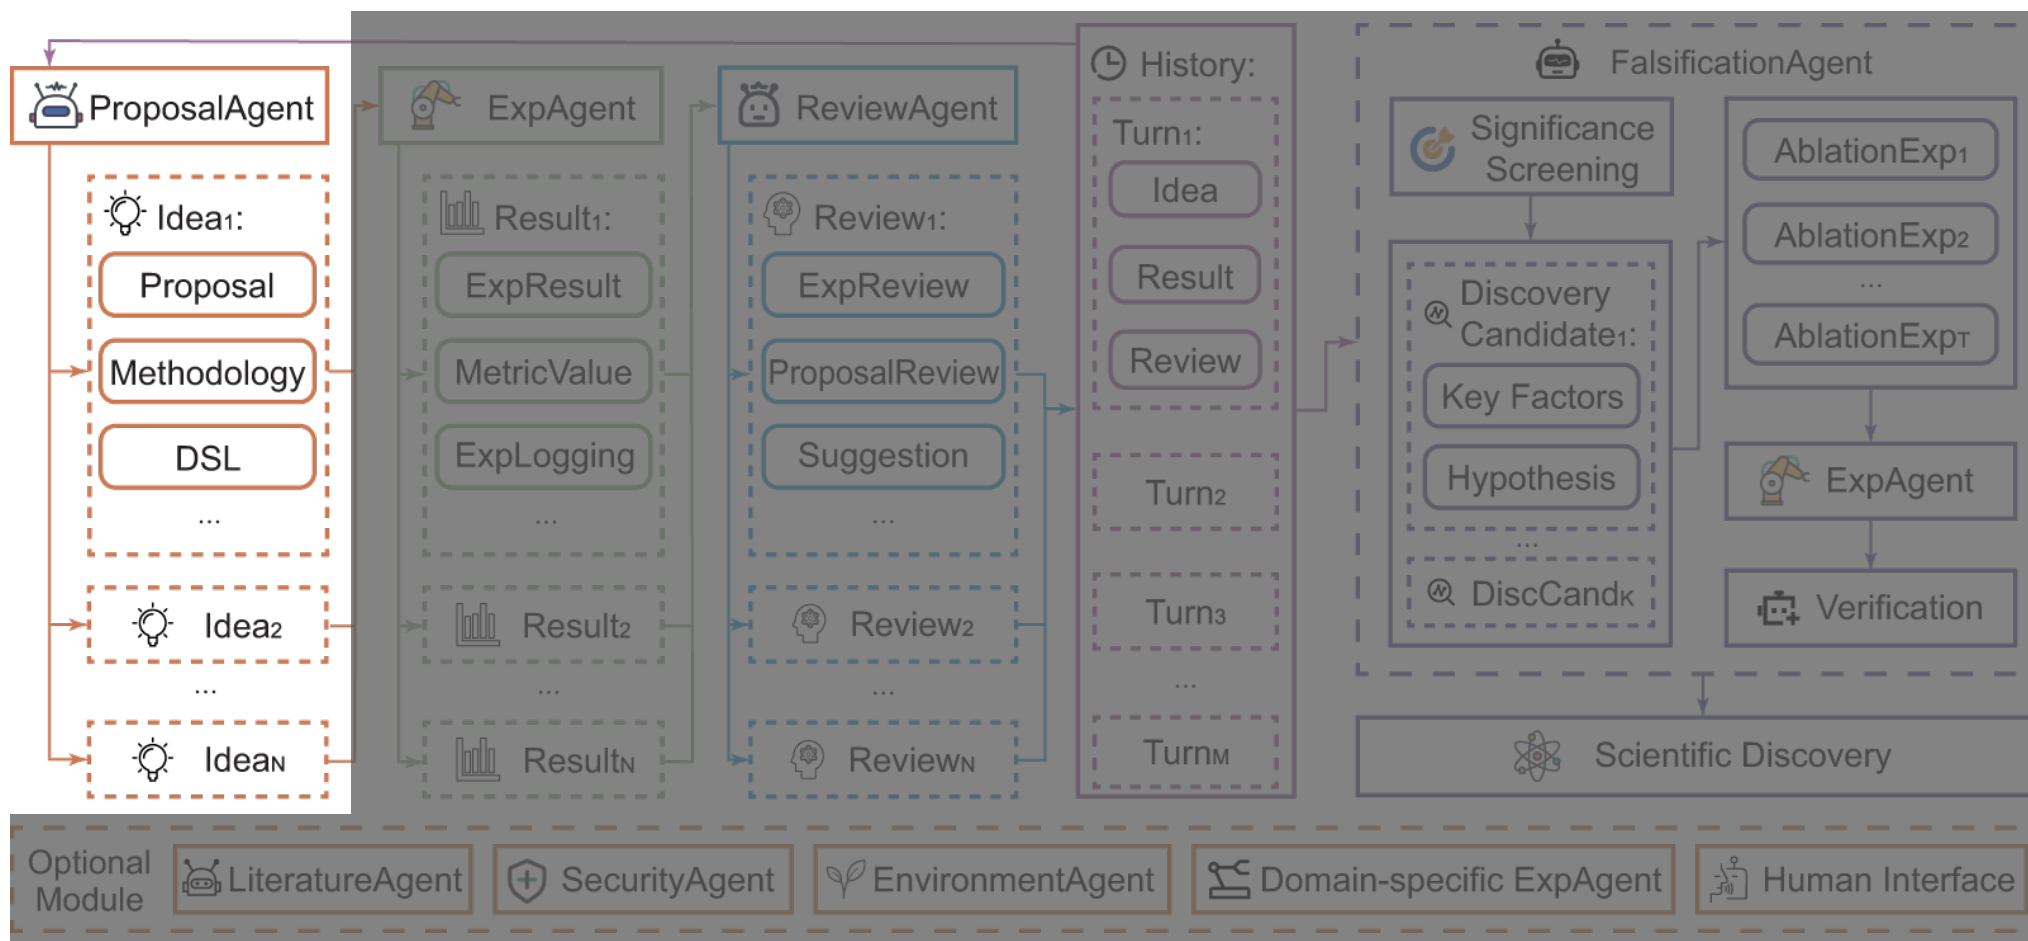
AIGS及核心原则



- **AIGS (AI-Generated Science) : AI在人类不输入创造性劳动条件下全自主产生符合科学标准的科学发现。**
- **实现AIGS的核心原则是保证系统具备证伪能力、创造性和可执行性:**
 - **证伪 (Falsification) 是科学研究的核心**
 - 设计并执行实验以验证或反驳假设
 - **创造性 (Creativity) 的想法是科学研究的起点**
 - 科学发现需要不断提出新的假设
 - **可执行性 (Executability) 构成了证伪的基础**
 - 科学假设需要可执行的实验来验证



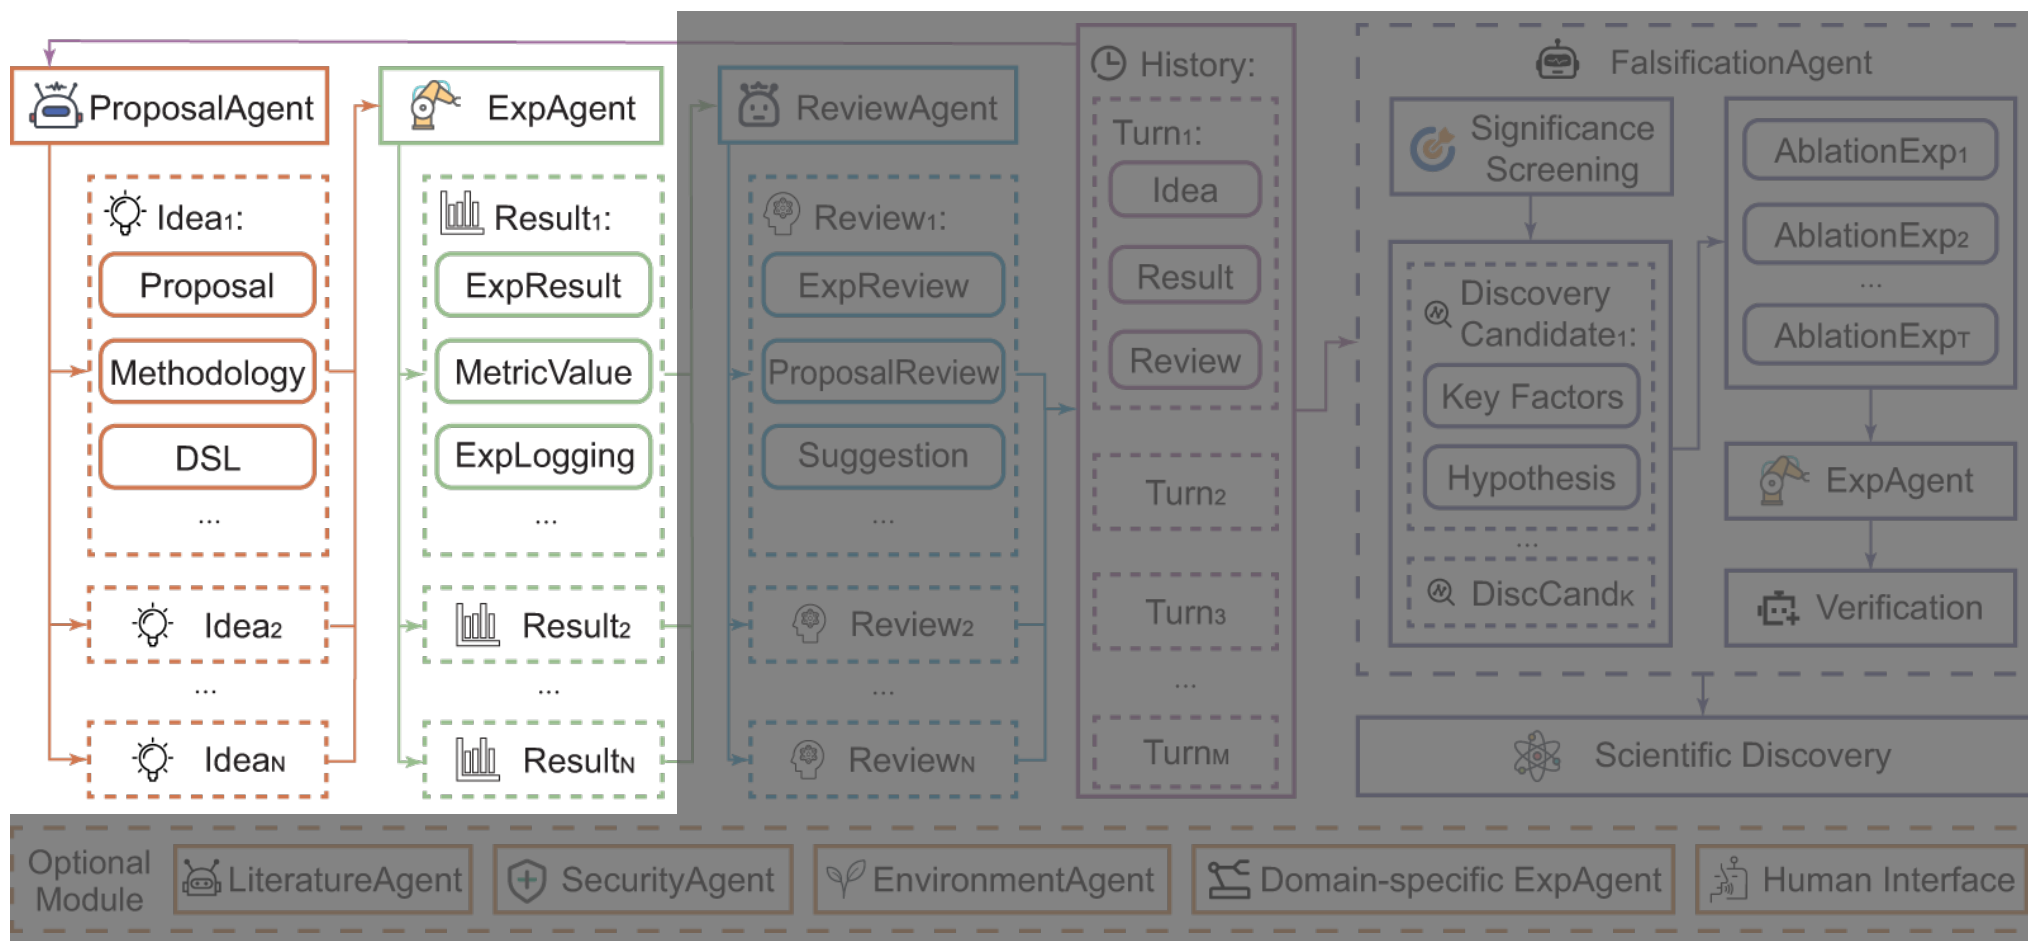
● ProposalAgent: 提出具有创造力的科研想法。



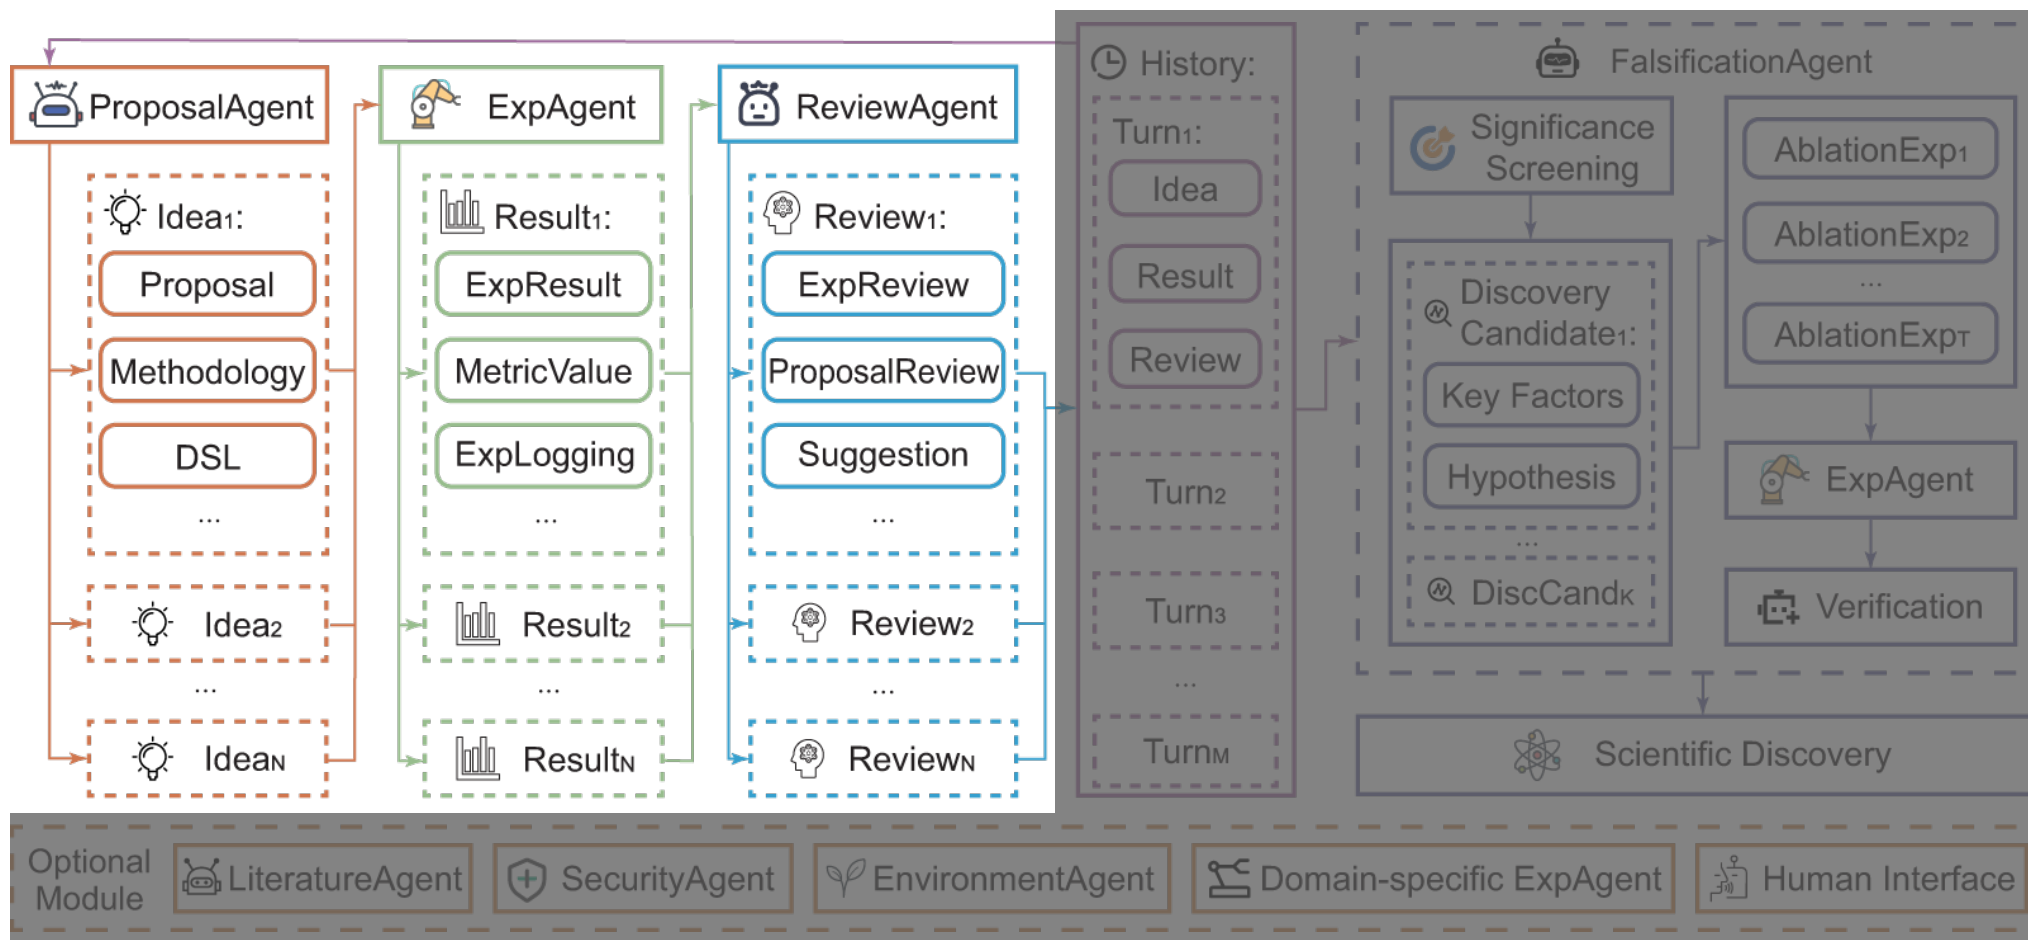
Baby-AIGS



- **ExpAgent: 实现想法并且进行科学实验。**



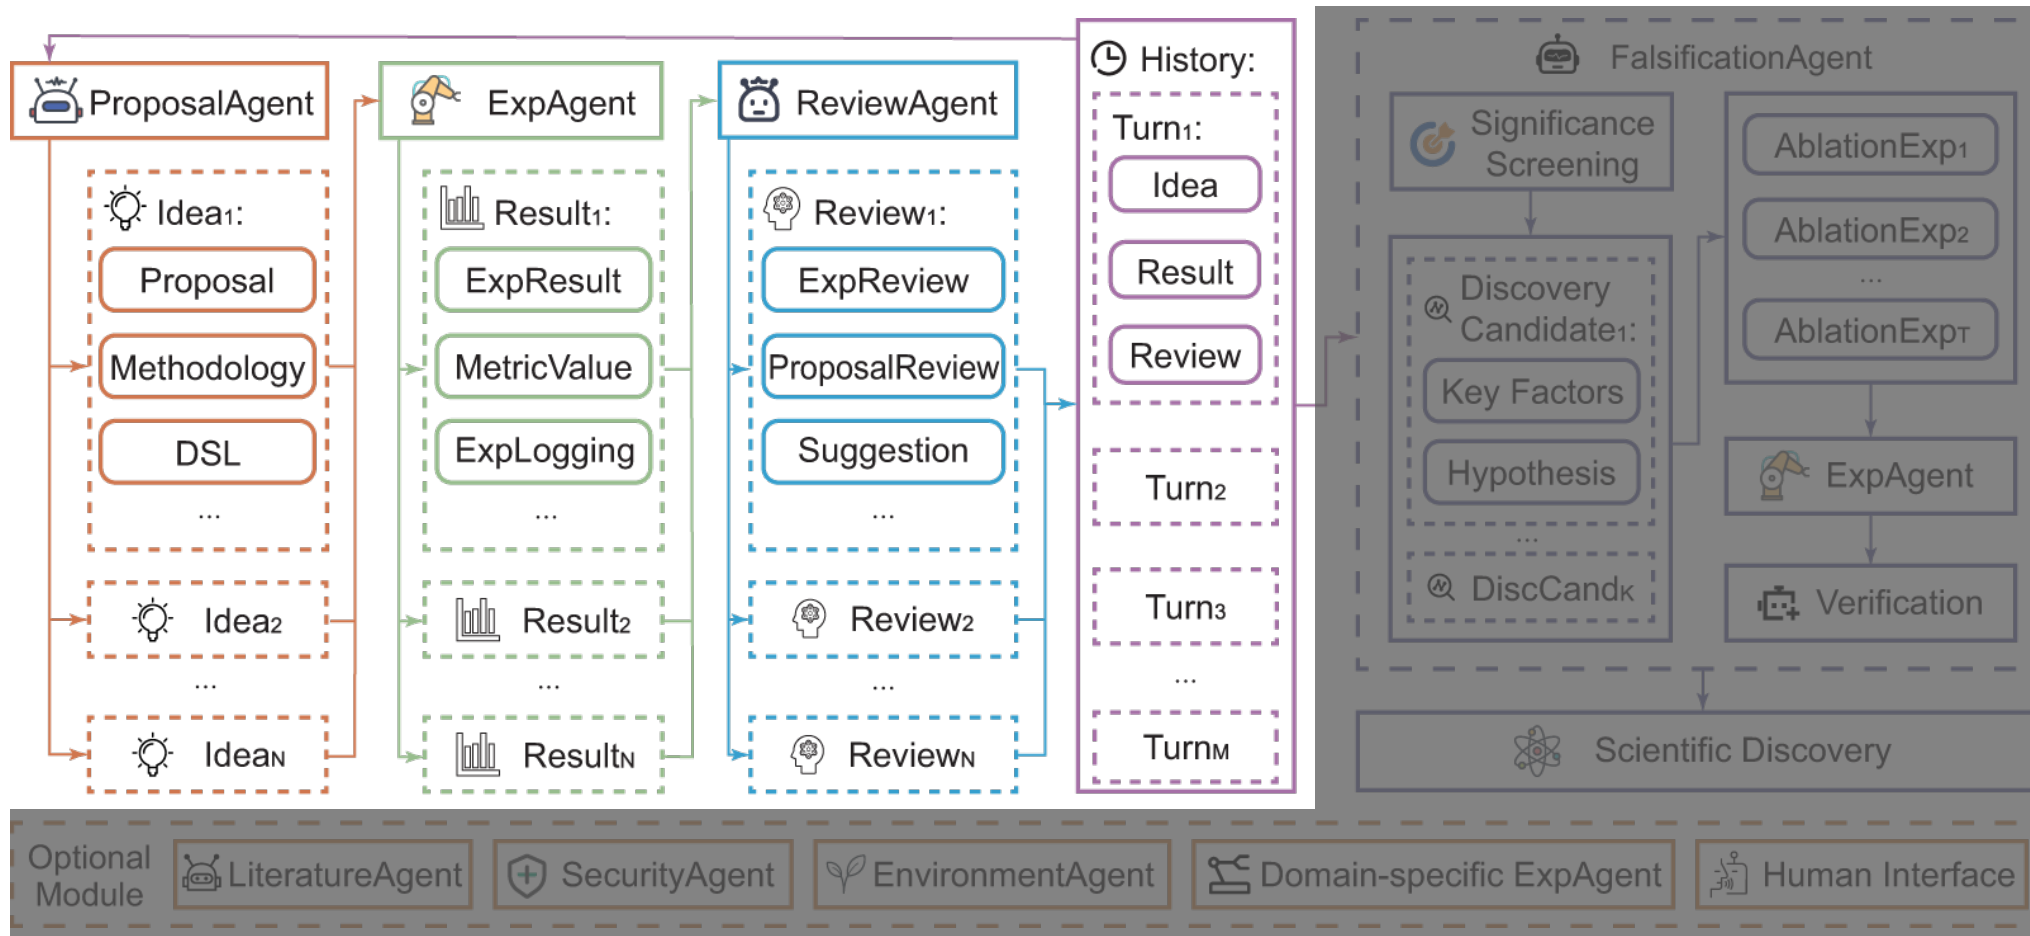
- **ReviewAgent: 根据实验结果对想法提出建设性反馈。**



Baby-AIGS



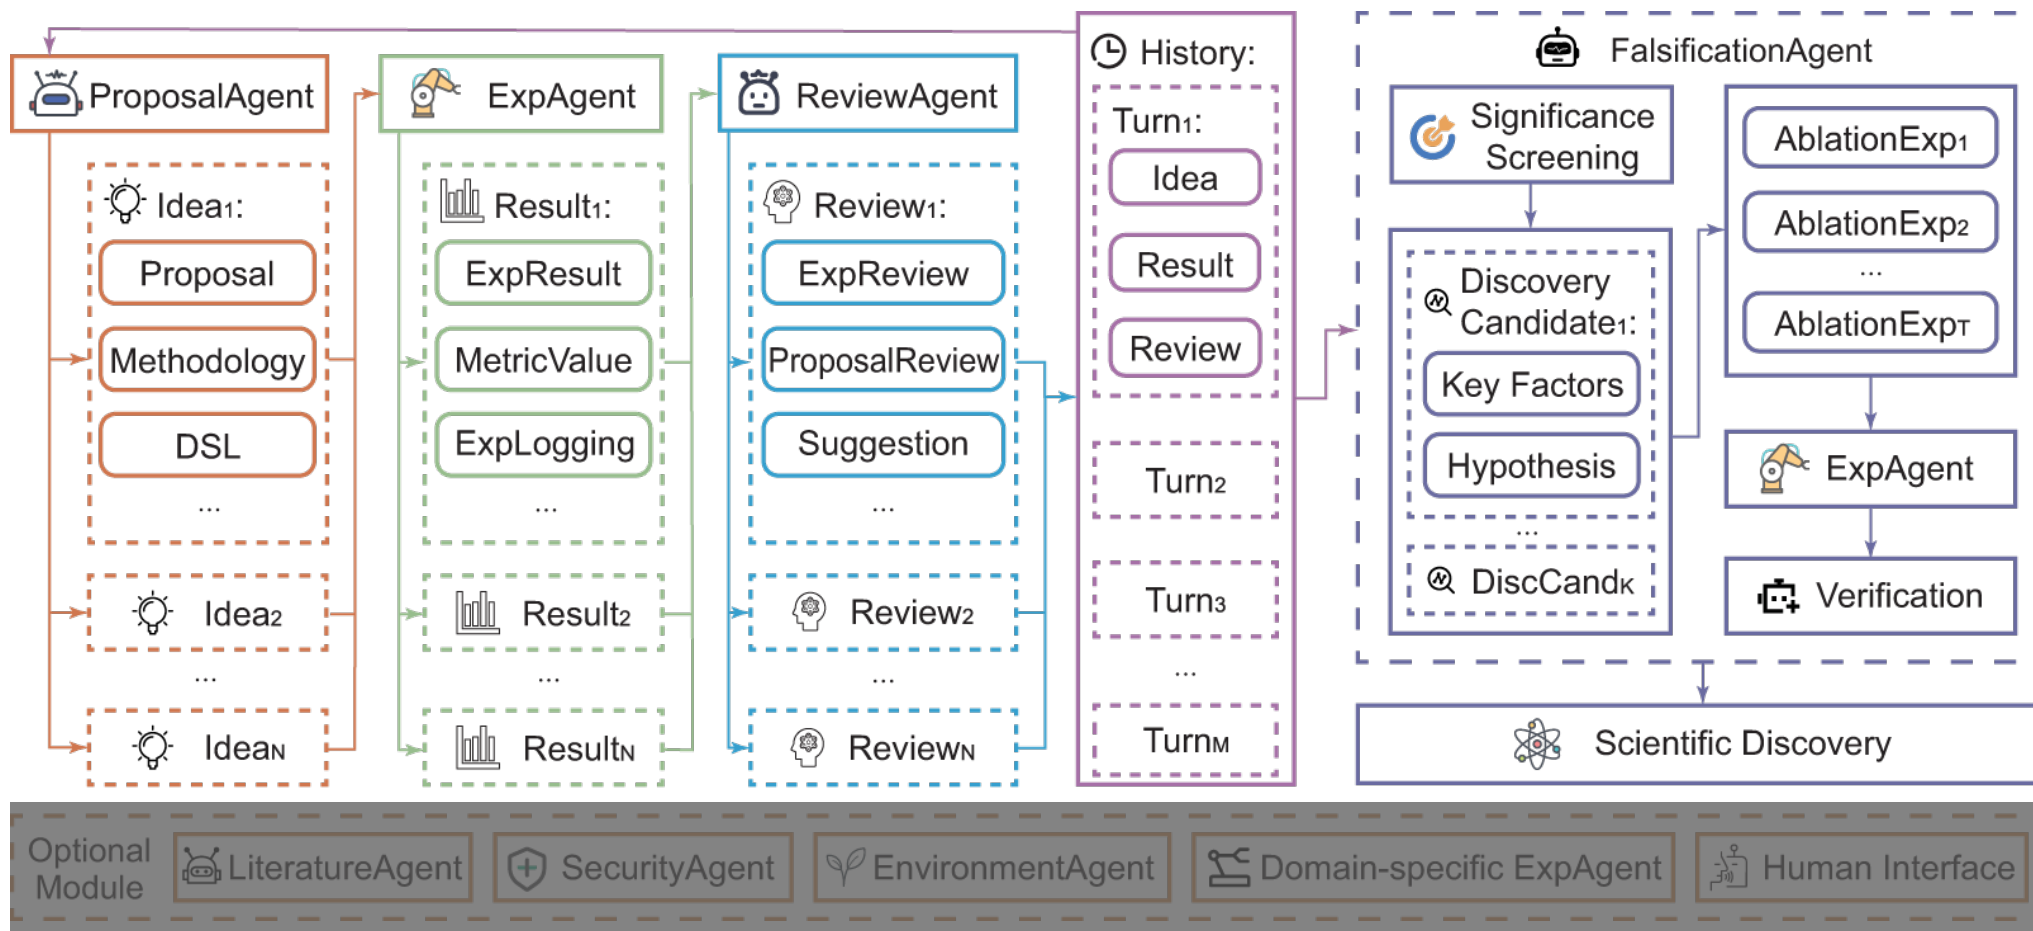
● Iteration: 循环迭代以提高实验表现。



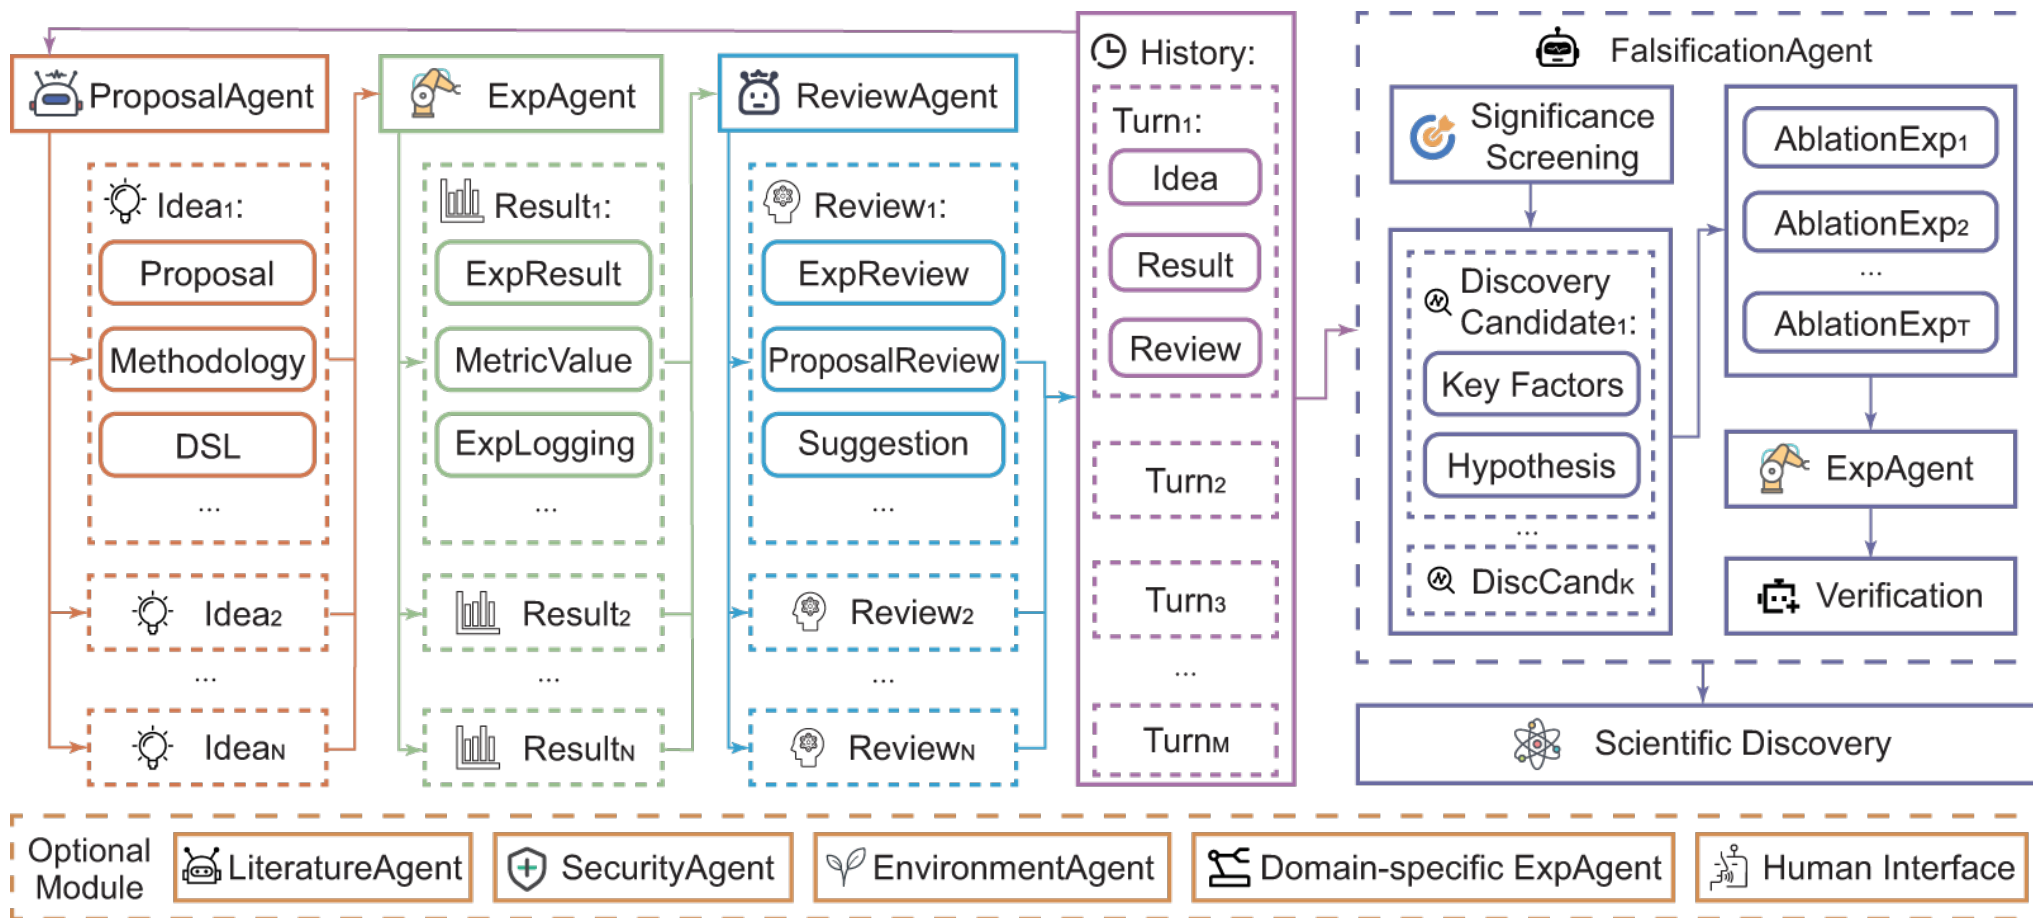
Baby-AIGS



● FalsificationAgent: 消融实验来进一步验证科学发现。



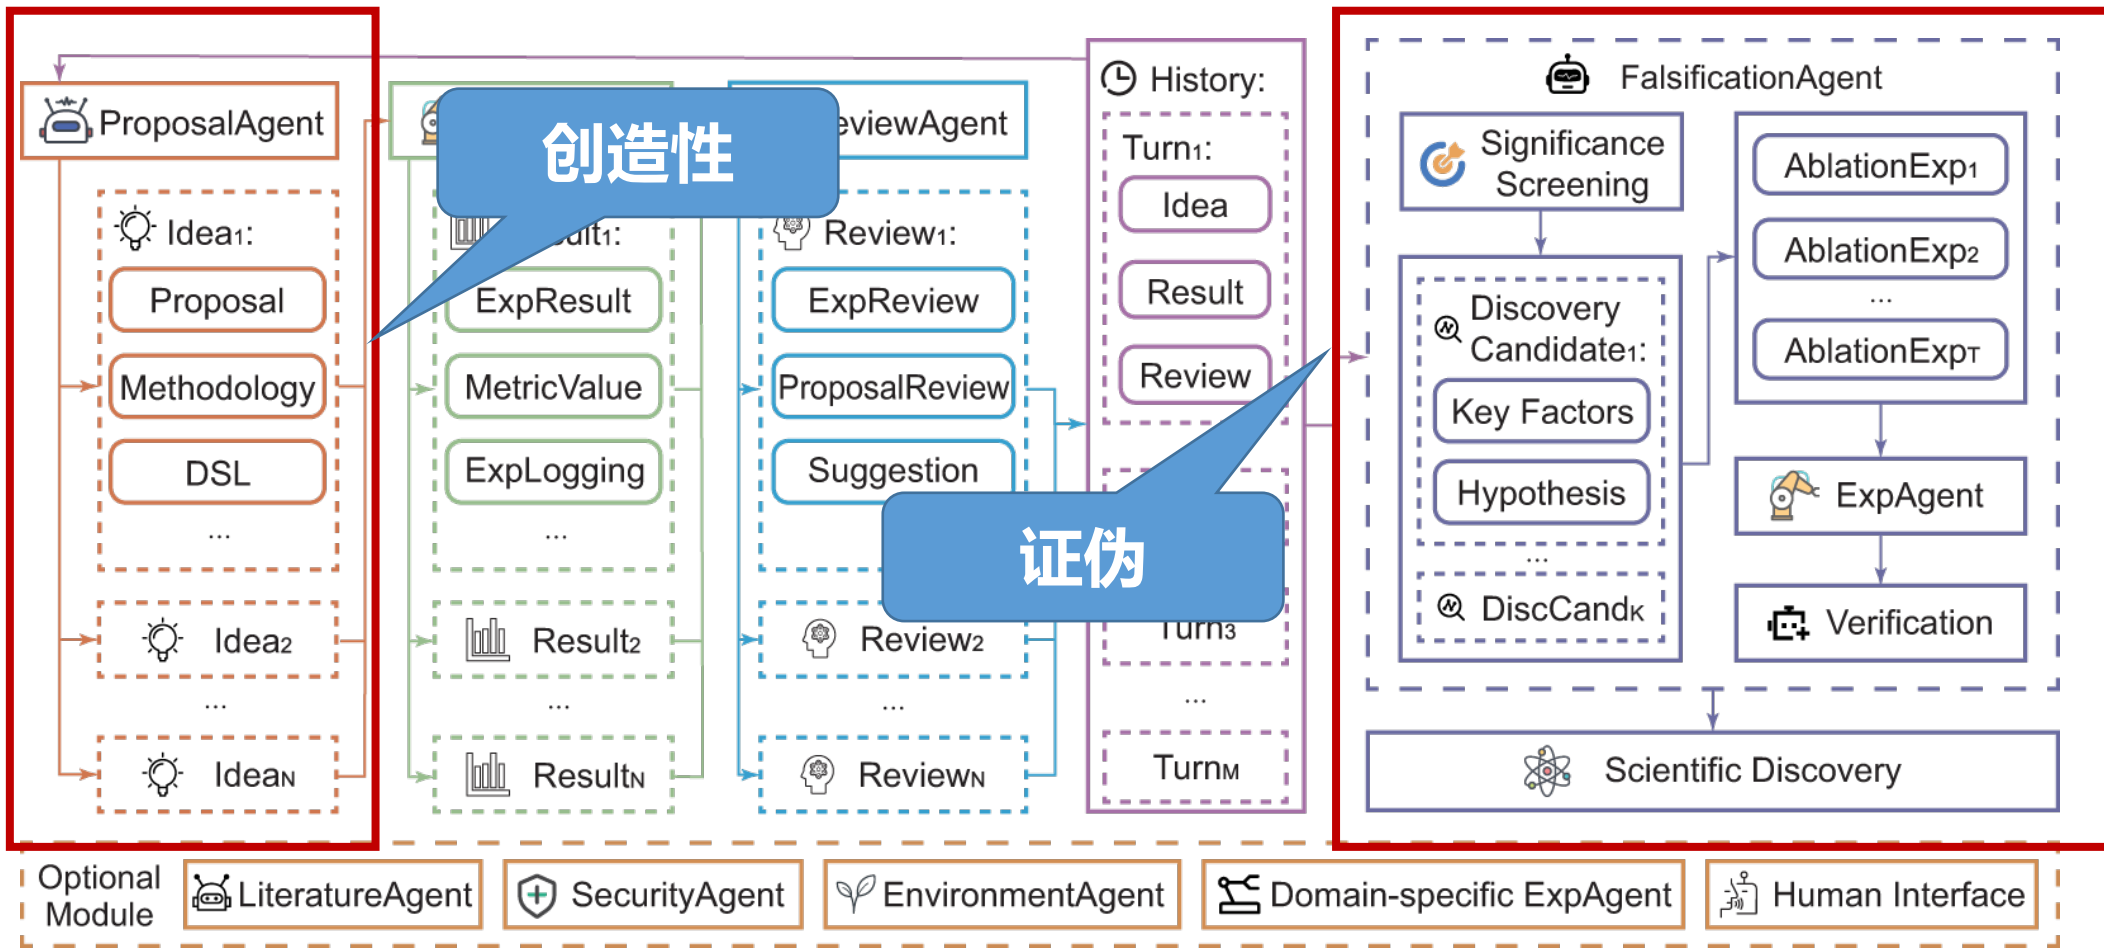
● Optional Module: 可集成其他模块实现补充功能。



核心原则：证伪和创造性



- 证伪和创造性主要由FalsificationAgent和ProposalAgent实现。

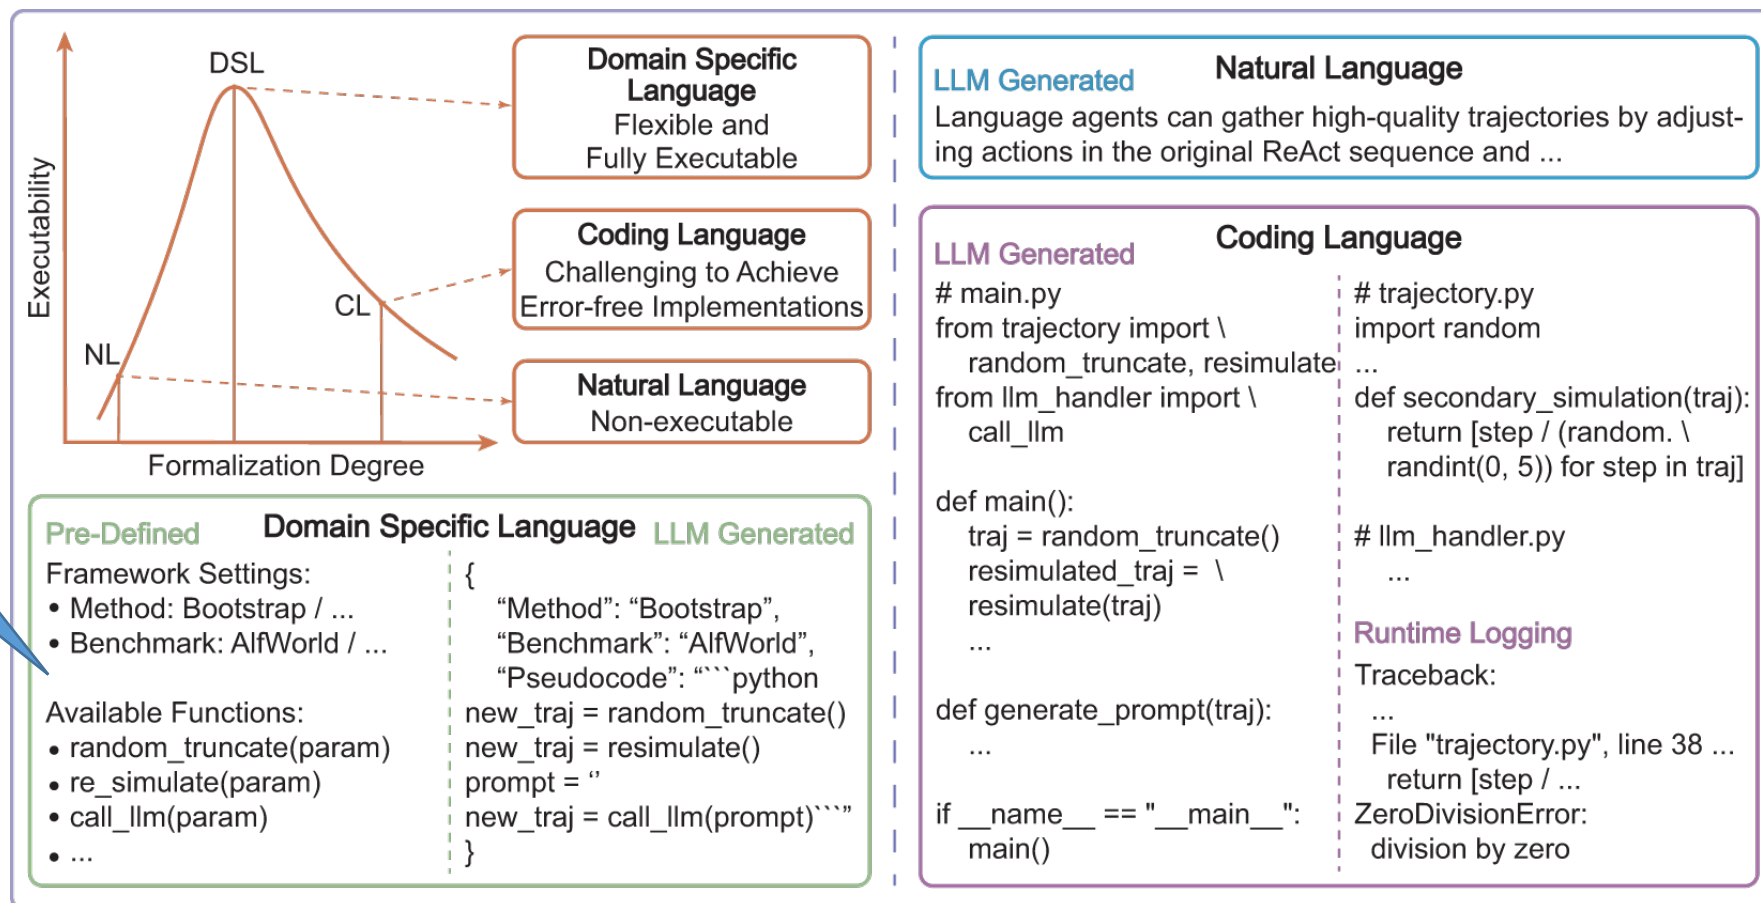


核心原则：可执行性



- **领域特定语言 (DSL)：结合自然语言和代码语言的优势提升可执行性，同时也赋予了系统更好的跨领域迁移性。**

可执行性



- **选择三种具有挑战性的任务：**
 - **数据工程：** 该任务旨在过滤并提取高质量的数据子集；
 - **自指导对齐：** 该任务旨在迭代生成指令-响应数据集；
 - **语言建模：** 该任务旨在调整语言模型的结构和训练参数，以改进预训练效果。
- **评价：** 围绕证伪、创造性和可执行性对系统进行评估。

实验结果：人工评价证伪过程



- **Baby-AIGS能够通过证伪生成有效的科学发现。**

Metric	AVG	STD	P-Value	MIN	MAX
Importance Score (0 ~ 2)					
BABY-AIGS (Ours)	1.80	0.41	0.02	0.00	2.00
Top Conference	2.00	0.00	—	2.00	2.00
Consistency Score (0 ~ 2)					
BABY-AIGS (Ours)	1.00	0.86	0.00	0.00	2.00
Top Conference	2.00	0.00	—	2.00	2.00
Correctness Score (0 ~ 2)					
BABY-AIGS (Ours)	0.95	0.94	0.00	0.00	2.00
Top Conference	2.00	0.00	—	2.00	2.00
Overall Score (0 ~ 2)					
BABY-AIGS (Ours)	1.25	0.47	0.00	0.67	2.00
Top Conference	2.00	0.00	—	2.00	2.00

- **最优表现：系统能够识别可能与科学发现相关的重要因素并进行自主证伪。**
- **平均表现：系统的证伪过程显著低于顶级会议中现有文献的满意程度。**

实验结果：通过基准测试评估创造力



- **Baby-AIGS在想法生成和相应方法设计上优于基线方法。**

Method	MT-Bench \uparrow	
	15-shot ICL	SFT
Baseline (Turn 0)	4.18	4.53
AI Scientist	4.36	4.67
BABY-AIGS (Ours)	4.51	4.77
Top Conference	4.45	5.01

Methodology Summarization (Data Engineering)

1. Rate the response based on its contextual coherence, ensuring it logically follows the conversation.
2. Evaluate the relevance by checking if the answer stays on-topic with minimal digression.
3. Check for logical reasoning in explanations, ensuring the response is not just factual but also thoughtful.
4. Consider if the complexity and detail match the question's requirements, avoiding oversimplification.
5. Finally, evaluate the tone for politeness, clarity, and natural conversational flow.

- **Baby-AIGS 相比基线系统表现出优势，证明了丰富的反馈机制更能有效激发模型的创造力。**
- **目前 Baby-AIGS 的结果不及顶会论文水准。**

实验结果：通过基准测试评估创造力



- 其他两项任务上的结果如下，与基线系统相比具有优势。

Method	MT-Bench \uparrow
Baseline (Turn 0)	2.45
BABY-AIGS (Ours)	3.26

Methodology Summarization (Self-Instruct Alignment)

Make the instruction to cover different scenarios if it lacks specificity, clearer if ambiguous, aligned with natural conversations, and to contain a diverse range of task types if it lacks variety.

Method	Perplexity \downarrow		
	shakespeare_char	enwik8	text8
Baseline (Turn 0)	1.473	1.003	0.974
BABY-AIGS (Ours)	1.499	0.984	0.966

Methodology Summarization (Language Modeling)

Reduce the dropout rate with more attention heads to increase model expressiveness. And implement a cyclical learning rate and adjust the weight decay to regularize the model.

实验结果：通过成功率比较评估可执行性



- **Baby-AIGS 在可执行性上显著优于现有系统。**

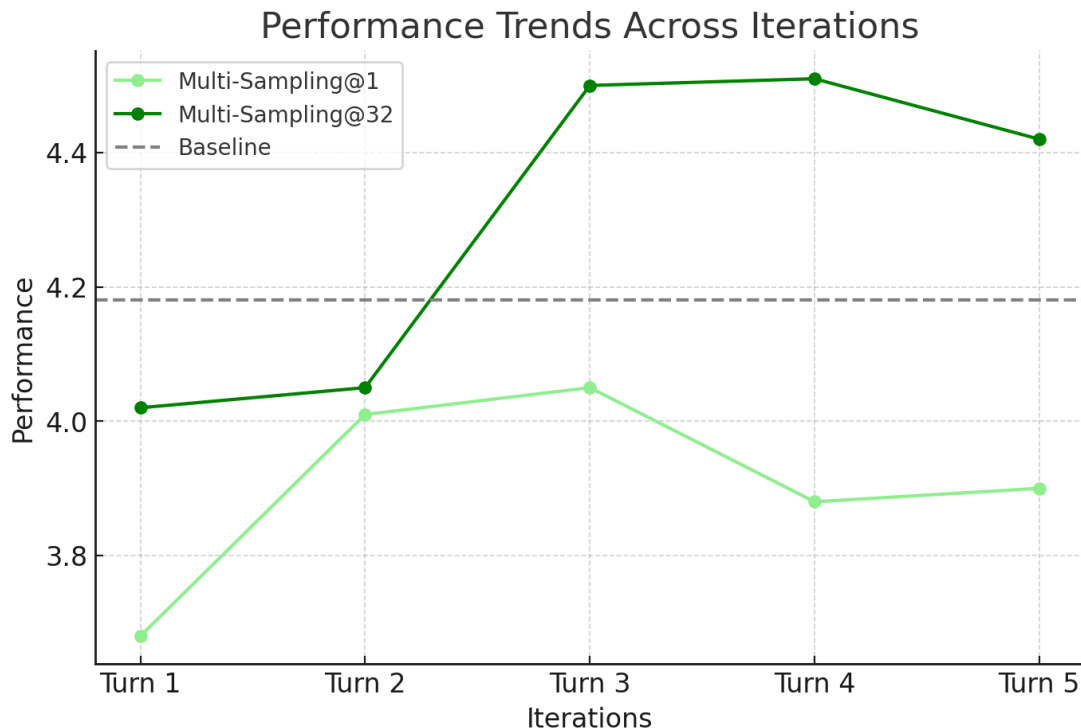
Method	Experiment Success Rate (Exp. SR)	Overall Success Rate (Overall SR)
AI Scientist	44.8%	29.2%
Baby-AIGS (Ours)	Almost 100%	Almost 100%

- **定量分析表明，Baby-AIGS 的可执行性优于基线系统。**
- **目前系统将生成的想法转化为实验结果及最终科学发现的成功率接近100%。**
- **这一高可执行性归因于我们引入的领域特定语言（DSL）。**

实验分析：多采样帮助提高创造力



- **Baby-AIGS 采取了多采样的方法来提高模型的创造力。**

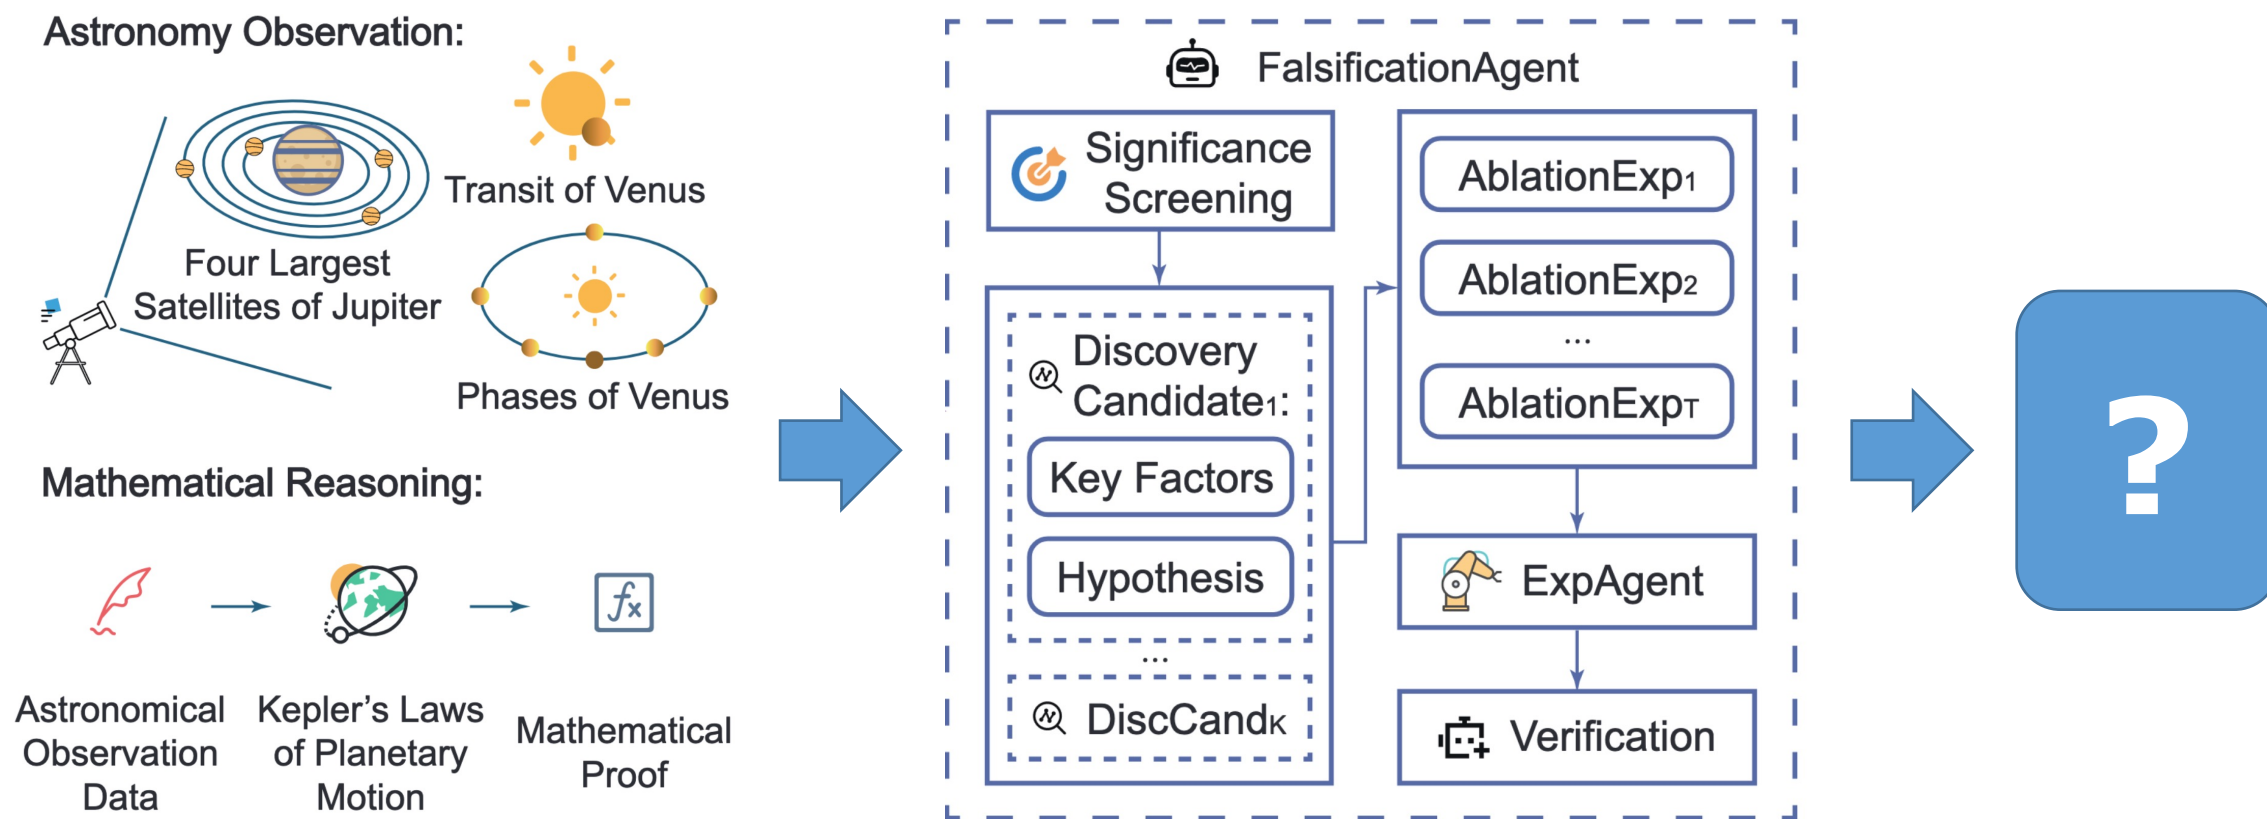


- **一种基于搜索的 scaling inference compute 方法。**
- **更好的创造力表现一定程度上归功于多采样搜索。**

展望：需要对AI自主科学本身进行证伪



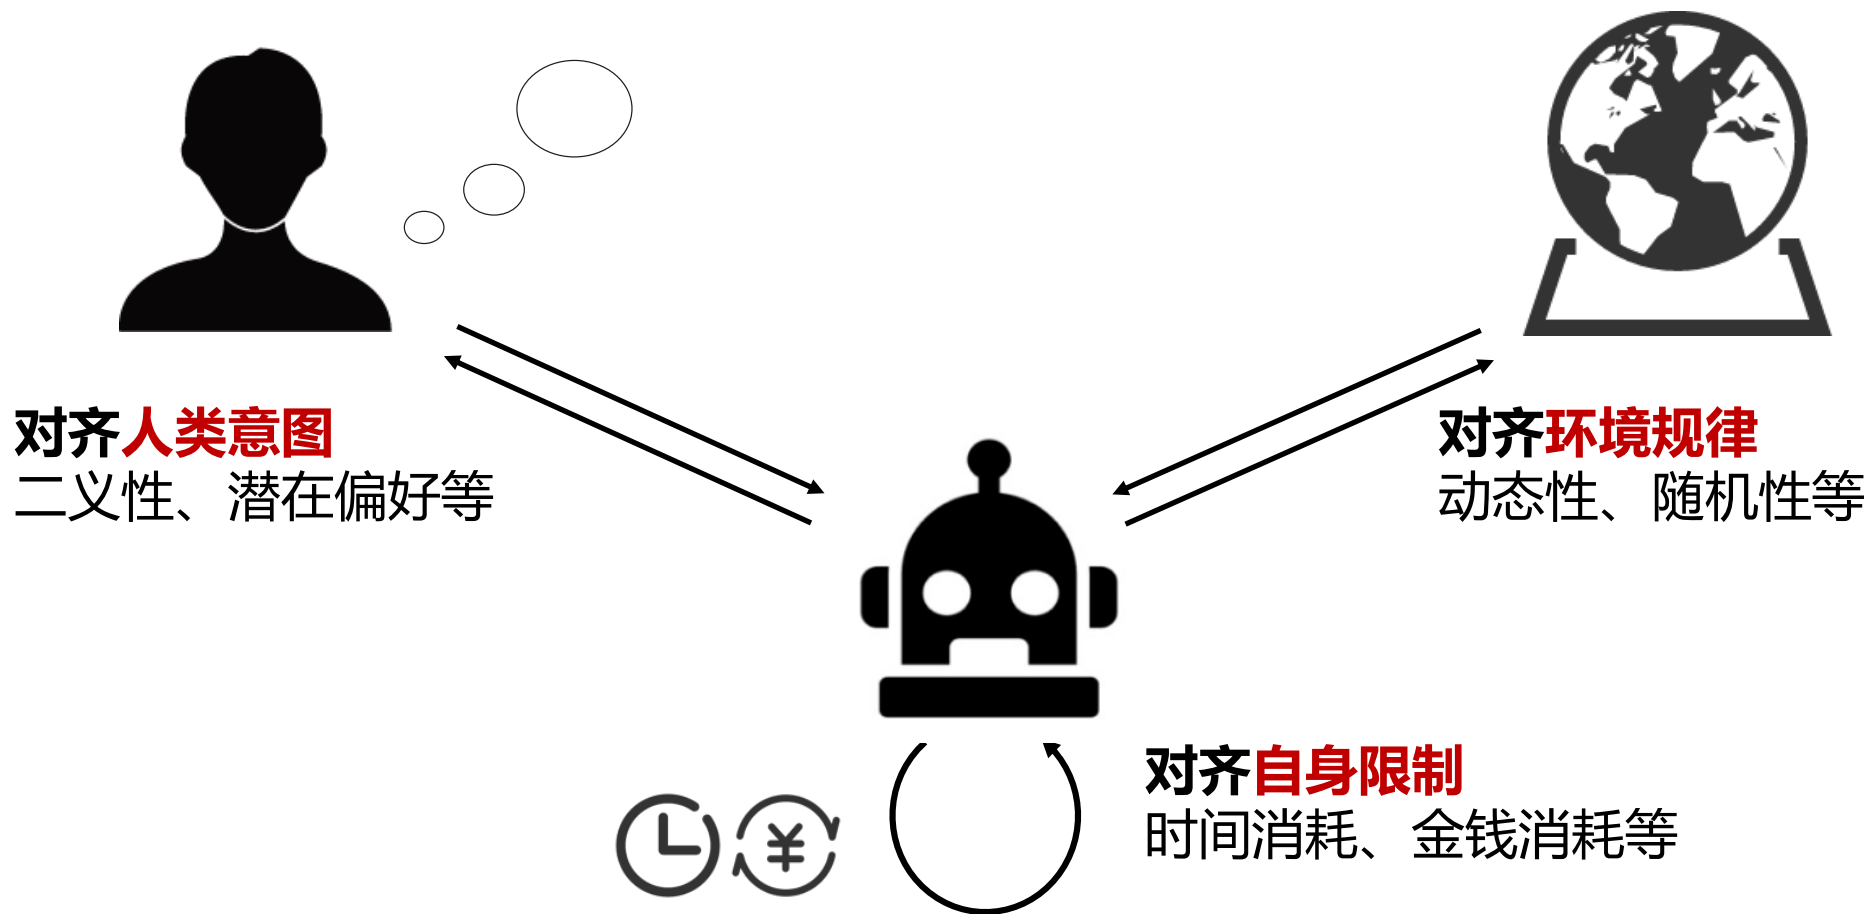
- 我们需要进一步设计针对 AI 科研系统的证伪流程。



展望：AIGS 需要遵循 UA² 对齐原则



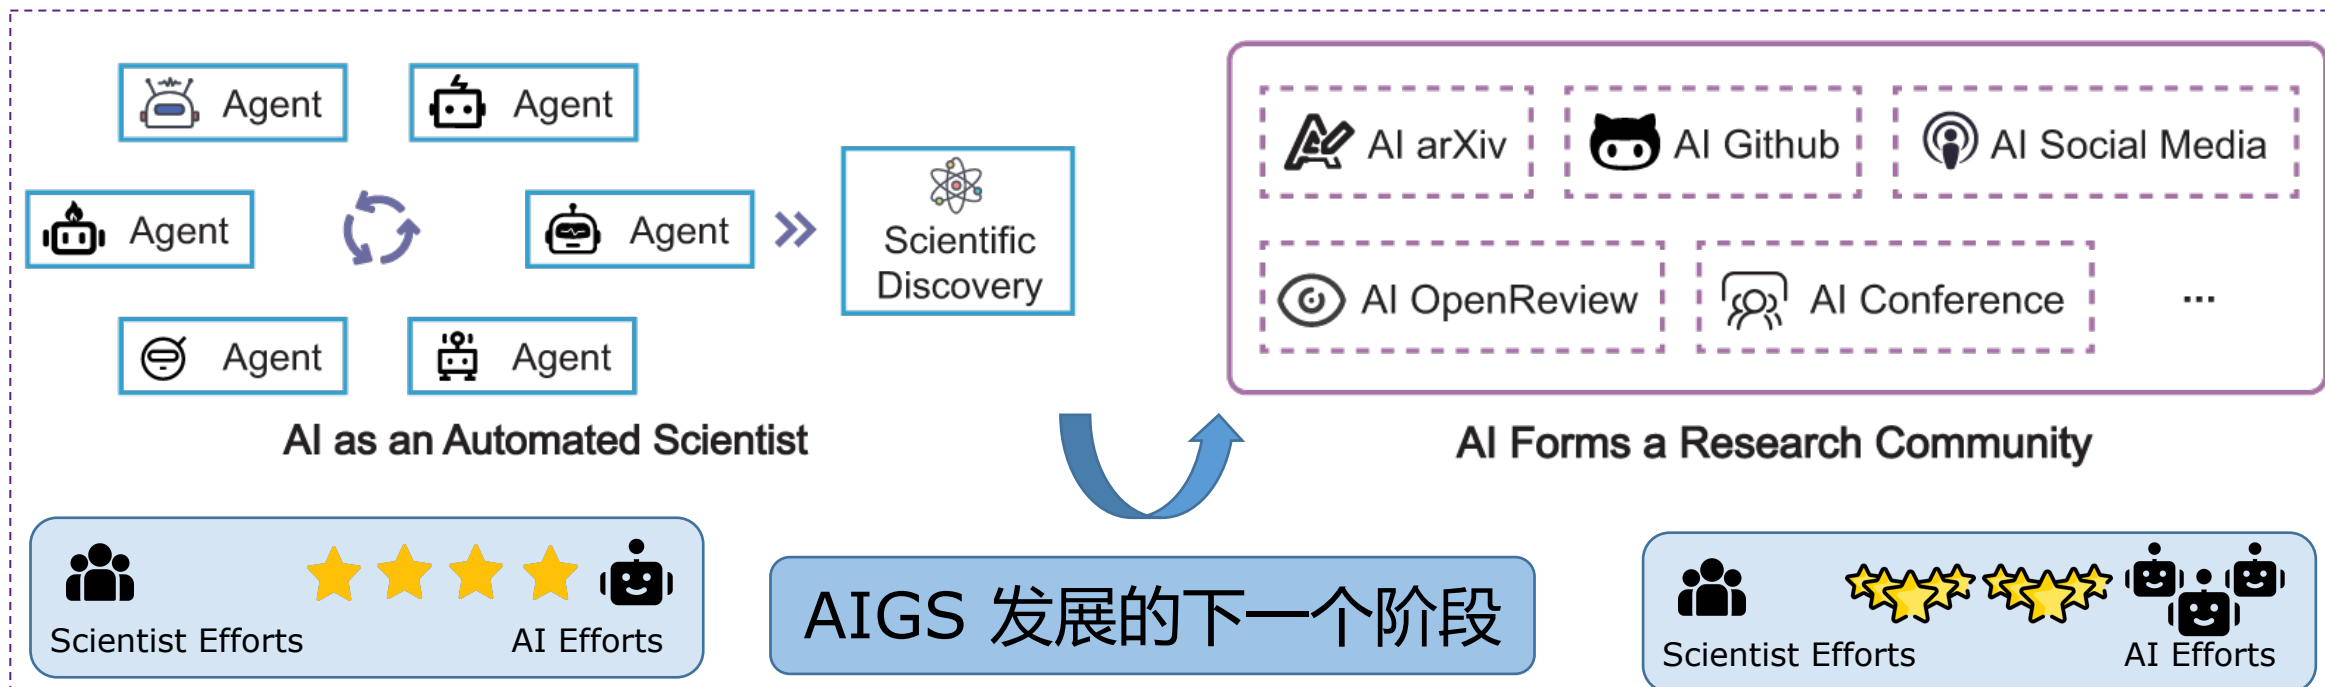
- AIGS 智能体需要和自身、人类、环境统一对齐。



展望：建立 AI 科学家社群



- 建立AI科学家社群，催化产生跨学科重大科学发展。

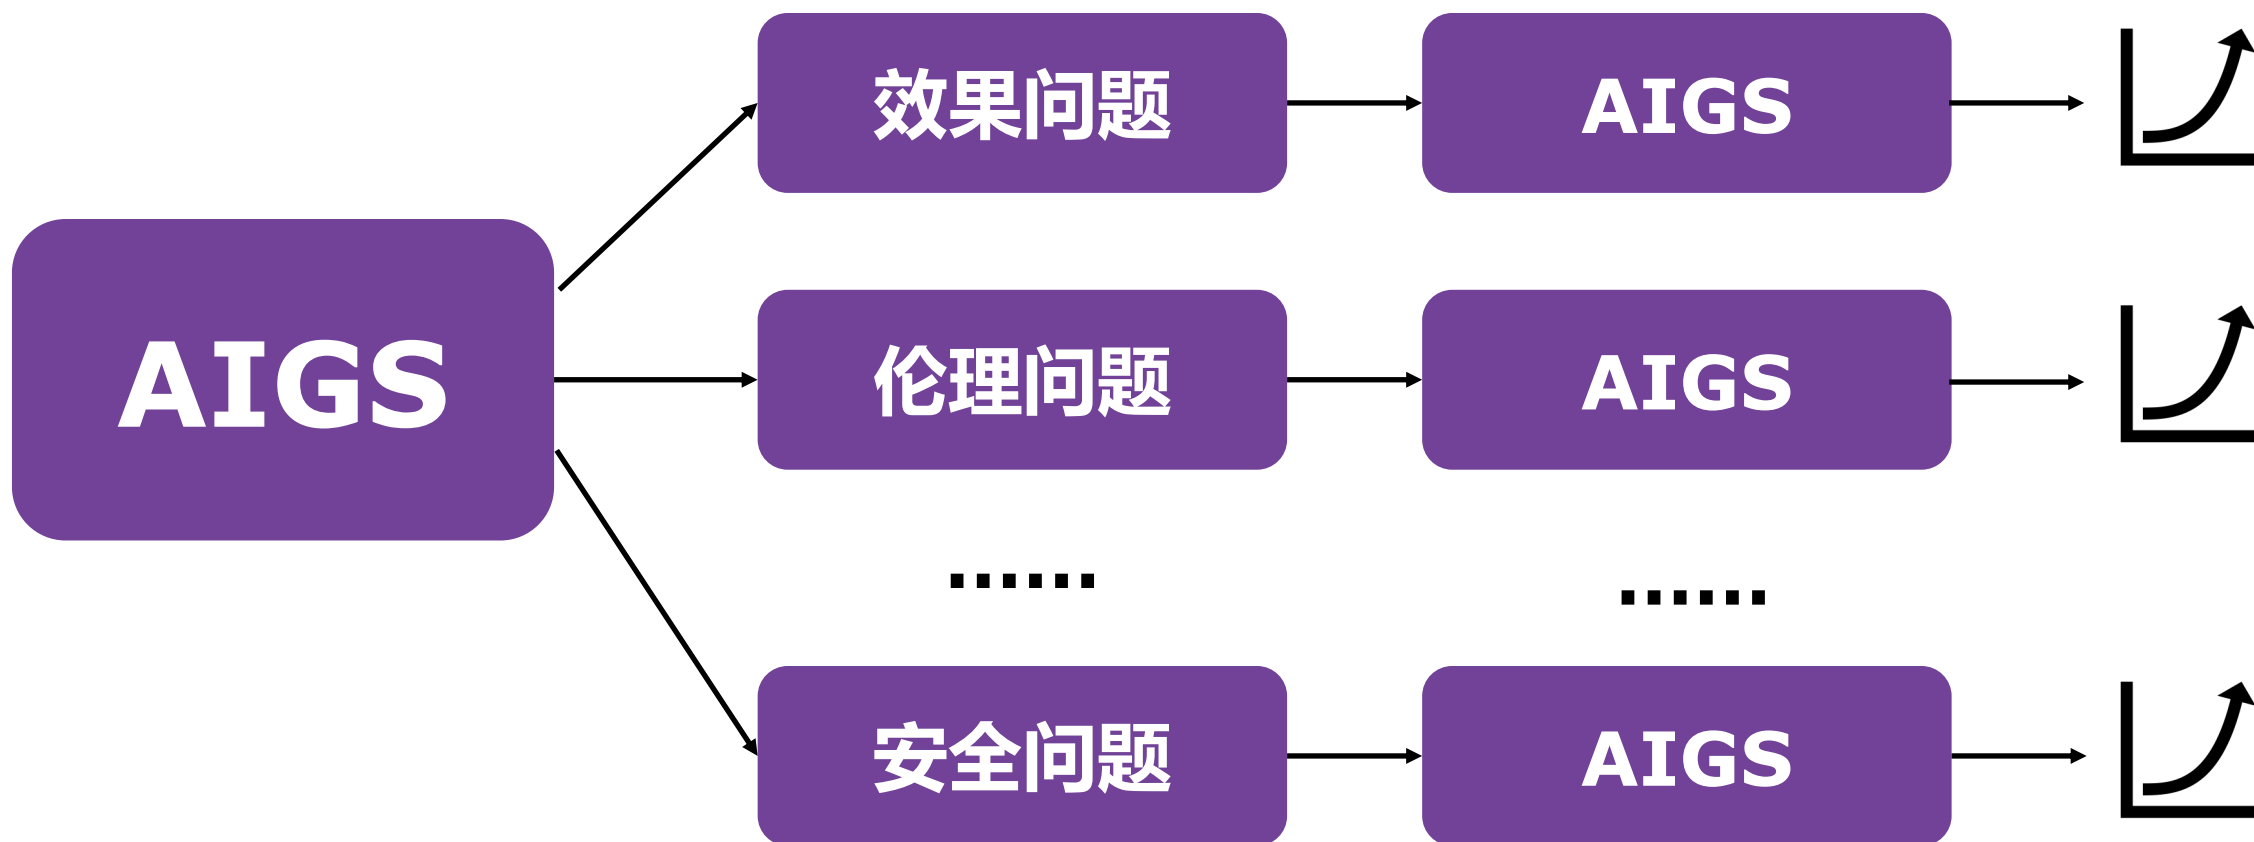


AI 科学家们也需要建立 AI 科学社群
建立高效的交流、合作和检验机制来激发群体智能

展望：AIGS for AIGS



- 利用AIGS来提升AIGS、解决AIGS自身面临的挑战。



主要成员



清华大学

Tsinghua University



李鹏



刘子君



刘铠铭



朱奕祺



刘洋



雷轩宇



杨宗瀚



张真赫

- **提出AIGS概念，即AI全自主作出的符合科学标准的科学发现。**
- **实现AIGS的核心原则是保证系统具备证伪能力、创造性和可执行性：**
 - **证伪 (Falsification) 是科学研究的核心；**
 - **创造性 (Creativity) 的想法是科学研究的起点；**
 - **可执行性 (Executability) 构成了证伪的基础。**
- **实现Baby-AIGS系统，具备自主证伪能力，初步验证AIGS的可行性。**
- **展望：未来符合AIGS定义的自主科研系统将成为推动科学发展重要力量。**



谢谢

